



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

**DESENVOLVIMENTO E APLICAÇÃO DE TECNOLOGIAS DE BAIXO CUSTO DE
SENSORIAMENTO REMOTO PARA AGRICULTURA DE PRECISÃO NO
SEMIÁRIDO NORDESTINO EM ÁREA DE PLANTIO DE PALMA FORRAGEIRA
IRRIGADA COM ÁGUA DE REÚSO**

MOISÉS ALVES DA SILVA NETO

Recife - Pernambuco

2024

MOISÉS ALVES DA SILVA NETO

**DESENVOLVIMENTO DE TECNOLOGIAS DE BAIXO CUSTO DE
SENSORIAMENTO REMOTO APLICADOS A AGRICULTURA DE PRECISÃO NO
SEMIÁRIDO NORDESTINO IRRIGADO COM ÁGUA DE REÚSO**

Dissertação apresentada ao Programa de Pós- Graduação em Engenharia Agrícola da Universidade Federal Rural de Pernambuco – UFRPE, como parte dos requisitos para obtenção do título de Mestre em Engenharia Agrícola.

Orientador: Prof. Dr. Abelardo Antônio de Assunção Montenegro

**Recife - Pernambuco
2024**

Dados Internacionais de Catalogação na
Publicação Sistema Integrado de Bibliotecas
da UFRPE Bibliotecário(a): Ana Catarina
Macêdo – CRB-4 1781

S586d Silva Neto, Moisés Alves da.

Desenvolvimento e aplicação de tecnologias de baixo custo desensoriamento remoto para agricultura de precisão no semiárido nordestino em área de plantio de palma forrageira irrigada com água de reúso / Moisés Alves da Silva Neto. — Recife, 2024.

135 f.

Orientador(a): Abelardo Antônio de Assunção Montenegro.

Dissertação (Mestrado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Engenharia Agrícola, Recife, BR-PE, 2024.

Inclui referências.

1. Biofísicos - Índices . 2. Monitoramento ambiental. 3. Drone. 4. Aprendizado do computador 5. Aeronaves não tripuladas. I. Montenegro, Abelardo Antônio de Assunção, orient. II. Título

CDD 630

MOISÉS ALVES DA SILVA NETO

**DESENVOLVIMENTO DE TECNOLOGIAS DE BAIXO CUSTO DE SENSORIAMENTO
REMOTO APLICADOS A AGRICULTURA DE PRECISÃO NO SEMIÁRIDO NORDESTINO
IRRIGADO COM ÁGUA DE REÚSO**

Dissertação apresentada à Universidade Federal Rural de Pernambuco, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de Mestre em Engenharia Agrícola.

DEFENDIDA em 23/07/2024.

Prof. Dr. Abelardo Antônio de Assunção Montenegro
(Orientador – Universidade Federal Rural de Pernambuco)

Prof. Dr. Fabrício Marcos Oliveira Lopes
(Examinador – Universidade Federal Rural de Pernambuco)

Prof. Dr. Pedro Rogério Giongo
(Examinador – Universidade Estadual de Goiás)

Prof. Dr. Rodrigo Gabriel Ferreira Soares
(Examinador – Universidade Federal Rural de Pernambuco)

Dedico este trabalho aos meus pais, Moisés Alves da Silva Júnior e Fabiana Cristina Almeida Silva, que sempre me ouviram, incentivaram e apoiaram com toda atenção ao longo dessa jornada. Dedico também a minha irmã Maria Júlia Almeida Silva e a minha namorada e companheira Maria Eloyse Gonçalves Luiz que me incentivaram e auxiliaram em toda essa jornada. Por fim, dedico a todos aqueles que contribuíram de qualquer forma para a execução deste projeto.

AGRADECIMENTOS

À Universidade Federal Rural de Pernambuco e ao Programa de Pós-graduação em Engenharia Agrícola pela oportunidade de estudos e pelos conhecimentos adquiridos.

Ao meu orientador, Professor Dr. Abelardo Montenegro, por toda a confiança, incentivo e

ensinamentos, que ajudaram muito no meu crescimento profissional e pessoal.

Aos professores e servidores que compõem o Programa de Pós-graduação em Engenharia

Agrícola.

À toda a equipe do Laboratório de Água e Solo (LAS) e Laboratório de Hidrologia, pela

parceria, motivação e prestatividade.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, que fomentou o projeto com o suporte oferecido no projeto Universal processo 420.488/2018-9 e com o projeto MAIDAI — Mestrado e Doutorado em Inovação, processo 403.488/2020-4 e pela bolsa fornecida através do processo 130846/2022-8.

À TPF Engenharia que incentivou a pesquisa tanto financeiramente com o projeto MAIDAI, quanto com saberes e tecnologias aplicadas ao longo de todo o projeto.

À COMPESA (Companhia Pernambucana de Saneamento) que contribuiu financeiramente e incentivando os avanços do projeto.

À FACEPE (Fundação de Amparo à Ciência e Tecnologia de Pernambuco) (processo APQ 0414-5.03/20 para o desenvolvimento da cadeia econômica pecuária no Estado de Pernambuco)

A todos que, direta ou indiretamente, colaboraram para a realização desse trabalho, deixo os meus sinceros agradecimentos.

Silva Neto, M. A. **Desenvolvimento de tecnologias de sensoriamento remoto aplicados a agricultura de precisão no semiárido nordestino irrigado com água de reúso.** 2024. XXXf. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal Rural de Pernambuco, Recife, Pernambuco, Brasil.

Resumo geral

A região semiárida brasileira possui recursos hídricos limitados, necessitando o uso de fontes alternativas de água para irrigação, como lençóis subterrâneos e reúso de efluentes. A avaliação de culturas irrigadas é crucial na agricultura de precisão para otimizar o uso de recursos. Historicamente, o sensoriamento remoto é caro para o monitoramento de pequenas áreas devido ao alto investimento associado a equipamentos aplicados, sendo possível aplicar sensoriamento remoto de baixo custo utilizando índices da banda de reflectância visível (RGB) e classificações de culturas de forma simplificada. O modelo de VANT aplicado foi o phantom 4 multiespectral com Real Time Kinematic (RTK) da DJI, onde as características de voo apresentadas foram de 40 metros de altura com porcentagem de recobrimento de 80% para as datas de 09 de outubro de 2023, 23 de fevereiro de 2024 e 06 de abril de 2024. O VANT phantom 4 captura dados de radiância, cujo são corrigidos através do painel calibrador de reflectância via software Agisoft Metashape. O monitoramento agrícola com índices que operam através da avaliação do teor de clorofila similares ao NDVI (Normalized Difference Vegetation Index) são avanços necessários. Neste caso, o algoritmo Gradiente Reduzido Generalizado (GRG) não linear foi aplicado com dados provenientes de uma área experimental em encosta do Vale Aluvial do Mimoso, em Pesqueira-PE, sendo um plantio de palma forrageira olheira de elefante mexicana (*Opuntia stricta* HAW.) irrigada com água de reúso com espaçamento de 0,5 metros entre linhas e 0,2 metros entre plantas aplicados no desenvolvimento de um índice de vegetação RGB intitulado aNDVI (Índice de Vegetação da Diferença Normalizada Alternativo). O aNDVI superou todos os outros índices avaliados, com coeficiente de correlação R^2 superiores a 0,85 e índice Nash Sutcliffe (NSE) acima de 0,84, demonstrando seu potencial para o monitoramento eficaz do uso e cobertura do solo, especialmente em condições variáveis de

umidade disponível entre os monitoramentos. No que tange a classificação de cultura e identificação de plantas invasoras, os algoritmos aplicados para classificação supervisionada GMM (Gaussian Mixture Model), KNN (K-Nearest Neighbors), RF (Random Forest), e SVM (Support Vector Machine) foram aplicados, apresentando resultados robustos devido a alta resolução espacial das imagens e a combinação das bandas, com índices, sendo aplicado o NDVI (Índice de Vegetação da Diferença Normalizada) para a análise multiespectral e o ANDVI (Índice de Vegetação da Diferença Normalizada Alternativo) para a análise RGB, onde o RF apresentou resultados melhores na presença de dados com ruídos e se comportou de forma similar ao SVM onde existiam menos ruídos, mas tendo menor custo computacional.

Palavras-chave: Índices biofísicos, Monitoramento ambiental , VANTs, Aprendizagem de máquina.

General abstract

The Brazilian semiarid region has limited water resources, requiring the use of alternative water sources for irrigation, such as underground aquifers and the reuse of effluents. The evaluation of irrigated crops is crucial in precision agriculture to optimize resource use. Historically, remote sensing has been expensive for monitoring small areas due to the high investment associated with the necessary equipment. However, low-cost remote sensing can be applied using indices from the visible reflectance band (RGB) and simplified crop classifications. The UAV model applied was the DJI Phantom 4 Multispectral with Real Time Kinematic (RTK), where the flight characteristics were 40 meters in altitude with an 80% overlap percentage for the dates of October 9, 2023, February 23, 2024, and April 6, 2024. The Phantom 4 UAV captures radiance data, which are corrected using a reflectance calibration panel via Agisoft Metashape software. Agricultural monitoring using indices that evaluate chlorophyll content, similar to the NDVI (Normalized Difference Vegetation Index), represents necessary advances. In this case, the Generalized Reduced Gradient (GRG) nonlinear algorithm was applied with data from an experimental area on the slopes of the Mimoso Alluvial Valley in Pesqueira-PE, with a plantation of Mexican Elephant Ear prickly pear (*Opuntia stricta* HAW.) irrigated with reused water, with spacing of 0.5 meters between rows and 0.2 meters between plants, applied in the development of an RGB vegetation index titled aNDVI (Alternative Normalized Difference Vegetation Index). The aNDVI outperformed all other indices evaluated, with correlation coefficients (R^2) above 0.85 and Nash Sutcliffe Efficiency (NSE) above 0.84, demonstrating its potential for effective monitoring of land use and cover, especially under varying moisture conditions between monitoring periods. Regarding crop classification and weed identification, the algorithms applied for supervised classification were GMM (Gaussian Mixture Model), KNN (K-Nearest Neighbors), RF (Random Forest), and SVM (Support Vector Machine). These algorithms provided robust results due to the high spatial resolution of the images and the combination of bands with indices, where NDVI was applied for multispectral analysis and aNDVI for RGB analysis. RF showed better results in the presence of noisy data and performed similarly to SVM in areas with less noise but with lower computational costs.

Keywords: Biophysical indices, Environmental monitoring, UAVs, Machine learning.

Sumário

Lista de Figuras	13
Lista de Tabelas	14
CAPÍTULO I	16
1. INTRODUÇÃO	16
2. HIPÓTESES	19
3. OBJETIVOS	19
3.1 Geral	19
3.2 Específico	20
4. FUNDAMENTAÇÃO TEÓRICA	20
4.1 Águas Subterrâneas e a sua importância para semiárido	20
4.2 Efeito das mudanças climáticas nos recursos subterrâneos e no abastecimento hídrico futuro da região semiárida	22
4.3 Reúso hidroagrícola	23
4.4 Sensoriamento Remoto	24
4.5 Índices Multiespectrais	25
4.6 Aprendizagem de máquina	29
5. REFERÊNCIAS	32
CAPÍTULO II	44
UM NOVO ÍNDICE DE BANDA VISÍVEL (ANDVI) PARA ESTIMAR VALORES DE NDVI EM IMAGENS VISÍVEIS (RGB) UTILIZANDO ALGORITMO DE SOLUÇÃO GRADIENTE REDUZIDO GENERALIZADO (GRG) NÃO LINEAR	44
1. INTRODUÇÃO	47
2. MATERIAL E MÉTODOS	50
2.1 Descrição da área de estudo	50
2.2 Sensoriamento remoto e cálculo dos índices vegetativos	51
2.3 Processamento das imagens	52
2.4 GRG Não Linear	53
2.5 Classificação de índices	55
2.6 Métricas de avaliação	56
3. RESULTADOS	57
3.1 Processamento das imagens	57

3.2 aNDVI	58
3.2.1 Análise dos índices multiespectrais	59
4. DISCUSSÃO	71
5. CONCLUSÃO	73
6. AGRADECIMENTOS	74
7. Referências	75
CAPÍTULO III	81
DETECÇÃO DE PLANTAS INVASORAS EM CULTIVO DE PALMA FORRAGEIRA IRRIGADA COM ÁGUA DE REÚSO: ALGORITMOS DE APRENDIZAGEM DE MÁQUINA APLICADAS EM IMAGENS GEORREFERENCIAS PRODUZIDAS POR VANTs NO SEMIÁRIDO PERNAMBUCANO	81
1. INTRODUÇÃO	84
2. MATERIAL E MÉTODOS	85
2.1 Descrição da área de estudo	86
2.2 Aquisição de imagens	87
2.3 Processamento das imagens	88
2.4 Algoritmos de aprendizagem de máquinas	89
2.5. Aplicação dos algoritmos	97
2.6. Amostras de treinamento	97
2.7. Métricas de análise	99
3. RESULTADOS	101
4. DISCUSSÃO	124
5. CONCLUSÃO	128
6. AGRADECIMENTOS	129
7. REFERÊNCIAS	129
CAPÍTULO IV	136
CONSIDERAÇÕES FINAIS	136

Lista de Figuras

CAPÍTULO II..... Error! Indicador Não Definido .

Figura 1. Mapa de localização (A), Solos vale do mimoso (B), Relevo vale do mimoso SRTM (C), Área experimental (D)	51
Figura 2. Fluxograma de aquisição de dados e processamento para obtenção do aNDVI	54
Figura 3. Imageamento 09/10/2023 (A) Imageamento 23/02/2024 (B) Imageamento 06/04/2024 (C) Modelo Digital de Elevação (D)	58
Figura 4. Correlação linear aNDVI vs NDVI e vNDVI vs NDVI	59
Figura 5. Correlação índices Vegetação	60
Figura 6. Frequência relativa acumulada dos dados amostrais de imageamentos de 09-10-2023; 23-02-2024 e 06-04-2024	61
Figura 7. Diagrama de caixa dos dados amostrais de imageamentos de 09-10-2023; 23-02-2024 e 06-04-2024	62
Figura 8. Índice NDVI e principais Índices da banda visível do imageamento do dia 09-10-2023 onde (A) NDVI; (B) aNDVI; (C) vNDVI; (D) NGRDI e (E) MGRVI	65
Figura 9. Índice NDVI e principais Índices da banda visível do imageamento do dia 23-02-2024 onde (A) NDVI; (B) aNDVI; (C) vNDVI; (D) NGRDI e (E) MGRVI	67
Figura 10. Índice NDVI e principais Índices da banda visível do imageamento do dia 06-04-2024 onde (A) NDVI; (B) aNDVI; (C) vNDVI; (D) NGRDI e (E) MGRVI	69

CAPÍTULO III..... Error! Indicador Não Definido .

Figura 1. Mapa de localização (A), Solos vale do Mimoso (B), Relevo vale do Mimoso SRTM (C), Área experimental (D)	87
Figura 2. Fluxograma Algoritmo GMM aplicado a classificação	91
Figura 3. Fluxograma Algoritmo KNN	93
Figura 4. Fluxograma Algoritmo RF	94
Figura 5. Fluxograma Algoritmo SVM	96
Figura 6. Mapa de localização Vale aluvial do mimoso e informações agroclimatológicas do ano anterior ao último imageamento	98
Figura 7. Precipitação acumulada ao longo de 90 dias antecedentes aos imageamentos.	101
Figura 8. Classificação multiespectral de outubro de 2023, GMM(A), KNN(B),	

RF (C) e SVM (D)	104
Figura 9. Classificação RGB de outubro de 2023, GMM(A), KNN(B), RF (C) e SVM (D)	108
Figura 10. Classificação multiespectral de fevereiro de 2024, GMM(A), KNN(B), RF (C) e SVM (D)	111
Figura 11. Classificação RGB de fevereiro de 2024, GMM(A), KNN(B), RF (C) e SVM (D)	115
Figura 12. Classificação multiespectral em abril de 2024, GMM(A), KNN(B), RF (C) e SVM (D)	118
Figura 13. Classificação RGB de abril de 2024, GMM(A), KNN(B), RF (C) e SVM (D)	122

Lista de Tabelas

CAPÍTULO II..... Error! Indicador Não Definido .

Tabela 1. Comprimento de onda do sensor multiespectral	52
Tabela 2. Índices de vegetação aplicados para índices biofísicos	55
Tabela 3. Métricas de erro dos índices com melhores estimativas do NDVI. ...	63
Tabela 4. Estatística descritiva outubro 2023	66
Tabela 5. Estatística descritiva fevereiro 2024	68
Tabela 6. Estatística descritiva abril 2024	70

CAPÍTULO III..... Error! Indicador Não Definido .

Tabela 1. Comprimento de onda do sensor multiespectral	88
Tabela 2. Classificação do índice kappa adaptado de Landis e Koch (1977). 100	
Tabela 3. Estatísticas espectrais das amostras aplicadas para classificação. 102	
Tabela 4. Matrizes de confusão das classificações multiespectrais de outubro de 2023.	105
Tabela 5. Avaliação das métricas aplicadas aos classificadores em imagens multiespectrais em outubro de 2023	106
Tabela 6. Matrizes de confusão das classificações RGB de outubro de 2023	108
Tabela 7. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de outubro de 2023.	109
Tabela 8. Matrizes de confusão das classificações multiespectrais de fevereiro de 2024	112
Tabela 9. Avaliação das métricas aplicadas aos classificadores em imagens	

RGB para o mês de fevereiro de 2024	113
Tabela 10. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de fevereiro de 2024	115
Tabela 11. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de fevereiro de 2024	117
Tabela 12. Matrizes de confusão das classificações multiespectrais de abril de 2024	119
Tabela 13. Avaliação das métricas aplicadas aos classificadores em imagens multiespectrais em abril de 2024	120
Tabela 14. Matrizes de confusão das classificações RGB de abril de 2024 ...	122
Tabela 15. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de abril de 2024.	123

CAPÍTULO I

1. INTRODUÇÃO

Para garantir uma gestão adequada dos recursos hídricos de uma bacia hidrográfica, é imprescindível compreender os processos hidrológicos, o que requer disponibilidade de dados confiáveis e a manutenção constante da rede de monitoramento (CHAGAS et al., 2021; SOUSA et al., 2023). A conservação e a gestão dos recursos hídricos tornam-se mais relevantes em regiões semiáridas e susceptíveis à desertificação. Dentre as práticas conservacionistas da umidade do solo, a cobertura morta é particularmente relevante para regiões semiáridas, uma vez que ela promove a infiltração da água no solo e otimiza a utilização da água da chuva (MONTENEGRO et al., 2013; CARVALHO et al., 2021), assim como os barramentos de palma (MONTENEGRO et al., 2020).

A substituição da vegetação nativa por cultivos agrícolas pode ter efeitos significativos na estrutura e fertilidade do solo, resultando em degradação ambiental. Isso ocorre quando técnicas de manejo inadequadas são empregadas ou quando áreas inadequadas para agricultura são cultivadas. Como consequência, ocorre uma redução progressiva na capacidade produtiva do solo e uma deterioração da qualidade da água devido à acumulação de sedimentos e poluentes (BLAINSKI et al., 2017).

A escassez de água e a distribuição irregular das chuvas têm impactado a produção agrícola em áreas semiáridas. A reutilização da água para irrigação é uma alternativa promissora, mas requer manejo adequado. As plantas forrageiras são importantes nessas regiões devido à sua resistência e uso como alimento animal. A cobertura do solo aumentou a produtividade em 24%, controlando a salinidade e contribuindo com a matéria orgânica. A irrigação com água tratada não afetou negativamente o solo devido às chuvas naturais que permitiram a lixiviação de sais (CARVALHO et al., 2021)

A utilização de efluentes domésticos na irrigação e o uso de lodo de esgoto e cobertura morta para fins hidroagrícolas beneficiaram a produção dos cultivos. O uso desses recursos como fonte de nutrientes e para preservar a umidade do solo teve efeitos positivos na produtividade das plantações. A aplicação de cobertura morta resultou em distribuição mais uniforme da umidade no solo, sendo crucial para a obtenção de massa verde, com reaproveitamento de efluentes domésticos. O manejo adequado da irrigação, a adoção de práticas conservacionistas, a ocorrência de chuvas intensas e a presença de um sistema de drenagem subterrânea contribuíram para controlar os níveis de sais no solo, preservando sua capacidade produtiva e sua sustentabilidade em relação à condutividade elétrica e à sodicidade (CARVALHO et al., 2020).

Os dados de sensoriamento remoto, especialmente aqueles obtidos por Veículos Aéreos Não Tripulados (VANTs) equipados com sensores espectrais avançados, são amplamente utilizados na agricultura para identificar problemas nas lavouras. Esses sensores coletam dados de radiância espectral, posteriormente transformada em reflectância espectral de áreas vegetadas, calculando índices de vegetação com base na reflectância das diferentes bandas espectrais, incluindo as relacionadas às cores vermelha, verde e infravermelha próxima. Essas informações são essenciais para a agricultura de precisão, pois fornecem dados valiosos sobre as plantas de maneira eficiente e precisa (ISHIDA et al., 2018; LIMA, JORGE, LIMA, 2021).

O uso crescente de Veículos Aéreos Não Tripulados (VANTs) na agricultura se deve ao avanço da tecnologia desses equipamentos. Esses robôs móveis se tornaram uma opção de baixo custo para a detecção e análise de dados. Com diferentes tipos disponíveis, os VANTs de baixo custo podem coletar dados de alta resolução em várias áreas. Embora ainda não sejam amplamente utilizados na agricultura de precisão, os VANTs desempenham um papel cada vez mais ativo no campo, promovendo práticas agrícolas sustentáveis e maior lucratividade. Além disso, sua utilização reduz a necessidade de recursos humanos e oferece medições

precisas. Quando os dados obtidos pelos VANTs são avaliados e interpretados corretamente, podem contribuir para o aumento da produção agrícola e da produtividade (ASLAN et al., 2022).

A agricultura inteligente utiliza tecnologias de informação e comunicação para aprimorar a administração da agricultura, aumentando a qualidade dos produtos. Sensores precisos coletam dados sobre nutrientes do solo, água, luz, umidade e temperatura, que são analisados por algoritmos avançados para ajudar na tomada de decisões, onde estudos recentes mostram que algoritmos de aprendizado profundo são úteis para identificar plantas e detectar problemas em plantações. Os algoritmos podem ter variação na sua eficiência de acordo com o nível de processamento da máquina usada, obtendo melhores resultados em hardwares mais potentes (MAMANI DIAZ, MEDINA CASTANEDA, MUGRUZA VASSALLO, 2019).

Recentemente, o aprendizado profundo, uma subárea do campo de aprendizado de máquina, tem se destacado como uma ferramenta poderosa para abordar problemas por meio do aprendizado a partir de dados. Esse avanço tem sido impulsionado pela disponibilidade de conjuntos de dados massivos, melhorias no poder computacional, armazenamento rápido de dados e o desenvolvimento de novos algoritmos de treinamento para redes neurais profundas. Como resultado, o aprendizado profundo tem despertado um interesse crescente e ganhado atenção significativa (ZUO et al., 2022).

Foi possível detectar precocemente plantas indesejadas em meio ao cultivo de culturas por meio da aplicação de métodos de classificação de culturas com VANTs. O método foi aplicado especificamente ao cultivo de milho, utilizando o modelo de análise de imagem baseada no objeto (OBIA) para a discriminação automática de linhas de cultivo e plantas daninhas em imagens remotas georreferenciadas com resolução espacial de 2 cm. Através da combinação de imagens remotas de VANTs com alta resolução espacial e o procedimento OBIA desenvolvido, foi possível gerar mapas de plantas daninhas em cultivos de milho no início da temporada. Esses mapas são úteis para o planejamento da aplicação de

medidas de controle de plantas daninhas durante o crescimento das culturas. Anteriormente, essa aplicação não era possível com imagens tradicionais de satélite ou de aeronaves (PEÑA et al., 2013). A classificação de vinhedos é essencial para a viticultura, permitindo a detecção da vegetação e o gerenciamento eficiente. Dados aéreos obtidos por VANTs foram usados para classificar elementos em vinhedos em quatro classes. O uso de características de dados RGB e multiespectrais melhorou a classificação, especialmente quando combinadas. Esses métodos podem ser aplicados não apenas em vinhedos, mas também em outras áreas de classificação de uso da terra (PÁDUA et al., 2022).

O uso de Veículos Aéreos Não Tripulados (VANTs) e técnicas de sensoriamento remoto permite obter dados detalhados sobre campos agrícolas. Esses dados são úteis para entender a variação espacial e as diferenças nos campos. Os VANTs capturam imagens em alta resolução, o que ajuda a avaliar a vegetação, o solo e até mesmo prever doenças em culturas.

2. HIPÓTESES

O sensoriamento remoto pode ser usado para estimar índices de vegetação, possibilitando a identificação e remediação precoce de alterações de saúde da vegetação.

A aplicação dos índices e dos dados coletados podem ser utilizados para indicar o vigor vegetativo das culturas, assim como poderá ser aplicado na classificação da palma forrageira, da cobertura morta e de plantas invasoras.

3. OBJETIVOS

3.1 Geral

Aplicar técnicas de sensoriamento remoto capazes de investigar o vigor vegetativo de culturas forrageiras irrigadas com água de reúso no semiárido pernambucano.

3.2 Específico

- Desenvolver índices de vegetação RGB capazes de estimar o vigor vegetativo da palma forrageira no semiárido pernambucano;
- Classificar o uso e ocupação do solo utilizando tecnologias de aprendizado de máquina;
- Identificar presença de plantas invasoras em meio a cultivo de forrageiras.

4. FUNDAMENTAÇÃO TEÓRICA

4.1 Águas Subterrâneas e a sua importância para semiárido

No semiárido, o clima provoca déficits hídricos severos devido às escassas precipitações e alta evapotranspiração (MONTENEGRO & RAGAB, 2010). A área depende intensamente da exploração de aquíferos aluviais para suprir a demanda das populações dispersas e práticas de irrigação em pequena escala, devido ao déficit hídrico predominante na maior parte do ano. No entanto, esses aquíferos são suscetíveis ao acúmulo de sais, tanto na zona não-saturada quanto na saturada (MONTENEGRO & MONTENEGRO, 2006; MONTEIRO et al., 2014).

A exploração excessiva de água subterrânea para fins agrícolas nas últimas décadas tem gerado sérios problemas. Ribeiro et al. (2015) observaram que a irrigação no baixo de Elqui, Chile, produziu fluxos de retorno que alteraram quantitativa e qualitativamente as águas subterrâneas. Além disso, um aumento na eficiência dos sistemas de irrigação modifica a recarga do aquífero e seu equilíbrio. O aumento do bombeamento de aquíferos pode levar ao seu esgotamento, afetando a relação rio-aquífero. As mudanças climáticas, como a redução das chuvas, também impactam negativamente a recarga dos aquíferos (PENÃ-ARANCIBIA et al., 2020; COELHO et al., 2017).

Apesar das vantagens do uso das águas dos vales aluviais no semiárido, esse recurso é limitado e tem sofrido degradações qualitativas e quantitativas nas últimas décadas, causadas por impactos antropogênicos (superexploração e poluição) e naturais (tipo de clima e aquecimento global) (BAHIR et al., 2020). A

exploração das águas subterrâneas requer um balanço hídrico que promova um equilíbrio entre a taxa de recarga e de extração, evitando a exaustão do aquífero por meio de uma gestão adequada (ALBUQUERQUE et al., 2015).

As águas subterrâneas constituem um recurso essencial para o fornecimento público e agrícola, conectado a outros elementos do ciclo hidrológico e reabastecido pela infiltração de chuvas, lixiviação ou águas superficiais (HAAS & BIRK, 2019). Em diversas regiões do mundo, especialmente em áreas áridas e semiáridas, este recurso é frequentemente a única fonte de água perene disponível, desempenhando um papel crucial no abastecimento de famílias e cidades durante a estação seca (COELHO et al., 2017).

A qualidade da água subterrânea é tão importante quanto sua quantidade para atender às necessidades hídricas (RUSLI et al., 2023). Reddy et al. (2019) constataram que a qualidade das águas subterrâneas varia no espaço e no tempo, além de sofrer influência da profundidade do aquífero e do tipo de rocha presente na área. Kumar et al. (2007) também destacam a importância de monitorar essas variações para definir padrões de uso e evitar problemas de manejo inadequado das águas de irrigação.

Fatores antropogênicos que afetam a qualidade das águas incluem mudanças no uso e ocupação do solo e despejos inadequados de efluentes urbanos (SAMANTARA et al., 2017; KAWO & KARUPPANNAN, 2018). A agricultura também pode contaminar as águas subterrâneas devido ao uso extensivo de produtos químicos, como pesticidas, inseticidas e fertilizantes, que alteram suas características químicas (ELTARABILY et al., 2018).

O gerenciamento eficaz e sustentável da água exige compreender as variações espaciais na qualidade das águas subterrâneas e seus fatores de controle (MASOUD et al., 2018). No caso dos aquíferos aluviais, o uso do solo agrícola nas encostas tem impacto direto na quantidade e qualidade das águas subterrâneas (ALMEIDA et al., 2024).

Dentre as atividades agrícolas nas encostas pode-se verificar cultivos de sequeiro e irrigado, sendo frequente o plantio de palma forrageira para alimentação animal.

4.2 Efeito das mudanças climáticas nos recursos subterrâneos e no abastecimento hídrico futuro da região semiárida

A seca é um fenômeno natural recorrente que pode ocorrer em qualquer zona climática. Os impactos da seca não se restringem apenas às crises regionais de água, mas podem acarretar significativas consequências sociais, econômicas e ambientais (VAZIFEHKHAH & KAHYA, 2019). Devido às mudanças climáticas, espera-se que as secas se tornem mais frequentes e intensas (YACOUB & TAYFUR, 2020). Assim, os efeitos da variabilidade climática sobre os recursos hídricos têm sido foco de estudos críticos para aprimorar a gestão da água em escala local (VELASCO et al., 2017).

No Nordeste brasileiro, as secas historicamente registradas variam desde períodos curtos de um ano até mais de sete anos consecutivos, provocando inúmeras mortes de pessoas e animais ao longo da história. Entretanto, esses eventos têm se intensificado nos últimos anos, levando a uma maior investigação sobre os efeitos das mudanças climáticas.

O Projeto de Intercomparação de Modelos Acoplados - Fase 5 (CMIP5) elaborou quatro cenários de mudanças climáticas, representando diferentes níveis de forças radiativas naturais e antropogênicas até o final do século 21, denominadas Vias de Concentração Representativas (RCPs). As RCPs descrevem as mudanças nas entradas e saídas de radiação na atmosfera, causadas por alterações nos componentes atmosféricos, como o dióxido de carbono (MOSS et al., 2010). A RCP 2.6 representa um nível baixo de força radiativa (até $2,6 \text{ Wm}^{-2}$), as RCPs 4.5 e 6.0 representam cenários de estabilização média ($4,5$ e $6,0 \text{ Wm}^{-2}$), enquanto a RCP 8.5 corresponde a um cenário de alta emissão ($8,5 \text{ Wm}^{-2}$) (MEINSHAUSEN et al., 2011; TAYLOR et al., 2012; TAN et al., 2017). Esses cenários também indicam aumentos na temperatura atmosférica até 2100, como, por exemplo, aquecimentos entre 1,1 e

2,6 °C na RCP 4.5 e entre 2,6 e 4,8 °C na RCP 8.5 (IPCC, 2013).

Segundo Tesfaye et al. (2019), o efeito combinado das mudanças nos padrões de precipitação com o aumento das temperaturas pode impactar negativamente a disponibilidade hídrica e aumentar a incidência de secas. Como resultado, os recursos hídricos podem ser temporariamente estressados em algumas regiões, especialmente sob condições de seca, e futuras mudanças no clima, uso da terra e gestão da água podem potencialmente ter efeitos adversos tanto na reposição quanto na exploração dos recursos hídricos subterrâneos, exacerbando o estresse hídrico. Para mitigar os impactos hidrológicos e utilizar os recursos hídricos de maneira sustentável, é crucial compreender as consequências da variabilidade climática nas respostas hidrológicas.

4.3 Reúso hidroagrícola

Uma estratégia para minimizar a escassez qualitativa e quantitativa de recursos hídricos, na região semiárida, para produção agrícola é o uso de água residuária, possibilitando atividade agropecuária mesmo em situação de secas, que por sua vez, estão mais recorrentes. A utilização de águas residuárias tratadas pode garantir disponibilidade hídrica para a agricultura irrigada, destinando a água de boa qualidade para usos mais nobres (POHL & LENZ, 2017).

O uso de efluentes tratados na agricultura irrigada vem sendo considerado uma alternativa essencial para uso eficiente da água, além de garantir a sustentabilidade dos sistemas ambientais, já que minimiza o volume de efluentes descarregados nos corpos hídricos (CARVALHO et al., 2020). Entretanto, Cavalcante et al. (2016) destacam a importância do acompanhamento e monitoramento da qualidade do solo e da água, para evitar a salinização e a inviabilização das áreas de cultivo com o uso de efluentes domésticos tratados.

O manejo inadequado da aplicação dos efluentes domésticos na irrigação pode resultar em diversos impactos ambientais, como a lixiviação de sais para as águas subterrâneas e salinização do solo (DE LIRA et al., 2015). O descarte

incorreto de efluentes doméstico tratados no solo aumenta a disponibilidade de nutrientes, e as concentrações de sais, elevando a condutividade elétrica do solo e reduzindo a capacidade das plantas em absorver água e nutrientes, o que acaba causando impactos negativos em fatores microbiológicos, como redução do estoque de carbono, e compromete a qualidade produtiva do solo (OFORI et al., 2021).

4.4 Sensoriamento Remoto

O sensoriamento remoto é uma técnica que permite a obtenção de informações sobre objetos sem a necessidade de contato físico com eles, sendo as informações obtidas de sensores, equipamentos de processamento de dados, entre outros, para estudar o ambiente terrestre por meio do registro e análise das interações entre a radiação eletromagnética e as diferentes coberturas da superfície terrestre. Para a agricultura, essa técnica oferece informações sobre a estimativa de área plantada, produção agrícola, modelos agrometeorológicos e fornece subsídios para o manejo agrícola em nível nacional, estadual, municipal ou mesmo em nível de bacia hidrográfica (DE SOUZA, AQUINO, DE QUEIROZ, 2020).

Essa técnica usa a energia eletromagnética para avaliar as características da Terra e pode ser usada para monitorar os recursos naturais, incluindo a agricultura. Os dados coletados podem ser usados para monitorar o crescimento das culturas, alterações no uso da terra, recursos hídricos, doenças e infestações de pragas, previsão de colheitas, agricultura de precisão e previsão do clima (SHANMUGAPRIYA et al., 2019).

O Sensoriamento Remoto (SR) tem avançado com o uso de Veículos Aéreos não Tripulados (VANTs). Esses VANTs permitem um controle preciso das condições de voo, resultando em melhorias na qualidade das informações adquiridas. O processamento digital de imagens de VANTs possibilita a obtenção de variáveis físicas da superfície, como o Índice de Vegetação por Diferença Normalizada (NDVI) e a temperatura da superfície. O NDVI tem sido amplamente aplicado em imagens de VANT para estudos ambientais, incluindo análise de áreas agrícolas e

monitoramento de pastagens. O uso de VANTs é uma ferramenta promissora para o estudo da vegetação e análise de uso e cobertura da terra, especialmente em biomas como a caatinga, onde os estudos ainda são limitados (SANTOS et al., 2021).

VANTs são valorizados por seu baixo custo, alta resolução, flexibilidade e segurança, enquanto algoritmos de IA, especialmente o aprendizado profundo, se destacam pela capacidade de analisar grandes volumes de dados de forma semi-automática, graças aos avanços da computação (SU et al., 2023). Equipados com uma variedade de câmeras especializadas e algoritmos, os dados coletados por VANTs permitem ao usuário gerar uma série de relatórios úteis sobre uma grande área de forma eficaz, como análise de índices de vegetação, mapeamento hidrológico, avaliação de estresse, mapeamento de doenças e monitoramento de ervas daninhas (PHANG et al., 2023).

A informação prévia sobre produção de colheitas é crucial para o planejamento nacional de alimentos. A previsão precisa do rendimento agrícola é importante e depende de vários fatores, incluindo a variedade da colheita, o status de água e nutrientes do solo, a presença de ervas daninhas, pragas e doenças, bem como os parâmetros meteorológicos. A curva de resposta espectral reflete esses fatores e pode indicar o desempenho da colheita (MENON, 2012).

4.5 Índices Multiespectrais

Imagens multiespectrais devem ser convertidas em dados de reflectância por meio da calibração radiométrica para serem usadas na interpretação ou no cálculo de índices de vegetação. A calibração radiométrica é uma barreira tecnológica significativa para o uso de VANTs em sensoriamento remoto. Existem várias abordagens para essa calibração, mas apenas algumas estão disponíveis em softwares comerciais ou de código aberto (DANIELS et al., 2023).

O desenvolvimento de imagens de baixa altitude requer técnicas de correção

específicas para imagens de VANTs, focando na redução de ruídos e erros de detecção devido à baixa altitude. Embora a correção atmosférica e solar seja frequentemente negligenciada, estudos recentes destacam sua importância, especialmente em condições desfavoráveis. A correção solar e topográfica é necessária para reduzir a iluminação desigual. A calibração radiométrica é crucial para converter dados digitais em unidades físicas utilizáveis no sensoriamento remoto (JENEROWICZ; WIERZBICKI; KEDZIERSKI, 2023).

O Índice de Vegetação por Diferença Normalizada (NDVI) é o mais amplamente utilizado, como o índice é calculado por meio de um procedimento de normalização, a faixa de valores do NDVI está entre -1 e 1, tendo uma resposta sensível para a vegetação verde, mesmo para áreas cobertas por vegetação baixa. O NDVI é um indicador que está relacionado à densidade da cobertura vegetal, e valores mais próximos de +1 indicam uma maior densidade, onde o NDVI responde com rapidez ao aumento de água disponível para as plantas. Isso ocorre porque o NDVI é ligado a quantidade e clorofila que aumenta significativamente com a disponibilidade hídrica em regiões secas (SILVA NETO et al., 2022).

O Índice de Vegetação por Diferença Normalizada (NDVI) enfrenta limitações significativas devido à saturação e aos efeitos de sombras nas imagens. A saturação do NDVI ocorre quando os valores do índice atingem um platô, dificultando a distinção entre áreas de alta densidade de vegetação. Além disso, a presença de sombras nas imagens pode distorcer os valores do NDVI, resultando em estimativas imprecisas. Essas sombras podem ser causadas por variações no relevo, estrutura das plantas ou condições de iluminação, complicando a interpretação precisa dos dados de vegetação. (XU et al., 2023)

O SAVI foi estabelecido como um modelo de solo-vegetação para melhorar a sensibilidade do NDVI em relação ao solo, utilizando o índice de condicionamento do solo (L). A variação de L é de 0 a 1 e seus valores são determinados pela cobertura vegetal, quando a cobertura vegetal é alta, L se aproxima de 1 e quando não há

cobertura, L se aproxima de 0 onde o valor de SAVI é igual ao NDVI. Na natureza, normalmente se utiliza o valor de L igual a 0,5, mas vale ressaltar a que o fator L deve variar inversamente com a quantidade de vegetação presente para obter o ajuste ideal para o efeito do solo (HUETE, 1988).

O Índice de Área Foliar (IAF) é um parâmetro ecofisiológico crucial para avaliar a saúde e o crescimento das plantas ao longo do tempo. Ele representa a relação entre a área de superfície foliar e a cobertura do solo em uma unidade de área, refletindo as trocas de gases nas folhas e indicando o potencial de crescimento, desenvolvimento e rendimento das plantas. O IAF é amplamente utilizado em modelos de crescimento de culturas para otimizar as decisões de manejo, abordando incertezas como erosão do terreno, problemas de carbono orgânico do solo e impactos das mudanças climáticas. Além disso, o IAF está associado ao balanço hídrico, balanço de carbono, interceptação de luz, evapotranspiração e fluxos de CO₂. Sua análise é de grande importância em estudos relacionados à fisiologia das plantas, melhoramento genético e estrutura vegetativa (LI et al., 2022).

O NDWI é um índice que maximiza a reflectância da água usando comprimentos de onda verdes, minimizando a reflectância baixa do NIR causada pela água e aproveitando a alta reflectância do NIR por vegetação e solo. No entanto, em áreas urbanizadas, o NDWI pode produzir ruído e confundir características da água com as da terra. Para resolver esse problema, foi desenvolvido o MNDWI, que substitui a banda NIR pela banda MIR, resultando em valores negativos para áreas urbanizadas e maior contraste entre a água e a terra. O NDWI proposto por Gao é um índice diferente usado para detectar a presença de água em vegetação e pode ser renomeado como NDMI de Wilson para evitar confusão com o NDWI de McFeeters (XU, 2006).

A criação de mapas de salinidade do solo através de dados de sensoriamento remoto é um processo difícil, devido ao fato da salinização não ser um processo estático. Por essa razão, foram propostas diversas alternativas e derivados ao índice de vegetação de diferença normalizada, a fim de abordar o monitoramento e

mapeamento da salinização do solo, sendo o índice de salinidade de diferença normalizada (NDSI) uma alternativa aplicada em ambientes áridos para detecção de salinidade (ELHAG, 2016). Outra aplicação de sensoriamento remoto indicou que o Índice de Vegetação de Diferença Generalizada (GDVI) onde $n = 2$, possuiu uma boa correlação com a indicação de salinidade aplicando o índice ao sensor do Sentinel -2 obtendo um coeficiente de determinação R^2 de 0,783 (SILVA et al., 2021).

O Índice de Vegetação de Diferença de Banda Visível (VDVI) foi criado para ser um método simplificado, rápido e eficaz para extrair informações de vegetação a partir de imagens visíveis. Para atingir esse objetivo, foram analisadas as características espectrais das plantas verdes saudáveis e as características espectrais típicas das imagens VANTs. Os valores do VDVI estão dentro do intervalo $[-1, 1]$, e a precisão da extração de vegetação com base no VDVI foi relatada como sendo maior do que outros índices de vegetação baseados em banda de luz visível e na banda verde que foram testados (WANG et al., 2015). O índice apresenta um alto grau de separação entre áreas vegetadas e não vegetadas, com valores que praticamente não se sobrepõe, sendo altamente qualificado para identificação de áreas verdes em imagens capturadas por VANTs (ZHOU et al., 2021).

O Índice de vegetação VARI pode ser calculado com a sua aplicação em satélites, possibilitando a identificação de plantas daninhas e a produção de mapas de distribuição espacial com diferentes graus de infestação, podendo com o auxílio de satélites interpretar as áreas de semeadura com alto e baixo grau de infestação durante a temporada de crescimento, observando-se que o valor do índice VARI das culturas de trigo com baixo grau de infestação é maior do que o valor do índice VARI das culturas de trigo com alto grau de infestação (ERUNOVA et al., 2021).

Um novo índice visível (vNDVI), estimado a partir de câmeras RGB não calibradas em VANTs, mostrou-se altamente preciso na estimativa dos valores de NDVI, oferecendo uma alternativa de baixo custo para o sensoriamento remoto e a fenotipagem de plantas. O vNDVI superou outros índices que utilizam dados RGB, fornecendo resultados confiáveis na avaliação da saúde das culturas (COSTA et al.,

2020).

Tabela 1: Principais Índices de Vegetação Aplicados na Literatura

Índice	Equações	Autores
NDVI	$(NIR - R)/(NIR + R)$ ⁽¹⁾	(ROUSE; HAAS, 1974)
SAVI	$[(NIR - R) * (1 + L)] / (NIR + R + L)$ ⁽²⁾	(HUETE, 1988)
LAI	$\{-\ln[(0,69 - SAVI) / 0,59] / 0,91\}$ ⁽³⁾	(SEBAL, 2002)
NDWI	$(G - NIR) / (G + NIR)$ ⁽⁴⁾	(MCFEETERS, 1996)
MNDWI	$(G - MIR) / (G + MIR)$ ⁽⁵⁾	(XU, 2006)
NDWI	$(NIR - MIR) / (NIR + MIR)$ ⁽⁶⁾	(GAO, 1996)
NDSI	$(R - NIR) / (R + NIR)$ ⁽⁷⁾	(KHAN et al., 2001)
GNDVI	$(NIR - G) / (NIR + G)$ ⁽⁸⁾	(WANG et al., 2007)
EVI	$[2,5 * (NIR - R)] / (NIR + 6 * R - 7,5 * B + 1)$ ⁽⁹⁾	(WANG et al., 2003)
MCARI	$(NIR - R) - 0,2 * (NIR - G) * (NIR / R)$ ⁽¹⁰⁾	(DAUGHTRY, 2000)
NDRE	$(NIR - RE) / (NIR + R)$ ⁽¹¹⁾	(BARNES et al., 2000)
MGRVI	$(G^2 - R^2) / (G^2 + R^2)$ ⁽¹²⁾	(BENDIG et al., 2015)
VDVI	$(2G - R - BLUE) / (2G + R + B)$ ⁽¹³⁾	(WANG et al., 2015)
MEXG	$1,262 * G - 0,884 * R - 0,311 * B$ ⁽¹⁴⁾	(BURGOS-ARTIZZU et al., 2011)
VARI	$(G - R) / (G + R - B)$ ⁽¹⁵⁾	(SCHNEIDER et al., 2008)
GDVI	$(NIR^n - R^n) / (NIR^n + R^n)$ ⁽¹⁶⁾	(WU et al., 2014)
VNDVI	$0,5268 * (R^{\wedge} - 0,1294 * G^{\wedge} 0,3389 * B^{\wedge} - 0,3118)$ ⁽¹⁷⁾	(COSTA et al., 2020).

4.6 Aprendizagem de máquina

A aprendizagem de máquinas é uma abordagem algorítmica que consiste em identificar e aprender padrões a partir de dados, composta por várias camadas de processamento para aprender representações de dados com diferentes níveis de abstração. O diferencial dessa abordagem é que as camadas de características não são projetadas por engenheiros humanos, mas sim aprendidas a partir dos dados usando um procedimento de aprendizado geral (GISELSSON et al., 2017).

Com a escassez de recursos naturais e os desafios climáticos atuais, a produção agrícola está sob estresse iminente. Felizmente, a aprendizagem de máquinas oferece diversas possibilidades, permitindo que modelos computacionais

aprendam representações precisas de dados agrícolas e gerenciem de forma inteligente as áreas agrícolas. Essas abordagens têm sido aplicadas com sucesso em vários aspectos da engenharia agrícola, incluindo a determinação de umidade do solo, detecção de doenças e identificação de plantas daninhas, entre outros. Ao usar a aprendizagem de máquinas, é possível evitar o viés humano, resultando em maior precisão e universalidade. Para que essa abordagem seja mais amplamente aceita e aplicada na agricultura, é necessário incluir conjuntos de dados de verdade terrena e integrar mecanismos de fusão de dados de várias fontes para tornar os modelos mais robustos e adequados para o campo (CHAKRABORTY et al., 2022).

A aprendizagem de máquina permite que máquinas processem dados brutos e descubram representações internas para detecção e classificação. Ela tem sido bem-sucedida em resolver problemas desafiadores, como reconhecimento de imagem e fala, análise de dados científicos e compreensão de linguagem natural. Acredita-se que a aprendizagem de máquina continuará a avançar com o aumento da disponibilidade de dados e recursos computacionais, juntamente com o desenvolvimento de novos algoritmos e arquiteturas (LECUN et al., 2015; ROY & CHAKRABORTY, 2023).

Abordagens de classificação de imagens não paramétricas, como Redes Neurais Artificiais (RNA) e Support Vector Machine (SVM), não fazem suposições sobre a característica estatística dos dados e são técnicas relativamente novas de classificação de imagens. O uso de técnicas de aprendizagem de máquina, como RNA, SVM, Random Forest, árvores de decisão e outros modelos, tem recebido muita atenção para classificar o uso e ocupação do solo. Estudos relatam que SVM e Random Forest são as melhores abordagens para a classificação do uso e ocupação do solo em comparação com outras técnicas de aprendizagem de máquinas (BAIG et al., 2022). O algoritmo de classificação Random Forest é superior a muitos algoritmos baseados em árvores, por ser menos sensível a ruídos e estar menos propenso ao sobreajuste devido ao seu processo de votação. Vários estudos têm testado seu desempenho em diferentes aplicações, como na

classificação de plantas, imagens de satélite e mapeamento de cobertura vegetal (OK, AKAR, GUNGOR, 2012).

A Rede Neural Artificial é uma ferramenta analítica inspirada na estrutura física dos neurônios biológicos e é amplamente utilizada na agricultura inteligente e no cultivo para monitorar a qualidade de frutas e vegetais. Essa metodologia é adequada para previsão, monitoramento e controle, pois não requer conhecimento prévio de parâmetros, ao contrário de outras ferramentas analíticas. A RNA coleta informações dos dados fornecidos anteriormente e analisa novas entradas de dados-alvo usando essas informações. Ela lida de forma eficiente com a incerteza dos dados e as relações não lineares. O uso da RNA tem melhorado significativamente o monitoramento da qualidade de frutas e vegetais, bem como a previsão da qualidade agrícola (SHARMA et al., 2022). As RNAs são úteis na resolução de problemas devido à sua capacidade de reconhecimento de padrões complexos, tolerância a falhas e adaptabilidade a novas condições. A modelagem em redes neurais é baseada em dados, sem a criação de restrições como em métodos de otimização matemática. As RNAs utilizam métodos de agrupamento baseados em modelos e podem ser classificadas quanto ao tipo de aprendizado, sendo supervisionado ou não supervisionado (BARBOSA, 2011).

As Support Vector Machine são amplamente conhecidas pela sua habilidade de generalização na classificação de dados que não fazem parte do conjunto utilizado para o seu treinamento, tendo sua teoria sendo consolidada nos princípios matemáticos. São robustas para imagens, além de permitir a otimização da função quadrática com apenas um mínimo global (ROY & CHAKRABORTY, 2023).

A área crítica do processamento de imagens tem se beneficiado enormemente da aplicação de algoritmos genéticos, que são considerados a técnica mais bem-sucedida para lidar com múltiplas variáveis em espaços grandes. Desde melhorias no contraste da imagem e realce de detalhes até a aplicação de filtros avançados e parâmetros deformáveis, esse paradigma tem se mostrado eficaz na resolução desses problemas. A aplicação desse algoritmo permite uma busca

abrangente e vigorosa, eliminando armadilhas em extremos locais e obtendo resultados ótimos de busca global (LAMBORA, GUPTA, CHOPRA, 2019). O algoritmo genético pode ser utilizado para a criação de índices de vegetação que visam obtenção de valores aproximados de NDVI utilizando dados das bandas RGB, obtendo R^2 acima de 0,8 para as áreas testadas (COSTA et al., 2020).

5. REFERÊNCIAS

ALBUQUERQUE, C.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. D. A.; FONTES JR., R. Recarga de aquífero aluvial sob uso agrícola. **Águas Subterrâneas**, v. 29, n. 1, 25 fev. 2015. DOI [10.14295/ras.v29i1.27931](https://doi.org/10.14295/ras.v29i1.27931). Disponível em: <http://aguassubterraneas.abas.org/asubterraneas/article/view/27931>. Acesso em: 3 jun. 2024.

ALLEN, R.; BASTIAANSEN, W.; TASUMI, M.; TREZZA, R. **Seball**. [S. l.: s. n.], 2002.

ALMEIDA, T. A. B.; MONTENEGRO, A. A. D. A.; MACKAY, R.; MONTENEGRO, S. M. G. L.; COELHO, V. H. R.; DE CARVALHO, A. A.; DA SILVA, T. G. F. Hydrogeological trends in an alluvial valley in the Brazilian semiarid: Impacts of observed climate variables change and exploitation on groundwater availability and salinity. **Journal of Hydrology: Regional Studies**, v. 53, p. 101784, jun. 2024. DOI [10.1016/j.ejrh.2024.101784](https://doi.org/10.1016/j.ejrh.2024.101784). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2214581824001320>. Acesso em: 15 jul. 2024.

BAHIR, M.; OUHAMDOUCH, S.; OUAZAR, D.; EL MOÇAYD, N. Climate change effect on groundwater characteristics within semi-arid zones from western Morocco. **Groundwater for Sustainable Development**, v. 11, p. 100380, out. 2020. DOI [10.1016/j.gsd.2020.100380](https://doi.org/10.1016/j.gsd.2020.100380). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352801X20300643>. Acesso em: 3 jun. 2024.

BAIG, M. F.; MUSTAFA, M. R. U.; BAIG, I.; TAKAIJUDIN, H. B.; ZESHAN, M. T. Assessment of Land Use Land Cover Changes and Future Predictions Using CA-ANN Simulation for Selangor, Malaysia. **Water**, v. 14, n. 3, p. 402, 28 jan. 2022. DOI [10.3390/w14030402](https://doi.org/10.3390/w14030402). Disponível em: <https://www.mdpi.com/2073-4441/14/3/402>. Acesso em: 3 jun. 2024.

BARBOSA, C. D. Rede neural artificial aplicada à agricultura. **Revista Vértices**, v. 13, n. 2, p. 161–170, 2011. DOI [10.5935/1809-2667.20110019](https://doi.org/10.5935/1809-2667.20110019). Disponível em: <http://www.gnresearch.org/doi/10.5935/1809-2667.20110019>. Acesso em: 3 jun. 2024.

BARBOSA, F. S.; ZANDONADI, R. S. Low cost apparatus for aparent soil electrical conductivity measurment based on direct current. **Nativa**, v. 5, n. 1, 2017. DOI [10.5935/2318-7670.v05n01a06](https://doi.org/10.5935/2318-7670.v05n01a06). Disponível em: <http://www.gnresearch.org/doi/10.5935/2318-7670.v05n01a06>. Acesso em: 3 jun. 2024.

BARNES, E. M.; CLARKE, T. R.; RICHARDS, S. E.; COLAIZZI, P. D.; HABERLAND, J.; KOSTRZEWSKI, M.; WALLER, P.; CHOI, C.; RILEY, E.; THOMPSON, T.; LASCANO, R. J.; LI, H.; MORAN, M. S. COINCIDENT DETECTION OF CROP WATER STRESS, NITROGEN STATUS AND CANOPY DENSITY USING GROUND-BASED MULTISPECTRAL DATA. [s. d]. .

BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79–87, jul. 2015. DOI [10.1016/j.jag.2015.02.012](https://doi.org/10.1016/j.jag.2015.02.012). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243415000446>. Acesso em: 14 maio 2023.

BLAINSKI, É.; PORRAS, E. A. A.; GARBOSSA, L. H. P.; PINHEIRO, A. Simulation of land use scenarios in the Camboriú River Basin using the SWAT model. **RBRH**, v. 22, n. 0, 2017. DOI [10.1590/2318-0331.011716110](https://doi.org/10.1590/2318-0331.011716110). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2318-03312017000100229&lng=en&tlng=en. Acesso em: 1 maio 2023.

BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; GUIJARRO, M.; PAJARES, G. Real-time image processing for crop/weed discrimination in maize fields. **Computers and Electronics in Agriculture**, v. 75, n. 2, p. 337–346, fev. 2011. DOI [10.1016/j.compag.2010.12.011](https://doi.org/10.1016/j.compag.2010.12.011). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169910002620>. Acesso em: 14 maio 2023.

CARVALHO, A. A. D.; MONTENEGRO, A. A. D. A.; DE LIMA, J. L. M. P.; SILVA, T. G. F. D.; PEDROSA, E. M. R.; ALMEIDA, T. A. B. Coupling Water Resources and Agricultural Practices for Sorghum in a Semiarid Environment. **Water**, v. 13, n. 16, p. 2288, 21 ago. 2021. DOI [10.3390/w13162288](https://doi.org/10.3390/w13162288). Disponível em: <https://www.mdpi.com/2073-4441/13/16/2288>. Acesso em: 3 jun. 2023.

CARVALHO, A. A.; MONTENEGRO, A. A. D. A.; TABOSA, J. N.; ALMEIDA, T. A. B.; SILVA, A. G. O. D.; SILVEIRA, A. V. M. Reuso hidroagrícola: uma solução para convivência com a escassez hídrica no Sertão e Agreste pernambucano. **Journal of Environmental Analysis and Progress**, v. 5, n. 2, p. 140–150, 9 abr. 2020. DOI [10.24221/jeap.5.2.2020.2841.140-150](https://doi.org/10.24221/jeap.5.2.2020.2841.140-150). Disponível em: <http://www.ead.codai.ufrpe.br/index.php/JEAP/article/view/2841>. Acesso em: 3 jun. 2023.

CHAGAS, A. M. S.; MONTENEGRO, A. A. D. A.; LINS, F. A. C.; FARIAS, C. W. L. D. A. Análise da umidade do solo em bacia experimental no semiárido pernambucano utilizando o modelo SWAT. **Agrometeoros**, v. 30, 8 ago. 2022. DOI [10.31062/agrom.v30.e026993](https://doi.org/10.31062/agrom.v30.e026993). Disponível em: <https://seer.sct.embrapa.br/index.php/agrometeoros/article/view/26993>. Acesso em: 1 jun. 2023.

CHAKRABORTY, S. K.; CHANDEL, N. S.; JAT, D.; TIWARI, M. K.; RAJWADE, Y. A.; SUBEESH, A. Deep learning approaches and interventions for futuristic engineering in agriculture. **Neural Computing and Applications**, v. 34, n. 23, p. 20539–20573, dez. 2022. DOI [10.1007/s00521-022-07744-x](https://doi.org/10.1007/s00521-022-07744-x). Disponível em: <https://link.springer.com/10.1007/s00521-022-07744-x>. Acesso em: 14 maio 2023.

COELHO, V. H. R.; MONTENEGRO, S.; ALMEIDA, C. N.; SILVA, B. B.; OLIVEIRA, L. M.; GUSMÃO, A. C. V.; FREITAS, E. S.; MONTENEGRO, A. A. A. Alluvial groundwater recharge estimation in semi-arid environment using remotely sensed data. **Journal of Hydrology**, v. 548, p. 1–15, maio 2017. DOI [10.1016/j.jhydrol.2017.02.054](https://doi.org/10.1016/j.jhydrol.2017.02.054). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0022169417301336>. Acesso em: 3 jun. 2024.

COSTA, L.; NUNES, L.; AMPATZIDIS, Y. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. **Computers and Electronics in Agriculture**, v. 172, p. 105334, maio 2020. DOI [10.1016/j.compag.2020.105334](https://doi.org/10.1016/j.compag.2020.105334). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S016816991932383X>. Acesso em: 1 maio 2023.

DANIELS, L.; ECKHOUT, E.; WIEME, J.; DEJAEGHER, Y.; AUDENAERT, K.; MAES, W. H. Identifying the Optimal Radiometric Calibration Method for UAV-Based Multispectral Imaging. **Remote Sensing**, v. 15, n. 11, p. 2909, 2 jun. 2023. DOI [10.3390/rs15112909](https://doi.org/10.3390/rs15112909). Disponível em: <https://www.mdpi.com/2072-4292/15/11/2909>. Acesso em: 6 ago. 2024.

DAUGHTRY, C. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229–239, nov. 2000. DOI [10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425700001139>. Acesso em: 13 maio 2023.

DE LIMA, I. P.; JORGE, R. G.; DE LIMA, J. L. M. P. Remote Sensing Monitoring of Rice Fields: Towards Assessing Water Saving Irrigation Management Practices. **Frontiers in Remote Sensing**, v. 2, p. 762093, 25 out. 2021. DOI [10.3389/frsen.2021.762093](https://doi.org/10.3389/frsen.2021.762093). Disponível em: <https://www.frontiersin.org/articles/10.3389/frsen.2021.762093/full>. Acesso em: 3 jun.

2024.

DE LIRA, R. M.; BARNABÉ, J. M. C. Revista Geama Environmental Sciences. **Environmental Sciences**, 2015. .

DE SOUZA, C. A.; AQUINO, B. G.; DE QUEIROZ, T. M. Expansão da agricultura irrigada por pivô central na região do Alto Teles Pires- MT utilizando sensoriamento remoto. [s. d.] .

ELHAG, M. Evaluation of Different Soil Salinity Mapping Using Remote Sensing Techniques in Arid Ecosystems, Saudi Arabia. **Journal of Sensors**, v. 2016, p. 1–8, 2016. DOI [10.1155/2016/7596175](https://doi.org/10.1155/2016/7596175). Disponível em: <http://www.hindawi.com/journals/js/2016/7596175/>. Acesso em: 14 maio 2023.

ELTARABILY, M. G.; NEGM, A. M.; YOSHIMURA, C.; ABDEL-ABDEL-FATTAH, S.; SAAVEDRA, O. C. Quality Assessment of Southeast Nile Delta Groundwater for Irrigation. **Water Resources**, v. 45, n. 6, p. 975–991, nov. 2018. DOI [10.1134/S0097807818060118](https://doi.org/10.1134/S0097807818060118). Disponível em: <http://link.springer.com/10.1134/S0097807818060118>. Acesso em: 3 jun. 2024.

ERUNOVA, M. G.; PISMAN, T. I.; SHEVYRNOGOV, A. P. The Technology for Detecting Weeds in Agricultural Crops Based on Vegetation Index VARI (PlanetScope). **Journal of Siberian Federal University. Engineering & Technologies**, p. 347–353, maio 2021. DOI [10.17516/1999-494X-0314](https://doi.org/10.17516/1999-494X-0314). Disponível em: <http://journal.sfu-kras.ru/en/article/141284>. Acesso em: 14 maio 2023.

GAO, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, dez. 1996. DOI [10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425796000673>. Acesso em: 14 maio 2023.

GISELSSON, T. M.; JØRGENSEN, R. N.; JENSEN, P. K.; DYRMANN, M.; MIDTIBY, H. S. A Public Image Database for Benchmark of Plant Seedling Classification Algorithms. 15 nov. 2017. Disponível em: <http://arxiv.org/abs/1711.05458>. Acesso em: 14 maio 2023.

HAAS, J. C.; BIRK, S. Trends in Austrian groundwater – Climate or human impact? **Journal of Hydrology: Regional Studies**, v. 22, p. 100597, abr. 2019. DOI [10.1016/j.ejrh.2019.100597](https://doi.org/10.1016/j.ejrh.2019.100597). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2214581818303045>. Acesso em: 3 jun. 2024.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, ago. 1988. DOI [10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/003442578890106X>. Acesso em: 13 maio 2023.

ISHIDA, T.; KURIHARA, J.; VIRAY, F. A.; NAMUCO, S. B.; PARINGIT, E. C.; PEREZ, G. J.; TAKAHASHI, Y.; MARCIANO, J. J. A novel approach for vegetation classification using UAV-based hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 144, p. 80–85, jan. 2018. DOI [10.1016/j.compag.2017.11.027](https://doi.org/10.1016/j.compag.2017.11.027). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169917310499>. Acesso em: 3 maio 2023.

JENEROWICZ, A.; WIERZBICKI, D.; KEDZIERSKI, M. Radiometric Correction with Topography Influence of Multispectral Imagery Obtained from Unmanned Aerial Vehicles. **Remote Sensing**, v. 15, n. 8, p. 2059, 13 abr. 2023. DOI [10.3390/rs15082059](https://doi.org/10.3390/rs15082059). Disponível em: <https://www.mdpi.com/2072-4292/15/8/2059>. Acesso em: 6 ago. 2024.

KAWO, N. S.; KARUPPANNAN, S. Groundwater quality assessment using water quality index and GIS technique in Modjo River Basin, central Ethiopia. **Journal of African Earth Sciences**, v. 147, p. 300–311, nov. 2018. DOI [10.1016/j.jafrearsci.2018.06.034](https://doi.org/10.1016/j.jafrearsci.2018.06.034). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1464343X1830195X>. Acesso em: 3 jun. 2024.

KUMAR, M.; KUMARI, K.; RAMANATHAN, A.; SAXENA, R. A comparative evaluation of groundwater suitability for irrigation and drinking purposes in two intensively cultivated districts of Punjab, India. **Environmental Geology**, v. 53, n. 3, p. 553–574, 25 out. 2007. DOI [10.1007/s00254-007-0672-3](https://doi.org/10.1007/s00254-007-0672-3). Disponível em: <http://link.springer.com/10.1007/s00254-007-0672-3>. Acesso em: 3 jun. 2024.

LAMBORA, A.; GUPTA, K.; CHOPRA, K. Genetic Algorithm- A Literature Review. *In*: 2019 INTERNATIONAL CONFERENCE ON MACHINE LEARNING, BIG DATA, CLOUD AND PARALLEL COMPUTING (COMITCON), fev. 2019. **2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)** [...]. Faridabad, India: IEEE, fev. 2019. p. 380–384. DOI [10.1109/COMITCon.2019.8862255](https://doi.org/10.1109/COMITCon.2019.8862255). Disponível em: <https://ieeexplore.ieee.org/document/8862255/>. Acesso em: 14 maio 2023.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 28 maio 2015. DOI [10.1038/nature14539](https://doi.org/10.1038/nature14539). Disponível em: <http://www.nature.com/articles/nature14539>. Acesso em: 1 maio 2023.

LI, M.; SHAMSHIRI, R. R.; SCHIRRMANN, M.; WELTZIEN, C.; SHAFIAN, S.; LAURSEN, M. S. UAV Oblique Imagery with an Adaptive Micro-Terrain Model for Estimation of Leaf Area Index and Height of Maize Canopy from 3D Point Clouds. **Remote Sensing**, v. 14, n. 3, p. 585, 26 jan. 2022. DOI [10.3390/rs14030585](https://doi.org/10.3390/rs14030585). Disponível em: <https://www.mdpi.com/2072-4292/14/3/585>. Acesso em: 2 jun. 2023.

MAMANI DIAZ, C. A.; MEDINA CASTANEDA, E. E.; MUGRUZA VASSALLO, C. A. Deep Learning for Plant Classification in Precision Agriculture. *In*: 2019 INTERNATIONAL CONFERENCE ON COMPUTER, CONTROL, INFORMATICS

AND ITS APPLICATIONS (IC3INA), out. 2019. **2019 International Conference on Computer, Control, Informatics and its Applications (IC3INA)** [...]. Tangerang, Indonesia: IEEE, out. 2019. p. 9–13. DOI [10.1109/IC3INA48034.2019.8949612](https://doi.org/10.1109/IC3INA48034.2019.8949612). Disponível em: <https://ieeexplore.ieee.org/document/8949612/>. Acesso em: 14 maio 2023.

MASOUD, A. A.; EL-HORINY, M. M.; ATWIA, M. G.; GEMAIL, K. S.; KOIKE, K. Assessment of groundwater and soil quality degradation using multivariate and geostatistical analyses, Dakhla Oasis, Egypt. **Journal of African Earth Sciences**, v. 142, p. 64–81, jun. 2018. DOI [10.1016/j.jafrearsci.2018.03.009](https://doi.org/10.1016/j.jafrearsci.2018.03.009). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1464343X18300670>. Acesso em: 3 jun. 2024.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425–1432, maio 1996. DOI [10.1080/01431169608948714](https://doi.org/10.1080/01431169608948714). Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431169608948714>. Acesso em: 14 maio 2023.

MONTEIRO, A.; MONTENEGRO, A.; MONTENEGRO, S. Modelagem de Fluxo e Análise do Potencial Hídrico de Aquífero Aluvial no Semiárido de Pernambuco. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 3, p. 151–163, 2014. DOI [10.21168/rbrh.v19n3.p151-163](https://doi.org/10.21168/rbrh.v19n3.p151-163). Disponível em: <http://www.abrh.org.br/SGCv3/index.php?PUB=1&ID=168&SUMARIO=4790>. Acesso em: 3 jun. 2024.

MONTENEGRO, A.; RAGAB, R. Hydrological response of a Brazilian semi-arid catchment to different land use and climate change scenarios: a modelling study. **Hydrological Processes**, v. 24, n. 19, p. 2705–2723, 15 set. 2010. DOI [10.1002/hyp.7825](https://doi.org/10.1002/hyp.7825). Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/hyp.7825>. Acesso em: 3 jun. 2024.

MONTENEGRO, A.A.A.; ABRANTES, J. R. C. B.; DE LIMA, J. L. M. P.; SINGH, V. P.; SANTOS, T. E. M. Impact of mulching on soil and water dynamics under intermittent simulated rainfall. **CATENA**, v. 109, p. 139–149, out. 2013. DOI [10.1016/j.catena.2013.03.018](https://doi.org/10.1016/j.catena.2013.03.018). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0341816213000866>. Acesso em: 5 jun. 2023.

MONTENEGRO, A. A. A.; MONTENEGRO, S. M. G. L. Variabilidade espacial de classes de textura, salinidade e condutividade hidráulica de solos em planície aluvial. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 10, n. 1, p. 30–37, mar. 2006. DOI [10.1590/S1415-43662006000100005](https://doi.org/10.1590/S1415-43662006000100005). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662006000100005&lng=pt&tlng=pt. Acesso em: 3 jun. 2024.

MONTENEGRO, A. A.A.; ALMEIDA, T. A. B.; LIMA, C. A. D.; ABRANTES, J. R. C. B.;

DE LIMA, J. L. M. P. Evaluating Mulch Cover with Coir Dust and Cover Crop with Palma Cactus as Soil and Water Conservation Techniques for Semiarid Environments: Laboratory Soil Flume Study under Simulated Rainfall. **Hydrology**, v. 7, n. 3, p. 61, 20 ago. 2020. DOI [10.3390/hydrology7030061](https://doi.org/10.3390/hydrology7030061). Disponível em: <https://www.mdpi.com/2306-5338/7/3/61>. Acesso em: 5 jun. 2023.

OFORI, S.; PUŠKÁČOVÁ, A.; RŮŽIČKOVÁ, I.; WANNER, J. Treated wastewater reuse for irrigation: Pros and cons. **Science of The Total Environment**, v. 760, p. 144026, mar. 2021. DOI [10.1016/j.scitotenv.2020.144026](https://doi.org/10.1016/j.scitotenv.2020.144026). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0048969720375574>. Acesso em: 15 maio 2023.

OK, A. O.; AKAR, O.; GUNGOR, O. Evaluation of random forest method for agricultural crop classification. **European Journal of Remote Sensing**, v. 45, n. 1, p. 421–432, jan. 2012. DOI [10.5721/EuJRS20124535](https://doi.org/10.5721/EuJRS20124535). Disponível em: <https://www.tandfonline.com/doi/full/10.5721/EuJRS20124535>. Acesso em: 14 maio 2023.

PÁDUA, L.; MATESE, A.; DI GENNARO, S. F.; MORAIS, R.; PERES, E.; SOUSA, J. J. Vineyard classification using OBIA on UAV-based RGB and multispectral data: A case study in different wine regions. **Computers and Electronics in Agriculture**, v. 196, p. 106905, maio 2022. DOI [10.1016/j.compag.2022.106905](https://doi.org/10.1016/j.compag.2022.106905). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169922002228>. Acesso em: 1 jun. 2023.

PHANG, S. K.; CHIANG, T. H. A.; HAPPONEN, A.; CHANG, M. M. L. From Satellite to UAV-Based Remote Sensing: A Review on Precision Agriculture. **IEEE Access**, v. 11, p. 127057–127076, 2023. DOI [10.1109/ACCESS.2023.3330886](https://doi.org/10.1109/ACCESS.2023.3330886). Disponível em: <https://ieeexplore.ieee.org/document/10310142/>. Acesso em: 6 ago. 2024.

PEÑA, J. M.; TORRES-SÁNCHEZ, J.; DE CASTRO, A. I.; KELLY, M.; LÓPEZ-GRANADOS, F. Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. **PLoS ONE**, v. 8, n. 10, p. e77151, 11 out. 2013. DOI [10.1371/journal.pone.0077151](https://doi.org/10.1371/journal.pone.0077151). Disponível em: <https://dx.plos.org/10.1371/journal.pone.0077151>. Acesso em: 3 maio 2023.

PEÑA-ARANCIBIA, J. L.; MAINUDDIN, M.; AHMAD, M. D.; HODGSON, Geoff.; IBN MURAD, K. F.; TICEHURST, C.; MANIRUZZAMAN, M.; GOLAM MAHBOOB, M.; KIRBY, J. M. Groundwater use and rapid irrigation expansion in a changing climate: Hydrological drivers in one of the world's food bowls. **Journal of Hydrology**, v. 581, p. 124300, fev. 2020. DOI [10.1016/j.jhydrol.2019.124300](https://doi.org/10.1016/j.jhydrol.2019.124300). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0022169419310352>. Acesso em: 3 jun. 2024.

POHL, S. C.; LENZ, D. M. Utilização de efluente tratado em complexo industrial automotivo. **Engenharia Sanitaria e Ambiental**, v. 22, n. 3, p. 551–562, maio 2017. DOI [10.1590/s1413-41522016122371](https://doi.org/10.1590/s1413-41522016122371). Disponível em:

http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-41522017000300551&lng=pt&tlng=pt. Acesso em: 3 jun. 2024.

REDDY, B. M.; V.SUNITHA; M.PRASAD; REDDY, Y. S.; REDDY, M. R. Evaluation of groundwater suitability for domestic and agricultural utility in semi-arid region of Anantapur, Andhra Pradesh State, South India. **Groundwater for Sustainable Development**, v. 9, p. 100262, out. 2019. DOI [10.1016/j.gsd.2019.100262](https://doi.org/10.1016/j.gsd.2019.100262). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352801X18302212>. Acesso em: 3 jun. 2024.

RIBEIRO, L.; KRETSCHMER, N.; NASCIMENTO, J.; BUXO, A.; RÖTTING, T.; SOTO, G.; SEÑORET, M.; OYARZÚN, J.; MATURANA, H.; OYARZÚN, R. Evaluating piezometric trends using the Mann-Kendall test on the alluvial aquifers of the Elqui River basin, Chile. **Hydrological Sciences Journal**, v. 60, n. 10, p. 1840–1852, 3 out. 2015. DOI [10.1080/02626667.2014.945936](https://doi.org/10.1080/02626667.2014.945936). Disponível em: <http://www.tandfonline.com/doi/full/10.1080/02626667.2014.945936>. Acesso em: 3 jun. 2024.

ROUSE, W.; HAAS, R. H. MONITORING VEGETATION SYSTEMS IN THE GREAT PLAINS WITH ERTS. [s. d]. .

ROY, A.; CHAKRABORTY, S. Support vector machine in structural reliability analysis: A review. **Reliability Engineering & System Safety**, v. 233, p. 109126, maio 2023. DOI [10.1016/j.ress.2023.109126](https://doi.org/10.1016/j.ress.2023.109126). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0951832023000418>. Acesso em: 3 jun. 2024.

RUSLI, S. R.; BENSE, V. F.; TAUFIQ, A.; WEERTS, A. H. Quantifying basin-scale changes in groundwater storage using GRACE and one-way coupled hydrological and groundwater flow model in the data-scarce Bandung groundwater Basin, Indonesia. **Groundwater for Sustainable Development**, v. 22, p. 100953, ago. 2023. DOI [10.1016/j.gsd.2023.100953](https://doi.org/10.1016/j.gsd.2023.100953). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352801X2300053X>. Acesso em: 3 jun. 2024.

SABU, D. T. MENON, A.R.R. (2012). Remote sensing applications in agriculture and forestry. A paper from the proceedings of the Kerala environment congress, pp. 222-235. [s. d]. .

SAMANTARA, M. K.; PADHI, R. K.; SOWMYA, M.; KUMARAN, P.; SATPATHY, K. K. Heavy metal contamination, major ion chemistry and appraisal of the groundwater status in coastal aquifer, Kalpakkam, Tamil Nadu, India. **Groundwater for Sustainable Development**, v. 5, p. 49–58, set. 2017. DOI [10.1016/j.gsd.2017.04.001](https://doi.org/10.1016/j.gsd.2017.04.001). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352801X1730036X>. Acesso em: 3 jun. 2024.

SANTOS, C.; MOURA, M.; GALVINCIO, J.; CARVALHO, H.; MIRANDA, R.; MONTENEGRO, S. Comparação de imagens multiespectrais utilizando Satélites e VANT para a análise de mudanças estruturais em área de Floresta Seca. **Revista Brasileira de Geografia Física**, p. 2510–2522, 2021. DOI [10.26848/rbgf.v14.5.p2510-2522](https://doi.org/10.26848/rbgf.v14.5.p2510-2522). Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/view/251569>. Acesso em: 1 maio 2023.

SCHNEIDER, P.; ROBERTS, D. A.; KYRIAKIDIS, P. C. A VARI-based relative greenness from MODIS data for computing the Fire Potential Index. **Remote Sensing of Environment**, v. 112, n. 3, p. 1151–1167, mar. 2008. DOI [10.1016/j.rse.2007.07.010](https://doi.org/10.1016/j.rse.2007.07.010). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425707003471>. Acesso em: 13 maio 2023.

SHANMUGAPRIYA, P.; RATHIKA, S.; RAMESH, T.; JANAKI, P. Applications of Remote Sensing in Agriculture - A Review. **International Journal of Current Microbiology and Applied Sciences**, v. 8, n. 01, p. 2270–2283, 20 jan. 2019. DOI [10.20546/ijcmas.2019.801.238](https://doi.org/10.20546/ijcmas.2019.801.238). Disponível em: <https://www.ijcmas.com/abstractview.php?ID=11625&vol=8-1-2019&SNo=238>. Acesso em: 14 maio 2023.

SHARMA, A.; GEORGI, M.; TREGUBENKO, M.; TSELYKH, A.; TSELYKH, A. Enabling smart agriculture by implementing artificial intelligence and embedded sensing. **Computers & Industrial Engineering**, v. 165, p. 107936, mar. 2022. DOI [10.1016/j.cie.2022.107936](https://doi.org/10.1016/j.cie.2022.107936). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0360835222000067>. Acesso em: 2 jun. 2023.

SILVA, D. C. D.; LOPES, P. M. O.; SILVA, M. V. D.; MOURA, G. B. D. A.; NASCIMENTO, C. R.; BRITO, J. I. B.; FRANÇA E SILVA, Ê. F. D.; ROLIM, M. M.; LIMA, R. P. D. Principal component analysis and biophysical parameters in the assessment of soil salinity in the irrigated perimeter of Bahia, Brazil. **Journal of South American Earth Sciences**, v. 112, p. 103580, dez. 2021. DOI [10.1016/j.jsames.2021.103580](https://doi.org/10.1016/j.jsames.2021.103580). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0895981121004260>. Acesso em: 30 maio 2023.

SILVA NETO, M. A. D.; JESUS, J. E. G. D.; MONTENEGRO, A. A. D. A.; SOUSA, L. D. B. D.; LINS, F. A. C.; CHAGAS, A. M. S. D. Parâmetros biofísicos como instrumento analítico de degradação do solo em bacia experimental do semiárido pernambucano. **Agrometeoros**, v. 30, 5 jul. 2022. DOI [10.31062/agrom.v30.e026989](https://doi.org/10.31062/agrom.v30.e026989). Disponível em: <https://seer.sct.embrapa.br/index.php/agrometeoros/article/view/26989>. Acesso em: 1 maio 2023.

SOUSA, L. D. B. D.; MONTENEGRO, A. A. D. A.; SILVA, M. V. D.; LOPES, P. M. O.; SILVA, J. R. I.; SILVA, T. G. F. D.; LINS, F. A. C.; SILVA, P. C. Spatiotemporal

Dynamics of Land Use and Land Cover through Physical–Hydraulic Indices: Insights in the São Francisco River Transboundary Region, Brazilian Semiarid Area. **AgriEngineering**, v. 5, n. 3, p. 1147–1162, 3 jul. 2023. DOI [10.3390/agriengineering5030073](https://doi.org/10.3390/agriengineering5030073). Disponível em: <https://www.mdpi.com/2624-7402/5/3/73>. Acesso em: 7 jul. 2023.

SU, J.; ZHU, X.; LI, S.; CHEN, W.-H. AI meets UAVs: A survey on AI empowered UAV perception systems for precision agriculture. **Neurocomputing**, v. 518, p. 242–270, jan. 2023. DOI [10.1016/j.neucom.2022.11.020](https://doi.org/10.1016/j.neucom.2022.11.020). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0925231222013996>. Acesso em: 6 ago. 2024.

TAN, M. L.; IBRAHIM, A. L.; YUSOP, Z.; CHUA, V. P.; CHAN, N. W. Climate change impacts under CMIP5 RCP scenarios on water resources of the Kelantan River Basin, Malaysia. **Atmospheric Research**, v. 189, p. 1–10, jun. 2017. DOI [10.1016/j.atmosres.2017.01.008](https://doi.org/10.1016/j.atmosres.2017.01.008). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0169809517300832>. Acesso em: 3 jun. 2024.

TAYLOR, K. E.; STOUFFER, R. J.; MEEHL, G. A. An Overview of CMIP5 and the Experiment Design. **Bulletin of the American Meteorological Society**, v. 93, n. 4, p. 485–498, 1 abr. 2012. DOI [10.1175/BAMS-D-11-00094.1](https://doi.org/10.1175/BAMS-D-11-00094.1). Disponível em: <https://journals.ametsoc.org/doi/10.1175/BAMS-D-11-00094.1>. Acesso em: 3 jun. 2024.

TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. Manual de Métodos de Análise de Solo. [s. d.] .

TESFAYE, S.; TAYE, G.; BIRHANE, E.; VAN DER ZEE, S. E. Observed and model simulated twenty-first century hydro-climatic change of Northern Ethiopia. **Journal of Hydrology: Regional Studies**, v. 22, p. 100595, abr. 2019. DOI [10.1016/j.ejrh.2019.100595](https://doi.org/10.1016/j.ejrh.2019.100595). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2214581818302866>. Acesso em: 3 jun. 2024.

VAZIFEHKHAH, S.; KAHYA, E. Hydrological and agricultural droughts assessment in a semi-arid basin: Inspecting the teleconnections of climate indices on a catchment scale. **Agricultural Water Management**, v. 217, p. 413–425, maio 2019. DOI [10.1016/j.agwat.2019.02.034](https://doi.org/10.1016/j.agwat.2019.02.034). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378377418304347>. Acesso em: 3 jun. 2024.

VELASCO, E. M.; GURDAK, J. J.; DICKINSON, J. E.; FERRÉ, T. P. A.; CORONA, C. R. Interannual to multidecadal climate forcings on groundwater resources of the U.S. West Coast. **Journal of Hydrology: Regional Studies**, v. 11, p. 250–265, jun. 2017. DOI [10.1016/j.ejrh.2015.11.018](https://doi.org/10.1016/j.ejrh.2015.11.018). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2214581815001330>. Acesso em: 3 jun. 2024.

2024.

WANG, F.; HUANG, J.; TANG, Y.; WANG, X. New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. **Rice Science**, v. 14, n. 3, p. 195–203, set. 2007. DOI [10.1016/S1672-6308\(07\)60027-4](https://doi.org/10.1016/S1672-6308(07)60027-4). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1672630807600274>. Acesso em: 13 maio 2023.

WANG, H.; WANG, N.; QUAN, H.; ZHANG, F.; FAN, J.; FENG, H.; CHENG, M.; LIAO, Z.; WANG, X.; XIANG, Y. Yield and water productivity of crops, vegetables and fruits under subsurface drip irrigation: A global meta-analysis. **Agricultural Water Management**, v. 269, p. 107645, jul. 2022. DOI [10.1016/j.agwat.2022.107645](https://doi.org/10.1016/j.agwat.2022.107645). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378377422001925>. Acesso em: 2 jun. 2023.

WANG, X.; WANG, M.; WANG, S.; WU, Y. Extraction of vegetation information from visible unmanned aerial vehicle images.pdf. v. 31, n. 5, p. 152–159, 2015. .

WANG, Z.; SHEN, W.; KOTLER, D. P.; HESHKA, S.; WIELOPOLSKI, L.; ALOIA, J. F.; NELSON, M. E.; PIERSON, R. N.; HEYMSFIELD, S. B. Total body protein: a new cellular level mass and distribution prediction model. **The American Journal of Clinical Nutrition**, v. 78, n. 5, p. 979–984, nov. 2003. DOI [10.1093/ajcn/78.5.979](https://doi.org/10.1093/ajcn/78.5.979). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0002916522034232>. Acesso em: 13 maio 2023.

WU, W.; MHAIMEED, A. S.; AL-SHAFIE, W. M.; ZIADAT, F.; DHEHIBI, B.; NANGIA, V.; DE PAUW, E. Mapping soil salinity changes using remote sensing in Central Iraq. **Geoderma Regional**, v. 2–3, p. 21–31, nov. 2014. DOI [10.1016/j.geodrs.2014.09.002](https://doi.org/10.1016/j.geodrs.2014.09.002). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352009414000108>. Acesso em: 1 jun. 2023.

XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3025–3033, 20 jul. 2006. DOI [10.1080/01431160600589179](https://doi.org/10.1080/01431160600589179). Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431160600589179>. Acesso em: 14 maio 2023.

XU, Z.; LI, Y.; LI, B.; HAO, Z.; LIN, L.; HU, X.; ZHOU, X.; YU, H.; XIANG, S.; PASCAL, M.-L.-F.; SHEN, W.; HE, A.; CHEN, L.; LI, Z. A comparative study on the applicability and effectiveness of NSVI and NDVI for estimating fractional vegetation cover based on multi-source remote sensing image. *Geocarto International*, v. 38, n. 1, p. 2184501, 31 dez. 2023. DOI [10.1080/10106049.2023.2184501](https://doi.org/10.1080/10106049.2023.2184501). Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10106049.2023.2184501>. Acesso em: 2 ago. 2024.

YACOUB, E.; TAYFUR, G. Spatial and temporal of variation of meteorological

drought and precipitation trend analysis over whole Mauritania. **Journal of African Earth Sciences**, v. 163, p. 103761, mar. 2020. DOI [10.1016/j.jafrearsci.2020.103761](https://doi.org/10.1016/j.jafrearsci.2020.103761). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1464343X20300121>. Acesso em: 3 jun. 2024.

ZHANG, Y.; LIANG, S.; ZHU, Z.; MA, H.; HE, T. Soil moisture content retrieval from Landsat 8 data using ensemble learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 185, p. 32–47, mar. 2022. DOI [10.1016/j.isprsjprs.2022.01.005](https://doi.org/10.1016/j.isprsjprs.2022.01.005). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271622000090>. Acesso em: 1 jun. 2023.

ZHOU, H.; FU, L.; SHARMA, R. P.; LEI, Y.; GUO, J. A Hybrid Approach of Combining Random Forest with Texture Analysis and VDVI for Desert Vegetation Mapping Based on UAV RGB Data. **Remote Sensing**, v. 13, n. 10, p. 1891, 12 maio 2021. DOI [10.3390/rs13101891](https://doi.org/10.3390/rs13101891). Disponível em: <https://www.mdpi.com/2072-4292/13/10/1891>. Acesso em: 14 maio 2023.

ZUO, C.; QIAN, J.; FENG, S.; YIN, W.; LI, Y.; FAN, P.; HAN, J.; QIAN, K.; CHEN, Q. Deep learning in optical metrology: a review. **Light: Science & Applications**, v. 11, n. 1, p. 39, 23 fev. 2022. DOI [10.1038/s41377-022-00714-x](https://doi.org/10.1038/s41377-022-00714-x). Disponível em: <https://www.nature.com/articles/s41377-022-00714-x>. Acesso em: 1 jun. 2023.

CAPÍTULO II

UM NOVO ÍNDICE DE BANDA VISÍVEL (ANDVI) PARA ESTIMAR VALORES DE NDVI EM IMAGENS VISÍVEIS (RGB) UTILIZANDO ALGORITMO DE SOLUÇÃO GRADIENTE REDUZIDO GENERALIZADO (GRG) NÃO LINEAR

Resumo: Veículos Aéreos Não Tripulados (VANTs) têm sido utilizados no monitoramento de cultivos agrícolas, destacando-se pela eficiência e rapidez no diagnóstico da saúde vegetal. O presente capítulo objetivou desenvolver um índice RGB utilizando o algoritmo gradiente reduzido generalizado (GRG) não linear disponibilizado pela Microsoft Corporation no pacote de ferramentas Office e avaliar índices RGB, comparando seus respectivos desempenhos em relação ao NDVI (Normalized Difference Vegetation Index) aplicado ao mapeamento de espécies forrageiras. O estudo foi desenvolvido em um lote agrícola no Vale Aluvial do Mimoso, em Pesqueira-PE, utilizando um VANT multiespectral DJI Phantom 4 com sistema de posicionamento Real Time Kinematic (RTK) e câmera multiespectral. Foram avaliados 10 índices comparados ao NDVI na área experimental de plantio irrigado de palma forrageira orelha de elefante mexicana (*Opuntia stricta* HAW.) com espaçamento entre linhas de 0,5 metros e espaçamento entre plantas de 0,2 metros. Os resultados indicaram que o índice aNDVI desenvolvido no estudo representa melhor os valores de NDVI da região, tendo resultados próximos ao Índice de Vegetação da Diferença Normalizada visível (vNDVI) no mês de outubro, que é um período seco, com R^2 de 0,7 contra 0,73 do vNDVI. Além disso, o aNDVI apresentou métricas de ajuste com menor erro, como Erro Médio Absoluto (MAE) de 0,10 contra 0,18 do vNDVI, Erro Quadrático Médio (RMSE) de 0,02 contra 0,06 e Índice de Nash Suttcliffe (NSE) de 0,65 contra -0,1, respectivamente. No período chuvoso, o índice aNDVI se sobressaiu a todos os outros. No mês de fevereiro, apresentou R^2 de 0,88 com MAE de 0,08, RMSE de 0,10 e NSE de 0,84. No mês de abril, apresentou R^2 de 0,85 com MAE de 0,07, RMSE de 0,09 e NSE de 0,85. O índice aNDVI se mostrou uma excelente solução de baixo custo para o monitoramento de culturas na região,

sendo uma ferramenta disseminadora de conhecimento e facilitadora na aplicação da ciência como ferramenta de auxílio nos objetivos dos Objetivos de Desenvolvimento Sustentável (ODS).

Palavras-chave: VANTs, Índices de Vegetação, Sensoriamento Remoto.

Abstract: Unmanned Aerial Vehicles (UAVs) have been used in the monitoring of agricultural crops, standing out for their efficiency and speed in diagnosing plant health. This chapter aimed to develop an RGB index using the Generalized Reduced Gradient (GRG) nonlinear algorithm provided by Microsoft Corporation in the Office toolset and to evaluate RGB indices, comparing their respective performances with the NDVI (Normalized Difference Vegetation Index) applied to the mapping of forage species. The study was conducted in an agricultural plot in the Mimoso Alluvial Valley, in Pesqueira-PE, using a DJI Phantom 4 multispectral UAV with a Real Time Kinematic (RTK) positioning system and a multispectral camera. Ten indices were evaluated and compared to the NDVI in the experimental area of irrigated planting of Mexican Elephant Ear prickly pear (*Opuntia stricta* HAW.), with a row spacing of 0.5 meters and a plant spacing of 0.2 meters. The results indicated that the aNDVI index developed in the study better represents the NDVI values in the region, with results close to the Visible Normalized Difference Vegetation Index (vNDVI) in October, which is a dry period, with an R^2 of 0.7 compared to 0.73 for the vNDVI. Additionally, the aNDVI showed better fit metrics with lower errors, such as a Mean Absolute Error (MAE) of 0.10 compared to 0.18 for the vNDVI, a Root Mean Square Error (RMSE) of 0.02 compared to 0.06, and a Nash-Sutcliffe Efficiency (NSE) of 0.65 compared to -0.1, respectively. In the rainy season, the aNDVI index outperformed all others. In February, it showed an R^2 of 0.88 with an MAE of 0.08, an RMSE of 0.10, and an NSE of 0.84. In April, it showed an R^2 of 0.85 with an MAE of 0.07, an RMSE of 0.09, and an NSE of 0.85. The aNDVI index proved to be an excellent low-cost solution for crop monitoring in the region, serving as a disseminator of knowledge and a facilitator in the application of science as a tool to support the objectives of the Sustainable Development Goals (SDGs).

Keywords: UAVs, Vegetation Index, Remote Sensing.

1. INTRODUÇÃO

A baixa disponibilidade hídrica e insegurança alimentar são desafios recorrentes no mundo (MAINARDIS et al., 2022). A região semiárida do Brasil tem grande potencial para produção agrícola, com alta radiação solar ao longo do ano. Os recursos hídricos são limitados, e há tendências de redução no número de dias chuvosos e na quantidade de chuva devido às mudanças climáticas (CARVALHO et al., 2021).

A agricultura é uma das áreas protagonistas no apoio aos Objetivos de Desenvolvimento Sustentável (ODS) desempenhando um papel crucial na segurança alimentar, objetivo ligado especialmente ao ODS 2 (Fome Zero). Estudos realizados em diversas regiões do mundo nos últimos 30 anos têm se concentrado em seis áreas principais: mudanças no uso da terra, eficiência agrícola, mudanças climáticas, motivação dos agricultores, agricultura urbana e periurbana, e adequação da terra. (VIANA et al., 2022).

Para atingir algumas das metas ligadas a ODS, é essencial um sistema alimentar resiliente, que depende de dados em tempo real para monitorar a produção agrícola. As incertezas nos mercados globais de alimentos aumentaram devido a eventos climáticos adversos e competição comercial intensificada, onde o monitoramento de culturas é fundamental, permitindo análises agroclimáticas, monitoramento de condições das culturas e previsões de produção. No entanto, a falta de informações confiáveis ainda representa uma ameaça séria para a segurança alimentar (WU et al., 2023). O crescimento populacional ocorre de forma abrupta, assim como a necessidade por alimentos. As técnicas tradicionais dos agricultores não são mais eficazes para alcançar esse objetivo. Como solução, o uso de tecnologia tende a aumentar, como na aplicação de VANTs (Veículos Aéreos Não Tripulados), que pode economizar água e auxiliar na aplicação de pesticidas e herbicidas de forma mais eficiente (YADAV et al., 2023).

A tecnologia de VANTs, especialmente os leves (5 a 50 kg), revolucionou a agricultura ao permitir um manejo mais preciso e eficiente das culturas, superando outras plataformas de sensoriamento remoto. Equipados com câmeras

multiespectrais, os VANTs capturam imagens detalhadas de diferentes tipos de culturas, fornecendo informações sobre sua saúde e necessidades de forma rápida (HERRERA et al., 2024). Nos últimos anos, a tecnologia de sensoriamento remoto por VANTs têm avançado rapidamente, complementando gradualmente as deficiências das plataformas de sensoriamento remoto via satélite e em solo. Plataformas de sensoriamento remoto por VANTs podem adquirir imagens de alta resolução do dossel das plantações, utilizando diferentes sensores para avaliar vários parâmetros de crescimento das culturas (SONG et al., 2022).

Os sensores espectrais acoplados a VANTs coletam dados de radiância espectral de áreas vegetadas, que posteriormente são transformadas em reflectância e calculando índices de vegetação com base na reflectância espectral, incluindo as relacionadas aos comprimentos de onda visível das bandas vermelha, verde e infravermelha próxima. Essas informações são essenciais para a agricultura de precisão, pois fornecem dados valiosos sobre as plantas de maneira eficiente e precisa (ISHIDA et al., 2018).

O avanço da tecnologia dos VANTs ocasionou o aumento de seu uso significativamente na agricultura devido ao baixo custo associado a alguns modelos de VANTs que podem coletar dados de alta resolução em várias áreas, desempenhando um papel cada vez mais ativo no campo, promovendo práticas agrícolas sustentáveis e maior lucratividade. Além disso, sua utilização reduz a necessidade de recursos humanos e oferece medições precisas (ASLAN et al., 2022).

Os dados espectrais coletados por VANTs são dados precisos e eficientes sobre plantas, fornecendo informações valiosas para a agricultura de precisão, permitindo análises mais profundas devido aos dados de alta resolução espacial e temporal. Essas informações são importantes para o gerenciamento agrícola e estimativas de rendimento das culturas. (BADAGLIACCA et al., 2023; LOURENÇO et al., 2023).

A utilização de métodos de classificação de cultivos, como a amostragem

Red-Green-Blue (RGB) visível em áreas agrícolas irrigadas, desempenha um papel crucial na agricultura de precisão e no aumento da eficiência na produção de alimentos, onde essas imagens podem ser aplicadas tanto na análise do crescimento das culturas, como na detecção e controle de plantas invasoras (RIEHLE et al., 2020). A aplicação de imagens RGB exigem alguns cuidados, apesar de apresentar bons resultados para estimativa de índices, a iluminação variável resulta em alterações nas cores das imagens tornando desafiador comparar características fenotípicas da cultura ao longo do tempo e do espaço (SUN et al., 2024).

A aplicação das bandas espectrais do RGB na classificação de culturas é possível e rende resultados promissores, onde juntamente aplicado com métodos de aprendizagem de máquina obtiveram resultados satisfatórios na classificação de culturas forrageiras consorciadas em diferentes condições do solo, sendo as culturas da palma forrageira, moringa e gliricídia e as condições de solo exposto e solo com cobertura morta, tendo taxa de precisão acima de 85% sendo uma opção que viabiliza a aplicação de VANTs de baixo custo na agricultura de precisão (ANDRADE et al., 2024).

Os índices vegetativos (VIs) são desenvolvidos combinando várias bandas espectrais e são amplamente usados devido à sua fácil aplicação. Entre esses índices, o Índice de Vegetação por Diferença Normalizada (NDVI) é o mais comumente utilizado para avaliar o vigor vegetativo em sensoriamento remoto (CARUSO et al., 2023). O NDVI pode ser aplicado por VANTs com sensores multiespectrais para determinar o vigor, o estresse fisiológico e a atividade fotossintética da vegetação (GALLARDO-SALAZAR et al., 2023).

O NDVI é um índice vegetativo calculado com base na diferença na absorção de radiação pelas plantas nas bandas espectrais vermelha e infravermelha próxima (NIR) (ROUSE & HAAS, 1974). Sendo o NDVI um índice utilizado como indicador de biomassa fotossinteticamente ativa, aplicado com sucesso para a previsão de rendimento de várias culturas (WALSH et al., 2023). Entretanto, enfrenta limitações significativas devido à saturação e aos efeitos de sombras nas imagens (XU et al.,

2023).

Um novo índice visível (vNDVI), estimado a partir de câmeras RGB não calibradas em VAs, se mostrou altamente preciso na estimativa dos valores de NDVI, oferecendo uma alternativa de baixo custo para o sensoriamento remoto e a fenotipagem de plantas. O vNDVI superou outros índices que utilizam dados RGB, fornecendo resultados confiáveis na avaliação da saúde das culturas (COSTA et al., 2020).

Em mesmo contexto, o estudo objetiva: (I) Propor novo índice vegetativo ajustado para a região estudada, em específico para o vale do Mimoso; (II) comparar índices vegetativos RGB com o NDVI que é o índice biofísico de vegetação mais aplicado para monitoramento agrícola.

2. MATERIAL E MÉTODOS

2.1 Descrição da área de estudo

O estudo foi desenvolvido em um lote agrícola onde é realizado o plantio de palma forrageira orelha de elefante mexicana (*Opuntia stricta Haw.*). A cultura foi plantada em maio de 2022 com espaçamento entre linhas de 0,5 metros e espaçamento entre culturas de 0,2 metros.

O lote agrícola é irrigado com água de reuso, uma vez que esta é uma fonte alternativa de água possível de ser aplicada a irrigação de forrageiras. A irrigação é feita através do método do gotejamento, visto que é o indicado para irrigação com água de reuso, onde a vazão de sistema é de 6000 litros por dia, com turno de rega de 3 dias e com 90% de uniformidade no sistema de irrigação.

O lote agrícola, cujo a área experimental é de aproximadamente 350 metros quadrados está localizado no Vale Aluvial do Mimoso (Figura 1), que está inserido na Bacia do Alto Ipanema situado entre as coordenadas 8°34'17" e 8°18'11" de Latitude Sul e 37°1'35" e 36°47'20" de Longitude Oeste.

O Vale Aluvial do Mimoso apresenta cursos d'água intermitentes e clima predominante na região da Bacia do Alto Ipanema é caracterizado como semiárido

quente, de acordo com a classificação de Köppen, com precipitação média anual de 607 mm e temperatura média de 23 °C, e evapotranspiração potencial de aproximadamente 2.000 mm por ano, com alta variabilidade espaço-temporal dos eventos de precipitação (FONTES JÚNIOR & MONTENEGRO, 2017).

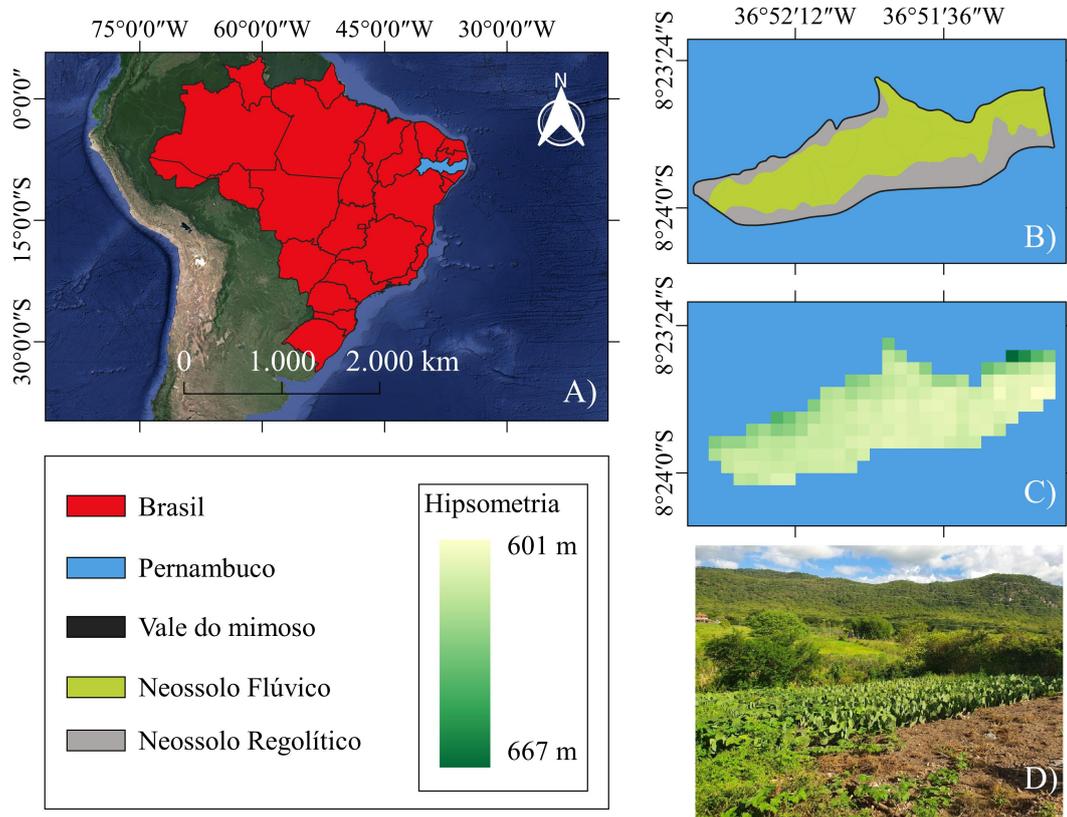


Figura 1. Mapa de localização (A), Solos vale do mimoso (B), Relevo vale do mimoso SRTM (C), Área experimental (D)

2.2 Sensoriamento remoto e cálculo dos índices vegetativos

As imagens multiespectrais e RGB foram adquiridas nos dias 23 de outubro de 2023, 09 de fevereiro de 2024 e 06 de abril de 2024. Os levantamentos foram realizados utilizando um Veículo Aéreo Não Tripulado (VANT), modelo DJI Phantom 4 Multispectral Real Time Kinematic (RTK), equipado com uma câmera de alta resolução espacial que captura simultaneamente seis imagens, sendo uma em composição RGB e cinco imagens espectrais monocromáticas: azul (B), verde (G), vermelho (R), borda vermelha (RE) e bandas de infravermelho próximo (NIR) (Tabela 1), gerando imagens com resolução de 2 Mega Pixels (MP).

Tabela 1. Comprimento de onda do sensor multiespectral

Phantom 4	Comprimento de onda (nm)
Azul (B)	450
Verde (G)	560
Vermelho (R)	650
RedEdge	730
Infravermelho próximo (NIR)	840

As características dos voos foram determinadas de acordo com as recomendações técnicas, respeitando as regulamentações da ANAC (Agência Nacional de Aviação Civil), o órgão regulador responsável pelas normas de voo no Brasil. Os voos foram realizados a uma velocidade uniforme de 2 m/s e a uma altura de 40 m. Uma missão de levantamento automático foi configurada para garantir 75% de sobreposição e lateralidade e foi aplicada para as datas do estudo. O tamanho por pixel foi de aproximadamente 2 cm² de área e a reflectância foi corrigida através do uso de um Painel Calibrador de Reflectância (PCR).

2.3 Processamento das imagens

Os processamentos no Metashape e QGIS foram realizados em um computador equipado com uma CPU Intel Core i7 10700F de 2,9 GHz, 8 núcleos e 16 threads, com frequência turbo máxima de 4,8 GHz. O computador também possui uma placa de vídeo rx550 com 4 GB de VRAM e 32 GB de memória RAM. A versão 2.1.2 (2023) do Agisoft Metashape Professional foi utilizada para o processamento dos dados, que posteriormente foram aplicados na plataforma QGIS 3.16.

2.3.1 Seleção das imagens via Agisoft Metashape

As imagens foram adicionadas através da adição de pasta, via aba “*Workflow*”, onde as referências pré-selecionadas foram o sistema de coordenadas World Geodetic System (WGS 84). Posteriormente as imagens passaram por uma pré avaliação e todas as imagens aplicadas obtiveram o parâmetro de aplicação do agisoft metashape como acima de 0,75.

2.3.2 Calibração das imagens via Agisoft Metashape

A calibração das imagens foi feita através das imagens de referências através da aba calibrar reflectância, disponível nas ferramentas, com a seleção de aplicar imagens do painel calibrador de reflectância para correção das imagens.

2.3.3 Alinhamento das imagens via Agisoft Metashape

O alinhamento das imagens é realizado através da ferramenta "Align Points" utilizando os dados de geolocalização e um algoritmo que identifica pontos homólogos entre elas. A qualidade desse processamento depende, entre outros fatores, do grau de sobreposição frontal e lateral entre as imagens. O resultado dessa etapa é a geração de uma nuvem esparsa de pontos.

2.3.4 Geração de nuvem densa de pontos via Agisoft Metashape

A densificação da nuvem de pontos foi feita utilizando a ferramenta "Build Dense Cloud", o programa aumenta a quantidade de pontos existentes, reduzindo os espaços vazios e representando a área mapeada com um maior nível de refinamento. O nível de qualidade selecionado foi o mais alto.

2.3.5 Geração de ortomosaico via Agisoft Metashape

A geração do ortomosaico foi feita através da ferramenta "Build Orthomosaic" por meio da ortorretificação das imagens, onde a partir dessa correção, é feita o mosaico, gerando um único produto final.

2.4 GRG Não Linear

Buscando desenvolver um índice RGB (Figura 2) que estime com confiabilidade os valores do Índice de Vegetação por Diferença Normalizada (NDVI) na região do semiárido brasileiro, o Índice de Vegetação por Diferença Normalizada Alternativo (aNDVI) (Equação 1) que depende apenas das bandas Azul, Verde e Vermelho, coeficientes de ajustes (C ; r^1 ; r^2 ; r^3 e A) que foram gerados através do ajuste não linear via GRG não linear com base nos dados de 23764 pontos retirados de forma regular das imagens de 09 de outubro de 2023, 23 de fevereiro de 2024 e 06 de abril de 2024.

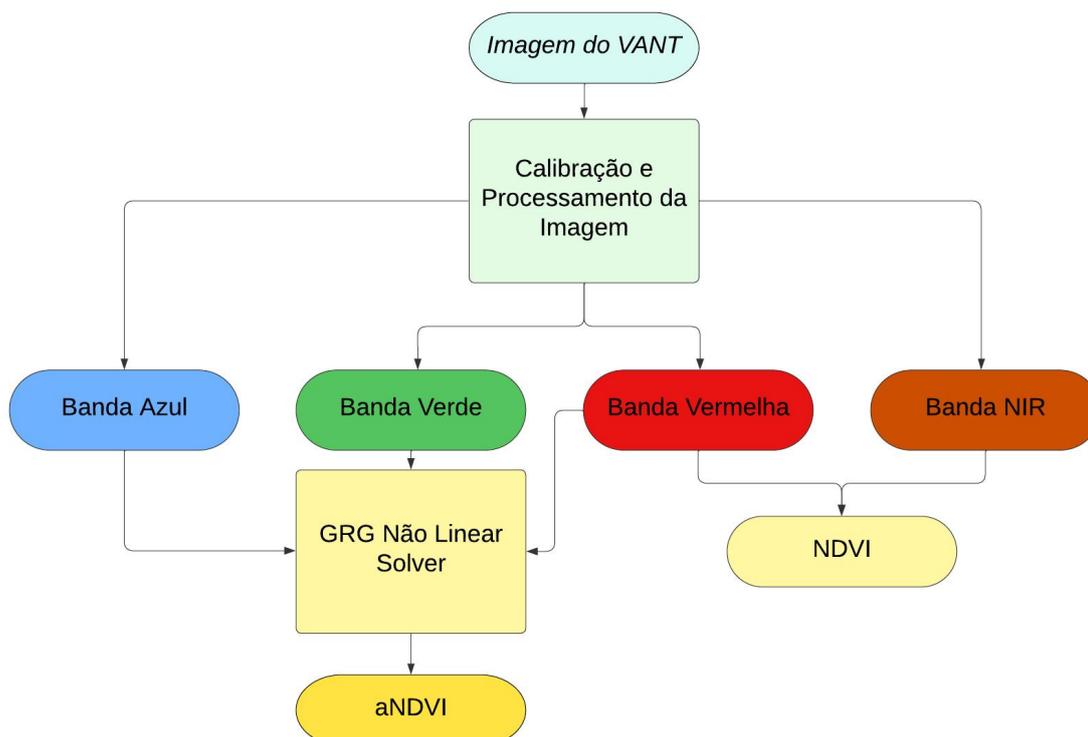


Figura 2. Fluxograma de aquisição de dados e processamento para obtenção do aNDVI

$$aNDVI = C * (B^{r^1} * G^{r^2} * R^{r^3}) + A \quad (1)$$

Onde: B- Reflectância de banda Azul, G- Reflectância de banda Verde, R- Reflectância de banda Vermelho, C- fator multiplicativo, A- fator aditivo.

O algoritmo não linear de gradiente reduzido generalizado (GRG) pode ser utilizado para induzir os coeficientes de forma que o erro seja minimizado, onde o algoritmo determina parâmetros que minimizam o valor do erro, com base nos coeficientes aplicados na equação. Uma vez que o algoritmo GRG é fortemente afetado pelos valores iniciais, o cálculo irá parar em uma região diferente da solução ótima, entretanto, o algoritmo é uma forte ferramenta na determinação de coeficientes de equações não linear, identificando rapidamente uma solução ótima próxima às condições iniciais, onde o algoritmo tem uma alta confiabilidade, visto que é um código comercial fornecido pela Microsoft via Microsoft Excel 365 (SIM et al., 2023).

O modelo inicial representado na Equação 1 foi escolhido utilizando como

base o modelo do vNDVI (Visible Normalized Difference Vegetation Index) (Equação 2), que foi desenvolvido utilizando algoritmo genético e apresentou resultados promissores (COSTA et al., 2020).

$$vNDVI = C * (R^{r^1} * G^{r^2} * B^{r^3}) \quad (2)$$

2.5 Classificação de índices

As imagens foram utilizadas para o cálculo de diferentes índices: Índice de Vegetação da Diferença Normalizada Visível (vNDVI), Índice de Diferença de Banda Visível para Vegetação (VDVI), Índice de Resistência Atmosférica Verde Modificado e Visível (VARI), Índice de Vegetação Vermelho Verde e Azul (RGBVI), Índice de Diferença Normalizada Verde Azul (NGRDI), Índice de Diferença Normalizada Verde Azul (NGBDI), Índice de Vegetação Vermelho e Azul Modificado (MRBVI), Índice de Verde Vermelho Modificado (MGRVI), Índice de Diferença de Excesso Verde Vermelho Azul (EGRBDI), Índice de Estresse Hídrico 4 (DWSI-4) e o Índice de Folha Verde (GLI). Os índices foram calculados conforme a Tabela 2.

Tabela 2. Índices de vegetação aplicados para índices biofísicos

Índice	Fórmula	Referência
vNDVI	$vNDVI = 0,5268 * (R^{-0,1294} * G^{0,3389} * B^{-0,3118})(2)$	(COSTA et al., 2020)
NDVI	$NDVI = \frac{NIR - R}{NIR + R}(3)$	(ROUSE; HAAS, 1974)
VDVI	$VDVI = \frac{(2G - R - B)}{2G + R + B}(4)$	(WANG et al., 2015)
VARI	$VARI = \frac{G - R}{G + R - B}(5)$	(SCHNEIDER et al., 2008)
RGBVI	$RGBVI = \frac{G^2 - B * R}{G^2 + B * R}(6)$	(BENDIG et al., 2015)
NGRDI	$NGRDI = \frac{G - R}{G + R}(7)$	(HUNT et al., 2005)
NGBDI	$NGBDI = \frac{G - B}{G + B}(8)$	(HUNT et al., 2005)
MRBVI	$MRBVI = \frac{R^2 - B^2}{R^2 + B^2}(9)$	(GUO et al., 2020)
MGRVI	$MGRVI = \frac{G^2 - R^2}{G^2 + R^2}(10)$	(BENDIG et al., 2015)
EGRBDI	$EGRBDI = \frac{(2 * G)^2 - (B * R)}{(2 * G)^2 + (B * R)}(11)$	(GAO et al., 2020)
DWSI-4	$DWSI_4 = \frac{G}{R}(12)$	(DUTTA et al., 2006)

Onde as bandas: B- Azul, G- Verde, R- Vermelho, NIR, Infravermelho Próximo

2.6 Métricas de avaliação

O Erro Quadrático Médio (RMSE, do inglês Root Mean Squared Error) e o Erro Médio Absoluto (MAE, do inglês Mean Absolute Error) são métricas amplamente utilizadas para avaliar modelos de estimativa e predição de valores. O RMSE é uma métrica adequada para erros gaussianos que são normalmente distribuídos, enquanto o MAE é uma métrica mais robusta sendo ótimo para erros laplacianos. Quando os erros se desviam dessas distribuições, outras métricas são superiores (HODSON, 2022).

O coeficiente de correlação mede a proximidade das observações emparelhadas quando são plotadas uma contra a outra, seguindo uma linha reta com inclinações positivas ou negativas. Uma correlação perfeita ($r=1$) não garante concordância absoluta. A concordância avalia o quão próximo a linha dos pontos está da linha $y=x$, e o coeficiente de concordância de Nash-Sutcliffe é usado como uma métrica de desempenho, especialmente em hidrologia para avaliar a confiabilidade de previsões de modelos variando de $-\infty$ a 1 (RASMUSSEN et al., 2021).

2.6.1 Erro Médio Absoluto

O Erro Médio Absoluto MAE mede a média das diferenças absolutas entre os valores previstos e os valores observados. Indica o quão perto as previsões estão dos valores reais.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

- n é o número de observações.
- y_i são os valores observados.
- \hat{y}_i são os valores previstos.

2.6.2 Erro Quadrático Médio

O Erro Quadrático Médio (RMSE) é a raiz quadrada da média dos quadrados dos erros. É mais sensível a grandes erros do que o MAE, pois os erros são quadrados antes de serem promediados.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

- n é o número de observações.
- y_i são os valores observados.
- \hat{y}_i são os valores previstos.

2.6.3 Coeficiente de Determinação (R^2)

O Coeficiente de Determinação (R^2) mede a proporção da variação nos valores observados que é explicada pelo modelo. Varia entre 0 e 1, onde 1 indica uma previsão perfeita.

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

- n é o número de observações.
- y_i são os valores observados.
- \bar{y} é a média dos valores observados.

2.6.4 Coeficiente de Eficiência de Nash-Sutcliffe (NSE)

O Coeficiente de Eficiência de Nash-Sutcliffe (NSE) mede a eficiência preditiva de um modelo. Varia de $-\infty$ a 1, onde 1 indica uma previsão perfeita, 0 indica que o modelo é tão bom quanto a média dos valores observados, e valores negativos indicam que o modelo é pior que a média dos valores observados.

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

3. RESULTADOS

3.1 Processamento das imagens

Os monitoramentos realizados em 09 de outubro de 2023, 23 de fevereiro de 2024 e 06 de abril de 2024 (Figura 3) apresentaram diferentes qualidades visuais, visto que ambas tiveram diferentes características

climáticas, onde a presença de nuvens afeta a iluminação das imagens, tais características poderiam ser contornadas, com a realização do voo em outras datas, mas devido a distância de 240km entre o campus universitário e a área experimental, não pode ser realizado. Os índices vegetativos que utilizam as bandas RGB são sensíveis a essa mudança de iluminação, como o NDVI é um índice que utiliza a banda do vermelho, ele acaba sofrendo essa influência, o mesmo não ocorre com índices que usam as bandas de diferentes comprimentos de onda do infravermelho, como o NDWI (ARROYO-MORA et al., 2021).

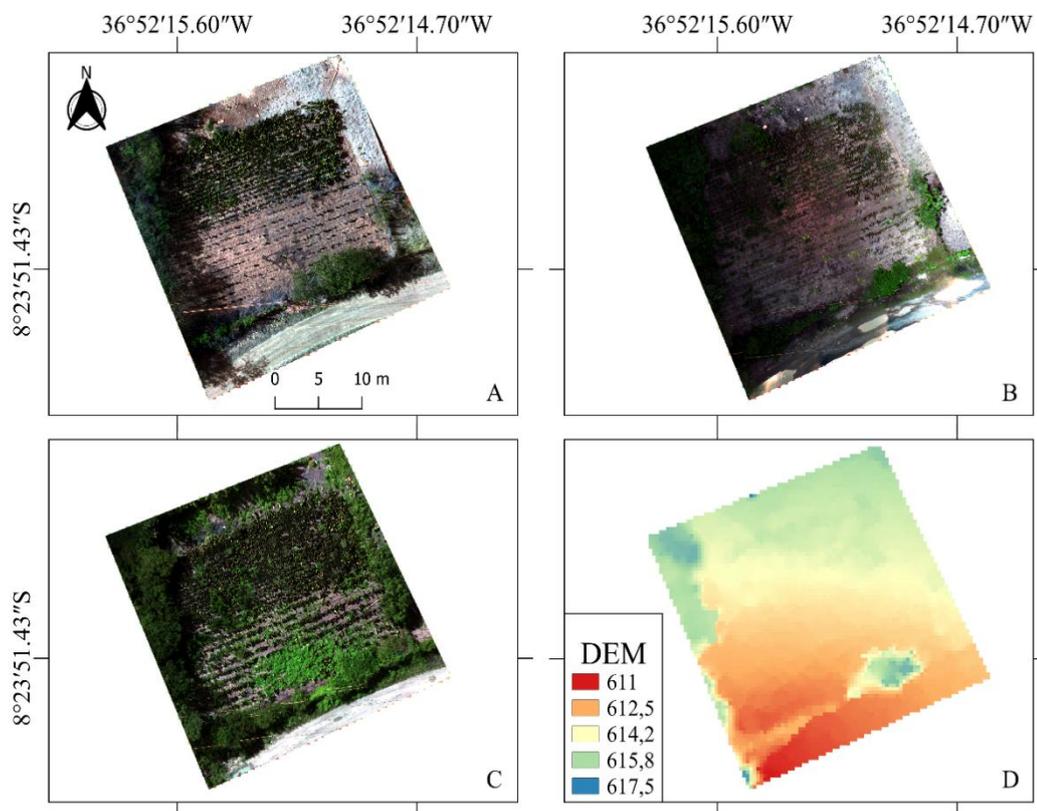


Figura 3. Imageamento 09/10/2023 (A) Imageamento 23/02/2024 (B)
Imageamento 06/04/2024 (C) Modelo Digital de Elevação (D)

3.2 aNDVI

O índice aNDVI (Equação 13) teve os coeficientes calibrados pelo GRG não linear e apresentou melhores resultados quando correlacionado com o

NDVI, com R^2 de 0,8475 em comparação ao vNDVI com R^2 de 0,7466 para os 23674 pontos retirados aleatoriamente dos 3 voos referentes às imagens de 09 de outubro de 2023, 23 de fevereiro de 2024 e 06 de abril de 2024 (Figura 4). Essa melhora de correlação ocorre devido ao modelo ser produzido com os dados relacionados as imagens analisadas, mas de forma similar, os resultados médios do vNDVI proposto por Costa et. al. (2020) para três áreas de citrinos, apresentou R^2 de 0,85. A apresentação de boa correlação nos pontos gerais não é um único fator de validação do modelo, sendo necessário uma investigação mais focada nas imagens utilizadas individualmente.

$$aNDVI = -0,64425 * (B^{0,029135} * G^{(-0,42464)} * R^{0,471079}) + 1,632973 \quad (13)$$

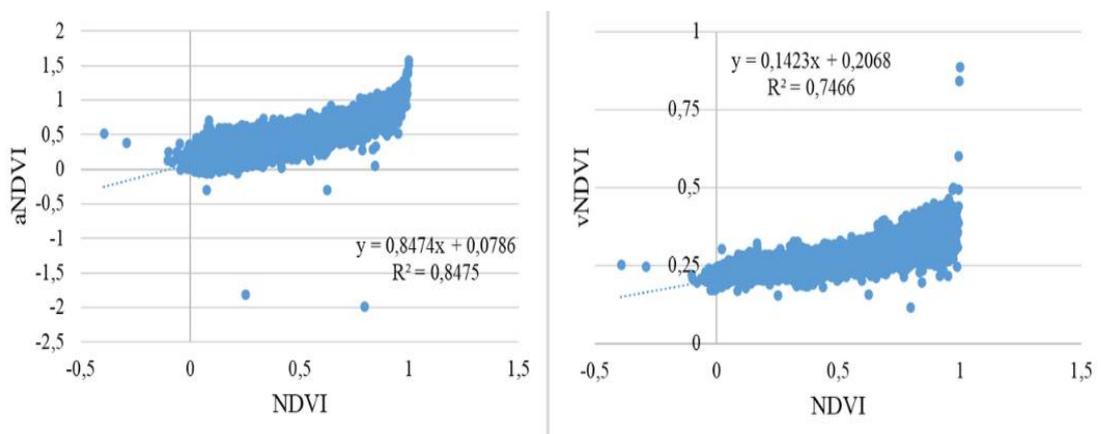


Figura 4. Correlação linear aNDVI vs NDVI e vNDVI vs NDVI

3.2.1 Análise dos índices multiespectrais

3.2.1.1 Métricas de ajuste

O imageamento dos meses de outubro de 2023, fevereiro de 2024 e abril de 2024 foram processados, e os índices de vegetação (Equações 3 a 13) foram gerados para cada data. O coeficiente de determinação R^2 indicou boa qualidade de ajuste dos modelos onde o aNDVI e vNDVI, apresentaram resultados mais precisos, enquanto o NGRDI e o MGRVI também apresentaram bons resultados. O índice aNDVI apresentou coeficientes de correlação de 70,0%; 88,0% e 85,0% respectivamente para as datas estudadas, onde o resultado inferior no mês de outubro se dá as diferenças agroclimatológicas acarretadas pela precipitação recente (Figura 1). Uma vez que o índice foi calibrado aplicando dados de pontos regulares nas imagens, com diferentes condições climáticas, é esperado uma

melhor resposta para condição mais favorável. O índice vNDVI apresentou coeficientes de correlação de 73,0%; 75,0% e 67,0% respectivamente para as datas estudadas, onde o bom resultado era esperado, indicando um bom ajuste para meses mais secos na região. Já o índice NGRDI apresentou respectivamente 59,0%; 80% e 69% enquanto o MGRVI apresentou 61,0%; 82,0% e 73,0%. Os demais índices não apresentaram correlações satisfatórias. Sendo os quatro índices RGB citados que melhor se correlacionaram com o NDVI (Figura 5). A percepção de que os índices aNDVI, VNDVI, NGRDI e MGRVI são os índices mais ajustados ao modelo do NDVI, é um indicativo de que ambos podem ser aplicados como um possível índice estimativo de biomassa fotossinteticamente ativa, tal qual o NDVI.

09-10-2023	NDVI	aNDVI	vNDVI	VDVI	VARI	RGVBI	NGRDI	NGBDI	MRVBI	MGRVI	EGRBDI	DSWI-4
NDVI	1,00											
aNDVI	0,70	1,00										
vNDVI	0,73	0,77	1,00									
VDVI	0,43	0,55	0,63	1,00								
VARI	0,21	0,29	0,23	0,30	1,00							
RGVBI	0,38	0,43	0,58	0,97	0,26	1,00						
NGRDI	0,59	0,85	0,66	0,80	0,34	0,70	1,00					
NGBDI	0,02	0,00	0,14	0,45	0,04	0,57	0,08	1,00				
MRVBI	0,35	0,61	0,22	0,09	0,16	0,04	0,48	0,24	1,00			
MGRVI	0,61	0,84	0,67	0,79	0,35	0,69	1,00	0,07	0,49	1,00		
EGRBDI	0,29	0,40	0,50	0,91	0,23	0,93	0,62	0,59	0,02	0,60	1,00	
DSWI-4	0,55	0,74	0,64	0,75	0,29	0,68	0,94	0,09	0,43	0,93	0,55	1,00
23-02-2023	NDVI	aNDVI	vNDVI	VDVI	VARI	RGVBI	NGRDI	NGBDI	MRVBI	MGRVI	EGRBDI	DSWI-4
NDVI	1,00											
aNDVI	0,88	1,00										
vNDVI	0,75	0,88	1,00									
VDVI	0,72	0,84	0,84	1,00								
VARI	0,60	0,71	0,60	0,69	1,00							
RGVBI	0,68	0,79	0,82	0,99	0,69	1,00						
NGRDI	0,80	0,93	0,82	0,95	0,77	0,91	1,00					
NGBDI	0,28	0,35	0,56	0,69	0,32	0,75	0,48	1,00				
MRVBI	0,64	0,71	0,42	0,46	0,56	0,39	0,67	0,03	1,00			
MGRVI	0,82	0,93	0,80	0,95	0,75	0,91	1,00	0,47	0,68	1,00		
EGRBDI	0,66	0,76	0,76	0,95	0,66	0,98	0,87	0,75	0,36	0,88	1,00	
DSWI-4	0,46	0,57	0,55	0,60	0,93	0,58	0,65	0,31	0,43	0,61	0,53	1,00
06-04-2024	NDVI	aNDVI	vNDVI	VDVI	VARI	RGVBI	NGRDI	NGBDI	MRVBI	MGRVI	EGRBDI	DSWI-4
NDVI	1,00											
aNDVI	0,85	1,00										
vNDVI	0,67	0,85	1,00									
VDVI	0,45	0,61	0,72	1,00								
VARI	0,17	0,24	0,19	0,14	1,00							
RGVBI	0,46	0,63	0,72	0,98	0,16	1,00						
NGRDI	0,69	0,91	0,82	0,81	0,25	0,84	1,00					
NGBDI	0,05	0,10	0,27	0,68	0,01	0,64	0,26	1,00				
MRVBI	0,55	0,66	0,36	0,12	0,22	0,14	0,50	0,06	1,00			
MGRVI	0,73	0,92	0,80	0,81	0,24	0,84	0,99	0,26	0,49	1,00		
EGRBDI	0,42	0,59	0,65	0,93	0,14	0,96	0,78	0,61	0,12	0,80	1,00	
DSWI-4	0,02	0,04	0,10	0,03	0,01	0,03	0,05	0,01	0,03	0,03	0,03	1,00

Figura 5. Correlação índices Vegetação

A frequência relativa acumulada foi aplicada para entender como se 60

distribuem os dados ao longo dos voos realizados e é perceptível que o comportamento do aNDVI é o que mais se comporta como o NDVI, com exceção dos máximos e mínimos (Figura 6).

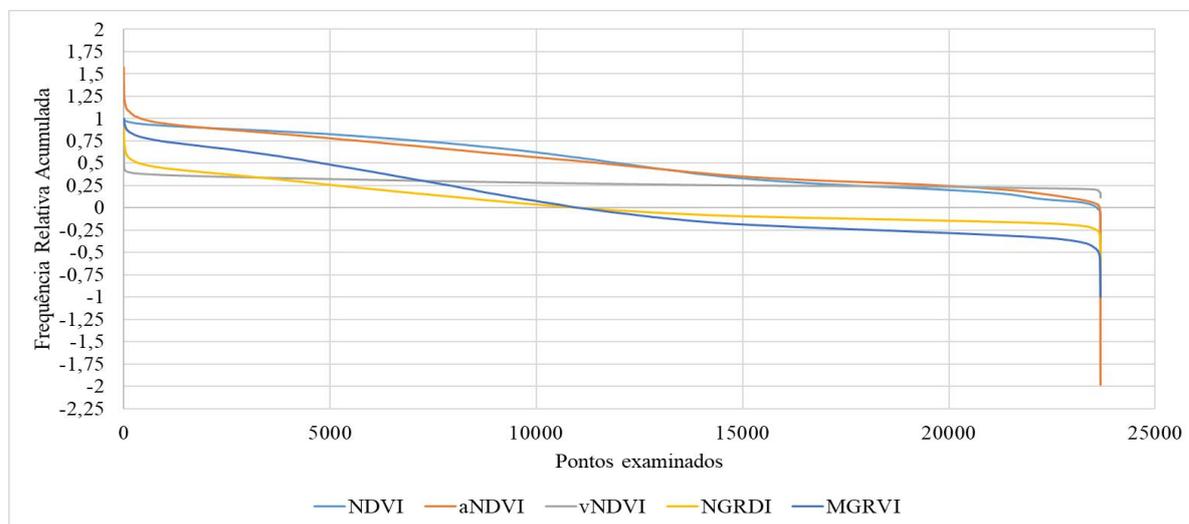


Figura 6. Frequência relativa acumulada dos dados amostrais de imageamentos de 09-10-2023; 23-02-2024 e 06-04-2024

A Frequência relativa acumulada age como um determinador da distribuição dos dados do conjunto analisado e para complementar a informação, foi aplicado as métricas de erro MAE e RMSE (Tabela 3). Valores de MAE próximos de 0 indicam que os valores estimados do modelo estão mais próximos dos valores reais medidos do NDVI.

Os pontos fora da curva (Figura 7) são ocasionados pelo fato de que a equação possui um fator de ajuste, ou seja, quando alguma das bandas RGB aplicadas possuem valores atípicos, os valores estimados são superestimados, mas esses valores estimados acima de 1 e abaixo de 0 não representam significância estatística, visto que são apenas 487 pontos dos 23674 coletados, representando 1,846%.

Os valores medianos entre o NDVI e o aNDVI são próximos, onde o NDVI tem mediana aproximada de 0,5 e o aNDVI de 0,45 enquanto os demais índices não desempenham de mesma maneira, além disso, notasse que apesar de maior proximidade de valores, o aNDVI possui menor variabilidade que o NDVI e mais

outliers, apresentando valores acima de 1 e abaixo de -1, devido a pixels sem informações registradas, o que acarreta na extrapolação dos resultados. O NDVI é um índice normalizado que varia de -1 até 1, mas valores abaixo de 0 são comumente associados a superfícies aquáticas, neve ou nuvens (KLIMAVIČIUS et al., 2023).

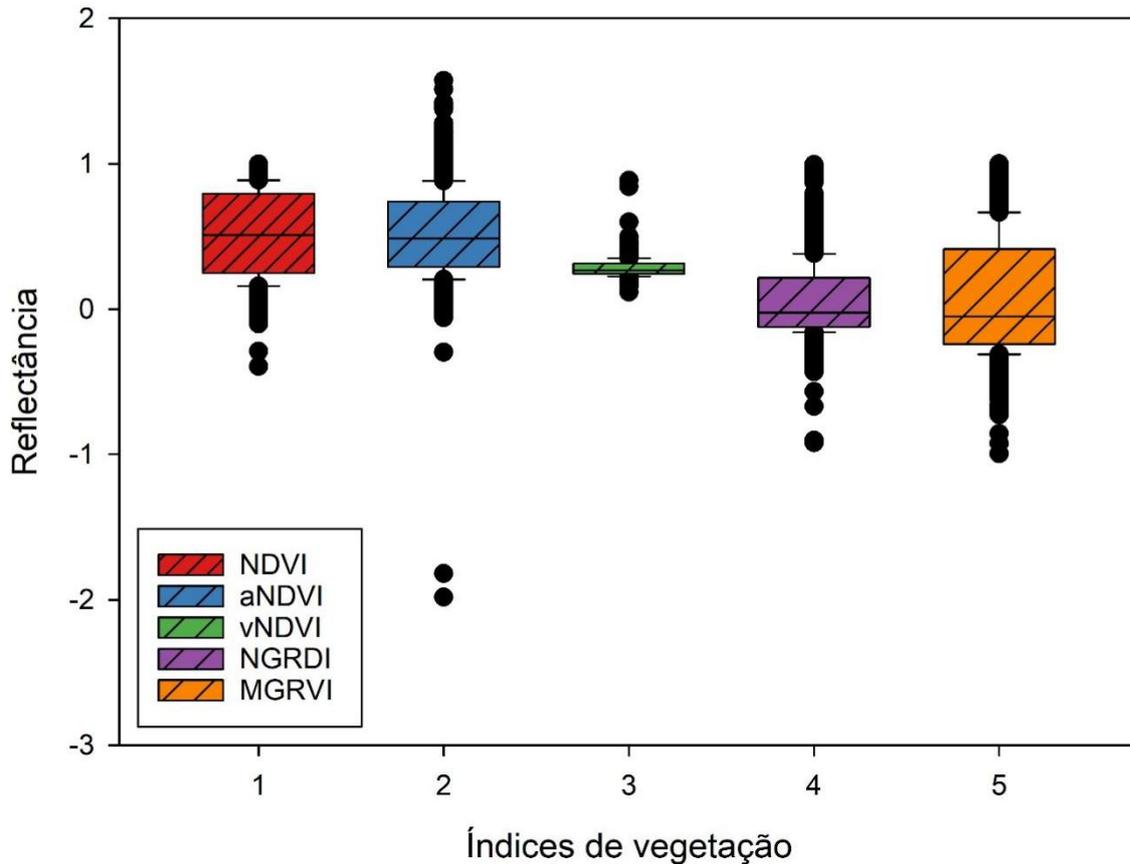


Figura 7. Diagrama de caixa dos dados amostrais de imageamentos de 09-10-2023; 23-02-2024 e 06-04-2024

O imageamento do mês de outubro apresentou MAE igual a 0,10, o que implica em um bom ajuste, principalmente quando comparado ao vNDVI, NGRDI e MGRVI que apresentaram MAE igual a 0,18; 0,44 e 0,49 respectivamente (Tabela 3). Este resultado é muito promissor, uma vez que o mês de outubro é o mês de menor correlação entre o aNDVI e o NDVI. O RMSE suplementa a afirmação de que o ajuste do modelo está acurado, onde o RMSE calculado foi de 0,02 para o aNDVI e contraste aos valores de 0,06; 0,22 e 0,27 do vNDVI, NGRDI e MGRVI

respectivamente (Tabela 3).

Para o mês de outubro é evidente que os valores dos erros serão minimizados em comparação ao mês de fevereiro e abril, devido a ser um mês com menor disponibilidade hídrica (Figura 1), o que implica em menor variação na faixa de valores estimados no NDVI. Por fim, o índice Nash-Sutcliffe Efficiency (NSE) suplemente a afirmação de que o modelo está bem ajustado, uma vez que ele varia $-\infty$ a 1.

Para os meses de fevereiro e abril ocorreu de forma similar, mas devido a maior variação da faixa de valor do NDVI, devido ao aumento de água disponível para as culturas, acaba apresentando valores mais altos de erro de modo geral.

O índice aNDVI respondeu bem aos momentos de alta umidade no solo e nas culturas, uma vez que no mês de fevereiro apresentou MAE de 0,08 em comparação a 0,21; 0,44 e 0,46 respectivamente para os índices vNDVI, NGRDI e MGRVI e 0,07 em comparação a 0,42; 0,51 e 0,36 respectivamente para os índices vNDVI, NGRDI e MGRVI.

Os valores apresentados de RMSE representaram o bom ajuste do modelo de forma semelhante, onde em fevereiro o aNDVI apresentou RMSE de 0,1 enquanto o vNDVI, NGRDI e MGRVI apresentaram 0,29; 0,45 e 0,48 respectivamente. Já para o mês de abril os resultados foram ainda melhores, onde o RMSE do aNDVI foi de 0,09 enquanto o vNDVI, NGRDI e MGRVI apresentaram 0,45; 0,53 e 0,4 respectivamente. Tais valores de RMSE suplementam a afirmação de que o índice aNDVI possui resposta superior aos demais índices na área do vale do mimoso, em período chuvoso. De modo a complementar a análise o índice Nash-Sutcliffe Efficiency (NSE) apresentou ótimos resultados, sendo de 0,84 e 0,85 para fevereiro e abril respectivamente, em comparação aos índices vNDVI de -0,2 e 0,64 NGRDI de -2 e 0,52 e o MGRVI de -2,38 e 0,72.

Tabela 3. Métricas de erro dos índices com melhores estimativas do NDVI.

aNDVI	vNDVI	NGRDI	MGRVI
-------	-------	-------	-------

Data	MA	RMSE	NSE	MAE	RMSE	NSE	MAE	RMSE	NSE	MAE	RMSE	NSE
	E											
09/10/23	0,10	0,02	0,65	0,18	0,06	-0,1	0,44	0,22	-3,3	0,49	0,27	-4,15
23/02/24	0,08	0,10	0,84	0,21	0,29	-0,2	0,44	0,45	-2,0	0,46	0,48	-2,38
06/04/24	0,07	0,09	0,85	0,42	0,45	0,64	0,51	0,53	0,52	0,36	0,40	0,72

3.2.1.2 Índices multiespectrais

A análise de índices multiespectrais pode dar-se de duas maneiras, sendo elas a análise matemática e a análise visual dos índices. Os índices NDVI, aNDVI, vNDVI, NGRDI e MGRVI foram contrastados (Figura 8).

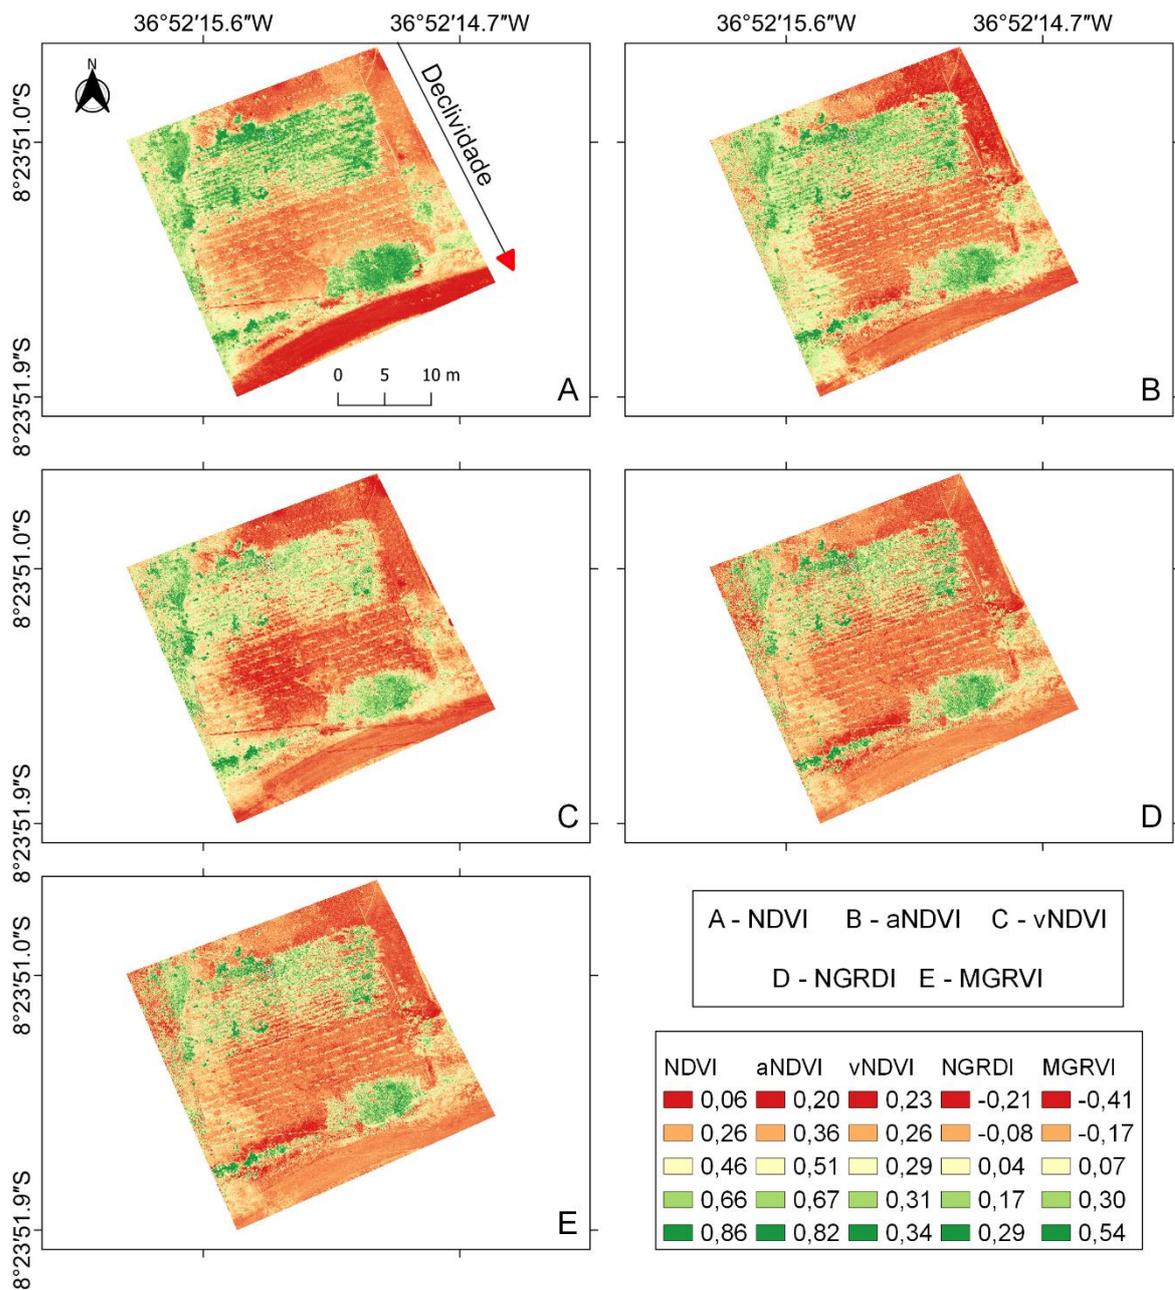


Figura 8. Índice NDVI e principais Índices da banda visível do imageamento do dia 09-10-2023 onde (A) NDVI; (B) aNDVI; (C) vNDVI; (D) NGRDI e (E) MGRVI

A região superior da área de plantio no mês de outubro de 2023 apresenta maiores valores de NDVI e por consequência dos outros índices analisados, isso se dá pelo fato da palma forrageira plantada naquela área estar em um período mais avançado do ciclo cultural. A escala dos índices foi feita utilizando o método de

processamento (real mais lento) da plataforma de acesso livre QGIS na versão 3.16. Esse tipo de processamento ajusta de forma mais precisa a escala de variação dos pixels, logo, os valores demonstrados na Figura 8 representam da melhor forma possível a distribuição nas imagens, isso implica que os valores de máximo do aNDVI se aproxima dos valores de máximo do NDVI, uma vez que são descritos como 0,82 e 0,86 respectivamente, entretanto, para valores de mínimo, existe uma diferença na faixa dos dados, onde o NDVI apresenta mais valores próximos a 0 para solo exposto que o aNDVI. De forma semelhante aconteceu com o vNDVI, porém com uma escala de valores muito reduzidas de 0,23 a 0,34 indicando um problema de ajuste dos parâmetros da equação para área. Os valores médios do NDVI e do aNDVI para todos os pontos do mapa gerado é bem próximo, enquanto os valores de máximo e mínimo destoam bastante, isso acontece em poucos pixels, próximos a áreas de pixel sem informação de alguma das bandas aplicadas. Já os valores médios do NDVI em comparação com o vNDVI, NGRDI e MGRVI são bem distintos, onde os valores médios de NGRDI e MGRVI são negativos.

Tabela 4. Estatística descritiva outubro 2023

	Máximo	Média	Mínimo	Desvio Padrão	Variância
NDVI	1,00	0,40	-0,99	0,23	0,052
aNDVI	1,55	0,44	-4,11	0,17	0,029
vNDVI	0,77	0,27	0,07	0,03	0,001
NGRDI	0,99	-0,05	-0,97	0,13	0,017
MGRVI	1,0	-0,09	-1	0,24	0,058

O imageamento feito em fevereiro sofreu problemas quanto à presença do sombreamento causado por nuvens, que afetou a visualização da imagem RGB (Figura 3), mas devido à presença do painel calibrador de reflectância, os dados calibrados não sofreram problemas nos valores, de tal forma que a correlação entre os índices foi adequada e as métricas de validação apresentadas foram satisfatórias. O mês de fevereiro teve uma elevada precipitação antecedente no período de 90 dias (Figura 1) o que acarretou um aumento na vegetação arbórea do local, como pode-se notar no lado esquerdo das imagens (Figura 9). Essa presença mais efetiva da cultura arbórea da caatinga que tem uma resposta rápida à disponibilidade

hídrica para a cultura, é um fator que aumenta a variedade dos dados na imagem.

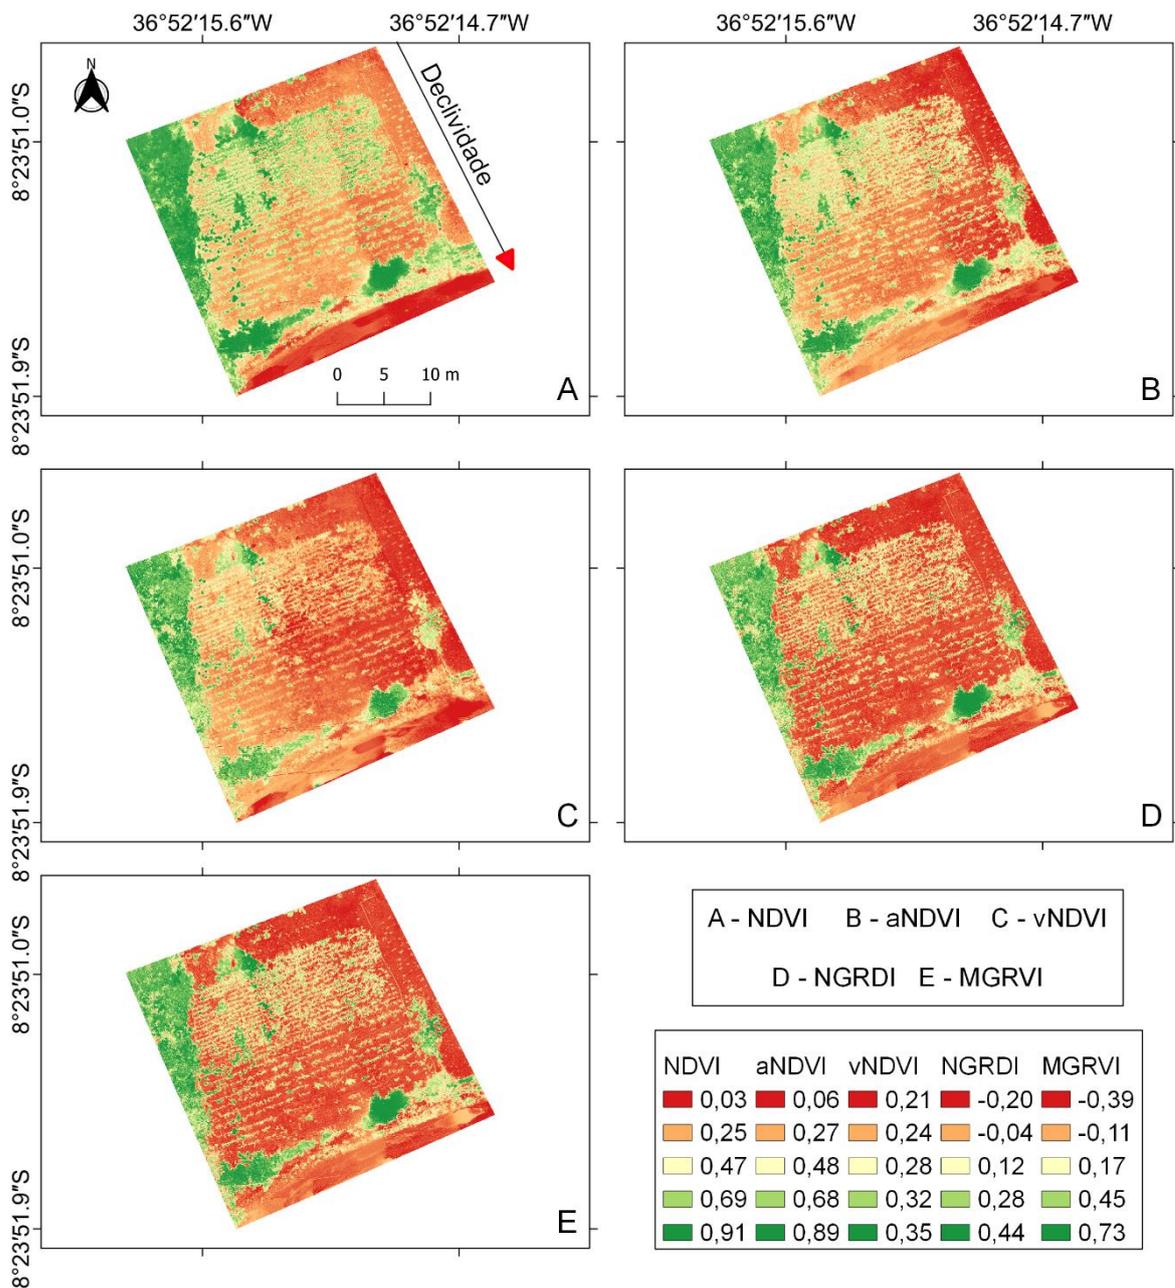


Figura 9. Índice NDVI e principais Índices da banda visível do imageamento do dia 23-02-2024 onde (A) NDVI; (B) aNDVI; (C) vNDVI; (D) NGRDI e (E) MGRVI

Os valores médios do NDVI e do aNDVI para todos os pontos do mapa gerado não são tão próximos quanto no mês anterior, ainda que próximos, é possível notar que no canto superior direito, os valores do solo exposto são mais baixos que o do NDVI, mesmo que neste caso, a escala de valores é muito mais

próxima. Os valores de máximo e mínimo destoam, mas são mais próximos que os apresentados em outubro, mas de forma semelhante, os valores de máximo e mínima acontecem em poucos pixels, também próximos a áreas de pixel sem informação de alguma das bandas aplicadas, visto que o índice aNDVI usa as três bandas do espectro visível RGB, é esperado que qualquer ruído apresentado em pixels mortos possa aumentar ou diminuir os valores de pixel de forma abrupta. A Tabela 5 apresenta a estatística descritiva para o mês de fevereiro de 2024.

Tabela 5. Estatística descritiva fevereiro 2024.

	Máximo	Média	Mínimo	Desvio Padrão	Variância
NDVI	1,00	0,43	-0,36	0,26	0,068
aNDVI	1,55	0,38	-2,32	0,24	0,058
vNDVI	1,33	0,25	0,09	0,04	0,002
NGRDI	0,99	-0,01	-0,91	0,18	0,017
MGRVI	1,00	-0,03	-0,99	0,34	0,058

O monitoramento do dia 06 de abril de 2024 foi realizado sem a presença de nuvens, o que resultou em imagens de ótima qualidade visual devido a iluminação uniforme na área (Figura 3), no entanto, devido ao aumento de precipitação nos dias que antecederam o monitoramento, houve um aumento significativo de plantas invasoras, de cunho nativo, que devido ao alto teor de disponibilidade hídrica, cresceram rapidamente (Figura 1). Devido à declividade do terreno, a água escoou para parte inferior do terreno, o que intensificou a ação das plantas nativas, que sobrepujaram a palma forrageira (Figura 10), tornando as três imagens apresentadas neste trabalho completamente diferentes. As culturas que invadiram a área experimental são herbáceas, como a *mimosa pudica*, que são comuns na caatinga e na mata atlântica, tendo rápido crescimento.

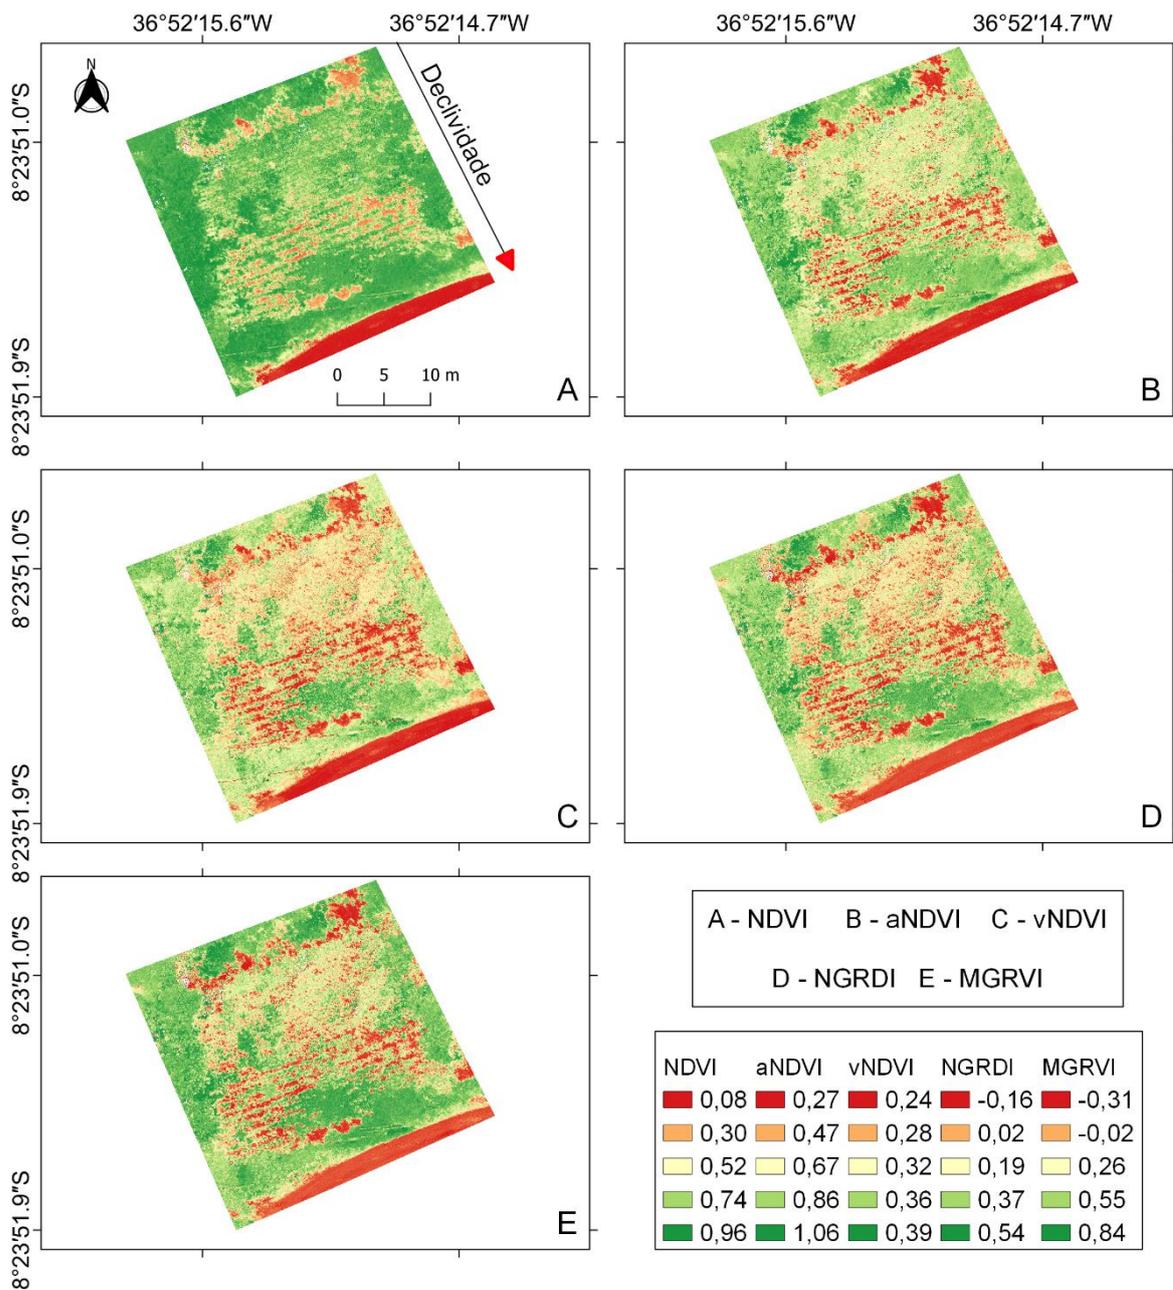


Figura 10. Índice NDVI e principais Índices da banda visível do imageamento do dia 06-04-2024 onde (A) NDVI; (B) aNDVI; (C) vNDVI; (D) NGRDI e (E) MGRVI

Os valores médios do NDVI e do aNDVI para todos os pontos do mapa gerado são próximos de tal maneira que o arredondamento do quarto algarismo significativo iguala os valores, assim como o desvio padrão e a variância, que são próximos. Apesar disso, é possível notar que o vigor vegetativo aparenta ser maior visualmente no NDVI, que nos índices RGB analisados (Figura 10). No entanto, não

impossibilita o uso dos índices RGB tão próximos quanto no mês anterior, ainda que próximos, é possível notar que no canto superior direito, os valores do solo exposto são mais explícitos que o do NDVI, uma vez que o índice NDVI é mais associado a plantas sendo necessário a aplicação do índice de vegetação ajustado ao solo (SAVI) que é proveniente de um fator de ajuste de acordo com o tipo de vegetação local (RADOČAJ et al., 2023). A Tabela 6 apresenta a estatística descritiva para o mês de abril de 2024.

Tabela 6. Estatística descritiva abril 2024

	Máximo	Média	Mínimo	Desvio Padrão	Variância
NDVI	1,00	0,73	-0,97	0,24	0,058
aNDVI	1,58	0,73	-7,36	0,22	0,048
vNDVI	2,44	0,32	0,05	0,04	0,002
NGRDI	1	0,21	-1	0,2	0,040
MGRVI	1,0	0,37	-1	0,35	0,123

A palma forrageira orelha de elefante mexicana apresentou bom comportamento na distribuição de dados obtidos nos dias 09/10/2023, 23/02/2024 e 06/04/2024 (Figura 11). O índice aNDVI foi o que mais se aproximou do índice NDVI, mesmo que apresentando outliers fora da escala normalizada do NDVI, o que ocorre devido ao aNDVI não ser um índice normalizado, mas sim um índice que estima valores de NDVI, sendo susceptível a valores fora da escala.

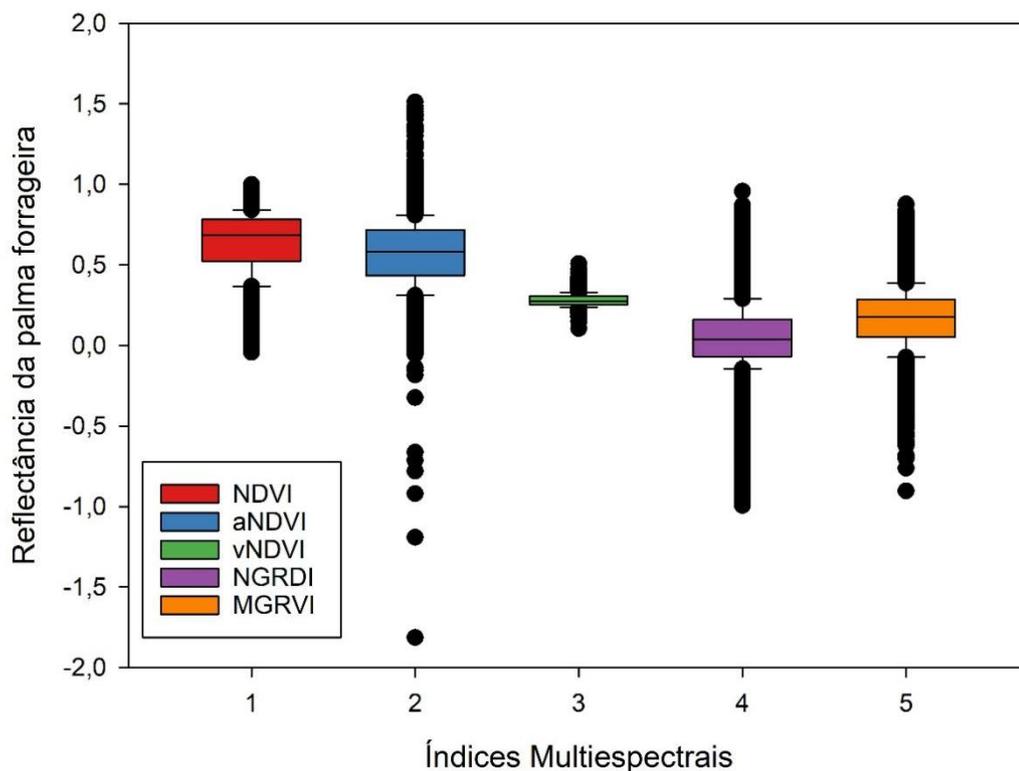


Figura 11. Diagrama de caixa da Palma Forrageira Orelha de Elefante Mexicana agrupados dos imageamentos realizados nas datas 09/10/2023, 23/02/2024 e 06/04/2024.

4. DISCUSSÃO

Índices vegetativos RGB são dotados de informações muito ricas a respeito de culturas agrícolas, podendo ser aplicada juntamente a conceitos de Internet das Coisas (IoT) maximizando a produtividade agrícola, compactuando com uma melhora nas atividades agrícolas que são um dos pilares da economia global e do desenvolvimento humano (LI et al., 2023).

Avanços na agricultura estão alinhados diretamente com a ODS 2 (fome zero) e por consequência com a ODS 1 (erradicação da pobreza) e a ODS 3 (saúde e bem estar) sendo crucial uma aplicação tecnológica na agricultura incorporando técnicas de agricultura de precisão, e agricultura sustentável (PANDEY & PANDEY 2022).

Em um trabalho realizado por Costa et al. (2020) foi desenvolvido um índice através de um algoritmo genético, com o propósito de estimar resultados do NDVI através das bandas visível (RGB) apresentando bons resultados, mas com diferentes correlações entre diferentes culturas como no caso de laranjal que apresentou R^2 de 0,79, do vinhedo com R^2 de 0,69 e por fim, o canavial com R^2 de 0,82.

Os resultados mostraram uma boa performance em estimar o NDVI na região semiárida pernambucana estudada, em um cultivo de forrageiras, com correlação geral de (0,85) demonstrando resultados sólidos quanto os índices propostos para VANTs já apresentados em literatura. Apesar de bons resultados, é possível evidenciar que o ajuste do índice a região no período mais seco não foi tão adequado quanto no período chuvoso, uma vez que no período mais seco, há uma maior amostra de pixels de solo exposto que possui valores de NDVI mais baixos que os pixels da palma forrageira e de plantas nativas que apareceram na área de cultivo ao longo dos meses, o que influencia de forma direta no ajuste do modelo, mas que ainda assim, apresentou melhores resultados de MAE, RMSE e NSE que os demais modelos aplicados.

O índice NGRDI foi desenvolvido por Hunt et al., (2005) como um índice de vegetação simples baseado em RGB para monitorar o crescimento e a biomassa das culturas, embora seja menos sensível em comparação com índices que utilizam bandas de infravermelho próximo (CHOUDHARY et al., 2021).

O índice MGRVI foi desenvolvido como um índice de vegetação RGB para o monitoramento automatizado e avaliação de culturas, vegetação e pastagens usando imagens RGB, tendo sido desenvolvido por Bendig et al. (2015) e sendo aplicado em pesquisas de baixo custo, cujo a aplicação de índices RGB é uma aplicação viável (BARBOSA et al., 2019).

Os índices com melhor resultado foram o aNDVI, vNDVI, NGRDI e MGRDI, que apresentaram os melhores resultados de acordo com as métricas de ajuste sendo o aNDVI o índice que se destacou e todos os quatro apresentam o fator em

comum de terem sido desenvolvidos como índices aplicáveis ao monitoramento de culturas.

A composição de formação mineralógicas dos solos afetam diferentemente na reflectância do mesmo, uma vez que diferentes minerais e frações que compõem o solo apresentam diferentes colorações e reflectâncias, o solo pode afetar diferentemente a resposta espectral do trigo, sendo o NDVI o índice que menos sofreu influência em relação ao SAVI e o EVI2 (PRUDNIKOVA et al., 2019). Tal afirmação implica no fato de que os índices RGB também são afetados de acordo com diferentes materiais de formação do solo.

As diferenças apresentadas entre o índice aNDVI e os demais índices citados neste trabalho estão associadas ao fato de que os índices citados não são ajustados para região do semiárido brasileiro, tão pouco ajustados para a cultura da palma forrageira, que é uma cultura com alto teor de clorofila e altamente resistente a ambientes semiáridos (JARDIM et al., 2021).

Além disto, as características de voo aplicadas com o VANT, foram de alta resolução espacial, com aproximadamente 2 cm² de área do pixel. Como limitações do estudo, sabe-se que uma abordagem ainda mais precisa poderia ser realizada com imagens de cunho diário ou até mesmo semanal, o que não foi possível neste estudo.

5. CONCLUSÃO

A agricultura de precisão é uma importante ferramenta para que seja possível alcançar as métricas dos objetivos de desenvolvimento sustentável (ODS), no entanto, é necessário um alto investimento, muitas vezes necessitando de um capital indisponível para o pequeno produtor.

Os índices de vegetação aplicados em VANTs são ferramentas de rápidos resultados analíticos, indicando regiões que precisam de melhor manejo, no entanto, para a maioria dos índices de vegetação aplicados, é necessário a aplicação de reflectância de banda infravermelho próximo (nir), presentes em câmeras

multiespectrais ou hiperespectrais que possuem custo de aquisição elevado. As câmeras RGB por sua vez, sendo mais baratas, constitui-se em uma alternativa de baixo custo.

Neste estudo, um índice visível foi desenvolvido com objetivo de estimar os valores do índice de vegetação NDVI, utilizando o algoritmo GRG não linear disponibilizado pela ferramenta solver, no aplicativo Excel disponibilizado pela empresa Microsoft Corporation, gerando assim o aNDVI (Índice De Vegetação Da Diferença Normalizada alternativo) sendo este uma função calibrada através do GRG não linear para a região da encosta do vale do mimoso no semiárido pernambucano, em particular para a região estudada. O índice aNDVI estimou valores de NDVI eficientemente nos três meses estudados, apresentado melhores estimativas nos meses chuvosos, onde a presença vegetativa foi maior, além disto, o índice estimou valores de NDVI para a palma forrageira orelha de elefante mexicana melhor que todos os índices de reflectância de banda visível (RGB) estudados.

Os resultados indicaram que o índice aNDVI desenvolvido no estudo representa melhor a região, tendo resultados próximos ao vNDVI no mês de outubro, que é um período seco, com R^2 de 0,7 contra 0,73 do vNDVI. Além disso, o aNDVI apresentou métricas de ajuste com menor erro, como MAE de 0,10 contra 0,18 do vNDVI, RMSE de 0,02 contra 0,06 e NSE de 0,65 contra -0,1, respectivamente. No período chuvoso, o índice aNDVI se sobressaiu a todos os outros. No mês de fevereiro, apresentou R^2 de 0,88 com MAE de 0,08, RMSE de 0,10 e NSE de 0,84. No mês de abril, apresentou R^2 de 0,85 com MAE de 0,07, RMSE de 0,09 e NSE de 0,85. O índice aNDVI pode ser aplicado a VANTs e ajustes podem ser feitos, para melhor representar uma determina área utilizando a metodologia aplicada.

6. AGRADECIMENTOS

Este projeto foi realizado com o apoio do CNPq (Projeto Universal processo 420.488/2018-9 e Projeto MAIDAI — Mestrado e Doutorado em Inovação, processo 403.488/2020-4, com contribuições financeiras da TPF Engenharia e Companhia Pernambucana de Saneamento-COMPESA para o reúso de águas residuais na

agricultura), da FACEPE (Fundação de Amparo à Ciência e Tecnologia de Pernambuco) (processo APQ 0414-5.03/20 para o desenvolvimento da cadeia econômica pecuária no Estado de Pernambuco) e do Ministério da Integração e Desenvolvimento Regional (MIDR), coordenado pelo Instituto Nacional do Semiárido (INSA). As bolsas também foram apoiadas pela CAPES-PrInt/UFRPE. Além disso, o estudo recebeu apoio de fundos portugueses através da Fundação para a Ciência e a Tecnologia, I.P. (FCT), sob as concessões UIDB/04292/2020, atribuídas ao MARE, e LA/P/0069/2020, atribuídas ao Laboratório Associado ARNET.

7. Referências

ANDRADE, O. B. D.; MONTENEGRO, A. A. D. A.; SILVA NETO, M. A. D.; SOUSA, L. D. B. D.; ALMEIDA, T. A. B.; DE LIMA, J. L. M. P.; CARVALHO, A. A. D.; SILVA, M. V. D.; MEDEIROS, V. W. C. D.; SOARES, R. G. F.; SILVA, T. G. F. D.; VILAR, B. P. UAV-Based Classification of Intercropped Forage Cactus: A Comparison of RGB and Multispectral Sample Spaces Using Machine Learning in an Irrigated Area. **AgriEngineering**, v. 6, n. 1, p. 509–525, 23 fev. 2024. DOI [10.3390/agriengineering6010031](https://doi.org/10.3390/agriengineering6010031). Disponível em: <https://www.mdpi.com/2624-7402/6/1/31>. Acesso em: 23 abr. 2024.

ARROYO-MORA, J. P.; KALACSKA, M.; LØKE, T.; SCHLÄPFER, D.; COOPS, N. C.; LUCANUS, O.; LEBLANC, G. Assessing the impact of illumination on UAV pushbroom hyperspectral imagery collected under various cloud cover conditions. **Remote Sensing of Environment**, v. 258, p. 112396, jun. 2021. DOI [10.1016/j.rse.2021.112396](https://doi.org/10.1016/j.rse.2021.112396). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425721001140>. Acesso em: 24 maio 2024.

ASLAN, M. F.; DURDU, A.; SABANCI, K.; ROPELEWSKA, E.; GÜLTEKIN, S. S. A Comprehensive Survey of the Recent Studies with UAV for Precision Agriculture in Open Fields and Greenhouses. **Applied Sciences**, v. 12, n. 3, p. 1047, 20 jan. 2022. DOI [10.3390/app12031047](https://doi.org/10.3390/app12031047). Disponível em: <https://www.mdpi.com/2076-3417/12/3/1047>. Acesso em: 5 jun. 2023.

BADAGLIACCA, G.; MESSINA, G.; PRATICÒ, S.; LO PRESTI, E.; PREITI, G.; MONTI, M.; MODICA, G. Multispectral Vegetation Indices and Machine Learning Approaches for Durum Wheat (*Triticum durum* Desf.) Yield Prediction across Different Varieties. **AgriEngineering**, v. 5, n. 4, p. 2032–2048, 2 nov. 2023. DOI [10.3390/agriengineering5040125](https://doi.org/10.3390/agriengineering5040125). Disponível em: <https://www.mdpi.com/2624-7402/5/4/125>. Acesso em: 27 dez. 2023.

BARBOSA, B. D. S.; FERRAZ, G. A. S.; GONÇALVES, L. M.; MARIN, D. B.; MACIEL, D. T.; FERRAZ, P. F. P.; ROSSI, G. RGB vegetation indices applied to grass monitoring: a qualitative analysis. , p. 675.9Kb, 2019. DOI [10.15159/AR.19.119](https://doi.org/10.15159/AR.19.119). Disponível em: <https://dspace.emu.ee/xmlui/handle/10492/4846>. Acesso em: 2 jun.

2024.

BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79–87, jul. 2015. DOI [10.1016/j.jag.2015.02.012](https://doi.org/10.1016/j.jag.2015.02.012). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243415000446>. Acesso em: 22 mar. 2024.

CARUSO, G.; PALAI, G.; TOZZINI, L.; D'ONOFRIO, C.; GUCCI, R. The role of LAI and leaf chlorophyll on NDVI estimated by UAV in grapevine canopies. **Scientia Horticulturae**, v. 322, p. 112398, dez. 2023. DOI [10.1016/j.scienta.2023.112398](https://doi.org/10.1016/j.scienta.2023.112398). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0304423823005678>. Acesso em: 23 abr. 2024.

CARVALHO, A. A. D.; MONTENEGRO, A. A. D. A.; DE LIMA, J. L. M. P.; SILVA, T. G. F. D.; PEDROSA, E. M. R.; ALMEIDA, T. A. B. Coupling Water Resources and Agricultural Practices for Sorghum in a Semiarid Environment. **Water**, v. 13, n. 16, p. 2288, 21 ago. 2021. DOI [10.3390/w13162288](https://doi.org/10.3390/w13162288). Disponível em: <https://www.mdpi.com/2073-4441/13/16/2288>. Acesso em: 21 dez. 2023.

CHOUDHARY, S. S.; BISWAL, S.; SAHA, R.; CHATTERJEE, C. A non-destructive approach for assessment of nitrogen status of wheat crop using unmanned aerial vehicle equipped with RGB camera. **Arabian Journal of Geosciences**, v. 14, n. 17, p. 1739, set. 2021. DOI [10.1007/s12517-021-08139-3](https://doi.org/10.1007/s12517-021-08139-3). Disponível em: <https://link.springer.com/10.1007/s12517-021-08139-3>. Acesso em: 2 jun. 2024.

COSTA, L.; NUNES, L.; AMPATZIDIS, Y. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. **Computers and Electronics in Agriculture**, v. 172, p. 105334, maio 2020. DOI [10.1016/j.compag.2020.105334](https://doi.org/10.1016/j.compag.2020.105334). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S016816991932383X>. Acesso em: 1 maio 2023.

DUTIA', S.; BHATIACHARYA', B. K.; RAJAK', D. R.; CHATIOPADHAYAY, C.; PATEL', N. K.; PARIHAR', S. DISEASE DETECTION IN MUSTARD CROP USING EO-I HYPERION SATELLITE DATA. [s. d.] .

FONTES JÚNIOR, R. V. D. P.; MONTENEGRO, A. A. D. A. Temporal dependence of potentiometric levels and groundwater salinity in alluvial aquifer upon rainfall and evapotranspiration. **RBRH**, v. 22, n. 0, 23 out. 2017. DOI [10.1590/2318-0331.0217170059](https://doi.org/10.1590/2318-0331.0217170059). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2318-03312017000100250&lng=en&tlng=en. Acesso em: 13 maio 2023.

GALLARDO-SALAZAR, J. L.; ROSAS-CHAVOYA, M.; POMPA-GARCÍA, M.; LÓPEZ-SERRANO, P. M.; GARCÍA-MONTIEL, E.; MELÉNDEZ-SOTO, A.; JIMÉNEZ-JIMÉNEZ, S. I. Multi-temporal NDVI analysis using UAV images of tree

crowns in a northern Mexican pine-oak forest. **Journal of Forestry Research**, v. 34, n. 6, p. 1855–1867, dez. 2023. DOI [10.1007/s11676-023-01639-w](https://doi.org/10.1007/s11676-023-01639-w). Disponível em: <https://link.springer.com/10.1007/s11676-023-01639-w>. Acesso em: 23 abr. 2024.

GAO, Y.; LIN, Y.; WEN, X.; JIAN, W.; GONG, Y. Vegetation information recognition in visible band based on UAV images. **Transactions of the Chinese Society of Agricultural Engineering**, v. 36, n. 3, p. 178-189., 2020. <https://dx.doi.org/10.11975/j.issn.1002-6819.2020.03.022>.

GUO, Y.; WANG, H.; WU, Z.; WANG, S.; SUN, H.; SENTHILNATH, J.; WANG, J.; ROBIN BRYANT, C.; FU, Y. Modified Red Blue Vegetation Index for Chlorophyll Estimation and Yield Prediction of Maize from Visible Images Captured by UAV. **Sensors**, v. 20, n. 18, p. 5055, 5 set. 2020. DOI [10.3390/s20185055](https://doi.org/10.3390/s20185055). Disponível em: <https://www.mdpi.com/1424-8220/20/18/5055>. Acesso em: 22 mar. 2024.

HERRERA, D.; ESCUDERO-VILLA, P.; CÁRDENAS, E.; ORTIZ, M.; VARELA-ALDÁS, J. Combining Image Classification and Unmanned Aerial Vehicles to Estimate the State of Explorer Roses. **AgriEngineering**, v. 6, n. 2, p. 1008–1021, 16 abr. 2024. DOI [10.3390/agriengineering6020058](https://doi.org/10.3390/agriengineering6020058). Disponível em: <https://www.mdpi.com/2624-7402/6/2/58>. Acesso em: 23 abr. 2024.

HODSON, T. O. Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. **Geoscientific Model Development**, v. 15, n. 14, p. 5481–5487, 19 jul. 2022. DOI [10.5194/gmd-15-5481-2022](https://doi.org/10.5194/gmd-15-5481-2022). Disponível em: <https://gmd.copernicus.org/articles/15/5481/2022/>. Acesso em: 25 abr. 2024.

HUNT, E. R.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; MCMURTREY, J. E.; WALTHALL, C. L. Evaluation of Digital Photography from Model Aircraft for Remote Sensing of Crop Biomass and Nitrogen Status. **Precision Agriculture**, v. 6, n. 4, p. 359–378, ago. 2005. DOI [10.1007/s11119-005-2324-5](https://doi.org/10.1007/s11119-005-2324-5). Disponível em: <http://link.springer.com/10.1007/s11119-005-2324-5>. Acesso em: 22 mar. 2024.

ISHIDA, T.; KURIHARA, J.; VIRAY, F. A.; NAMUCO, S. B.; PARINGIT, E. C.; PEREZ, G. J.; TAKAHASHI, Y.; MARCIANO, J. J. A novel approach for vegetation classification using UAV-based hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 144, p. 80–85, jan. 2018. DOI [10.1016/j.compag.2017.11.027](https://doi.org/10.1016/j.compag.2017.11.027). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169917310499>. Acesso em: 3 maio 2023.

JARDIM, A. M. D. R. F.; SANTOS, H. R. B.; ALVES, H. K. M. N.; FERREIRA-SILVA, S. L.; SOUZA, L. S. B. D.; ARAÚJO JÚNIOR, G. D. N.; SOUZA, M. D. S.; ARAÚJO, G. G. L. D.; SOUZA, C. A. A. D.; SILVA, T. G. F. D. Genotypic differences relative photochemical activity, inorganic and organic solutes and yield performance in clones of the forage cactus under semi-arid environment. **Plant Physiology and Biochemistry**, v. 162, p. 421–430, maio 2021. DOI [10.1016/j.plaphy.2021.03.011](https://doi.org/10.1016/j.plaphy.2021.03.011). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0981942821001352>. Acesso em: 2 jun. 2024.

KLIMAVIČIUS, L.; RIMKUS, E.; STONEVIČIUS, E.; MAČIULYTĖ, V. Seasonality and

long-term trends of NDVI values in different land use types in the eastern part of the Baltic Sea basin. **Oceanologia**, v. 65, n. 1, p. 171–181, jan. 2023. DOI [10.1016/j.oceano.2022.02.007](https://doi.org/10.1016/j.oceano.2022.02.007). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0078323422000240>. Acesso em: 3 jun. 2024.

LI, X.; HOU, B.; ZHANG, R.; LIU, Y. A Review of RGB Image-Based Internet of Things in Smart Agriculture. **IEEE Sensors Journal**, v. 23, n. 20, p. 24107–24122, 15 out. 2023. DOI [10.1109/JSEN.2023.3309774](https://doi.org/10.1109/JSEN.2023.3309774). Disponível em: <https://ieeexplore.ieee.org/document/10238443/>. Acesso em: 2 jun. 2024.

LOURENÇO, V. R.; MONTENEGRO, A. A. D. A.; CARVALHO, A. A. D.; SOUSA, L. D. B. D.; ALMEIDA, T. A. B.; ALMEIDA, T. F. S. D.; VILAR, B. P. Spatial variability of biophysical multispectral indexes under heterogeneity and anisotropy for precision monitoring. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 27, n. 11, p. 848–857, nov. 2023. DOI [10.1590/1807-1929/agriambi.v27n11p848-857](https://doi.org/10.1590/1807-1929/agriambi.v27n11p848-857). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662023001100848&tlng=en. Acesso em: 21 dez. 2023.

MAINARDIS, M.; CECCONET, D.; MORETTI, A.; CALLEGARI, A.; GOI, D.; FREGUIA, S.; CAPODAGLIO, A. G. Wastewater fertigation in agriculture: Issues and opportunities for improved water management and circular economy. **Environmental Pollution**, v. 296, p. 118755, mar. 2022. DOI [10.1016/j.envpol.2021.118755](https://doi.org/10.1016/j.envpol.2021.118755). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S026974912102337X>. Acesso em: 21 dez. 2023.

PANDEY, P. C.; PANDEY, M. Highlighting the role of agriculture and geospatial technology in food security and sustainable development goals. **Sustainable Development**, v. 31, n. 5, p. 3175–3195, out. 2023. DOI [10.1002/sd.2600](https://doi.org/10.1002/sd.2600). Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/sd.2600>. Acesso em: 2 jun. 2024.

PRUDNIKOVA, E.; SAVIN, I.; VINDEKER, G.; GRUBINA, P.; SHISHKONAKOVA, E.; SHARYCHEV, D. Influence of Soil Background on Spectral Reflectance of Winter Wheat Crop Canopy. **Remote Sensing**, v. 11, n. 16, p. 1932, 19 ago. 2019. DOI [10.3390/rs11161932](https://doi.org/10.3390/rs11161932). Disponível em: <https://www.mdpi.com/2072-4292/11/16/1932>. Acesso em: 2 jun. 2024.

RADOČAJ, D.; ŠILJEG, A.; MARINOVIĆ, R.; JURISIĆ, M. State of Major Vegetation Indices in Precision Agriculture Studies Indexed in Web of Science: A Review. **Agriculture**, v. 13, n. 3, p. 707, 18 mar. 2023. DOI [10.3390/agriculture13030707](https://doi.org/10.3390/agriculture13030707). Disponível em: <https://www.mdpi.com/2077-0472/13/3/707>. Acesso em: 3 jun. 2024.

RASMUSSEN, J.; AZIM, S.; BOLDSSEN, S. K.; NITSCHKE, T.; JENSEN, S. M.; NIELSEN, J.; CHRISTENSEN, S. The challenge of reproducing remote sensing data from satellites and unmanned aerial vehicles (UAVs) in the context of management zones and precision agriculture. **Precision Agriculture**, v. 22, n. 3, p. 834–851, jun. 2021. DOI [10.1007/s11119-020-09759-7](https://doi.org/10.1007/s11119-020-09759-7). Disponível em: <https://link.springer.com/10.1007/s11119-020-09759-7>. Acesso em: 8 maio 2024.

RIEHLE, D.; REISER, D.; GRIEPENTROG, H. W. Robust index-based semantic plant/background segmentation for RGB- images. **Computers and Electronics in Agriculture**, v. 169, p. 105201, fev. 2020. DOI [10.1016/j.compag.2019.105201](https://doi.org/10.1016/j.compag.2019.105201). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169919314346>. Acesso em: 22 mar. 2024.

ROUSE, W.; HAAS, R. H. MONITORING VEGETATION SYSTEMS IN THE GREAT PLAINS WITH ERTS. [s. d]. .

SCHNEIDER, P.; ROBERTS, D. A.; KYRIAKIDIS, P. C. A VARI-based relative greenness from MODIS data for computing the Fire Potential Index. **Remote Sensing of Environment**, v. 112, n. 3, p. 1151–1167, mar. 2008. DOI [10.1016/j.rse.2007.07.010](https://doi.org/10.1016/j.rse.2007.07.010). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425707003471>. Acesso em: 22 mar. 2024.

SIM, J.-B.; YOOK, S.-J.; KIM, Y. W. Development of 180 kW Organic Rankine Cycle (ORC) with a High-Efficiency Two-Stage Axial Turbine. **Energies**, v. 16, n. 20, p. 7112, 16 out. 2023. DOI [10.3390/en16207112](https://doi.org/10.3390/en16207112). Disponível em: <https://www.mdpi.com/1996-1073/16/20/7112>. Acesso em: 24 abr. 2024.

SONG, X.; WU, F.; LU, X.; YANG, T.; JU, C.; SUN, C.; LIU, T. The Classification of Farming Progress in Rice–Wheat Rotation Fields Based on UAV RGB Images and the Regional Mean Model. **Agriculture**, v. 12, n. 2, p. 124, 18 jan. 2022. DOI [10.3390/agriculture12020124](https://doi.org/10.3390/agriculture12020124). Disponível em: <https://www.mdpi.com/2077-0472/12/2/124>. Acesso em: 23 abr. 2024.

SUN, B.; LI, Y.; HUANG, J.; CAO, Z.; PENG, X. Impacts of Variable Illumination and Image Background on Rice LAI Estimation Based on UAV RGB-Derived Color Indices. **Applied Sciences**, v. 14, n. 8, p. 3214, 11 abr. 2024. DOI [10.3390/app14083214](https://doi.org/10.3390/app14083214). Disponível em: <https://www.mdpi.com/2076-3417/14/8/3214>. Acesso em: 8 maio 2024.

VIANA, C. M.; FREIRE, D.; ABRANTES, P.; ROCHA, J.; PEREIRA, P. Agricultural land systems importance for supporting food security and sustainable development goals: A systematic review. **Science of The Total Environment**, v. 806, p. 150718, fev. 2022. DOI [10.1016/j.scitotenv.2021.150718](https://doi.org/10.1016/j.scitotenv.2021.150718). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S004896972105796X>. Acesso em: 23 abr. 2024.

WALSH, O. S.; NAMBI, E.; SHAFIAN, S.; JAYAWARDENA, D. M.; ANSAH, E. O.; LAMICHHANE, R.; MCCLINTICK-CHESS, J. R. UAV-based NDVI estimation of sugarbeet yield and quality under varied nitrogen and water rates. **Agrosystems, Geosciences & Environment**, v. 6, n. 1, p. e20337, mar. 2023. DOI [10.1002/agg2.20337](https://doi.org/10.1002/agg2.20337). Disponível em: <https://access.onlinelibrary.wiley.com/doi/10.1002/agg2.20337>. Acesso em: 7 maio 2024.

WANG, X.; WANG, M.; WANG, S.; WU, Y. Extraction of vegetation information from

visible unmanned aerial vehicle images.pdf. v. 31, n. 5, p. 152–159, 2015. .

WU, B.; ZHANG, M.; ZENG, H.; TIAN, F.; POTGIETER, A. B.; QIN, X.; YAN, N.; CHANG, S.; ZHAO, Y.; DONG, Q.; BOKEN, V.; PLOTNIKOV, D.; GUO, H.; WU, F.; ZHAO, H.; DERONDE, B.; TITS, L.; LOUPIAN, E. Challenges and opportunities in remote sensing-based crop monitoring: a review. **National Science Review**, v. 10, n. 4, p. nwac290, 21 mar. 2023. DOI [10.1093/nsr/nwac290](https://doi.org/10.1093/nsr/nwac290). Disponível em: <https://academic.oup.com/nsr/article/doi/10.1093/nsr/nwac290/6939854>. Acesso em: 23 abr. 2024.

XU, Z.; LI, Y.; LI, B.; HAO, Z.; LIN, L.; HU, X.; ZHOU, X.; YU, H.; XIANG, S.; PASCAL, M.-L.-F.; SHEN, W.; HE, A.; CHEN, L.; LI, Z. A comparative study on the applicability and effectiveness of NSVI and NDVI for estimating fractional vegetation cover based on multi-source remote sensing image. *Geocarto International*, v. 38, n. 1, p. 2184501, 31 dez. 2023. DOI [10.1080/10106049.2023.2184501](https://doi.org/10.1080/10106049.2023.2184501). Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10106049.2023.2184501>. Acesso em: 2 ago. 2024.

YADAV, J.; CHAUHAN, U.; SHARMA, D. Importance of Drone Technology in Indian Agriculture, Farming: *In*: KHAN, M. A.; GUPTA, B.; VERMA, A. R.; PRAVEEN, P.; PEOPLES, C. J. (orgs.). **Advances in Electronic Government, Digital Divide, and Regional Development**. [S. l.]: IGI Global, 2023. p. 35–46. DOI [10.4018/978-1-6684-6418-2.ch003](https://doi.org/10.4018/978-1-6684-6418-2.ch003). Disponível em: <https://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/978-1-6684-6418-2.ch003>. Acesso em: 21 dez. 2023.

CAPÍTULO III

DETECÇÃO DE PLANTAS INVASORAS EM CULTIVO DE PALMA FORRAGEIRA IRRIGADA COM ÁGUA DE REÚSO: ALGORITMOS DE APRENDIZAGEM DE MÁQUINA APLICADAS EM IMAGENS GEORREFERENCIADAS PRODUZIDAS POR VANTs NO SEMIÁRIDO PERNAMBUCANO

Resumo: A agricultura de precisão requer métodos rigorosos para a classificação de culturas e cobertura do solo em áreas de produção agrícola. A classificação de culturas invasoras é uma metodologia fundamental para identificar áreas que necessitam de um manejo adequado, sendo um indicador essencial em zonas de cultivo. Este estudo tem como propósito avaliar quatro classificadores baseados em aprendizado de máquina com o objetivo de aplicar imagens de Veículos Aéreos Não Tripulados (VANTs) para identificar culturas invasoras em áreas de plantio irrigado de palma forrageira orelha de elefante mexicana (*Opuntia stricta* HAW.) com espaçamento entre plantas de 0,2 metros e espaçamento entre linhas de 0,5 metros. Foi realizada uma análise comparativa entre amostragens multiespectrais e visíveis de cores Vermelho-Verde-Azul (RGB), seguida pela avaliação da eficiência dos algoritmos Gaussian Mixture Model (GMM), K-Nearest Neighbors(KNN), Random Forest (RF) e Support Vector Machine (SVM). Os alvos de classificação variaram conforme o mês avaliado, abrangendo solo exposto, solo com cobertura morta, solo sombreado, palma forrageira orelha de elefante mexicana, mimosa pudica e *Cyperus hermaphroditus*. Os resultados indicaram que o algoritmo SVM e o algoritmo RF superaram os métodos GMM e KNN, onde o RF se mostrou mais eficaz em presença de ruídos. Para o imageamento de outubro, que incluía três classes de solo, uma classe de palma e uma classe de planta invasora, o SVM apresentou índices kappa de 0,91035 e 0,89722, respectivamente. O RF ficou em segundo lugar, com resultados muito próximos, mas com menor custo computacional, apresentando índices kappa de 0,91032 e 0,88694. Para o imageamento de fevereiro, que continha três classes de solo, uma classe de palma e

duas classes de plantas invasoras, o SVM obteve índices kappa de 0,86521 e 0,84041, enquanto o RF apresentou valores de 0,86520 e 0,83284. No imageamento de abril, que incluía duas classes de solo, uma classe de palma e duas classes de invasoras, o SVM alcançou índices kappa de 0,9727 e 0,94494, e o RF, índices de 0,98132 e 0,96313, respectivamente. Esses resultados destacam a eficiente aplicabilidade dos métodos para a determinação de culturas invasoras, sublinhando a importância do desenvolvimento de tecnologias mais acessíveis, como a classificação por RGB. Embora a performance das imagens RGB seja inferior à das multiespectrais, os algoritmos aplicados a estas amostras produziram resultados promissores para a classificação de culturas.

Palavras-chave: Classificação de culturas, VANTs, Imagens RGB, Aprendizagem de máquina.

Abstract: Precision agriculture requires rigorous methods for crop and land cover classification in agricultural production areas. The classification of invasive crops is a fundamental methodology for identifying areas that require appropriate management, serving as an essential indicator in cultivation zones. This study aims to evaluate four machine learning classifiers to apply Unmanned Aerial Vehicle (UAV) images to identify invasive crops in irrigated planting areas of Mexican Elephant Ear prickly pear (*Opuntia stricta* HAW.), with a plant spacing of 0.2 meters and a row spacing of 0.5 meters. A comparative analysis was conducted between multispectral and Red-Green-Blue (RGB) visible color samples, followed by the evaluation of the efficiency of the Gaussian Mixture Model (GMM), K-Nearest Neighbors (KNN), Random Forest (RF), and Support Vector Machine (SVM) algorithms. The classification targets varied according to the month evaluated, covering exposed soil, soil with mulch, shaded soil, Mexican Elephant Ear prickly pear, *Mimosa pudica*, and *Cyperus hermaphroditus*. The results indicated that the SVM and RF algorithms outperformed the GMM and KNN methods, with RF proving more effective in the presence of noise. For the October imaging, which included three soil classes, one prickly pear class, and one invasive plant class, SVM presented kappa indices of 0.91035 and 0.89722, respectively. RF came in second, with very close results but lower computational cost, presenting kappa indices of 0.91032 and 0.88694. For the February imaging, which contained three soil classes, one prickly pear class, and two invasive plant classes, SVM achieved kappa indices of 0.86521 and 0.84041, while RF presented values of 0.86520 and 0.83284. In the April imaging, which included two soil classes, one prickly pear class, and two invasive plant classes, SVM reached kappa indices of 0.9727 and 0.94494, and RF indices of 0.98132 and 0.96313, respectively. These results highlight the efficient applicability of these methods for determining invasive crops, emphasizing the importance of developing more accessible technologies, such as RGB classification. Although the performance of RGB images is inferior to that of multispectral images, the algorithms applied to these samples produced promising results for crop classification.

Keywords: Crop classification, UAVs, RGB images, Machine learning.

1. INTRODUÇÃO

A escassez de água e a segurança alimentar são desafios persistentes na região semiárida do Brasil. A reutilização de águas residuais agrícolas emerge como uma solução promissora para melhorar a gestão hídrica e promover a economia circular (POHL & LENZ, 2017; CARVALHO et al., 2021; MAINARDIS et al., 2022). Entre as culturas que demonstram elevado potencial e resiliência nesse ambiente, destaca-se a palma forrageira. Quando irrigada utilizando técnicas de conservação, essa planta exibe um crescimento vigoroso e uma produção elevada, apresentando resultados promissores especialmente em consórcios com outras espécies agrícolas (ALVES et al., 2022). A capacidade de prever com precisão os tipos de culturas é crucial para estimar a área cultivada, prever o volume de produção e determinar as necessidades hídricas das culturas (BHUYAN et al., 2022). O monitoramento detalhado das terras agrícolas é essencial na agricultura de precisão, pois contribui para a maximização da produção de culturas e a conservação da água (ASADI & SHAMSODDINI, 2024).

O sensoriamento remoto, como uma ferramenta da agricultura de precisão, fornece informações essenciais para o monitoramento de recursos naturais, incluindo o crescimento das culturas, o uso da terra, a umidade do solo, a saúde das plantas e a previsão de safras (SHANMUGAPRIYA et al., 2019). Para uma ampla adoção na agricultura, é fundamental estimar dados precisos e integrar diversas fontes para garantir robustez prática (CHAKRABORTY et al., 2022). Veículos Aéreos Não Tripulados (VANTs) equipados com sensores multiespectrais oferecem vários benefícios na agricultura de precisão, permitindo a obtenção de dados de alta resolução que capturam a variabilidade espacial dos atributos das culturas (BADAGLIACCA et al., 2023; LOURENÇO et al., 2023; DERICQUEBOURG et al., 2022). Um estudo de Cao et al. (2021) comparou imagens RGB e multiespectrais de VANTs para mapear o fenótipo "Stay Green" em um germoplasma diversificado de trigo. Embora as imagens visíveis (Vermelho-Verde-Azul, RGB) forneçam informações valiosas, os índices espectrais que contêm a borda vermelha ou a banda do infravermelho próximo foram mais eficazes para a classificação precisa

das culturas. Os VANTs permitem capturar imagens aéreas com alta resolução espacial devido à sua baixa altitude de voo (PENG et al., 2015; STARK et al., 2018; SANTANA et al., 2024).

A adoção de técnicas de Inteligência Artificial (IA) na agricultura otimiza a produtividade e o manejo da irrigação, identificando zonas que necessitam de intervenção e reduzindo o desperdício de água (PALLATHADKA et al., 2023). O aprendizado de máquina pode estar associado à economia de recursos, como na irrigação autônoma, onde o algoritmo ajusta o volume e o tempo de irrigação com base nas necessidades das culturas, otimizando a aplicação de água e, assim, aumentando a produtividade hídrica e a sustentabilidade agrícola (ABIOYE et al., 2022).

Estudos como o de Yadav et al. (2023) destacam o potencial do sensoriamento remoto no monitoramento da saúde das culturas, no controle de ervas daninhas e na estimativa da evapotranspiração. Iqbal et al. (2023) desenvolveram aplicações de aprendizado de máquina para a classificação de culturas, com o objetivo de identificar plantas invasoras no Paquistão, demonstrando o alto desempenho dos algoritmos Modelo de Mistura Gaussiana (GMM), Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF). Paralelamente, Sivakumar e TYJ (2021) detectaram ervas daninhas usando imagens de alta resolução, sublinhando o potencial dos VANTs na pesquisa agrícola.

Neste contexto, o presente estudo visa: (i) avaliar o desempenho de algoritmos de aprendizado de máquina (ML) para a classificação de culturas invasoras na região semiárida brasileira com imagens provenientes de VANTs e comparar os espaços amostrais de aplicação com a reflectância de banda visível e reflectância de banda do infravermelho próximo; (ii) classificar diferentes estados de uso e ocupação do solo.

2. MATERIAL E MÉTODOS

2.1 Descrição da área de estudo

O estudo foi desenvolvido em um lote agrícola onde é realizado o plantio de palma forrageira orelha de elefante mexicana (*Opuntia stricta* Haw.). A cultura foi plantada em maio de 2022 com espaçamento entre linhas de 0,5 metros e espaçamento entre culturas de 0,2 metros.

O lote agrícola é irrigado com água de reuso, uma vez que esta é uma fonte alternativa de água possível de ser aplicada a irrigação de forrageiras. A irrigação é feita através do método do gotejamento, visto que é o indicado para irrigação com água de reuso, onde a vazão de sistema é de 6000 litros por dia, com turno de rega de 3 dias e com 90% de uniformidade no sistema de irrigação.

O lote agrícola, cujo a área experimental é de aproximadamente 350 metros quadrados está localizado no Vale Aluvial do Mimoso (Figura 1), que está inserido na Bacia do Alto Ipanema situado entre as coordenadas 8°34'17" e 8°18'11" de Latitude Sul e 37°1'35" e 36°47'20" de Longitude Oeste.

O Vale Aluvial do Mimoso apresenta cursos d'água intermitentes e clima predominante na região da Bacia do Alto Ipanema é caracterizado como semiárido quente, de acordo com a classificação de Köppen, com precipitação média anual de 607 mm e temperatura média de 23 °C, e evapotranspiração potencial de aproximadamente 2.000 mm por ano, com alta variabilidade espaço-temporal dos eventos de precipitação (FONTES JÚNIOR & MONTENEGRO, 2017).

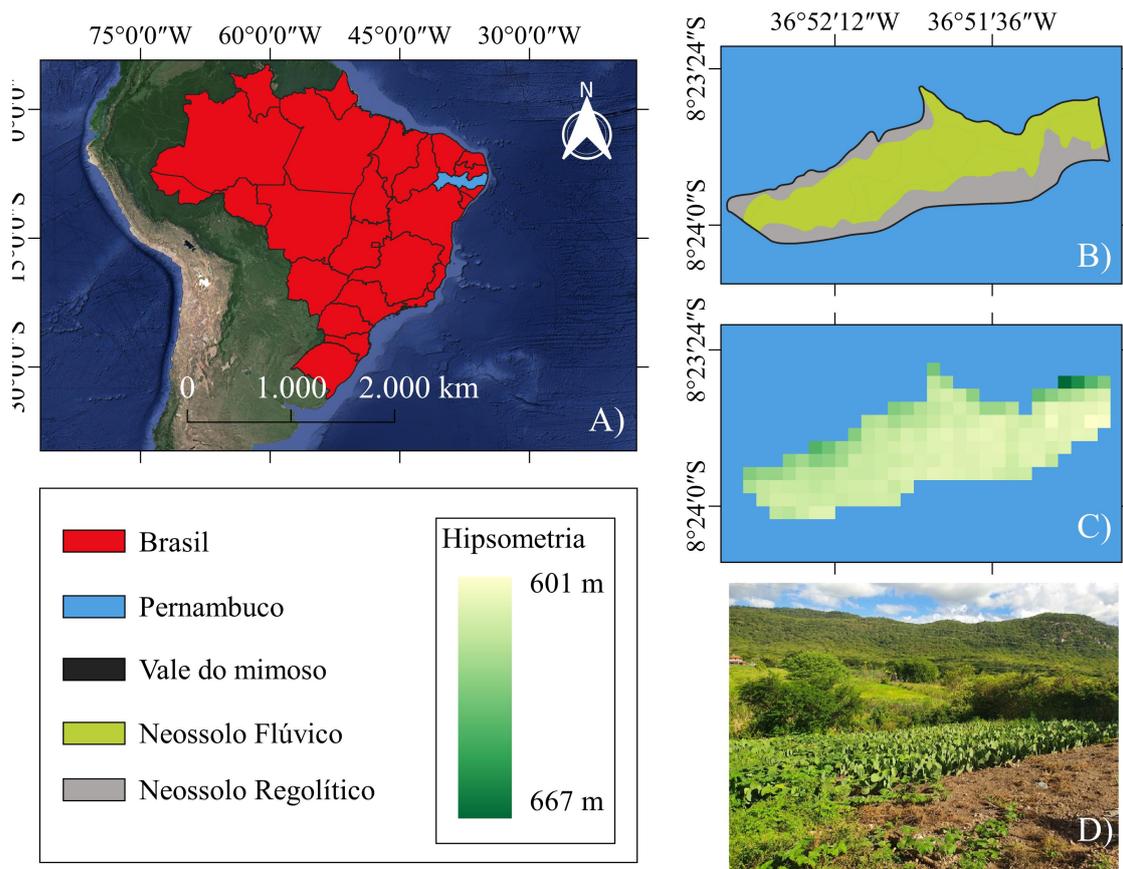


Figura 1. Mapa de localização (A), Solos vale do Mimoso (B), Relevo vale do Mimoso SRTM (C), Área experimental (D)

2.2 Aquisição de imagens

As imagens multiespectrais e RGB foram adquiridas nos dias 23 de outubro de 2023, 09 de fevereiro de 2024 e 06 de abril de 2024. Os levantamentos foram realizados utilizando um Veículo Aéreo Não Tripulado (VANT), modelo DJI Phantom 4 Multispectral Real Time Kinematic (RTK), equipado com uma câmera de alta resolução espacial que captura simultaneamente seis imagens, sendo uma em composição RGB e cinco imagens espectrais monocromáticas: azul (B), verde (G), vermelho (R), borda vermelha (RE) e bandas de infravermelho próximo (NIR) (Tabela 1), gerando imagens com resolução de 2 Mega Pixels (MP).

Tabela 1. Comprimento de onda do sensor multiespectral

Phantom 4	Comprimento de onda (nm)
Azul (B)	450
Verde (G)	560
Vermelho (R)	650
RedEdge	730
Infravermelho próximo (NIR)	840

As características dos voos foram determinadas de acordo com as recomendações técnicas, respeitando as regulamentações da ANAC (Agência Nacional de Aviação Civil), o órgão regulador responsável pelas normas de voo no Brasil. Os voos foram realizados a uma velocidade uniforme de 2 m/s e a uma altura de 40 m. Uma missão de levantamento automático foi configurada para garantir 75% de sobreposição e lateralidade e foi aplicada para as datas do estudo. O processo fotogramétrico, que incluiu o alinhamento das imagens, empilhamento e correção radiométrica, foi realizado utilizando o software Agisoft Metashape (Versão 2.1), juntamente com um painel de calibração de refletância.

2.3 Processamento das imagens

Os processamentos no Metashape e QGIS foram realizados em um computador equipado com uma CPU Intel Core i7 10700F de 2,9 GHz, 8 núcleos e 16 threads, com frequência turbo máxima de 4,8 GHz. O computador também possui uma placa de vídeo rx550 com 4 GB de VRAM e 32 GB de memória RAM. A versão 2.1.2 (2023) do Agisoft Metashape Professional foi utilizada para o processamento dos dados, que posteriormente foram aplicados na plataforma QGIS 3.16.

2.3.1 Seleção das imagens via Agisoft Metashape

As imagens foram adicionadas através da adição de pasta, via aba “*Workflow*”, onde as referências pré-selecionadas foram o sistema de coordenadas World Geodetic System (WGS 84). Posteriormente as imagens passaram por uma pré avaliação e todas as imagens aplicadas obtiveram o parâmetro de aplicação do

agisoft metashape como acima de 0,75.

2.3.2 Calibração das imagens via Agisoft Metashape

A calibração das imagens foi feita através das imagens de referências através da aba calibrar reflectância, disponível nas ferramentas, com a seleção de aplicar imagens do painel calibrador de reflectância para correção das imagens.

2.3.3 Alinhamento das imagens via Agisoft Metashape

O alinhamento das imagens é realizado através da ferramenta "Align Points" utilizando os dados de geolocalização e um algoritmo que identifica pontos homólogos entre elas. A qualidade desse processamento depende, entre outros fatores, do grau de sobreposição frontal e lateral entre as imagens. O resultado dessa etapa é a geração de uma nuvem esparsa de pontos.

2.3.4 Geração de nuvem densa de pontos via Agisoft Metashape

A densificação da nuvem de pontos foi feita utilizando a ferramenta "Build Dense Cloud", o programa aumenta a quantidade de pontos existentes, reduzindo os espaços vazios e representando a área mapeada com um maior nível de refinamento. O nível de qualidade selecionado foi o mais alto.

2.3.5 Geração de ortomosaico via Agisoft Metashape

A geração do ortomosaico foi feita através da ferramenta "Build Orthomosaic" por meio da ortorretificação das imagens, onde a partir dessa correção, é feita o mosaico, gerando um único produto final.

2.4 Algoritmos de aprendizagem de máquinas

2.4.1 Análise e Classificação das Imagens

As imagens foram analisadas e classificadas utilizando o software QGIS (versão 3.16.1), com o auxílio do plugin Dzetsaka (versão 3.70) (KARASIAK, 2024). A classificação realizada pelo plugin Dzetsaka é orientada a objetos, com aplicações em diversas áreas, como o monitoramento do progresso do desmatamento, a abertura ilegal de estradas e a conversão de áreas de pastagem, entre outras (FITZ,

2020; BALIEIRO & VELOSO, 2022). O QGIS 3 é uma aplicação de Sistema de Informação Geográfica (SIG) que oferece uma interface gráfica robusta para a visualização, edição e análise de dados geoespaciais. O QGIS 3 possui integração com a linguagem Python, o que permite a integração com o Scikit-learning, uma biblioteca de aprendizado de máquina de código aberto.

Foram testados quatro algoritmos de classificação: Gaussian Mixture Model (GMM), K-Near Neighbors (KNN), Random Forest (RF) e Support Vector Machine (SVM).

2.4.2. Modelo de Mistura Gaussiana (GMM)

O algoritmo Gaussian Mixture Model (GMM) (Figura 2) é um algoritmo probabilístico utilizado para representar subpopulações distribuídas normalmente dentro de uma população geral. Normalmente, ele é empregado para aprendizado não supervisionado, a fim de aprender automaticamente subpopulações e suas atribuições. Ele também é utilizado para aprendizado supervisionado ou classificação, com o objetivo de aprender os limites das subpopulações.

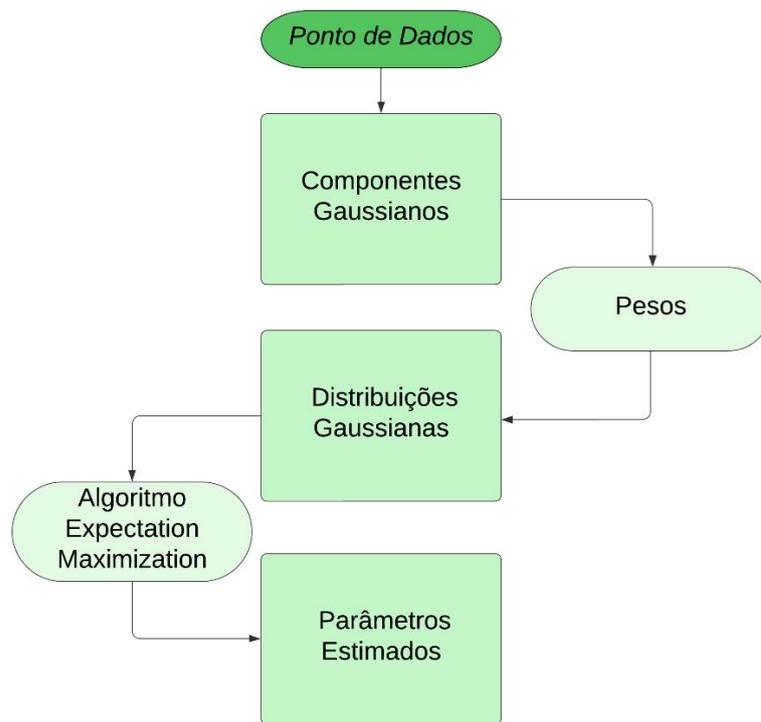


Figura 2. Fluxograma Algoritmo GMM aplicado a classificação

O Gaussian Mixture Model começa com as médias de cada Gaussiana sendo iguais às médias de cada classe real, assim como seus desvios padrão. Cada classe potencial é representada por uma função Gaussiana. Essa representação é refinada iterativamente, ou treinada, pelo algoritmo de Maximização da Expectativa. Os rótulos das instâncias são atribuídos de acordo com a Gaussiana que melhor representa cada uma. O Modelo de Mistura Gaussiana é uma soma ponderada de densidades Gaussianas com M componentes, da seguinte forma:

$$p(x|\lambda) = \sum_{i=1}^M \omega_i g(x|\mu_i, \Sigma_i) \quad (1)$$

onde x corresponde a um vetor de dados contínuo com D dimensões, ω_i (para i variando de 1 a M) representa os pesos da mistura, e $g(x|\mu_i, \Sigma_i)$ (com i variando de 1 a M) representa as densidades Gaussianas dos componentes. Cada densidade de componente assume a forma de uma função Gaussiana com D variáveis.

$$g(x|\mu_i, \Sigma_i) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (x - u_i)' \Sigma_i^{-1} (x - u_i) \right\} \quad (2)$$

onde o vetor médio: μ_i , e a matriz de covariância: Σ_i .

O modelo assume que todos os pontos de dados são obtidos a partir de uma mistura de distribuições Gaussianas finitas com parâmetros desconhecidos (REYNOLDS, 2009).

2.4.3. *K-Nearest Neighbors (KNN)*

O algoritmo dos K-vizinhos mais próximos (K-nearest Neighbors) (Figura 3) é um método que classifica dados com base na proximidade aos vizinhos mais próximos (MUCHERINO et al., 2009). Ele usa um conjunto de dados rotulado e, quando um novo ponto precisa ser classificado, o algoritmo identifica os K pontos mais próximos com base em uma medida de distância, sendo ela unidades de pixels. Em seguida, o algoritmo atribui ao novo ponto o rótulo da classe mais frequente entre esses K vizinhos. O valor de K é definido através de uma busca em grade com valores variando entre 1 a 17.

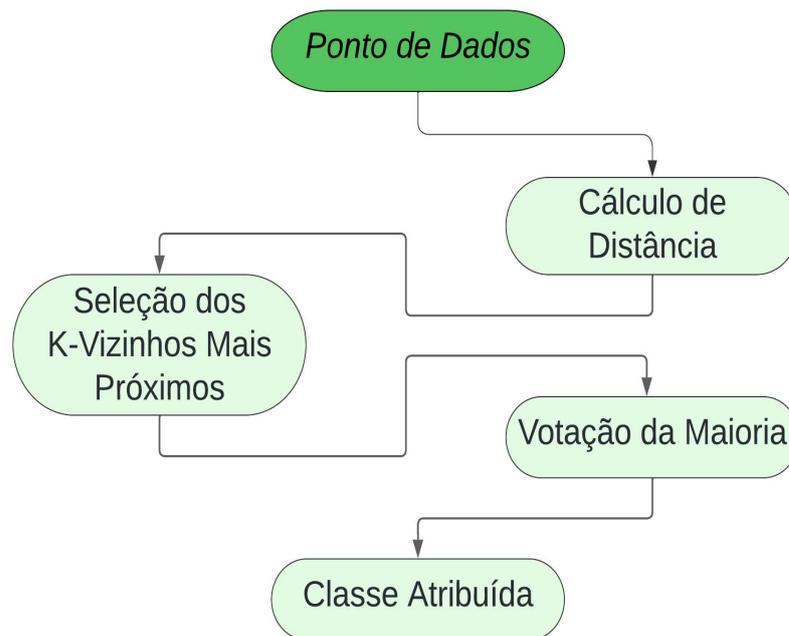


Figura 3. Fluxograma Algoritmo KNN

2.4.4. *Random Forest (RF)*

O algoritmo Random Forest (Figura 4) é um método que utiliza múltiplas Árvores de Decisão para classificação ou regressão. Cada árvore é construída usando uma amostra aleatória dos dados de treinamento e uma seleção aleatória de características. Durante o treinamento, cada árvore faz previsões independentes, e o resultado é obtido através da combinação das previsões individuais, como votação ou média. O conceito chave do Random Forest é que a combinação de árvores ajuda a reduzir o overfitting (ajuste excessivo) aos dados de treinamento e melhora a capacidade de generalização do modelo (GISLASON et al., 2006).

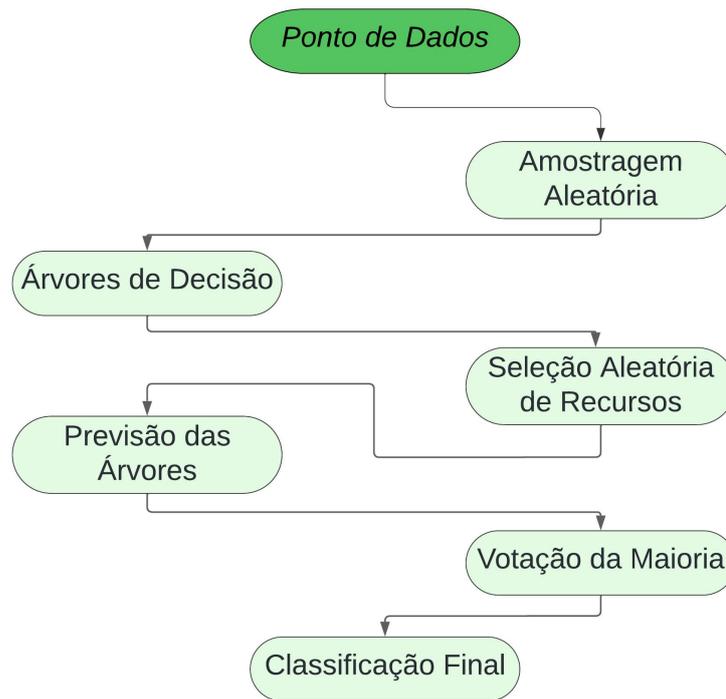


Figura 4. Fluxograma Algoritmo RF

O classificador Random Forest usa o índice de Gini (G) para selecionar características que preveem as classes. Para um conjunto de treinamento T , ao selecionar aleatoriamente uma instância (pixel) e afirmar que ela pertence a alguma classe C_i , o índice de Gini pode ser escrito como:

$$\sum \sum_{j \neq i} (f(C_i, T)/|T|)(f(C_j, T)/|T|) \quad (3)$$

onde $f(C_i, T)/|T|$ é a probabilidade de que o pixel selecionado pertença a classe C_i (PAL, 2005).

Os parâmetros associados ao Random Forest foram selecionados através de uma busca em grade e são o número de estimadores e as características máximas. O número de estimadores é o parâmetro que define o número de árvores na floresta e foram selecionados entre $[3^1, 3^2, 3^3, 3^4]$. A escolha do número de árvores afeta o desempenho e a robustez do modelo. Um número muito baixo de árvores pode levar a um modelo subajustado, enquanto um número excessivamente alto pode

aumentar o tempo de treinamento sem necessariamente melhorar a precisão do modelo.

2.5.5. Support Vector Machine (SVM)

O SVM (Figura 5) é um algoritmo clássico voltado para classificação que apresenta características atraentes e desempenho promissor. Ele segue o princípio da minimização do risco estrutural, que é superior ao princípio tradicional de minimização do risco empírico usado por métodos convencionais de aprendizado de máquina. Inicialmente, o SVM foi projetado para resolver problemas de classificação, mas foi estendido para lidar também com problemas de regressão (ROY & CHAKRABORTY, 2023).

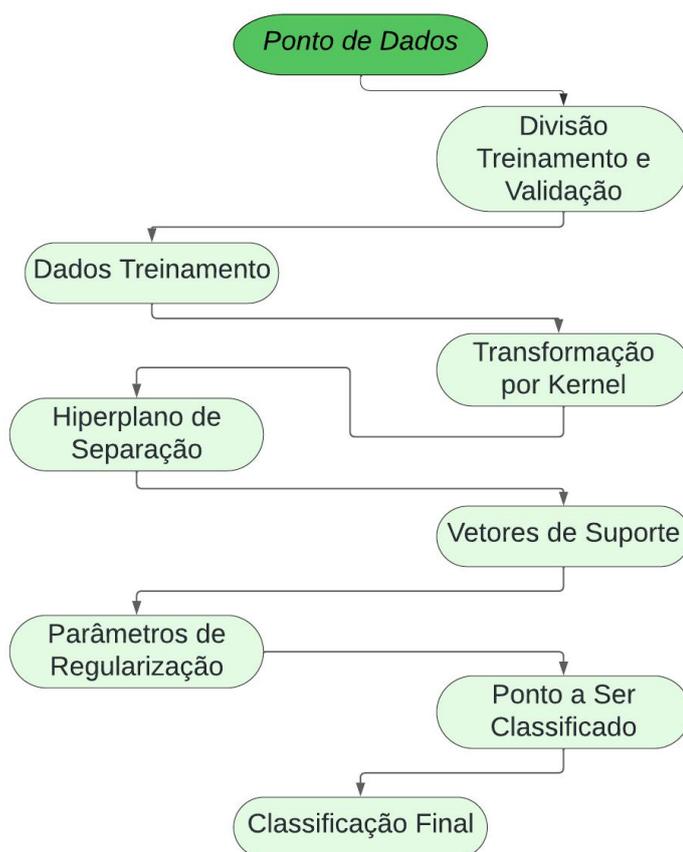


Figura 5. Fluxograma Algoritmo SVM

Os hiper parâmetros associados ao SVM são o λ e o C . O parâmetro λ define o quão longe a influência de um único ponto de treinamento alcança. Ele é utilizado nos kernels que medem a similaridade entre os pontos de dados em espaços de alta dimensão, especialmente no kernel radial e no kernel polinomial. Valores baixos de λ apresentam uma influência de pontos mais ampla, superfície de decisão suave, risco de subajuste enquanto que valores mais altos apresentam uma influência de pontos mais limitada, superfície de decisão complexa e risco de sobreajuste. O parâmetro C regula o equilíbrio entre uma fronteira de decisão ampla (que generaliza melhor) e a penalização dos erros de classificação no treinamento. Baixos valores de C apresentam maior margem, menos penalização de erros e risco de subajuste, enquanto que maiores valores apresentam menor margem, maior penalização de erros e risco de sobreajuste (FAJRI & PRIMAJAYA, 2023).

Os valores de λ e C foram selecionados através de uma busca em grade, variando de $[2^{-4}, 2^{-3}, 2^{-2}, 2^{-1}, 2^0, 2^1, 2^2, 2^3, 2^4]$ para λ e $[10^{-2}, 10^{-1}, 10^0, 10^1, 10^2]$ para o C.

2.5. Aplicação dos algoritmos

aplicação dos algoritmos de classificação foi realizada em dois conjuntos de amostras distintos:

I) Os dados de entrada utilizados para o mosaico nas classificações foram gerados a partir de um conjunto de amostras composto por rasters de bandas multiespectrais. Estas bandas incluem: Vermelho (R), Verde (G), Azul (B), Infravermelho Próximo (NIR) e o Índice de Vegetação por Diferença Normalizada (NDVI) (ROUSE & HAAS, 1973), com o objetivo de aumentar a precisão da classificação (PAL, 2005).

II) Os rasters de entrada para as classificações foram gerados a partir das bandas do espectro visível, que são: Vermelho (R), Verde (G), Azul (B) e o Índice alternativo de Vegetação por Diferença Normalizada (aNDVI) que apresentou índice de correlação (R^2) de 0,85 quando comparado ao NDVI para as imagens aplicadas.

2.6. Amostras de treinamento

Para a aplicação dos algoritmos de classificação, as amostras foram selecionadas com base no número de pixels localizados em cada polígono selecionado como alvo de classificação, onde cada pixel funciona como uma única unidade a ser classificada. Esse processo de seleção foi realizado manualmente, baseando-se no conhecimento da área de estudo e na análise visual das imagens. Consequentemente, foi criada uma camada shapefile com o mesmo referencial DATUM das imagens do VANT, utilizando o sistema de referência de coordenadas WGS 84.

As amostras selecionadas variaram para os meses de outubro de 2023, fevereiro de 2024 e abril de 2024, uma vez que fatores climáticos e relevo afetam a

cobertura de solo e a vegetação local, alterando a paisagem para cada imageamento (Figura 6).

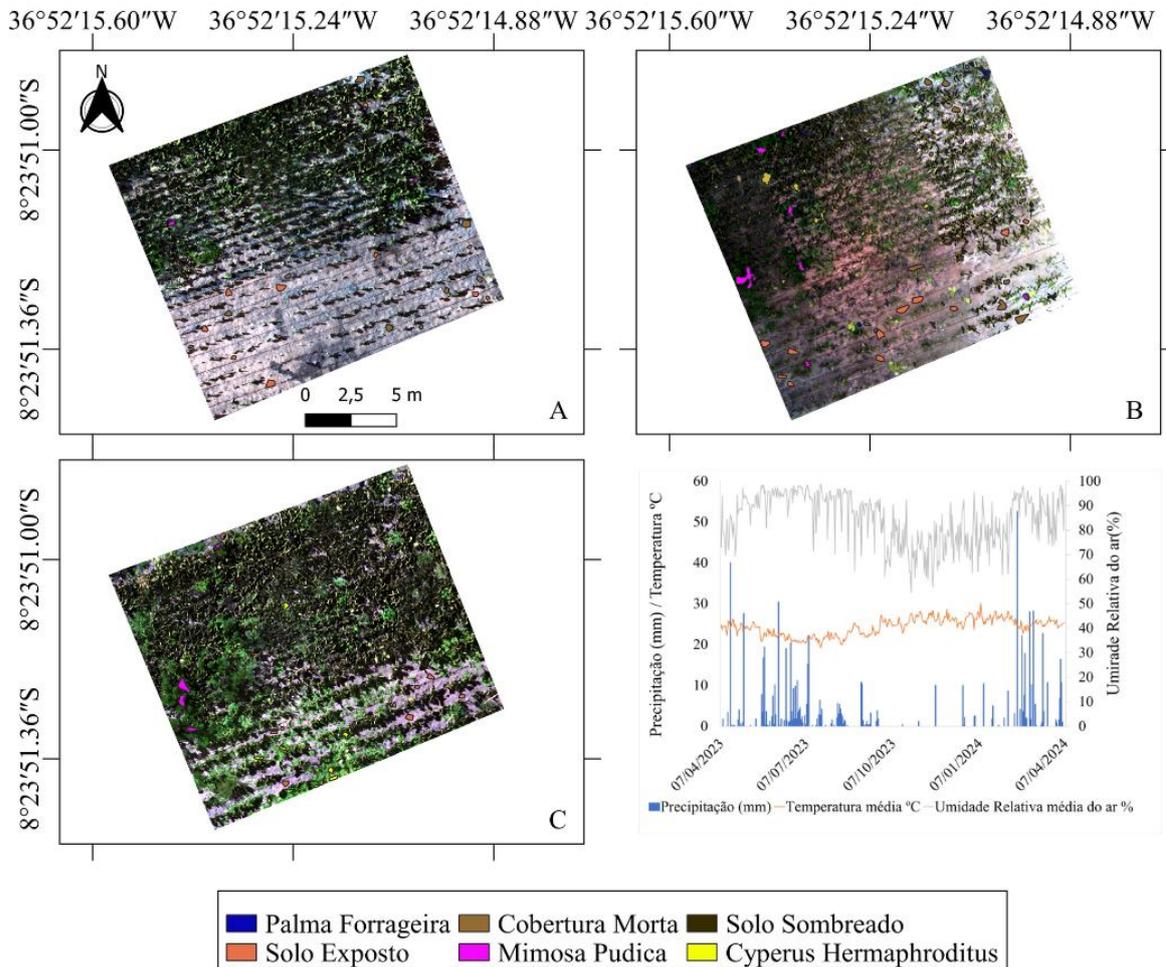


Figura 6. Mapa de localização Vale aluvial do mimoso e informações agroclimatológicas do ano anterior ao último imageamento

A seleção de amostras por classe foi feita de forma visual, através da copa das culturas, o que pode acarretar em ruídos, por tratar-se de uma rotulagem manual. A seleção de amostras foi equilibrada manualmente com o objetivo de obter os resultados mais fiéis possíveis na classificação e resultou nas seguintes quantidades para os meses de outubro, fevereiro e abril respectivamente: palma_out (1780 amostras), solo exposto_out (1221 amostras), cobertura morta_out (1550 amostras), mimosa pudica_out (773 amostras) e Solo sombreado_out (1703

amostras), palma_fev (2345 amostras), solo exposto_fev (2740 amostras), cobertura morta_fev (1911 amostras), mimosa pudica_fev (1893 amostras), cyperus hermaphroditus (2035 amostras) e Solo sombreado_fev (590 amostras), palma_abr (1222 amostras), solo exposto_abr (1271 amostras), mimosa pudica_abr (1062 amostras), cyperus hermaphroditus_abr (1257 amostras) e Solo sombreado_abr (1283 amostras). Vale destacar que a seleção das amostras foi baseada na presença de todos os elementos amostrais (classes) presentes na área de estudo.

2.7. Métricas de análise

Após a aplicação dos algoritmos, com uma distribuição de dados onde 70% das amostras foram usadas para treinamento e 30% para teste, foram geradas e analisadas matrizes de confusão para cada algoritmo de classificação aplicado. Dessa forma, foi possível analisar métricas derivadas das classificações realizadas pelos algoritmos, como precisão (4), recall (5), F1 Score (6), acurácia global (7) e, por fim, o índice Kappa (8) (Tabela 2) (LANDIS & KOCH, 1977). Isso permite avaliar o desempenho de cada algoritmo para cada classe individual de amostras selecionadas, apresentando uma média geral dos valores e avaliando o desempenho geral do algoritmo.

$$Precisão = \frac{VP}{VP+FP} \quad (4)$$

$$Recall = \frac{VP}{VP+FN} \quad (5)$$

$$F1\ Score = 2 * \frac{Precisão*Recall}{Precisão+Recall} \quad (6)$$

$$Acurácia\ Global = \frac{VP+VN}{VP+FP+VN+FN} \quad (7)$$

- VP é o número de verdadeiros positivos.
- FP é o número de falsos positivos.

- VN é o número de verdadeiros negativos.
- FN é o número de falsos negativos.

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (8)$$

· P_0 é a proporção de observações em que o modelo e a verdade real concordam.

- P_e é a proporção de concordância esperada ao acaso

Onde:

$$P_e = \frac{(VP+FP)*(VP+FN)+(FN+VN)*(FP+VN)}{(VP+FN+FP+VN)^2} \quad (9)$$

Tabela 2. Classificação do índice kappa adaptado de Landis e Koch (1977).

Índice Kappa	Concordância
<0	Nenhum
0<K≤0.2	Baixo
0.2<K≤0.4	Fraco
0.4<K≤0.6	Moderado
0.6<K≤0.8	Considerável
0.8<K≤1.0	Quase perfeito

A precisão avalia a fração de amostras identificadas como positivas que realmente são positivas. O recall, também conhecido como sensibilidade, mede a proporção de amostras verdadeiramente positivas que foram corretamente identificadas em comparação com o total de amostras positivas. Em outras palavras, ele indica a capacidade do modelo de identificar todas as amostras positivas existentes. O F1 Score é uma métrica valiosa para equilibrar precisão e recall em tarefas de classificação. Um F1 Score elevado sugere que o modelo é eficaz tanto em reconhecer corretamente as instâncias positivas quanto em reduzir os falsos

positivos (ANDRADE et al., 2024).

3. RESULTADOS

A caatinga, um bioma exclusivo do semiárido brasileiro, é notável por seu clima árido e pela vegetação altamente adaptada à escassez de água. Contudo, a resposta dessa vegetação às chuvas é um fenômeno marcante, que destaca a resiliência e a adaptabilidade das plantas nesse ecossistema (SILVA NETO et al., 2022). As chuvas desempenham um papel vital na dinâmica ecológica da caatinga.

Esse renascimento vegetativo impulsionado pelas chuvas é tão vigoroso que as plantas nativas crescem rapidamente, muitas vezes invadindo áreas de cultivo. Essas espécies, que não têm valor agrônômico, são frequentemente consideradas daninhas e podem interferir nas culturas agrícolas. Observações durante diferentes períodos mostram como a vegetação local reage às variações de umidade, sendo associadas a precipitação (Figura 7).

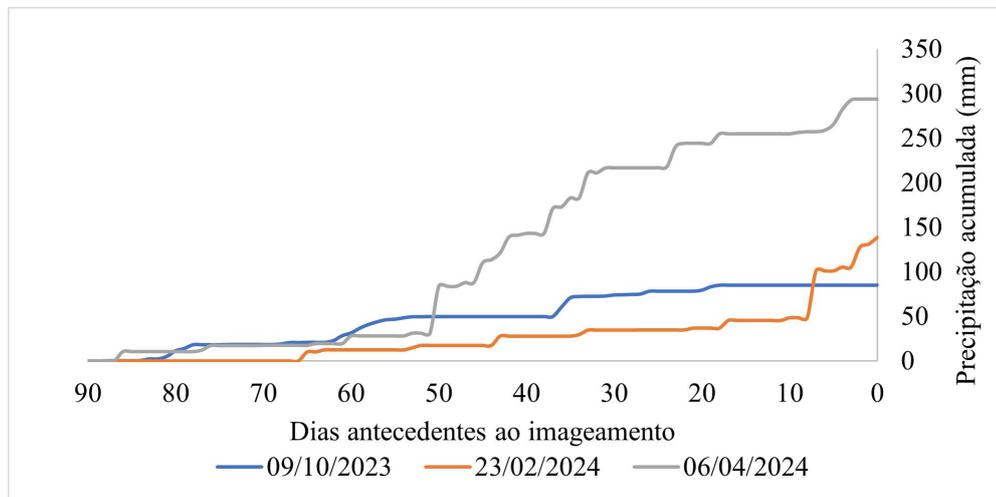


Figura 7. Precipitação acumulada ao longo de 90 dias anteriores aos imageamentos.

A mudança abrupta da paisagem devido a disponibilidade de umidade afeta drasticamente a resposta espectral de culturas entre o mês mais seco, outubro, e o período de maior umidade, abril (Tabela 3). Essa alta disponibilidade de água

favorece o crescimento das plantas invasoras, permitindo uma distinção mais clara em sua resposta espectral, sendo essas respostas essenciais para entender as complexas interações entre as chuvas e a vegetação da caatinga, e para manejar de forma eficaz as culturas e a biodiversidade nesse bioma único.

Tabela 3. Estatísticas espectrais das amostras aplicadas para classificação.

NDVI 09 de outubro de 2023					
Classe	Máximo	Média	Mínimo	Desvio Padrão	Variância
Palma	0,80897	0,59035	0,31572	0,11799	0,01392
Solo exposto	0,35185	0,21486	0,11342	0,05882	0,00346
Cobertura morta	0,46422	0,31026	0,14882	0,05130	0,00263
Mimosa Pudica	0,87251	0,66191	0,33714	0,13018	0,01695
Solo sombreado	0,99870	0,64940	0,24742	0,15374	0,02364
aNDVI 09 de outubro de 2023					
Classe	Máximo	Média	Mínimo	Desvio Padrão	Variância
Palma	0,83931	0,59628	0,42272	0,09284	0,00862
Solo exposto	0,56685	0,36818	0,23960	0,08680	0,00753
Cobertura morta	0,38846	0,26200	0,04396	0,05998	0,00360
Mimosa Pudica	0,91021	0,62339	0,33956	0,12260	0,01503
Solo sombreado	0,94369	0,63140	0,17877	0,09411	0,00886
NDVI 23 de fevereiro de 2024					
Classe	Máximo	Média	Mínimo	Desvio Padrão	Variância
Palma	0,79158	0,63886	0,36844	0,07490	0,00561
Solo exposto	0,43900	0,22205	0,12789	0,03042	0,00093
Cobertura morta	0,32654	0,23376	0,10122	0,04020	0,00162
Mimosa Pudica	0,87314	0,65013	0,26824	0,09071	0,00823
Cyperus Hermaphroditus	0,90849	0,83831	0,63551	0,05672	0,00322
Solo sombreado	0,93641	0,65211	0,36936	0,19987	0,03995
aNDVI 23 de fevereiro de 2024					
Classe	Máximo	Média	Mínimo	Desvio Padrão	Variância
Palma	0,68109	0,52241	0,24128	0,08678	0,00753
Solo exposto	0,37774	0,21144	-0,01022	0,03195	0,00102
Cobertura morta	0,28549	0,14189	0,02551	0,04995	0,00250
Mimosa Pudica	0,86350	0,56858	0,27477	0,07565	0,00572
Cyperus Hermaphroditus	0,94985	0,77629	0,55933	0,08107	0,00657

Solo sombreado	0,93530	0,50271	0,28661	0,20333	0,04134
NDVI 06 de abril de 2024					
Classe	Máximo	Média	Mínimo	Desvio Padrão	Variância
Palma	0,94550	0,75154	0,51389	0,12481	0,01558
Solo exposto	0,45149	0,25913	0,17467	0,05263	0,00277
Mimosa Pudica	0,96554	0,92196	0,81028	0,02035	0,00041
Cyperus Hermaphroditus	0,91591	0,80962	0,56095	0,05294	0,00280
Solo sombreado	0,98604	0,67183	0,16179	0,24219	0,05866
aNDVI 06 de abril de 2024					
Classe	Máximo	Média	Mínimo	Desvio Padrão	Variância
Palma	0,82579	0,69697	0,63403	0,04517	0,00204
Solo exposto	0,37557	0,30012	0,19143	0,03508	0,00123
Mimosa Pudica	1,06051	0,91882	0,68965	0,05769	0,00333
Cyperus Hermaphroditus	1,04458	0,82926	0,57313	0,07951	0,00632
Solo sombreado	1,24115	0,66474	0,19366	0,22463	0,05046

A classificação aplicada usando a composição de bandas multiespectrais com os algoritmos Gaussian Mixture, KNN, RF e SVM para o mês de outubro podem ser observadas na Figura 8.

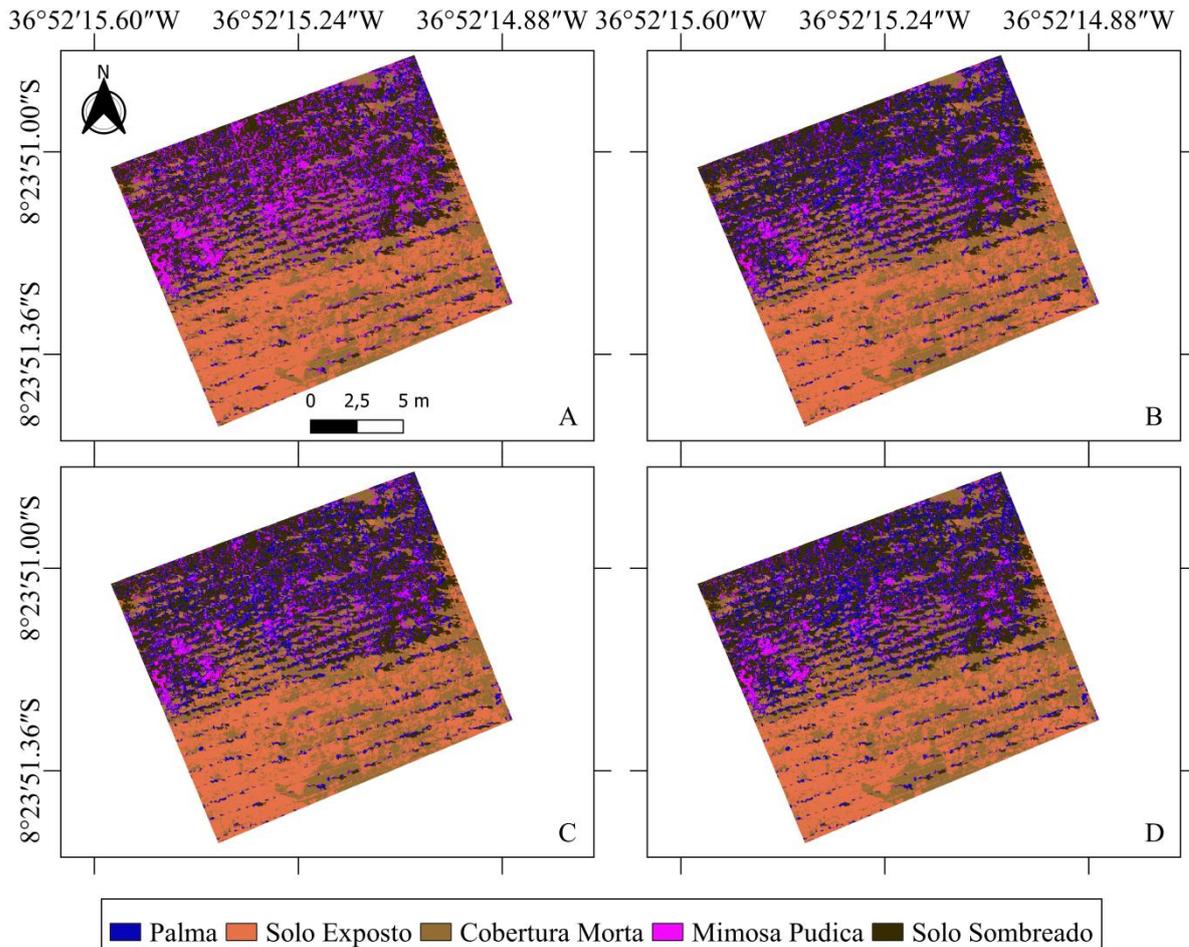


Figura 8. Classificação multiespectral de outubro de 2023, GMM(A), KNN(B), RF (C) e SVM (D)

A Tabela 4 exibe os resultados obtidos através da matriz de confusão dos algoritmos GMM, KNN, RF e SVM. A matriz de confusão pode ser descrita como um modelo que mostra a precisão da classificação, onde as linhas representam as referências usadas como alvos para as amostras no banco de dados, enquanto as colunas refletem as previsões feitas para cada referência. Conseqüentemente, a diagonal principal dessas matrizes esclarece o número de previsões corretamente reconhecidas pelo algoritmo em questão. Valores altos podem ser observados para todos os elementos da diagonal. Os hiper parâmetros associados a predição do algoritmo foram selecionados sendo o melhor K para o KNN como 5, melhor número de árvores sendo 27 e o melhor número de características sendo 1 para o RF e λ 1

associado ao C 1000 para o SVM.

Tabela 4. Matrizes de confusão das classificações multiespectrais de outubro de 2023.

GMM - Multiespectral					
PA	SE	CM	MP	SS	Referências x Predições
712	2	7	41	1	Palma Forrageira (PA)
3	514	32	0	0	Solo Exposto (SE)
1	73	586	3	1	Cobertura Morta (CM)
108	0	4	212	7	Mimosa Pudica (MP)
4	1	1	5	719	Solo Sombreado (SS)
KNN - Multiespectral					
PA	SE	CM	MP	SS	Referências x Predições
770	0	3	66	0	Palma Forrageira (PA)
3	536	42	0	0	Solo Exposto (SE)
1	54	584	3	1	Cobertura Morta (CM)
49	0	1	186	4	Mimosa Pudica (MP)
5	0	0	6	723	Solo Sombreado (SS)
RF - Multiespectral					
PA	SE	CM	MP	SS	Referências x Predições
784	0	4	60	0	Palma Forrageira (PA)
3	538	39	0	1	Solo Exposto (SE)
1	52	585	2	0	Cobertura Morta (CM)
36	0	2	193	2	Mimosa Pudica (MP)
4	0	0	6	725	Solo Sombreado (SS)
SVM - Multiespectral					
PA	SE	CM	MP	SS	Referências x Predições
778	1	5	60	2	Palma Forrageira (PA)
3	535	31	0	0	Solo Exposto (SE)
1	54	593	1	0	Cobertura Morta (CM)
42	0	0	195	2	Mimosa Pudica (MP)
4	0	1	5	724	Solo Sombreado (SS)

Com base nos resultados acima, foi realizada uma comparação entre os quatro algoritmos, considerando métricas como precisão, recall (sensibilidade), F1

score, acurácia global e, por fim, o índice Kappa apresentados na Tabela 5.

Tabela 5. Avaliação das métricas aplicadas aos classificadores em imagens multiespectrais em outubro de 2023

GMM - Multiespectral						
Média	PA	SE	CM	MP	SS	Parâmetros
0,8755	0.9332	0.9363	0.8825	0.6405	0.9849	Precisão
0.8922	0.8599	0.8712	0.9302	0.8123	0.9876	Recall
0.8812	0.8950	0.9026	0.9057	0.7162	0.9863	F1 score
KNN - Multiespectral						
Média	PA	SE	CM	MP	SS	Parâmetros
0.9017	0.9178	0.9226	0.9082	0.775	0.9850	Precisão
0.8942	0.9300	0.9085	0.9270	0.7126	0.9931	Recall
0.8977	0.9238	0.9155	0.9175	0.7425	0.9891	F1 score
RF - Multiespectral						
Média	PA	SE	CM	MP	SS	Parâmetros
0.9159	0.9245	0.9260	0.9141	0.8283	0.9864	Precisão
0.9045	0.9469	0.9119	0.9286	0.7395	0.9959	Recall
0.9096	0.9356	0.9189	0.9213	0.7814	0.9911	F1 score
SVM - Multiespectral						
Média	PA	SE	CM	MP	SS	Parâmetros
0.9152	0.9196	0.9403	0,9137	0.8159	0.9864	Precisão
0.9059	0.9396	0.9068	0.9413	0.7471	0.9945	Recall
0.9101	0.9295	0.9232	0.9273	0.78	0.9904	F1 score

A avaliação do desempenho dos modelos aplicados às imagens multiespectrais, indicou que o SVM se destacou juntamente ao RF. O RF apresentou melhor precisão geral, enquanto que o SVM apresentou melhores valores de recall e F1 score, assim como no índice kappa, onde o SVM, RF, KNN e GMM apresentaram respectivamente valores calculados de (0,91035; 0,91032; 0,8994 e 0,8765). O SVM apresentou valores de precisão acima do RF apenas na classe de solo exposto, enquanto que o melhor valor de precisão na classe Palma, foi obtido pelo GMM, já no solo sombreado, houve um empate entre o RF e o SVM, por fim para cobertura morta e a cultura nativa mimosa pudica, os valores calculados pelo RF foram

superiores. No que tange a métrica do recall, o SVM apresentou melhores resultados nas classes de solo exposto, cobertura morta e mimosa pudica, enquanto que o RF apresentou melhores resultados na classificação de palma e solo sombreado. Por fim, o F1 score indicou melhor desempenho no RF nas classes de palma, mimosa pudica e solo sombreado, enquanto que o SVM desempenhou melhor na classificação de solo exposto e cobertura morta.

Todos os quatro modelos exibiram valores do índice Kappa superiores a 0,8, classificando-os como 'Quase Perfeitos' de acordo com a Tabela 2. Tanto os algoritmos SVM, quanto o Random Forest e K-Nearest Neighbors demonstraram métricas notavelmente semelhantes, com o Random Forest se destacando no espaço amostral multiespectral com base nas classificações individuais de classes, mas perdendo em resultados globais para o SVM.

Da mesma forma, na classificação das imagens adquiridas pelo VANT com base no espaço amostral composto por bandas RGB, foi observado um resultado altamente consistente com as classificações baseadas em bandas multiespectrais. Os hiper parâmetros associados a predição do algoritmo foram selecionados sendo o melhor K para o KNN como 17, melhor número de árvores sendo 81 e o melhor número de características sendo 1 para o RF e λ de 0,25 associado ao C 1000 para o SVM e a consistência da classificação com imagens RGB em relação a multiespectrais foram principalmente evidenciadas através da análise numérica e dos mapas de classificação gerados, como mostrado na Figura 9.

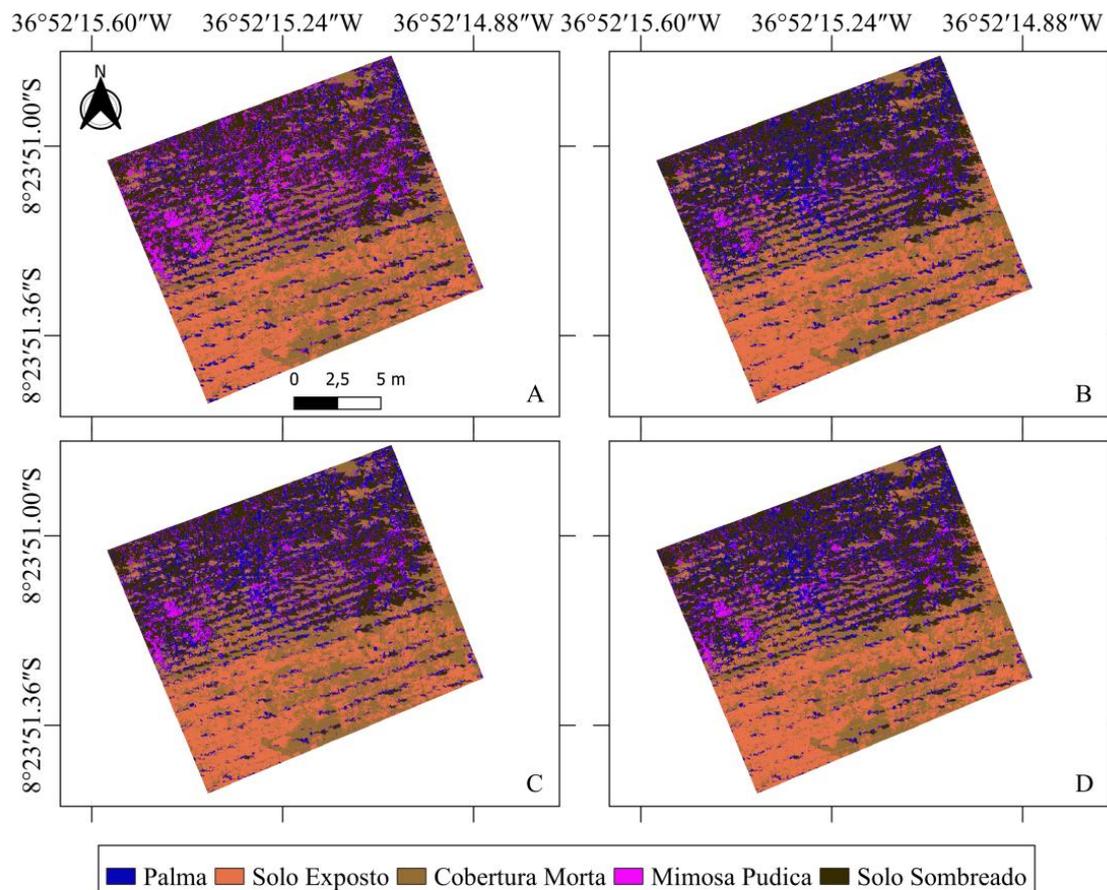


Figura 9. Classificação RGB de outubro de 2023, GMM(A), KNN(B), RF (C) e SVM (D)

Da mesma forma que na abordagem utilizada para as classificações de imagens multiespectrais, as matrizes de confusão (Tabela 6) derivadas dessas imagens RGB foram submetidas a uma análise detalhada em relação às métricas de precisão, recall, F1 Score, acurácia e índice Kappa (Tabela 7). As tabelas a seguir apresentam esses resultados de forma concisa.

Tabela 6. Matrizes de confusão das classificações RGB de outubro de 2023

GMM - RGB					
PA	SE	CM	MP	SS	Referências x Predições
680	12	8	57	4	Palma Forrageira (PA)
8	532	44	2	0	Solo Exposto (SE)

8	48	578	2	0	Cobertura Morta (CM)
122	0	3	202	1	Mimosa Pudica (MP)
12	1	0	0	724	Solo Sombreado (SS)
KNN - RGB					
PA	SE	CM	MP	SS	Referências x Predições
755	1	5	96	1	Palma Forrageira (PA)
10	548	44	3	0	Solo Exposto (SE)
5	44	584	2	0	Cobertura Morta (CM)
57	0	0	161	0	Mimosa Pudica (MP)
3	0	0	1	728	Solo Sombreado (SS)
RF - RGB					
PA	SE	CM	MP	SS	Referências x Predições
763	4	4	89	1	Palma Forrageira (PA)
10	540	43	2	0	Solo Exposto (SE)
6	48	582	4	0	Cobertura Morta (CM)
45	0	4	168	1	Mimosa Pudica (MP)
6	1	0	0	727	Solo Sombreado (SS)
SVM - RGB					
PA	SE	CM	MP	SS	Referências x Predições
761	3	4	75	2	Palma Forrageira (PA)
8	548	44	2	0	Solo Exposto (SE)
4	42	585	3	0	Cobertura Morta (CM)
54	0	0	183	0	Mimosa Pudica (MP)
3	0	0	0	727	Solo Sombreado (SS)

Com base nos resultados acima, foi realizada uma comparação entre os quatro algoritmos, considerando métricas como precisão, recall (sensibilidade), F1 score, acurácia global e, por fim, o índice Kappa apresentados na Tabela 7.

Tabela 7. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de outubro de 2023.

GMM - RGB						
Média	PA	SE	CM	MP	SS	Parâmetros
0,8617	0.8936	0.9078	0.9088	0.6159	0.9824	Precisão

0.8781	0.8193	0.8971	0.9131	0.7681	0.9931	Recall
0.8679	0.8548	0.9025	0.9109	0.6836	0.9877	F1 score
KNN - RGB						
Média	PA	SE	CM	MP	SS	Parâmetros
0.8877	0.8800	0.9058	0.9197	0.7385	0.9945	Precisão
0.8734	0.9096	0.9241	0.9226	0.6122	0.9986	Recall
0.8793	0.8946	0.9149	0.9211	0.6694	0.9966	F1 score
RF - RGB						
Média	PA	SE	CM	MP	SS	Parâmetros
0.8928	0.8862	0.9076	0.9094	0.7706	0.9904	Precisão
0.8771	0.9193	0.9106	0.9194	0.6388	0.9973	Recall
0.8837	0.9024	0.9091	0.9144	0.6985	0.9938	F1 score
SVM - RGB						
Média	PA	SE	CM	MP	SS	Parâmetros
0.9003	0.9006	0.9103	0,9227	0.7721	0.9959	Precisão
0.8916	0.9169	0.9241	0.9242	0.6958	0.9973	Recall
0.8956	0.9087	0.9171	0.9234	0.732	0.9966	F1 score

A avaliação do desempenho dos modelos aplicados às imagens RGB, indicou que o SVM se destacou em todas as métricas globais. O SVM apresentou resultados superiores em todas as métricas com exceção do recall do solo sombreado, onde o KNN foi superior e o RF obteve resultado igual. O índice kappa, foi outro destaque do SVM, onde o SVM, RF, KNN e GMM apresentaram respectivamente valores calculados de (0,8972; 0,8869; 0,8853 e 0,8611). Todos os quatro modelos exibiram valores do índice Kappa superiores a 0,8, classificando-os como 'Quase Perfeitos' de acordo com a Tabela 2.

O imageamento de fevereiro apresentou uma nova classe de invasoras, o *Cyperus Hermaphroditus*, que é uma cultura comum no semiárido pernambucano e está associada com o aumento significativo de umidade disponível no solo ocasionado pela precipitação antecedente de 60 dias ao imageamento (Figura 2). A aparição do *Cyperus Hermaphroditus*, assim como o crescimento da mimosa pudica afetou drasticamente na representação das culturas na área de estudo, tendo ainda um diferencial de menor apresentação da classe de solo sombreado, visto que o voo

foi feito próximo ao meio dia, o que ficou explícito no voo realizado no espaço amostral multiespectral (Figura 10).

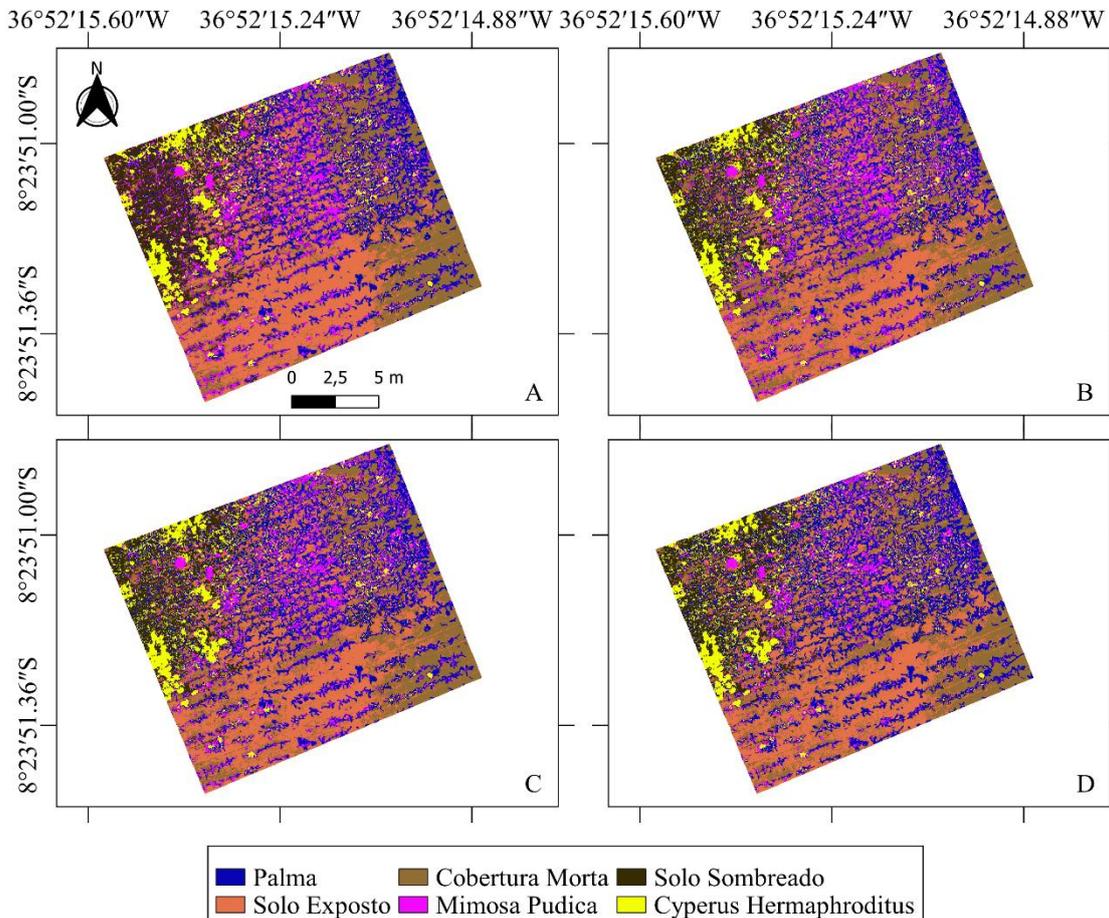


Figura 10. Classificação multiespectral de fevereiro de 2024, GMM(A), KNN(B), RF (C) e SVM (D)

A Tabela 8 demonstra os resultados obtidos pela matriz de confusão dos algoritmos GMM, KNN, RF e SVM. Esta matriz pode ser vista como um diagrama que mostra a precisão na classificação, onde as linhas representam as referências usadas como metas para as amostras no conjunto de dados, enquanto as colunas refletem as previsões realizadas para cada referência. Conseqüentemente, a diagonal principal destas matrizes indica o número de previsões corretas feitas pelo algoritmo considerado. Observam-se valores elevados em todos os elementos dessa

diagonal. Os hiper parâmetros para a previsão pelo algoritmo foram determinados com base na otimização: o valor ideal de K para o KNN foi 13, o número correto de árvores foi 13, e o número ótimo de características foi 2 para o RF. Para o SVM, λ foi ajustado para 8 e C para 100.

Tabela 8. Matrizes de confusão das classificações multiespectrais de fevereiro de 2024

GMM - Multiespectral						
PA	SE	CM	MP	CH	SS	Referências x Predições
882	0	0	102	21	0	Palma Forrageira (PA)
0	930	243	0	0	1	Solo Exposto (SE)
6	97	715	1	0	0	Cobertura Morta (CM)
186	0	0	572	53	0	Mimosa Pudica (MP)
26	0	0	50	783	13	Cyperus Hermaphroditus (CH)
0	1	14	0	9	229	Solo Sombreado (SS)
KNN - Multiespectral						
PA	SE	CM	MP	CH	SS	Referências x Predições
964	0	0	100	31	0	Palma Forrageira (PA)
0	938	139	1	0	0	Solo Exposto (SE)
4	89	833	0	0	2	Cobertura Morta (CM)
114	1	0	586	47	0	Mimosa Pudica (MP)
18	0	0	38	778	7	Cyperus Hermaphroditus (CH)
0	0	0	0	10	234	Solo Sombreado (SS)
RF - Multiespectral						
PA	SE	CM	MP	CH	SS	Referências x Predições
976	0	1	91	23	0	Palma Forrageira (PA)
0	961	138	0	0	1	Solo Exposto (SE)
2	67	832	0	0	0	Cobertura Morta (CM)
105	0	0	600	46	0	Mimosa Pudica (MP)
17	0	0	34	789	7	Cyperus Hermaphroditus (CH)
0	0	1	0	8	235	Solo Sombreado (SS)
SVM - Multiespectral						
PA	SE	CM	MP	CH	SS	Referências x Predições
973	0	1	86	21	0	Palma Forrageira (PA)

0	949	130	0	0	1	Solo Exposto (SE)
1	79	841	0	0	0	Cobertura Morta (CM)
108	0	0	596	41	0	Mimosa Pudica (MP)
18	0	0	43	797	5	Cyperus Hermaphroditus (CH)
0	0	0	0	7	237	Solo Sombreado (SS)

Com base nos resultados apresentados, uma análise comparativa entre os algoritmos aplicados foi realizada, sendo considerado métricas como precisão, recall (sensibilidade), F1 score, acurácia global e, por fim, o índice Kappa apresentados na Tabela 9.

Tabela 9. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de fevereiro de 2024

Gaussian Mixture -Multispectral							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8419	0.8776	0.7922	0.8730	0.7053	0.8979	0.9051	Precisão
0.8463	0.8018	0.9047	0.7356	0.7890	0.9042	0.9424	Recall
0.8417	0.8380	0.8447	0.7984	0.7448	0.9010	0.9234	F1 score
K- Nearest Neighbors - Multispectral							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8859	0.8804	0.8701	0.8976	0.7834	0.9251	0.9590	Precisão
0.8859	0.8764	0.9125	0.8570	0.8083	0.8984	0.9630	Recall
0.8857	0.8784	0.8908	0.8768	0.7957	0.9115	0.9610	F1 score
Random Forest - Multispectral							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8975	0.8946	0.8736	0.9234	0.7989	0.9315	0.9631	Precisão
0.8973	0.8873	0.9348	0.8560	0.8276	0.9111	0.9671	Recall
0.8970	0.8909	0.9032	0.8884	0.8130	0.9212	0.9651	F1 score
Random Forest - Multispectral							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8978	0.9001	0.8787	0.9131	0.800	0.9235	0.9713	Precisão
0.8984	0.8845	0.9232	0.8652	0.8221	0.9203	0.9753	Recall
0.8979	0.8923	0.9004	0.8885	0.8109	0.9219	0.9733	F1 score

A análise do desempenho dos modelos aplicados às imagens multiespectrais

revelou que o SVM se destacou, apresentando resultados superiores em termos globais de precisão, recall e F1 score, assim como no índice kappa, onde os valores calculados para o SVM, RF, KNN e GMM foram, respectivamente, (0,86521; 0,86519; 0,85023 e 0,79524). O RF apresentou resultados menos precisos que o SVM quando analisado os resultados gerais, apesar de ter superado o SVM em precisão nas classes de cobertura morta e Cyperus Hermaphroditus. Em relação ao recall, o SVM obteve os melhores resultados nas classes de cobertura morta, Cyperus Hermaphroditus e solo sombreado, enquanto o RF teve melhor desempenho nas classes de palma, solo exposto e mimosa pudica.

No que se refere ao F1 score, o SVM mostrou melhor desempenho nas classes de palma, cobertura morta, Cyperus Hermaphroditus e solo sombreado, enquanto o RF teve melhores resultados nas classes de solo exposto e mimosa pudica. O GMM exibiu um valor de índice kappa inferior a 0,8, sendo o único dos quatro algoritmos classificado como de desempenho razoável; já o KNN, RF e SVM mostraram valores de índice Kappa acima de 0,8, classificando-os como 'Quase Perfeitos', conforme descrito na Tabela 2.

Tanto o SVM quanto o Random Forest exibiram métricas muito semelhantes, com o SVM se destacando na análise multiespectral globalmente e apresentando melhores resultados de F1 score em mais classes do que o RF. Da mesma forma, na classificação das imagens capturadas pelo VANT com base em bandas RGB, os resultados foram altamente consistentes com as classificações baseadas em bandas multiespectrais, apresentando uma baixa perda nas métricas de avaliação. Os hiper parâmetros para a predição dos algoritmos foram escolhidos como o melhor K para o KNN sendo 17, o número ótimo de árvores sendo 81 e o número ideal de características sendo 3 para o RF, enquanto para o SVM, o λ foi ajustado para 8 e C para 100. A consistência da classificação usando imagens RGB em relação às multiespectrais foi principalmente evidenciada pela análise numérica e pelos mapas de classificação gerados, como mostrado na Figura 11.

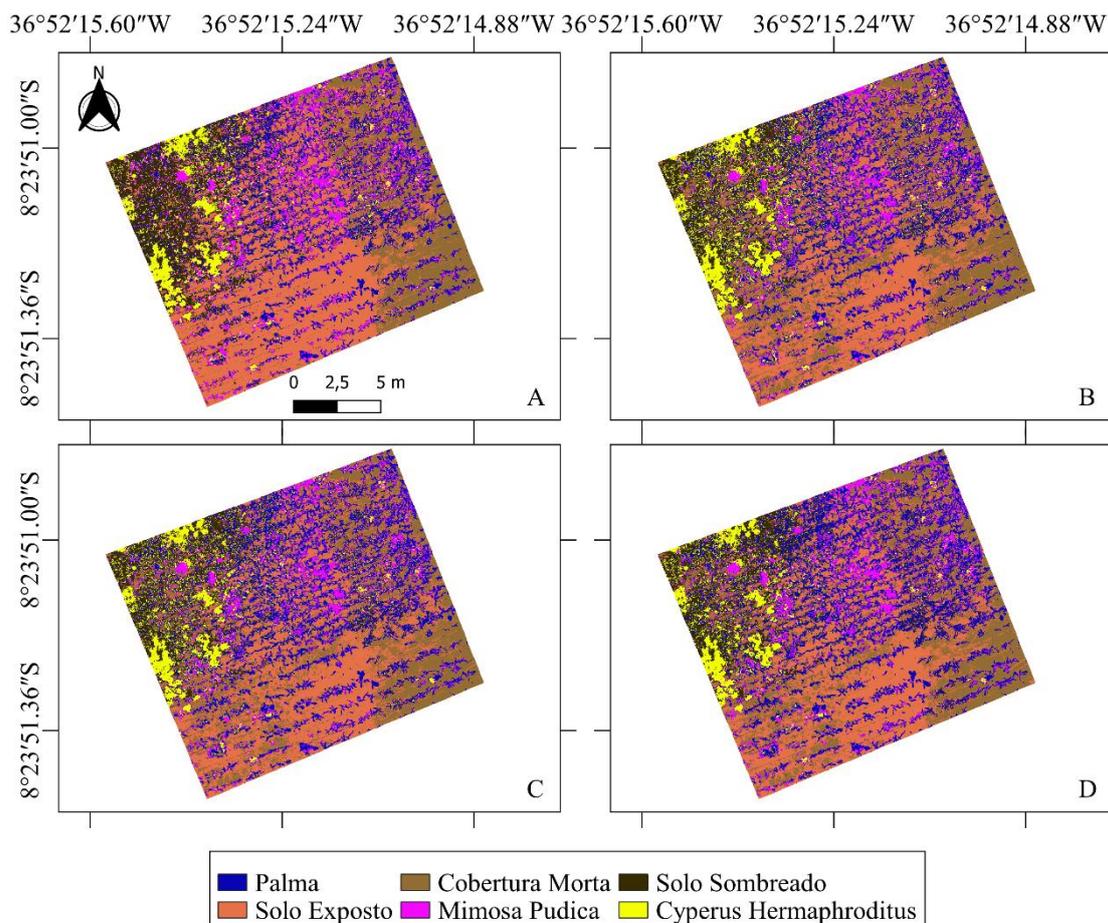


Figura 11. Classificação RGB de fevereiro de 2024, GMM(A), KNN(B), RF (C) e SVM (D)

Assim como na metodologia empregada para as classificações das imagens multiespectrais, as matrizes de confusão (Tabela 10) geradas a partir das imagens RGB foram minuciosamente analisadas com respeito às métricas de precisão, recall e F1 Score (Tabela 11).

Tabela 10. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de fevereiro de 2024

GMM - RGB						Referências x Predições
PA	SE	CM	MP	CH	SS	
806	3	0	55	14	1	Palma Forrageira (PA)

6	948	297	0	0	3	Solo Exposto (SE)
6	75	658	0	0	1	Cobertura Morta (CM)
259	1	0	632	87	0	Mimosa Pudica (MP)
23	0	0	38	753	15	Cyperus Hermaphroditus (CH)
0	1	17	0	12	223	Solo Sombreado (SS)
KNN - RGB						
PA	SE	CM	MP	CH	SS	Referências x Predições
928	3	0	86	30	0	Palma Forrageira (PA)
8	930	163	1	0	0	Solo Exposto (SE)
3	95	808	0	0	4	Cobertura Morta (CM)
141	0	0	599	53	0	Mimosa Pudica (MP)
20	0	0	39	775	8	Cyperus Hermaphroditus (CH)
0	0	1	0	8	231	Solo Sombreado (SS)
RF - RGB						
PA	SE	CM	MP	CH	SS	Referências x Predições
934	2	0	106	26	0	Palma Forrageira (PA)
8	928	160	0	0	0	Solo Exposto (SE)
1	98	811	0	0	4	Cobertura Morta (CM)
130	0	0	582	57	0	Mimosa Pudica (MP)
27	0	0	37	776	7	Cyperus Hermaphroditus (CH)
0	0	1	0	7	232	Solo Sombreado (SS)
SVM - RGB						
PA	SE	CM	MP	CH	SS	Referências x Predições
933	2	1	82	36	0	Palma Forrageira (PA)
7	933	158	0	0	0	Solo Exposto (SE)
2	93	813	0	0	4	Cobertura Morta (CM)
146	0	0	618	60	0	Mimosa Pudica (MP)
12	0	0	25	762	5	Cyperus Hermaphroditus (CH)
0	0	0	0	8	234	Solo Sombreado (SS)

Tomando por referência os resultados mencionados, procedeu-se à comparação entre os quatro algoritmos, levando em conta métricas como precisão, recall (sensibilidade), F1 score, acurácia global e, por último, o índice Kappa, conforme ilustrado na Tabela 11.

Tabela 11. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de fevereiro de 2024

GMM - RGB							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8329	0.9169	0.7560	0.8892	0.6456	0.9083	0.8814	Precisão
0.8318	0.7327	0.9222	0.6770	0.8717	0.8695	0.9177	Recall
0.8239	0.8146	0.8309	0.7687	0.7418	0.8885	0.8992	F1 score
KNN - RGB							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8761	0.8863	0.8439	0.8879	0.7553	0.9204	0.9625	Precisão
0.8752	0.8436	0.9047	0.8313	0.8262	0.8949	0.9506	Recall
0.8749	0.8645	0.8732	0.8587	0.7892	0.9075	0.9565	F1 score
RF - RGB							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8747	0.8745	0.8467	0.8873	0.7568	0.9162	0.9667	Precisão
0.8733	0.8491	0.9027	0.8344	0.8028	0.8961	0.9547	Recall
0.8735	0.8616	0.8738	0.8600	0.7791	0.9060	0.9607	F1 score
SVM - RGB							
Média	PA	SE	CM	MP	CH	SS	Parâmetros
0.8819	0.8852	0.8497	0.8914	0.7500	0.9478	0.9669	Precisão
0.8812	0.8482	0.9076	0.8364	0.8524	0.8799	0.9630	Recall
0.8804	0.8663	0.8777	0.8631	0.7979	0.9630	0.9650	F1 score

A análise do desempenho dos modelos aplicados às imagens RGB revelou que o SVM sobressaiu em todas as métricas globais. O SVM demonstrou resultados superiores em quase todas as métricas, exceto na classe mimosa pudica em relação à precisão, e nas classes palma e Cyperus Hermaphroditus em relação ao recall, onde o RF obteve resultados melhores. Outro destaque foi o índice Kappa, com os valores calculados para o SVM, RF, KNN e GMM sendo, respectivamente, (0,8404; 0,8328; 0,8349 e 0,7731). O GMM teve um valor de índice Kappa abaixo de 0,8, sendo o único dos quatro algoritmos classificado como de desempenho moderado. O KNN, neste caso, apresentou um resultado superior ao do RF, enquanto o SVM alcançou o maior valor de índice Kappa. Os algoritmos KNN, RF e SVM

apresentaram valores de índice Kappa superiores a 0,8, classificando-os como 'Quase Perfeitos', conforme indicado na Tabela 2.

O imageamento de abril não apresentou a classe de cobertura morta no solo, uma vez que as fortes chuvas antecedentes acabaram limpando a área, além disso, devido à o aumento da disponibilidade de umidade no solo, houve um crescimento de plantas invasoras na área de forma muito mais abrupta que no período entre outubro de 2023 e fevereiro de 2024. O aumento de culturas de porte maior que a palma, que era a cultura mais presente nos outros imageamentos, facilitou no sombreamento do solo na área experimental, aumentando assim a presença da classe (Figura 12).

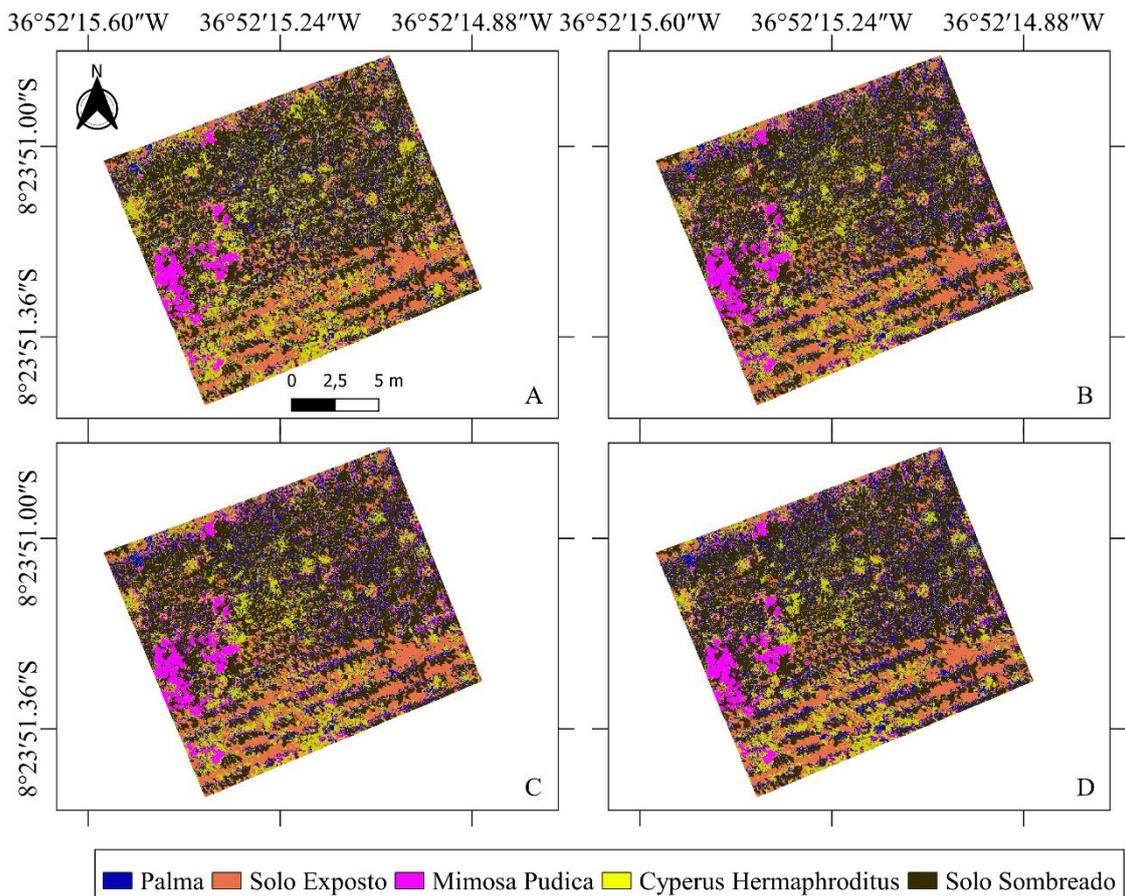


Figura 12. Classificação multiespectral em abril de 2024, GMM(A), KNN(B), RF (C) e

SVM (D)

A Tabela 12 apresenta os resultados derivados da matriz de confusão dos algoritmos GMM, KNN, RF e SVM. Esta matriz pode ser entendida como um gráfico que demonstra a precisão da classificação, onde as linhas representam as referências usadas como metas para as amostras no conjunto de dados, enquanto as colunas exibem as predições realizadas para cada referência. Assim, a diagonal principal dessas matrizes indica o número de previsões corretas feitas pelo algoritmo em questão. Em todos os elementos dessa diagonal, observam-se valores altos. Os hiperparâmetros para a predição pelos algoritmos foram definidos com base na otimização: o valor ideal de K para o KNN foi 1, o número apropriado de árvores foi 81, e o número ótimo de características foi 4 para o RF. No caso do SVM, λ foi ajustado para 8 e C para 10.

Tabela 12. Matrizes de confusão das classificações multiespectrais de abril de 2024

GMM - Multiespectral					
PA	SE	MP	CH	SS	Referências x Predições
492	0	0	32	0	Palma Forrageira (PA)
0	542	0	0	3	Solo Exposto (SE)
0	0	447	8	0	Mimosa Pudica (MP)
34	3	8	494	0	Cyperus Hermaphroditus (CH)
0	0	1	0	549	Solo Sombreado (SS)
KNN - Multiespectral					
PA	SE	MP	CH	SS	Referências x Predições
509	0	0	16	0	Palma Forrageira (PA)
0	545	0	0	0	Solo Exposto (SE)
1	0	450	5	0	Mimosa Pudica (MP)
16	0	6	513	0	Cyperus Hermaphroditus (CH)
5	0	0	0	552	Solo Sombreado (SS)
RF - Multiespectral					
PA	SE	MP	CH	SS	Referências x Predições
510	0	0	10	0	Palma Forrageira (PA)
0	545	0	0	0	Solo Exposto (SE)
0	0	449	6	0	Mimosa Pudica (MP)

16	0	7	518	0	Cyperus Hermaphroditus (CH)
0	0	0	0	552	Solo Sombreado (SS)
SVM - Multiespectral					
PA	SE	MP	CH	SS	Referências x Predições
498	0	1	15	0	Palma Forrageira (PA)
0	545	0	0	0	Solo Exposto (SE)
1	0	448	6	0	Mimosa Pudica (MP)
27	0	6	513	0	Cyperus Hermaphroditus (CH)
0	0	1	0	552	Solo Sombreado (SS)

Com base nos resultados mencionados, foi realizada uma comparação entre os quatro algoritmos, levando em consideração métricas como precisão, recall (sensibilidade), F1 score, acurácia global e, finalmente, o índice Kappa, conforme apresentados na Tabela 13.

Tabela 13. Avaliação das métricas aplicadas aos classificadores em imagens multiespectrais em abril de 2024

GMM - Multiespectral						
Média	PA	SE	MP	CH	SS	Parâmetros
0,9661	0.9389	0.9945	0.9824	0.9165	0.9982	Precisão
0.9660	0.9354	0.9945	0.9803	0.9251	0.9946	Recall
0.9660	0.9371	0.9945	0.9813	0.9208	0.9964	F1 score
KNN - Multiespectral						
Média	PA	SE	MP	CH	SS	Parâmetros
0.9830	0.9695	1	0.9868	0.9589	1	Precisão
0.9830	0.9677	1	0.9868	0.9607	1	Recall
0.9830	0.9686	1	0.9868	0.9598	1	F1 score
RF - Multiespectral						
Média	PA	SE	MP	CH	SS	Parâmetros
0.9850	0.9808	1	0.9868	0.9575	1	Precisão
0.9848	0.9696	1	0.9846	0.9700	1	Recall
0.9849	0.9751	1	0.9857	0.9637	1	F1 score
SVM - Multiespectral						
Média	PA	SE	MP	CH	SS	Parâmetros

0.9782	0.9689	1	0.9846	0.9396	0.9982	Precisão
0.9780	0.9468	1	0.9825	0.9607	1	Recall
0.9781	0.9577	1	0.9835	0.9500	0.9991	F1 score

A análise do desempenho dos modelos aplicados às imagens multiespectrais revelou que o RF, junto com o KNN, teve um desempenho notável. O RF obteve os melhores resultados em precisão geral, recall e F1 score em termos de valores médios. Quanto às métricas individuais, o RF superou nas diversas categorias, exceto na classe mimosa pudica, onde o KNN teve um desempenho superior em recall e F1 score. Os valores do índice Kappa indicaram que o RF teve o melhor desempenho, seguido pelo KNN, com os valores para SVM, RF, KNN e GMM sendo, respectivamente, (0,97270; 0,98132; 0,97893 e 0,95738).

Todos os quatro modelos apresentaram valores de índice Kappa acima de 0,8, classificando-os como 'Quase Perfeitos', conforme descrito na Tabela 2. O Random Forest demonstrou uma superioridade nas métricas, destacando-se no espaço amostral multiespectral, tanto em termos de classificações individuais de classes quanto em resultados globais, sendo seguido de perto pelo KNN.

De forma semelhante, na classificação das imagens adquiridas pelo VANT, com base no conjunto amostral composto por bandas RGB, observou-se um resultado altamente consistente com as classificações baseadas em bandas multiespectrais. Os hiperparâmetros para a predição pelos algoritmos foram otimizados, sendo o melhor K para o KNN igual a 1, o número ideal de árvores sendo 81 e o número ótimo de características sendo 1 para o RF. Para o SVM, λ foi ajustado para 8 e C para 10. A consistência entre a classificação das imagens RGB e das multiespectrais foi evidenciada principalmente pela análise numérica e pelos mapas de classificação gerados, como mostrado na Figura 13.

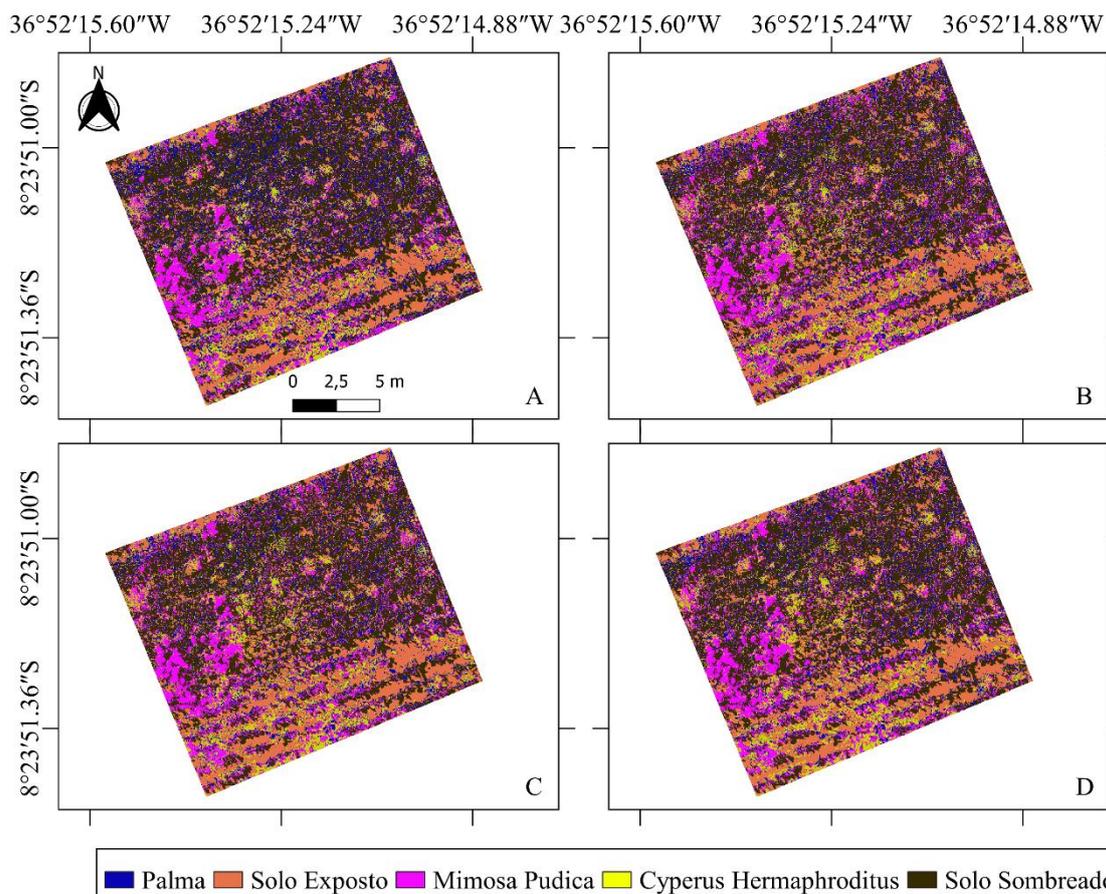


Figura 13. Classificação RGB de abril de 2024, GMM(A), KNN(B), RF (C) e SVM (D)

Assim como na abordagem empregada para as classificações de imagens multiespectrais, as matrizes de confusão (Tabela 14) geradas a partir dessas imagens RGB foram analisadas detalhadamente em relação às métricas de precisão, recall, F1 Score, acurácia e índice Kappa (Tabela 15). As tabelas a seguir resumem esses resultados de forma clara e concisa.

Tabela 14. Matrizes de confusão das classificações RGB de abril de 2024

GMM - RGB					
PA	SE	MP	CH	SS	Referências x Predições
493	7	3	35	0	Palma Forrageira (PA)
1	537	0	0	1	Solo Exposto (SE)
3	0	417	33	8	Mimosa Pudica (MP)

29	0	33	466	1	Cyperus Hermaphroditus (CH)
0	1	3	0	542	Solo Sombreado (SS)
KNN - RGB					
PA	SE	MP	CH	SS	Referências x Predições
508	1	2	23	0	Palma Forrageira (PA)
0	544	0	0	0	Solo Exposto (SE)
1	0	425	21	1	Mimosa Pudica (MP)
17	0	28	490	1	Cyperus Hermaphroditus (CH)
0	0	1	0	550	Solo Sombreado (SS)
RF - RGB					
PA	SE	MP	CH	SS	Referências x Predições
501	0	0	16	0	Palma Forrageira (PA)
0	545	0	0	0	Solo Exposto (SE)
4	0	437	17	0	Mimosa Pudica (MP)
21	0	18	501	0	Cyperus Hermaphroditus (CH)
0	0	1	0	552	Solo Sombreado (SS)
SVM - RGB					
PA	SE	MP	CH	SS	Referências x Predições
489	1	1	12	0	Palma Forrageira (PA)
2	544	0	0	0	Solo Exposto (SE)
3	0	429	38	0	Mimosa Pudica (MP)
32	0	23	484	0	Cyperus Hermaphroditus (CH)
0	0	3	0	522	Solo Sombreado (SS)

Com base nos resultados acima, foi realizada uma comparação entre os quatro algoritmos, considerando métricas como precisão, recall (sensibilidade), F1 score, acurácia global e, por fim, o índice Kappa apresentados na Tabela 15.

Tabela 15. Avaliação das métricas aplicadas aos classificadores em imagens RGB para o mês de abril de 2024.

GMM - RGB						
Média	PA	SE	MP	CH	SS	Parâmetros
0.9382	0.9164	0.9963	0.9046	0.8809	0.9927	Precisão
0.9338	0.9373	0.9853	0.9145	0.8727	0.9819	Recall

0.9382	0.9267	0.9908	0.9095	0.8768	0.9872	F1 score
KNN - RGB						
Média	PA	SE	MP	CH	SS	Parâmetros
0.9625	0.9513	1	0.9487	0.9142	0.9982	Precisão
0.9620	0.9658	0.9982	0.9321	0.9176	0.9964	Recall
0.9622	0.9585	0.9991	0.9403	0.9159	0.9973	F1 score
RF - RGB						
Média	PA	SE	MP	CH	SS	Parâmetros
0.9698	0.9691	1	0.9541	0.9278	0.9982	Precisão
0.9698	0.9525	1	0.9583	0.9382	1	Recall
0.9698	0.9607	1	0.9562	0.9330	0.9991	F1 score
SVM - RGB						
Média	PA	SE	MP	CH	SS	Parâmetros
0.9548	0.9722	0.9963	0.9128	0.8980	0.9950	Precisão
0.9550	0.9300	0.9982	0.9408	0.9064	1	Recall
0.9547	0.9504	0.9973	0.9266	0.9021	0.9973	F1 score

A análise do desempenho dos modelos aplicados às imagens RGB mostrou que o RF se sobressaiu em todas as métricas globais. O RF obteve os melhores resultados em todas as métricas globais e na maioria das métricas individuais, exceto no recall da classe palma, onde o KNN teve um desempenho superior. O índice Kappa também destacou o RF, com os valores calculados para o SVM, RF, KNN e GMM sendo, respectivamente, (0,9450; 0,9631; 0,9540 e 0,9243). Todos os quatro modelos apresentaram valores do índice Kappa acima de 0,8, o que os classifica como 'Quase Perfeitos', conforme descrito na Tabela 2.

4. DISCUSSÃO

O monitoramento de áreas agrícolas é um elemento de extrema necessidade para auxiliar na produtividade, uma vez que culturas invasoras podem afetar a disponibilidade de nutrientes para o cultivo (GARCÍA et al., 2023). Índices multiespectrais, assim como índices feitos a partir das bandas visíveis RGB podem ser aplicados na classificação de culturas, diferenciando culturas e estágios de crescimento, além de diferenciar coberturas do solo. (ANDRADE et al., 2024). Tal

fato corrobora com o demonstrado por Wang et al. (2022), que utilizou técnicas de aprendizagem de máquina em conjunto com dados espectrais, envolvendo diferentes níveis do infravermelho e em índices multiespectrais para monitorar o uso e cobertura do solo.

Os resultados demonstraram um bom desempenho geral, em especial indicando o RF como uma melhor opção, visto que o mesmo, desempenhou tão bem quanto o SVM, performando um pouco abaixo para os meses de outubro e fevereiro, mas mostrando um resultado superior em abril, uma vez que como demonstrado na tabela 3, houve maior diferença nos valores de reflectância espectral nos índices NDVI e aNDVI entre cada classe, o que vai ao encontro do que foi demonstrado por Sarma & Nidamanuri (2023) que aplicou imagens hiperespectrais para classificar cultivos agrícolas na Índia, apresentando dificuldades em classificar as culturas do tomate e berinjela, apresentando confusões nos algoritmos devido a resposta espectral similar. Tal confusão na classificação não ocorre somente entre os cultivos, como no caso da palma forrageira e as culturas invasoras, mimosa pudica e cyperus hermaphroditus, mas ocorre também entre as classificações de solo exposto e cobertura morta, em particular ocorrendo mais na classificação RGB, visto que as respostas espectrais da banda visível agem de forma superficial, enquanto que a banda do infravermelho próximo aplicado a análise multiespectral, tem maior sensibilidade ao teor de água (LE et al., 2023), o que permite diferenciar melhor a umidade presente no solo em áreas de cobertura morta, visto que a cobertura morta atua como uma técnica conservacionista, aumentando a disponibilidade de água no solo (Montenegro et al., 2013).

As classificações utilizando apenas reflectâncias de bandas do espectro visível (RGB) e o índice aNDVI apresentaram resultados empolgantes, com altos valores de F1 score, que leva em consideração tanto a precisão, quanto o recall, onde a diferença entre aplicação multiespectral e RGB foi de menos de 5%, o que também foi observado nas outras métricas, incluindo o índice kappa aplicado para concordância, que só apresentou resultados abaixo de 0,8 com o GMM, visto que é

um algoritmo de agrupamento não supervisionado que assume que os dados de entrada que seguem uma distribuição normal, sendo amplamente aplicado para o mapeamento de cobertura do solo, devido a seu baixo custo computacional (GUAN et al., 2023). Tal resultado positivo é um avanço significativo, uma vez que tecnologias de baixo custo em países emergentes são necessárias para o avanço econômico e social da região, tornando essa perda de desempenho da classificação com imagens de reflectância de banda visível ferramentas ainda mais impactantes.

Os algoritmos KNN, RF e SVM apresentaram melhores resultados que o GMM, sendo relevante ressaltar que os valores de RF e SVM estão muito próximos, onde uma maior margem de diferenças entre as classes representou um melhor desempenho para o RF. Isto ocorre, pois, o KNN é um algoritmo de classificação que opera em uma amostra através de dados de rótulos vizinhos mais próximos no espaço de atributos, sendo um algoritmo mais sensível a ruídos e outliers (PRISCILA et al., 2023). Na vida real, muitos dos dados não são rotulados e rotular todos os dados é uma tarefa que demanda tempo e atenção, o que ocasiona ruídos nos dados, afetando o desempenho dos algoritmos de classificação (HAN *et al.*, 2023).

No que tange o RF que é um algoritmo “ensemble”, que constitui em um grupo de indivíduos (árvores de decisão) onde a classificação é feita baseada na maioria dos resultados dessas árvores (BREIMAN, 2001). Por fim, o SVM opera encontrando o hiperplano de separação ideal que maximiza a margem entre as classes no espaço dos atributos, isto é, ele pode ser estendido para problemas não lineares através do uso de funções de kernel que encontra a hiperplano de separação ideal que maximiza a margem entre as classes no espaço dos atributos. Pode ser estendido para problemas não lineares através do uso dos parâmetros de regularização e de funções de kernel (CHANDRA & BEDI, 2021).

Apesar de acurados, os algoritmos poderiam ter resultados ainda melhores, uma vez que a presença de ruídos atrapalha os algoritmos de classificação. Os dados do mundo real são frequentemente imperfeitos e contaminados por ruídos, o que pode comprometer a qualidade da classificação. A rotulagem desses dados é

uma tarefa que, além de ser dispendiosa e subjetiva, está sujeita a frequentes erros. Esses erros de rotulagem, combinados com o ruído inerente aos dados, podem ter vários impactos negativos, incluindo o risco de overfitting. Overfitting ocorre quando o modelo se ajusta excessivamente aos detalhes e anomalias nos dados ruidosos, o que prejudica sua capacidade de generalizar e prever com precisão em novos conjuntos de dados (FENG et al., 2023). Tais ruídos podem ser encontradas na imagem, podendo ter afetado negativamente o desempenho dos algoritmos, que teriam resultados ainda melhores, uma vez que houveram pixels sem dados, que necessitaram de preenchimento nas imagens, gerando ruídos, e que a rotulação as culturas invasoras, foi feita totalmente de forma remota, visto que há uma abrupta mudança na vegetação.

Similar ao aplicado no estudo, Rodriguez-Garlito & Paz-Gallardo (2021) aplicaram métodos de aprendizado de máquina para a classificação semiautomática de imagens multiespectrais de VANTs com um tamanho de pixel de 3 cm, onde o SVM e o RF se destacaram, com um melhor desempenho do RF, distinguindo eficientemente classes de cobertura do solo devido à alta resolução espacial da imagem. Ainda sobre o tema, um outro estudo aplicado por Guo et al. (2022) apresentou resultados similares aplicando RF para classificação de árvores em áreas urbanas, apresentando índice kappa acima de 0,9.

Apesar de muitos estudos, como os citados que aplicam algoritmos de aprendizagem de máquina para classificação de culturas com imagens de VANTs, também é possível fazer classificações baseadas em satélites, como no estudo proposto por Iqbal et al.(2023), que aplicou a ferramenta Dzetsaka, a mesma utilizada neste trabalho, para classificar imagens de satélites, onde apresentou melhores resultados com aplicações na constelação de satélites PlanetScope quando comparados a classificação de imagens com os produtos do sentinel-2, que possui mais bandas espectrais, estando esse melhor resultado associado a resolução espacial maior do PlanetScope, tendo imagens com pixels de 3 metros de comprimento, contra 10 metros do sentinel-2. A diferença da resolução nos

resultados é ainda mais evidente quando comparado aos resultados em VANTs.

Apesar de muitas similaridades com algumas ações encontradas na literatura, onde o estudo se diferencia com a aplicação da classificação para cultivo de palma forrageira no nordeste, que pode ser usada para alimentação animal, sendo uma ótima fonte de nutrientes, além de apresentar situações não demonstradas em diversos trabalhos, como na avaliação de crescimento de plantas invasoras ao longo do tempo, tendo seu crescimento associado a mudanças agroclimáticas na Caatinga. Os resultados são compatíveis com os obtidos por Andrade et al. (2024), que classificaram adequadamente a palma forrageira consorciada no semiárido de Pernambuco.

5. CONCLUSÃO

O monitoramento de áreas agrícolas é fundamental para a produtividade e manejo eficiente das culturas, sendo amplamente beneficiado por técnicas avançadas de sensoriamento remoto e análise de dados espectrais. A utilização de índices multiespectrais e dados provenientes de bandas visíveis RGB são meios de informação robustos para a classificação de diferentes tipos de culturas, auxiliando na investigação de uso e cobertura do solo.

A aplicação de algoritmos de aprendizado de máquina, como RF (Random Forest) e SVM (Support Vector Machine), mostrou-se especialmente eficaz para essa finalidade. Esses algoritmos têm a capacidade de manejar grandes volumes de dados complexos, identificando padrões e diferenças sutis entre as classes de cobertura do solo, no entanto, a precisão da classificação pode ser comprometida por ruídos nos dados e erros de rotulagem, desafios comuns em ambientes reais que impactam negativamente o desempenho dos algoritmos.

A classificação com imagens de banda de reflectância visível RGB para monitoramento agrícola mostrou-se eficaz, embora com algumas limitações em comparação com as imagens multiespectrais, a perda de desempenho é baixa, apresentando menos de 5% de diferença nas métricas de desempenho, o que é

justificável quando comparada com a economia gerada.

O estudo em questão diferencia-se ao focar na aplicação de técnicas de classificação de imagem para o cultivo de palma forrageira no nordeste brasileiro, uma cultura vital para a alimentação animal na região semiárida. Essa abordagem não só contribui para a literatura existente, mas também oferece insights valiosos para o manejo sustentável e eficiente das culturas em ambientes desafiadores, como a Caatinga, especialmente em face das mudanças climáticas.

6. AGRADECIMENTOS

Este projeto foi realizado com o apoio do CNPq (Projeto Universal processo 420.488/2018-9 e Projeto MAIDAI — Mestrado e Doutorado em Inovação, processo 403.488/2020-4, com contribuições financeiras da TPF Engenharia e Companhia Pernambucana de Saneamento-COMPESA para o reúso de águas residuais na agricultura), da FACEPE (Fundação de Amparo à Ciência e Tecnologia de Pernambuco) (processo APQ 0414-5.03/20 para o desenvolvimento da cadeia econômica pecuária no Estado de Pernambuco) e do Ministério da Integração e Desenvolvimento Regional (MIDR), coordenado pelo Instituto Nacional do Semiárido (INSA). As bolsas também foram apoiadas pela CAPES-Print/UFRPE. Além disso, o estudo recebeu apoio de fundos portugueses através da Fundação para a Ciência e a Tecnologia, I.P. (FCT), sob as concessões UIDB/04292/2020, atribuídas ao MARE, e LA/P/0069/2020, atribuídas ao Laboratório Associado ARNET.

7. REFERÊNCIAS

ABIOYE, E. A.; HENSEL, O.; ESAU, T. J.; ELIJAH, O.; ABIDIN, M. S. Z.; AYOBAMI, A. S.; YERIMA, O.; NASIRAHMADI, A. Precision Irrigation Management Using Machine Learning and Digital Farming Solutions. **AgriEngineering**, v. 4, n. 1, p. 70–103, 1 fev. 2022. DOI [10.3390/agriengineering4010006](https://doi.org/10.3390/agriengineering4010006). Disponível em: <https://www.mdpi.com/2624-7402/4/1/6>. Acesso em: 4 fev. 2024.

ALVES, C. P.; JARDIM, A. M. D. R. F.; ARAÚJO JÚNIOR, G. D. N.; SOUZA, L. S. B. D.; ARAÚJO, G. G. L. D.; SOUZA, C. A. A. D.; SALVADOR, K. R. D. S.; LEITE, R. M. C.; PINHEIRO, A. G.; SILVA, T. G. F. D. How to enhance the agronomic performance of cactus-sorghum intercropped system: planting configurations, density

and orientation. **Industrial Crops and Products**, v. 184, p. 115059, set. 2022. DOI [10.1016/j.indcrop.2022.115059](https://doi.org/10.1016/j.indcrop.2022.115059). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0926669022005428>. Acesso em: 21 dez. 2023.

ANDRADE, O. B. D.; MONTENEGRO, A. A. D. A.; SILVA NETO, M. A. D.; SOUSA, L. D. B. D.; ALMEIDA, T. A. B.; DE LIMA, J. L. M. P.; CARVALHO, A. A. D.; SILVA, M. V. D.; MEDEIROS, V. W. C. D.; SOARES, R. G. F.; SILVA, T. G. F. D.; VILAR, B. P. UAV-Based Classification of Intercropped Forage Cactus: A Comparison of RGB and Multispectral Sample Spaces Using Machine Learning in an Irrigated Area. **AgriEngineering**, v. 6, n. 1, p. 509–525, 23 fev. 2024. DOI [10.3390/agriengineering6010031](https://doi.org/10.3390/agriengineering6010031). Disponível em: <https://www.mdpi.com/2624-7402/6/1/31>. Acesso em: 28 jun. 2024.

ASADI, B.; SHAMSODDINI, A. Crop mapping through a hybrid machine learning and deep learning method. **Remote Sensing Applications: Society and Environment**, v. 33, p. 101090, jan. 2024. DOI [10.1016/j.rsase.2023.101090](https://doi.org/10.1016/j.rsase.2023.101090). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352938523001726>. Acesso em: 4 fev. 2024.

BADAGLIACCA, G.; MESSINA, G.; PRATICÒ, S.; LO PRESTI, E.; PREITI, G.; MONTI, M.; MODICA, G. Multispectral Vegetation Indices and Machine Learning Approaches for Durum Wheat (*Triticum durum* Desf.) Yield Prediction across Different Varieties. **AgriEngineering**, v. 5, n. 4, p. 2032–2048, 2 nov. 2023. DOI [10.3390/agriengineering5040125](https://doi.org/10.3390/agriengineering5040125). Disponível em: <https://www.mdpi.com/2624-7402/5/4/125>. Acesso em: 27 dez. 2023.

BALIEIRO, B. T. D. S.; VELOSO, G. A. Análise multitemporal da cobertura do solo da Terra Indígena Ituna-Itatá através da classificação supervisionada de imagens de satélites. **Revista Cerrados**, v. 20, n. 02, p. 261–282, 27 set. 2022. DOI [10.46551/rc24482692202227](https://doi.org/10.46551/rc24482692202227). Disponível em: <https://www.periodicos.unimontes.br/index.php/cerrados/article/view/5076>. Acesso em: 21 dez. 2023.

BHUYAN, B. P.; TOMAR, R.; SINGH, T. P.; CHERIF, A. R. Crop Type Prediction: A Statistical and Machine Learning Approach. **Sustainability**, v. 15, n. 1, p. 481, 28 dez. 2022. DOI [10.3390/su15010481](https://doi.org/10.3390/su15010481). Disponível em: <https://www.mdpi.com/2071-1050/15/1/481>. Acesso em: 4 fev. 2024.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324). Disponível em: <http://link.springer.com/10.1023/A:1010933404324>. Acesso em: 1 jul. 2024.

CARVALHO, A. A. D.; MONTENEGRO, A. A. D. A.; DE LIMA, J. L. M. P.; SILVA, T. G. F. D.; PEDROSA, E. M. R.; ALMEIDA, T. A. B. Coupling Water Resources and Agricultural Practices for Sorghum in a Semiarid Environment. **Water**, v. 13, n. 16, p. 2288, 21 ago. 2021. DOI [10.3390/w13162288](https://doi.org/10.3390/w13162288). Disponível em:

<https://www.mdpi.com/2073-4441/13/16/2288>. Acesso em: 21 dez. 2023.

CHAKRABORTY, S. K.; CHANDEL, N. S.; JAT, D.; TIWARI, M. K.; RAJWADE, Y. A.; SUBEESH, A. Deep learning approaches and interventions for futuristic engineering in agriculture. **Neural Computing and Applications**, v. 34, n. 23, p. 20539–20573, dez. 2022. DOI [10.1007/s00521-022-07744-x](https://doi.org/10.1007/s00521-022-07744-x). Disponível em: <https://link.springer.com/10.1007/s00521-022-07744-x>. Acesso em: 21 dez. 2023.

CHANDRA, M. A.; BEDI, S. S. Survey on SVM and their application in image classification. **International Journal of Information Technology**, v. 13, n. 5, p. 1–11, out. 2021. DOI [10.1007/s41870-017-0080-1](https://doi.org/10.1007/s41870-017-0080-1). Disponível em: <https://link.springer.com/10.1007/s41870-017-0080-1>. Acesso em: 1 jul. 2024.

DERICQUEBOURG, E.; HAFIANE, A.; CANALS, R. Generative-Model-Based Data Labeling for Deep Network Regression: Application to Seed Maturity Estimation from UAV Multispectral Images. **Remote Sensing**, v. 14, n. 20, p. 5238, 20 out. 2022. DOI [10.3390/rs14205238](https://doi.org/10.3390/rs14205238). Disponível em: <https://www.mdpi.com/2072-4292/14/20/5238>. Acesso em: 5 fev. 2024.

FAJRI, M.; PRIMAJAYA, A. Komparasi Teknik Hyperparameter Optimization pada SVM untuk Permasalahan Klasifikasi dengan Menggunakan Grid Search dan Random Search. **Journal of Applied Informatics and Computing**, v. 7, n. 1, p. 14–19, 30 jan. 2023. DOI [10.30871/jaic.v7i1.5004](https://doi.org/10.30871/jaic.v7i1.5004). Disponível em: <https://jurnal.polibatam.ac.id/index.php/JAIC/article/view/5004>. Acesso em: 26 jun. 2024.

FENG, W.; LONG, Y.; WANG, S.; QUAN, Y. A review of addressing class noise problems of remote sensing classification. **Journal of Systems Engineering and Electronics**, v. 34, n. 1, p. 36–46, fev. 2023. DOI [10.23919/JSEE.2023.000034](https://doi.org/10.23919/JSEE.2023.000034). Disponível em: <https://ieeexplore.ieee.org/document/10066216/>. Acesso em: 1 jul. 2024.

FITZ, P. R. Classificação de imagens de satélite e índices espectrais de vegetação: uma análise comparativa. **Geosul**, v. 35, n. 76, p. 171–188, 27 out. 2020. DOI [10.5007/2177-5230.2020v35n76p171](https://doi.org/10.5007/2177-5230.2020v35n76p171). Disponível em: <https://periodicos.ufsc.br/index.php/geosul/article/view/67414>. Acesso em: 21 dez. 2023.

FONTES JÚNIOR, R. V. D. P.; MONTENEGRO, A. A. D. A. Temporal dependence of potentiometric levels and groundwater salinity in alluvial aquifer upon rainfall and evapotranspiration. **RBRH**, v. 22, n. 0, 23 out. 2017. DOI [10.1590/2318-0331.0217170059](https://doi.org/10.1590/2318-0331.0217170059). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2318-03312017000100250&lng=en&tlng=en. Acesso em: 13 maio 2023.

GARCÍA, S.; GUIDO, A.; PEZZANI, F.; LATTANZI, F. A. Invasion strategies of *Cynodon dactylon*: Competitive ability under low-nutrient conditions. **Austral**

Ecology, v. 48, n. 6, p. 1107–1120, set. 2023. DOI [10.1111/aec.13341](https://doi.org/10.1111/aec.13341). Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/aec.13341>. Acesso em: 1 jul. 2024.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random Forests for land cover classification. **Pattern Recognition Letters**, v. 27, n. 4, p. 294–300, mar. 2006. DOI [10.1016/j.patrec.2005.08.011](https://doi.org/10.1016/j.patrec.2005.08.011). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0167865505002242>. Acesso em: 21 dez. 2023.

GUAN, H.; HUANG, J.; LI, L.; LI, X.; MIAO, S.; SU, W.; MA, Y.; NIU, Q.; HUANG, H. Improved Gaussian mixture model to map the flooded crops of VV and VH polarization data. **Remote Sensing of Environment**, v. 295, p. 113714, set. 2023. DOI [10.1016/j.rse.2023.113714](https://doi.org/10.1016/j.rse.2023.113714). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425723002651>. Acesso em: 1 jul. 2024.

GUO, Q.; ZHANG, J.; GUO, S.; YE, Z.; DENG, H.; HOU, X.; ZHANG, H. Urban Tree Classification Based on Object-Oriented Approach and Random Forest Algorithm Using Unmanned Aerial Vehicle (UAV) Multispectral Imagery. **Remote Sensing**, v. 14, n. 16, p. 3885, 11 ago. 2022. DOI [10.3390/rs14163885](https://doi.org/10.3390/rs14163885). Disponível em: <https://www.mdpi.com/2072-4292/14/16/3885>. Acesso em: 1 jul. 2024.

HAN, M.; WU, H.; CHEN, Z.; LI, M.; ZHANG, X. A survey of multi-label classification based on supervised and semi-supervised learning. **International Journal of Machine Learning and Cybernetics**, v. 14, n. 3, p. 697–724, mar. 2023. DOI [10.1007/s13042-022-01658-9](https://doi.org/10.1007/s13042-022-01658-9). Disponível em: <https://link.springer.com/10.1007/s13042-022-01658-9>. Acesso em: 7 ago. 2024.

IQBAL, I. M.; BALZTER, H.; FIRDAUS-E-BAREEN; SHABBIR, A. Mapping Lantana camara and Leucaena leucocephala in Protected Areas of Pakistan: A Geo-Spatial Approach. **Remote Sensing**, v. 15, n. 4, p. 1020, 12 fev. 2023. DOI [10.3390/rs15041020](https://doi.org/10.3390/rs15041020). Disponível em: <https://www.mdpi.com/2072-4292/15/4/1020>. Acesso em: 21 dez. 2023.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159, mar. 1977. DOI [10.2307/2529310](https://doi.org/10.2307/2529310). Disponível em: <https://www.jstor.org/stable/2529310?origin=crossref>. Acesso em: 21 dez. 2023.

LE, T. S.; HARPER, R.; DELL, B. Application of Remote Sensing in Detecting and Monitoring Water Stress in Forests. **Remote Sensing**, v. 15, n. 13, p. 3360, 30 jun. 2023. DOI [10.3390/rs15133360](https://doi.org/10.3390/rs15133360). Disponível em: <https://www.mdpi.com/2072-4292/15/13/3360>. Acesso em: 1 jul. 2024.

LOURENÇO, V. R.; MONTENEGRO, A. A. D. A.; CARVALHO, A. A. D.; SOUSA, L. D. B. D.; ALMEIDA, T. A. B.; ALMEIDA, T. F. S. D.; VILAR, B. P. Spatial variability of

biophysical multispectral indexes under heterogeneity and anisotropy for precision monitoring. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 27, n. 11, p. 848–857, nov. 2023. DOI [10.1590/1807-1929/agriambi.v27n11p848-857](https://doi.org/10.1590/1807-1929/agriambi.v27n11p848-857). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662023001100848&tlng=en. Acesso em: 21 dez. 2023.

MAINARDIS, M.; CECCONET, D.; MORETTI, A.; CALLEGARI, A.; GOI, D.; FREGUIA, S.; CAPODAGLIO, A. G. Wastewater fertigation in agriculture: Issues and opportunities for improved water management and circular economy. **Environmental Pollution**, v. 296, p. 118755, mar. 2022. DOI [10.1016/j.envpol.2021.118755](https://doi.org/10.1016/j.envpol.2021.118755). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S026974912102337X>. Acesso em: 21 dez. 2023.

MONTENEGRO, A. A. A.; ABRANTES, J. R. C. B.; DE LIMA, J. L. M. P.; SINGH, V. P.; SANTOS, T. E. M. Impact of mulching on soil and water dynamics under intermittent simulated rainfall. **CATENA**, v. 109, p. 139–149, out. 2013. DOI [10.1016/j.catena.2013.03.018](https://doi.org/10.1016/j.catena.2013.03.018). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0341816213000866>. Acesso em: 1 jul. 2024.

MUCHERINO, A.; PAPAORGJI, P. J.; PARDALOS, P. M. k-Nearest Neighbor Classification. *In*: MUCHERINO, A.; PAPAORGJI, P. J.; PARDALOS, P. M. **Data Mining in Agriculture**. Springer Optimization and Its Applications. New York, NY: Springer New York, 2009. v. 34, p. 83–106. DOI [10.1007/978-0-387-88615-2_4](https://doi.org/10.1007/978-0-387-88615-2_4). Disponível em: http://link.springer.com/10.1007/978-0-387-88615-2_4. Acesso em: 21 dez. 2023.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, n. 1, p. 217–222, jan. 2005. DOI [10.1080/01431160412331269698](https://doi.org/10.1080/01431160412331269698). Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431160412331269698>. Acesso em: 21 dez. 2023.

PALLATHADKA, H.; MUSTAFA, M.; SANCHEZ, D. T.; SEKHAR SAJJA, G.; GOUR, S.; NAVED, M. Impact of machine learning on management, healthcare, and agriculture. **Materials Today: Proceedings**, v. 80, p. 2803–2806, 2023. DOI [10.1016/j.matpr.2021.07.042](https://doi.org/10.1016/j.matpr.2021.07.042). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S221478532104894X>. Acesso em: 21 dez. 2023.

PENG, Z.-R.; WANG, D.; WANG, Z.; GAO, Y.; LU, S. A study of vertical distribution patterns of PM_{2.5} concentrations based on ambient monitoring with unmanned aerial vehicles: A case in Hangzhou, China. **Atmospheric Environment**, v. 123, p. 357–369, dez. 2015. DOI [10.1016/j.atmosenv.2015.10.074](https://doi.org/10.1016/j.atmosenv.2015.10.074). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1352231015304908>. Acesso em: 21 dez. 2023.

POHL, S. C.; LENZ, D. M. Utilização de efluente tratado em complexo industrial automotivo. **Engenharia Sanitaria e Ambiental**, v. 22, n. 3, p. 551–562, maio 2017. DOI [10.1590/s1413-41522016122371](https://doi.org/10.1590/s1413-41522016122371). Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-41522017000300551&lng=pt&tlng=pt. Acesso em: 21 dez. 2023.

PRISCILA, S. S.; RAJEST, S. S.; REGIN, R. Classification of Satellite Photographs Utilizing the K-Nearest Neighbor Algorithm. v. 04, n. 06, 2023. .

REYNOLDS, D. A. **Gaussian Mixture Models**. *Encycl. Biom.*: [s. n.], 2009(741).

RODRIGUEZ-GARLITO, E. C.; PAZ-GALLARDO, A. Efficiently Mapping Large Areas of Olive Trees Using Drones in Extremadura, Spain. **IEEE Journal on Miniaturization for Air and Space Systems**, v. 2, n. 3, p. 148–156, set. 2021. DOI [10.1109/JMASS.2021.3067102](https://doi.org/10.1109/JMASS.2021.3067102). Disponível em: <https://ieeexplore.ieee.org/document/9381404/>. Acesso em: 1 jul. 2024.

ROY, A.; CHAKRABORTY, S. Support vector machine in structural reliability analysis: A review. **Reliability Engineering & System Safety**, v. 233, p. 109126, maio 2023. DOI [10.1016/j.ress.2023.109126](https://doi.org/10.1016/j.ress.2023.109126). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0951832023000418>. Acesso em: 26 jun. 2024.

SANTANA, D. C.; THEODORO, G. D. F.; GAVA, R.; DE OLIVEIRA, J. L. G.; TEODORO, L. P. R.; DE OLIVEIRA, I. C.; BAIIO, F. H. R.; DA SILVA JUNIOR, C. A.; DE OLIVEIRA, J. T.; TEODORO, P. E. A New Approach to Identifying Sorghum Hybrids Using UAV Imagery Using Multispectral Signature and Machine Learning. **Algorithms**, v. 17, n. 1, p. 23, 5 jan. 2024. DOI [10.3390/a17010023](https://doi.org/10.3390/a17010023). Disponível em: <https://www.mdpi.com/1999-4893/17/1/23>. Acesso em: 4 fev. 2024.

SARMA, A. S.; NIDAMANURI, R. R. Transfer Learning for Plant-level Crop Classification using Drone-based Hyperspectral Imagery. *In: 2023 INTERNATIONAL CONFERENCE ON MACHINE INTELLIGENCE FOR GEOANALYTICS AND REMOTE SENSING (MIGARS)*, 27 jan. 2023. **2023 International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing (MIGARS) [...]**. Hyderabad, India: IEEE, 27 jan. 2023. p. 1–4. DOI [10.1109/MIGARS57353.2023.10064501](https://doi.org/10.1109/MIGARS57353.2023.10064501). Disponível em: <https://ieeexplore.ieee.org/document/10064501/>. Acesso em: 21 dez. 2023.

SHANMUGAPRIYA, P.; RATHIKA, S.; RAMESH, T.; JANAKI, P. Applications of Remote Sensing in Agriculture - A Review. **International Journal of Current Microbiology and Applied Sciences**, v. 8, n. 01, p. 2270–2283, 20 jan. 2019. DOI [10.20546/ijcmas.2019.801.238](https://doi.org/10.20546/ijcmas.2019.801.238). Disponível em: <https://www.ijcmas.com/abstractview.php?ID=11625&vol=8-1-2019&SNo=238>. Acesso em: 21 dez. 2023.

SILVA NETO, M. A. D.; JESUS, J. E. G. D.; MONTENEGRO, A. A. D. A.; SOUSA, L.

D. B. D.; LINS, F. A. C.; CHAGAS, A. M. S. D. Parâmetros biofísicos como instrumento analítico de degradação do solo em bacia experimental do semiárido pernambucano. **Agrometeoros**, v. 30, 5 jul. 2022. DOI [10.31062/agrom.v30.e026989](https://doi.org/10.31062/agrom.v30.e026989). Disponível em: <https://seer.sct.embrapa.br/index.php/agrometeoros/article/view/26989>. Acesso em: 1 jul. 2024.

STARK, D. J.; VAUGHAN, I. P.; EVANS, L. J.; KLER, H.; GOOSSENS, B. Combining drones and satellite tracking as an effective tool for informing policy change in riparian habitats: a proboscis monkey case study. **Remote Sensing in Ecology and Conservation**, v. 4, n. 1, p. 44–52, mar. 2018. DOI [10.1002/rse2.51](https://doi.org/10.1002/rse2.51). Disponível em: <https://zslpublications.onlinelibrary.wiley.com/doi/10.1002/rse2.51>. Acesso em: 21 dez. 2023.

WANG, L.; WANG, J.; LIU, Z.; ZHU, J.; QIN, F. Evaluation of a deep-learning model for multispectral remote sensing of land use and crop classification. **The Crop Journal**, v. 10, n. 5, p. 1435–1451, out. 2022. DOI [10.1016/j.cj.2022.01.009](https://doi.org/10.1016/j.cj.2022.01.009). Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2214514122000411>. Acesso em: 1 jul. 2024.

YADAV, J.; CHAUHAN, U.; SHARMA, D. Importance of Drone Technology in Indian Agriculture, Farming: *In*: KHAN, M. A.; GUPTA, B.; VERMA, A. R.; PRAVEEN, P.; PEOPLES, C. J. (orgs.). **Advances in Electronic Government, Digital Divide, and Regional Development**. [S. l.]: IGI Global, 2023. p. 35–46. DOI [10.4018/978-1-6684-6418-2.ch003](https://doi.org/10.4018/978-1-6684-6418-2.ch003). Disponível em: <https://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/978-1-6684-6418-2.ch003>. Acesso em: 21 dez. 2023.

CAPÍTULO IV

CONSIDERAÇÕES FINAIS

Neste estudo foram obtidos resultados importantes no que tange à aplicação do sensoriamento remoto em monitoramento de área irrigada com água de reúso, o que é um avanço importante no manejo dos recursos hídricos, com ações que visam promover a segurança hídrica no semiárido.

As aplicações com imagens RGB em VANTs são elemento extremamente necessários para o avanço da agricultura no semiárido, uma vez que diminuem significativamente os custos necessários, chegando a diminuir dezenas de milhar de reais investido. A elaboração de um índice de vegetação RGB (aNDVI) sensível as características da vegetação e de reflectâncias no semiárido, podendo ser aplicado facilmente em plataformas como o QGIS que é um software livre de sistema de informação geográfica. Os avanços obtidos com os produtos gerados são bem vindos tanto para a comunidade local, como para as empresas parceiras, que conseguirão aplicar as tecnologias desenvolvidas e aprimoradas em trabalhos futuros, podendo contribuir para a expansão e sustentabilidade agrícola, onde apesar de ter sido aplicado para o cultivo de palma forrageiras, índices podem ser desenvolvidos aplicando a mesma metodologia, para monitoramento ambiental, ajustando dados de reflectância a culturas nativas e até mesmo no monitoramento de matas ciliares, visando a manutenção das bacias hidrográficas.

O produto de classificação também indicou bons direcionamentos para classificação de culturas e detecção de invasoras, aplicando algoritmos de aprendizagem de máquina para automatizar trabalhos, através de uma plugin facilitador via QGIS, onde pode-se alterar os códigos do plugin, ou extrair dados para aplicação em Python para um usuário mais avançado.

O algoritmo Random Forest apresentou resultados sólidos, tendo menor custo

computacional significativamente que o Support Vector Machine, que teve resultados tão bons quanto, sendo o Random Forest menos susceptível a ruídos, melhor adaptável para o uso com VANTs com câmeras de menor qualidade.

A área de estudo é uma área irrigada, portanto, tendo maior disponibilidade hídrica para as culturas, que o resto da região, o que impacta tanto na classificação das culturas, quanto na produção do índice, visto que ambos utilizaram como base, dados desta área, porém, o que não inviabiliza o uso das ferramentas para cultivo em sequeiro, uma vez que ambos os produtos também tiveram bons resultados na classificação e nos valores estimados de leituras envolvendo o solo.

Alguns aspectos desse estudo podem indicar um rumo para pesquisas futuras, principalmente no desenvolvimento de índices mais acurados e de métodos de classificação mais acurados, visando a viabilização total de imagens RGB na agricultura de precisão de baixo custo.