

CLASSIFICAÇÃO EM ÁREAS DE MANDIOCA COM TÉCNICAS DE APRENDIZAGEM PROFUNDA EM IMAGEM OBTIDAS COM SISTEMAS DE AERONAVES PILOTADAS REMOTAMENTE

Alexis Fernández- Sarabia¹

Soltan Galano-Duverger²

Taimy Cantillo-Perez³

Washington Franca-Rocha⁴

RESUMO

A mandioca, amplamente cultivada no Brasil, exige monitoramento constante para garantir seu desenvolvimento, especialmente em grandes áreas onde métodos tradicionais se tornam ineficientes. Este estudo propõe uma abordagem alternativa baseada em inteligência artificial aplicada ao geoprocessamento de imagens multispectrais e RGB obtidas por RPAS. A pesquisa foi realizada na EMBRAPA Mandioca e Fruticultura (Cruz das Almas, BA), utilizando dados do drone DJI Phantom 4 Pro e do sensor Parrot Sequoia. As imagens foram pré-processadas no Agisoft Metashape e analisadas nas plataformas Google Earth Engine e Google Colab. Foram testados os algoritmos Random Forest Support Vector Machine, Gradient Tree Boosting e Redes Neurais Artificiais para classificar quatro classes espectrais: plantas cultivadas, solo exposto, plantas daninhas e sombra. Os resultados evidenciam o potencial dessas técnicas para aprimorar o monitoramento automatizado da cultura da mandioca, permitindo a detecção precoce de anomalias e decisões agronômicas mais eficientes.

PALAVRAS CHAVES: Sensoriamento remoto; Processamento Digital de Imagens; Índice espectral; Inteligência artificial; Agricultura de precisão.

CLASSIFICATION OF CASSAVA FIELDS USING DEEP LEARNING TECHNIQUES ON IMAGES OBTAINED WITH REMOTELY PILOTED AIRCRAFT SYSTEMS

ABSTRACT

Cassava, widely cultivated in Brazil, requires constant monitoring to ensure its development, especially in large areas where traditional methods become inefficient. This study proposes an alternative approach based on artificial intelligence applied to the geoprocessing of multispectral and RGB images obtained by RPAS. The research was conducted at EMBRAPA

¹Mestre em Geomática, Universidade Estadual de Feira de Santana - UEFS, Feria de Santana, BA, Email: alexis30fdz@gmail.com

²Mestre em Modelagem em Ciências Ambientais, Geodatin-Inteligência em Dados e Geoinformação, Feria de Santana, BA Email: solkan1201@gmail.com

³Doutora em Ciências em Botânica, Universidade Estadual de Feira de Santana - UEFS, Feria de Santana, BA, Email: taycantillo@gmail.com

⁴Doutor em Geologia, Universidade Estadual de Feira de Santana - UEFS, Feria de Santana, BA, Email: twrocha@uefs.br

Cassava and Fruit Crops (Cruz das Almas, BA), using data from the DJI Phantom 4 Pro drone and the Parrot Sequoia sensor. The images were pre-processed in Agisoft Metashape and analyzed on the GoogleEarth Engine and Google Colab platforms. Random Forest Support Vector Machine, Gradient Tree Boosting and Artificial Neural Networks algorithms were tested to classify four spectral classes: cultivated plants, exposed soil, weeds, and shade. The results highlight the potential of these techniques to improve automated monitoring of cassava cultivation, enabling early detection of anomalies and more efficient agronomic decisions.

KEYWORDS: Remote Sensing; Digital Image Processing; Spectral Index; Artificial Intelligence; Precision Agriculture.

CLASIFICACIÓN DE ÁREAS DE YUCA CON TÉCNICAS DE APRENDIZAJE PROFUNDO EN IMÁGENES OBTENIDAS CON SISTEMAS DE AERONAVES PILOTADAS REMOTAMENTE

RESUMEN

La yuca es cultivada en todos los estados de Brasil, requiere un seguimiento constante para garantizar su desarrollo, especialmente en grandes áreas donde los métodos tradicionales se vuelven ineficientes. Este estudio propone un enfoque alternativo basado en inteligencia artificial aplicada al geoprocесamiento de imágenes multiespectrales y RGB obtenidas por RPAS. La investigación se llevó a cabo en la Empresa EMBRAPA Mandioca e Fruticultura (Cruz das Almas, BA), utilizando datos obtenidos con DJI Phantom 4 Pro y del sensor Parrot Sequoia. Las imágenes fueron pre-procesadas en Agisoft Metashape y analizadas en las plataformas *Google Earth Engine* y *Google Colab*. *Random Forest*, *Support Vector Machine*, *Gradient Tree Boosting* e *Redes Neurales Artificiales* se probaron para clasificar cuatro clases espectrales: plantas cultivadas, suelo expuesto, maleza y sombra. Los resultados muestran el potencial de estas técnicas para mejorar el monitoreo del cultivo de mandioca, permitiendo la detección temprana de anomalías y detección precoz de anomalías y decisiones agronómicas más eficientes.

PALABRAS-CLAVES: Teledetección, Procesamiento Digital de Imágenes; Índice espectral; Inteligencia Artificial; Agricultura de precisión.

INTRODUÇÃO

A agricultura de precisão desporta como um paradigma tecnológico essencial para enfrentar os desafios contemporâneos relacionados à segurança alimentar, à sustentabilidade agrícola e à crescente demanda global por alimentos. Estima-se que, até 2050, será necessário alimentar mais de 10 bilhões de pessoas, o que exigirá um aumento significativo na produtividade agrícola, estimado entre 35% e 56% em relação aos níveis de 2013 (FAO, 2017; Van Dijk et al., 2021). Nesse cenário, torna-se urgente o desenvolvimento de estratégias

eficientes para o monitoramento e manejo das culturas, especialmente frente às limitações impostas por pragas, doenças, plantas daninhas e estresses ambientais (Fried et al., 2017).

Entre as culturas de relevância global, a mandioca (*Manihot esculenta Crantz*) destaca-se como fonte primária de carboidratos para mais de 800 milhões de pessoas, sobretudo em regiões tropicais em desenvolvimento. No Brasil, ocupa posição de destaque entre os principais produtos agrícolas, sendo amplamente utilizada na agroindústria e na alimentação humana e animal (IBGE, 2017; Oyewole, Ogundele, 2001). Apesar de sua rusticidade, a mandioca é suscetível a diversos fatores limitantes, o que demanda monitoramento assertivo para garantir sua produtividade (Siviero, Tremacoldi, 2011).

Tradicionalmente, o acompanhamento do desenvolvimento das lavouras tem dependido de inspeções visuais *in situ*, métodos que, além de laboriosos e subjetivos, são limitados em escala temporal e espacial. O advento do sensoriamento remoto, especialmente por meio de RPAS equipados com sensores RGB e multiespectrais, revolucionou essa abordagem, oferecendo imagens de alta resolução espacial e temporal a baixo custo (Han et al., 2022; Bouguettaya et al., 2021). Essas tecnologias permitem a observação detalhada do estado nutricional e fitossanitário das culturas, favorecendo a aplicação localizada de insumos e a tomada de decisões mais precisas (Hunt, Daughtry, 2018; Santos et al., 2022).

No entanto, a transformação dos dados espectrais em informação açãoável exige métodos computacionais avançados, capazes de decodificar padrões complexos associados aos diferentes componentes agrícolas. Nesse contexto, os algoritmos de aprendizado de máquina surgem como ferramentas promissoras para a classificação automatizada de elementos como plantas cultivadas, solo exposto e plantas daninhas componentes críticos para o manejo eficiente das lavouras.

Entre os algoritmos mais utilizados, destacam-se o Support Vector Machine (SVM), conhecido por sua capacidade de lidar com conjuntos de dados de alta dimensionalidade e margens de separação bem definidas; o Random Forest (RF), que utiliza múltiplas árvores de decisão para melhorar a precisão e reduzir o risco de overfitting; o Gradient Tree Boosting, técnica ensemble que combina árvores fracas para formar um preditor robusto; e as Redes

Neurais Artificiais, que oferecem arquiteturas profundas capazes de aprender representações hierárquicas complexas a partir de dados multiespectrais.

Apesar dos avanços, ainda há escassez de estudos comparativos sistemáticos que avaliem o desempenho relativo desses algoritmos no contexto específico dos cultivos de mandioca, cuja arquitetura foliar, ciclo fenológico e assinatura espectral exigem abordagens customizadas de classificação. Além disso, a discriminação de plantas daninhas em meio ao dossel cultural representa um desafio técnico relevante, devido à sobreposição espectral entre espécies e à variabilidade sazonal dos alvos de interesse. A precisão nessa distinção impacta diretamente a eficiência do controle fitossanitário, a redução de insumos agrícolas e a maximização da produtividade.

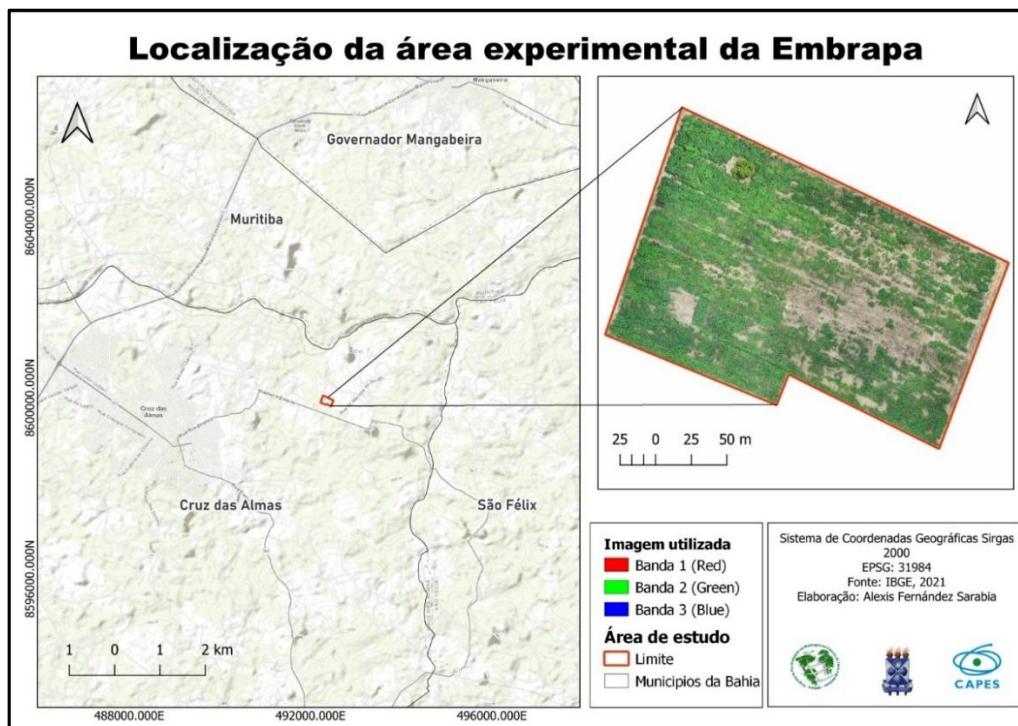
Diante desse contexto, este estudo tem como objetivo avaliar comparativamente a eficácia de diferentes algoritmos de *Machine learning Random Forest, Support Vector Machine, Gradient Tree Boosting* e Redes Neurais Artificiais (Deep Learning) na classificação espectral de componentes agrícolas em cultivos de mandioca. O foco principal está na discriminação entre plantas cultivadas, solo exposto e plantas daninhas. A análise contempla não apenas métricas de acurácia, mas também aspectos relacionados à robustez operacional, eficiência computacional e capacidade de generalização em diferentes contextos espaciais e temporais.

A relevância desta pesquisa transcende o âmbito acadêmico, oferecendo subsídios técnicos para: Desenvolvimento de sistemas automáticos de alerta precoce para infestações de plantas daninhas; Otimização de práticas de manejo integrado em agricultura de precisão. Ao integrar técnicas de aprendizado de máquina de última geração com dados espetrais obtidos por RPAS, este trabalho busca contribuir para a transição paradigmática rumo a sistemas agrícolas mais eficientes, sustentáveis e resilientes.

MATERIAIS E MÉTODOS

Os trabalhos foram realizados na estação experimental da EMBRAPA Mandioca e Fruticultura, localizada no município de Cruz das Almas, Bahia, Brasil ($12^{\circ}39'25,462''$ S; $39^{\circ}05'43,485''$ W), Figura 1.

**Figura 1. Área de estudo, áreas cultivo estação experimental da Embrapa
Mandioca e Fruticultura, Cruz das Almas, Bahia**



Fontes: Elaborado autores 2025

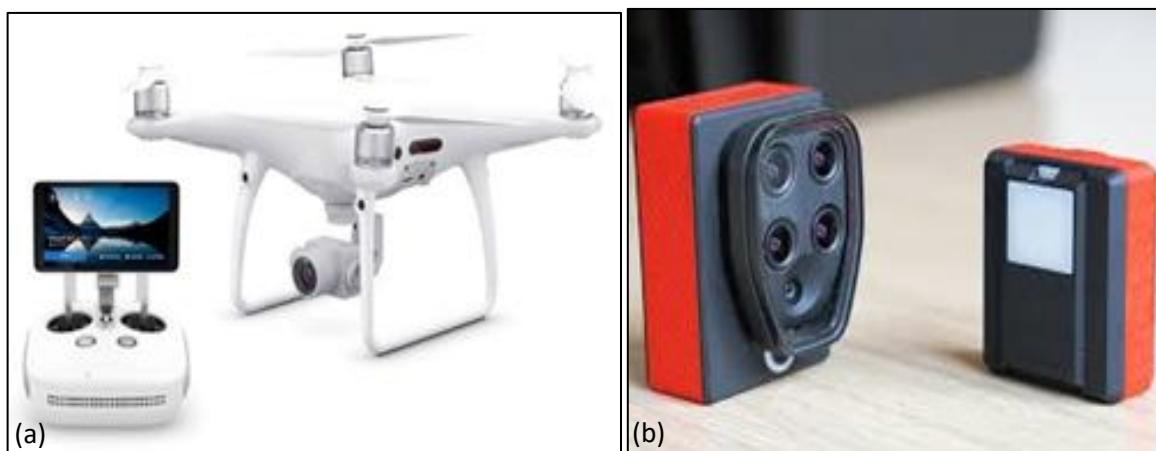
Inicialmente, foi efetuado um levantamento aéreo com um RPAS de asa rotativa, modelo *DJI Phantom 4 Pro*, Figura 2a, equipado com uma câmera RGB com distância focal de 5,74 mm e resolução de 12 MP. Adicionalmente, foi acoplada ao drone uma câmera multiespectral *Parrot Sequoia*, composta pelas bandas *Green*, *Red*, *Red-edge* e *NIR* Figura 2b, totalizando um peso de aproximadamente 1460 g. O drone utilizado na pesquisa possui registro no Sistema de Aeronaves Não Tripuladas (SISANT) da Agência Nacional de Aviação Civil-ANAC, o número de cadastro PP355316018. Ressalta-se que o piloto responsável pelo voo também está devidamente registrado no SISANT, conforme exigido pela regulamentação brasileira. De acordo com as normas da ANAC, voos realizados fora de zonas de restrição e que não ultrapassem a altitude de 400 pés não necessitam de autorização específica emitida pela agência.

O planejamento da missão aérea foi realizado por meio do aplicativo DJI GS Pro (v2.0.17), levando em consideração as condições meteorológicas e de iluminação ideais para a

aquisição de imagens de alta qualidade. Foram observadas as condições de vento, que se mantiveram dentro dos limites operacionais seguros para o RPAS, garantindo a estabilidade da aeronave e evitando distorções nas imagens durante o voo.

A operação foi executada a uma altura de 40 metros acima do nível do solo, com velocidade constante de 4 m/s, cobrindo uma área total de 9,14 hectares. A missão foi iniciada por volta das 11h00, horário estrategicamente escolhido para assegurar iluminação solar adequada, minimizando a formação de sombras e otimizando a resposta espectral dos alvos. Foram configuradas sobreposições de 80% na direção transversal e 70% na longitudinal, visando garantir a qualidade dos ortomosaicos e a precisão na reconstrução tridimensional da área.

Figura 2. Imagem do RPAS e Sensor *Parrot Sequoia* utilizados.



Fonte: www.dji.com e www.parrot.com

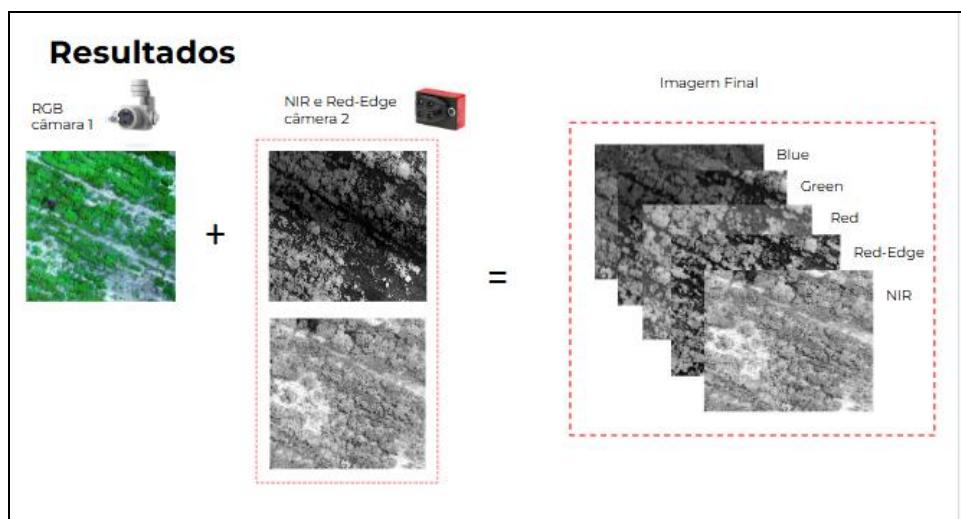
Foram coletadas cerca de 511 imagens RGB, com GSD de 1,2 cm/px e 4688 imagens provenientes da câmera multiespectral *Parrot Sequoia*, abrangendo as bandas *Green* (550 nm), *Red* (660 nm), *Red-edge* (735 nm) e *NIR* (790 nm) para um GSD de 4,157 cm/px.

Posteriormente, as imagens foram processadas no software Agisoft Metashape, resultando na geração de produtos geoespaciais como a nuvem de pontos, o Modelo Digital de Elevação (MDE), o Modelo Digital do Terreno (MDT) e os respectivos ortomosaicos. Foram gerados ortomosaicos específicos para as bandas *NIR*, *Green*, *Red* e *Red-edge*, captadas pela

câmera multiespectral Parrot Sequoia, bem como o ortomosaico correspondente à câmera RGB embarcada no drone Phantom, Figura 3.

Todos os mosaicos foram posteriormente exportados para a plataforma Google Earth Engine, onde foram utilizados para o cálculo dos índices espectrais. Para isso, as bandas foram combinadas, integrando as imagens RGB do Phantom com as bandas Green, Red, Red-edge e NIR da Parrot Sequoia.

Figura 3. Imagem do RPAS e Sensor Parrot Sequoia utilizados.



Fonte: Elaborado autores 2025

Índices espectrais de Vegetação

Para o cálculo dos índices espectrais, foi utilizada a biblioteca eemont, desenvolvida em Python por Montero (2021). Esse pacote estende a API do Google Earth Engine, oferecendo funcionalidades avançadas para o pré-processamento e análise de imagens de satélite, especialmente de plataformas como Landsat, Sentinel e MODIS. A biblioteca eemont incorpora métodos utilitários que simplificam tarefas como: aplicação de correções atmosféricas, cálculo de índices espectrais (NDVI, EVI, SAVI, entre outros), manipulação de máscaras de nuvens e sombras, além da integração com bibliotecas como pandas e matplotlib para análise estatística e visualização gráfica.

Para otimizar o desempenho dos modelos de classificação, aplicou-se a técnica de Eliminação Recursiva de Variáveis com Validação Cruzada (RFECV), permitindo selecionar as variáveis mais relevantes, reduzir a dimensionalidade e evitar overfitting (de Villiers et al., 2024).

Durante o processo, o atributo ranking_ foi utilizado para avaliar a importância relativa de cada variável. As variáveis com ranking igual a 1 foram consideradas as mais relevantes e mantidas no modelo final, enquanto aquelas com valores superiores foram descartadas por apresentarem menor contribuição preditiva. Essa seleção automatizada favorece a construção de modelos mais robustos, interpretáveis e eficientes, especialmente em contextos com grande volume de dados espectrais.

Os índices de vegetação desempenham um papel fundamental na quantificação de indicadores de saúde vegetal, incluindo atividade fotossintética, presença de clorofila, biomassa e propriedades do solo (Brewer et al 2022; Burns et al.,2022; Xiao et al 2013, Li, Z.; Chen, Z, 2011; Ballesteros et al 2021). Sua aplicação se estende à avaliação de atributos-chave de crescimento e rendimentos potenciais da cultura. Neste estudo, foram explorados 12 índices de vegetação amplamente utilizados na caracterização da vegetação descritos na tabela 1.

Tabela 1. Descrição dos índices de vegetação selecionados.

Indice	Bandas	Formula	Referencias
Índice de Vegetação Avançado (AVI)	('N', 'R')	(N * (1.0 - R) * (N - R)) ** (1/3)	Montero (2021)
BITM	('B', 'G', 'R')	(((B**2.0)+(G**2.0)+(R**2.0))/3.0)**0.5	Montero (2021)
Índice de Vegetação da Clorofila (CVI)	('N', 'R', 'G')	(N * R) / (G ** 2.0)	Colla et al., 2024
Índice de excesso de vermelho (ExR)	('R', 'G')	1.4 * R - G	Fernandes et al., 2022

Índice de Vegetação por Diferença Normalizada Verde-Azul (GBNDVI)	('N', 'G', 'B')	$(N - (G + B)) / (N + (G + B))$	Moges et al., 2005
Índice de vegetação por diferença normalizada (NDVI)	('N', 'R')	$(NIR - RED) / (NIR + RED)$	Marion et al., 2021
Índice de Água por Diferença Normalizada (NDWI)	('G', 'N')	$(G - N) / (G + N)$	Rodrigues et al., 2017
Índice de estrutura (SI)	('B', 'G', 'R')	$((1.0 - B) * (1.0 - G) * (1.0 - R)) ^{**} (1/3)$	Montero (2021)
Proporção Simples (SR)	('N', 'R')	N/R	Montero (2021)
Índice de Vegetação por Diferença Transformada (TDVI)	('N', 'R')	$1.5 * ((N - R) / (N ^{**} 2.0 + R + 0.5) ^{**} 0.5))$	Barros et al., 2020
Índice de Vegetação Aprimorado 2 (EVI2)	('g', 'N', 'R', 'L')	$g * (N - R) / (N + 2.4 * R + L)$	Villela (2019)
Índice de Vegetação Ajustado ao Solo Otimizado (OSAVI)	('N', 'R')	$(N - R) / (N + R + 0.16)$	Neves et al., 2025

Algoritmos de Aprendizado de Máquina

Foram selecionados três algoritmos de aprendizado de máquina para este estudo: *Random Forest* (RF), *Gradient Tree Boosting* (GTB) e *Super Vector Machine* (SVM). Esses algoritmos foram implementados em Python utilizando suas respectivas bibliotecas. A otimização de hiperparâmetros foi realizada para determinar os melhores parâmetros para cada modelo.

A regressão RF é um algoritmo de aprendizado de máquina supervisionado disponível para a previsão de dados contínuos. Para melhorar a precisão, o RF cria uma floresta de árvores

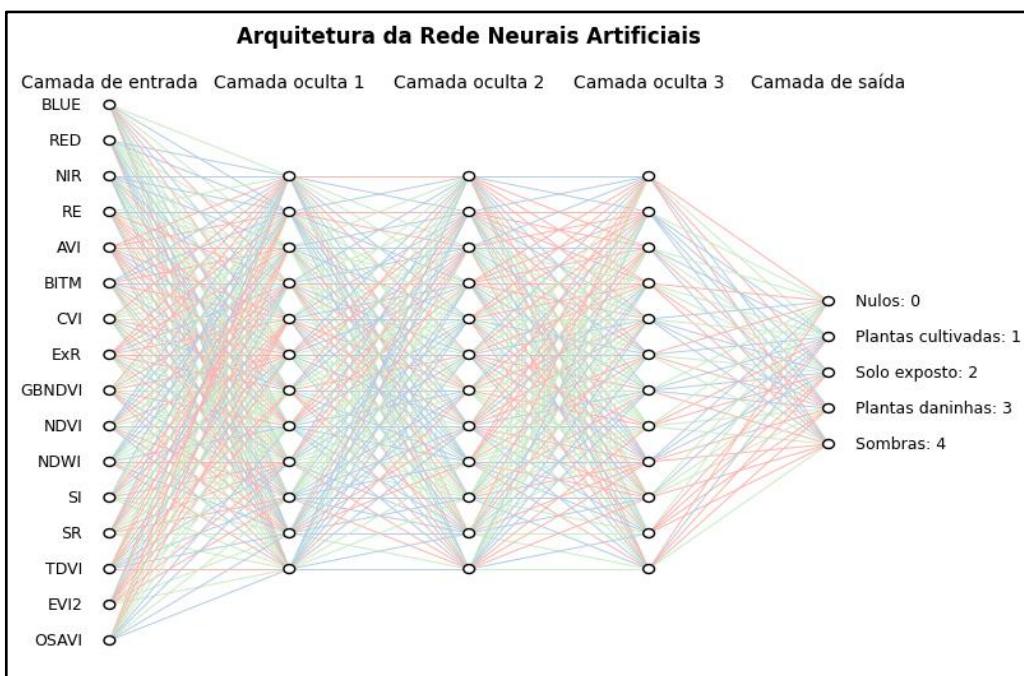
de decisão usando um subconjunto aleatório de dados de treinamento. Cada árvore consiste em uma previsão que é usada para criar uma previsão final com base nos valores médios de todas as previsões das árvores individuais (Breiman, 2001; Pedregosa et al., 2011)

O algoritmo de regressão Gradiente Boosting é uma técnica de aprendizado conjunto que cria modelos preditivos (Pedregosa et al., 2011 Ke et al., 2017). Árvores de decisão são criadas usando um procedimento iterativo que começa com aprendizes fracos. O objetivo é criar aprendizes fortes reduzindo os pseudo-valores residuais (a diferença entre os valores observados e previstos). Cada árvore é adicionada para minimizar a função de perda, que é definida inicialmente no início do processo. Portanto, cada árvore é treinada para prever valores que possam reduzir o erro entre os valores observados e previstos (Friedman, 2001).

Para a aplicação dos algoritmos de classificação de imagens, foi necessário realizar a coleta de amostras, distribuídas nas classes seguintes: plantas cultivadas 461 amostras, solo exposto 149 amostras, plantas daninhas 126 amostras e sombras 102 amostras. Com base na amostragem, aplicou-se a função *Feature Collection* sobre um conjunto de polígonos amostrais, a fim de quantificar o número de pixels correspondentes a cada classe: plantas cultivadas 165763, solo exposto 45657, plantas daninhas 5695 e sombras 4224.

Com base na seleção das variáveis mais relevantes pelo método RFECV, foram definidos os dados de entrada para o treinamento da Rede Neural Artificial. A partir dessa seleção e da escolha dos pixels amostrais, a rede foi configurada para processar os valores por meio de técnicas de Deep Learning, utilizando um algoritmo de redes neurais. As classes propostas foram utilizadas como dados de saída, com o objetivo de gerar uma imagem classificada a partir das amostras, conforme ilustrado na Figura 5.

Figura 5. Estrutura da Rede Neural Artificial com arquitetura FeedForward com 16 neurônios de entrada, 3 camadas ocultas de 9 neurônios cada, e uma camada de saída como os 5 neurônios correspondentes as 5 classes Fonte: Elaborado pelos autores



Fonte: Elaborado pelos autores 2025

Para a implementação dos algoritmos, os dados foram exportados para o *assets* do *Google Earth Engine*, permitindo o processamento em nuvem e facilitando a manipulação de grandes volumes de dados. A aplicação dos algoritmos de classificação *Gradient Tree Boosting* (GTB) e Redes Neurais Artificiais (RNA) teve como objetivo avaliar a eficácia de técnicas supervisionadas baseadas em aprendizado de máquina e aprendizado profundo na segmentação automática de áreas de cultivo de mandioca a partir de imagens obtidas por RPAS.

RESULTADOS

Os três algoritmos de aprendizado de máquina Gradient Tree Boosting (GTB), Random Forest (RF) e Support Vector Machine (SVM) foram avaliados com base nas métricas de precisão, recall e F1-Score, considerando três classes: plantas cultivadas, solo exposto e plantas daninhas. A Tabela 2 apresenta os valores obtidos para cada métrica, incluindo a acurácia geral. O SVM demonstrou desempenho sólido e equilibrado entre as classes, embora tenha apresentado um recall mais baixo (0.77) na classe (solo exposto). O RF teve desempenho satisfatório nas classes de plantas cultivadas e plantas daninhas, mas falhou completamente na classe solo exposto, com valores nulos de precisão, recall e F1-Score, evidenciando sua incapacidade de identificar essa categoria. Em contraste, o GTB destacou-se como o modelo

mais robusto e consistente, alcançando altos resultados em todas as métricas e classes especialmente na classe (solo exposto), onde obteve precisão (1.00) e F1-Score de 0.97 consolidando-se como o algoritmo superior nesta comparação.

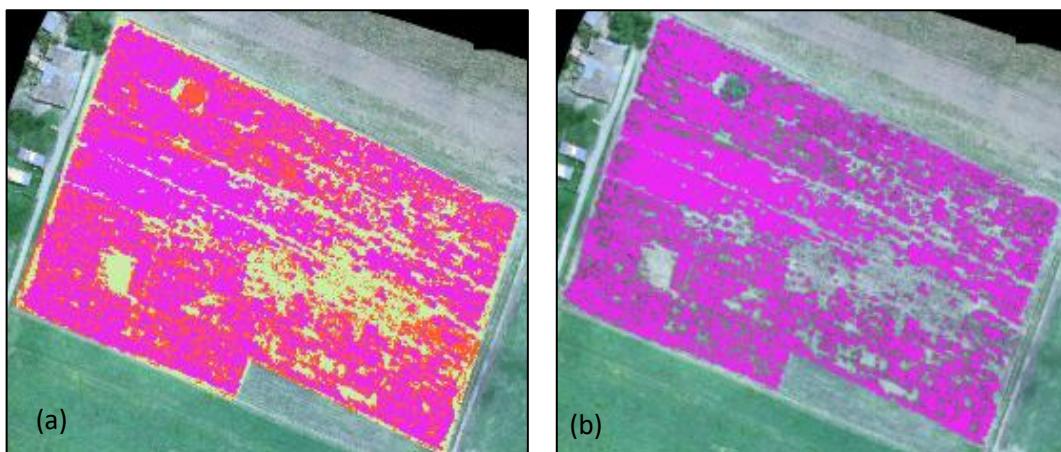
Tabela 2. Valores das métricas analisadas

	Support Vector Machine			Random Forest			Gradiente Tree Boosting		
Clases	Plantas cultivadas	Solo exposto	Plantas Daninha	Plantas cultivadas	Solo exposto	Plantas Daninha	Plantas cultivadas	Solo exposto	Plantas Daninha
Presídio n	0.88	0.96	0.89	0.91	0.00	0.84	0.95	1.00	0.94
Recall	0.91	0.77	0.87	0.88	0.00	0.90	0.94	0.94	0.94
F1-Score	0.90	0.86	0.88	0.89	0.00	0.87	0.95	0.97	0.94
Acurácia	0,89			0.86			0.94		

Fonte: Elaborado autor 2025

O desempenho do modelo foi avaliado com diferentes números de épocas de treinamento (100, 200, 300, 400, 800, 1000 e 1200), entendidas como o número de vezes que todo o conjunto de dados é processado para atualização dos pesos da rede neural. Na primeira tentativa de classificação, os resultados iniciais revelaram limitações no conjunto de amostras de treinamento, tanto em termos de quantidade quanto de representatividade, o que poderia comprometer a capacidade de generalização do modelo. Diante disso, novas amostras foram coletadas para a análise, considerando três classes de interesse: plantas daninhas, plantas cultivadas e solo exposto (Figura 6).

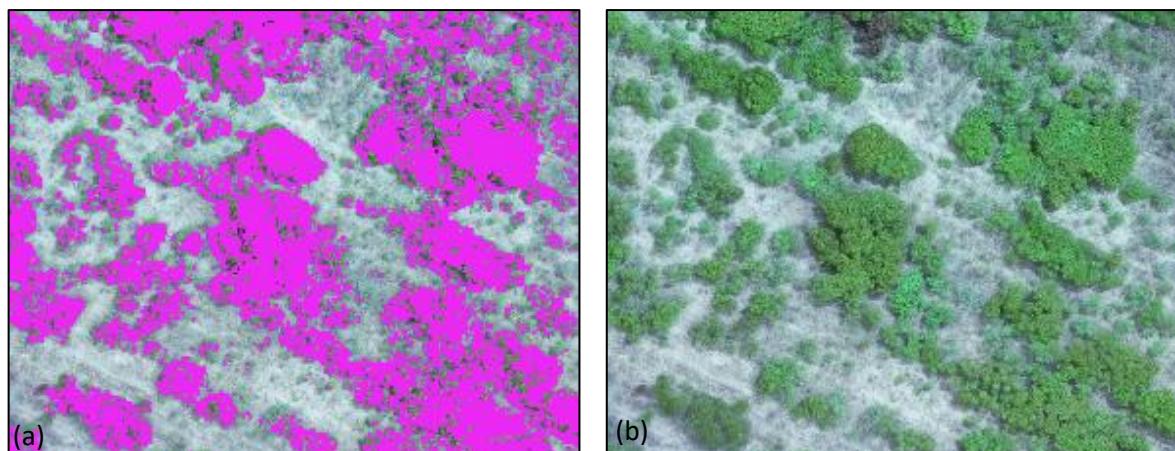
Figura 6. Classificação da cultura da mandioca utilizando o algoritmo Gradient Tree Boosting (GTB), considerando três classes: (a) imagem representando as classes identificadas, sendo a vegetação espontânea plantas daninhas em vermelho, o solo exposto em amarelo e as plantas de mandioca em magenta; (b) camada isolada correspondente apenas as plantas de mandioca, extraída da classificação GTB.



Fonte: Elaborado pelos autores.

A partir da análise dos resultados obtidos com a classificação utilizando o algoritmo *Gradient Tree Boosting* (GTB), observa-se que o classificador identificou corretamente diversas áreas do plantio. No entanto, verificou-se a omissão de algumas bordas do dossel das plantas, bem como de plantas isoladas que não foram classificadas, Figura 7.

Figura 7. A imagem (a) representa as áreas em que as bordas do dossel da cultura não foram corretamente classificadas; na imagem (b) representa o RGB correspondente à mesma área da classificação.

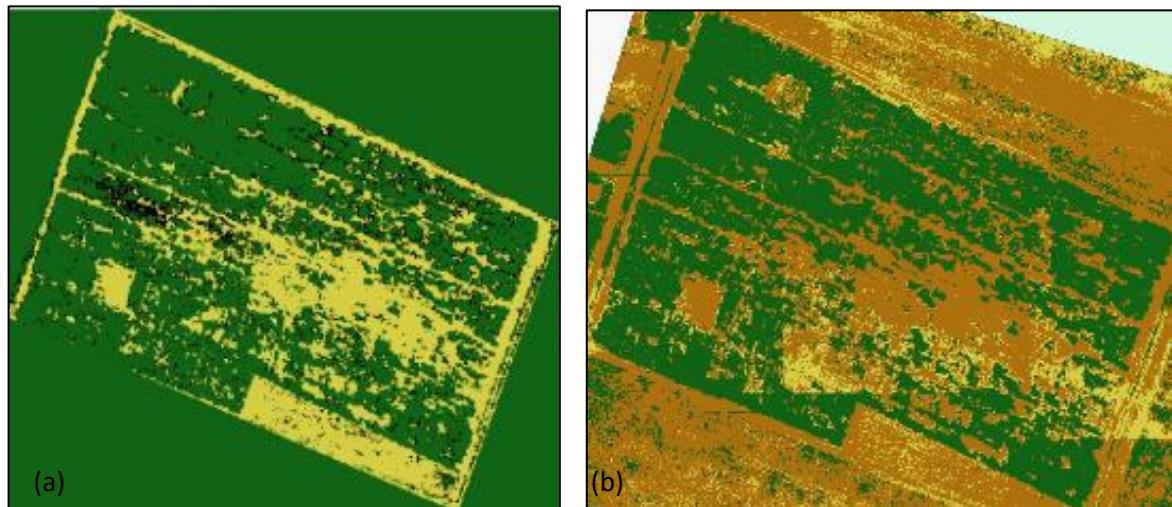


Fonte: Elaborado pelos autores.

Os resultados da primeira tentativa de classificação com *Deep Learning*, utilizando três classes, mostraram-se promissores. No entanto, foi identificada a necessidade de ajustes, como o aumento do número de amostras e a inclusão de uma nova classe representando as sombras

das plantas de mandioca, fator que impacta diretamente no desempenho do classificador, Figura 6.

Figura 6. A imagem (a) representa a camada de classificação da cultura da mandioca utilizando Redes Neurais Artificiais, considerando quatro classes: plantas cultivadas em verde, plantas daninhas e solo exposto em amarelo, sombras em preto; na imagem (b) representada a camada da mandioca isolada, classificada com Redes Neurais Artificiais.



Fonte: Elaborado pelos autores.

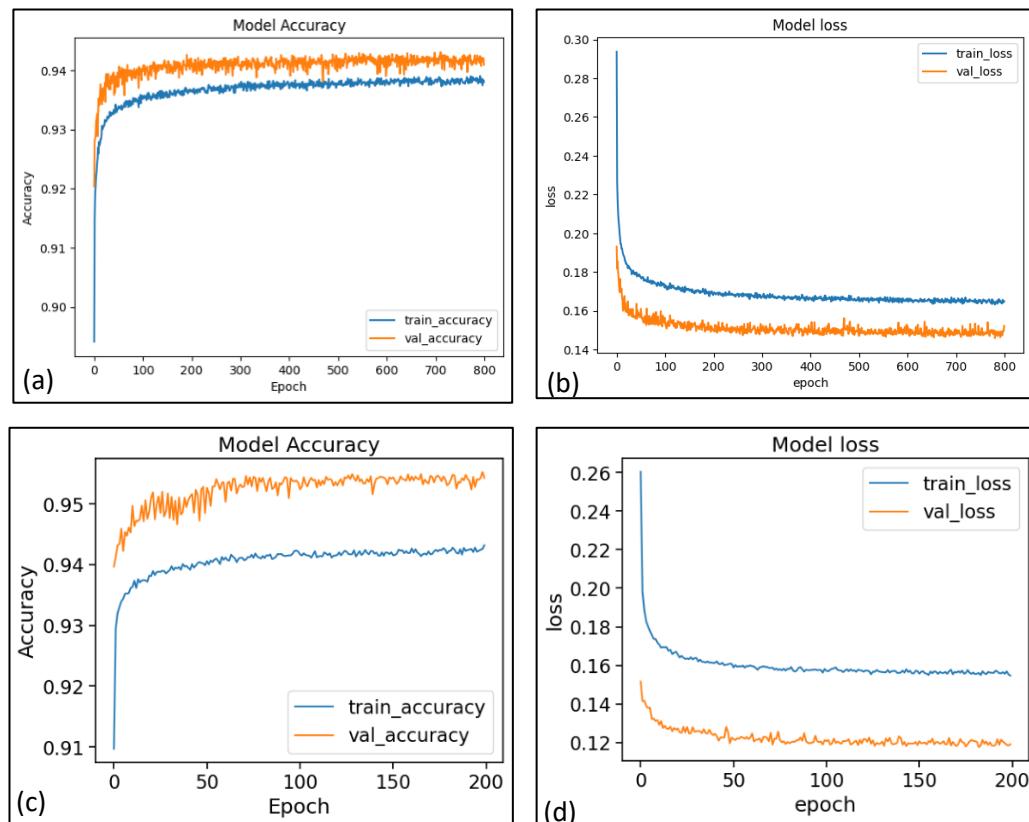
A precisão do modelo foi mensurada por meio da métrica de acurácia, a qual expressa a proporção de classificações corretas em relação ao total de amostras avaliadas. Nesse parâmetro, o modelo obteve valor de 0,954, indicando elevada capacidade de atribuir corretamente as classes aos dados. A acurácia é calculada como a razão entre o número de amostras corretamente classificadas e o número total de amostras empregadas na fase de teste, sendo amplamente reconhecida como um dos principais indicadores de desempenho em tarefas de classificação.

Os resultados obtidos após 200 e 800 épocas de treinamento do modelo Redes Neurais são apresentados na Figura 7. A métrica *Model Loss* quantifica o grau de ajuste do modelo aos dados de treinamento, refletindo a discrepância entre as previsões produzidas e os valores reais observados. A comparação entre diferentes números de épocas permite avaliar a evolução do aprendizado.

Pode-se destacar que, com 200 épocas de treinamento, o modelo apresentou melhores resultados em relação ao equilíbrio entre acurácia e perda, tanto nos dados de treinamento quanto de validação.

Observa-se uma melhor generalização, com valores mais próximos entre acurácia de treino e validação, e menor diferença nas curvas de perda, o que indica menor risco de *overfitting*. Já com 800 épocas, apesar do aumento na acurácia de treinamento, nota-se uma tendência ao ajuste excessivo (*overfitting*), onde o modelo se adapta demais aos dados de treino, mas perde desempenho ao ser aplicado em novos dados. Assim, os resultados indicam que o treinamento com 200 épocas foi mais eficiente, promovendo melhor desempenho geral do classificador.

Figura 7. Model Accuracy e Model loss, obtidos nas épocas de treinamento, O gráfico (a) representa a curva de acurácia do classificador durante o treinamento com 800 épocas. A linha azul mostra a acurácia nos dados de treinamento, enquanto a linha marrom indica a acurácia nos dados de validação. No gráfico (b), é apresentada a curva de perda (Loss) correspondente: a linha azul representa os valores de perda nos dados de treinamento e a linha marrom, nos dados de validação. O gráfico (c) mostra a curva de acurácia durante o treinamento com 200 épocas, seguindo a mesma convenção de cores, azul para os dados de treinamento e marrom para validação. Por fim, o gráfico (d) representa a curva de perda para as 200 épocas, também com a linha azul indicando a perda nos dados de treinamento e a marrom, nos dados de validação.

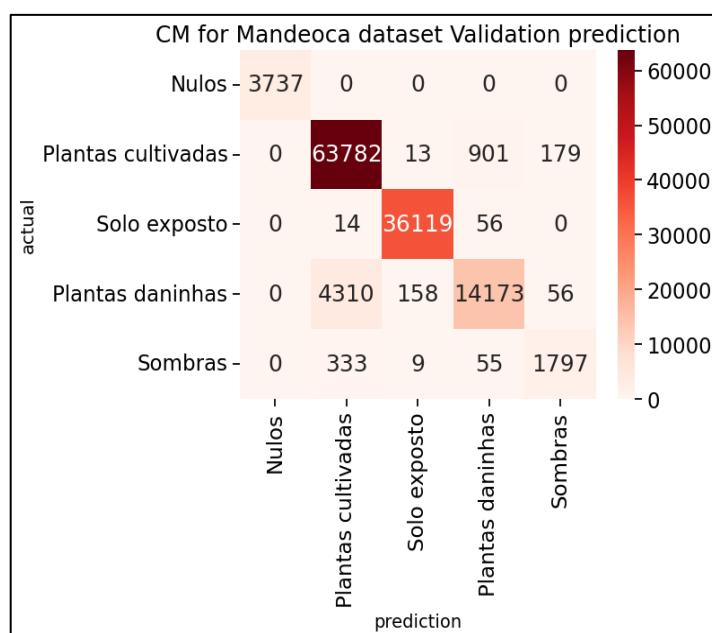


Fonte: Elaborado pelos autores.

Matriz de Confusão

A matriz de confusão foi utilizada para representar o desempenho do modelo de Redes Neurais Artificiais na tarefa de classificação. Essa ferramenta permite visualizar a quantidade de acertos e erros do classificador, comparando as previsões geradas com os valores reais e facilitando a análise da eficácia do modelo. Os resultados indicam que o modelo é capaz de diferenciar as classes e alcançar elevados níveis de precisão na maioria dos casos.

Figura 8. A imagem representa a matriz de confusão do algoritmo de Redes Neurais Artificiais, permitindo uma comparação direta da performance com o algoritmo GTB. Essa visualização é fundamental para a avaliação quantitativa da precisão de cada modelo nas diferentes classes analisadas.



Fonte: Elaborado pelos autores.

DISCUSSÃO

Este estudo avaliou o desempenho de algoritmos de aprendizado de máquina aplicados à classificação espectral em cultivos de mandioca. Imagens obtidas por drones foram utilizadas para extrair variáveis explicativas, incluindo índices de vegetação e características texturais derivadas da

matriz de covariância de níveis de cinza (GLCM) (de Villiers et al., 2024), com base nas bandas espectrais RGB, Red, Red-edge e infravermelho próximo (NIR). Essas variáveis foram empregadas como entrada em quatro algoritmos: Random Forest, Gradient Tree Boosting, Support Vector Machine e Redes Neurais Artificiais.

Estudos que aplicaram redes neurais artificiais na agricultura têm demonstrado resultados promissores em diferentes contextos, como o monitoramento de cultivos de uva, a identificação de doenças em plantas e o reconhecimento de plantas daninhas. Entre esses, destacam-se os trabalhos de (Silva, Schimiguel, 2020), (da Silva, Menezes, 2023), e (Marques, 2019).

No estudo conduzido por (da Silva, Menezes, 2023), o modelo foi avaliado por meio da métrica de acurácia, alcançando o valor de 0,9795 após apenas 15 épocas de treinamento. Embora os autores não apresentem detalhes sobre a arquitetura da rede empregada, observam-se diferenças significativas em relação ao presente trabalho

Geralmente, quanto maior for o número de épocas, melhor o modelo aprende com os dados e reduz os erros de treinamento. Embora a quantidade de épocas utilizada para treinar os algoritmos não seja um valor fixo em cada estudo, o fator mais representativo é o volume de dados das variáveis de entrada para a construção da rede. A quantidade e a qualidade das amostras coletadas influenciam diretamente os resultados, garantindo que estes permaneçam dentro de valores aceitáveis.

Na classificação da doença da folha da mandioca utilizando Redes Neurais Convolucionais, Santos (2021) obteve resultados satisfatórios com o algoritmo desenvolvido, alcançando 91% de acurácia nos diagnósticos de patógenos, com apenas 10 épocas de treinamento. Os conjuntos de dados utilizados nesse estudo foram obtidos por meio da coleta manual de folhas, posteriormente fotografadas para compor os bancos de amostras, utilizando exclusivamente imagens no espectro visível (RGB).

Em contraste, o presente trabalho empregou imagens multiespectrais obtidas por câmeras RGB e Parrot Sequoia acopladas a um RPAS, abrangendo as bandas NIR, RedEdge e Green. Essa abordagem possibilitou o cálculo de diversos índices espectrais, resultando na extração de um conjunto mais abrangente de variáveis e, consequentemente, em um desempenho superior do modelo de Redes Neurais Artificiais, aplicado ao monitoramento da cultura da mandioca.

Por outro lado, neste estudo, a coleta das amostras foi realizada digitalmente, diretamente sobre o raster gerado pelas imagens obtidas com o RPAS. Essa abordagem, embora prática e eficiente, pode resultar na seleção de pixels mistos, ou seja, pixels que representam mais de uma classe, o que pode

comprometer a qualidade das amostras e, consequentemente, afetar negativamente o desempenho do classificador.

Os algoritmos treinados Gradient Tree Boosting, Random Forest, Support Vector Machine e Redes Neurais, segundo os apresentaram desempenho na classificação espectral da cultura da mandioca. Este resultado pode ser atribuído à capacidade das Redes Neurais de extrair automaticamente padrões relevantes a partir das imagens multiespectrais, proporcionando um aprendizado mais eficiente em relação às demais técnicas avaliadas. As Redes Neurais apresentaram maior acurácia tanto na etapa de treinamento quanto na de classificação, mostrando-se mais eficazes na diferenciação das distintas classes espectrais associadas à cultura da mandioca.

Apesar dos resultados positivos, observou-se que o GTB apresenta limitações em determinadas situações, como nas bordas do dossel das plantas e na detecção de plantas isoladas. Essas limitações podem estar associadas à resolução espacial das imagens, à variabilidade espectral ou à necessidade de uma amostragem mais representativa durante o treinamento dos modelos. Além disso, a ausência da classe “sombra” em algumas tentativas iniciais de classificação demonstrou impacto direto no desempenho dos modelos, reforçando a importância de sua inclusão nas abordagens supervisionadas.

Em síntese, os resultados indicam que tanto o GTB quanto as CNN são algoritmos robustos e eficazes para aplicações em agricultura de precisão, desde que acompanhados por um conjunto de dados bem estruturado e por estratégias complementares, como a seleção de atributos e o ajuste fino dos parâmetros de classificação. Os avanços obtidos com esses métodos reforçam o papel dos RPAS e das técnicas de geoprocessamento como aliados estratégicos no monitoramento de culturas agrícolas, como a mandioca.

CONCLUSÕES

Este estudo avaliou o desempenho de uma Rede Neural FeedForward, *Gradient Tree Boosting* (GTB), Random Forest e Support Vector Machine na classificação de áreas de cultivo de mandioca a partir de imagens multiespectrais obtidas por RPAS. A pesquisa foi conduzida com o objetivo de identificar qual abordagem oferece maior acurácia e robustez na segmentação automática das classes de interesse, contribuindo para a agricultura de precisão e para o manejo eficiente desta cultura de grande importância socioeconômica no Brasil.

Os resultados demonstraram que ambos os algoritmos apresentaram desempenho satisfatório na classificação das áreas, com elevada taxa de acertos na identificação das classes

plantas cultivadas, solo exposto e plantas daninhas. No entanto, a Rede Neural FeedForward mostrará desempenho superior, em relação à O GTB, RF e SVM, especialmente na definição dos contornos das plantas, na discriminação de áreas com alta densidade de vegetação e na capacidade de diferenciar variações sutis entre classes espectrais. Esse resultado reforça a adequação da rede para tarefas de classificação de imagens de alta resolução, nas quais a preservação e interpretação das relações espaciais entre pixels desempenham papel fundamental.

A utilização de imagens multiespectrais, combinando bandas RGB, *Green*, *Red*, *Red-edge* e NIR, possibilitou o cálculo de uma ampla gama de índices espectrais, enriquecendo o conjunto de variáveis e permitindo maior sensibilidade à variação no vigor vegetativo e no estado nutricional das plantas. Essa abordagem se mostrou mais eficaz do que métodos baseados apenas em imagens RGB, conforme evidenciado na literatura comparada.

Apesar dos resultados positivos, alguns desafios foram identificados. A coleta digital de amostras diretamente no ortomosaico pode gerar pixels mistos, o que compromete a pureza espectral e, consequentemente, a precisão do treinamento. Além disso, a ausência inicial da classe sombra reduziu a capacidade de discriminação do modelo em algumas tentativas de classificação, reforçando a necessidade de uma definição abrangente das classes desde o início do processo. Também se observou que condições de iluminação, variações fenológicas e a representatividade do conjunto de amostras influenciam diretamente o desempenho final.

Do ponto de vista prático, este trabalho evidencia que sistemas de classificação baseados em visão computacional e processados em plataformas de computação em nuvem representam ferramentas estratégicas para o monitoramento agrícola. No caso da mandioca, essa abordagem permite a detecção precoce de estresses bióticos e abióticos, a otimização na aplicação de insumos, a redução de custos operacionais e o aumento da eficiência no manejo. Sua aplicação pode ser estendida para programas de monitoramento em larga escala, integrando informações geoespaciais para apoiar a tomada de decisão de agricultores, técnicos e gestores públicos.

Para trabalhos futuros, recomenda-se ampliar a base de dados com imagens adquiridas em diferentes estágios fenológicos e sob distintas condições ambientais, explorar o uso de sensores hiperespectrais e integrar séries temporais de imagens para análises dinâmicas.

Também introduzir o uso de Redes Neurais Convolucionais que são mais robustas na extração de características de contexto, e testar a escalabilidade de modelos para áreas maiores. Além disso, a integração dessa abordagem com sistemas de gestão agrícola e plataformas de agricultura digital pode potencializar seu impacto, contribuindo para a transição rumo a sistemas produtivos mais sustentáveis, eficientes e tecnologicamente avançados.

Os resultados deste estudo confirmam o potencial das redes neurais, associadas a imagens multiespectrais de alta resolução, como ferramenta robusta e versátil para o monitoramento e a gestão de áreas de cultivo de mandioca. Essa metodologia oferece não apenas avanços técnicos em relação a abordagens tradicionais, mas também benefícios concretos para a prática agrícola, fortalecendo o papel da agricultura de precisão como aliada no enfrentamento dos desafios contemporâneos de produção, sustentabilidade e segurança alimentar.

AGRADECIMENTOS

A.F.S gostaria de agradecer à CAPES pela bolsa de estudo concedida (número de processo 88887.679889/2022-00), assim como ao programa de Pós-graduação Em Modelagem Em Ciências Da Terra E Do Ambiente (PPGM/UEFS) pelo apoio durante a realização deste estudo. Agradecer também a Embrapa Mandioca e Fruticultura pela colaboração na pesquisa.

REFERÊNCIAS

- AMARAL, L. R. et al. UAV applications in Agriculture 4.0. *Revista Ciência Agronômica*, v. 51, n. 5, 2020.
- BALLESTEROS, R. et al. Avaliação do crescimento e desenvolvimento do milho com produtos de sensoriamento remoto de alta e média resolução. *Agronomy*, v. 11, p. 940, 2021.
- BARROS, A. S.; FARIA, L. D.; MARINHO, J. L. A. Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) na caracterização da cobertura vegetativa de Juazeiro do Norte–CE. *Revista Brasileira de Geografia Física*, v. 13, n. 6, p. 2885–2895, 2020.

BARROS, A. S.; FARIAS, L. D.; MARINHO, J. L. A. Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) na caracterização da cobertura vegetativa de Juazeiro do Norte–CE. *Revista Brasileira de Geografia Física*, v. 13, n. 6, p. 2885–2895, 2020.

BOUGUETTAYA, A. et al. Avanços recentes em UAV e aprendizagem profunda para identificação precoce de doenças em culturas: uma breve revisão. In: CONFERÊNCIA INTERNACIONAL SOBRE TECNOLOGIA DA INFORMAÇÃO (ICIT), 2021. Disponível em <https://doi-org.ez77.periodicos.capes.gov.br/10.1109/ICIT52682.2021.9491661>.

BREIMAN, L. Florestas aleatórias. *Machine Learning*, v. 45, p. 5–32, 2001.

BREWER, K. et al. Previsão do teor de clorofila do milho por meio da fenotipagem como indicador da saúde da cultura em sistemas de agricultura familiar. *Remote Sensing*, v. 14, p. 518, 2022.

BURNS, B. W. et al. Determinação de deficiências de nitrogênio em milho usando vários índices de sensoriamento remoto. *Precision Agriculture*, v. 23, p. 791–811, 2022.

COLLA, C. E. K.; ROSA, H. A. Correlação de diferentes índices de vegetação com índice de clorofila e produtividade da cultura da soja. *Revista Thêma et Scientia*, v. 14, n. 2E, p. 26–44, 2024.

da Silva, A. M. M., & da Silva Menezes, M. (2023). REDES NEURAIS CONVOLUCIONAIS NA AGRICULTURA: DETECÇÃO DE DOENÇAS FÚNGICAS EM PLANTAS DE UVA.

DE ALMEIDA, G. S. et al. Monitoramento das interações solo-planta e da produtividade do milho por meio de índices de vegetação por satélite, condutividade elétrica do solo e zonas de manejo. *Precision Agriculture*, v. 24, p. 1380–1400, 2023.

DE VILLIERS, C. et al. Avaliação da variabilidade espaço-temporal da produtividade do milho usando veículos aéreos não tripulados e aprendizado de máquina. *Geomatics*, v. 4, n. 3, p. 213–236, 2024. DOI: <https://doi.org/10.3390/geomatics4030012>..

FAO. How to feed the world in 2050—High-level expert forum. Rome: FAO, 2009. Disponível em: https://www.fao.org/fileadmin/templates/wsfs/docs/Issues_papers/HLEF2050_Global_Agriculture.pdf. Acesso em: 15 mar. 2025.

FERNANDES, W. M. et al. Comparação de índices NDVI com índices do espectro visível para avaliar o uso e ocupação do solo no entorno da represa de Itupararanga–SP. *Ações antrópicas sobre o meio ambiente*, 2022.

FRIED, G.; CHAUVEL, B.; REYNAUD, P.; SACHE, I. Decreases in crop production by non-native weeds, pests, and pathogens. In: VILÀ, M.; HULME, P. E. (Ed.). Impact of biological invasions on ecosystem services. Cham, Switzerland: Springer International Publishing, 2017. p. 83–101.

FRIEDMAN, J. H. Aproximação de função gulosa: uma máquina de boosting de gradiente. *Annals of Statistics*, v. 29, p. 1189–1232, 2001.

HAN, N. et al. Rapid diagnosis of nitrogen nutrition status in summer maize over its life cycle by a multi-index synergy model using ground hyperspectral and UAV multispectral sensor data. *Atmosphere*, v. 13, n. 1, p. 122, 12 jan. 2022.

HUNT, E. R.; DAUGHERTY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? *International Journal of Remote Sensing*, v. 39, n. 15-16, p. 5345–5376, 2018.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Censo agropecuário 2017: resultados preliminares. Rio de Janeiro: IBGE, 2017. v. 7, p. 1–108. Disponível em: https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_preliminares.pdf. Acesso em: 10 mar. 2025.

KE, G. et al. LightGBM: a highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, v. 30, 2017.

LI, Z.; CHEN, Z. Indicadores de sensoriamento remoto para monitoramento do crescimento de culturas em diferentes escalas. In: *IEEE International Geoscience and Remote Sensing Symposium*, Vancouver, Canadá, 24–29 jul. 2011. Anais [...]. p. 4062–4065.

Marion, F. A., Andres, J., & Hendges, E. R. (2021). EVOLUÇÃO DOS ÍNDICES DE VEGETAÇÃO E SUA RELAÇÃO COM O ESTRESSE HÍDRICO: UMA REVISÃO. *GEOFRONTER*, 7(1). <https://doi.org/10.61389/geofronter.v7.6758>

Marques Junior, L. C. (2019). Classificação de plantas daninhas em banco de imagens utilizando redes neurais convolucionais.

NEVES, S. O. et al. Correlação entre a produtividade do milho e os índices de vegetação utilizando imagens do Sentinel 2. *Revista de Gestão e Secretariado*, v. 16, n. 4, p. e4811–e4811, 2025.

OYEWOLE, O. B.; OGUNDELE, S. L. Effect of length of fermentation on the functional characteristics of fermented cassava “fufu”. *The Journal of Food Technology in Africa*, v. 6, n. 2, p. 38–40, jun. 2001.

PEDREGOSA, F. et al. Scikit-learn: aprendizado de máquina em Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

RODRIGUES, W. B.; MORAIS, F.; PASCHOAL, L. G. Índice de diferença normalizada da água (NDWI) calculado para estações chuvosas e secas na bacia do Córrego Barreiro, Lagoa da Confusão–TO. *Os Desafios da Geografia Física na Fronteira do Conhecimento*, v. 1, p. 254–263, 2017.

ROSALEN, D. L. Veículo aéreo não tripulado – VANT: Conceituação e utilização na agricultura. In: Processos Agrícolas e Mecanização da Cana-de-açúcar. 1. ed. Jaboticabal: SBEA, 2015. p. 589-600.

SANTOS, H.A.; SANTOS, L. B. Classificação da Doença da Folha da Mandioca utilizando Redes Neurais Convolucionais. *Revista de Engenharia e Pesquisa Aplicada*, Recife, v.6, n. 5, p. 47-55, novembro, 2021.

SANTOS, J. M. et al. Spectral responses at visible and near-infrared wavelengths of soybean plants to fungicides. *Ciência Rural*, v. 52, n. 10, 2022.

SHAH, S. A. et al. Application of drone surveillance for advance agriculture monitoring by Android application using Convolution Neural Network. *Agronomy*, v. 13, n. 7, p. 1764, 2023. Disponível em: <https://doi.org/10.3390/agronomy13071764>. Acesso em: 13 abr. 2025.

SILVA, M. J.; SCHIMIGUEL, J. Identificação de doenças em plantas por meio de processamento de imagens: redes neurais convolucionais como auxílio à agricultura. *Revista de Ubiquidade*, São Paulo, v. 3, n. 1, p. 91–111, 2020.

SIVIERO, A.; TREMACOLDI, C. R. Ocorrência da ferrugem da mandioca causada por Uromyces manihotis no Estado do Pará. *Tropical Plant Pathology*, v. 36, p. 924, ago. 2011.

SUJATHA, R. et al. Desempenho de aprendizado profundo versus aprendizado de máquina na detecção de doenças foliares de plantas. *Microprocesso. Microsyst.*, v. 80, n. 103, 2021. Acesso em: <https://doi-org.ez77.periodicos.capes.gov.br/10.1016/j.micpro.2020.103615>.

TORRES-SÁNCHEZ, J.; LÓPEZ-GRANADOS, F.; PEÑA, J. M. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, v. 139, p. 85-93, 2018.

VAN DIJK, M. et al. A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050. *Nature Food*, [S.l.], v. 2, p. 494–501, 2021. Disponível em: <https://doi.org/10.1038/s43016-021-00322-9>. Acesso em: 15 mar. 2025.

VILLELA, M. A. L. Análise multitemporal da recuperação natural de áreas de cerrado degradadas pela mineração classe II, no DF, com uso do EVI2. 2019. Trabalho não publicado.

XIAO, Y. et al. Análise de sensibilidade da refletância da vegetação a variáveis bioquímicas e biofísicas em escalas foliar, de dossel e regional. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, p. 4014–4024, 2013.