






REVISTA MULTIDISCIPLINAR EPISTEMOLOGÍA DE LAS CIENCIAS



Universidad de Sonsonate



Volumen 3, Número 3



Julio - Septiembre, 2026
Edición Especial

CROSSREF PREFIX DOI: 10.71112

ISSN: 3061-7812, www.omniscens.com

Revista Multidisciplinar Epistemología de las Ciencias

Volumen 3, Número 3
Julio-Septiembre 2026
Edición Especial

Publicación trimestral
Hecho en México

La Revista Multidisciplinar Epistemología de las Ciencias acepta publicaciones de cualquier área del conocimiento, promoviendo una plataforma inclusiva para la discusión y análisis de los fundamentos epistemológicos en diversas disciplinas. La revista invita a investigadores y profesionales de campos como las ciencias naturales, sociales, humanísticas, tecnológicas y de la salud, entre otros, a contribuir con artículos originales, revisiones, estudios de caso y ensayos teóricos. Con su enfoque multidisciplinario, busca fomentar el diálogo y la reflexión sobre las metodologías, teorías y prácticas que sustentan el avance del conocimiento científico en todas las áreas.


Contacto principal: admin@omniscens.com

Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación

Se autoriza la reproducción total o parcial del contenido de la publicación sin previa autorización de la Revista Multidisciplinar Epistemología de las Ciencias siempre y cuando se cite la fuente completa y su dirección electrónica.




Copyright © 2026: Los autores



9773061781003

Cintillo legal

Revista Multidisciplinar Epistemología de las Ciencias Vol. 3, Núm. 3, julio-septiembre 2026, edición especial, es una publicación trimestral editada por el Dr. Moises Ake Uc, C. 51 #221 x 16B , Las Brisas, Mérida, Yucatán, México, C.P. 97144 , Tel. 9993556027, Web: <https://www.omniscens.com>, admin@omniscens.com, Editor responsable: Dr. Moises Ake Uc. Reserva de Derechos al Uso Exclusivo No. 04-2024-121717181700-102, ISSN: 3061-7812, ambos otorgados por el Instituto Nacional del Derecho de Autor (INDAUTOR). Responsable de la última actualización de este número, Dr. Moises Ake Uc, fecha de última modificación, 1 julio 2026.



Revista Multidisciplinar Epistemología de las Ciencias

Vol. 3, Núm. 3, 2026, julio-septiembre, Edición Especial

DOI: <https://doi.org/10.71112/5yx9sp43>

**MONITOREO DEL DESARROLLO DE CULTIVOS DE MAÍZ MEDIANTE IMÁGENES
AÉREAS MULTIESPECTRALES PROCESADAS CON INTELIGENCIA ARTIFICIAL**

**MONITORING OF MAIZE CROPS THROUGH MULTISPECTRAL AERIAL IMAGERY
PROCESSED WITH ARTIFICIAL INTELLIGENCE.**

Carlos Roberto Martínez Martínez

El Salvador

Monitoreo del desarrollo de cultivos de maíz mediante imágenes aéreas multiespectrales procesadas con inteligencia artificial

Monitoring of maize crops through multispectral aerial imagery processed with artificial intelligence.

Carlos Roberto Martínez Martínez^{a,*}

carlos.martinez@usonsonate.edu.sv

<https://orcid.org/0000-0002-6098-8765>

Facultad de Ingeniería y Ciencias Naturales.

*Autor de correspondencia: carlos.martinez@usonsonate.edu.sv, ^aUniversidad de Sonsonate, El Salvador.

RESUMEN

Distintos modelos de inteligencia artificial fueron evaluados para la segmentación de imágenes multiespectrales de cultivos de maíz obtenidas mediante dron, con el propósito de monitorear su desarrollo bajo condiciones de agricultura tradicional en El Salvador. Se aplicaron los modelos Binary Threshold, Random Forest, K-Means, DNN y CNN-MobileNet para discriminar áreas de maíz, malezas y suelo a partir imágenes con colores normalizados con base en el índice GNDVI. Los resultados demostraron que Random Forest alcanzó la mayor precisión (0.95) y consistencia en la predicción de los índices de vegetación LAI y GNDVI, superando significativamente a los modelos de aprendizaje profundo, cuyos resultados se vieron limitados por la calidad de las máscaras generadas por K-Means. El método Binary Threshold también mostró desempeño aceptable por su sencillez y rapidez. Se concluyó que Random Forest

ofreció resultados equilibrados entre precisión, costo y aplicabilidad práctica para el monitoreo de cultivos de subsistencia.

Palabras clave: Teledetección; agricultura de precisión; Índice de vegetación; segmentación de imágenes; aprendizaje automático.

ABSTRACT

Different artificial intelligence models were evaluated for the segmentation of multispectral images of maize crops obtained by drone, with the purpose of monitoring their development under traditional farming conditions in El Salvador. The models Binary Threshold, Random Forest, K-Means, DNN, and CNN-MobileNet were applied to discriminate maize, weed, and soil areas from images with colors normalized based on the GNDVI index. The results showed that Random Forest achieved the highest accuracy (0.95) and consistency in predicting the vegetation indices LAI and GNDVI, significantly outperforming deep learning models, whose results were limited by the quality of the masks generated by K-Means. The Binary Threshold method also showed acceptable performance due to its simplicity and speed. It was concluded that Random Forest provided balanced results in terms of accuracy, cost, and practical applicability for monitoring subsistence crops.

Keywords: Remote sensing; precision agriculture; vegetation index; image segmentation; machine learning.

Recibido: 16 febrero 2026 | Aceptado: 30 junio 2026 | Publicado: 1 julio 2026

INTRODUCCIÓN

El cultivo del maíz es fundamental para garantizar la soberanía alimentaria en los países de México y Centroamérica. Sin embargo, en las últimas décadas ha tenido que enfrentar serias dificultades, como los altos costos de producción, la disponibilidad de suelos con fertilidad y topografía poco adecuadas, los cambios en los patrones de lluvia que limitan su capacidad de cosecha (Radia et al., 2024; Chen et al., 2021; Ubilava & Abdollahimi, 2019), el incremento en la incidencia de plagas y enfermedades como la mancha asfáltica (Mohanty et al., 2023; Pan et al., 2022), la resistencia inducida de las malezas por el uso inadecuado de herbicidas y la falta de tecnificación para la recolección oportuna de información científica para la toma de decisiones. Una de las nuevas tendencias en la agricultura es el uso de tecnologías de monitoreo remoto mediante drones no tripulados que poseen cámaras multiespectrales, capaces de medir y cuantificar la reflectancia de la clorofila como indicador de vigor vegetal (Huang et al., 2021; Guo et al., 2020). Sin embargo, los datos provenientes de estas mediciones usualmente necesitan ser procesados para que sean útiles, empleando software especializado que ensambla múltiples fotografías aéreas en imágenes consolidadas, calcula índices normalizados de verdor que homogeneizan la representación pictográfica de las plantas y, con base en ello, discrimina las áreas que corresponden a cultivos, malezas, follaje de árboles de sombra, suelo parcial o completamente descubierto, entre otros factores.

A la discriminación de figuras en imágenes con base en su forma o rango de color se le conoce como “segmentación”, y este proceso puede lograrse mediante la implementación de algoritmos de aprendizaje automatizado como Random Forest (Cheng et al., 2022; Marques et al., 2020), o de aprendizaje profundo, como Redes Neuronales Profundas o “DNN” (Danilevicz et al., 2021; Kim et al., 2020) y Redes Neuronales Convolucionales o “CNN” (Shahi et al., 2023; Tseng et al., 2022), todos los cuales se clasifican como ramas de la inteligencia artificial (IA), y cuya aplicación ha sido reportada exitosamente en distintos tipos de casos según la literatura.

El presente estudio analiza la conveniencia de uso de estos principales modelos de IA, enfocados a la segmentación de imágenes multiespectrales ortocompuestas, con base en rangos de color normalizados a través del cálculo de índices de verdor.

Marco Teórico

Los avances tecnológicos en sistemas monitoreo remoto por drones, combinados con la inteligencia artificial y el análisis de datos, están revolucionando la agricultura de precisión. Estas tecnologías emergentes mejoran el monitoreo de cultivos, la predicción del rendimiento, la detección de enfermedades, el estrés hídrico y las deficiencias de nutrientes, lo que resulta en prácticas agrícolas más eficientes. Los drones suelen estar equipados con cámaras RGB de alta resolución y sensores multiespectrales (Hunt et al., 2010), que capturan y registran cuatro espectros de la luz: verde (560 ± 16 nm), rojo (650 ± 16 nm), borde del rojo o “Red Edge” (730 ± 16 nm) e infrarrojo cercano o “NIR” (840 ± 26 nm). Las imágenes que captan son ensambladas en un proceso llamado “ortocomposición” y que permite el cálculo generalizado de índices de vegetación que miden el vigor del follaje, como el Índice de Vegetación de Diferencia Normalizada (NDVI) y su variante GNDVI, que se especializa en el color verde. Estos pueden utilizarse para medir la reflectancia de la luz que causa la clorofila de las hojas lo cual es útil para distintos tipos de estudios, como la estimación del estrés hídrico en el maíz (Mndela et al., 2023; Shuai & Basso, 2022) y la clasificación de enfermedades en maíz (Nan et al., 2023).

Las tecnologías de aprendizaje automático son un excelente complemento ya que procesan conjuntos de imágenes con otros datos como registros climáticos y resultados de cosechas. El flujo de trabajo generalmente incluye la recopilación de datos, el preprocesamiento, el entrenamiento del modelo y su optimización para lograr predicciones precisas. Los modelos Random Forest, comúnmente utilizados para la detección de enfermedades, se configuran ajustando el número y la profundidad de los árboles de decisión

para explorar interacciones complejas en los datos (DeSalvio et al., 2022). En cambio, para la predicción del rendimiento de cosechas, modelos como XGBoost se han ajustado eficientemente (Chen et al., 2022). De manera similar, K-Nearest Neighbors (KNN) clasifica los datos comparándolos con un número específico de vecinos similares, facilitando tareas como la predicción de rendimientos en diferentes regiones (Cedric et al., 2022). Por su parte, Bolfe et al. (2023) aplicaron Random Forest para clasificar tipos de cultivos y evaluar la intensificación agrícola, superando desafíos como la cobertura nubosa en imágenes satelitales mediante el ajuste de hiperparámetros.

En cuanto a las innovaciones en el aprendizaje profundo, Darwin et al. (2021) revisaron el uso de CNN para la predicción del rendimiento y la detección de floración en diversos cultivos, destacando la eficiencia de esta red neurales el procesamiento de datos de imagen. Sin embargo, dicha revisión también señaló desafíos como los altos costos computacionales y la necesidad de grandes conjuntos de datos. Liu et al. (2021) compararon modelos de aprendizaje profundo y superficial para estimar el Índice de Área Foliar (LAI) en maíz, utilizando CNNs para procesar imágenes RGB, mejorando la precisión en la segmentación y clasificación de hojas, superando a otros métodos tradicionales con una exactitud de clasificación del 92.3%. A pesar de estos avances, el estudio identificó desafíos en condiciones de campo, particularmente debido a la variabilidad ambiental. Nowakowski et al. (2021) demostraron que las CNN preentrenadas, como GoogLeNet y VGG16, podían alcanzar alta precisión en la clasificación de diferentes cultivos, incluso en condiciones de poca disponibilidad de con datos etiquetados. Por su parte, Danilevycz et al. (2021) utilizaron modelos diferentes para predecir la capacidad de cosechas de cultivos de maíz, entrenando un modelo DNN que realizó análisis cruzado de datos provenientes de imágenes multiespectrales con información de genotipos de maíz, obteniendo un nivel aceptable de confiabilidad. Luego, Shao et al. (2022) compararon la eficiencia de varios modelos como Random Forest, DNN y Support Vector Machine (SVM),

entrenados con datos multiespectrales y de temperatura, para la predicción de coeficientes de cultivo (K_c) de maíz y su respectiva evapotranspiración de cultivo (E_{tc}), obteniendo un alto nivel de confiabilidad.

Todos estos trabajos han brindado aportes significativos al análisis tecnológico de cultivos de maíz, aunque cada uno desde una perspectiva o con un propósito distinto. A continuación, se describe la metodología empleada en el presente estudio, en la cual se reporta el uso de los mismos modelos que han demostrado ser efectivos, pero aplicados a la segmentación de imágenes normalizadas mediante la diferenciación de cultivos de maíz a través de umbrales de color basados en índices GNDVI, con el fin de medir el vigor del cultivo en sus diferentes etapas fenológicas, bajo condiciones de campo en El Salvador.

METODOLOGÍA

Este estudio empleó un enfoque de métodos mixtos, integrando tanto técnicas cuantitativas como cualitativas. La investigación se llevó a cabo en seis plantaciones de maíz de pequeños agricultores ubicadas en el departamento de Santa Ana, El Salvador, situadas a altitudes entre 680 y 700 metros sobre el nivel del mar, con un terreno irregular y densidades variables de malezas que compiten con el cultivo. Todas las plantaciones fueron fertilizadas manualmente con sulfato de amonio, a una dosis aproximada de 231 lb por acre, con una dosis 15 días después de la germinación y una segunda luego de los 30 días siguientes. Para monitorear el desarrollo y la salud vegetal de los cultivos, se tomaron colecciones de fotografías aéreas en las siguientes etapas: El primer vuelo del dron, a los 15 días después de la germinación, correspondió a las etapas vegetativas V3–V4. El segundo vuelo, a los 30 días, se realizó en V6–V7. El tercer vuelo, a los 45 días, coincidió con V9–V10. El cuarto vuelo, a los 60 días, se ubicó en V12–V14. El quinto vuelo, a los 75 días, correspondió a la terminación de la etapa vegetativa o VT, que corresponde al espigamiento. El sexto vuelo, a los 90 días, se

realizó en etapa reproductiva R1. El séptimo vuelo, a los 105 días, coincidió con R2–R3.

Finalmente, el octavo vuelo, a los 120 días, se ubicó en R4–R5.

Las imágenes aéreas fueron capturadas utilizando un dron DJI equipado con una cámara RGB de 20 MP y cuatro sensores multispectrales de 5 MP que operaban en las siguientes bandas de luz G, R, RE y NIR, que corresponden a los espectros del verde (560 ± 16 nm), rojo (650 ± 16 nm), borde rojo (730 ± 16 nm) e infrarrojo cercano (860 ± 26 nm). Los vuelos se realizaron a 30 m de altitud con un traslape del 80% y una resolución espacial (GSD) de 3.31 cm/píxel. El procesamiento de imágenes se llevó a cabo mediante la API de OpenDroneMap para generar ortofotos compuestas de fotografías individuales georeferenciadas y solapadas, con las cuales se calcularon mapas de color normalizados según el índice GNDVI. Esta “estandarización” de colores, permitió la diferenciación visual entre plantas de maíz, malezas y suelo. Para que el análisis del cultivo tomara en cuenta únicamente los píxeles relativos a plantas de maíz, se implementó un proceso de segmentación basado en el color de las imágenes GNDVI. Primero, se muestrearon manualmente los valores RGB más claros y más oscuros de 30 plantas de maíz por cada campo, con el fin de definir umbrales superiores e inferiores para la inclusión de píxeles. Estos umbrales se usaron inicialmente para probar un algoritmo de umbralización binaria. Posteriormente, los mismos rangos fueron introducidos en un modelo de Random Forest para entrenar un clasificador de píxeles. En un enfoque alternativo, los umbrales RGB se emplearon en una rutina de agrupamiento K-means para generar una máscara de pseudo “ground truth”, que luego se utilizó para entrenar una Red Neuronal Profunda (DNN) y una Red Neuronal Convolucional (CNN) basada en la arquitectura MobileNet. Estos modelos permitieron la exclusión automatizada de malezas y elementos del suelo. Una vez completada la segmentación, un script personalizado en Python calculó el GNDVI promedio utilizando (1), realizando los

cálculos en función de los valores de color de los píxeles identificados como maíz, mientras se excluía la interferencia de otros estratos de vegetación o suelo.

$$GNDVI = \frac{1}{N} \sum_{i=1}^N \left(\frac{G_i - R_i}{G_i + R_i} \right) \quad 1)$$

donde:

G_i es el valor verde del píxel i en escala RGB,

R_i es el valor rojo del píxel i en escala RGB,

N es el total de píxeles clasificados como plantas de maíz.

Por otra parte, la sumatoria de píxeles dentro de las máscaras de maíz se utilizó para calcular el índice de área foliar, como medida de la cobertura vegetal del cultivo en sus diferentes estados. Para validar los resultados, los valores obtenidos a partir de los píxeles segmentados se compararon con curvas de desarrollo reportadas en otras investigaciones, basadas en métodos clásicos para estimar el incremento del LAI y el GNDVI a lo largo de las etapas fenológicas del maíz.

RESULTADOS

Las parcelas usadas como objeto de estudio fueron seleccionadas porque representaban las prácticas tradicionales en la agricultura salvadoreña, realizadas por agricultores de subsistencia, con el fin de evidenciar los retos y desafíos que deben encarar para brindar su aporte en la seguridad alimentaria de sus familias y del país. En las imágenes RGB de cada vuelo, pudo observarse anomalías en el crecimiento del cultivo y en el manejo de suelos, sobre todo en lo relativo a escorrentías (Fig. 1). Las colecciones de imágenes multiespectrales se tomaron mediante un recorrido de líneas rectas sobre el cultivo, incorporando un vuelo en diagonal (Fig. 2) para incrementar la precisión de datos de georeferenciación de imágenes para el ensamblaje del plano ortomosaico.


Figura 1

Cultivo tradicional de maíz con problemas de desarrollo y de escorrentías.



Figura 2

Construcción 3D de la trayectoria de vuelo del dron.




En cada punto de muestreo, el dron capturó cuatro fotografías multiespectrales (G, R, RE y NIR) que se utilizaron para calcular una única capa ráster de reflectancia de clorofila. Esta se obtuvo a partir del cálculo del índice de reflectancia con base en los cuatro canales de color multiespectral. Posteriormente, el software aplicó una normalización de color mediante el

cálculo del índice GNDVI, el cual está fundamentado en el canal verde como indicador de salud vegetal. Como resultado, las que plantas de una misma especie, como el maíz y otras gramíneas consideradas malezas, presentaran colores semejantes entre sí, pero diferenciados respecto a otras especies. Este índice normalizado permitió diferenciar las plantas tanto por especie como por su estado de vigor. Fue notorio que luego de la normalización de color, se preservaron los patrones visuales de cultivos por surco (Fig. 3, izquierda) y anomalías como microcuencas con malezas por donde se descargaban escorrentías (Fig. 3, derecha). Por cada etapa de cultivo, la presencia de malezas era menor debido a la presión de cultivo que el maíz ejerció sobre las malezas en competencia por la luz solar, dejando cada vez menos espacios vacíos y creando un patrón progresivo de color más homogéneo a través de los estados de desarrollo agronómico o “stages”.

Figura 3

Imágenes procesadas del cultivo, con índices de verdor normalizados



Cada modelo informático generó sus propias configuraciones de filtrado de píxeles para el cultivo de maíz, a partir de la clasificación de sus rangos de verdor. La Fig. 4 muestra una imagen correspondiente a una etapa vegetativa temprana, caracterizada por una marcada variabilidad en el desarrollo del cultivo debido a la anegación del terreno, lo que favoreció la

competencia de malezas. Aun así, el índice de color normalizado se mantuvo estable y la segmentación del maíz conservó su coherencia visual, evidenciándose claramente en el patrón regular de los surcos. Esta imagen no solo demuestra la posibilidad de detección inmediata de problemas de manejo agronómico que son característicos de la agricultura de subsistencia en lo relativo al manejo del suelo y drenajes, sino que también demuestra la capacidad del modelo para preservar la distribución espacial del dosel de interés, logrando minimizar las interferencias asociadas a factores que afectan la captura de imágenes multiespectrales, como las sombras proyectadas por la propia cobertura vegetal, las irregularidades topográficas y la variabilidad en la reflectancia de la clorofila generada por la presencia de distintas especies de maleza.

Figura 4

Segmentación y selección de píxeles correspondientes al cultivo de maíz



Las métricas que se obtuvieron para cuantificar la efectividad de los modelos predictivos fueron:

1. “*Accuracy*” o exactitud, que indicó la proporción de predicciones correctas que el modelo realizó con base en los datos de prueba.
2. “*Precision*” o precisión, que midió la pureza de las predicciones aceptadas, descartando los falsos positivos.

3. “*Recall*” o exhaustividad, fue la métrica utilizada para evaluar la capacidad del modelo de evitar omisiones en las predicciones positivas.
4. “*F1 Score*” o media F de igual ponderación, que integró los datos de precisión y de exhaustividad en un solo indicador de desempeño.
5. “*IoU*” o intersección sobre unión de áreas, indicó el grado de coincidencia espacial entre la segmentación predicha y la máscara de referencia para la selección de píxeles.

Los resultados de cada modelo se presentan en la Tabla 1. El método básico de clasificación binaria, que no usa ningún tipo de IA, tuvo un desempeño comparativamente bajo para clasificar las áreas de cultivos según los insumos tecnológicos y las condiciones de este caso de estudio. Por su parte, el modelo de machine learning llamado Random Forest alcanzó los valores más altos de cada métrica, evidenciando una mejor capacidad para la tarea de clasificación de píxeles.

Tabla 1



Comparación de métricas de entrenamiento de los modelos de IA

Modelo	Accuracy	Precision	Recall	F1 Score	IoU
<i>Binary Threshold</i>	0.55	0.71	0.61	0.57	0.42
<i>Random Forest</i>	0.95	0.91	0.98	0.95	0.91
<i>K-Means</i>	0.73	0.82	0.40	0.54	0.36
<i>DNN</i>	0.58	0.61	0.79	0.69	0.50
<i>CNN-MobileNet</i>	0.47	0.66	0.55	0.60	0.41

Los modelos deep learning utilizados no tuvieron buenos resultados al ser probados como una posible herramienta de detección rápida, basados en la clasificación no

supervisada de K-Means. Éste último tuvo rendimientos no muy altos en la generación de máscaras, por lo cual al ser utilizadas como insumo de entrenamiento de las redes neurales DNN y CNN, estas mostraron una desventaja que no pudo ser compensada a pesar de los entrenamientos iterativos con las imágenes de los cultivos.

Las imágenes extractadas sirvieron posteriormente como entrada de un script que calculaba los índices LAI y GNDVI promedio para todas las plantaciones, pero subdivididas según los estados vegetativos del cultivo, permitiendo evidenciar el progreso en el desarrollo agronómico. La efectividad de la máscara generada por K-Means fue limitada, lo cual disminuyó la exactitud de DNN y CNN. Sin embargo, estos últimos fueron capaces de simular con cierta verosimilitud la tendencia de la curva de desarrollo foliar en función del tiempo. Con respecto al LAI, Random Forest tuvo una progresión similar, aunque más exacta que Binary Threshold (Fig. 5). En el caso del GNDVI (Fig. 6), la respuesta del pronóstico de verdor fue más consistente en función del tiempo debido a la pronta y repetida aplicación del fertilizante sulfato de amonio, que aporta dosis altas de nitrógeno y azufre para la formación de clorofila y la activación metabólica. En este caso, Random Forest y Binary Threshold mostraron las mejores predicciones, muy similares entre sí, mientras que DNN se pudo solamente imitar el patrón producido por K-Means y CNN presentó una respuesta menos coherente. Los resultados muestran cierta similitud en la tendencia de los datos generados por los modelos a lo largo de los distintos estados vegetativos de las plantas de maíz, sugiriendo una coherencia transversal entre los datos de las parcelas, a pesar de ciertos factores que podrían inducir cambios en el análisis de datos, tales como el tiempo transcurrido entre las tomas aéreas con dron, el avance del crecimiento de malezas y los cambios fisiológicos del cultivo en sus etapas tempranas, intermedias y reproductivas.

Figura 5*Predicción del desarrollo de LAI del cultivo de maíz, según distintos modelos***Figura 6***Predicción del índice GNDVI del cultivo de maíz, según distintos modelos*

DISCUSIÓN

Las imágenes multiespectrales captadas por dron de uso científico fueron sometidas al procesamiento del índice normalizado de verdor GNDVI, como recurso que habilitó la determinación del estado de salud y la progresión del desarrollo del área foliar de seis cultivos de maíz, a través de ocho etapas fenológicas. Dado que el contexto era la evaluación rápida de plantaciones en condiciones de producción tradicional enfocada en la subsistencia del agricultor, se probaron tecnologías de software que no requirieran el levantamiento exhaustivo de datos para la generación de rásteres de tipo “ground truth”. Como primera opción, se utilizó Binary Threshold, que es una técnica clásica de procesamiento de imágenes que toma como base umbrales fijos de colores normalizados para discriminar los píxeles correspondientes a áreas de interés. Como segunda opción se entrenó un modelo de Random Forest, el cual se reporta en la literatura como bien evaluado para este tipo de propósito (Du *et al.*, 2022). Random Forest obtuvo resultados de exactitud y precisión más elevados que Binary Threshold en cuanto a la identificación de los píxeles correspondientes a plantas de maíz, con respecto a los de follaje de malezas y los del suelo. Al ocupar estas imágenes segmentadas para el cálculo de los índices LAI y GNDVI que miden el desarrollo y la salud vegetal exclusivos de las plantas de maíz, los promedios generales en cada etapa agronómica fueron muy semejantes y mantuvieron la tendencia fisiológica esperada. Los resultados sugieren que el desempeño de las herramientas de OpenDroneMap para normalizar colores contribuyó a que el método simple de clasificación binaria tuviera buen desempeño (Markov *et al.*, 2025; Radócz *et al.*, 2024; Hernandez *et al.*, 2024). Sin embargo, Random Forest ofreció bordes más definidos en las imágenes segmentadas y mejor continuidad en surcos, aportando mayor confiabilidad para posibles usos cartográficos (Savitha *et al.*, 2025) o de estudio de variabilidad espacial (Xie *et al.*, 2025).

El modelo K-Means fue utilizado para generar una máscara no supervisada de pseudo ground-truth con la intención de generar una alternativa de bajo costo. Se logró obtener una buena segmentación visual de las imágenes, aunque con métricas de calidad inferiores a las de Random Forest. El posterior uso de este recurso como insumo para el entrenamiento de redes neuronales complejas como DNN y CNN+MobileNet obtuvo un rendimiento limitado en la predicción de datos de LAI y GNDVI. Se identificó que una mayor cantidad de datos y una configuración más robusta del entrenamiento podrían haber mejorado la calidad de los resultados, pero esto habría añadido más complejidad a una solución informática que buscaba ser asequible para aplicaciones de agricultura de subsistencia.

Los hallazgos del presente estudio brindan un aporte específico para la selección y articulación de un conjunto combinado de tecnologías que constituyan una herramienta integrada de apoyo al monitoreo del desarrollo de cultivos de maíz y la detección temprana de posibles problemas agronómicos, determinando la conveniencia técnica de distintos métodos de software para la extracción y análisis de datos. Este tema se ha convertido en sujeto de gran interés y distintos estudios reportan resultados comparables a pesar de poseer enfoques metodológicos diferentes (Deng *et al.*, 2024; Buthelezi *et al.*, 2023). El uso de drones para la captura de imágenes multiespectrales que permitan medir la reflectancia de clorofila como indicador de salud vegetal, resulta muy práctico pero a su vez requiere de tecnologías complementarias de software que normalicen los datos, los seleccionen adecuadamente y que permitan una evaluación rápida, confiable y de bajo costo para la obtención de datos técnicos que promuevan la toma informada de decisiones agronómicas.

CONCLUSIONES

Este estudio demostró que, al analizar cultivos de maíz bajo condiciones de producción tradicional utilizando imágenes multiespectrales con colores normalizados, el

método Binary Threshold permitió una buena representación y predicción de la tendencia fenológica de índices como LAI y GNDVI. Por su parte, Random Forest proporcionó una segmentación acertada y con buena capacidad de predicción de índices vegetativos, generando máscaras más precisas y confiables para otros usos basados en tecnologías de reconocimiento de imágenes. El rendimiento limitado de modelos DNN y CNN+MobileNet se asoció al uso de pseudoetiquetas de K-Means; mejorar la calidad de máscaras y aplicar transfer learning podría haber mejorado esa situación, pero posiblemente sin superar la practicidad y rapidez de Random Forest. Finalmente, el análisis de datos provenientes de imágenes normalizadas es posible en términos del desarrollo fenológico de cultivos a lo largo del tiempo, pero su adopción como herramienta de apoyo para la toma de decisiones en campo requiere soluciones prácticas y accesibles, para lo cual Random Forest equilibra precisión y costo.

Declaración de conflicto de interés

El autor declara no tener ningún conflicto de interés relacionado con esta investigación.

Declaración de uso de inteligencia artificial

El autor declara que utilizó la inteligencia artificial como apoyo para este artículo y para el análisis de datos, dada la temática. Sin embargo, esta herramienta no sustituye de ninguna manera la tarea o proceso intelectual. Después de rigurosas revisiones con diferentes herramientas en la que se comprobó que no existe plagio como constan en las evidencias, el autor manifiesta y reconoce que este trabajo fue producto de un trabajo intelectual propio, que no ha sido escrito ni publicado en ninguna plataforma electrónica o de IA.

REFERENCIAS

- Bolfe, L., Parreiras, C., daSilva, L., Sano, E., Maranhão, G., Victoria, C, Del'Arco, I., & Eduardo Vicente, L. (2023). Mapping Agricultural Intensification in the Brazilian Savanna: A Machine Learning Approach Using Harmonized Data from Landsat Sentinel-2. *ISPRS International Journal of Geo-Information*. <https://doi.org/10.3390/ijgi12070263>
- Buthelezi, S., Mutanga, O., Sibanda, M., Odindi, J., Clulow, A. D., Chimonyo, V. G. P., & Mabhaudhi, T. (2023). Assessing the Prospects of Remote Sensing Maize Leaf Area Index Using UAV-Derived Multi-Spectral Data in Smallholder Farms across the Growing Season. *Remote Sensing*, 15(6), 1597. <https://doi.org/10.3390/rs15061597>
- Cedric, S., Hamilton, W. Y., Aworka, R., Thouakesseh, J., Kalala, F., Krichen, M., & Mberi, C. L. (2022). Crops yield prediction based on machine learning models: Case of West African countries. *Smart Agricultural Technology*. <https://doi.org/10.1016/j.atech.2022.100049>
- Chen, J., Liu, X., Du, S., Ma, Y., Liu, L. (2021). Effects of drought on the relationship between photosynthesis and chlorophyll fluorescence for maize. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. <https://doi.org/10.1109/JSTARS.2021.3123111>
- Chen, S., Liu, W., Feng, P., Ye, T., Ma, Y., & Zhang, Z. (2022). Improving Spatial Disaggregation of Crop Yield by Incorporating Machine Learning with Multisource Data: A Case Study of Chinese Maize Yield. *Remote Sensing*. <https://doi.org/10.3390/rs14102340>
- Cheng, Q., Xu, H., Fei, S., Li, Z., & Chen, Z. (2022). Estimation of Maize LAI Using Ensemble Learning and UAV Multispectral Imagery under Different Water and Fertilizer Treatments. *Agriculture*. <https://doi.org/10.3390/agriculture12081267>

- Danilevicz, M., Bayer, P., Boussaid, F., Bennamoun, M., & Edwards, D. (2021). Maize yield prediction at an early developmental stage using multispectral images and genotype data for preliminary hybrid selection. *Remote Sensing*, 13(19), 3976.
<https://doi.org/10.3390/rs13193976>
- Darwin, B., Dharmaraj, P., Prince, S., Popescu, D. E., & Hemanth, D. J. (2021). Recognition of bloom/yield in crop images using deep learning models for smart agriculture: A review. *Agronomy*, 11(4), 646. <https://doi.org/10.3390/agronomy11040646>
- Deng, H., Zhang, W., Zheng, X., & Zhang, H. (2024). Crop Classification Combining Object-Oriented Method and Random Forest Model Using Unmanned Aerial Vehicle (UAV) Multispectral Image. *Agriculture*, 14(4), 548.
<https://doi.org/10.3390/agriculture14040548>
- DeSalvio, A., Adak, A., C. Murray, S., C. Wilde, S., & Isakeit, T. (2022). Phenomic data-facilitated rust and senescence prediction in maize using machine learning algorithms. *Scientific Reports*. <https://doi.org/10.1038/s41598-022-11591-0>
- Du, L., Yang, H., Song, X., Wei, N., Yu, C., Wang, W., & Zhao, Y. (2022). Estimating leaf area index of maize using UAV-based digital imagery and machine learning methods. *Scientific Reports*, 12, 15937. <https://doi.org/10.1038/s41598-022-20299-0>
- Guo, Y., Yin, G., Sun, H., Wang, H., Chen, S., Senthilnath, J., Wang, J., & Fu, Y. (2020). Scaling effects on chlorophyll content estimations with RGB camera mounted on a UAV platform using machine-learning methods. *Sensors*.
<https://doi.org/10.3390/s20185130>
- Hernandez, A., Bushman, S., Johnson, P., Robbins, M. D., & Patten, K. (2024). Prediction of Turfgrass Quality Using Multispectral UAV Imagery and Ordinal Forests: Validation Using a Fuzzy Approach. *Agronomy*, 14(11), 2575.
<https://doi.org/10.3390/agronomy14112575>

- Huang, S., Tang, L., Hupy, J. P., Wang, Y., & Shao, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32, 1-12. <https://doi.org/10.1007/s11676-020-01155-1>
- Hunt, E. R., Jr., Hively, W. D., Fujikawa, S. J., Linden, D. S., Daughtry, C. S. T., & McCarty, G. W. (2010). Acquisition of NIR-green-blue digital photographs from unmanned aircraft for crop monitoring. *Remote Sensing*, 2(1), 290-305. <https://doi.org/10.3390/rs2010290>
- Kim, N., Na, S., Park, C., Huh, M., Oh, J., Ha, K., Cho, J., & Lee, Y. (2020). An artificial intelligence approach to prediction of corn yields under extreme weather conditions using satellite and meteorological data. *Applied Sciences*, 10(11), 3785. <https://doi.org/10.3390/app10113785>
- Liu, J., Goering, C. E., & Tian, L. (2001). A neural network for setting target corn yields. *Transactions of the American Society of Agricultural Engineers*, 44(3), 705–710. <https://doi.org/10.13031/2013.6097>
- Markov, N., Yorgov, D., Veleva, P., Petrova, A., & Atanasova, S. (2025). Assessing the applicability of drone-mounted multispectral camera measurements to characterize wheat status during the vegetation. *AGRICULTURAL SCIENCE AND TECHNOLOGY*, 17(1), 81-86.
- Marques, A. P., Prado, L., Garcia, D. E., Nunes, W., Cordeiro, D., Ribeiro, L. P., Silva, C. A. d., Capristo, G., Li, J., Rojo, F. H., Marcato, J. & Pistori, H. (2020). A random forest ranking approach to predict yield in maize with UAV-based vegetation spectral indices. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2020.105791>
- Mndela, Y., Ndou, N., & Nyamugama, A. (2023). Irrigation scheduling for small-scale crops based on crop water content patterns derived from UAV multispectral imagery. *Sustainability*, 15(15), 12034. <https://doi.org/10.3390/su151512034>

- Mohanty, S., Ghosh, H., Rahat, I. S., & Reddy, C. V. R. (2023). Advanced deep learning models for corn leaf disease classification: A field study in Bangladesh. *Engineering Proceedings*, 3(5), 59–69. <https://doi.org/10.3390/engproc2023059069>
- Nan, F., Song, Y., Yu, X., Nie, C., Liu, Y., Bai, Y., Zou, D., Wang, C., Yin, D., Yang, W., & Jin, X. (2023). A novel method for maize leaf disease classification using the RGB-D post-segmentation image data. *Frontiers in Plant Science*. <https://doi.org/10.3389/fpls.2023.1268015>
- Nowakowski, A., Mrziglod, J., Spiller, D., Bonifacio, R., Ferrari, I., Mathieu, P. P., Garcia-Herranz, M., & Kim, D.-H. (2021). Crop type mapping by using transfer learning. *International Journal of Applied Earth Observations and Geoinformation*, 101, 102313. <https://doi.org/10.1016/j.jag.2021.102313>
- Pan, S., Qiao, J., Wang, R., Yu, H., Wang, C., Taylor, K., & Pan, H. (2022). Intelligent diagnosis of northern corn leaf blight with deep learning model. *Journal of Integrative Agriculture*, 21(1), 637–707. [https://doi.org/10.1016/S2095-3119\(21\)63707-3](https://doi.org/10.1016/S2095-3119(21)63707-3)
- Radia, B., Assia, B., Narimene, S. R., & Ali, G. (2024). Evaluation of the Biochemical and Antioxidant Behaviour of Four Species *Chenopodium quinoa* Willd, *Zea mays* L., *Triticosecale wittmack* and *Hordeum vulgare* L. Effected by Oxidative Stress Caused by Water Stress. *Basrah Journal of Agricultural Sciences*, 37(2), 113–123. <https://doi.org/10.37077/25200860.2024.37.2.10>
- Radócz, L., Juhász, C., Tamás, A., Illés, Á., Ragán, P., & Radócz, L. (2024). Multispectral UAV-Based Disease Identification Using Vegetation Indices for Maize Hybrids. *Agriculture*, 14(11), 2002. <https://doi.org/10.3390/agriculture14112002>
- Savitha, C., & Talari, R. (2025). Evaluating the performance of random forest, support vector machine, gradient tree boost, and CART for improved crop-type monitoring using

greenest pixel composite in Google Earth Engine. *Environmental Monitoring and Assessment*, 197(4), 1-25.

- Shao, G., Han, W., Zhang, H., Zhang, L., Wang, Y., & Zhang, Y. (2022). Prediction of maize crop coefficient from UAV multisensor remote sensing using machine learning methods. *Agricultural Water Management*. <https://doi.org/10.1016/j.agwat.2022.108064>
- Shuai, G., & Basso, B. (2022). Subfield maize yield prediction improves when in-season crop water deficit is included in remote sensing imagery-based models. *Remote Sensing of Environment*, 268, 112938. <https://doi.org/10.1016/j.rse.2022.112938>
- Tseng, H., Yang, M., Saminathan, R., Hsu, Y., Yang, C., & Wu, D. (2022). Rice seedling detection in UAV images using transfer learning and machine learning. *Remote Sensing*, 14(12), 2837. <https://doi.org/10.3390/rs14122837>
- Ubilava, D. & Abdolrahimi, M. (2019). The el niño impact on maize yields is amplified in lower income teleconnected countries. *Environmental Research Letters*. <https://doi.org/10.1088/1748-9326/ab0cd0>
- Xie, Y., Nhu, A. N., Song, X. P., Jia, X., Skakun, S., Li, H., & Wang, Z. (2025). Accounting for spatial variability with geo-aware random forest: A case study for US major crop mapping. *Remote Sensing of Environment*, 319, 114585.