



UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO
FACULTAD DE CIENCIAS AGRARIAS Y FORESTALES
CARRERA DE INGENIERÍA AGRÍCOLA

Trabajo de integración Curricular
previa a la obtención del Grado
Académico de Ingeniero Agrícola.

Proyecto de Investigación:

“FRACCIÓN DE COBERTURA VEGETAL EN *Zea mays* L, CON EL EMPLEO DE
IMÁGENES DIGITALES ADQUIRIDAS POR VEHÍCULO AÉREO NO TRIPULADO”

Autor:

Nadelin Solange Abeiga Cornejo

Director del proyecto de Investigación:

Ing. Edwin Miguel Jiménez Romero M.Sc.


Quevedo – Los Ríos – Ecuador

2026



INFORME FAVORABLE DEL DIRECTOR/A SOBRE LA CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN

El suscrito, **Edwin Miguel Jiménez Romero**, Docente de la Universidad Técnica Estatal de Quevedo, certifica que el estudiante **Nadelin Solange Abeiga Cornejo**, realizó el Proyecto de Investigación de grado titulado **“Fracción de cobertura vegetal en *Zea mays* L, con el empleo de imágenes digitales adquiridas por vehículo aéreo no tripulado”**, previo a la obtención del título de **Ingeniero Agrícola**, bajo mi dirección, habiendo cumplido con las disposiciones establecidas para el efecto en los Arts. 52, 54, 57 y 59 del Reglamento de la Unidad de Integración Curricular.



Ing. Edwin Miguel Jiménez Romero M.Sc.
DIRECTOR DEL PROYECTO DE INVESTIGACIÓN



DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS

Yo, Nadelin Solange Abeiga Cornejo, declaro que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Universidad Técnica Estatal de Quevedo, puede hacer uso de los derechos correspondientes a este documento, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.

Nadelin Solange Abeiga Cornejo


C.C. 0942553025



CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO

El suscrito, **Edwin Miguel Jiménez Romero**, mediante el presente cumpla en presentar a usted, el informe de proyecto de Investigación titulado **“Fracción de cobertura vegetal en *Zea mays* L, con el empleo de imágenes digitales adquiridas por vehículo aéreo no tripulado”** Presentado por el estudiante **Nadelin Solange Abeiga Cornejo**, egresado de la Carrera de Ingeniería Agrícola, que fue revisado bajo mi dirección según resolución del Consejo Directivo de la Facultad de Ciencias Agrarias y Forestales, que se ha desarrollado de acuerdo al Artículo 57 y 59 del Reglamento de la Unidad de Integración Curricular de la Universidad Técnica Estatal de Quevedo y cumple con el requerimiento de análisis del sistema COMPILATIO el cual avala los niveles de originalidad en un 93% y similitud 7%, del trabajo investigativo. Valido este documento para que el estudiante siga con los trámites pertinentes, de acuerdo como lo establece el Reglamento.

 Informe de análisis Compilatio Magister+ UTEQ-ECU	
TESIS_ABEIGA CORNEJO NADELIN SOLANGE	
ID : 950c57a4207269c434a85a1ece94119724c628d1	
7%	
Textos sospechosos	
Nombre del fichero : TESIS_ABEIGA CORNEJO NADELIN SOLANGE.txt	Depositante : EDWIN MIGUEL JIMENEZ ROMERO
Tamaño del archivo original : 108 MB	Fecha de depósito : 14 de abril de 2026
Número de palabras : 16.739	Tipo de carga : interface
Número de caracteres : 11.3127	fecha de fin de análisis : 14 de abril de 2026


Ing. Edwin Miguel Jiménez Romero M.Sc.
DIRECTOR DEL PROYECTO DE INVESTIGACIÓN



CERTIFICACIÓN DE LOS INTEGRANTES DEL TRIBUNAL

Quevedo, 11 de mayo del 2026

Ing. Francisco Espinoza Carrillo PhD

DECANO

FACULTAD DE CIENCIAS AGRARIAS Y FORESTALES

Presente

Para los trámites pertinentes remito al presente el informe favorable de consenso:

INFORME FAVORABLE

Los abajo firmantes que actuamos como Presidente y Miembros del Tribunal de la Unidad de Titulación; designada por el Consejo Directivo de la Facultad de Ciencias de Ciencias Agrarias y Forestales, tenemos a bien de **CERTIFICAR** que el Proyecto de Investigación “Fracción de cobertura vegetal en *Zea mays* L, con el empleo de imágenes digitales adquiridas por vehículo aéreo no tripulado”, Srta. Nadelin Solange Abeiga Cornejo con cédula # 0942553025, estudiante de la carrera de Ingeniería Agrícola; fue revisado por este tribunal y se encuentra aprobado y listo para su Sustentación. Dando cumplimiento a lo estipulado por el reglamento, firmo y dando fe de lo actuado, los que conformamos este tribunal.

Atentamente,

Dra. Marisol Rivero Herreda

PRESIDENTA DEL TRIBUNAL

Ing. Mauricio Renato Morejón Centeno M.Sc.

MIEMBRO DEL TRIBUNAL

Ing. Erick Alberto Eguez Enriquez M.Sc.

MIEMBRO DEL TRIBUNAL

AGRADECIMIENTO

Primeramente, quiero agradecerle a Dios por haberme dado la fuerza y por enseñarme el camino correcto de la vida, por guiarme en esta etapa más importante de mi vida estudiantil y profesional.

A la Universidad Técnica Estatal de Quevedo, que me abrió las puertas para pertenecer a esta gran familia, a los docentes cuyo conocimiento y guía en cada etapa de mi carrera, les agradezco por su paciencia, dedicación y valiosas enseñanzas.

Expreso mi más sincero agradecimiento a mi director de Tesis, el Ing. Edwin Jiménez Romero por su apoyo y su valioso aporte que hicieron posible la realización de esta investigación.

Al ingeniero Juan Antonio Torres Rodríguez por sus recomendaciones y enseñanzas que me serán de ayuda en mi vida profesional.

También agradezco a mi familia por su amor incondicional, motivación y confianza en mi capacidad para alcanzar esta meta, su respaldo ha sido mi mayor fortaleza en los momentos de desafío y aprendizaje.

A mis compañeros o amigos por brindarme su amistad y apoyo para seguir adelante, también a cada una de las personas que de una u otra forma han estado involucradas directa e indirectamente al concluir una de mis metas más anheladas.

Nadelin Solange Abeiga Cornejo

DEDICATORIA

Dedico este proyecto de Tesis a Dios que estuvo en cada paso conmigo, dándome la fortaleza necesaria para no rendirme ante los obstáculos que se me presento, sobre todo por ser mi guía en todo momento.

A mi padre, Galo Abeiga Ruiz por siempre velar por mi bienestar y educación, brindándome confianza desde el inicio hasta el final de mi carrera, con la cual he logrado el objetivo anhelado de ser una profesional.

A mi querida madre, Lenny Cornejo Macias por sus oraciones diarias, su cariño, y sobre todo por guiarme e inculcarme valores de honestidad, responsabilidad, constancia y dedicación en mi etapa estudiantil.

A mis queridos hermanos Andrea Abeiga y Ezequiel Abeiga, a mi novio Jeison Palacios por siempre brindarme su apoyo, colaboración y fortaleza, sin ellos no hubiese sido posible el poder finalizar una de mis tantas metas propuestas.

Nadelin Solange Abeiga Cornejo

RESUMEN

La estimación de la fracción de cobertura vegetal (FCV) en *Zea mays* L, mediante imágenes RGB obtenidas con VANT representa una herramienta práctica y accesible para el monitoreo del cultivo, ofrecen la posibilidad de realizar varios vuelos y cubrir grandes extensiones de terreno permitiendo la disponibilidad de datos en tiempo real. El objetivo de este estudio fue identificar el índice que presentara menor error en la extracción de la vegetación y definir el método de umbralización más adecuado para su clasificación. Se realizaron cinco vuelos entre los 18 hasta 46 días después de la siembra en el campus La María, calculando los índices ExG, NGRDI y TGI, y aplicando los métodos Otsu, IsoData, Conservación de Momentos y Fuzzy. La validación se llevó a cabo comparando la fracción de cobertura estimada (FCE) con la observada (FCO) en parcelas de 1 m², 9 m² y 36 m², mediante el error absoluto medio (EMA) y la raíz cuadrada del error cuadrático medio (RMSE). Los resultados presentaron que las combinaciones NGRDI – Otsu mostraron la mayor concordancia con la cobertura observada en campo y los menores valores de RMSE, con 14.01%. Por lo tanto, se demostró que el índice NGRDI posee una adecuada capacidad para resaltar la señal espectral de la vegetación en imágenes RGB, permitiendo una mejor diferenciación entre píxeles de vegetación y suelo.

Palabras claves: imágenes RGB, índice de vegetación, umbralización, agricultura de precisión.

ABSTRACT

Estimating the vegetation cover fraction (FCV) in *Zea mays* L, using RGB images obtained with VANT is a practical and accessible tool for crop monitoring, these images allow for multiple flights and the coverage of large areas, providing real-time data availability. The objective of this study was to identify the index with the lowest error in vegetation extraction and to define the most appropriate thresholding method for its classification. Five flights were conducted between 18 and 46 days after planting at the La María campus, the ExG, NGRDI, and TGI indices were calculated, and the Otsu, IsoData, Conservation of Moments, and Fuzzy methods were applied. Validation was performed by comparing the estimated cover fraction (FCE) with the observed cover fraction (FCO) in plots of 1 m², 9 m², and 36 m², using the mean absolute error (MAE) and the root mean square error (RMSE). The results showed that the NGRDI-Otsu combinations exhibited the greatest agreement with the observed field cover and the lowest RMSE values, at 14.01%. Therefore, it was demonstrated that the NGRDI index has an adequate capacity to highlight the spectral signal of vegetation in RGB images, allowing for better differentiation between vegetation and soil pixels.

Keywords: RGB imagery, vegetation index, thresholding, precision agriculture.

TABLA DE CONTENIDO

PORTADA	i
INFORME FAVORABLE DEL DIRECTOR/A SOBRE LA CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN	ii
DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS	iii
CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO	iv
CERTIFICACIÓN DE LOS INTEGRANTES DEL TRIBUNAL	v
AGRADECIMIENTO	vi
DEDICATORIA	vii
RESUMEN	viii
ABSTRACT	ix
TABLA DE CONTENIDO	x
ÍNDICE DE TABLAS	xiv
ÍNDICE DE FIGURAS	xv
ÍNDICE DE ANEXOS	xvi
CÓDIGO DUBLÍN	xvii
Introducción.....	1
CAPÍTULO I	3
CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN	3
1.1. Problema de investigación.....	4
1.1.1. Planteamiento del problema.....	4
Diagnóstico	4
Pronóstico	5
1.1.2. Formulación del problema	5
1.1.3. Sistematización del problema	5
1.1. Objetivos	6
1.1.1. Objetivo General	6
1.1.2. Objetivos Específicos	6
1.2. Justificación.....	6
CAPÍTULO II	7
FUNDAMENTACIÓN TEÓRICA DE LA INVESTIGACIÓN	7
2.1. Marco conceptual	8

2.1.1.	<i>Agricultura</i>	8
2.1.2.	<i>Tecnología</i>	8
2.1.3.	<i>Teledetección aplicada a la agricultura</i>	8
2.1.4.	<i>Drones</i>	9
2.1.5.	<i>Resolución espacial en imágenes VANT</i>	9
2.1.6.	<i>Biomasa aérea</i>	9
2.1.7.	<i>Índice de área foliar (LAI)</i>	10
2.1.8.	<i>Influencia del fondo del suelo</i>	10
2.2.	Marco referencial	11
2.2.1.	<i>Origen del maíz</i>	11
2.2.2.	<i>Clasificación botánica</i>	11
2.2.3.	<i>Fenología</i>	12
2.2.4.	<i>Vehículos aéreos no tripulados</i>	13
2.2.5.	<i>Imágenes RGB montadas en drones</i>	14
2.2.6.	<i>Fracción de cobertura vegetal</i>	15
2.2.7.	<i>Índice de vegetación</i>	15
2.2.7.1.	<i>Índice de verdor triangular (TGI)</i>	16
2.2.7.2.	<i>Índice de exceso verde (ExG)</i>	16
2.2.7.3.	<i>Índice de resistencia atmosférica visible (VARI)</i>	17
2.2.7.4.	<i>Índice de diferencia normalizada Verde – Rojo (NGRDI)</i>	18
2.2.8.	<i>Procesamiento y clasificación de imágenes en Matlab</i>	18
2.2.9.	<i>Métodos de umbralización</i>	19
2.2.9.1.	<i>Otsu</i>	19
2.2.9.2.	<i>IsoData</i>	20
2.2.9.3.	<i>Conservación de momentos</i>	20
2.2.9.4.	<i>Fuzzy</i>	21
	CAPÍTULO III	22
	METODOLOGÍA DE LA INVESTIGACIÓN	22
3.1.	Localización	23
3.2.	Tipo de investigación	24
3.3.	Método de investigación	24
3.3.1.	Método de observación	24
3.3.2.	Método deductivo	24
3.3.3.	Método analítico	24

3.4. Fuentes de recopilación de la información.....	24
3.4.1. <i>Fuentes primarias</i>	25
3.4.2. <i>Fuentes secundarias</i>	25
3.5. Diseño de la investigación.....	25
3.5.1. <i>Enfoque y tipo de estudio</i>	25
3.5.2. <i>Unidad de estudio y población</i>	25
3.5.3. <i>Factores de estudio y tratamientos</i>	26
3.5.3.1. <i>Índice de vegetación</i>	26
3.5.3.2. <i>Métodos de umbralización</i>	27
3.5.4. <i>Variables del estudio</i>	28
3.5.4.1. <i>Variables independientes</i>	28
3.5.4.2. <i>Variables dependientes</i>	28
3.5.4.3. <i>Co-variables</i>	28
3.5.5. <i>Diseño experimental</i>	28
3.6. Instrumentos de investigación	28
3.6.1. <i>Manejo del experimento</i>	29
3.6.1.1. <i>Limpieza y preparación del terreno</i>	29
3.6.1.2. <i>Siembra</i>	29
3.6.1.3. <i>Control de malezas</i>	29
3.6.1.4. <i>Fertilización</i>	30
3.6.1.5. <i>Control fitosanitario</i>	30
3.6.1.6. <i>Imágenes adquiridas mediante cada vuelo</i>	31
3.6.1.7. <i>Procesamiento de imágenes y generación de ortomosaicos</i>	33
3.6.1.8. <i>Estimación de la fracción de cobertura vegetal</i>	33
3.6.1.9. <i>Validación de datos de la fracción de cobertura estimada</i>	34
3.1.1. <i>Variables evaluadas</i>	35
3.1.1.1. <i>Umbrales</i>	35
3.1.1.2. <i>Error absoluto medio</i>	35
3.1.1.3. <i>Raíz cuadrática del error medio</i>	35
3.1.1.4. <i>Fracción de cobertura observada</i>	35
3.1.1.5. <i>Fracción de cobertura esperada</i>	36
3.2. Tratamientos de los datos	36
3.3. Recursos humanos y materiales	36
3.3.1. <i>Recursos humanos</i>	36

3.3.2. <i>Materiales</i>	36
3.3.2.1. <i>Material vegetal</i>	36
3.3.2.2. <i>Material de oficina</i>	37
3.3.2.3. <i>Material de campo</i>	37
CAPÍTULO IV	38
RESULTADOS Y DISCUSIÓN	38
4.1.1. <i>Desempeño de los índices de vegetación y métodos de umbralización en la extracción de la vegetación</i>	39
4.1.2. <i>Estadísticas descriptivas de umbrales y cobertura vegetal</i>	40
4.1.3. <i>Cobertura de la vegetación observada y estimada en el desarrollo del cultivo</i>	41
4.2. <i>Discusión</i>	46
CAPÍTULO V	48
CONCLUSIONES Y RECOMENDACIONES	48
5.1. <i>Conclusiones</i>	49
5.2. <i>Recomendaciones</i>	50
CAPÍTULO VI	51
BIBLIOGRAFÍA	51
6.1. <i>Bibliografía</i>	52
CAPÍTULO VII	64
ANEXOS	64
7.1. <i>Anexos</i>	65

ÍNDICE DE TABLAS

Clasificación botánica del maíz.....	12
Etapas fenológicas del cultivo de maíz.....	13
Índices de vegetación de bandas del espectro visible (RGB) calculada para la extracción de la vegetación y estimación de la fracción de cobertura vegetal	27
Clasificación de la vegetación por umbrales	27
Características agronómicas del híbrido Esplendor (<i>Zea mays</i> L).....	29
Bitácora de vuelo	32
Umbrales, error absoluto medio (EMA) y la raíz cuadrada del error cuadrático medio (RMSE) para los índices de vegetación y métodos de umbralización durante el desarrollo del cultivo	40

ÍNDICE DE FIGURAS

Evolución histórica de los vehículos aéreos no tripulados	14
Ubicación geográfica del área de estudio	23
Ortomosaico generado con imágenes capturadas con el VANT durante el desarrollo del cultivo	39
Comparación de la FCO y la FCE obtenida con el ExG bajo diferentes métodos de segmentación	42
Comparación de la FCO y la FCE obtenida con el NGRDI bajo diferentes métodos de segmentación	43
Comparación de la FCO y la FCE obtenida con el TGI bajo diferentes métodos de segmentación	44
Combinaciones con el menor error (RMSE) en la estimación de la fracción de cobertura vegetal.....	45

ÍNDICE DE ANEXOS

Recorte de ortomosaicos del sitio de estudio para cada vuelo con la herramienta de Global Mapper.	65
Digitalización manual de la Fracción observada para cada uno de los vuelos con el programa de QGIS.	65
Conteo de polígonos asociados como vegetación para una parcela de 9 m ²	66
Conteo de pixeles de la imagen binaria para el índice TGI y el método Otsu.	66
Valores de la fracción de cobertura estimada FCE mediante combinaciones de índices y métodos de umbralización por parcelas en función de los días despues de la siembra.	68

CÓDIGO DUBLÍN

Título:	Fracción de cobertura vegetal en <i>Zea mays</i> L, con el empleo de imágenes digitales adquiridas por vehículo aéreo no tripulado.
Autor (a):	Abeiga-Cornejo, Nadelin Solange
Palabras clave:	imágenes RGB, índice de vegetación, umbralización, agricultura de precisión.
Fecha de publicación:	
Editorial:	
Resumen: (hasta 300 palabras) Abstract: (hasta 300 palabras)	La estimación de la fracción de cobertura vegetal (FCV) en <i>Zea mays</i> L, mediante imágenes RGB obtenidas con VANT representa una herramienta práctica y accesible para el monitoreo del cultivo, ofrecen la posibilidad de realizar varios vuelos y cubrir grandes extensiones de terreno permitiendo la disponibilidad de datos en tiempo real. El objetivo de este estudio fue identificar el índice que presentara menor error en la extracción de la vegetación y definir el método de umbralización más adecuado para su clasificación. Se realizaron cinco vuelos entre los 18 hasta 46 días después de la siembra en el campus La María, calculando los índices ExG, NGRDI y TGI, y aplicando los métodos Otsu, IsoData, Conservación de Momentos y Fuzzy (...) Estimating the vegetation cover fraction (FCV) in <i>Zea mays</i> L, using RGB images obtained with VANT is a practical and accessible tool for crop monitoring, these images allow for multiple flights and the coverage of large areas, providing real-time data availability. The objective of this study was to identify the index with the lowest error in vegetation extraction and to define the most appropriate thresholding method for its classification. Five flights were conducted between 18 and 46 days after planting at the La María campus, the ExG, NGRDI, and TGI indices were calculated, and the Otsu, IsoData, Conservation of Moments, and Fuzzy methods were applied (...)
Descripción:	85 hojas: dimensiones, 29,7 x 21 cm.
URL:	

Introducción

Con el aumento de la población global y los recursos limitados de tierras agrícolas, la agricultura de precisión ha surgido como una solución clave para garantizar la seguridad alimentaria y el desarrollo sostenible (Zhao, 2024). Por otro lado, el uso de drones, también conocidos como vehículos aéreos no tripulados (VANT), permite un amplio campo de visión de monitoreo en la recopilación de datos en tiempo real en la producción agrícola (Guzmán-Albores et al., 2024; Zhao, 2024).

Los drones han pasado de ser utilizados como dispositivos militares y recreativos a convertirse en herramientas cruciales en múltiples sectores agrícolas debido a su calidad en la toma de imágenes previo a sistemas de seguimiento, monitoreo de parámetros en el ámbito ambiental y de sanidad vegetal (Cabrera, 2021; Khanpara et al., 2024). Por lo tanto, nos ayuda en soluciones a los retos globales, además de la falta de conocimientos que enfrentan los agricultores.

A nivel internacional, estudios en países como México, Italia y China, en cultivos de maíz (*Zea mays* L), evidencian que la integración de imágenes captadas por el uso de drones permite detectar variaciones en el crecimiento del maíz, optimizar la aplicación de fertilizantes y monitorear la eficiencia de riego, contribuyendo a la agricultura de precisión (Stroppiana et al., 2019; Marcial-Pablo et al., 2021; Niu et al., 2021). Por otro lado, García-Martínez et al. (2020) al implementar el uso de drones logran evaluar parámetros en la vegetación como el vigor de las plantas, densidad, índice de área y rendimiento, mediante el empleo de sensores RGB bandas (rojo-verde-azul).

Además, los VANT presentan ciertos beneficios, entre ellos: i) no tener un piloto a bordo; ii) poder modificar la altitud de vuelo o la distancia focal; iii) volar en condiciones de cielo nublado; y iv) ser capaces de instalar distintos sensores (Stroppiana et al., 2019). Debido a que ofrecen la posibilidad de realizar varios vuelos y cubrir grandes extensiones de terreno, programar el momento óptimo para cada estudio de cultivo y obtener imágenes capturadas de alta resolución espacial a un costo reducido (Ríos-Hernández, 2021).

Actualmente debido a la limitada implementación en drones dentro de la localidad de Quevedo, se han realizado investigaciones en el campo agrícola explorando el uso de VANT

en cultivos como el banano Cedeño (2024) y maíz (Navia, 2019) dando a conocer los beneficios en el monitoreo no destructivo en recopilación de datos más detallados, preciso y con mayor frecuencia. Zhang et al. (2021); García-López y Hernández (2023) indican que el cultivo de maíz por ser uno de los principales cultivos a nivel mundial, ha sido objeto de múltiples estudios que busca mejorar su manejo mediante técnicas de agricultura de precisión.

El proceso de la fracción de cobertura vegetal (FCV) en un área determinada es un parámetro de importancia de relación entre el área de vegetación proyectada verticalmente en elementos vegetales, como copas, brotes, hojas y coronas y el área objetivo (Choi et al., 2016; Song et al., 2017). Esta proyección permite cuantificar la proporción del terreno que se encuentra cubierto por vegetación, expresada como fracción o porcentaje del área de referencia (Choi et al., 2016; García-Martínez et al., 2020).

El presente trabajo de investigación se realizó con el objetivo de estimar la fracción de cobertura vegetal en el cultivo de maíz (*Zea mays* L) con el empleo de imágenes digitales adquiridos por vehículos aéreos no tripulados, para determinar el índice que presente menor error en la extracción de la vegetación y el método de umbralización que clasifique mejor la vegetación, así como el comportamiento de la fracción de cobertura en el cultivo.

CAPÍTULO I
CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN

1.1. Problema de investigación

1.1.1. Planteamiento del problema

Presente a la adopción tecnológica de drones en la agricultura de precisión, se considera lenta debido a una combinación de barreras técnicas, desafíos de altos costos de adquisición, la falta de capacitación técnica entre los agricultores, a pesar de que las aplicaciones de los drones a la agricultura son vastas y están en constante evolución (Nagel, 2012; Guebsi et al., 2024). La implementación de nuevas tecnologías trae consigo desafíos vinculados a su evolución e innovación, lo que genera un incremento en los costos dentro de los distintos procesos productivos y exige una adaptación constante para mantener la eficiencia operativa (Buenrostro, 2022; Morales y Ojeda, 2024).

Debido a los desafíos globales, la heterogeneidad de suelos y condiciones climáticas, la tecnología de algoritmos de análisis de imágenes RGB se utiliza eficazmente en el análisis del suelo y la vegetación, ya que requiere del uso de drones para proporcionar datos precisos, en menor tiempo para la toma de decisiones agronómicas (Álava et al., 2024; Guebsi et al., 2024). La estimación remota de la FCV dependía de vuelos costosos y de imágenes satelitales con limitaciones, pero recientemente los drones ofrecen una alternativa más accesible y eficiente (Marcial-Pablo et al., 2019).

Diagnóstico

El aporte de drones en la agricultura de precisión se está fomentando de manera lenta debido a las limitaciones técnicas, los costos considerables previos y la ausencia de formación entre los productores, lo cual obstaculiza su incorporación en sistemas agrícolas convencionales. Aunque tiene el potencial de optimizar decisiones agronómicas y mejorar el monitoreo de cultivos, todavía existen desafíos asociados a la complejidad operativa, a la adaptación a nuevas herramientas digitales y a la variabilidad ecológica que requiere técnicas más ágiles y precisas. Esta situación resalta la importancia de contar con tecnologías accesibles, como el análisis de imágenes RGB, que faciliten una estimación eficaz y confiable de parámetros cruciales, incluyendo la proporción de cobertura vegetal.

Pronóstico

El empleo de drones se convertirá en una herramienta crucial para la gestión del cultivo de maíz si se optimizan los procesos de capacitación, se incorporan algoritmos más exactos para el procesamiento de imágenes RGB y se disminuyen los costos tecnológicos. Se prevé que en el transcurso de los años la estimación de la fracción de cobertura vegetal a través del VANT se convierta en un estándar para la toma de decisiones, lo cual optimizará los insumos, incrementará la productividad y facilitará resultados más ágiles ante cambios fitosanitarios o climáticos. Esto fomentará una adopción más amplia de la tecnología y convertirá los sistemas agrícolas en prácticas más eficientes y sostenibles.

1.1.2. Formulación del problema

¿Cuál índice de vegetación basado en imágenes RGB y el método de umbralización nos permiten obtener la estimación más precisa de la fracción de cobertura vegetal en cultivos de *Zea mays* L, mediante datos adquiridos por un vehículo aéreo no tripulado?

1.1.3. Sistematización del problema

- ¿Qué índice de vegetación basado en sensores RGB presenta el menor error en la extracción de la vegetación del cultivo de maíz?
- ¿Qué método de umbralización ofrece la mejor clasificación de la vegetación en las imágenes adquiridas por dron?

1.1. Objetivos

1.1.1. *Objetivo General*

Estimar la fracción de cobertura vegetal en *Zea mays* L, con el empleo de imágenes digitales adquiridos por vehículos aéreos no tripulados.

1.1.2. *Objetivos Específicos*

- Determinar el índice que presenta menor error en la extracción de la vegetación.
- Definir el método de umbralización que clasifique mejor la vegetación.

1.2. Justificación

Esta investigación es de suma importancia debido a que la agricultura de precisión ha transformado el manejo agrícola al emplear drones accesibles y fáciles de gestionar. Este fenómeno ha facilitado conseguir información con una resolución espacial y temporal muy alta, lo que optimiza la toma de decisiones y refuerza el acopio y análisis de datos que promueven soluciones detalladas y útiles para cada tipo de cultivo.

El estudio tiene como objetivo de aplicar un método tecnológico para la estimación de la fracción de cobertura vegetal en el cultivo de maíz, mediante el uso de imágenes digitales obtenidas por VANT. Debido a la trascendencia del maíz como cultivo estratégico en la seguridad alimentaria y la necesidad de monitorear su desarrollo en tiempo real, el uso de drones permite optimizar la toma de decisiones agronómicas, detectar anomalías a tiempo y mejorar el manejo del cultivo.

Mediante la estimación de la FCV con el empleo de índices de vegetación en diferentes longitudes de ondas, a través de vehículos aéreos no tripulados con sensores RGB, implica una ventaja en costos o recursos económicos y técnicos a comparación del empleo de sensores multiespectrales o hiperespectrales.

CAPÍTULO II
FUNDAMENTACIÓN TEÓRICA DE LA INVESTIGACIÓN

2.1. Marco conceptual

2.1.1. Agricultura

La agricultura es un ámbito de la economía que integra todas las actividades enfocadas en cultivar la tierra y manejar el suelo fértil con el objetivo de producir alimentos (Sánchez et al., 2024). Además, la agricultura urbana tiene un impacto en la estructura social al transformar de qué manera las personas emplean su tiempo, aprenden a llevar a cabo prácticas productivas y se integran en redes de la comunidad (Fonseca-Carreño y Bossa-Pabon, 2022).

2.1.2. Tecnología

En griego, la palabra "tecnología" es una combinación de "tekne", que se traduce como arte o técnica, y "logia", que significa destreza sobre algo (Sánchez et al., 2024). La tecnología agraria puede beneficiarse del uso de tecnologías inteligentes cuando los productores cuentan con conocimientos, experiencia, capacitación, infraestructura y recursos económicos que les permitan aplicar la ciencia y la tecnología de manera práctica e innovadora en sus actividades productivas (Kovács y Husti, 2018; Vargas-Canales, 2022). Hoy en día, estas tecnologías están transformando la agricultura y se han vuelto clave para enfrentar los retos del sector, ya que permiten a los agricultores conocer mejor sus campos mediante el uso de datos, GPS, sensores e IoT, facilitando el monitoreo del suelo, el clima y la salud de los cultivos en tiempo real y mejorando la toma de decisiones productivas (Yanog, 2024).

2.1.3. Teledetección aplicada a la agricultura

Los sistemas de teledetección generan grandes volúmenes de datos espectrales debido a sus altas resoluciones temporal, espacial, radiométrica y espectral, necesarias para aplicaciones de agricultura de precisión (AP) (Huang et al., 2018). Según Mulla (2013) la teledetección en la agricultura de precisión inició con sensores de materia orgánica del suelo y evolucionó rápidamente hacia el uso de sensores satelitales, aéreos y portátiles o integrados en maquinaria agrícola. Los sistemas de teledetección en agricultura de precisión se clasifican

según la plataforma y el tipo de sensor, donde la resolución espacial está determinada por el tamaño del píxel que representa el área del terreno (Sishodia et al., 2020).

2.1.4. Drones

Un dron es un vehículo aéreo no tripulado (VANT, por sus siglas en español), se controlan remotamente (tipo joystick) o por medio de aplicaciones para dispositivos inteligentes o tabletas para procesar datos e imágenes de alta resolución sobre el terreno y los cultivos (Ríos-Hernández, 2021). En agricultura, los drones permiten un monitoreo remoto rápido y eficiente para generar mapas de cobertura, estimar biomasa y detectar estrés hídrico o nutricional, optimizando el uso de insumos y mejorando la precisión en la toma de decisiones mediante métodos no destructivos (Buitrago et al., 2024).

2.1.5. Resolución espacial en imágenes VANT

La resolución espacial se define como el tamaño del área que corresponde al tamaño de la mínima unidad distinguible en una imagen y está directamente relacionada con el tamaño del píxel y la escala de representación (Tristán et al., 2005). Por lo tanto Ordóñez-Prado et al. (2024) detalla que a mayor resolución espacial, el píxel representa con mayor precisión una sola cubierta, mientras que píxeles grandes combinan varias coberturas y dificultan la interpretación de la imagen; también nos explica que aunque las imágenes de alta resolución son cada vez más accesibles, existen pocos estudios sobre el efecto de la resolución espacial en la detección de la vegetación, especialmente en imágenes de drones con resolución submétrica.

2.1.6. Biomasa aérea

La biomasa aérea (BPA), es un indicador clave de los agroecosistemas, ya que refleja el crecimiento y la productividad del cultivo, permite predecir rendimientos y eficiencia en el uso del agua, por lo que su estimación es rápida y precisa (Walter et al., 2018; Niu et al., 2019). Además, las revisiones sobre teledetección para monitorear la biomasa de cultivos son escasas y se centran principalmente en sensores satelitales, mientras que el uso de VANT se aborda de forma limitada (Chao et al., 2019). Por otro lado, Grijalva (2022) menciona que la biomasa aérea es un parámetro clave en la evaluación de sistemas pastoriles, ya que refleja

el crecimiento vegetal y se relaciona con el aprovechamiento de la energía solar, el rendimiento productivo y la calidad de la semilla.

2.1.7. *Índice de área foliar (LAI)*

El índice de área foliar (LAI) se define como la relación entre el área total de hojas y el área de suelo que estas cubren, siendo un parámetro clave del funcionamiento del dosel vegetal (Bréda, 2003; Zhou et al., 2025). También se lo define como un indicador del crecimiento, altura, densidad y medidas geométricas de referencia específicas y rendimiento de los cultivos (Buitrago et al., 2024), el LAI puede estimarse indirectamente mediante índices de vegetación obtenidos a partir de imágenes capturadas por drones (Song et al., 2017; García-Martínez et al., 2020). Por lo otro lado, Gutieres et al. (2023) determinan que una de las principales dificultades para estudiar el índice de área foliar en áreas naturales es la complejidad de realizar mediciones en campo, debido a la logística, el traslado de equipos y el acceso limitado a zonas forestales o propiedades privadas.

2.1.8. *Influencia del fondo del suelo*

La influencia del fondo del suelo en la teledetección se entiende como el impacto que tienen características del suelo, como su color, textura o contenido de materia orgánica, sobre la señal que captan los sensores al observar la vegetación, lo que puede afectar la forma en que se interpretan los índices, parámetros que describen el estado y el crecimiento de los cultivos (Prudnikova et al., 2019). Según Zhao et al. (2025) al realizar el análisis espectral de una escena es fundamental separar o modelar la señal proveniente de la vegetación y del suelo, ya que esta diferenciación permite obtener estimaciones más confiables de la cobertura vegetal y de los índices biofísicos utilizados para describir su estado y desarrollo. Para ello, el modelo de píxeles dimidiados asume que cada píxel es una mezcla de suelo y vegetación en diferentes proporciones, permitiendo reducir la influencia del suelo y obtener estimaciones más precisas del estado real de la vegetación (Ding et al., 2016).

2.2. Marco referencial

2.2.1. Origen del maíz

El maíz (*Zea mays* L) es uno de los cultivos más antiguos y de mayor importancia en la agricultura, su origen se remonta a Mesoamérica, principalmente a la región que hoy corresponde a México, hace aproximadamente 8000 a 600 a.C (Acosta, 2009; Prado, 2023). Desde entonces, se convirtió en un alimento básico para las civilizaciones humanas como para los animales, expandiéndose hacia el resto del continente americano, adaptándose a diferentes condiciones climáticas y edáficas (Moustafa, 2024).

Las propiedades anteriores del género *Tripsacum* provenían de: 1) una forma de maíz silvestre; 2) un teocintle silvestre; 3) un antepasado desconocido (ni maíz silvestre ni teocintle), cada teoría se basa en varios campos de investigación para deducir su evidencia, incluyendo la citogenética, la morfología, la taxonomía, la arqueología y los análisis bioquímicos, isoenzimáticos y moleculares (Acosta, 2009).

2.2.2. Clasificación botánica

El maíz es una gramínea anual de porte alto que puede alcanzar entre 2 y 4 metros de altura, dependiendo de la variedad y de las condiciones de cultivo; su tallo es cilíndrico y macizo, las hojas son alargadas con nervaduras paralelas, y presenta inflorescencias masculinas en la parte superior (espiga) e inflorescencias femeninas en la parte media (mazorca) (Gómez, 2024; Mascorro-De Loera et al., 2024).

Esta clasificación lo ubica dentro de las monocotiledóneas, caracterizadas por la presencia de una sola hoja embrionaria, raíces fasciculadas y hojas con nervaduras paralelas, dentro del género *Zea*, el maíz cultivado (*Zea mays* L) es la especie más difundida y domesticada, y presenta una amplia variabilidad genética que ha permitido desarrollar híbridos y variedades adaptadas a distintas condiciones agroecológicas en todo el mundo (Fuentes, 2021).

Tabla 1*Clasificación botánica del maíz*

Reino	Plantae
División	Magnoliophyta
Subdivisión	Pterapsidae
Clase	Liliopsida
Subclase	Monocotiledóneas
Orden	Poales
Familia	Poaceae
Subfamilia	Panicoideae
Género	<i>Zea</i>
Especie	<i>mays</i> L.

FUENTE: Acosta (2009); Prado (2023)

2.2.3. Fenología

El ciclo fenológico del maíz se divide en dos fases, 1) fase vegetativa comprende la emergencia, el desarrollo de hojas, el crecimiento del tallo y la diferenciación floral; durante este período la planta establece su estructura y capacidad fotosintética, 2) fase reproductiva inicia con la emisión de la espiga (flor masculina), seguida de la aparición de los estigmas o “pelos de elote” en la mazorca (flor femenina); posteriormente se da la polinización, fecundación, formación y llenado de granos, hasta llegar a la madurez fisiológica (Qin et al., 2024; Yao et al., 2024).

Tabla 2*Etapas fenológicas del cultivo de maíz*

Estados vegetativos	Estados reproductivos
VE emergencia	R1 sedas
V1 primera hoja	R2 ampolla
V2 segunda hoja	R3 Grano lechoso
V3 tercera hoja	R4 Grano pastoso
V(n) enésima hoja	R5 dentado
VT panoja	R6 madurez fisiológica


FUENTE: Prado (2023)

2.2.4. Vehículos aéreos no tripulados

Los drones, también llamados VANT (vehículos aéreos no tripulados), se han vuelto fundamentales en diversas áreas, incluyendo la agricultura, se utilizan para obtener información sobre la cobertura terrestre, equipados con cámaras RGB permiten la captura de imágenes y videos de alta resolución que revelan características no visibles a simple vista (Ríos-Hernández, 2021). Aunque su uso en este campo aún está en etapas iniciales, el cambio climático y el crecimiento demográfico han llevado a los agricultores a adoptar drones para mejorar el monitoreo de cultivos permitiendo evaluar los campos de maíz al inicio de la temporada a través de técnicas de aprendizaje automático, el algoritmo realiza tareas como contar plantas, identificar áreas de maleza y evaluar el estado de salud de las plantas (Rachmawati et al., 2021). Esta información apoya la toma de decisiones para aumentar la productividad y optimizar recursos.

Figura 1

Evolución histórica de los vehículos aéreos no tripulados



FUENTE: (Cuerno et al., 2016; Ruiz, 2023)

Los drones son sistemas aéreos que operan sin un piloto a bordo, pudiendo ser controlados a distancia o volar de forma autónoma, se componen del equipo, los sistemas de comunicación y el personal necesarios para su operación. Sus herramientas de teledetección son muy versátiles, lo que facilita su aplicación en diversos ámbitos de la agricultura (Hassler y Baysal-Gurel, 2019). Permiten realizar mapeos aéreos de alta resolución espacial de manera ágil mediante su patrón de vuelo, ofrecen una cobertura superior en áreas donde otras tecnologías de percepción remota presentan limitaciones, ya sea por sus elevados costos de operación y adquisición, o por las restricciones de tiempo y vuelo (Aslan et al., 2022).

2.2.5. Imágenes RGB montadas en drones

La evaluación y el monitoreo de la biodiversidad a menudo recurren a tecnologías avanzadas como las cámaras multispectrales o los sensores LiDAR para caracterizar la estructura del hábitat, a pesar de su elevado costo (Li et al., 2020). Estas herramientas permiten obtener generación de nubes de punto, el mapeo de cultivos, hasta la correlación con índices de vegetación calculados a partir de imágenes multispectrales (Martínez y Escolá, 2023). Por otra parte, las cámaras RGB instaladas en vehículos aéreos no tripulados (VANT) se posicionan como una alternativa prometedora y más económica, que permiten al productor

en cierta área tener la disponibilidad constante de datos de las coberturas de suelo y vegetación.

Las imágenes aéreas RGB adquiridas con drones son adecuadas para la estimación del área y volumen de la copa de especies vegetales; Pacheco Gil et al. (2023) mediante el uso de imágenes RGB obtuvieron un procesamiento fotogramétrico de alta precisión lo que facilitó la creación de productos topográficos detallados como ortomosaicos y nubes de puntos 3D; al procesar las imágenes en el software PIX4Dmapper, no solo mejoraron la calidad de los datos, sino que también permitieron la clasificación efectiva de la cobertura del suelo y la estimación precisa de la altura del dosel del cultivo.

2.2.6. *Fracción de cobertura vegetal*

La fracción de cobertura vegetal (FCV) se define como la proporción del suelo cubierto por vegetación verde activa en relación con el área total observada (García-Martínez et al., 2020). La fracción de cobertura vegetal, se calcula como proporción de píxeles clasificados como vegetación y suelo; Gao et al. (2020) la consideran una métrica robusta para monitorear la cantidad de vegetación verde en una superficie y es un indicador esencial de la sanidad vegetal, la biomasa disponible y la estructura del ecosistema, se emplea con frecuencia en modelos climáticos, en investigaciones sobre erosión y para monitorear tierras de pastizales y agrícolas.

Según, Xiao y Moody (2005) se puede obtener la FVC a través de técnicas de teledetección: 1) por medio de índices de vegetación y funciones lineales o no lineales, que vinculan el NDVI con la fracción vegetal; 2) a través del análisis espectral de mezcla (spectral unmixing), que descompone el píxel en endmembers (vegetación, suelo, sombra); o 3) mediante segmentación y clasificación directa de imágenes (VANT/ortofotos).

2.2.7. *Índice de vegetación*

Los índices de vegetación se conceptualizan como parámetros derivados de mediciones de reflectancia en diversas longitudes de onda, con el propósito de extraer información inherente a la vegetación (Gilabert et al., 1997). Los índices de vegetación (IV) han demostrado ser herramientas de gran éxito en la evaluación y monitoreo de diversos atributos

de la vegetación, incluyendo su estado fisiológico, densidad de follaje, cobertura del suelo, fases fenológicas y procesos biofísicos asociados a la fracción de radiación activa fotosintética absorbida por la vegetación (fPAR) (Gitelson et al., 2002; Huete et al., 2011).

Los índices de vegetación nos permiten diferenciar entre distintos tipos de cobertura del suelo, como el suelo desnudo y la vegetación, cuando se presentan valores bajos en estos índices sugieren una vegetación poco saludable o escasa, mientras que valores altos indican una vegetación densa y vigorosa (Muñoz, 2013). En el estudio de Li et al. (2025) evaluaron la clasificación de especies arbóreas, extrayendo índices de vegetación RGB de los cuales se mostraron una aportación de categorización exacta de las especies arboledas, relacionado con los IV obtenidos de las imágenes capturadas por el VANT mostrando una correlación con factores del crecimiento y desarrollo de las plantas, tales como el cierre del dosel, la densidad, el índice de área foliar, la biomasa y el rendimiento.

2.2.7.1. *Índice de verdor triangular (TGI).*

El Índice de Verdor Triangular (TGI, Triangular Greenness Index) se define en base a combinaciones lineales de los valores RGB de la imagen capturada por el vehículo aéreo no tripulado, está orientado a estimar el contenido de clorofila en las hojas mediante bandas visibles (Hunt et al., 2013). Además, el índice nos permite detectar cambios en la pigmentación del follaje y la evaluación de la sanidad vegetal en cultivos como maíz y arroz; estudios recientes con el uso de VANT del vigor foliar nos muestra buena correlación con los contenidos de clorofila y variaciones dentro del campo en fases vegetativas (Radočaj et al., 2023). El índice se calcula de la siguiente manera:

$$TGI = R_{verde} - 0.39 R_{rojo} - 0.61 R_{azul}$$

Gerardo y De Lima (2023) mencionan que el TGI en el monitoreo de cultivo de arroz mediante la aplicación de VANT ofrece una respuesta coherente a la variabilidad espacial dentro de las parcelas y fue comparado con otros índices como VARI y MCARI1; aunque su rango de valores suele ser más estrecho, las variaciones relativas del TGI reflejan diferencias en pigmentación y vigor entre zonas del mismo cultivo.

2.2.7.2. *Índice de exceso verde (ExG).*

El Índice de Exceso Verde (ExG, Excess Green Index) es ampliamente utilizado en aplicaciones agrícolas con imágenes RGB porque resalta los píxeles de vegetación de manera robusta, incluso frente a condiciones variables de iluminación, está diseñado para potenciar la señal verde frente a la roja y azul (Wei et al., 2022; Machado Guimarães et al., 2025). Por otro lado, el ExG es sensible al contenido de clorofila de los cultivos, valores altos indican una vegetación vigorosa, mientras que los valores bajos indican estrés o una vegetación dañada (Patrignani y Ochsner, 2015). El índice se calcula de la siguiente manera:

$$ExG = 2 * r - g - b$$

Donde:

$r = \text{Red} / (\text{Rojo} + \text{Verde} + \text{Azul})$

$g = \text{Green} / (\text{Rojo} + \text{Verde} + \text{Azul})$

$b = \text{Blue} / (\text{Rojo} + \text{Verde} + \text{Azul})$

Según, Wei et al. (2022) la sensibilidad de ExG a la intensidad verde lo convierte en un indicador confiable y eficaz para discriminar vegetación frente a suelo por medio de procesos de clasificación y seguimiento del ciclo del cultivo. Torres-Sánchez et al. (2015) considera que ExG es ideal para aplicaciones prácticas y agrícolas por su fácil acceso y precisión media.

2.2.7.3. *Índice de resistencia atmosférica visible (VARI).*

El Índice de Resistencia Atmosférica Visible (VARI, Visible Atmospherically Resistant Index) permite reducir el efecto de variaciones atmosféricas en imágenes RGB, como bruma, sombras o iluminación desigual. Al incorporar la banda azul en el denominador, VARI logra mayor robustez frente a condiciones variables y brinda estimaciones más estables de cobertura vegetal en ambientes con interferencias atmosféricas (Wijayanto et al., 2020; Radočaj et al., 2023). El índice se calcula de la siguiente manera:

$$VARI = \frac{R_{rojo} - R_{verde}}{R_{verde} + R_{rojo} - R_{azul}}$$

De acuerdo con Kaufman y Tanre (1992); Ramírez et al. (2020) el VARI es un modelo que mejora la clasificación en imágenes RGB, es decir, organiza eficientemente la información espectral de las bandas azul, verde y rojo.

2.2.7.4. *Índice de diferencia normalizada Verde – Rojo (NGRDI).*

El Índice de Diferencia Normalizada Verde – Rojo (NGRDI, Normalized Green–Red Difference Index) destaca cambios en el contenido de clorofila y presenta una alternativa económica a NDVI cuando solo se dispone de cámaras RGB (Motohka et al., 2010; Nieto Pisco et al., 2022). El índice se calcula utilizando la reflectancia de las bandas verde y roja de la imagen capturada por el VANT (Piedad Rubio et al., 2020):

$$NGRDI = \frac{R_{verde} - R_{rojo}}{R_{verde} + R_{rojo}}$$

Este índice permite estimar la biomasa generada y evaluar el estado nutricional de los cultivos a partir de imágenes captadas con cámaras RGB. Además, facilita la diferenciación de la vegetación frente a otras coberturas presentes en el área analizada (Pádua et al., 2018).

2.2.8. *Procesamiento y clasificación de imágenes en Matlab*

La plataforma MATLAB (Mathworks, Massachusetts, EE. UU) es ampliamente utilizada para procesar imágenes multiespectrales derivadas de plataformas VANT, incluyendo pasos clave como la corrección radiométrica y la calibración de reflectancia; la imagen raw se transforma mediante la multiplicación de cada píxel por un valor de corrección específico por banda espectral; este procedimiento genera una imagen hiperespectral corregida que posteriormente permite el cálculo de los índices de vegetación (Aliane et al., 2022).

La fracción de cobertura vegetal con el uso del programa MATLAB ofrece herramientas como el uso de álgebra matricial para aplicar operaciones píxel a píxel en capas espaciales, el cálculo de NDVI se realiza con una sola expresión aritmética que crea una matriz con valores normalizados del índice; a partir de dicha matriz se implementa una umbralización calcular la diferencia entre el valor del canal de infrarrojo cercano (NIR) y el del canal rojo, y luego normalizarla dividiéndola por la suma de ambos valores para ayudar a equilibrar los

efectos de la iluminación irregular, como las sombras de nubes o colinas, generar una imagen binaria que clasifique la vegetación y suelo (Santa-María et al., 2021; MathWorks, 2025).

En MATLAB, las variables pueden almacenar diferentes tipos de información sin necesidad de declarar previamente un tipo de dato, a diferencia de otros lenguajes de programación. Cada variable debe iniciar con una letra, y los caracteres siguientes pueden incluir letras, números o guiones bajos (García, 2008).

2.2.9. Métodos de umbralización

La umbralización convierte los índices de vegetación en mapas binarios clasificados en suelo o vegetación, son técnicas fundamentales en el procesamiento digital de imágenes, utilizadas para segmentar regiones de interés, como la vegetación en imágenes VANT, mediante la clasificación de píxeles según su intensidad (Gómez y Martínez, 2019). Los umbrales se aplican comúnmente para separar áreas de vegetación activa del suelo desnudo o zonas degradadas el cual consiste en definir un valor umbral a partir de la clasificación de cada píxel como perteneciente a una clase (vegetación) o (suelo), permitiendo así la generación de mapas binarios que representan la fracción de cobertura vegetal en una superficie determinada.

Para determinar si un píxel pertenece a una clase u otra, se compara su valor con un umbral denominado T ; si el valor del píxel es mayor que este umbral, se clasifica como parte del objeto; en caso contrario, se considera parte del fondo (García y Sigut, 2018). Su fórmula es la siguiente:

$$g(x, y) = \begin{cases} 1, & f(x, y) > T; \text{hace parte del objeto} \\ 0, & f(x, y) \leq T; \text{hace parte del fondo} \end{cases}$$

2.2.9.1. Otsu.

El método de Otsu es una técnica automática de umbralización que selecciona el umbral óptimo maximizando la varianza entre clases, segregando de forma eficiente las áreas de vegetación y suelo desnudo en imágenes de teledetección (Huang et al., 2021). Es ampliamente utilizado en estudios con VANT para extraer cobertura vegetal, debido a su

simplicidad, objetividad y capacidad de procesamiento por lotes en grandes volúmenes de datos. No obstante, López-Portilla et al. (2016) detalla que el cálculo realizado con este método exige numerosas operaciones aritméticas complejas y repetitivas, como la división y la multiplicación, que no favorecen una ejecución rápida y eficiente en términos de recursos.

La umbralización adaptativa mediante el método de Otsu se basa en un análisis de varianza para identificar un valor umbral óptimo que se ajusta a las condiciones específicas de la imagen, considerando los niveles de luminosidad y el tamaño de los objetos presentes en el área principal. Este umbral permite segmentar la imagen de forma eficiente al minimizar la varianza intra-clase, es decir, la diferencia entre los grupos de píxeles clasificados como fondo (negros) y objeto (blancos) (Niño-Rondón et al., 2021).

2.2.9.2. *IsoData.*

El algoritmo IsoData es un método iterativo que ajusta umbrales segmentando el histograma en dos clases hasta lograr la estabilización del valor umbral según la media de cada clase. En estudios de detección de daños en cultivos de avena, se utilizó junto con Otsu y Fuzzy thresholding como parte de una combinación que mejora la precisión global de segmentación (Macedo-Cruz et al., 2025).

El estudio de Ruggeri et al. (2021) evidenció que la utilización del algoritmo IsoData además del OBIA (Object-Based Image Analysis) optimizó la categorización no supervisada del uso y cobertura del suelo usando imágenes Landsat-8; las investigaciones indicaron que esta perspectiva optimizada mejoró de manera importante la exactitud temática en relación con los métodos de clasificación convencionales, reduciendo la confusión entre clases espectralmente parecidas y adaptándose de manera más efectiva a la diversidad espacial de las coberturas.

2.2.9.3. *Conservación de momentos.*

El método de conservación de momentos (moment-preserving thresholding) busca un umbral que preserve los momentos estadísticos del histograma de la imagen original (media,

varianza, sesgo), lo que garantiza una segmentación con menor pérdida de información estructural (Harrak et al., 2025).

Mediante la investigación de García-Martínez et al. (2020) mostraron que el método de umbralización por conservación de momentos es útil para calcular la proporción de cobertura vegetal en maíz, sobre todo en las fases iniciales del cultivo; aunque su exactitud puede disminuir en etapas avanzadas debido a la mayor presencia de sombras y de píxeles mixtos que dificultan la clasificación de las imágenes RGB de alta resolución obtenidas por el dron.

2.2.9.4. *Fuzzy.*

La umbralización Fuzzy se basa en la teoría de conjuntos difusos, asignando grados de pertenencia a cada píxel en lugar de decisiones binarias estrictas, utiliza integrales borrosas para determinar umbrales locales que se adaptan a variaciones de iluminación y texturas, logrando una segmentación más robusta que técnicas clásicas (Bardozzo et al., 2021).

Macedo-Cruz et al. (2025) detalla en su estudio que las aplicaciones agrícolas no supervisadas como la detección de daños por heladas en avena, la fusión de umbralización Fuzzy con Otsu e IsoData ha demostrado mejorar los resultados de clasificación al mitigar errores asociados a condiciones de iluminación y variabilidad espectral.


CAPÍTULO III
METODOLOGÍA DE LA INVESTIGACIÓN

3.1. Localización

El área de estudio se localiza en la Universidad Técnica Estatal de Quevedo, Campus La María, km 7 ½ de la vía Quevedo – El Empalme, Cantón Mocache, Provincia de Los Ríos, con coordenadas UTM 17S, X: 666778; Y: 9880125; altitud de 74 m.s.n.m. La investigación se realizó en un cultivo de maíz (*Zea mays* L) con el híbrido Esplendor, en una superficie de 1,4 ha; que presenta una población del cultivo 125.000 plantas ha⁻¹.

Figura 2

Ubicación geográfica del área de estudio



ELABORADO: AUTOR

Nota. Ubicación geográfica del sitio de estudio en diferentes escalas: a. Ubicación a nivel provincial dentro del territorio nacional; b. Delimitación a escala cantonal, correspondiente al cantón Mocache; c. Localización específica del sitio experimental dentro del Campus La María, ortofotografía aérea.

3.2. Tipo de investigación

Este estudio se desarrolló como una investigación experimental y aplicada en el campo de la teledetección agrícola, con el propósito de evaluar y mejorar métodos para estimar la fracción de cobertura vegetal en el cultivo de maíz. Para ello, se trabajó con imágenes de alta resolución tomadas mediante un dron equipado con un sensor RGB, en condiciones de campo controladas, analizando el desempeño de diferentes índices de vegetación y técnicas de umbralización para diferenciar suelo y vegetación. Además, el trabajo tiene un enfoque longitudinal, ya que evalúa la evolución de la cobertura vegetal a lo largo del ciclo del cultivo, y comparativo, al contrastar diferentes técnicas mediante indicadores estadísticos de error, con el propósito de identificar el método más preciso y confiable.

3.3. Método de investigación

3.3.1. Método de observación

Se utilizó para la recolección de datos de campo y en la validación de resultados, mediante la identificación visual y la digitalización manual de la cobertura vegetal en los ortomosaicos, considerada como fracción de cobertura observada (FCO).

3.3.2. Método deductivo

Se aplicó a partir de fundamentos teóricos de la teledetección y del procesamiento digital de imágenes para evaluar la aplicación de los índices de vegetación y algoritmos de segmentación en la estimación de la fracción de cobertura vegetal.

3.3.3. Método analítico

Se utilizó para descomponer el proceso en etapas (adquisición, procesamiento, extracción y validación), así como para comparar cuantitativamente los errores obtenidos, facilitando la evaluación individual y conjunta de cada método aplicado.

3.4. Fuentes de recopilación de la información

3.4.1. Fuentes primarias

La información se obtuvo mediante la recopilación de datos de campo obtenidos del sitio de estudio, mediciones de vuelo y las imágenes digitales de alta resolución capturadas por el dron.

3.4.2. Fuentes secundarias

La información recopilada para esta investigación fue mediante artículos científicos, tesis, revistas académica, sitios bibliográficos como Scopus, Consensus, Google académico, entre otros, lo que facilitó la generación de resultados e interpretación.

3.5. Diseño de la investigación

3.5.1. Enfoque y tipo de estudio

El diseño de la investigación es de tipo experimental, de carácter no probabilístico y longitudinal, desarrollado en condiciones de campo cuidadosamente controladas. El estudio se apoya en mediciones realizadas de manera repetida a lo largo del tiempo, abarcando distintas etapas del ciclo fenológico del cultivo de maíz, lo que permite observar y analizar cómo evoluciona la fracción de cobertura vegetal. Además, el diseño adopta un enfoque comparativo, ya que contrasta el desempeño de diferentes índices de vegetación y métodos de umbralización aplicados a imágenes obtenidas con VANT. La validación de los resultados se lleva a cabo comparando los valores estimados con mediciones observadas, mediante indicadores estadísticos de error, lo que aporta solidez y confiabilidad a las conclusiones del estudio.

3.5.2. Unidad de estudio y población

La población o sujeto de estudio principal fue un cultivo de maíz (*Zea mays* L., híbrido Esplendor) establecido en una superficie de 14000 m². La unidad de estudio a partir de la cual se obtuvieron las estimaciones fue la fracción de cobertura vegetal FCV en porcentaje (%), medida indirectamente mediante el análisis de imágenes digitales de alta resolución (ortomosaicos) capturadas por un sensor RGB montado en un Vehículo Aéreo No Tripulado

(VANT) a lo largo del desarrollo del cultivo, de los cuales se realizaron cinco vuelos semanales cada viernes. Para la validación métricas de error (%) y comparación de los resultados, se definieron como unidades de muestreo específicas nueve sitios distribuidos al azar en el cultivo, con áreas variables (desde 1 m² con una planta, 9 m² con 165 plantas, 36 m² con 48 plantas), donde se calculó la fracción de cobertura observada manualmente con unidad de medida en porcentaje (%).

3.5.3. Factores de estudio y tratamientos

3.5.3.1. Índice de vegetación.

Se emplearon como variables para resaltar las diferencias espectrales entre la vegetación y el suelo, a partir de imágenes RGB captadas por el dron, en donde se aplicaron tres índices de vegetación (TGI, ExG y NGRDI). Para los ajustes de la imagen y georreferenciación de los ortomosaicos se los realizó en el programa Agisoft Metashape (Agisoft LLC, San Petersburgo, Rusia) para cada canal. Los índices de vegetación se lo cálculo en el espacio de color estandar RGB en el programa Matlab (Mathworks, Massachusetts, EE. UU), para separar la reflectancia de canales del rojo, verde y azul de la imagen y realizar la operación matemática por cada píxel o número digital en canales de la imagen, con una matriz en escala de grises 0 – 255 por cada índice de vegetación calculado.

Fórmula para normalizar los valores de cada banda RGB:

$$r = \frac{R_N}{R_N + G_N + B_N}, g = \frac{G_N}{R_N + G_N + B_N}, b = \frac{B_N}{R_N + G_N + B_N}$$

$$R_N = \frac{R}{R_{max}}, G_N = \frac{G}{G_{max}}, B_N = \frac{B}{B_{max}}$$

Donde:

R_N, G_N, B_N = son los valores normalizados de cada banda

R, G y B = son los valores sin normalizar de los canales rojo, verde y azul

$R_{max}, G_{max}, B_{max}$ = son los números digitales máximos de cada canal (255 en la escala 0 – 255)

Tabla 3

Índices de vegetación de bandas del espectro visible (RGB) calculada para la extracción de la vegetación y estimación de la fracción de cobertura vegetal

<i>Índice de vegetación</i>	<i>Fórmula</i>	<i>Referencias</i>
Índice de verdor triangular	$TGI = R_{\text{verde}} - 0.39R_{\text{rojo}} - 0.61R_{\text{azul}}$	(Polat et al., 2024)
Índice de extracción del verde	$ExG = 2 * r - g - b$	(Yang et al., 2025)
Índice de diferencia normalizada verde – rojo	$NGRDI = R_{\text{verde}} - R_{\text{rojo}} / R_{\text{verde}} + R_{\text{rojo}}$	(Ruiz, 2023)

3.5.3.2. *Métodos de umbralización.*

Los umbrales permitieron separar de manera binaria los píxeles correspondientes a vegetación y suelo en las imágenes adquiridas por vehículo aéreo no tripulado, en los que se utilizaron cuatro métodos de umbralización (Otsu, IsoData, Fuzzy y conservación de momentos) que serán ejecutados por el programa Matlab para realizar el cálculo del umbral del método de Otsu; IsoData y conservación de momentos utilizaron funciones de HistThresh del software libre bajo licencia GNU, mientras que el método Fuzzy se calculó con el programa de Rstudio con el paquete Autothresholdr.

Tabla 4

Clasificación de la vegetación por umbrales

<i>Métodos de umbralización</i>	<i>Programas</i>	<i>Referencias</i>
Otsu	Matlab	(Triana et al., 2016)
IsoData	GNU	(Torres-Sánchez et al., 2015)
Conservación de momentos	GNU	(Aureliano et al., 2018)
Fuzzy	Rstudio	(García-Martínez et al., 2020)

3.5.4. Variables del estudio

3.5.4.1. Variables independientes.

- Índices de Vegetación (IV)
- Métodos de Umbralización
- Etapa de Desarrollo del Cultivo (Días Después de Siembra, DDS)

3.5.4.2. Variables dependientes.

- Fracción de Cobertura Estimada (FCE)
- Error en la Estimación

3.5.4.3. Co-variables.

- Fracción de Cobertura Observada (FCO)
- Densidad de Población
- Parámetros de Adquisición de la Imagen

3.5.5. Diseño experimental

El estudio se plantea de manera no probabilística, con un enfoque longitudinal y comparativo, y se desarrolla bajo condiciones de campo cuidadosamente controladas. El trabajo se organiza a partir de mediciones repetidas en el tiempo, realizadas mediante varias campañas de vuelo con dron en diferentes etapas del desarrollo del cultivo de maíz. A partir de los ortomosaicos generados en cada vuelo, se aplican distintos tratamientos analíticos que combinan índices de vegetación y métodos de umbralización. Los resultados obtenidos se contrastan con mediciones de referencia realizadas de forma manual en sitios específicos de muestreo, lo que permite evaluar con claridad el desempeño de cada método y analizar la evolución de la cobertura vegetal a lo largo del tiempo con apoyo en criterios estadísticos objetivos.

3.6. Instrumentos de investigación

3.6.1. Manejo del experimento

3.6.1.1. Limpieza y preparación del terreno.

Para favorecer el crecimiento de las raíces, el terreno fue preparado con dos pasadas de rastra en direcciones opuestas, logrando así una mejor aireación e incorporación de restos vegetales. Posteriormente, se procedió al tratamiento de la semilla cada kilogramo de semilla fue tratado con una mezcla de 6 cc de Yara Vita Synergise® (9 N -15 P-18 Zn) y 15 cc del insecticida Ilustre® (Tiodicarb + Imidacloprid).

3.6.1.2. Siembra.

Se empleó el híbrido Esplendor mediante siembra manual en hileras simples, para garantizar un porcentaje de germinación óptimo, se depositaron dos semillas por sitio. El marco de plantación se definió con una distancia de 0,80 m entre hileras y 0,20 m entre plantas, alcanzando una densidad poblacional aproximada de 125,000 pl/ha⁻¹.

Tabla 5

Características agronómicas del híbrido Esplendor (Zea may L)

Características	Esplendor
Tipo de híbrido	F1
Altura de planta (cm)	220 – 230
Altura inserción de mazorca (cm)	120 – 130
Días a la floración	47 – 50
Días a la cosecha	120 – 125
Resistencia al acame	Muy buena
Arquitectura de la planta	Semi erecta
Tipo de grano	Cristalino
Hileras por mazorca	14 – 16
Granos por hilera	33 – 36

FUENTE: Ficha técnica (Agripac, 2025)

3.6.1.3. Control de malezas.

Se realizó en dos etapas: pre-emergencia y post-emergencia. Para la fase inicial, se empleó una mezcla de Acción® (2 L ha⁻¹), Atrapim® (900 g ha⁻¹) y Armaize® (1 kg ha⁻¹), adicionando 200 cc ha⁻¹ de Cosmo-in® como coadyuvante. Posteriormente, a los 15 días de la siembra, se realizó el control post-emergente aplicando una combinación de Zeamax® (32 g ha⁻¹) y Armaize® (1 kg ha⁻¹), aprovechando la acción conjunta de Nicosulfuron, Atrazina y Mesotrione.

3.6.1.4. Fertilización.

Se realizaron cuatro aplicaciones al suelo y dos vías foliares. La fertilización al suelo se realizó (8 DDS) con la aplicación 200 kg ha⁻¹ de Bonanza Inicio Active® (16 N – 12 P – 28 K – 2 S), 25 kg ha⁻¹ de Green Edge® (15 N – 15 P – 15 K – 10 % ácidos húmicos – 2,5 % extractos de algas marinas). Posteriormente, se realizaron aplicaciones secuenciales a los (18 DDS) 200 kg ha⁻¹ de Bonanza Nitro KS Active® (25 N – 21 K – 4,5 S), a los (33 DDS) 200 kg ha⁻¹ de Bonanza Nitro N-38 (38 N – 7 S) y a los (59 DDS) 150 kg ha⁻¹ de urea N-46.

Las dos aplicaciones foliares se las realizó: una con 200 cc ha⁻¹ del bioestimulante Biotek® a los (24 DDS) y otra con 1 kg ha⁻¹ de Cosmo Madurador® (25 P – 34 K – 4,2 B – 1 Zn) a los (36 DDS).

3.6.1.5. Control fitosanitario.

El primer control se realizó a los (2 DDS) con 1 L ha⁻¹ de Gusaphos® para el control inicial de insectos. El segundo control fue a los (12 DDS), se realizó una intervención para insectos chupadores al cual se aplicó 250 cc ha⁻¹ de Miterra® (Thiamethoxam: 141 g L⁻¹ + Lambda-cihalotrina: 106 g L⁻¹) y 100 cc ha⁻¹ de Premio® (Chlorantraniliprole: 200 g L⁻¹) para el manejo de *S. frugiperda*. También, se incorporó 1 L ha⁻¹ del enraizador Raíz Plant®. La tercera aplicación se efectuó a los (24 DDS) junto con la primera fertilización foliar aplicando 100 g ha⁻¹ de Sparko® (Sulfoxaflor: 300 g kg⁻¹ + Spinetoram: 100 g kg⁻¹) y 1,5 kg ha⁻¹ de Glory® (Mancozeb: 700 g kg⁻¹ + Azoxystrobin: 50 g kg⁻¹) para el control de insectos chupadores, enfermedades fúngicas y bacterianas.

La cuarta aplicación se integró a los (36 DDS), junto con la segunda fertilización foliar, se aplicaron 100 cc ha⁻¹ de Pleo® (Pyridalyl 500 g L⁻¹), 80 g ha⁻¹ de Rally 40 PM® (Myclobutanil: 40 g kg⁻¹) y 900 g ha⁻¹ de Dithane® NT (Mancozeb: 800 g kg⁻¹). La última aplicación fue a los (60 DDS) con 400 cc ha⁻¹ de Tronkal® (Azoxystrobin: 200 g L⁻¹ + Difenconazole: 125 g L⁻¹) y 150 g ha⁻¹ de Tejo® (Benzoato de emamectina: 50 g kg⁻¹).

3.6.1.6. *Imágenes adquiridas mediante cada vuelo.*

Se generaron puntos de control en el terreno con el uso de un equipo GNSS COMNAV SINO (ComNav Technology Ltd, China) con una precisión de 8 mm para poder realizar el ajuste de la imagen y georreferenciación de los ortomosaicos en el programa Agisoft Metashape (Agisoft LLC, San Petersburgo, Rusia) en el procesamiento de imagen. La captura de imágenes se controló con la configuración de vuelo en el software Pix4Dcapture, versión 4.2.2 (Pix4D SA, Lausanne, Suiza) registrando cada toma de posición con un modelo GPS/GLONASS Emlid Reach M2 (Emlid Ltd, Tallin, Estonia), altura, fecha, hora y propiedades del sensor.

Para la adquisición de imágenes aéreas se programaron cinco vuelos automatizados con el vehículo aéreo no tripulado Dji Phantom 4 versión 2 (DJI, Shenzhen, China) a una altura de 30 m sobre el nivel del suelo, con un traslape horizontal del 80 % y lateral del 80 % para garantizar la calidad de los ortomosaicos. El equipo cuenta con un sensor semiconductor de óxido metálico (CMO, por sus siglas en inglés) de una pulgada, con un tamaño de 20 megapíxeles de imágenes en el empleo de canales rojo, verde, azul (RGB), con dimensiones de 5472 x 3648 píxeles por canal. Tiene la capacidad de despegar y aterrizar con una autonomía de vuelo de 30 minutos y una capacidad de carga 1,388 Kg. Está equipado con un sistema de posicionamiento global por sus siglas en inglés GPS (Global Positioning System) con una precisión vertical $\pm 0,5$ m y horizontal de $\pm 1,5$ m, lo que permite realizar vuelos autónomos mediante rutas previamente programadas.

El recorrido cubrió un área de 2 hectáreas en aproximadamente 7:35 minutos, generando un total estimado de 302 imágenes con una sola batería. La dirección de vuelo establecida fue de -147°, con una velocidad de mapeo de 5 m/s, iniciando desde el waypoint 1. El ángulo del gimbal se ajustó a -90°, asegurando la captura nadiral de las imágenes, condición

indispensable para obtener representaciones ortorrectificadas de alta resolución espacial. El primer vuelo se lo realizó el viernes 19 de septiembre 2025, con un total de cinco vuelos semanales cada viernes, en horario variable entre las 11:30 a.m. y 3:00 p.m. para obtener buenas condiciones de iluminación.

A partir de las características del dron y sensor se pueden planificar el tamaño de píxel en el suelo Ground Sample Distance (GSD, por sus siglas en ingles), altura de vuelo (H), velocidad de vuelo (V), traslape horizontal (TH) y traslape lateral (TL).

$$GDS = \frac{Tsx * H}{Npx * LF} = \frac{Tsy * H}{Npy * LF}$$

$$Al = GSD^2 * Np * Npy$$

$$TH = \left(1 - \frac{DL * Vd}{GSD * Npy}\right) * 100 = \left(1 - \frac{Vd * LF}{H * Tsy}\right) * 100$$

$$TL = \left(1 - \frac{DL * LF}{H * Tsy}\right) * 100$$

Donde:

Al: es el área de la imagen

Tsx – Tsy: es el ancho y alto del espesor (mm)

Npx – Npy: es el número de píxeles en X y Y.

LF: es la longitud focal del sensor (mm),

DL: es la distancia entre líneas de vuelo (m)

Tabla 6

Bitácora de vuelo

<i>N° vuelo</i>	<i>Días despues de la siembra</i>	<i>Fecha</i>	<i>Altura (m)</i>	<i>Número de imágenes</i>	<i>Área (m²)</i>	<i>Tamaño de píxel (cm)</i>
1	18	19/09/2025	30	351	10200	0.5
2	25	26/09/2025	30	359	10200	0.5
3	32	03/10/2025	30	351	10200	0.5
4	39	10/10/2025	30	352	10200	0.5
5	46	17/10/2025	30	352	10200	0.5

3.6.1.7. *Procesamiento de imágenes y generación de ortomosaicos.*

Se generaron cinco ortomosaicos a partir del procesamiento de las imágenes capturadas por el sensor instalado en el dron, utilizando el software Pix4D (Pix4D SA, Lausanne, Suiza). El procedimiento se llevó a cabo mediante el método de estructura a partir del movimiento (SFM, por sus siglas en inglés), el cual identifica características en imágenes individuales y las correlaciona con aquellas presentes en imágenes traslapadas, conocidas como puntos clave. A partir de estos puntos se calibraron los parámetros internos y externos de la cámara (posición, escala y orientación), permitiendo establecer correspondencias entre imágenes en áreas comunes. Posteriormente, las posiciones 3D calculadas se densificaron y se texturizaron con las imágenes correspondientes, permitiendo obtener un ortomosaico final en el que cada píxel se proyectó sobre un plano 2D con alta resolución espacial.

3.6.1.8. *Estimación de la fracción de cobertura vegetal.*

Se estimaron las imágenes con relación entre el número de píxeles clasificados como vegetación y el total de píxeles presentes en el área de estudio. Para ello, a partir de cada índice de vegetación y métodos de umbralización se obtuvo una imagen en escala de grises, calculados en el software de código abierto QGIS (licencia GNU) utilizando la herramienta calculadora ráster. De esta manera, los valores superiores al umbral establecido se clasificaron como vegetación, mientras que los inferiores se identificaron como suelo, generando finalmente una imagen binaria que permitirá distinguir de forma precisa las áreas cubiertas por vegetación respecto a las descubiertas.

Se seleccionaron nueve sitios de muestreo distribuidos al azar dentro del área de estudio. Los sitios están conformados por parcelas pequeñas de tres sitios de 1 m² y una planta, tres sitios 9 m² y 165 plantas, tres sitios con área de 36 m² y 48 plantas. En cada uno de estos sitios de muestreo se determinó la fracción de cobertura vegetal correspondiente a las cinco fechas de vuelo programadas, permitiendo validar y comparar los resultados obtenidos a partir del procesamiento digital de las imágenes aéreas.

De manera manual se digitalizaron los píxeles que pertenecen a suelo y los píxeles que pertenecen a vegetación, mediante el programa QGIS se midió el polígono cubierto por vegetación y se dividió entre el área total del polígono en cada ortomosaico, de esta manera se obtuvo la fracción de cobertura observada (FCO).

$$FCO = \frac{\text{área cubierta por vegetación}}{\text{área total del polígono de muestreo}}$$

Mientras que para obtener la fracción de cobertura esperada (FCE) se calculó a partir de la imagen binaria generada con el índice de vegetación y el método de umbralización, mediante la herramienta QGIS se empleó la herramienta informe de valores únicos de capa ráster para el conteo de píxeles clasificados como vegetación y suelo que hay dentro de un polígono de muestreo definido.

$$FCE = \frac{\text{número de píxeles clasificados como vegetación}}{\text{número total de píxeles en el polígono}}$$

3.6.1.9. Validación de datos de la fracción de cobertura estimada.

Se analizó la fracción de cobertura vegetal mediante los métodos de umbralización e índices de vegetación, se comparó con la fracción de cobertura observada, para lo cual se aplicaron los calculos de métricas estadísticas para encontrar la raíz cuadrada de error cuadrático medio (RMSE) y el error absoluto medio (EAM), utilizando los datos recolectados y estimados dentro de los polígonos definidos del muestreo.

$$E_s = FCE - FCO$$

$$EAM = \frac{1}{N} \sum_{i=1}^N |(E_s)_i|$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (FCE - FCO)^2}{N}}$$

Donde:

N = número de polígonos validados

$|(E_s)_i|$ = valor absoluto de E_s

E_s = diferencia entre FCE (fracción de cobertura estimada) y FCO (fracción de cobertura observada)

3.1.1. Variables evaluadas

3.1.1.1. Umbrales.

Se determinaron mediante los algoritmos de clasificación automática Otsu, IsoData, Fuzzy y conservación de momentos, aplicados sobre las imágenes en escala de grises generadas a partir de los índices de vegetación para separar los píxeles de vegetación y suelo, generando una imagen binaria para cada combinación de índice y método de umbralización (Ruiz, 2023; Jiang et al., 2025)

3.1.1.2. Error absoluto medio.

Se calcularon como la diferencia promedio entre la fracción de cobertura observada en campo y la estimada a partir de las imágenes clasificadas como suelo y vegetación, el indicador permitió cuantificar el grado de desviación entre los valores reales y los obtenidos digitalmente, proporcionando una medida de precisión en cada tratamiento (Song et al., 2022).

3.1.1.3. Raíz cuadrática del error medio.

Se emplearon para evaluar la exactitud de las estimaciones realizadas. Este indicador indico mayor peso a los errores más grandes, permitiendo identificar qué combinaciones de índice y umbralización producen resultados más consistentes y confiables para la estimación de la fracción de cobertura vegetal (Marcial-Pablo, 2017).

3.1.1.4. Fracción de cobertura observada.

La fracción de cobertura observada se la obtuvo mediante los sitios de muestreo registrados en campo, contabilizando el área cubierta por vegetación en relación con el área total de cada parcela, mediante el programa de QGIS (García-Martínez et al., 2020).

3.1.1.5. *Fracción de cobertura esperada.*

La fracción de cobertura estimada se calculó a partir de las imágenes procesadas y clasificadas con los índices de vegetación y los métodos de umbralización con el programa QGIS empleando la herramienta informe de valores únicos de capa ráster que nos permitió realizar un conteo de píxeles para la clasificación de la vegetación y suelo (García-Martínez et al., 2020).

3.2. Tratamientos de los datos

El tratamiento de los datos se orientó a la validación y comparación de las 12 combinaciones resultantes de la aplicación de índices de vegetación y métodos de umbralización. En primer lugar, se calculó la fracción de cobertura observada (FCO) como medida de referencia, obtenida mediante la digitalización manual de la vegetación dentro de los polígonos de muestreo. La fracción de cobertura estimada (FCE) para cada combinación de índice de vegetación y umbralización, se obtuvo a partir de las imágenes binarias en las que se clasificaron los píxeles en vegetación y suelo; para ello, se realizó el conteo de los píxeles y se dividió entre el total de píxeles de cada polígono de muestreo, proceso realizado en el programa de QGIS. La validación de los resultados se efectuó mediante la comparación entre la FCE y la FCO, utilizando métricas de error como la raíz del error cuadrático medio (RMSE), el error absoluto medio (EAM). Además, se realizó un análisis estadístico descriptivo, presentando los valores de FCO, FCE y las métricas de error para cada combinación de métodos e índices.

3.3. Recursos humanos y materiales

3.3.1. *Recursos humanos*

- Ing. Edwin Miguel Jiménez Romero M.Sc. (director del proyecto de investigación)
- Nadelin Solange Abeiga Cornejo (autor del proyecto de investigación)

3.3.2. *Materiales*

3.3.2.1. *Material vegetal.*

- Cultivo de maíz híbrido Esplendor

3.3.2.2. *Material de oficina.*

- Computadora
- Licencia Software (procesamiento de imágenes)
- Internet
- Material bibliográfico
- Insumos de papelería

3.3.2.3. *Material de campo.*

- Dron Dji Phantom 4 versión 2
- Disco SSD Kingston 1 Tb USB puerto tipo C
- Equipo GNSS (COMNAV SINO)
- Baterías de repuesto


CAPÍTULO IV
RESULTADOS Y DISCUSIÓN

4.1.1. Desempeño de los índices de vegetación y métodos de umbralización en la extracción de la vegetación

La figura 3 se observa la imagen RGB y las imágenes procesadas mediante índices y métodos de umbralización para la estimación de la fracción de cobertura vegetal, donde el primer vuelo 18 DDS con NGRDI – IsoData represento una FCV de 5.79%, indicando baja cobertura vegetal en etapa temprana del cultivo. De manera similar, el segundo vuelo 25 DDS con TGI – Fuzzy se registró una FCV de 4.78%, evidenciando aún una escasa presencia de vegetación. El tercer vuelo 32 DDS con NGRDI – Momentos la FCV alcanzó 97.56%, reflejando una cobertura casi total del área evaluada, por otro lado, en el cuarto vuelo 39 DDS con ExG – Otsu presentaron una FCV de 82.32% y quinto vuelo 46 DDS con TGI – Momentos una FCV de 71.18%, estos valores indicaron una alta presencia de vegetación.

Figura 3

Ortomosaico generado con imágenes capturadas con el VANT durante el desarrollo del cultivo



ELABORADO: AUTOR

Nota. Sitio de muestreo de 9 m², a) Ortomosaico a los 18 días después de siembra (DDS), a1) vegetación a partir del índice NGRDI y método IsoData, umbral de 0.6196, b) ortomosaico a los 25 DDS, b1) vegetación a partir del índice TGI y método Fuzzy, umbral

de 0.2235, c) ortomosaico a los 32 DDS, c1) vegetación a partir del índice NGRDI y método conservación de momentos, umbral de 0.3490, d) ortomosaico a los 39 DDS, d1) vegetación a partir del índice ExG y método Otsu, umbral de 0.4392, e) ortomosaico a los 46 DDS, e1) vegetación a partir del índice TGI y método conservación de momentos, umbral de 0.3490.

4.1.2. Estadísticas descriptivas de umbrales y cobertura vegetal

En la tabla 7 se presentan el umbral obtenido por cada fecha de vuelo e índice de vegetación, el error medio absoluto y la raíz cuadrada del error medio cuadrático obtenido a partir de los sitios de muestreo. El método de Otsu e IsoData presentan umbrales similares para la mayoría de índices y fechas debido a que ambos buscan separaciones óptimas en el histograma de la imagen. Para ExG se obtuvieron valores de 0.623 en Otsu y 0.620 en IsoData, mientras que para NGRDI los umbrales fueron 0.619 en Otsu e IsoData. De forma similar, en TGI se registraron valores cercanos de 0.388 con Otsu y 0.387 con IsoData. Sin embargo, el método de conservación de momentos presentó umbrales más bajos en ExG de 0.482 y NGRDI de 0.376, mientras que el método Fuzzy generó los valores más bajos de todos los métodos evaluados, especialmente en TGI de 0.215 y ExG de 0.305. Lo que sugiere diferencias importantes en las coberturas calculadas.

Tabla 7

Umbrales, error absoluto medio (EMA) y la raíz cuadrada del error cuadrático medio (RMSE) para los índices de vegetación y métodos de umbralización durante el desarrollo del cultivo

Método	DDS	ExG			NDRDI			TGI		
		T	EMA	RMSE	T	EMA	RMSE	T	EMA	RMSE
Otsu	18	0.623	23.66	25.98	0.619	20.59	21.73	0.388	30.31	30.96
	25	0.470	10.49	13.26	0.596	18.27	19.27	0.392	19.08	20.54
	32	0.447	3.58	4.78	0.596	6.09	8.22	0.392	6.81	9.74
	39	0.439	8.01	9.09	0.580	6.54	6.91	0.317	56.45	56.80
	46	0.419	11.71	12.09	0.572	3.46	4.80	0.360	61.49	62.00
Momentos	18	0.482	24.78	26.00	0.376	24.08	26.12	0.419	26.33	27.75
	25	0.027	8.10	12.99	0.039	8.08	12.97	0.384	20.70	22.08
	32	0.286	21.54	24.76	0.349	23.79	26.66	0.443	53.24	53.80

IsoData	39	0.423	52.37	52.58	0.035	28.03	32.43	0.396	56.46	56.57
	46	0.117	16.62	17.47	0.509	44.83	44.90	0.349	49.31	49.70
	18	0.620	25.88	27.43	0.619	19.48	20.51	0.387	17.81	18.92
	25	0.466	36.53	37.28	0.596	28.99	29.41	0.392	28.33	29.40
	32	0.446	50.13	51.19	0.598	41.88	42.27	0.391	47.07	47.68
Fuzzy	39	0.431	52.16	52.35	0.580	41.77	41.98	0.321	45.66	45.79
	46	0.418	58.08	58.16	0.575	50.59	50.72	0.363	52.01	52.10
	18	0.305	21.83	24.30	0.435	22.92	25.15	0.215	21.63	24.03
	25	0.290	10.17	13.86	0.396	9.53	13.44	0.223	8.99	13.30
	32	0.807	25.37	26.69	0.396	27.88	29.07	0.211	28.16	29.71
	39	0.737	26.53	26.93	0.431	28.74	29.10	0.184	30.63	31.01
	46	0.305	36.83	37.28	0.415	36.00	36.46	0.215	37.05	37.45

ELABORADO: AUTOR


Nota. Se detallan los cuatro métodos utilizados Otsu, Momentos, IsoData y Fuzzy, días después de la siembra (DDS), empleo de tres índices ExG (Índice de extracción del verde), NGRDI (Índice de diferencia normalizada verde – rojo), TGI (Índice de verdor triangular), valor del umbral (T) y EMA (error absoluto medio), RMSE (raíz cuadrática del error medio).

4.1.3. Cobertura de la vegetación observada y estimada en el desarrollo del cultivo

En la figura 4 el índice de ExG – Otsu presentan una estimación cercana a la FCO especialmente en coberturas medias y altas entre el 60 – 85%, aunque en algunos casos presentan ligera sobrestimación. Por otro lado, el índice EXG – IsoData presenta una subestimación de la cobertura entre 0 y 35%, incluso cuando la observada supera el 70 – 80%. Para ExG – Fuzzy muestra una tendencia a mantener valores relativamente constantes alrededor de 42 – 52%, independientemente del aumento de la FCO, indicando subestimación en coberturas altas cuando la observada es mayor a 70% y sobrestimada en coberturas bajas, lo que sugiere una menor sensibilidad del método para detectar cambios en la cobertura vegetal real. ExG – Momentos presentan una sobreestimación cuando la observada supera el 70%, indicando valores que alcanzan entre 90 – 100%, indicando que este método tiende a clasificar una mayor cantidad de píxeles como vegetación.

Figura 4

Comparación de la FCO y la FCE obtenida con el ExG bajo diferentes métodos de segmentación




ELABORADO: AUTOR

En la Figura 5 el índice NGRDI – Otsu presenta una distribución de puntos cercana en coberturas medias y altas entre 60 – 90 %, sin embargo, en varios casos los valores estimados indican una ligera sobreestimación de la cobertura vegetal. Sin embargo, mantiene una tendencia consistente con el incremento de la FCO. Para NGRDI – IsoData se observa una subestimación de la cobertura entre 20 – 45%, incluso cuando la observada se encuentra entre 70 y 90 %. NGRDI – Fuzzy presentan estimados de 45 – 55% independientemente del aumento de la FCO. Esto provoca que el método sobreestime la cobertura cuando los valores observados son bajos y subestime cuando la FCO es alta, por lo que refleja baja sensibilidad para detectar variaciones reales en la cobertura vegetal. NGRDI – Conservación de Momentos muestra una tendencia a sobreestimar la cobertura vegetal cuando la cobertura observada supera el 70%, los valores estimados alcanzan entre 95 – 100%.

Figura 5

Comparación de la FCO y la FCE obtenida con el índice NGRDI bajo diferentes métodos de segmentación




ELABORADO: AUTOR

En la figura 6 el índice TGI – Otsu muestra una tendencia cercana en coberturas medias 50 – 78 %, indicando una estimación moderadamente ajustada en ese rango. Sin embargo, cuando la observada supera el 70 %, la mayoría de los valores estimados se sitúan entre 15 y 25 %, observándose una subestimación de la cobertura vegetal en etapas de mayor desarrollo del cultivo. Por otro lado, el índice TGI – IsoData también presenta subestimación de la cobertura, ya que los valores estimados se mantienen principalmente entre 10 y 35 %, incluso cuando la observada se encuentra entre 70 y 90 %. Para TGI – Fuzzy se observan valores constantes de 40 – 50%, independientemente del aumento de la FCO, lo que provoca que el método sobreestime la cobertura en valores bajos y altos manteniendo una baja capacidad para diferenciar cambios en la densidad del cultivo. Mientras, TGI – Conservación de Momentos muestra un comportamiento variable, con sobreestimación en coberturas medias entre 70 – 78% cuando la observada esta entre 50 – 60% y subestimación en coberturas altas, donde los valores estimados se concentran entre 15 – 35% cuando la

observada supera el 70%, representando una estimación inconsistente dependiendo del nivel de cobertura.

Figura 6

Comparación de la FCO y la FCE obtenida con el índice TGI bajo diferentes métodos de segmentación




ELABORADO: AUTOR

En la figura 7 se observó que las combinaciones NGRDI – Otsu (14.01%) y ExG – Otsu (14.85%) presentaron los valores más bajos de RMSE, lo que indicó una mayor precisión en la estimación de la fracción de cobertura vegetal obtenida a partir de las imágenes RGB. Estos resultados sugirieron que el método de umbralización Otsu permitió una mejor separación entre los píxeles de vegetación y suelo cuando se aplicaron los índices NGRDI y ExG. Por el contrario, las combinaciones ExG – IsoData (46.66%), TGI – Momentos (44.32%) y TGI – Otsu (41.34%) mostraron los valores más altos de RMSE, evidenciando una mayor diferencia entre la cobertura vegetal estimada y la observada en campo. Esto indicó que estos métodos de segmentación presentaron menor precisión en la clasificación de la vegetación. Por lo tanto, la combinación que mostro un mejor resultado es el índice

NGRDI con el método de Otsu, fueron las que ofrecieron un mejor desempeño para la estimación de la cobertura vegetal en el cultivo evaluado.

Figura 7
Combinaciones con el menor error (RMSE) en la estimación de la fracción de cobertura vegetal



ELABORADO: AUTOR

4.2. Discusión

El aumento progresivo de la fracción de cobertura vegetal a medida que avanzó el desarrollo del cultivo de maíz, pasando de valores bajos 6 % en etapas iniciales a coberturas altas 70 % en los vuelos. Rodrigo-Comino et al. (2025) menciona que esto ocurre porque en las primeras etapas del cultivo la mayor parte del área corresponde a suelo descubierto, lo que reduce la señal espectral asociada a la vegetación en las imágenes RGB adquiridas por VANT. Mientras, Du et al. (2022) indican que a medida que el cultivo crece y aumenta el área foliar, el dosel vegetal cubre una mayor superficie del suelo y mejora la detección de la vegetación mediante índices espectrales derivados de imágenes RGB.

Los métodos Otsu e IsoData mostraron valores de umbral similares en la mayoría de los índices evaluados, lo que indica un comportamiento consistente en la separación entre vegetación y suelo. Esto se debe a que ambos algoritmos determinan el umbral óptimo a partir de la distribución del histograma de la imagen para separar automáticamente las clases espectrales (Han et al., 2024). Sin embargo, los métodos Fuzzy y Conservación de Momentos generaron umbrales más bajos, lo que puede provocar que una mayor cantidad de píxeles sea clasificada como vegetación y producir diferencias en la cobertura estimada.

En la combinación ExG – Otsu, las estimaciones cercanas a la cobertura observada se las obtuvo en etapas medias y altas. Esto se debe a que el índice ExG resalta el componente verde de la vegetación y mejora el contraste entre plantas y suelo en imágenes RGB (Jiang, et al., 2025). A diferencia del índice TGI – Otsu que en las coberturas altas presento una subestimación. Rodrigo-Comino et al. (2025) detalla que esto sucede porque algunos índices derivados de imágenes RGB tienden a saturarse cuando la densidad foliar es elevada, lo que reduce su capacidad para detectar incrementos adicionales de vegetación.

El método más preciso en nuestros resultados fue la combinación NGRDI – Otsu, la cual mostró una relación consistente con la cobertura observada, indicando que esta combinación permite estimar adecuadamente la cobertura vegetal en diferentes niveles de densidad del cultivo. Esto ocurre porque el índice NGRDI mejora la diferenciación entre vegetación y suelo al utilizar la relación espectral entre las bandas roja y verde en imágenes RGB (Du et al., 2022). El menor RMSE de la estimación de la cobertura vegetal se obtuvo mediante

esta combinación con (14.01%), esto se debe a que el método de Otsu optimiza la separación entre vegetación y suelo al maximizar la varianza entre clases en el histograma de la imagen (Han et al., 2024). Los resultados difieren con (García-Martínez et al., 2020) donde la mejor combinación que obtuvieron fue con ExG obteniendo errores entre 2.2 % y 17.8 %, combinado con el método de Fuzzy los errores fueron menores al 5 % durante gran parte del desarrollo del cultivo hasta 58 DDS. Sin embargo, estas diferencias pueden deberse a diversos factores como condiciones de iluminación, resolución de imágenes, estado fenológico del cultivo al momento de la captura.

Otros estudios como Ruiz (2023) determina que el índice VARI, en combinación con el algoritmo SVM (Maquina de vectores de soporte), fue el que ofreció la mayor precisión en la estimación de la cobertura vegetal. Por el contrario, nuestro estudio se observó que la combinación ExG – IsoData presentaron el mayor RMSE (46.65%), indicando menor capacidad del método para clasificar correctamente los píxeles de vegetación, esto se debe a que en etapas más avanzadas la presencia de sombras y superposición de hojas en el dosel, dificulta la segmentación precisa de la vegetación (Zhang et al., 2024).

CAPÍTULO V
CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

- Los resultados obtenidos indican que el índice NGRDI presentó el menor error en la extracción de la vegetación cuando fue combinado con el método de umbralización Otsu, registrando el valor más bajo de RMSE (14.01%), demostrando que estos índices poseen una adecuada capacidad para resaltar la señal espectral de la vegetación en imágenes RGB, permitiendo una mejor diferenciación entre píxeles de vegetación y suelo.
- El método de umbralización Otsu presentó el mejor desempeño en la clasificación de la vegetación, ya que generó las estimaciones más precisas de la fracción de cobertura vegetal al ser combinado con los índices evaluados, especialmente con NGRDI. Por el contrario, los métodos IsoData, Fuzzy y Conservación de Momentos presentaron mayores desviaciones en la clasificación de la vegetación, lo que indica una menor precisión en la identificación de los píxeles correspondientes al dosel vegetal.

5.2. Recomendaciones

- Utilizar la combinación NGRDI – Otsu para la estimación de la fracción de cobertura vegetal en cultivos de maíz a partir de imágenes RGB adquiridas mediante drones, debido a que presentó el menor error y una mayor precisión en la extracción de la vegetación en comparación con las demás combinaciones evaluadas.
- Se sugiere emplear métodos de umbralización automáticos como Otsu, debido a que demostraron un mejor desempeño en la separación entre vegetación y suelo en comparación con otros métodos evaluados.
- Evaluar otros índices de vegetación o sensores multispectrales, así como incorporar métodos más avanzados de análisis de imágenes, con el objetivo de mejorar la precisión en la estimación de la cobertura vegetal.

CAPÍTULO VI
BIBLIOGRAFÍA

6.1. Bibliografía

- Acosta, R. (2009). El cultivo del maíz, SU origen y clasificación. EL MAIZ en Cuba. *Cultivos Tropicales*, 30(2), 00-00.
- Agripac. (2025). Esplendor Semilla de Maíz. *Ficha Técnica*. <https://agripac.com.ec/productos/esplendor-semilla-de-maiz/>
- Álava Bermeo, M., García Solórzano, A., Pacheco Gil, H., Delgado Marcillo., C., Álava Bermeo, M., García Solórzano, A., Pacheco Gil, H., & Delgado Marcillo., C. (2024). Model for estimating soil chemical properties with RGB drone images. *Enfoque UTE*, 15(4), 19-26. <https://doi.org/10.29019/enfoqueute.1078>
- Aliane, N., Gómes Muñoz, C. Q. G., & Sánchez-Soriano, J. (2022). Web and MATLAB-Based Platform for UAV Flight Management and Multispectral Image Processing. *Sensors*, 22(11), Article 11. <https://doi.org/10.3390/s22114243>
- Aslan, M. F., Durdu, A., Sabanci, K., Ropelewska, E., & Gültekin, S. S. (2022). A Comprehensive Survey of the Recent Studies with UAV for Precision Agriculture in Open Fields and Greenhouses. *Applied Sciences*, 12(3), 1047. <https://doi.org/10.3390/app12031047>
- Aureliano Netto, A. F., Nogueira Martins, R., Aquino de Souza, G. S., & De Moura Araújo, G. (2018). SEGMENTATION OF RGB IMAGES USING DIFFERENT VEGETATION INDICES AND THRESHOLDING METHODS. *ResearchGate*, 6(4), 389-394. <https://doi.org/10.31413/nativa.v6i4.5405>
- Bardozzo, F., De la Osa, B., Horanska, L., Fumanal-Idocin, J., Priscoli, M. delli, Troiano, L., Tagliaferri, R., Fernandez, J., & Bustince, H. (2021). Adaptive binarization based on fuzzy integrals. *Information Fusion*, 68, 37-45. <https://doi.org/10.1016/j.inffus.2020.10.020>
- Bréda, N. (2003). Ground- based measurements of leaf area index: A review of methods, instruments and current controversies. *Journal of Experimental Botany*, 54(392). <https://doi.org/10.1093/jxb/erg263>
- Buenrostro Mercado, E. (2022). Propuesta de adopción de tecnologías asociadas a la industria 4.0 en las pymes mexicanas. *Entreciencias: diálogos en la sociedad del conocimiento*, 10(24). <https://doi.org/10.22201/enesl.20078064e.2022.24.81347>
- Buitrago Bolívar, E., Rico Franco, J. A., & Amador, S. (2024). Revista Tecnura. *Tecnura*, 28(82), 75-103. <https://doi.org/10.14483/22487638.22360>

- Cabrera Rosero, A. F. (2021). *Evaluación del uso de los drones como herramienta de apoyo para un efectivo control y monitoreo de páramos en Colombia*. Universidad de Antioquia.
- Cedeño Campoverde, K. J. (2024). *Sistema de teledetección utilizando drones para la identificación de enfermedades de banano en la hacienda la lorena* [UTEQ]. <https://repositorio.uteq.edu.ec/handle/43000/7934>
- Chao, Z., Liu, N., Zhang, P., Ying, T., & Song, K. (2019). Estimation methods developing with remote sensing information for energy crop biomass: A comparative review. *Biomass and Bioenergy*, 122, 414-425. <https://doi.org/10.1016/j.biombioe.2019.02.002>
- Choi, S. K., Lee, S. K., Jung, S. H., Choi, J. W., Choi, D. Y., & Chun, S. J. (2016). Estimation of Fractional Vegetation Cover in Sand Dunes Using Multi-spectral Images from Fixed-wing UAV. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 34(4), 431-441. <https://doi.org/10.7848/ksgpc.2016.34.4.431>
- Cuerno Rejado, C., Garcia Hernandez, L., Sanchez Carmona, A., Carrio Fernandez, A., Sanchez Lopez, J. L., & Campoy Cervera, P. (2016). EVOLUCIÓN HISTÓRICA DE LOS VEHICULOS AEREOS NO TRIPULADOS HASTA LA ACTUALIDAD. *DYNA INGENIERIA E INDUSTRIA*, 91(1), 282-288. <https://doi.org/10.6036/7781>
- Ding, Y., Zheng, X., Zhao, K., Xin, X., & Liu, H. (2016). Quantifying the Impact of NDVIsoil Determination Methods and NDVIsoil Variability on the Estimation of Fractional Vegetation Cover in Northeast China. *Remote Sensing*, 8(1), 29. <https://doi.org/10.3390/rs8010029>
- 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. *Scientific Reports*, 12. <https://www.nature.com/articles/s41598-022-20299-0>
- Fonseca-Carreño, N. E., & Bossa-Pabon, K. A. (2022). La Agricultura y su incidencia en la Seguridad y la Soberanía Alimentaria. Una revisión. *Revista Científica Profundidad Construyendo Futuro*, 17(17), 85-101. <https://doi.org/10.22463/24221783.3833>
- Fuentes Cuesta, Á. J. (2021). *Evaluación de la severidad de la mancha de asfalto (Phyllachora maydis) en maíz (Zea mays) bajo el efecto del azufre*. UTEQ.
- Gao, L., Wang, X., Johnson, B. A., Tian, Q., Wang, Y., Verrelst, J., Mu, X., & Gu, X. (2020). Remote sensing algorithms for estimation of fractional vegetation cover using pure

- vegetation index values: A review. *ISPRS journal of photogrammetry and remote sensing : official publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 159, 364-377. <https://doi.org/10.1016/j.isprsjprs.2019.11.018>
- García Hernandez, S., & Sigut Saavedra, J. F. (2018). Umbralización adaptada de imágenes basadas en histogramas espacio—Color. *Universida de la Laguna*.
- García Santillán, I. D. (2008). *Visión Artificial y Procesamiento Digital de Imágenes usando Matlab*. 103.
- García-López, D., & Hernández, R. A. (2023). Estudio de altas densidades de siembra en la producción de maíz (*Zea mays*) híbrido. *Revista Tecnología en Marcha*, 36(4), 160-168. <https://doi.org/10.18845/tm.v36i4.6427>
- García-Martínez, H., Flores-Magdaleno, H., Khalil-Gardezi, A., Ascencio-Hernández, R., Tijerina-Chávez, L., Vázquez-Peña, M., & Mancilla-Villa, O. (2020). Estimación de la fracción de cobertura de la vegetación en maíz (*Zea mays*) mediante imágenes digitales tomadas por un vehículo aéreo no tripulado (UAV). *Revista fitotecnica mexicana*, 43(4), 399-409. <https://doi.org/10.35196/rfm.2020.4.399>
- Gerardo, R., & De Lima, I. P. (2023). Applying RGB-Based Vegetation Indices Obtained from UAS Imagery for Monitoring the Rice Crop at the Field Scale: A Case Study in Portugal. *Agriculture*, 13(10), Article 10. <https://doi.org/10.3390/agriculture13101916>
- Gilabert, M., Gonzáles-Piqueras, J., & García-Haro, J. (1997). Acerca de los índices de vegetación. *Revista de Teledetección*, 8(10). https://www.researchgate.net/publication/39195330_Acerca_de_los_indices_de_vegetacion
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- Gómez Borbor, J. S. (2024). EVALUACIÓN DE RENDIMIENTO Y PRODUCTIVIDAD DE CUATRO HÍBRIDOS DE MAÍZ (*Zea mays* L) EN LA PARROQUIA COLONCHE, PROVINCIA DE SANTA ELENA. *UPSE*, 65.
- Gómez Hidalgo, R., & Martínez Izquierdo, E. (2019). SEGMENTACION DE IMÁGENES RGB DE ALTA RESOLUCIÓN ESPACIAL. *Universida Politécnica de Madrid*.
- Grijalva Gómez, I. R. (2022). *ESTIMACIÓN DE BIOMASA EN PASTIZALES MEDIANTE MÉTODOS TRADICIONALES Y USO DE DRONES EN EL ESTADO DE*

- CHIHUAHUA [Masters, UNIVERSIDAD AUTÓNOMA DE CHIHUAHUA].
<http://repositorio.uach.mx/500/>
- Guebsi, R., Mami, S., Chokmani, K., Guebsi, R., Mami, S., & Chokmani, K. (2024). Drones in Precision Agriculture: A Comprehensive Review of Applications, Technologies, and Challenges. *Drones*, 8(11). <https://doi.org/10.3390/drones8110686>
- Gutieres Camatta, B., Reis de Andrade, N. L., Dresch Weblar, A., Sanches, L., Gonçalves Aguiar, R., & Antonucci, B. (2023). Índice de área foliar e sua relação com o microclima em floresta e pastagem na Amazônia Ocidental. *Revista Brasileira de Climatologia*, 32, 311-335. <https://doi.org/10.55761/abclima.v32i19.16296>
- Guzmán-Albores, J. M., Matuz-Cruz, M. de J., Arana-Llanes, J. Y., López-Carrasco, E., Gómez-Vázquez, V., & González-Cárdenas, N. (2024). Avances y perspectivas de la agricultura de precisión para la sostenibilidad agrícola. *XIKUA Boletín Científico de la Escuela Superior de Tlahuelilpan*, 12(24), 1-6. <https://doi.org/10.29057/xikua.v12i24.12790>
- Han, L., Wang, Z., He, M., & He, X. (2024). Effects of different ground segmentation methods on the accuracy of UAV-based canopy volume measurements. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1393592>
- Harrak, Y., Rachid, A., & Aguejidad, R. (2025). Evaluation of Spectral Indices and Global Thresholding Methods for the Automatic Extraction of Built-Up Areas: An Application to a Semi-Arid Climate Using Landsat 8 Imagery. *Urban Science*, 9(3), Article 3. <https://doi.org/10.3390/urbansci9030078>
- Hassler, S. C., & Baysal-Gurel, F. (2019). Unmanned Aircraft System (UAS) Technology and Applications in Agriculture. *Agronomy*, 9(10), 618. <https://doi.org/10.3390/agronomy9100618>
- Huang, C., Li, X., & Wen, Y. (2021). AN OTSU image segmentation based on fruitfly optimization algorithm. *Alexandria Engineering Journal*, 60(1), 183-188. <https://doi.org/10.1016/j.aej.2020.06.054>
- Huang, Y., Zhong-xin, C., Yu, T., Xiang-zhi, H., & Xing-fa, G. (2018). Agricultural remote sensing big data: Management and applications. *Journal of Integrative Agriculture*, 17(9), 1915-1931. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8)
- Huete, A., Didan, K., Van Leeuwen, W. J. D., Miura, T., & Glenn, E. (2011). *MODIS vegetation indices* (Land Remote Sensing and Global Environmental Change, Vol. 26). https://doi.org/10.1007/978-1-4419-6749-7_26

- Hunt, E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry, C. S. T., Perry, E. M., & Akhmedov, B. (2013). A visible band index for remote sensing leaf chlorophyll content at the canopy scale. *International Journal of Applied Earth Observation and Geoinformation*, 21, 103-112. <https://doi.org/10.1016/j.jag.2012.07.020>
- Jiang, J., Li, D., Qiu, Q., & Xiao, L. (2025). Improving sugar beet canopy mapping through UAV image analysis. *Scientific Reports*, 15(1), 40106. <https://doi.org/10.1038/s41598-025-23868-1>
- Kaufman, Y. J., & Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 261-270. <https://doi.org/10.1109/36.134076>
- Khanpara, B. M., Patel, B. P., Parmar, N. B., & Mehta, T. D. (2024). Transforming Agriculture with Drones: Applications, Challenges and Implementation Strategies. *Journal of Scientific Research and Reports*, 30(8), 792-802. <https://doi.org/10.9734/jsrr/2024/v30i82299>
- Kovács, I., & Husti, I. (2018). The role of digitalization in the agricultural 4.0 – how to connect the industry 4.0 to agriculture? *Hungarian Agricultural Engineering*, (33), 38-42. <https://doi.org/10.17676/HAE.2018.33.38>
- Li, L., Chen, J., Mu, X., Li, W., Yan, G., Xie, D., & Zhang, W. (2020). Quantifying Understory and Overstory Vegetation Cover Using UAV-Based RGB Imagery in Forest Plantation. *Remote Sensing*, 12(2), 298. <https://doi.org/10.3390/rs12020298>
- Li, Z., Yu, S., Ye, Q., Zhang, M., Yin, D., & Zhao, Z. (2025). Tree Species Classification Using UAV-Based RGB Images and Spectral Information on the Loess Plateau, China. *Drones*, 9(4), Article 4. <https://doi.org/10.3390/drones9040296>
- López-Portilla Vigil, B., Menéndez Alonso, R., & Iglesias Martínez, M. (2016). Implementación del Algoritmo de Otsu sobre FPGA. *Revista Cubana de ciencias informáticas*, 10(3).
- Macedo-Cruz, A., Pajares, G., Santos Peñas, M., & Villegas-Romero, I. (2025). Digital Image Sensor-Based Assessment of the Status of Oat (*Avena sativa* L.) Crops after Frost Damage. *Sensores*, 11. <https://doi.org/10.3390/s110606015>
- Machado Guimarães, M. J., dos Reis, I. D., Alves Barros, J. R., Lopes, I., Gomes da Costa, M., Pereira Ribeiro, D., Carvalho, G. C., Santos da Silva, A., & Oliveira Alves, C. V. (2025). Identification of Vegetation Areas Affected by Wildfires Using RGB Images Obtained by UAV: A Case Study in the Brazilian Cerrado. *Geomatics*, 5(1), Article 1. <https://doi.org/10.3390/geomatics5010013>

- Marcial-Pablo, M. D. J. (2017). *DETERMINACIÓN DE VARIABLES AGRONÓMICAS DEL CULTIVO DE MAÍZ MEDIANTE IMÁGENES OBTENIDAS DESDE UN VEHÍCULO AÉREO NO TRIPULADO (VANT)* [Instituto mexicano de tecnología del agua].
http://repositorio.imta.mx/bitstream/handle/20.500.12013/1750/T_075.pdf?sequence=1&isAllowed=y
- Marcial-Pablo, M. de J., Gonzalez-Sanchez, A., Jimenez-Jimenez, S. I., Ontiveros-Capurata, R. E., & Ojeda-Bustamante, W. (2019). Estimation of vegetation fraction using RGB and multispectral images from UAV. *International Journal of Remote Sensing*, 40(2), 420-438. <https://doi.org/10.1080/01431161.2018.1528017>
- Marcial-Pablo, M. de J., Ontiveros-Capurata, R. E., Jiménez-Jiménez, S. I., & Ojeda-Bustamante, W. (2021). Maize Crop Coefficient Estimation Based on Spectral Vegetation Indices and Vegetation Cover Fraction Derived from UAV-Based Multispectral Images. *Agronomy*, 11(4), Article 4. <https://doi.org/10.3390/agronomy11040668>
- Martínez Casanovas, J. A., & Escolá Agustí, A. (2023). Avances en la aplicabilidad de tecnologías en la agricultura de precisión en fruticultura. *Revista de Fruticultura*, (92), 64-73.
- Mascorro-De Loera, R. D., Sosa-Ramírez, J., Luna-Ruíz, J. de J., Perales-Segovia, C., Cabrera-Manuel, F., Mascorro-de Loera, R. D., Sosa-Ramírez, J., Luna-Ruíz, J. de J., Perales-Segovia, C., & Cabrera-Manuel, F. (2024). Arvenses en cultivos de maíz de temporal en las tres provincias biogeográficas del estado de Aguascalientes, México. *Botanical Sciences*, 102(1), 234-255. <https://doi.org/10.17129/botsci.3362>
- MathWorks. (2025). *Find Vegetation in a Multispectral Image—MATLAB & Simulink Example*. Sitio Web. <https://es.mathworks.com/help/images/finding-vegetation-in-a-multispectral-image.html>
- Morales Bocanegra, Y., & Ojeda Castro, Á. (2024). *La adopción de las tecnologías de información en la agricultura de precisión* [Thesis doctoral, UNIVERSIDAD ANA G MÉNDEZ].
<https://www.proquest.com/openview/9720b95971c8db9b9f17283ef37d7fb4/1?pq-origsite=gscholar&cbl=18750&diss=y>
- Motohka, T., Nasahara, K. N., Oguma, H., & Tsuchida, S. (2010). Applicability of Green-Red Vegetation Index for Remote Sensing of Vegetation Phenology. *Remote Sensing*, 2(10), Article 10. <https://doi.org/10.3390/rs2102369>

- Moustafa, K. (2024). Maize's origin to be revisited. *Plant Signaling & Behavior*, 19(1).
<https://doi.org/10.1080/15592324.2024.2332017>
- Mulla, D. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering, Special Issue: Sensing Technologies for Sustainable Agriculture*, 114(4), 358-371.
<https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Muñoz Aguayo, P. (2013). Apuntes de Teledetección: Índices de vegetación. *Ciren (centro de información de Recursos Naturales)*.
https://www.researchgate.net/publication/327558326_Apuntes_de_Teledeteccion_Indices_de_vegetacion
- Nagel, J. (2012). Principales barreras para la adopción de las TIC en la agricultura y en las áreas rurales. *Nac. Unidas-CEPAL*, 54.
- Navia Zamora, J. R. (2019). *Optimización del proceso de fumigación agrícola mediante la utilización de los drones* [Quevedo-UTEQ].
<https://repositorio.uteq.edu.ec/handle/43000/3708>
- Nieto Pisco, S. A., Villacis Rivadeneira, R. A., Mejia Murillo, E. N., Calderón Vega, M. F., & Realpe Robalino, M. A. (2022). *Cuantificación de plantas de banano usando imágenes de UAV, técnicas SIG y de aprendizaje profundo* [Thesis, ESPOL. FCV].
<http://www.dspace.espol.edu.ec/handle/123456789/55848>
- Niño-Rondón, C. V., Castro-Casadiegos, S. A., Medina-Delgado, B., Guevara-Ibarra, D., & Camargo-Ariza, L. L. (2021). Comparativa entre la técnica de umbralización binaria y el método de Otsu para la detección de personas. *Revista UIS Ingenierías*, 20(2).
<https://doi.org/10.18273/revuin.v20n2-2021006>
- Niu, Y., Han, W., Zhang, H., Zhang, L., & Chen, H. (2021). Estimating fractional vegetation cover of maize under water stress from UAV multispectral imagery using machine learning algorithms. *Computers and Electronics in Agriculture*, 189, 106414.
<https://doi.org/10.1016/j.compag.2021.106414>
- Niu, Y., Zhang, L., Zhang, H., Han, W., & Peng, X. (2019). Estimating Above-Ground Biomass of Maize Using Features Derived from UAV-Based RGB Imagery. *Remote Sensing*, 11(11), 1261. <https://doi.org/10.3390/rs11111261>
- Ordóñez-Prado, C., Valdez-Lazalde, J. R., Flores-Magdaleno, H., Ángeles-Pérez, G., Santos-Posadas, H. M. de los, & Buendía-Rodríguez, E. (2024). Implicaciones operativas de la resolución espacial de imágenes de drones en el mapeo de la

- vegetación para el manejo forestal. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 30(2), 1-18. <https://doi.org/10.5154/r.rchscfa.2023.06.040>
- Pacheco Gil, H., Jarre, E., Macias, J. R., Intriago, F., Ortega, B., & Menéndez, E. (2023). Uso de un vehículo aéreo no tripulado como alternativa para generar información topográfica: Vehículo aéreo no tripulado para topografía. *Enfoque UTE*, 14(1). <https://doi.org/10.29019/enfoqueute.881>
- Pádua, L., Marques, P., Hruška, J., Adão, T., Peres, E., Morais, R., & Sousa, J. J. (2018). Multi-Temporal Vineyard Monitoring through UAV-Based RGB Imagery. *Remote Sensing*, 10(12), Article 12. <https://doi.org/10.3390/rs10121907>
- Patrignani, A., & Ochsner, T. E. (2015). Canopeo: A Powerful New Tool for Measuring Fractional Green Canopy Cover. *Agronomy Journal*, 107(6), 2312-2320. <https://doi.org/10.2134/agronj15.0150>
- Piedad Rubio, A. M., Hernández López, D. R., Lárraga Altamirano, H., & Zacarías González, E. (2020). Teledetección en la agricultura de precisión: Estado del arte de los índices de vegetación. *TECTZAPIC: Revista Académico-Científica*, 6(2), 46-58.
- Polat, N., Memduhoğlu, A., & Kaya, Y. (2024). Triangular Greenness Index Analysis for Monitoring Fungal Disease in Pine Trees: A UAV-based Approach. *Bartın Orman Fakültesi Dergisi*, 26(2), Article 2. <https://doi.org/10.24011/barofd.1352729>
- Prado Ruiz, A. J. (2023). EVALUACIÓN AGRONÓMICA DEL CULTIVO DE MAÍZ (*Zea mays*. L) HÍBRIDO DEKALB 7088 CON LA APLICACIÓN DE DISTINTAS DOSIS DE FERTILIZACIÓN EN LA PARROQUIA TRES DE NOVIEMBRE. *Escuela Superior Politécnica de Chimborazo*.
- Prudnikova, E., Savin, I., Vindeker, G., Grubina, P., Shishkonakova, E., & Sharychev, D. (2019). Influence of Soil Background on Spectral Reflectance of Winter Wheat Crop Canopy. *Remote Sensing*, 11(16), 1932. <https://doi.org/10.3390/rs11161932>
- Qin, M., Li, R., Ye, H., Nie, C., & Zhang, Y. (2024). Study on the Extraction of Maize Phenological Stages Based on Multiple Spectral Index Time-Series Curves. *Agriculture*, 14(11), 2052. <https://doi.org/10.3390/agriculture14112052>
- Rachmawati, S., Syah Putra, A., Priyatama, A., Parulian, D., Katarina, D., Tri Habibie, M., Siahaan, M., Prawesti Ningrum, E., Medikano, A., & Valentino, V., H. (2021). Application of Drone Technology for Mapping and Monitoring of Corn Agricultural Land. *2021 International Conference on ICT for Smart Society (ICISS)*, 1-5. <https://doi.org/10.1109/ICISS53185.2021.9533231>

- Radočaj, D., Šiljeg, A., Marinović, R., & Jurišić, M. (2023). State of Major Vegetation Indices in Precision Agriculture Studies Indexed in Web of Science: A Review. *Agriculture*, 13(3), Article 3. <https://doi.org/10.3390/agriculture13030707>
- Ramírez Vargas, M., Martín Rincón, R. O., & Ortega Rubio, A. (2020). Fotogrametría aérea aplicada a encinos (*Quercus* spp.) en Sierra La Laguna, B.C.S. Recomendaciones para su identificación y conservación. *FAO*. https://cibnor.repositorioinstitucional.mx/jspui/bitstream/1001/2037/3/ramirez_m%20TESIS.pdf
- Ríos-Hernández, R. (2021). Uso de los Drones o Vehículos Aéreos no Tripulados en la Agricultura de Precisión. *Revista Ingeniería Agrícola*, 11(4). <https://www.redalyc.org/journal/5862/586268743010/html/>
- Rodrigo-Comino, J., Al-Shammary, A. A. G., Durán-Zuazo, V. H., Serrano-Bernardo, F., Caballero-Calvo, A., & Rodríguez-Galiano, V. (2025). The Limits of RGB-Based Vegetation Indexes under Canopy Degradation: Insights from UAV Monitoring of Harvested Cereal Fields. *Drones and Autonomous Vehicles*, 3(1), 10021. <https://doi.org/10.70322/dav.2025.10021>
- Ruggeri, S., Henao-Cespedes, V., Garcés-Gómez, Y. A., & Parra Uzcátegui, A. (2021). Optimized unsupervised CORINE Land Cover mapping using linear spectral mixture analysis and object-based image analysis. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3, Part 2), 1061-1069. <https://doi.org/10.1016/j.ejrs.2021.10.009>
- Ruiz Castañares, K. (2023). Evaluacion de la cobertura vegetal en unidades de producción agrícola con vehículos aéreos no tripulados y sistema de información geográfica. *Universidad Nacional Autónoma de México*.
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV Flight Experiments Applied to the Remote Sensing of Vegetated Areas. *Remote Sensing*, 6(11), 11051-11081. <https://doi.org/10.3390/rs6111051>
- Sánchez Palacios, L. E., Martínez Alcivar, F. R., Torres Sánchez, S. T., Lascano Montes, A. C., & Terán Guajala, G. N. (2024). Agricultura de Precisión en El Ecuador. *Ciencia Latina Revista Científica Multidisciplinar*, 8(1), 1532-1542. https://doi.org/10.37811/cl_rcm.v8i1.9547
- Santa-María, J., Ríos, C., Rodríguez, C., & Gracia, C. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista*


- Científica de Sistemas e Informática*, 1(2), Article 2.
<https://doi.org/10.51252/rcsi.v1i2.131>
- Sishodia, R., Ray, R., & Singh, S. (2020). Applications of Remote Sensing in Precision Agriculture: A Review. *Remote Sensing*, 12(19), 3136.
<https://doi.org/10.3390/rs12193136>
- Song, C., Sang, J., Zhang, L., Liu, H., Wu, D., Yuan, W., & Huang, C. (2022). Adaptiveness of RGB-image derived algorithms in the measurement of fractional vegetation coverage. *BMC Bioinformatics*, 23(1), 358. <https://doi.org/10.1186/s12859-022-04886-6>
- Song, W., Mu, X., Ruan, G., Gao, Z., Li, L., & Yan, G. (2017). Estimating fractional vegetation cover and the vegetation index of bare soil and highly dense vegetation with a physically based method. *International Journal of Applied Earth Observation and Geoinformation*, 58, 168-176. <https://doi.org/10.1016/j.jag.2017.01.015>
- Stroppiana, D., Pepe, M., Boschetti, M., Crema, A., Candiani, G., Giordan, D., Baldo, M., Allasia, P., & Monopoli, L. (2019). ESTIMATING CROP DENSITY FROM MULTI-SPECTRAL UAV IMAGERY IN MAIZE CROP. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W13, 619-624. ISPRS Geospatial Week 2019 (Volume XLII-2/W13) - 10–14 June 2019, Enschede, The Netherlands. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-619-2019>
- Torres-Sánchez, J., López-Granados, F., & Peña, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114, 43-52. <https://doi.org/10.1016/j.compag.2015.03.019>
- Triana, N., Jaramillo, A. E., Gutiérrez, R. M., & Rodríguez, C. A. (2016). Técnicas de umbralización para el procesamiento digital de imágenes de GEM-Foils. *Scientia et technica*, 21(4), 352. <https://doi.org/10.22517/23447214.13271>
- Tristán, P., Wainschenker, R., & Doorn, J. H. (2005). *Super – Resolución: Una técnica para incrementar la resolución espacial de Imágenes Satelitales*. VII Workshop de Investigadores en Ciencias de la Computación. <http://sedici.unlp.edu.ar/handle/10915/21080>
- Vargas-Canales, J. M. (2022). El sector agroalimentario mexicano y las nuevas tecnologías. *eagronegocios*, 8(2), 89-113. <https://doi.org/10.18845/ea.v8i2.6156>

- Walter, J., Edwards, J., McDonald, G., & Kuchel, H. (2018). Photogrammetry for the estimation of wheat biomass and harvest index. *Field Crops Research*, 216, 165-174. <https://doi.org/10.1016/j.fcr.2017.11.024>
- Wei, H.-E., Grafton, M., Bretherton, M., Irwin, M., & Sandoval, E. (2022). Evaluation of the Use of UAV-Derived Vegetation Indices and Environmental Variables for Grapevine Water Status Monitoring Based on Machine Learning Algorithms and SHAP Analysis. *Remote Sensing*, 14(23), Article 23. <https://doi.org/10.3390/rs14235918>
- Wijayanto, A. W., Wahyu Triscowati, D., & Marsuhandi, A. H. (2020). Maize field area detection in East Java, Indonesia: An integrated multispectral remote sensing and machine learning approach. *2020 12th International Conference on Information Technology and Electrical Engineering (ICITEE)*, 168-173. <https://doi.org/10.1109/ICITEE49829.2020.9271683>
- Xiao, J., & Moody, A. (2005). A comparison of methods for estimating fractional green vegetation cover within a desert-to-upland transition zone in central New Mexico, USA. *Remote Sensing of Environment*, 98, 237-250. <https://doi.org/10.1016/j.rse.2005.07.011>
- Yang, Z., Qi, H., Hu, K., Kou, W., Xu, W., Wang, H., & Lu, N. (2025). Estimation of Amorphophallus Konjac Above-Ground Biomass by Integrating Spectral and Texture Information from Unmanned Aerial Vehicle-Based RGB Images. *Drones*, 9(3), Article 3. <https://doi.org/10.3390/drones9030220>
- Yanog, H. (2024). Agricultural Technology: Transforming the Future of Farming. *African Journal of Food Science and Technology*, 15(9). <https://www.interestjournals.org/articles/agricultural-technology-transforming-the-future-of-farming-112317.html>
- Yao, Y., Yue, J., Liu, Y., Yang, H., Feng, H., Shen, J., Hu, J., & Liu, Q. (2024). Classification of Maize Growth Stages Based on Phenotypic Traits and UAV Remote Sensing. *Agriculture*, 14(7), 1175. <https://doi.org/10.3390/agriculture14071175>
- Zhang, Y., Xia, C., Zhang, X., Cheng, X., Feng, G., Wang, Y., & Gao, Q. (2021). Estimating the maize biomass by crop height and narrowband vegetation indices derived from UAV-based hyperspectral images. *Ecological Indicators*, 129, 107985. <https://doi.org/10.1016/j.ecolind.2021.107985>


- Zhao, J. (2024). Drone Technology for Precision Agriculture: Advancements and Optimization Strategies. *Highlights in Science, Engineering and Technology*, 111, 185-191. <https://doi.org/10.54097/h70j2c34>
- Zhao, Z., Li, Y., Liu, K., Wu, C., Yu, B., Liu, G., & Wang, Y. (2025). Layered Soil Moisture Retrieval and Agricultural Application Based on Multi-Source Remote Sensing and Vegetation Suppression Technology: A Case Study of Youyi Farm, China. *Remote Sensing*, 17(13), 2130. <https://doi.org/10.3390/rs17132130>
- Zhou, P., Geng, L., Li, J., & Wang, H. (2025). Intercomparison of Leaf Area Index Products Derived from Satellite Data over the Heihe River Basin. *Remote Sensing*, 17(7), 1233. <https://doi.org/10.3390/rs17071233>

CAPÍTULO VII
ANEXOS


7.1. Anexos




Anexo 1. Recorte de ortomosaicos del sitio de estudio para cada vuelo con la herramienta de Global Mapper.



Anexo 2. Digitalización manual de la Fracción observada para cada uno de los vuelos con el programa de QGIS.



Anexo 3. Conteo de polígonos asociados como vegetación para una parcela de 9 m².



Anexo 4. Conteo de píxeles de la imagen binaria para el índice TGI y el método Otsu.

área parcela (m ²)	área de planta (m ²)	DDS	FCO	Fracción de cobertura estimada (FCE)											
				IsoData			Otsu			Fuzzy			Momentos		
				ExG	NGRDI	TGI	ExG	NGRDI	TGI	ExG	NGRDI	TGI	ExG	NGRDI	TGI
1	0.27	18	27.70	0.71	6.39	10.10	51.95	5.54	57.86	50.69	51.07	50.10	51.01	51.61	57.18
1	0.39	18	39.50	2.96	14.69	13.66	48.94	13.00	62.93	48.80	50.28	49.06	55.71	51.29	61.08
1	0.02	18	2.40	0.00	0.17	0.43	52.41	0.37	48.93	51.49	51.61	51.00	47.87	52.05	49.44
9	2.84	18	31.66	0.90	7.24	10.95	51.18	5.90	58.72	50.04	50.68	49.73	51.74	51.51	56.23
9	2.91	18	32.38	2.52	10.66	10.98	49.71	9.15	59.20	47.97	49.15	48.42	54.22	50.61	58.01
9	2.22	18	24.73	0.74	6.43	8.81	51.46	5.43	56.71	47.78	49.98	47.30	50.96	51.43	55.94
36	10.00	18	27.80	1.09	6.68	9.32	51.95	5.35	57.11	49.23	50.17	48.87	51.44	51.48	48.87
36	12.22	18	33.96	2.69	11.34	11.52	49.43	9.85	59.50	47.36	48.81	47.50	54.32	50.63	47.50
36	9.08	18	25.25	0.80	6.48	9.29	51.29	5.43	57.16	48.48	49.90	48.10	51.10	51.44	48.10
1	0.51	25	51.60	14.30	21.56	26.25	61.47	68.56	73.46	49.86	49.88	50.52	51.58	51.60	75.70
1	0.68	25	68.30	27.09	36.06	30.02	73.51	84.69	77.49	49.09	50.17	50.44	51.66	51.66	79.22
1	0.18	25	18.80	2.76	3.27	9.75	51.63	51.06	56.47	51.15	51.10	51.26	52.05	52.02	58.18
9	5.22	25	58.00	17.90	24.16	27.18	64.38	71.61	74.74	48.88	49.21	49.92	51.54	51.54	76.60
9	5.01	25	55.74	15.56	26.25	23.29	61.58	73.67	70.73	48.29	48.95	49.12	50.97	51.06	72.05
9	4.49	25	49.94	10.41	20.47	21.15	58.16	67.79	68.58	44.53	45.76	46.99	50.67	50.66	69.93
36	18.26	25	50.73	14.12	20.42	22.70	60.87	68.00	70.28	47.81	48.18	49.15	51.05	51.09	71.79
36	21.21	25	58.94	18.14	27.88	23.67	64.82	75.51	71.29	47.57	48.86	49.06	51.01	51.12	72.79
36	17.43	25	48.43	11.43	19.54	21.47	58.49	67.04	69.17	46.45	47.18	48.02	51.22	51.26	70.55
1	0.81	32	81.30	17.94	34.58	31.68	78.65	82.22	79.13	49.15	49.15	48.03	97.12	98.16	24.94
1	0.83	32	83.30	36.57	41.45	29.84	81.55	89.17	76.98	50.52	49.28	48.72	96.54	98.19	23.90
1	0.44	32	44.30	14.21	15.58	16.81	56.09	63.42	63.92	51.97	51.97	48.00	98.44	99.72	11.13
9	7.50	32	83.42	24.62	34.92	29.81	78.67	82.74	63.92	48.49	46.70	46.49	95.05	97.18	23.72
9	6.50	32	72.22	33.82	32.25	27.25	74.37	80.06	74.75	51.12	48.47	47.27	96.11	98.22	21.14
9	6.41	32	71.30	20.82	32.17	24.96	72.05	79.97	72.47	50.13	43.93	43.37	91.64	95.39	18.50
36	28.69	32	79.71	16.54	32.34	27.35	75.54	80.26	74.96	48.79	46.12	45.74	94.65	96.94	21.29

área parcela (m ²)	área de planta (m ²)	DDS	FCO	Fracción de cobertura estimada (FCE)											
				IsoData			Otsu			Fuzzy			Momentos		
				ExG	NGRDI	TGI	ExG	NGRDI	TGI	ExG	NGRDI	TGI	ExG	NGRDI	TGI
36	28.41	32	78.93	29.70	34.54	28.46	75.66	82.45	76.03	50.70	48.04	46.74	95.46	98.08	22.21
36	25.07	32	69.66	18.79	29.37	24.38	70.61	77.29	71.95	50.31	44.94	43.78	93.03	96.35	18.14
1	0.76	39	76.80	30.38	39.90	37.34	73.90	87.30	14.87	50.51	50.89	48.89	30.55	99.94	26.45
1	0.82	39	82.30	30.49	42.32	30.17	75.20	89.21	22.34	48.03	46.68	45.22	29.89	99.36	18.45
1	0.72	39	72.90	10.40	21.33	29.36	54.98	67.37	23.27	52.16	51.52	51.35	9.47	0.00	15.86
9	7.46	39	82.91	29.58	39.41	34.57	73.42	86.85	17.60	50.20	48.39	46.09	29.88	99.90	25.63
9	6.41	39	71.29	25.02	33.89	27.73	69.28	81.08	24.44	49.94	46.26	43.37	24.91	99.66	17.67
9	6.58	39	73.13	22.01	33.80	29.06	66.02	80.78	23.10	50.46	46.87	45.54	21.57	99.79	17.62
36	28.99	39	80.55	28.22	38.09	34.05	72.04	85.58	18.03	50.30	48.90	46.67	28.33	99.85	24.78
36	27.61	39	76.71	24.73	34.99	28.27	69.02	82.27	17.73	50.11	45.02	42.48	24.62	99.52	17.82
36	26.96	39	74.89	21.20	31.78	30.03	65.55	78.82	22.02	51.01	48.26	46.20	20.94	99.89	19.03
1	0.88	46	88.50	30.38	37.86	35.15	76.57	85.30	17.31	48.29	48.23	48.41	99.57	41.03	35.67
1	0.91	46	91.30	30.00	38.54	32.80	76.12	85.78	19.49	45.50	45.90	46.06	99.33	42.08	33.47
1	0.74	46	74.40	9.59	15.47	26.07	56.22	62.60	26.17	50.25	50.56	49.12	99.98	28.97	27.25
9	7.76	46	86.22	31.00	38.72	33.63	77.25	86.62	18.50	46.31	47.66	46.56	99.54	42.21	33.94
9	7.20	46	80.08	23.23	29.29	28.52	69.70	77.14	23.65	44.18	45.86	42.74	99.46	35.56	29.15
9	6.89	46	76.56	22.24	30.83	28.75	68.57	78.61	23.41	43.34	44.49	43.53	99.05	36.36	29.21
36	30.84	46	85.68	29.32	37.49	33.47	75.72	85.42	18.63	46.91	47.61	46.81	99.57	41.45	33.94
36	30.17	46	83.81	25.07	32.38	30.34	71.49	80.33	21.77	43.81	45.04	43.37	99.13	38.09	50.00
36	28.46	46	79.06	22.10	29.68	28.73	68.59	77.61	23.29	45.55	46.23	45.54	99.52	36.38	29.18

Anexo 5. Valores de la fracción de cobertura estimada FCE mediante combinaciones de índices y métodos de umbralización por parcelas en función de los días después de la siembra.