

**CUANTIFICACIÓN SEMIAUTOMÁTICA EN CULTIVOS CÍTRICOS UTILIZANDO
IMÁGENES AÉREAS, CASO DE ESTUDIO DAGUA-VALLE DEL CAUCA**

**MARIO ERNESTO AMADOR ORTIZ
CRISTHIAN ANDRES GUERRERO TABARES
Trabajo de grado**

**Director:
ING. CÉSAR EDWIN GARCÍA**

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA TOPOGRÁFICA
SANTIAGO DE CALI
2025**

AGRADECIMIENTOS

Queremos brindar un especial agradecimiento a nuestro director y profesor, el ingeniero Cesar Edwin García, quien fue un pilar fundamental en nuestra formación académica de principio a fin, siempre demostró un sincero interés en todos nuestros proyectos, nos animó, apoyó y asesoró para poder desarrollar este proyecto. Igualmente, a la Universidad del Valle y todos los docentes que hicieron parte de nuestra vida académica.

También queremos agradecer a nuestras familias quienes fueron fundamentales durante toda nuestra formación académica, brindándonos apoyo emocional, económico y espiritual, motivándonos alcanzar nuestros objetivos personales y académicos.

Agradecer también a los ingenieros de la CVC DAR Pacifico Este, quienes nos brindaron sus conocimientos y equipos necesarios para desarrollar este proyecto.

RESUMEN

La detección y el conteo arbóreo en cultivos agrícolas es una problemática común, debido a la dificultad para realizar censos manuales precisos sin incurrir en altos costos operativos y tiempos prolongados. En este estudio se implementó un algoritmo de detección para cuantificar árboles en cultivos cítricos a partir de mosaicos generados con imágenes aéreas obtenidas mediante vehículos aéreos no tripulados (*Unmanned Aerial Vehicles*, UAV). La metodología integró dos enfoques, primero un procesamiento manual supervisado, que incluyó la captura de imágenes, toma de puntos de control con receptores (*Global Navigation Satellite System*, GNSS) y procesamiento de imágenes; el segundo es un procesamiento autónomo, donde se utiliza el algoritmo de aprendizaje autónomo *Random Forests* para aplicar el índice *espectral Green Leaf Index* (GLI) y realizar la segmentación de la vegetación, y el algoritmo DBSCAN se utilizó para la clasificación de valores de píxel. La evaluación del desempeño se realizó mediante métricas basadas en los resultados de matrices de confusión, obteniendo una precisión global entre 76.98 y 84.44 %, lo que demuestra la viabilidad del método propuesto al compararse con investigaciones similares.

PALABRAS CLAVE.

Agricultura de precisión, detección semiautomática, UAV's, conteo arbóreo, segmentación de imágenes.

ABSTRACT

Detection and counting of trees in agricultural crops is a common issue due to the difficulty of conducting accurate manual censuses without incurring high operational costs and prolonged timeframes. In this study, a detection algorithm was implemented to identify and quantify trees in citrus crops from mosaics generated with aerial images obtained via unmanned aerial vehicles (UAVs). The methodology integrated two approaches: first, a supervised manual processing, which included image capture, control point collection with GNSS receivers, and image processing; and second, an autonomous processing, which utilized the autonomous learning algorithm Random Forest to apply the Green Leaf Index (GLI) spectral index and perform vegetation segmentation, and the DBSCAN algorithm for pixel value classification. The performance evaluation was conducted using metrics based on confusion matrix results, obtaining an overall accuracy between 76.98 and 84.44 %, demonstrating the feasibility of the proposed method when compared to similar research.

KEYWORDS:

Precision agriculture, semi-automatic classification, agricultural monitoring, tree inventory, image segmentation.

TABLA DE CONTENIDO

RESUMEN.....	3
ABSTRACT	4
1. INTRODUCCIÓN.....	12
2. PROBLEMÁTICA.....	13
3. OBJETIVOS	15
3.1. OBJETIVO GENERAL	15
3.2. OBJETIVOS ESPECÍFICOS	15
4. JUSTIFICACIÓN	16
5. MARCO CONTEXTUAL.....	17
5.1. CULTIVO DE CÍTRICOS EN EL MUNICIPIO DE DAGUA.....	17
6. MARCO CONCEPTUAL	19
6.1. AGRICULTURA DE PRECISIÓN	19
6.1.1. CUANTIFICACIÓN ARBÓREA.....	20
6.1.2. INDIVIDUO ARBÓREO	21
6.2. FOTOGRAMETRÍA.....	21
6.2.1. METADATOS	24
6.2.2. NUBE DE PUNTOS.....	25
6.3. SOFTWARE DE MAPEO	25
6.4. ÍNDICE <i>GREEN LEAF INDEX</i> (GLI)	27
6.5. CLUSTERING Y DBSCAN.....	28
7. MARCO REFERENCIAL.....	29

8. MARCO TEÓRICO.....	36
8.1. RANDOM FOREST.....	36
8.1.1. GENERACIÓN DE CONTRASTE ÓPTICO A TRAVÉS DE GREEN LEAF INDEX (GLI)	37
8.2. CLASIFICACIÓN DE VALORES DE PÍXEL POR MEDIO DEL ALGORITMO DBSCAN.....	37
8.3. EVALUACIÓN DEL MODELO.....	39
8.3.1. MATRIZ DE CONFUSIÓN.....	39
9. METODOLOGÍA.....	41
9.1. MATERIALES.....	42
9.1.1. ZONA DE ESTUDIO.....	42
9.1.2. DISPOSITIVO GNSS.....	44
9.1.3. VEHÍCULO AÉREO NO TRIPULADO (UAV).....	46
9.1.4. EQUIPO INFORMÁTICO.....	49
9.1.5. SOFTWARE AGISOFT METASHAPE.....	49
9.1.6. PUNTOS DE CONTROL (<i>Ground Control Points</i> , GCPs).....	49
9.1.7. IMÁGENES FOTOGRAMÉTRICAS.....	49
9.1.8. SOFTWARE PYTHON.....	50
9.1.9. IDE (ENTORNO DE DESARROLLO INTEGRADO).....	50
9.1.10. ORTOMOSAICO.....	50
9.1.11. PUNTOS DE ENTRENAMIENTO.....	50
9.1.12. SOFTWARE MICROSOFT EXCEL.....	50
9.2. MÉTODO.....	52
9.2.1. LEVANTAMIENTO DE DATOS GEOESPACIALES.....	53
9.2.2. PREPROCESAMIENTO DE IMÁGENES.....	56
9.2.3. PROCESAMIENTO DE DATOS.....	59
9.2.4. ANÁLISIS DE RESULTADOS.....	63
10. RESULTADOS.....	65
10.1. EJECUCIÓN DEL ALGORITMO.....	65
10.2. RESULTADOS DE MUESTRAS.....	71
10.2.1. MUESTRA 1.....	71
10.2.2. MUESTRA 2.....	74
10.2.3. MUESTRA 3.....	76
10.2.4. MUESTRA 4.....	79
10.2.5. MUESTRA 5.....	81
10.2.6. MUESTRA 6.....	83

11.	DISCUSIÓN	86
12.	CONCLUSIONES	88
13.	BIBLIOGRAFÍA	90
14.	ANEXOS	97
14.1.	ANEXO A	97

LISTA DE FIGURAS

Figura 1. <i>Individuo arbóreo de especie Citrus limón</i>	21
Figura 2. <i>Diagrama del proceso metodológico</i>	41
Figura 3. <i>Localización del Municipio Dagua dentro del Departamento de Valle del Cauca</i>	42
Figura 4. <i>Localización finca Campo Alegre</i>	43
Figura 5. <i>Clasificación de árboles por grupo según su desarrollo morfológico</i>	44
Figura 6. <i>Receptor GNSS Reach RS2</i>	45
Figura 7. <i>UAV DJI Mavic Air 2S</i>	46
Figura 8. <i>Configuración y diseño de vuelo fotogramétrico</i>	53
Figura 9. <i>Localización de puntos de control terrestre</i>	54
Figura 10. <i>Diana de alta visibilidad.</i>	55
Figura 11. <i>Equipo receptor GNSS REACH RS2</i>	55
Figura 12. <i>Configuración y resultado de alineación de imágenes.</i>	57
Figura 13. <i>Configuración y resultado de nube de puntos densa</i>	58
Figura 14. <i>Configuración y resultado de ortomosaico</i>	59
Figura 15. <i>Interfaz de inicio del algoritmo para conteo arbóreo</i>	66
Figura 16. <i>Ventana de inicio para pestaña Preproceso</i>	67
Figura 17. <i>ventana de dialogo para selección de zona de estudio</i>	68
Figura 18. <i>ventana para selección de puntos de entrenamiento</i>	68
Figura 19. <i>ventana de inicio de proceso</i>	70
Figura 20. <i>ventana de resultados</i>	71
Figura 21. <i>Resultados de cuantificación semiautomática para la muestra 1</i>	72

Figura 22. Comparación de predicciones hechas por el algoritmo con conteo manual	72
Figura 23. Resultados de cuantificación semiautomática para la muestra 2	74
Figura 24. Comparación de predicciones hechas por el algoritmo con conteo manual	75
Figura 25. Resultados de cuantificación semiautomática para la muestra 3	77
Figura 26. Comparación de predicciones hechas por el algoritmo con conteo manual	77
Figura 27. Resultados de cuantificación semiautomática para la muestra 4	79
Figura 28. Comparación de predicciones hechas por el algoritmo con conteo manual	79
Figura 29. Resultados de cuantificación semiautomática para la muestra 5	81
Figura 30. Comparación de predicciones hechas por el algoritmo con conteo manual	81
Figura 31. Resultados de cuantificación semiautomática para la muestra 6	83
Figura 32. Comparación de predicciones hechas por el algoritmo con conteo manual	84

LISTA DE TABLAS

Tabla 1. Categorías de elaboración para la matriz de confusión	39
Tabla 2. <i>Características de receptor GNSS REACH RS2</i>	45
Tabla 3. <i>Características de UAV MAVIC AIR2S</i>	47
Tabla 4. <i>Características de sensor CMOS 1"</i>	48
Tabla 5. <i>Características de materiales usados en la etapa de preprocesamiento de imágenes y Procesamiento de datos</i>	51
Tabla 6. <i>Comparación de desempeño entre algoritmo y operario humano en la muestra 1</i>	73
Tabla 7. <i>Resultados de matriz de confusión en muestra 1</i>	73
Tabla 8. <i>Resultado de cálculo de métricas en la muestra 1</i>	73
Tabla 9. <i>Comparación de desempeño entre algoritmo y operario humano en la muestra 2</i>	75
Tabla 10. <i>Resultados de matriz de confusión en muestra 2</i>	75
Tabla 11. <i>Resultado de cálculo de métricas en la muestra 2</i>	76
Tabla 12. <i>Comparación de desempeño entre algoritmo y operario humano en la muestra 3</i>	78
Tabla 13. <i>Resultados de matriz de confusión en muestra 3</i>	78
Tabla 14. <i>Resultados de cálculo de métricas en muestra 3</i>	78
Tabla 15. <i>Comparación de desempeño entre algoritmo y operario humano en la muestra 4</i>	80
Tabla 16. <i>Resultados de matriz de confusión en muestra 4</i>	80
Tabla 17. <i>Resultados de cálculo de métricas en muestra 4</i>	80

Tabla 18. <i>Comparación de desempeño entre algoritmo y operario humano en la muestra 5</i>	82
Tabla 19. <i>Resultados de matriz de confusión en muestra 5</i>	82
Tabla 20. <i>Resultados de cálculo de métricas en muestra 5</i>	82
Tabla 21. <i>Comparación de desempeño entre algoritmo y operario humano en la muestra 6</i>	84
Tabla 22. <i>Resultados de matriz de confusión en muestra 6</i>	84
Tabla 23. <i>Resultados de cálculo de métricas en muestra 6</i>	85
Tabla 24. <i>Resultado de cálculo promedio métricas.</i>	87

1. INTRODUCCIÓN

La agricultura es un sector esencial para la economía global, proporcionando el 27 % del empleo mundial y asegurando la seguridad alimentaria de la población. FAO. (2021). Sin embargo, la creciente demanda de alimentos y los efectos del cambio climático han generado la necesidad de implementar tecnologías avanzadas para mejorar la eficiencia de la producción agrícola. Hasan, M. M., et al., (2022). En la actualidad, el uso de sensores remotos y técnicas de análisis de imágenes ha demostrado ser una herramienta eficaz para optimizar la gestión, monitoreo y producción de cultivos agrícolas. Zhang, et al., (2019).

En el caso de Colombia, el sector agropecuario contribuye entre el 6 y el 8 % del PIB nacional y emplea a más del 15 % de la población económicamente activa. Finagro, (2023), No obstante, es necesario el aumento de la productividad agropecuaria, ya que puede ayudar a incrementar el ingreso y bienestar de la población rural, mejorar el balance comercial del sector agropecuario, minimizar el impacto de la agricultura en los recursos naturales, reducir las emisiones de gases de efecto invernadero (GEI) y mitigar el cambio climático. Banco Mundial. (2022).

Sin embargo, los cultivos están en constante exposición a fenómenos climáticos extremos, plagas y enfermedades, los cuales pueden afectar gravemente la producción y calidad de los cultivos, este riesgo aumenta si el proceso de monitoreo y control de los cultivos se realiza de forma tradicional. Berrío, et al., (2015). Por otro lado, Falk y Campos, (2014) recalcan la importancia del conteo arbóreo actualizado, pues este permite comprender el estado real de la forestación y su evolución a través del tiempo, permitiendo detectar cambios significativos en etapas tempranas.

De Castro, (2018) en su investigación, confirma que la integración de tecnologías como los vehículos aéreos no tripulados (*Unmanned Aerial Vehicles*, UAV) y la automatización de procesos en la agricultura, permiten mejorar el monitoreo agrícola y la detección temprana de cambios en los cultivos, lo que permite a los agricultores reaccionar con antelación ante anomalías y tomar decisiones adecuadas. El presente estudio propone abordar esta problemática implementando una metodología que logre optimizar el proceso cuantificación de árboles de manera semiautomática en un cultivo de cítricos mediante el uso de UAVs, con el objetivo de aminorar los tiempos en el conteo tradicional de arboles

2. PROBLEMÁTICA

Los cultivos arbóreos y arbustivos, como la naranja y el limón, enfrentan diversos desafíos derivados del cambio climático, los cuales pueden afectar significativamente su productividad. Las soluciones propuestas por la agricultura convencional no disminuirán los problemas de hambruna, su alto costo puede generar impactos sociales y ambientales adversos, especialmente en países en desarrollo. IAASTD. (2009)

La agricultura es una actividad esencial para la supervivencia humana, especialmente ahora cuando los efectos del cambio climático se notan en mayor medida y además se presenta un rápido aumento de la población mundial. Por ende, es oportuno atribuir un aumento en la salida de productos destinados al campo de la agricultura, Según Godfray et al. (2010), se demandará aumentar la producción de alimentos en aproximadamente un 70 % para el año 2050, proyectando que la población mundial podría alcanzar cerca de 9 mil millones de habitantes. Para Pederi y Cheporniuk, (2015) salvaguardar los cultivos de distintos factores influye en el 50 % del rendimiento de la producción agrícola, el brindar la protección a los cultivos genera un incremento en los gastos ya que se necesita disponer de mayores recursos para realizar un monitoreo permanentemente, se debe tener en cuenta también que el terreno donde se encuentra el cultivo puede presentar dificultades a la hora de recorrerlo influyendo directamente en el tiempo de monitoreo.

La implementación de un inventario, control y registro es importante para el cuidado de los árboles en cultivos agrícolas. Sin embargo, realizar este proceso manualmente, demanda de tiempo y recursos ya que requiere de recurso humano calificado y desplazamiento entre los cultivos, por consiguiente, llevar a cabo un inventario exhaustivo de todos los árboles en una plantación puede representar un gasto significativo para el agricultor, afectando sus ingresos. Vásquez, A.; Restrepo, C., (2019).

La gestión eficiente de cultivos arbustivos en la actualidad enfrenta desafíos importantes, especialmente cuando se requiere realizar una cuantificación precisa de árboles en grandes extensiones. Para Avitt, A. (2020) los métodos tradicionales, como el conteo manual, implican altos costos y tiempos de empleo, lo que afecta la capacidad de los agricultores para tomar decisiones informadas sobre la productividad y el manejo de sus cultivos. Estas limitaciones plantean la necesidad

de explorar alternativas innovadoras que optimicen el proceso de conteo, dando lugar a la pregunta:

¿Cómo realizar un conteo arbóreo eficiente y preciso en cultivos arbustivos, minimizando los recursos y tiempo para su ejecución, utilizando como insumos mosaicos derivados de imágenes aéreas?

3. OBJETIVOS

3.1. OBJETIVO GENERAL

Realizar un conteo arbóreo en cultivos arbustivos de cítricos de forma semi automática, utilizando imágenes aéreas.

3.2. OBJETIVOS ESPECÍFICOS

- Identificar el contorno típico de los árboles en los cultivos estudiados.
- Implementar un algoritmo que permita extraer las características específicas como el número de árboles en un área definida.
- Evaluar los resultados obtenidos con la implementación de la metodología propuesta

4. JUSTIFICACIÓN

En la actualidad se busca consolidar una seguridad alimentaria a futuro, implementando nuevas tecnologías que permitan concentrar la atención en particularidades de los cultivos para disminuir gastos. Solórzano, et al., (2016). Entre tanto, la agricultura de precisión recopila la información necesaria para monitorear cultivos, realizando predicciones de rendimiento, control de riego entre otras. Por ello, Mitsikostas, E., (2017) plantea mejorar las producciones agrícolas utilizando vehículos aéreos no tripulados para el control y monitoreo de estos. Reduciendo gastos y permitiendo que los agricultores tengan mayores beneficios económicos.

En Colombia se ha implementado el uso de tecnologías en la agricultura, por ejemplo, en cultivos de caña se hace el uso de (UAV) para el monitoreo y conteo de plantas, en los aportes de Gaitán García, C. A. (2017), se pudo detectar sectores de resiembra de tallos, con el fin de elevar la productividad del lote.

Por esto, conocer la cantidad de árboles en un cultivo es un dato importante para los agricultores, ya que este es un indicativo de la productividad agrícola del cultivo; esta es una tarea que en la actualidad en la mayoría de las actividades del país se desarrolla en sitio, lo que ocasiona que los tiempos en el monitoreo de cultivos sea mayor y menos precisión, lo que al final puede ocasionar pérdidas en recursos y tiempo. Koc-San, et al., (2018).

Asimismo, el mapeo individual de los árboles en los entornos agrícolas es importante para mejorar el manejo de cultivos. Este monitoreo se debe realizar con cierta regularidad en varios niveles a lo largo del ciclo de vida de la planta. Un enfoque automatizado y estandarizado desempeñará un papel clave en la calidad de los resultados lo cual permitirá la toma de decisiones oportuna. Csillik, et al., (2018).

Con este proyecto se busca implementar un algoritmo de aprendizaje autónomo que sea capaz de realizar una cuantificación de árboles en diferentes cultivos arbustivos, logrando optimizar el proceso de monitoreo y desarrollo del cultivo en sus diferentes etapas; los principales beneficiarios con este proyecto son los agricultores con grandes extensiones de cultivos arbóreos.

5. MARCO CONTEXTUAL

Colombia es un país con una amplia diversidad agroclimática que favorece la producción de cultivos cítricos como naranja, limón y mandarina. Este subsector agrícola tiene un papel relevante en la economía nacional, representando el 7,6 % del área cultivada con frutales en el país, lo que equivale a aproximadamente 85.000 hectáreas sembradas. Minagricultura. (2020). Las principales zonas productoras de cítricos incluyen departamentos como Antioquia, Santander, Tolima y Valle del Cauca.

Por otro lado, El Valle del Cauca es una de las regiones más representativas en la producción agrícola del país, destacándose por su contribución significativa al abastecimiento de frutas y verduras en el mercado nacional, Minagricultura, (2020). Dentro de esta región, los cítricos ocupan una posición estratégica debido a su adaptabilidad a las condiciones agroecológicas locales, Según datos de Minagricultura. (2017), el departamento contaba con 3.232 hectáreas sembradas de cítricos, con una producción de 18.583 toneladas. Municipios como Jamundí y Ansermanuevo se destacan en esta actividad.

El caso de estudio para esta investigación se localiza en el municipio de Dagua, ubicado en el departamento del Valle del Cauca, Colombia. Esta región, caracterizada por su clima cálido y geografía montañosas, es reconocida por la producción agrícola de cítricos, un sector que representa una fuente económica clave tanto para pequeños como para grandes productores, CVC. (2014). Sin embargo, el sector agrícola enfrenta retos asociados a la sostenibilidad y la implementación de nuevas tecnologías que permitan optimizar la productividad y el manejo de los recursos disponibles, Gago, et al., (2015). En Dagua, predomina una agricultura basada en prácticas tradicionales con baja adopción de tecnologías avanzadas, esta situación ha motivado a entidades como la Corporación autónoma regional del Valle del Cauca (CVC), a impulsar iniciativas orientadas a modernizar el sector agrícola, con el objetivo de promover prácticas agrícolas sostenibles y mejorar la productividad en la región. CVC. (2014)

5.1. CULTIVO DE CÍTRICOS EN EL MUNICIPIO DE DAGUA

Su diversidad climática, determinada por la presencia de distintos pisos térmicos, especialmente el cálido y el templado, crea condiciones agroecológicas favorables para el desarrollo agrícola y pecuario, así como a diferentes actividades agroindustriales o de transformación de materias primas en productos terminados. Estas zonas se encuentran en rangos altitudinales que varían entre los 1.200 y

1.800 metros sobre el nivel del mar, con temperaturas promedio que oscilan entre los 17 °C y 24 °C. Municipio de Dagua. (2009)

Mayoritariamente las tierras se han destinado al cultivo de piña, caña, panelera, plátano, cacao, entre otros, seguido del pastoreo de ganado y la explotación forestal, que demandan gran cantidad de agua. CVC. (2104)

Este municipio presenta condiciones favorables para el cultivo de limón, especialmente el limón Tahití, entre las que destaca la altitud media del municipio sobre el nivel del mar. Esta característica y las condiciones climáticas de la región son adecuadas para el desarrollo de cultivos cítricos. Los cultivos de limón Tahití se han adaptado muy bien a las condiciones tropicales presentando un buen comportamiento productivo en zonas subtropicales. En Colombia, los cultivos de limón Tahití representan grandes oportunidades para la exportación debido a su excelente calidad. DANE, (2015).

La Alcaldía del Municipio Dagua ha establecido contrataciones con la Casa Agraria del Pacífico S.A.S. para compra de árboles frutales cítricos, concretamente de las variedades limón Tahití y pajarito, naranja mineola y mandarina arrayana, para fortalecer los procesos de seguridad alimentaria en varias veredas del municipio. SECOP I, (2018).

La agricultura de cítricos requiere un manejo preciso para maximizar la producción y minimizar el impacto ambiental. Las actividades de manejo incluyen la cuantificación arbórea, esencial para planificar labores como la fertilización, el riego y la poda. No obstante, los métodos tradicionales de conteo, que implican recorridos manuales en campo, presentan importantes limitaciones debido a los altos costos, el tiempo requerido y el riesgo de error humano, especialmente en áreas extensas o de difícil acceso, Gago et al., (2015). Estas limitaciones subrayan la necesidad de herramientas tecnológicas más eficientes y precisas que optimicen estas tareas y reduzcan costos operativos, IAASTD, (2009).

6. MARCO CONCEPTUAL

6.1. AGRICULTURA DE PRECISIÓN

La agricultura de precisión, también conocida como “agricultura por satélite” o “manejo-sitio específico de los cultivos”, es un tipo de aplicación agrícola de las Tecnologías de la Información y Comunicación (TIC), cuyo objetivo es mejorar la productividad agrícola mediante la aplicación de técnicas que tienen en cuenta las particularidades en el desarrollo de los cultivos, el estado del suelo o los factores climáticos, y se aleja de las aplicaciones tradicionales y homogéneas. Esta se basa en la observación, medición y respuesta a la variabilidad temporal y espacial para mejorar la sostenibilidad de la producción agrícola. Beltrán Barreto, G. X. (2023)

La agricultura de precisión se muestra como una excelente herramienta para aumentar el rendimiento y minimizar los costos en áreas que presentan limitantes para la agricultura convencional. A través de la elaboración de distintos mapas de rendimiento y cuantificación arbórea del cultivo, se puede aplicar dosis óptimas de pesticidas, abonos, fertilizantes, etc. La agricultura de precisión utiliza tecnologías avanzadas como sensores, sistemas de información geográfica, UAV, satélites y software de análisis de datos, a fin de recopilar y analizar información sobre el terreno, los cultivos y las condiciones climáticas. La información así obtenida se utiliza para tomar decisiones precisas y oportunas sobre la gestión de los cultivos, para optimizar la producción agrícola. Esto aporta en gran medida a la disminución en el costo de la producción de diversos cultivos; además contribuye con una agricultura más amigable con el medio ambiente. Marote, (2010).

La integración de la electrónica, electrohidráulica, electroneumática, robótica, (*Global Navigation Satellite System*, GNSS) y softwares específicos en la maquinaria agrícola actual y futura, permitirá avances significativos en términos de prestación, automatización y entrega de información. Se presume que quienes no sigan el desarrollo de estos avances tecnológicos en proceso y productos quedarán fuera del mercado, ya que estas tecnologías revolucionarias transformarán la agricultura y mejorarán la eficiencia en la producción agrícola. Marote, (2010).

6.1.1. CUANTIFICACIÓN ARBÓREA

El inventario arbóreo (también denominado “inventario florístico”, “inventario forestal” o “levantamiento arbóreo”) consiste en la identificación, mapeo, marcado y medición de especies vegetales en un área específica. Este proceso es una etapa necesaria en el proceso de licenciamiento ambiental y constituye un trabajo de evaluación cuantitativa y cualitativa de las especies forestales presentes en un determinado lote. Es fundamental para la planificación y gestión ambiental de proyectos que involucren la ocupación de áreas con presencia de individuos arbóreos o manchas de vegetación. FAO, (2004).

El inventario arbóreo es efectuado por profesionales como ingenieros forestales e ingenieros topográficos. Los datos en él recopilados se integran en un informe que se entrega al cliente. Tal proceso es fundamental para la planificación y gestión de áreas verdes, aunque también para la forestación con especies adecuadas a las condiciones específicas de suelo, clima y espacios físicos. Por otro lado, es obligatorio para los nuevos emprendimientos, bien sea con fines públicos o privados, residenciales, comerciales o industriales. Palacio y Pedraza, (2012).

Un inventario arbóreo actualizado permite recolectar información cuantitativa sobre los cultivos, además de brindar información para la planificación, diseño, plantación y mantenimiento. Un inventario de árboles proporciona la ubicación, cantidad de árboles por zona y ayuda a identificar problemas que pueden afectar el desarrollo del cultivo, como vacíos, áreas sin sembrar. Con la información recolectada se pueden planificar y priorizar los mantenimientos, administrar la información para identificar diversos datos de los árboles. Elmendorf, (2022).

Para efectuar el inventario arbóreo se requieren los datos de localización del terreno o áreas de muestreo (divididas a su vez en parcelas u otras subunidades, dependiendo de la extensión del área a evaluar) y la ubicación cartográfica de los árboles (mediante georreferenciación en la que se representan los árboles como puntos sobre plano digital a escala). Los materiales que suelen emplearse son los planos digitales y físicos, formatos para el registro de la información levantada en el campo; y, ya en la era de la agricultura de precisión, sensores satelitales o UAV, para el mapeo fotográfico del campo. Palacio y Pedraza, (2012).

6.1.2. INDIVIDUO ARBÓREO

Un individuo arbóreo es la unidad cuantificable en los inventarios arbóreos o en las clasificaciones forestales, de acuerdo con su caracterización, variable según la hoja, fruto, flor, altura, corteza, estructura, ecosistema, etc. Bejarano y García, (2018). La presente investigación se realizará para contar los individuos arbóreos de la especie *Citrus limón*, árbol frutal perenne de la familia Rutaceae. El árbol, conocido comúnmente como limonero, tiene tronco delgado y ramificado, con hojas simples, grandes y ovaladas de color verde brillante; flores pequeñas y aromáticas, con pétalos blancos en la parte superior y purpúreos en el dorso. El fruto del limón es de forma oval u oblonga, de color verde o amarillo verdoso, con cáscara gruesa y punteada de glándulas. La altura promedio de las plantas adultas oscila entre los 3 y los 6 metros. UEIA, U. (2014).

Figura 1.

Individuo arbóreo de especie Citrus limón



Fuente: Elaboración propia, fotografía tomada en zona de estudio

6.2. FOTOGRAMETRÍA

La fotogrametría es una técnica de registro visual desarrollada con el objetivo de estudiar y definir con precisión la forma, dimensiones y posición en el espacio de un objeto cualquiera, utilizando esencialmente medidas hechas sobre una o varias fotografías de ese objeto. Instituto Geográfico Nacional, (2020). Ortega (2018) define la fotogrametría como “el arte, ciencia y tecnología de obtención de información confiable sobre los objetos físicos y el medio ambiente a través del

proceso de registro, medición e interpretación de imágenes fotográficas, patrones de imágenes de radiancia electromagnética y otros” (p. 34).

Esta técnica, arte, ciencia o tecnología permite obtener información en primera instancia de la geometría del objeto, es decir, información bidimensional; y con dos fotos, en la zona común a estas, se puede tener visión estereoscópica, es decir, información tridimensional.

Según el tipo de fotograma, la fotogrametría es terrestre (cuando se usa en una posición tal que el eje de la cámara resulta horizontal y paralelo al terreno o corteza terrestre) o aérea (cuando las fotografías se obtienen desde vehículos aéreos y el eje óptico de la cámara resulta sensiblemente perpendicular al terreno o corteza terrestre). Según el tipo de tratamiento, la fotogrametría es analógica (cuando se usan directamente las fotografías formando modelos estereoscópicos y reconstruyendo el modelo espacial con sistemas ópticos o mecánicos), analítica (cuando el modelo espacial se reconstruye mediante programas informáticos simuladores de la geometría) o digital (cuando se usan fotografías aéreas previamente transformadas a formato digital, reconstruyendo el modelo espacial de forma numérica o digital).

Según Ortega (2018), la fotogrametría digital se centra en el uso de fotografías digitales para almacenar información en un archivo *denominado Exif (Exchangeable image file format)*, que incluye datos como la fecha y hora, información de localización, coordenadas GNSS conectadas a la cámara, y datos de configuración y calibración de la cámara. Esta tecnología ha evolucionado y se ha automatizado para obtener medidas precisas y generar datos espaciales 3D y modelos 3D a partir de una nube de puntos de manera más rápida. La disponibilidad de imágenes en formato digital y el aumento de la capacidad de procesamiento de los computadores digitales han permitido la adaptación de técnicas de otras disciplinas, como el procesamiento digital de imágenes, el reconocimiento de patrones y la inteligencia artificial, que se han incorporado al método fotogramétrico, especialmente en la automatización de tareas, reduciendo el trabajo del operador fotogramétrico.

La fotogrametría mediante UAVs consiste en la captura de múltiples imágenes aéreas de un objeto o superficie terrestre, las cuales son procesadas para generar modelos digitales en dos o tres dimensiones con alta resolución espacial, el procesamiento de las imágenes se realiza mediante *softwares* especializados como *Agisoft Metashape* o *Pix4Dmapper*. Estos *softwares* emplean algoritmos de correlación y estructura desde el movimiento (*Structure from Motion*, SfM) para identificar coincidencias entre las imágenes y generar productos cartográficos de alta resolución, como ortomosaicos, modelos digitales de superficie (MDS) y

modelos digitales de terreno (MDT), a partir de los cuales es posible derivar mediciones espaciales precisas. Over, et al., (2021). Estas técnicas tienen aplicaciones en áreas como la agricultura de precisión, minería, medio ambiente, evaluación de la vegetación, ingeniería y obras civiles, entre otros. Para garantizar la precisión en la fotogrametría con UAVs, es necesario tomar fotografías desde múltiples ángulos, ya que una sola fotografía aérea no puede utilizarse como mapa fotogramétrico. Dependiendo de la escala del proyecto, la creación de un modelo fotogramétrico puede requerir de un par de cientos a varios miles de imágenes individuales, por lo que los UAV suelen ser la forma más económica de tomar todas las fotografías aéreas necesarias para crear este tipo de mediciones en comparación con otros métodos de topográficos. Fernández Requelme, J. L., & Narro Mantilla, V. A. (2024).

La fotogrametría se utiliza en diversas aplicaciones, tales como la topografía, la cartografía digital, la ortofotografía, el medio ambiente, la agricultura, la arqueología, la conservación del patrimonio, la arquitectura, los videojuegos y el cine, ya que ofrece un gran realismo. La técnica se ha perfeccionado con el uso de TIC, lo que ha permitido su aplicación en distintos campos y la exportación del resultado de las imágenes finales en formato ráster o vectorial. La fotogrametría aérea, por ejemplo, permite una gran amplitud de captación, aunque no se conoce ni la posición de la cámara ni su orientación en el momento del disparo, pero la tecnología y digitalización de los procesos permiten resolver estos problemas. La fotogrametría es una de las actividades más emblemáticas en la obtención de modelos de elevaciones, proporcionando información de referencia básica para la realización de la cartografía y la obtención de información geográfica en general. Global Mediterránea Geomática, (2020).

Por tanto, la fotogrametría se presenta como una alternativa eficiente que une e innova en las labores agrícolas de inventarios arbóreos de cultivos. La agricultura de precisión utiliza las imágenes provenientes de satélites o las fotografías aéreas obtenidas a partir de vehículos aéreos tripulados y no tripulados para obtener información acerca de los cultivos. González, et al., (2016).

La fotogrametría a partir de un conjunto de imágenes aéreas obtiene información fidedigna del entorno y los objetos físicos. Ortega, (2018). A través de los años por distintas fases la analogía, la analítica y la digital (está en los últimos años) se ha incrementado por el uso de los UAVS en distintas áreas como la agricultura. El uso de estos vehículos ayuda a capturar información importante para realizar una evaluación de las condiciones de los terrenos monitoreados. Además, brindan grandes ventajas para sobrevolar los campos y los cultivos, disminuyendo el tiempo

en el que se recorren los cultivos ya que no es necesario hacerlo de manera manual y se puede realizar a distancia. González, et al., (2016).

Para garantizar la precisión en la fotogrametría con UAVs, es necesario tomar fotografías desde múltiples ángulos, ya que una sola fotografía aérea no puede utilizarse como mapa fotogramétrico. Dependiendo de la escala del proyecto, la creación de un modelo fotogramétrico puede requerir de un par de cientos a varios miles de imágenes individuales, por lo que los UAVs suelen ser la forma más económica de tomar todas las fotografías aéreas necesarias para crear este tipo de mediciones. Gómez, et al., (2021).

La extracción de individuos arbóreos para su cuantificación a partir de métodos fotogramétricos se logra siguiendo una serie de pasos, comenzando por la extracción de la vegetación, usando el método de segmentación, el cual extrae regiones homogéneas, a partir de lo cual se elimina el fondo de cada imagen y se calculan las características para su posterior análisis, este proceso se puede llevar a cabo aplicando un índice de vegetación (*Green Leaf Index*, GLI), permitiendo discriminar las masas vegetales siendo una alternativa del NDVI, y de igual manera puede identificar de manera eficaz el área de cobertura vegetal, con una precisión del reconocimiento superior al 91 %. Bassine et al., (2019).

Para el conteo arbóreo, Recio et al. (2013) realizan una delimitación por parcelas, aislando los árboles y logrando calcular con mayor facilidad la cantidad de grupos de píxeles que contienen información de árboles y no de suelo, haciendo uso del algoritmo de aprendizaje autónomo K-medias, el cual permite de manera sencilla resolver el problema de agrupamiento, consistiendo en clasificar cierto número de conglomerados determinados, definiendo centroides por grupos asociando conjuntos de datos a los centroides más cercanos este proceso se repite creando un bucle, obteniendo como resultado un cambio en la ubicación de los k centroides cada que se repite el paso a paso, hasta que la ubicación de los centroides sea permanente.

6.2.1. METADATOS

Los metadatos en el contexto de la fotogrametría y el inventario de árboles son información adicional que se almacena junto con las imágenes digitales tomadas. Estos datos incluyen información como la fecha y hora de la toma, la ubicación geoespacial (coordenadas GNSS), la configuración y calibración de la cámara, entre otros. En el caso de la fotogrametría, los metadatos son esenciales para la orientación interna de las fotos, ya que permiten recuperar información importante

de las imágenes digitales, como la ubicación y la hora de la toma. Además, los metadatos son fundamentales para la generación de modelos 3D y la obtención de medidas precisas a partir de las imágenes. En el contexto del inventario de árboles, los metadatos pueden proporcionar información valiosa sobre la ubicación y las condiciones en las que se tomaron las imágenes, lo que es crucial para la identificación y el análisis de los árboles. Koc-San, et al., (2018); Oliveira, et al., (2020).

Los metadatos son fundamentales para la gestión y el análisis de datos geoespaciales, ya que proporcionan contexto y detalles importantes sobre la información recopilada, lo que es crucial para la toma de decisiones informadas en proyectos de fotogrametría e inventario de árboles. Koc-San, et al., (2018)

6.2.2. NUBE DE PUNTOS

Una nube de puntos en fotogrametría aplicada a la agricultura de precisión es una colección de coordenadas tridimensionales que representan la superficie de un terreno o cultivo. Estas coordenadas se obtienen a partir de las imágenes capturadas por UAVs o aeronaves equipadas con cámaras multiespectrales o RGB. La fotogrametría se utiliza para procesar estas imágenes y generar la nube de puntos, que luego se puede utilizar para crear modelos digitales del terreno, ortomosaicos, modelos 3D y otros productos útiles para el análisis y la toma de decisiones en agricultura de precisión. La nube de puntos proporciona información detallada sobre la topografía, la estructura y la salud de los cultivos, lo que permite realizar un seguimiento preciso y tomar medidas específicas para optimizar la producción agrícola. Bassine et al., (2019); El Imanni et al., (2023).

6.3. SOFTWARE DE MAPEO

Los softwares de mapeo son herramientas que permiten recopilar, procesar y visualizar información geoespacial. Estos programas pueden ser utilizados para crear mapas, modelos 2D y 3D, y para analizar datos geoespaciales. Algunos softwares de mapeo son de código abierto y están disponibles de forma gratuita, mientras que otros son comerciales y requieren una licencia. Los softwares de mapeo pueden ser utilizados en una variedad de campos. Algunos ejemplos de softwares de mapeo son *Mapeo*, *QGIS*, *Dronelink*, entre otros.

A continuación, se describirán tres softwares de mapeo usados en la fotogrametría digital: *QGIS* y *Dronelink*.

QGIS es un sistema de información geográfica (SIG) de código abierto que permite a los usuarios crear, editar, visualizar, analizar y publicar información geoespacial en una variedad de formatos. Algunas características y capacidades clave de *QGIS* son las siguientes:

- **Análisis geoespacial:** *QGIS* ofrece una amplia gama de herramientas para realizar análisis geoespacial, como análisis de proximidad, análisis de superficies, análisis de redes y análisis de patrones espaciales.
- **Visualización de datos:** *QGIS* permite crear mapas temáticos, mapas de calor, mapas de densidad y otros tipos de visualizaciones para representar datos geoespaciales de manera efectiva.
- **Gestión de datos:** *QGIS* es compatible con una variedad de formatos de datos geoespaciales, incluyendo formatos vectoriales y ráster, lo que permite a los usuarios importar, exportar y manipular datos de diferentes fuentes.
- **Personalización y extensibilidad:** *QGIS* es altamente personalizable y extensible, lo que permite a los usuarios adaptar el software a sus necesidades específicas. Además, ofrece una amplia gama de complementos y extensiones que amplían sus funcionalidades.
- **Interoperabilidad:** *QGIS* es compatible con una amplia variedad de formatos de datos y sistemas de información geográfica, lo que facilita la integración de datos de diferentes fuentes y proyectos.

QGIS es usado por profesionales de múltiples ámbitos, desde los urbanistas hasta los ingenieros ambientales. Es una herramienta popular y ampliamente utilizada en la comunidad SIG debido a su versatilidad y su naturaleza de código abierto, lo que permite a los usuarios acceder a una amplia gama de funcionalidades y recursos *QGIS*, (2023).

Dronelink es una aplicación de pago que brinda una plataforma de planificación de vuelos para UAVs que permite a los usuarios diseñar y ejecutar misiones de vuelo automatizadas, desde la web o dispositivos móviles. Entre sus características principales se encuentran:

- Planificación de misiones: Permite la creación de rutas de vuelo detalladas, especificando parámetros como altitud, velocidad y puntos de interés.
- Automatización de vuelos: Facilita la ejecución de misiones predefinidas, reduciendo la intervención manual y aumentando la precisión en la captura de datos.
- Integración con SIG: Aunque no es un software SIG en sí mismo, *Dronelink* puede integrarse con herramientas como *QGIS* para el análisis y procesamiento posterior de los datos capturados.
- *Dronelink* es especialmente útil en proyectos de fotogrametría digital, donde la precisión y consistencia en la captura de imágenes son cruciales para la generación de modelos 3D y ortomosaicos. Su capacidad para planificar misiones detalladas y automatizar la captura de datos lo convierte en una herramienta valiosa para profesionales en cartografía y mapeo. Dronelink, (2023).

6.4. ÍNDICE *GREEN LEAF INDEX* (GLI)

El índice GLI es una adaptación para trabajar con los valores digitales de las bandas roja, verde y azul (RGB) en el rango visible del espectro electromagnético, modificando la composición para resaltar el color verde característico de elementos vegetales. Este ayuda a mejorar la calidad y la precisión de las imágenes tomadas, permitiendo obtener información más precisa y útil para el análisis y la interpretación de datos geoespaciales. El GLI es una de las varias herramientas y técnicas que se utilizan en la fotogrametría para mejorar la calidad y la precisión de las imágenes y, en última instancia, para generar modelos 3D y obtener medidas precisas a partir de las imágenes. Geoinnova, (2021).

En el marco de un inventario de árboles, el GLI puede ser particularmente útil, ya que permite identificar y analizar de manera más precisa y eficiente la vegetación, incluyendo los árboles de limón. Al aplicar el GLI en las imágenes fotogramétricas, se pueden mejorar la calidad y la precisión de la información recopilada, lo que resulta en una mejor gestión y análisis de datos geoespaciales en proyectos de inventario de árboles.

6.5. CLUSTERING Y DBSCAN

En el contexto del procesamiento de imágenes y análisis geoespacial, el *clustering* es una técnica que permite agrupar elementos similares en subconjuntos (*clusters*), basándose en las características intrínsecas de estos. Este método de agrupamiento no supervisado es ampliamente utilizado en aplicaciones como la detección de objetos y segmentación de imágenes. Ester, et al., (1996); Schubert, et al., (2017).

El *clustering* identifica patrones o conjuntos naturales en los datos sin la necesidad de etiquetas o categorías predefinidas. Jain, et al., (1999). Los algoritmos de *clustering* son herramientas esenciales en aplicaciones como la agricultura de precisión, donde la agrupación de datos geoespaciales permite segmentar cultivos, identificar regiones de interés y analizar distribuciones espaciales de vegetación. Ester et al., (1996); Schubert et al., (2017). Dentro de los enfoques más comunes se encontró el basado en densidad, el cual identifica regiones densamente pobladas de puntos que están separados por otras regiones de menor densidad.

El método de aprendizaje no supervisado llamado algoritmo *DBSCAN* (*Density-Based Spatial Clustering of Applications with Noise*) es un algoritmo de *clustering* basado en densidad que identifica grupos de puntos densamente conectados y diferencia el ruido o puntos atípicos que no pertenecen a ningún *cluster*. Ester, et al., (1996). A diferencia de algoritmos como *K-means*, este no requiere especificar el número de *clusters* de previamente y es muy útil para datos espaciales.

El *DBSCAN* se utiliza para agrupar detecciones individuales de árboles obtenidas mediante la clasificación de píxeles en la ráster. Permitiendo identificar conglomerados ayudando agrupar detecciones individuales para formar *clusters* representativos de árboles.

7. MARCO REFERENCIAL

Reyes, et al. (2022) realizaron un estudio dasométrico cuantitativo de especies de coníferas y latifoliadas en Santa Catarina Ixtepeji, Oaxaca, México, mediante imágenes capturadas con vehículo aéreo no tripulado (UAV) (DJI Phantom3 Professional), procesadas luego con técnicas fotogramétricas (integrándolas en un sistema de información geográfica en rodales). Las variables dasométricas fueron: altura del individuo arbóreo, diámetro de copa, área de copa y diámetro normal. Las mediciones también se realizaron de forma manual tradicional, para contrastarla con la información digital.

Se determinó, en la comparación de los resultados de las mediciones manual y digital, que las variables altura y diámetro de copa no presentan diferencias significativas ($p > 0.05$); mientras que en las restantes variables sí se presentaron diferencias estadísticas significativas ($p < 0.01$). Se logró detectar el número de individuos arbóreos y calcular la distancia entre las copas y el área.

El estudio comprueba el uso potencial que puede dársele a la fotogrametría digital en proyectos forestales de grandes extensiones, que implican inversiones muy elevadas con los métodos de inventario forestal tradicionales. Se concluye por tanto que, dado que la fotogrametría garantiza una estimación fiable de las variables dasométricas, así como la identificación del individuo arbóreo, es una tecnología que genera resultados confiables a menor costo que la medición tradicional.

En el ámbito de la teledetección aplicada a la agricultura de precisión, estudios han demostrado la efectividad de los algoritmos de clasificación automática en el análisis de cultivos a partir de imágenes aéreas de alta resolución. Osco, et al. (2021), por ejemplo, desarrollaron un enfoque basado en redes neuronales convolucionales (*Convolutional Neural Networks*, CNN) para la detección y conteo automático de plantas en cultivos de maíz y cítricos, empleando imágenes capturadas por (UAV). Su modelo alcanzó métricas de precisión y sensibilidad superiores al 85 %, destacando la capacidad de las técnicas de *Deep Learning* para reconocer patrones complejos en datos espectrales y espaciales derivados de ortomosaicos. Por otra parte, Verdiguier (2011) propuso un método de detección y clasificación automática de plantaciones a partir de imágenes de muy alta resolución espacial, utilizando técnicas de análisis de objetos (*Object-Based Image Analysis*, OBIA). Los resultados de este estudio evidenciaron una precisión del 95 % en la identificación de árboles individuales, validando la utilidad de los enfoques automáticos en la delimitación y caracterización de coberturas vegetales. Los resultados de estas

investigaciones constituyen antecedentes importantes que sustentan la veracidad en la aplicación de algoritmos supervisados para el conteo de individuos arbóreos en cultivos.

Así mismo, Kumar, et al. (2021) realizó un estudio en Nebraska, Estados Unidos, que no se enfocó en detectar individuos arbóreos en cultivos cítricos si no de maíz, no obstante, utiliza metodologías similares a las mencionadas anteriormente; donde el principal objetivo es la detección de las borlas en los cultivos utilizando vehículos aéreos no tripulados (UAV) y teledetección. Su metodología consiste en tomar imágenes aéreas de alta resolución del campo de maíz utilizando un UAV equipado con una cámara, y luego procesar las imágenes para identificar las borlas.

Se desarrolla un algoritmo que combina la segmentación de imágenes, la extracción de características y las técnicas de aprendizaje automático para detectar con precisión las borlas en las imágenes. El algoritmo se entrenó utilizando un conjunto de datos de imágenes anotadas y logró una alta precisión de detección de más del 95 %.

En esta investigación se utilizan imágenes multiespectrales y RGB, para desarrollar un análisis comparativo en los resultados finales, llegando a la conclusión que las imágenes multiespectrales pueden proporcionar una información más detallada sobre el campo de maíz y ser útiles para detectar con mayor precisión las borlas.

El estudio realizado por Khanal, et al. (2020) es una revisión documental que muestra los logros, limitaciones y oportunidades de la teledetección en la agricultura. Este estudio destaca que la teledetección ha sido utilizada con éxito en la agricultura para una variedad de aplicaciones, como la detección de plagas y enfermedades, el monitoreo del crecimiento y la salud de los cultivos, la estimación de la producción y el control de la calidad del suelo y del agua. En el corpus revisado, se observó que la mayoría de los trabajos de teledetección se realizó con sensores hiperespectrales; en tanto que la minoría se efectuó con sensores multiespectrales y visibles.

Sin embargo, el estudio también reconoce que la teledetección tiene sus limitaciones, de las cuales la mayor es la dependencia de las condiciones meteorológicas y la resolución espacial de las imágenes en ciertos casos; pero también resalta la importancia del uso de nuevas tecnologías vinculadas a la agricultura, como lo son los sensores avanzados, sensores hiperespectrales y de radar, que pueden proporcionar información más detallada sobre los cultivos. Además, se destaca la importancia de la integración de la teledetección con otras

tecnologías, como la agricultura de precisión y los sistemas de información geográfica.

Por otro lado, Bejarano y García, (2018) desarrollaron un inventario arbóreo en ecosistemas de páramo a partir de técnicas de percepción remota, para identificar el conjunto de parámetros propio de este tipo de inventarios en ese ecosistema. El resultado fue una clasificación de especies arbóreas, con su distribución en el espacio, para discriminar la maleza.

La muestra de dicho estudio se obtuvo en el sector denominado Paramillo, en Santa Rosa de Cabal, Colombia, con altitudes que van de los 3200 m.s.n.m hasta los 4300 m.s.n.m. Las variables utilizadas fueron aquellas que influyen en la biodiversidad: sistema de drenaje, direcciones de flujo, pendientes, curvas de nivel. Para el inventario se usó el algoritmo *FLAASH (Fast Line-of-sight Atmospheric Correction)*. Se utilizaron imágenes de satélite captadas por el sensor EO-1 Satélite de Hyperion, que es un escáner con alta resolución espectral.

Los resultados fueron mejores, en cuanto a la clasificación arbórea, que los estudios que se tomaron como antecedentes, debido a la alta resolución espacial de las imágenes utilizadas. Se constató la relación espacial existente entre las comunidades de especies y variables como la temperatura superficial de la tierra y las curvas de nivel.

Entre las limitaciones del estudio se encuentra que el producto final no tiene equilibrio entre la resolución geométrica de las imágenes (se necesita una resolución más fina) y la resolución espectral, ello con el fin de mejorar la discriminación de comunidades de especies vegetales, e incluso afinar la discriminación hasta el nivel del reconocimiento de individuos arbóreos. Un elevado porcentaje de píxeles no se clasificó correctamente (en el caso de algunas especies vegetales se clasificó correctamente el 60,4 % de los píxeles). También tiene como limitación este estudio la poca amplitud de recolección de muestras.

Asimismo, González, et al., (2016) realizan una revisión documental para exponer las generalidades del uso de los UAVs en la agricultura de precisión. Establecen que las metodologías aplicadas a este tipo de agricultura, si bien varían de acuerdo con el investigador o con las empresas que demandan el procedimiento, tienen en común tres fases, a saber:

- 1) Operación

- Monitorización del área seleccionada mediante la detección de variables de importancia.

- Planificación del vuelo y obtención de imágenes de resolución óptima por cultivo.
- Uso de vehículos aéreos no tripulados (UAVs) para realizar los vuelos.
- Definición de la totalidad del área de estudio para asignar líneas de vuelo y estimar tiempo de vuelo y cantidad de información capturada.
- Selección de sensores y equipos adecuados.

2) Posproceso

- Tratamiento de imágenes obtenidas por el UAV.
- Generación de imágenes NDVI térmicas y multiespectrales de la zona para valorar el estado de los cultivos.
- Elaboración de mapas con datos de importancia para agricultores.
- Generación del NDVI utilizando la imagen en color verdadero (RGB), donde se combina la banda del rojo con la banda infrarroja.
- Cuantificación o evaluación de la salud de la vegetación, por planta, por hoja, según la resolución espacial.

3) Aplicación a los cultivos

- Elaboración a posteriori de mapas basados en la teledetección para localizar los problemas que sufren la vegetación y los cultivos.
- Determinación de la forma de actuar basada en la evaluación de la rentabilidad económica y medioambiental.
- Direcccionar el resultado de la teledetección a la solución de los problemas de partida (baja productividad, saneamiento de los cultivos, etc.).

Resaltan la efectividad, mayor que la de los vehículos aéreos tripulados, del vehículo aéreo no tripulado para hacer este tipo de mediciones

Los UAVs tienen una gran ventaja y es su alta resolución en comparación con imágenes satelitales de open data. Como otro factor muy favorable se tiene que no presentan ningún conflicto con las nubes, un problema que en Colombia se da con mucha frecuencia en más del 70 % del territorio nacional. (p. 35)

Sin embargo, este tipo de vehículos también presentan sus limitaciones, de las cuales la principal es la poca autonomía de vuelo, lo que reduce la información capturada con respecto a la variable temporal. Para ello se propone como solución la operatividad entre UAVs, a través de redes inalámbricas entre unidades que cumplan líneas y diseños de vuelo convenientemente parametrizados.

En los análisis de la vegetación a partir de imágenes aéreas en color verdadero (RGB), el índice GLI es una herramienta eficiente para la detección de coberturas vegetales en estudios de fotogrametría. Eng, et al., (2019) Realizaron un estudio comparativo entre diferentes índices como GLI, (*Visible Green Index*, Vlgreen) y (*Visible Atmospherically Resistant Index*, VARI), aplicándolos a fotografías obtenidas mediante el uso de UAVs en entornos urbanos y rurales. El estudio concluyó que la aplicación del índice GLI generaba una sensibilidad mayor en la diferenciación entre áreas con vegetación y no vegetadas, en escenarios donde las condiciones de iluminación y el tipo de cultivos afectan a otros índices basados en la reflectancia.

Por su parte, Berrio, et al., (2015) usaron la fotogrametría digital en un cultivo de papas ubicados en el departamento de Cundinamarca, Colombia, con la finalidad de identificar puntos focales de conflicto (plagas), los cuales visualizaron con precisión, demostrando con ello que esta tecnología tiene un impacto positivo “en cuando a la posibilidad de ahorro en tiempo y dinero en el tratamiento de dichos problemas, así como en la toma de decisiones oportunas para evitar la propagación de plagas y enfermedades a zonas saludables del cultivo” (p. 29). Incluso relacionan la agricultura tradicional no tecnificada, unida ahora al cambio climático, con la vulnerabilidad de los sistemas productivos agrícolas de Colombia; agregan que la agricultura de precisión asistida por las TIC podría disminuir la aplicación de insecticidas y fungicidas, que tienen impacto ambiental negativo.

Mediante la teledetección y con el uso de cámaras multiespectrales y el índice *NDVI*, se identificaron cuatro clases diferentes de respuestas espectrales: 1) zonas con vegetación saludable y vigorosa; 2) zonas con vegetación estresada por exceso de sales minerales y exceso de humedad en el suelo; 3) zonas con vegetación no saludable; 4) zonas con suelo desnudo.

La fortaleza de este estudio está en que demostró que la respuesta espectral (representada en una ortofoto *NDVI* generada a partir de las fotografías de una cámara NGB) permite identificar problemas en el cultivo. Para ello estableció los siguientes valores cromáticos, aplicando a dichas imágenes las técnicas de procesamiento digital y los algoritmos asociados con el índice *NDVI*: tonalidades cafés y rojizas corresponden a índices *NDVI* bajos, relacionados con suelo desnudo,

problemas de crecimiento o presencia de plantas invasoras; tonalidades amarillas corresponden a zonas de cultivos poco desarrollados; y, por último, tonalidades verdes corresponden a las zonas con los cultivos mejor desarrollados. Incluso afirman que las técnicas empleadas en el estudio “permiten identificar fácilmente problemas de cultivos que podrían no ser visibles a partir de una observación convencional” (p. 38).

En su estudio, Falk y Campos, (2014) se enfocan en las limitaciones de las tecnologías fotogramétricas digitales para la realización de inventarios arbóreos. Sostienen que la detección de árboles a través del procesamiento digital de imágenes puede ser abordada mediante la segmentación espectral, la utilización de modelos de elevación y el reconocimiento de formas geométricas. La segmentación espectral se fundamenta en la singularidad de la reflexión y emisión de energía electromagnética de cada objeto, conocida como firma espectral. Posteriormente, se emplean técnicas de detección de bordes para delinear las copas de los árboles. Además, el contraste en la banda infrarroja entre áreas con vegetación activa de alta intensidad y suelo de baja intensidad permite identificar máximos locales que representan los centros geométricos de las copas de los árboles.

Los modelos de elevación se generan a partir de escaneos láser aéreos, clasificando la diferencia de altura relativa entre un árbol y su entorno. La representación de objetos mediante modelos geométricos facilita la identificación de figuras geométricas y parámetros morfométricos en las imágenes. A pesar de los avances en este campo, declaran Falk y Campos, (2014), los métodos actuales no logran caracterizar con precisión todos los parámetros buscados, y ninguno de ellos ofrece resultados significativos al aplicarse en diferentes tipos de áreas forestales.

Debe destacarse que este estudio de Falk y Campos, (2014). se basó en imágenes captadas por cámara multiespectral *GeoSpatial* MS4100 a bordo de un avión. Es probable por tanto que las tecnologías digitales desarrolladas con posterioridad a ese estudio, que data del año 2014, capten con más fidelidad los objetos a estudiar en los inventarios arbóreos. En el algoritmo que diseñaron, establecieron dos zonas: la zona 1, con alta intensidad infrarroja, que representa la copa del árbol; y la zona 2, con baja intensidad infrarroja, que representa la sombra del árbol. Consiguientemente, diseñaron valores de máxima y de mínima intensidad de los píxeles para cada zona. El algoritmo se realizó siguiendo un modelo matemático de cuatro parámetros, a saber: un centro, un radio menor, un radio mayor y un ángulo.

Reportan alto porcentaje de exactitud (entre el 92,5 y el 99,8 %). Los errores vienen dados por el tamaño de los árboles, particularmente los pequeños, los cuales presentan baja intensidad infrarroja en la fotografía (debido a su escasa

frondosidad, comparada con la de los árboles grandes); y por las cortinas forestales, que tapan la sombra de los árboles.

Recio, et al., (2013) proponen un método automatizado para la extracción de parámetros basados en árboles y parcelas en huertos de cítricos a partir de imágenes aéreas. El estudio se basó en imágenes capturadas por UAVs equipados con cámaras multiespectrales, con el objetivo de mejorar la eficiencia y precisión del monitoreo de cultivos. La muestra se obtuvo en la región de Valencia, España.

En el método propuesto se utilizó un algoritmo de segmentación de objetos que permitió la identificación de árboles individuales y la medición de su altura, diámetro de copa y otros factores condicionados por la disposición de los árboles en la parcela, así como sus propiedades espectrales. Se aplicó una clasificación no supervisada del algoritmo *K-means*, seguida de la identificación automática de las clases que representan árboles. Además, se implementó un método de análisis de imagen basado en parcelas que permitió la medición de parámetros como la superficie foliar, la distribución espacial de los árboles y la densidad de plantación.

Las imágenes aéreas utilizadas (recogidas en 2006 con un *Vexcel Ultracam-D*) tuvieron resolución espacial de 0,5 m/píxel. Estas imágenes se ortorrectificaron y se georreferenciaron para la realización del análisis fotogramétrico. Se validó el estudio mediante comparaciones con datos de referencia obtenidos a través de delineación manual de las imágenes.

Los resultados del estudio mostraron que el método propuesto permitió una extracción precisa y automatizada de parámetros de árboles y parcelas en huertos de cítricos. Además, se demostró que el uso de imágenes aéreas y UAVs equipados con cámaras multiespectrales puede mejorar significativamente la eficiencia del monitoreo de cultivos en comparación con los métodos tradición.

Sin embargo, es importante resaltar que el algoritmo DBSCAN ha sido ampliamente implementado en bibliotecas de aprendizaje automático, como *scikit-learn* en Python, lo que facilita su aplicación en diversos proyectos de análisis de datos geoespaciales. Scikit-learn, (2023).

8. MARCO TEÓRICO

El análisis y procesamiento de imágenes satelitales ha ganado una relevancia significativa en diversas áreas, desde la agricultura de precisión hasta la monitorización medioambiental. En este marco teórico, se abordarán cuatro componentes fundamentales que permiten extraer información valiosa a partir de imágenes satelitales.

En primer lugar, se explorará la Generación de Contraste Óptico a través *del Green Leaf Index* (GLI), un indicador crucial para evaluar la salud vegetal y la distribución de la vegetación en un área específica. Luego se analizará la Clasificación de Valores de Píxel mediante el algoritmo DBSCAN, una técnica de agrupamiento que facilita la segmentación y categorización de la información contenida en las imágenes.

Estos elementos conforman un marco integral que potencia la comprensión y el aprovechamiento de los datos capturados por imágenes satelitales, abriendo un abanico de posibilidades para su aplicación en una amplia gama de campos científicos y aplicaciones prácticas.

8.1. RANDOM FOREST

El algoritmo *Random Forest* es un modelo de aprendizaje automático basado en múltiples árboles de decisión, que se utiliza para clasificar píxeles en una imagen en función de características espectrales. Cánovas, et al., (2016). analiza el algoritmo *Random Forest* en la clasificación de imágenes, destacando la aplicabilidad de los algoritmos de aprendizaje autónomo en las aplicaciones de análisis de imágenes.

Cada árbol de decisión se entrena con un subconjunto aleatorio de los datos y utiliza la siguiente función de predicción:

$$f(x) = \frac{1}{t} \sum_{t=1}^T h_t(x) \quad (01)$$

Donde:

$f(x)$ =es la predicción final

T = es el número de arboles

$h_t(x)$ = predicción de cada árbol t

8.1.1. GENERACIÓN DE CONTRASTE ÓPTICO A TRAVÉS DE GREEN LEAF INDEX (GLI)

El índice de vegetación GLI o índice de hoja verde trabaja en las bandas visibles, permitiendo discriminar las masas vegetales, ayudando a la segmentación de la imagen. Bassine et al., (2019). La fórmula para calcular el índice de hojas verdes, que se utiliza para evaluar la cantidad y el estado de la vegetación en un área determinada, matemáticamente se expresa así:

$$GLI = \frac{(GREEN - RED) + (GREEN - BLUE)}{(2 * GREEN) + (RED + BLUE)} \quad (02)$$

En la ecuación del *Green Leaf Index* (GLI), las variables representan la reflectancia de la luz en diferentes longitudes de onda. *GREEN* se refiere a la reflectancia en la banda verde, *RED* se refiere a la reflectancia en la banda roja y *BLUE* se refiere a la reflectancia en la banda azul. La fórmula se utiliza para calcular el índice de vegetación de hojas verdes (GLI) a partir de las imágenes de satélite. El índice GLI es útil para evaluar la cantidad y estado de la vegetación en una determinada área, proporcionando información valiosa para la gestión de recursos naturales y la toma de decisiones en el manejo de los recursos vegetales.

8.2. CLASIFICACIÓN DE VALORES DE PÍXEL POR MEDIO DEL ALGORITMO DBSCAN

Wardana, et al., (2024). analiza la implementación de los algoritmos *DBSCAN* y *K-Means* en la segmentación de áreas de vuelo para UAVs agrícolas. El artículo explora cómo estos algoritmos para el agrupamiento permiten mejorar la eficiencia mediante la clasificación de datos espaciales. Si bien el enfoque de su estudio no es la cuantificación de árboles, los resultados demuestran que el algoritmo *DBSCAN*

es significativamente ventajoso para la detección de zonas con mayor densidad de puntos, lo cual indica su aplicabilidad en la identificación de estructuras arbóreas dentro de cultivos.

DBSCAN se basa en dos parámetros fundamentales:

- ε (*epsilon*): Radio de vecindad
- *MinPts*: Numero mínimo de puntos en la vecindad de radio ε para considerar el punto como central.

Dado un conjunto de puntos $X = \{x_1, x_2, \dots, x_n\}$, por lo tanto:

Vecindad ε de un punto p :

$$N_\varepsilon(p) = \{q \in X | d(p, q) \leq \varepsilon\} \quad (03)$$

Clasifica los puntos como:

Un punto p es central si $|N_\varepsilon(p)| \geq \text{MinPts}$.

Un punto p es alcanzable por densidad si está dentro de la vecindad ε de un punto central.

Un punto es ruido si no es ni central ni alcanzable por densidad.

Un *Cluster* C es un conjunto de puntos conectados por la densidad:

$$C = \{q \in X | p \text{ es alcanzable desde } q\} \quad (04)$$

Para algún punto central p en C

DBSCAN recorre todos los puntos del *dataset* y agrupa los puntos alcanzables por densidad en *clusters* hasta que no haya más puntos conectados.

Centro de masa de los arboles

Para determinar la ubicación de cada árbol, se calcula el centro de masa de región detectada.

$$C_x = \frac{1}{n} \sum_{i=1}^n x_i, \quad C_y = \frac{1}{n} \sum_{i=1}^n y_i \quad (05)$$

Donde:

(C_x, C_y) = coordenadas del centro de masa del árbol.

n = número total de píxeles en la región.

(x_i, y_i) = son las coordenadas de cada píxel en la región segmentada.

Estos valores se transforman en coordenadas geográficas utilizando la matriz de transformación del ráster.

8.3. EVALUACIÓN DEL MODELO

8.3.1. MATRIZ DE CONFUSIÓN

Para evaluar la precisión del modelo, se utiliza la matriz de confusión, con el fin de medir el desempeño al comparar las predicciones con los valores reales. La categorización de la matriz se muestra en la Tabla 1.

Tabla 1.

Categorías de elaboración para la matriz de confusión

	Predicción Positiva	Predicción Negativa
Clasificación Positiva (Árbol detectado)	Verdadero Positivo (TP)	Falso Negativo (FN)
Clasificación Negativa (No es árbol)	Falso Positivo (FP)	Verdadero Negativo (TN)

Con la información resultante de la matriz de confusión, se realizaron cálculos de las siguientes métricas para comprobar la efectividad de los resultados:

Precisión global:

Representa la proporción de predicciones correctas (verdaderos positivos y verdaderos negativos) respecto al total de observaciones. Se calcula como:

$$Precisión\ global = \frac{TP+TN}{Total\ observaciones} \quad (06)$$

Precisión:

Evalúa la proporción de predicciones positivas que son realmente correctas, se utiliza para medir la confiabilidad de las detecciones positivas y se define como:

$$Precisión = \frac{TP}{TP + FP} \quad (07)$$

Sensibilidad:

Mide la capacidad del modelo para detectar correctamente todos los casos positivos en el conjunto real. Se expresa como:

$$Sensibilidad = \frac{TP}{TP + FN} \quad (08)$$

F1-Score

Es el promedio armónico entre la precisión y la sensibilidad, proporcionando un equilibrio entre ambas métricas. Se calcula como:


$$F1 = 2 * \frac{Precisión * Sensibilidad}{Precisión + Sensibilidad} \quad (08)$$

9. METODOLOGÍA

Se adoptó una metodología de tipo aplicada y experimental, compuesta de tres fases que son complementarias, y una cuarta fase con un enfoque cuantitativo, donde se realiza el análisis y evaluación de resultados, (Figura 2).

Figura 2.

Diagrama del proceso metodológico



Fuente: Elaboración propia

9.1. MATERIALES


El desarrollo de la metodología requirió el uso de equipos y herramientas en cada una de sus etapas. A continuación, se describen los materiales utilizados, junto con sus características y la función que desempeñaron dentro del proceso metodológico.

9.1.1. ZONA DE ESTUDIO

Se seleccionó la finca denominada Campo Alegre como Área de estudio, se encuentra ubicada en el corregimiento Atuncela, municipio de Dagua departamento del Valle del Cauca, Colombia. Dagua está situado aproximadamente a 3°38' 45" de Latitud Norte y 76°41' 30" de Longitud Oeste del Meridiano de Greenwich. Limita al Norte con el municipio Calima; al Oriente, con los municipios Restrepo, La Cumbre y Santiago de Cali; al Sur, con el municipio Santiago de Cali; al Occidente, con el Municipio Buenaventura, como se muestra en la (Figura 3). Se caracteriza por su territorio montañoso, su relieve corresponde a la cordillera Occidental de los Andes, y goza de diferentes climas debido a la accidentada topografía. La altitud media del municipio es de 1218 m.s.n.m., la temperatura media es de 24° C, y se encuentra a una distancia de 48 kilómetros de Cali, la capital del departamento. Alcaldía Municipal de Dagua, (2022a).

Figura 3.

Localización del Municipio Dagua dentro del Departamento de Valle del Cauca



Fuente: Alcaldía Municipal de Dagua, (2022b).

La localización de la finca Campo Alegre se muestra en la (Figura 4), tiene un área de 29278,27 m² y se encuentra entre los 750 y 850 m.s.n.m., con clima cálido, >24° C en la mayoría del año, y pendiente fuertemente inclinada (12-25 %).

Figura 4.

Localización finca Campo Alegre



Fuente: Elaboración propia, elaborada con QGIS

El cultivo en la zona de estudio corresponde a la especie (*Citrus latifolia*) conocida localmente como limón Tahití, esta especie alcanza su adultez aproximadamente 2 años después de realizarse la siembra, logrando una altura entre 4 y 5 metros, por sus características es altamente valorado en la agricultura colombiana. Se cultiva ampliamente en regiones tropicales y subtropicales debido a su vigor y tolerancia relativa a enfermedades y al frío. Hernández, et al., (2014).

En la zona evaluada, los árboles no comparten una misma fecha de siembra, lo que generó diferencias significativas en su desarrollo morfológico, la distribución temporal de la siembra no siguió un patrón homogéneo por zonas, por este motivo se hallan individuos en distintos estados fenológicos dentro de un mismo sector. Se identificaron dos grupos principales diferenciados por su edad y desarrollo morfológico. (Figura 5).

Grupo 1: Árboles con aproximadamente 1 año, con alturas aproximadas de dos metros.

Grupo 2: Árboles jóvenes, con una edad aproximada de 6 meses, alturas inferiores a un metro por su edad.

Figura 5.

Clasificación de árboles por grupo según su desarrollo morfológico



Fuente: Elaboración propia por medio de QGIS.

9.1.2. DISPOSITIVO GNSS

Para la toma de puntos de control, se utilizó el receptor (*Global Navigation Satellite System*, GNSS) Reach RS2, (Figura 6). Su función es la georreferenciación de puntos de control en el área de estudio, estos puntos permitieron mejorar la precisión espacial del ortomosaico generado posteriormente. Este equipo opera en modo RTK y PPK, lo que permitió la obtención de coordenadas en tiempo real o su procesamiento posterior para mayor exactitud, es compatible con múltiples constelaciones satelitales (GPS, GLONASS, BeiDou, Galileo). Las especificaciones técnicas detalladas del equipo, incluyendo su precisión, conectividad y capacidad operativa, se presentan en la Tabla 2.

Figura 6.
Receptor GNSS Reach RS2



Fuente: Emlid. (2024). Receptor GNSS Reach RS2

Tabla 2.
Características de receptor GNSS REACH RS2

RECEPTOR GNSS REACH RS2		
ITEM	CARACTERÍSTICAS TÉCNICAS	FUNCIÓN
Frecuencias GNSS	Multibanda (GPS/QZSS L1C/A, L2C GLONASS L1OF, L2OF BeiDou B1I, B2I Galileo E1-B/C, E5b SBAS L1C/A)	Mejora la precisión en áreas con obstrucciones y aumenta la robustez del posicionamiento.
Procesamiento	RTK (Real-Time Kinematic) con precisión centimétrica; modo PPK (Post-Processed Kinematic)	Aumenta la precisión en tiempo real o en postproceso.
Antena	Antena de alimentación múltiple con rechazo de multitrayecto.	Maximiza la recepción de señales satelitales incluso en áreas con condiciones difíciles.
Rango de Trabajo RTK	Hasta 8 km con correcciones por radio LoRa; ilimitado mediante NTRIP y conexión celular.	Uso en levantamientos de campo con estaciones base y conexión remota a redes de referencia.
Precisión	- Horizontal: ±7 mm + 1 ppm - Vertical: ±14 mm + 1 ppm.	

Batería	- Capacidad: 6400 mAh - Duración: Hasta 22 horas (sin correcciones LoRa) o 16 horas (con LoRa activa)	Permite jornadas de trabajo prolongadas sin necesidad de recarga frecuente.
Conectividad	- Radio LoRa 868/915 MHz. - Bluetooth 4.0. - Wi-Fi integrado. - Puerto USB-C. B10	Facilita la transferencia de datos y la conexión con dispositivos móviles o estaciones base.
Software Compatibles	- ReachView (propietario). - Compatible con software de terceros como QGIS, ArcGIS, AutoCAD	Integración con diferentes plataformas de procesamiento y análisis.
Protocolo de datos	NTRIP, VRS, RTCM3, Posición de salida en NMEA, LLH/XYZ, RINEX a una tasa de actualización de hasta 20 Hz	Permiten que el receptor se integre eficientemente con otros equipos y softwares

9.1.3. VEHÍCULO AÉREO NO TRIPULADO (UAV)

Para la captura de imágenes aéreas, se empleó el UAV DJI Mavic Air 2S, equipado con un sensor CMOS de 1 pulgada (Figura 7), este dispositivo se encarga de la adquisición de imágenes aéreas de la zona de estudio. Se programó un vuelo fotogramétrico con parámetros específicos de altura y superposición para garantizar la captura óptima de imágenes. Las especificaciones técnicas detalladas del Vehículo aéreo y el sensor, se presentan en la Tabla 3 y tabla 4 respectivamente.

Figura 7.
UAV DJI Mavic Air 2S



Fuente: DJI (2024). DJI Mavic Air 2S

Tabla 3.*Características de UAV MAVIC AIR2S*

UAV MAVIC AIR 2S		
ITEM	CARACTERÍSTICAS TÉCNICAS	FUNCIÓN
Plataforma UAV (vehículo)	-Peso: 595 g -Tiempo de vuelo: Hasta 31 minutos - Velocidad máxima: 19 m/s - Alcance de transmisión: 12 km (OcuSync 2.0)	Proporciona estabilidad y tiempo suficiente para realizar vuelos fotogramétricos.
Sistema de navegación	- GNSS: GPS + GLONASS	Permite georreferenciar imágenes capturadas durante el vuelo.
Estabilización	- Gimbal mecánico de 3 ejes	Garantiza la captura de imágenes nítidas y sin distorsión debido a vibraciones o movimientos.
Batería	- Capacidad: 3750 mAh - Voltaje: 11.55 V	Brinda energía para el funcionamiento del vehículo
Almacenamiento	- Memoria interna: 8 GB	Permite almacenar gran cantidad de imágenes.
Software	- DJI Fly (propietario) - <i>Dronelink (usado)</i>	Facilita la planificación de vuelos automáticos
Velocidad del obturador	- Velocidad: 8-1/8000 s	Permite capturar imágenes en movimiento sin distorsión
Rango dinámico	- HDR: Soporte para captura de imágenes en alto rango dinámico	Mejora la calidad de las imágenes, conservando detalles en áreas oscuras y brillantes
Sistema anticolidión	Sensores en 4 direcciones (adelante, atrás, arriba y abajo)	Evita los choques con obstáculos durante las misiones.
Frecuencia de disparo	- Hasta 1 imagen por segundo	Captura imágenes en intervalos regulares, asegurando solapamiento

Tabla 4.
Características de sensor CMOS 1"

SENSOR CMOS 1"		
ITEM	CARACTERÍSTICAS TÉCNICAS	FUNCIÓN
Resolución	20 megapíxeles	Garantiza imágenes detalladas
Tamaño de Píxel	2.4 μm	Mejora la sensibilidad a la luz, capturando más detalles incluso en condiciones de baja iluminación.
Campo de Visión (FOV)	88°	Permite capturar un área amplia en cada toma, reduciendo el número de imágenes necesarias.
Longitud Focal	Equivalente a 22 mm (en formato de 35 mm)	Proporciona un nivel de detalle adecuado para levantamientos topográficos y mediciones precisas.
Apertura	f/2.8	Mejora el rendimiento en condiciones de poca luz
Resolución Máxima de Imagen	5472 $\times$ 3648 (3:2) / 5472 $\times$ 3078 (16:9)	Genera imágenes de alta resolución, esenciales para procesar modelos de alta precisión.
Formatos de Imagen	JPEG y DNG (RAW)	Proporciona flexibilidad en el procesamiento de imágenes, con opciones de edición avanzada en formato RAW.
Velocidad de Obturación	De 8 segundos a 1/8000 de segundo	Permite capturar imágenes nítidas durante vuelos a alta velocidad.
ISO (Fotografía)	Auto: 100 – 3200 / Manual: 100 – 12800	Adapta la sensibilidad a la luz según las condiciones de vuelo

9.1.4. EQUIPO INFORMÁTICO

Para las etapas de preprocesamiento de imágenes, procesamiento de datos y análisis de resultados, se utilizó ordenadores de escritorio, con especificaciones adecuadas para el procesamiento de grandes volúmenes de datos, estas se presentan en la Tabla 5. Se utilizó para ejecutar el software de fotogrametría, procesar las imágenes capturadas, asegurando su alineación y la creación del ortomosaico, también Se utilizó para ejecutar los softwares y bibliotecas encargadas para la implementación del algoritmo de detección, conteo arbóreo y análisis de resultados.

9.1.5. SOFTWARE AGISOFT METASHAPE

Software es especializado en fotogrametría digital y reconstrucción 3D a partir de imágenes. Se empleó para el procesamiento de las imágenes capturadas por el UAV, permitiendo la alineación de imágenes, generación de la nube de puntos densa y la creación del mosaico ortorrectificado. Las características del software se pueden ver en la Tabla 5.

9.1.6. PUNTOS DE CONTROL (*Ground Control Points, GCPs*)

Los puntos de control son marcadores físicos distribuidos en el área de estudio, cuyas coordenadas fueron medidas con el receptor GNSS. Se utilizaron para mejorar la precisión del ortomosaico generado en Agisoft Metashape, permitiendo corregir distorsiones geométricas en la imagen final. Las características de los (GCP) se pueden ver en la Tabla 5.

9.1.7. IMÁGENES FOTOGRAMÉTRICAS

Las imágenes obtenidas por el UAV fueron el insumo principal en la etapa de preprocesamiento de imágenes. Se utilizó un solapamiento entre fotografías (70-80 %), lo que facilitó la reconstrucción tridimensional y la generación del ortomosaico. Las características de las imágenes se pueden ver en la Tabla 5.

9.1.8. SOFTWARE PYTHON

Para la implementación del algoritmo que realizará el conteo arbóreo semiautomático se utilizó el lenguaje de programación Python, por medio de sus bibliotecas como OpenCV, NumPy y Pandas se procesó el ortomosaico y ejecutó el reconocimiento de árboles dentro del área de estudio. Las características del software y de las bibliotecas se pueden ver en la Tabla 5.

9.1.9. IDE (ENTORNO DE DESARROLLO INTEGRADO)

Es un entorno de programación utilizado para la escritura y ejecución del código en lenguaje Python, se empleó el entorno Jupyter Notebook para el desarrollo, depuración y optimización del algoritmo. Este entorno permite combinar código, visualizaciones y documentación en un mismo archivo, lo que facilitó el análisis de resultados y el ajuste progresivo del modelo de cuantificación.

9.1.10. ORTOMOSAICO

El mosaico es la imagen georreferenciada producto de la etapa de preprocesamiento de imágenes procesadas con el software Agisoft Metashape. Se utilizó como insumo principal para la detección y cuantificación de árboles mediante el algoritmo desarrollado. Las características técnicas de los archivos se pueden ver en la Tabla 5.

9.1.11. PUNTOS DE ENTRENAMIENTO

Se establecieron manualmente puntos de entrenamiento sobre el ortomosaico con coordenadas seleccionadas manualmente en QGIS para entrenar el algoritmo. Se utilizaron como datos de entrenamiento para guiar la identificación y conteo automático de árboles. Las características técnicas de los archivos se pueden ver en la Tabla 5.

9.1.12. SOFTWARE MICROSOFT EXCEL

Para la validación de los resultados y la evaluación del desempeño del algoritmo, se utilizaron herramientas estadísticas en Microsoft Excel. Se calcularon matrices de confusión, métricas de desempeño.

Tabla 5.

Características de materiales usados en la etapa de preprocesamiento de imágenes y Procesamiento de datos

MATERIALES PARA PRE PROCESAMIENTO DE IMÁGENES Y PROCESAMIENTO DE IMÁGENES		
ITEM	CARACTERÍSTICAS TÉCNICAS	FUNCIÓN
Equipo informático	Sistema operativo Windows 10 PRO 64 bits; Procesador AMD Ryzen 5 3400G; Memoria RAM de 32 GB; Tarjeta gráfica Radeon Vega Graphics; Almacenamiento SSD de 1 TB.	Realizar el procesamiento de datos
Software Agisoft Metashape	Software privativo Versión Profesional; Compatible con Windows.	Realizar las tareas necesarias para procesar información y generar el mosaico
Mosaico	Imagen formato .TIF, georreferenciada en el sistema de referencia WGS 84 (EPSG: 4326)	Proporcionar la base visual para identificar y procesar los árboles en el área de estudio.
Puntos de Control (GCPs)	9 puntos distribuidos uniformemente en el área de estudio, obtenidos mediante receptor GNSS Reach RS2 (RTK/PPK).	Mejora la precisión espacial del modelo fotogramétrico
Imágenes Fotogramétricas	199 fotografías Capturadas por el sensor del UAV DJI Mavic Air 2S (20 MP, 1" CMOS, formato JPEG); resolución 72 pixeles por pulgada; Resolución espacial de 8.73 mm/píxel en el área de vuelo.	Insumo principal para la creación del mosaico
Software Python	Versión 3.9, bibliotecas utilizadas: OpenCV, NumPy, Pandas, Matplotlib	Crear y ejecutar el algoritmo encargado de procesar el mosaico .TIF y realizar el censo arbóreo.
Biblioteca OpenCV	Versión 4.5, especializada en procesamiento de imágenes y visión por computadora	Proporciona herramientas para la segmentación y análisis de imágenes aéreas.

Biblioteca NumPy	Versión 1.21, para cálculo numérico y manejo eficiente de matrices	Soporte para realizar operaciones matemáticas en las imágenes
Biblioteca Pandas	Versión 1.3, para manipulación y análisis de datos tabulares	Gestión de las tablas de datos generadas por el código, como los archivos CSV.
Puntos de entrenamiento	Puntos en formato <i>shapefile</i> , seleccionados manualmente con coordenadas específicas de árboles seleccionados en el mosaico	Entrenar el algoritmo para identificar árboles en el mosaico basado en características visuales.

9.2. MÉTODO

En la primera y segunda fase se realiza el levantamiento de datos geoespaciales utilizando técnicas fotogramétricas y topográficas. Para ello, se ejecuta un vuelo fotogramétrico con un vehículo aéreo no tripulado (UAV), complementado con el levantamiento de puntos de control terrestre utilizando receptores GNSS de doble frecuencia. Riaño Rodríguez, E. R. (2018).

La tercera fase corresponde al procesamiento de datos, donde se implementa un algoritmo desarrollado en lenguaje Python para el conteo semiautomatizado de individuos arbóreos en cultivos de cítricos, a partir de imágenes aéreas generadas mediante el vuelo fotogramétrico, McClain, B. P. (2022). Este algoritmo emplea técnicas de *Machine Learning* (aprendizaje automático), específicamente aprendizaje supervisado, una rama de la Inteligencia Artificial (*Artificial Intelligence*, AI) orientada al desarrollo de modelos predictivos a partir de datos etiquetados. En este caso, se entrena al modelo con muestras previamente identificadas (puntos de entrenamiento), que permiten clasificar regiones de la imagen como presencia o ausencia de árboles. Gómez, et al., (2011).

La última etapa de la metodología se centra en la evaluación y validación de los resultados. Para ello, se emplea una matriz de confusión, que permite comparar las predicciones del algoritmo con conteos manuales considerados como referencia o valores reales, a partir de esta comparación, se calculan métricas de desempeño como la precisión, sensibilidad y F1-score, lo que garantiza una evaluación objetiva del modelo y permite identificar oportunidades de mejora. Borja-Robalino, Et al., (2020).


9.2.1. LEVANTAMIENTO DE DATOS GEOESPACIALES

La etapa de levantamientos de datos espaciales se desarrolla con el objetivo de obtener las imágenes aéreas de alta resolución que sirvieran como insumos principales para la generación del mosaico de la zona de estudio. Se realizaron tres tareas principales, planeación del vuelo, establecimiento de puntos de control terrestre (GCP) y ejecución del vuelo.

El planeamiento del vuelo se realizó con el software *Dronelink* el día previo al vuelo, en este se hizo la delimitación del área de interés, donde se definió un polígono que cubría una extensión de 84096,5 m², teniendo en cuenta un margen de cobertura adicional para evitar zonas sin información, con el área de vuelo definida se realizó el diseño de vuelo para el modelo de UAV MAVIC AIR 2S.

El vuelo se realizó exitosamente en 13 líneas de vuelo, ejecutadas en 11 minutos y 49 segundos, los parámetros y diseño de vuelo se muestran en la (Figura 8)

Figura 8.
Configuración y diseño de vuelo fotogramétrico



Fuente: Elaboración propia, elaborado con el software Dronelink

El vuelo se realizó el día 22 de noviembre del 2023, entre las 11:00 y 12:00 horas, con el propósito de tener condiciones climáticas óptimas y la mayor iluminación posible. Previo al vuelo se realizó la toma de puntos de control con apoyo topográfico, estos se recolectaron con un equipo GNSS doble frecuencia *REACH RS2*, en total se midieron 9 puntos de control, se distribuyeron estratégicamente para abarcar toda la extensión del terreno de manera uniforme, priorizando ubicaciones visibles desde el aire y evitando áreas con cobertura densa de vegetación o elementos que pudieran obstruir la visibilidad en las imágenes aéreas, se puede ver en la (Figura 9). Además, para el diseño geométrico de los puntos de control terrestre (GCPs) se realizó una distribución uniforme de los puntos, en los bordes y en el centro del área de interés, garantizando que las correcciones se aplicaran de manera homogénea en todo el mosaico fotogramétrico. González, et al., (2016).

Figura 9.

Localización de puntos de control terrestre



Fuente: Elaboración propia, elaborado con QGIS

Cada punto de control fue materializado en el campo utilizando dianas de alta visibilidad diseñadas específicamente para vuelos fotogramétricos, asegurando una fácil identificación en las imágenes aéreas, estas se colocaron sobre superficies visibles, y se fijaron al terreno para evitar desplazamientos debido a las condiciones ambientales (Figura 10).

Para localizar las coordenadas de cada punto de control, se operó el receptor en modo RTK (*Real-Time Kinematic*). Este método permite obtener coordenadas con precisión centimétrica en tiempo real (Figura 11).

Figura 10.
Diana de alta visibilidad.



Fuente: elaboración propia de datos tomados en campo

Figura 11.
Equipo receptor GNSS REACH RS2



Fuente: elaboración propia de datos tomados en campo

Para cada punto de control se realizó el siguiente procedimiento:

Se posicionó el receptor *Rover* directamente sobre el centro del marcador, Cada punto fue observado durante al menos 120 segundos, lo que permitió estabilizar la señal y minimizar los errores debidos al ruido en la medición GNSS, cada punto tuvo en promedio errores de medición de 0.05 m, el equipo registró coordenadas en formato LLH (latitud, longitud, altura) en el sistema de referencia WGS 84 (EPSG: 4326). Se verificó la calidad de la señal GNSS mediante indicadores como la

dilución de precisión (*Position Dilution of Precision*, PDOP) y la cantidad de satélites visibles. Solo se aceptaron mediciones con un PDOP inferior a 2 y con al menos 10 satélites activos.

Los datos de cada medición se exportaron a un formato compatible con el software de procesamiento, archivos .CSV y RINEX, y se almacenaron en una base de datos organizada.

Finalmente, se ejecutó el vuelo fotogramétrico con el UAV DJI Air 2S, previamente inspeccionado para asegurar el correcto funcionamiento de sus sistemas. Antes del despegue. Durante el vuelo, el UAV siguió automáticamente la ruta planificada, tomando fotografías con un solapamiento de 75 % para cubrir el área delimitada. El vuelo fue monitoreado en tiempo real para garantizar su correcto desarrollo y registrar datos adicionales como la altitud, velocidad y consumo de batería.


Como resultado del vuelo fotogramétrico se obtuvo un total de 199 imágenes en formato .JPG con unas dimensiones de 4000*3000 pixeles cada imagen. Estos insumos se utilizaron como base para la siguiente fase del proyecto.

9.2.2. PREPROCESAMIENTO DE IMÁGENES

El procesamiento de las imágenes fotogramétricas, se desarrolla con el software *Agisoft Metashape*, se inicia con la importación de las imágenes fotogramétricas, Estas imágenes incorporan metadatos que contienen información espacial, incluyendo georreferenciación y parámetros de orientación predeterminados dados por del sistema GNSS del UAV. Una vez importadas, el software organiza las imágenes en un proyecto para facilitar su manejo y procesamiento.

El primer paso es la alineación de imágenes, en este proceso *Agisoft Metashape* utiliza algoritmos de correlación basados en puntos de interés (*feature points*) detectados automáticamente, además aplica el algoritmo de detección y emparejamiento de puntos, como *SIFT (Scale-Invariant Feature Transform)*, para identificar patrones únicos en las imágenes y establecer correspondencias entre ellas. A partir de estas correspondencias, se construye un modelo inicial de nube de puntos dispersa, el cual describe la distribución espacial de los objetos presentes en las imágenes. Rímolo Donadio, R., et al., (2021). Para la alineación de imágenes se utilizó una configuración con calidad alta y un número de puntos de interés de 40000 con la finalidad de maximizar la calidad del producto resultante (Figura 12).

Figura 12.
Configuración y resultado de alineación de imágenes.




Fuente: elaboración propia por medio de Agisoft Metashape

A continuación, se integran los puntos de control terrestre (GCPs) adquiridos con el receptor GNSS *Reach RS2*, estos se encuentran en un archivo de datos de texto en formato .CSV. Los GCPs se cargan al proyecto mediante sus coordenadas geográficas y se vinculan manualmente con sus posiciones exactas en las imágenes correspondientes. asociados los GCPs, el software ajusta el modelo mediante un proceso de optimización basado en un enfoque de mínimos cuadrados, minimizando los errores de reproyección y asegurando una alineación precisa.

El siguiente paso en el flujo de trabajo es la generación de una nube de puntos densa. *Metashape* utiliza técnicas de correlación estéreo, procesando pares de imágenes con traslape para interpolar puntos adicionales en el espacio tridimensional, este proceso requiere un análisis intensivo y hace uso de métodos como *Semi-Global Matching* (SGM), ajustando las disparidades entre las imágenes emparejadas. Rímolo Donadio, R., et al., (2021). Se optó por una configuración con calidad alta y un filtrado de profundidad moderado, y no por la configuración de mayor calidad, debido a que reduce la resolución progresivamente y aminora el tiempo de procesamiento, ya que no es necesario un nivel de detalle muy alto para los fines de este proyecto (Figura 13).

Figura 13.

Configuración y resultado de nube de puntos densa



Fuente: elaboración propia por medio de Agisoft Metashape.

Finalmente, se lleva a cabo la creación del mosaico ortorrectificado (imagen .tif). Para esta tarea, *Metashape* combina las imágenes alineadas y corrige las distorsiones geométricas causadas por la perspectiva de la cámara y las irregularidades del terreno. Este paso implica proyectar las imágenes sobre un modelo digital de elevación (DEM) generado a partir de la nube de puntos densa. El software selecciona automáticamente las mejores regiones de cada imagen para generar el mosaico, minimizando sombras, áreas de distorsión o duplicados, y asegurando la continuidad visual, se aplicó el modo de mezcla Mosaico, esta configuración fue seleccionada porque permite obtener un mosaico ortorrectificado de alta precisión espacial (5 cm/píxel), también se seleccionó el sistema de referencia WGS 84 (EPSG: 4326) (Figura 14)

El resultado es una ortofoto georreferenciada de alta precisión, contenida en un archivo .TIFF de 8338 MB de peso incluyendo sus metadatos espaciales asociados.

Este mosaico se utilizará para el análisis y procesamiento automatizado en las siguientes etapas del proyecto.

Figura 14.
Configuración y resultado de ortomosaico



Fuente: elaboración propia por medio de Agisoft Metashape.

9.2.3. PROCESAMIENTO DE DATOS

Esta etapa del proyecto se centra en el procesamiento y análisis de datos geoespaciales para identificar y clasificar árboles en cultivos arbustivos mediante un algoritmo de aprendizaje automático. Este enfoque integra varias bibliotecas y técnicas de Python. El proceso está dividido en cinco pasos fundamentales: (a) la lectura de los datos geoespaciales, (b) el entrenamiento del modelo de clasificación, (c) la clasificación de la imagen, (d) el agrupamiento de árboles detectados y, finalmente, (e) la visualización de los resultados.

Lectura de datos geoespaciales

La función de este proceso es la lectura de los datos de tipo geoespaciales, debe procesar los archivos formato *shapfile* que contiene las coordenadas geográficas y un identificador único de los puntos de entrenamiento, y también los archivos formato ráster con la información geoespacial de la zona de estudio con los árboles a contabilizar; los archivos formato *shapfile* corresponden a puntos de entrenamiento que son seleccionados manualmente en un software de procesamiento de información geográfica como QGIS y actúan como las muestras de entrenamiento que el algoritmo usará para aprender a diferenciar los árboles de otros objetos en la imagen. Para la lectura del *shapfile* se utiliza la función

geopandas.read_file(shapefile_path), que permite cargar el archivo de puntos en formato *GeoDataFrame*. Esta función facilita la manipulación de datos espaciales dentro de un entorno Python y permite trabajar con geometrías de puntos, líneas o polígonos, ayudando para identificar las ubicaciones de los árboles. Se utilizó a biblioteca Geopandas para desarrollar esta tarea, por su integración con otras bibliotecas como *Shapely* y *Fiona*, lo que permite realizar operaciones espaciales avanzadas. McClain, B. P. (2022).

Para la lectura de la imagen rasterizada, se utiliza la biblioteca *rasterio*, que está diseñada específicamente para trabajar con datos de tipo ráster, Esta biblioteca permite extraer los valores de los píxeles de la imagen y realizar una transformación, permitiendo convertir las coordenadas geográficas de los puntos de entrenamiento a las coordenadas de la imagen en píxeles, esta tarea debe realizarse ya que los puntos de entrenamiento no se encuentran directamente en la imagen rasterizada, y es necesario establecer una relación espacial entre ambos para poder asociar correctamente cada punto de entrenamiento a los valores espectrales correspondientes en la imagen. Todo este proceso se ejecuta mediante la función *rasterio.open(raster_path)* permitiendo abrir y leer los archivos ráster, esta realiza la tarea de la interpretación espacial de las coordenadas dentro del sistema de referencia geoespacial. Gillies, S. (2019).

Entrenamiento de Modelo de Clasificación

En esta etapa se busca entrenar un modelo de clasificación que pueda reconocer y distinguir los árboles dentro de la imagen aérea, el algoritmo se fundamenta en el uso del clasificador *Random Forest*, un método de ensamble basado en la construcción de múltiples árboles de decisión, que mejora la precisión del modelo al reducir la varianza y evitar el sobreajuste, esta técnica permite modelar relaciones no lineales entre las variables espectrales y espaciales extraídas de las imágenes, optimizando así la detección de individuos arbóreos frente a la heterogeneidad del cultivo. Cánovas, et al., (2016).

Este paso permite que el algoritmo aprenda a reconocer patrones en los datos y sea capaz de clasificar de manera automática los píxeles de la imagen, Para este propósito, se ha optado por utilizar un *Random Forest Classifier* implementado en la biblioteca *Scikit-learn*. *Random Forest* es un algoritmo comúnmente utilizado en problemas de clasificación en imágenes, gracias a su capacidad para manejar grandes volúmenes de datos y su resistencia al sobreajuste. Breiman (2001).

Se emplea la función *RandomForestClassifier(n_estimators=50, random_state=42)* para entrenar el modelo con un conjunto de características extraídas de los puntos de entrenamiento proporcionados por el *shapefile*.

Para entrenar el modelo, el algoritmo utiliza las características extraídas de la imagen, como valores de píxeles en diferentes bandas espectrales del ráster, cada punto de entrenamiento se asocia con una clase (en este caso, árbol o no árbol), y el modelo aprende a identificar las características espectrales que distinguen a los árboles de otros elementos en la imagen, como suelo o vegetación no arbustiva.

Finalmente la función *train_model(features, labels)* ajusta el modelo, recibe las características espectrales extraídas de la imagen como entradas y las clases correspondientes de los puntos de entrenamiento como etiquetas, resultando en un clasificador que podrá predecir la clase de cada píxel en la imagen completa.

Clasificación de la Imagen

Con el modelo entrenado, el algoritmo debe aplicar este a toda la imagen para clasificar cada píxel en función de si pertenece al grupo árbol o no árbol, para esto, utiliza las características espectrales de cada píxel para predecir su clase y así obtener un mapa de clasificación, donde cada píxel es asignado a una categoría. Este proceso es realizado mediante la función *classify_image(model, image)*, que toma el modelo entrenado y la imagen para hacer una predicción de cada píxel, la imagen se reestructura en un formato adecuado para que cada píxel sea etiquetado de acuerdo con la clase a la que pertenece.

La clasificación de la imagen se realiza utilizando la técnica de predicción de píxeles basada en el modelo de *Random Forest* y la función *reshape*, que reorganiza la imagen en una estructura unidimensional, aplicando el modelo de clasificación a todos los píxeles simultáneamente, con la predicción hecha en todos los píxeles de la imagen, los resultados son transformados al formato original de la imagen para que las clasificaciones puedan ser visualizadas. Breiman (2001).

Este tipo de clasificación es muy efectivo cuando se dispone de un modelo bien entrenado, por eso el resultado de las predicciones dependerá en gran medida de la calidad de los puntos de entrenamiento. Pal, M. (2005).

Agrupamiento de Árboles Detectados

Los árboles detectados en la etapa anterior, se agrupan a partir de resultados de la clasificación utilizando un algoritmo de agrupamiento. Esto se realiza mediante el uso del algoritmo de agrupamiento espacial *DBSCAN (Density-Based Spatial Clustering of Applications with Noise)* y la biblioteca *Scikit-learn*, este efectúa una técnica de agrupamiento que clasifica puntos basándose en la densidad local en el espacio geográfico. Este enfoque resulta particularmente útil cuando se trabaja con conjuntos de datos espaciales que contienen distribuciones irregulares. Ester, M. et al., (1996).

La función *compute_cluster_centers(centers)* se encarga de identificar los centros de los árboles y agruparlos según su proximidad. El parámetro EPS (radio de vecindad) se utiliza para definir la distancia máxima entre los puntos para que puedan ser considerados parte de un mismo grupo, mientras que *min_samples* (mínimo de puntos requeridos para formar un clúster) permiten ajustar el modelo para adaptarse a la densidad y escala de los árboles en la imagen analizada. Por las características de las muestras utilizadas en este proyecto, el valor de EPS= por defecto es 120, debido a que es el valor de EPS= más común entre los árboles del cultivo estudiado.

Visualización de Resultados

Finalmente, los resultados de la clasificación y el agrupamiento se pueden visualizar para brindar una representación gráfica de los resultados obtenidos del proceso. Para esta visualización, se utiliza la función *plt.subplots()* de la biblioteca *Matplotlib*, que permite generar subgráficos para visualizar las diferentes etapas del proceso. En este paso, la función *visualize_results(image, results, pixel_coords, cluster_centers, max_region, regions, labeled_image, affine, raster_path)* genera gráficos interactivos que muestran los puntos de entrenamiento, la densidad de coincidencias, las detecciones de árboles y el contorno de árbol común. Además, se permite al usuario ajustar parámetros como el tamaño mínimo de las regiones, lo que da flexibilidad para modificar la sensibilidad del modelo según las características específicas de la imagen. También se proporciona una opción para guardar los resultados del conteo arbóreo en formatos .SHP y .CSV, donde hay un identificador único y las coordenadas geográficas de cada uno de los árboles detectados.

9.2.4. ANÁLISIS DE RESULTADOS

Para evaluar la eficacia del algoritmo de conteo semiautomático de árboles, se implementó un análisis comparativo entre los resultados generados por el algoritmo y los obtenidos manualmente por un operador con experiencia intermedia en el uso de software geoespacial como QGIS y en la interpretación de imágenes aéreas. Congalton, R. G., y Green, K. (2019), señalan que esta práctica es importante en estudios relacionados con la validación de algoritmos de clasificación y segmentación en imágenes aéreas, porque permite medir la precisión de las predicciones realizadas por el algoritmo.

Este análisis se llevó a cabo en seis (6) zonas de estudio distintas, que hacen parte de un mismo cultivo. La selección de las zonas de estudio se realizó considerando la inclusión de áreas que presentaran variabilidad en las características de los árboles, tales como diferencias en edad o tamaño, este enfoque tuvo como objetivo garantizar la heterogeneidad de las muestras, permitiendo evaluar el desempeño del algoritmo en condiciones diversificadas. Además, se pretende medir tanto la eficiencia temporal como la precisión del modelo automatizado.

Se inició con el conteo manual, este consistió en la identificación y registro de árboles de manera visual, utilizando herramientas de software geoespacial como QGIS. El operador generó un archivo vectorial *shapefile* con geometría de punto, sus atributos incluyen coordenadas geográficas y un identificador único (ID) para cada árbol detectado. Este proceso manual, considerado como la referencia o valor real, también permitió registrar el tiempo requerido para completar la tarea en cada una de las seis zonas seleccionadas.

Posteriormente, se ejecutó el algoritmo de conteo semiautomático en las mismas zonas de estudio, generando archivos *shapefile* con las mismas características que los obtenidos manualmente. Se realizó una comparación directa del tiempo invertido en el proceso manual frente al tiempo de ejecución del algoritmo.

Para evaluar la precisión del algoritmo, se construyó una matriz de confusión para cada una de las zonas analizadas. La matriz de confusión es una herramienta idónea para evaluación de algoritmos de clasificación o detección, ya que permite analizar en detalle el desempeño del modelo al comparar sus predicciones con los valores reales. Borja-Robalino, Et al., (2020).

Esta herramienta permite visualizar la correspondencia entre los árboles detectados correctamente de manera automáticamente (verdaderos positivos) y aquellos detectados manualmente, así como los errores cometidos, tanto las falsas detecciones (falsos positivos) como los árboles no identificados (falsos negativos).

A partir de las matrices de confusión, se calcularon métricas como la Precisión Global (*Accuracy*), que mide la proporción de detecciones correctas sobre el total de observaciones; la Precisión (*Precision*), que evalúa la proporción de verdaderos positivos frente al total de predicciones positivas; la Sensibilidad (*Recall*), que mide la proporción de verdaderos positivos frente al total de positivos reales; y la Puntuación F1 (*F1-Score*), que combina precisión y sensibilidad en una única métrica equilibrada. Estas métricas proporcionan una forma cuantitativa y estandarizada de medir la eficacia del modelo e interpretar posibles errores en las predicciones. Foody, G. M. (2002).

10.RESULTADOS

El proceso de evaluación de resultados se llevó a cabo en dos fases. La primera fase correspondió a la ejecución del algoritmo, el cual fue operado por el usuario a través de una interfaz interactiva diseñada para optimizar el procedimiento de conteo arbóreo de manera semiautomática.

En la segunda fase, se evaluó la precisión y eficacia del algoritmo en la detección y cuantificación de árboles. Para ello, se ejecutó el modelo en seis zonas de muestreo dentro del cultivo, comparando los resultados obtenidos con un conteo manual de referencia. Posteriormente, se calcularon métricas de desempeño con el objetivo de cuantificar la confiabilidad del algoritmo en la estimación del número de árboles presentes en el área de estudio.

10.1. EJECUCIÓN DEL ALGORITMO

Con el código completo, la segunda parte de esta etapa se centra en cómo el usuario interactúa con el sistema para realizar el conteo de árboles de forma semiautomática. Para iniciar el proceso, el usuario debe ejecutar el script principal del proyecto, típicamente un archivo Python. Esto se logra mediante un entorno de desarrollo integrado (IDE) como *VSCode*.

Al ejecutar el código, se carga la interfaz gráfica diseñada para facilitar la interacción con el usuario. Esta interfaz ha sido desarrollada empleando la biblioteca *Tkinter*, la interfaz proporciona un entorno intuitivo para que el usuario configure los parámetros necesarios y realice el conteo semiautomático de árboles.

Antes de proceder con el conteo semiautomático, el usuario debe disponer de un mosaico geoespacial, que corresponde a un archivo ráster en formato .TIF, .JPG o .PNG. Este mosaico debe contener la zona de estudio donde se desea realizar el conteo arbóreo. La interfaz del programa presenta, al iniciar, una ventana principal configurada por defecto en la pestaña denominada Conteo (Figura 15).

Esta modalidad es adecuada para los casos en los que el usuario ya cuenta con puntos de entrenamiento predefinidos, dichos puntos deben haberse generado previamente en un software especializado en Información Geográfica, como QGIS, y deben ser proporcionados en formato *shapefile*, este archivo debe contener atributos espaciales de coordenadas geográficas y un identificador único asociado

a cada punto (ID), asegurando que cada uno corresponde a lo que se clasifica como árbol.

Para cargar los datos necesarios en esta modalidad, el usuario debe utilizar los botones habilitados en la interfaz (Figura 15):

Seleccionar *shapefile*: Este botón permite al usuario cargar el archivo vectorial que contiene los puntos de entrenamiento predefinidos. Al pulsarlo, se abre un cuadro de diálogo para navegar por los archivos del sistema y seleccionar el *shapefile* deseado.

Cargar mosaico: Mediante este botón, el usuario puede seleccionar y cargar el archivo ráster que representa el mosaico de la zona de estudio. Este archivo será utilizado como base para ejecutar el algoritmo.

En esta etapa, el sistema valida los formatos de los archivos cargados y verifica que los datos sean compatibles con los requisitos del procesamiento, este paso inicial asegura que el algoritmo pueda ejecutar los procesos siguientes.

Figura 15.
Interfaz de inicio del algoritmo para conteo arbóreo




Fuente: elaboración propia, por medio de Python.

El sistema también ofrece una modalidad alternativa a través de la pestaña Preproceso, donde la ventana de inicio le indica al usuario cómo utilizar la herramienta para seleccionar y procesar los datos, (Figura 16). Tras cargar el mosaico, se abre una nueva ventana interactiva que proporciona al usuario la posibilidad de seleccionar una zona de estudio en específico y definir los puntos de entrenamiento manualmente desde la interfaz, el usuario debe definir de forma manual el área de estudio específica directamente sobre el mosaico cargado (Figura 17), y también debe de seleccionar los puntos de entrenamiento necesarios para el algoritmo (Figura 18). En este método, no es necesario proporcionar un *shapefile* predefinido, ya que los puntos se generan directamente en la interfaz.


Figura 16.

Ventana de inicio para pestaña Preproceso




Fuente: elaboración propia, por medio de Python

Figura 17.
ventana de dialogo para selección de zona de estudio



Fuente: elaboración propia, por medio de Python

Figura 18.
ventana para selección de puntos de entrenamiento



Fuente: elaboración propia, por medio de Python

Una vez que el usuario ha definido el área de estudio y seleccionado los puntos de entrenamiento mediante la modalidad Preproceso, estos se almacenan en el equipo local. El siguiente paso consiste en volver a la pestaña Conteo y repetir el proceso de carga descrito previamente: importar el archivo ráster que contiene la zona de estudio y el archivo *shapefile* que incluye los puntos de entrenamiento. Estos archivos son los insumos principales que requiere el algoritmo para realizar el análisis.

Cuando ambos archivos han sido cargados correctamente, el sistema verifica sus características principales y muestra un mensaje informativo que incluye el sistema de referencia espacial utilizado (tanto del *shapefile* como del ráster) (Figura 19). Esto garantiza que ambos insumos estén en un sistema de coordenadas compatible.

Con los insumos validados, el usuario puede iniciar el procesamiento semiautomático seleccionando el botón Iniciar Proceso (Figura 19). Al activar esta función, el algoritmo comienza la ejecución, y el sistema genera una nueva ventana en la que se visualizan los resultados intermedios y finales del análisis, estos resultados se presentan de manera gráfica en una serie de visualizaciones, organizadas en ventanas individuales que incluyen:

Puntos de entrenamiento: Una representación de los puntos utilizados para entrenar el algoritmo.

Densidad de coincidencias: Un mapa de densidad que refleja las áreas donde el algoritmo ha identificado patrones de similitud con los puntos de entrenamiento.

Detecciones de árboles: Un mapa que destaca los árboles detectados por el algoritmo y la cantidad de detecciones.

Contorno de árbol común: Una visualización que ilustra el perímetro del tipo de árbol más común.

Figura 19.
ventana de inicio de proceso




Fuente: elaboración propia, por medio de Python

Además, la interfaz ofrece una opción para ajustar el parámetro de Tamaño de Región Mínimo (Figura 20), el cual define el tamaño mínimo de las áreas detectadas que el sistema considera como árboles, este parámetro asegura que solo se incluyan en los resultados áreas con dimensiones adecuadas, si el usuario aumenta este valor, el algoritmo ignorará regiones pequeñas que podrían no corresponder a árboles reales. Esta funcionalidad permite al usuario personalizar el análisis según las características específicas de la zona de estudio.

Finalmente, el sistema ofrece la posibilidad de descargar los resultados del conteo semiautomático en dos formatos, un archivo *Shapefile* con información vectorial que contiene geometrías de puntos, cada uno asociado a un árbol detectado. Los atributos de este archivo incluyen las coordenadas geográficas y un identificador único (ID) para cada árbol. También un archivo .CSV tabular que proporciona la misma información en formato de texto, con columnas que incluyen las coordenadas geográficas y los identificadores únicos.

Figura 20.
ventana de resultados



Fuente: elaboración propia, por medio de Python

10.2. RESULTADOS DE MUESTRAS

Los resultados de las pruebas realizadas en cada muestra se presentan a continuación:


10.2.1. MUESTRA 1

Una vez completada la configuración y ejecución del código, los resultados obtenidos se presentan en la (Figura 21), en la (Figura 22) Se comparan las detecciones realizadas por el algoritmo con aquellas obtenidas mediante conteo manual. Adicionalmente, los resultados del análisis de comparación de desempeño del algoritmo frente al procesamiento manual supervisado, se muestran en la Tabla 6, mientras que la precisión del modelo se evalúa a través de la matriz de confusión en la Tabla 7 y las métricas de rendimiento en la Tabla 8.

Figura 21.

Resultados de cuantificación semiautomática para la muestra 1

Resultados para árboles cítricos de la imagen Archivo Raster: area.tif



Tamaño de región mínimo

400

Aplicar


Guardar SHP

Guardar CSV

Nota: elaboración propia, elaborado por medio de Python

Figura 22.

Comparación de predicciones hechas por el algoritmo con conteo manual



Nota: Elaboración propia, elaborado con Python y QGIS

Tabla 6.*Comparación de desempeño entre algoritmo y operario humano en la muestra 1*

MUESTRA 1		
ITEM EVALUADO	CONTEO MANUAL	PREDICCIÓN DEL ALGORITMO
Área censada en m ²	5036	5036
Tiempo de ejecución	10'22"	3'16"
Detecciones realizadas	114	111

Tabla 7.*Resultados de matriz de confusión en muestra 1*

MATRIZ DE CONFUSIÓN		
DATOS REALES (CONTEO MANUAL)	PREDICCIÓN	
	POSITIVO	NEGATIVO
Árbol (114) Grupo 1 (113) Grupo 2 (11)	102(TP)	12(FN)
No árbol (0)	9(FP)	0(TN)

Tabla 8.*Resultado de cálculo de métricas en la muestra 1*

METRICA	VALOR
Precisión global	82.9 %
Precisión	91.9 %
Sensibilidad	89.5 %
F1-score	90.7 %

El algoritmo logró identificar correctamente 111 individuos arbóreos en la muestra evaluada, un F1-Score del 90.7 % indica un equilibrio entre precisión y sensibilidad, esto garantiza que el modelo para esta muestra no solo está detectando correctamente los árboles presentes, sino que no omite demasiados elementos reales.


La vegetación cercana no perteneciente al cultivo pudo incidir en la identificación errónea de 9 falsos positivos, ya que la variación en la información espectral de los píxeles de esta vegetación podría haber coincidido con las características utilizadas por el algoritmo para identificar árboles.

10.2.2. MUESTRA 2

Finalizada la ejecución del código sobre la segunda muestra, los resultados obtenidos se presentan en la (Figura 23). La comparación entre las detecciones generadas por el algoritmo y el conteo manual se ilustra en la (Figura 24). La evaluación cuantitativa del desempeño se encuentra en la Tabla 9, donde se analizan los valores obtenidos en contraste con el procesamiento manual. Adicionalmente, la Tabla 10 muestra la matriz de confusión y la Tabla 11 expone las métricas que reflejan la precisión del modelo en esta muestra.

Figura 23.


Resultados de cuantificación semiautomática para la muestra 2



Nota: elaboración propia, elaborado por medio de Python

Figura 24.

Comparación de predicciones hechas por el algoritmo con conteo manual



Nota: Elaboración propia, elaborado con Python y QGIS

Tabla 9.

Comparación de desempeño entre algoritmo y operario humano en la muestra 2

MUESTRA 2		
ITEM EVALUADO	CONTEO MANUAL	PREDICCIÓN DEL ALGORITMO
Área censada en m ²	3419	3419
Tiempo de ejecución	9'14"	2'45"
Detecciones realizadas	126	103

Tabla 10.

Resultados de matriz de confusión en muestra 2

MATRIZ DE CONFUSIÓN		
DATOS REALES (CONTEO MANUAL)	PREDICCIÓN	
	POSITIVO	NEGATIVO
Árbol (126) Grupo 1 (113) Grupo 2 (13)	103(TP)	23(FN)
No árbol (0)	0(FP)	0(TN)

Tabla 11.*Resultado de cálculo de métricas en la muestra 2*


METRICA	VALOR
Precisión global	81.7 %
Precisión	100.0 %
Sensibilidad	81.7 %
F1-score	90.0 %

En esta muestra a pesar que la precisión es máxima (100 %), lo que significa que no hubo falsos positivos en esta muestra, la sensibilidad es más baja (81 %), lo que indica que el algoritmo no detectó una cantidad significativa de árboles correctamente. La alta cantidad de falsos negativos (23) puede explicarse por la prevalencia de árboles en etapas muy jóvenes con copas de poco follaje, Estos casos pueden generar confusión en el algoritmo, ya que la cobertura reducida y las características espectrales menos definidas dificultan la identificación.

10.2.3. MUESTRA 3


La ejecución del algoritmo en la tercera muestra permitió obtener los resultados expuestos en la (Figura 25), mientras que la comparación entre las detecciones automáticas y el conteo manual se visualiza en la (Figura 26). En la Tabla 12 se detallan los valores obtenidos del análisis comparativo entre ambos métodos, complementados por la matriz de confusión en la Tabla 13 y las métricas de desempeño en la Tabla 14.

Figura 25.
Resultados de cuantificación semiautomática para la muestra 3



Nota: elaboración propia, elaborado por medio de Python

Figura 26.
Comparación de predicciones hechas por el algoritmo con conteo manual



Nota: Elaboración propia, elaborado con Python y QGIS

Tabla 12.*Comparación de desempeño entre algoritmo y operario humano en la muestra 3*

MUESTRA 3		
ITEM EVALUADO	CONTEO MANUAL	PREDICCIÓN DEL ALGORITMO
Área censada en m ²	3492	3492
Tiempo de ejecución	5'02"	2'15"
Detecciones realizadas	66	66

Tabla 13.*Resultados de matriz de confusión en muestra 3*

MATRIZ DE CONFUSIÓN		
DATOS REALES (CONTEO MANUAL)	PREDICCIÓN	
	POSITIVO	NEGATIVO
Arboles (66) Grupo 1 (59) Grupo 2 (7)	60(TP)	6(FN)
No árbol (0)	6(FP)	0(TN)

Tabla 14.*Resultados de cálculo de métricas en muestra 3*


METRICAS	VALOR
Precisión global	83.3 %
Precisión	90.9 %
Sensibilidad	90.9 %
F1-score	90.9 %

Tanto la precisión como la sensibilidad son altas (90.9 %), lo que demuestra que el algoritmo es eficiente para entornos con características similares a las de esta muestra. El algoritmo tuvo un mejor comportamiento en la calidad de predicción en entornos donde los árboles tienen sus características definidas, como un claro contraste entre la copa y el terreno o poca vegetación circundante, además hay un mayor espacio entre las copas de árboles sembrados.

10.2.4. MUESTRA 4


Para la cuarta muestra, la aplicación del algoritmo generó los resultados representados en la (Figura 27). En la (Figura 28) se presenta un análisis comparativo entre las detecciones realizadas por el modelo y el conteo manual. La Tabla 15 recoge los datos obtenidos del análisis de desempeño, mientras que la precisión del modelo se cuantifica a través de la matriz de confusión en la Tabla 16 y las métricas específicas en la Tabla 17.

Figura 27.
Resultados de cuantificación semiautomática para la muestra 4



Nota: elaboración propia, elaborado por medio de Python

Figura 28.
Comparación de predicciones hechas por el algoritmo con conteo manual



Nota: Elaboración propia, elaborado con Python y QGIS

Tabla 15.*Comparación de desempeño entre algoritmo y operario humano en la muestra 4*

MUESTRA 4		
ITEM EVALUADO	CONTEO MANUAL	PREDICCIÓN DEL ALGORITMO
Área censada m ²	3940	3940
Tiempo de ejecución	4'54"	2'21"
Detecciones realizadas	86	78

Tabla 16.*Resultados de matriz de confusión en muestra 4*

MATRIZ DE CONFUSIÓN		
DATOS REALES (CONTEO MANUAL)	PREDICCIÓN	
	POSITIVO	NEGATIVO
Árbol (88)	76(TP)	12(FN)
No árbol (0)	2(FP)	0(TN)

Tabla 17.*Resultados de cálculo de métricas en muestra 4*


METRICA	VALOR
Precisión global	84.4 %
Precisión	97.4 %
Sensibilidad	86.4 %
F1-score	91.6 %

Este caso presentó la mayor precisión (97.4 %) de todas las muestras, con un F1-Score de 91.6 %. La sensibilidad es ligeramente menor, lo que indica que algunos árboles no fueron detectados. Los falsos negativos (12) se agrupan en una región donde la vegetación cercana tenía un color muy similar al de las copas de los árboles, esto puede indicar que el modelo no logra diferenciar entre estos elementos con similitud espectral.

10.2.5. MUESTRA 5


Tras la ejecución del algoritmo en la quinta muestra, los resultados obtenidos se visualizan en la (Figura 29). La (Figura 30) muestra la correspondencia entre las detecciones automáticas y el conteo manual de referencia. En la Tabla 18 se presentan los valores obtenidos del análisis de desempeño, seguidos por la matriz de confusión en la Tabla 19 y las métricas de evaluación en la Tabla 20.

Figura 29.
Resultados de cuantificación semiautomática para la muestra 5



Nota: elaboración propia, elaborado por medio de Python

Figura 30.
Comparación de predicciones hechas por el algoritmo con conteo manual



Nota: Elaboración propia, elaborado con Python y QGIS

Tabla 18.*Comparación de desempeño entre algoritmo y operario humano en la muestra 5*

MUESTRA 5		
ITEM EVALUADO	CONTEO MANUAL	PREDICCIÓN DEL ALGORITMO
Área censada m ²	2106	2106
Tiempo de ejecución	4'30"	2'12"
Detecciones realizadas	73	59

Tabla 19.*Resultados de matriz de confusión en muestra 5*

MATRIZ DE CONFUSIÓN		
DATOS REALES (CONTEO MANUAL)	PREDICCIÓN	
	POSITIVO	NEGATIVO
Árbol (73) Grupo 1(62) Grupo 2(11)	57(TP)	17(FN)
No árbol (0)	2(FP)	0(TN)

Tabla 20.*Resultados de cálculo de métricas en muestra 5*

METRICA	VALOR
Precisión global	75.0 %
Precisión	96.6 %
Sensibilidad	77.0 %
F1-score	85.7 %


Esta muestra presenta una precisión global del 75 %, un porcentaje bajo comparado con las demás zonas evaluadas, la precisión de (96.6 %) sugiere que las detecciones positivas realizadas por el algoritmo son en su mayoría correctas, con solo 2 falsos positivos registrados, pero la sensibilidad (77 %) indica un índice alto de omisiones (17 falsos negativos). La estructura menos definida de las copas de los árboles jóvenes puede haber reducido la capacidad del algoritmo para diferenciar entre árboles y su entorno.

10.2.6. MUESTRA 6

En la sexta muestra, los resultados tras la ejecución del código se presentan en la (Figura 31). La (Figura 32) proporciona una comparación entre las detecciones realizadas por el algoritmo y el conteo manual. Para evaluar cuantitativamente el desempeño del modelo, en la Tabla 21 se expone el análisis comparativo con el método manual, la Tabla 22 presenta la matriz de confusión y la Tabla 23 expone los resultados de las métricas.

Figura 31.

Resultados de cuantificación semiautomática para la muestra 6



Nota: elaboración propia, elaborado por medio de Python

Figura 32.

Comparación de predicciones hechas por el algoritmo con conteo manual




Tabla 21.

Comparación de desempeño entre algoritmo y operario humano en la muestra 6

MUESTRA 6		
ITEM EVALUADO	CONTEO MANUAL	PREDICCIÓN DEL ALGORITMO
Área censada m ²	3073	3073
Tiempo de ejecución	3'40"	2'51"
Detecciones realizadas	61	58

Tabla 22.

Resultados de matriz de confusión en muestra 6

MATRIZ DE CONFUSIÓN		
DATOS REALES (CONTEO MANUAL)	PREDICCIÓN	
	POSITIVO	NEGATIVO
Árbol (61) Grupo 1(61) Grupo 2(0)	50(TP)	11(FN)
No árbol (0)	8(FP)	0(TN)

Tabla 23.*Resultados de cálculo de métricas en muestra 6*

METRICA	VALOR
Precisión global	72.5 %
Precisión	86.2 %
Sensibilidad	82.0 %
F1-score	84.0 %

El algoritmo tuvo una precisión global del 72.5 %, la menor de todas las muestras realizadas, la presencia de objetos no arbóreos en la imagen que fueron detectados como árboles sugiere que el algoritmo puede estar sensible a texturas o formas similares a las copas de los árboles. Adicionalmente, la configuración del tamaño de región mínimo (400) puede haber contribuido a la omisión de detecciones en una zona de estudio con un área menor, comparada con las muestras anteriores. las omisiones restantes (11 falsos negativos) no presentan un patrón claro más allá de un posible ajuste insuficiente de los parámetros.

11. DISCUSIÓN

Tras concluir las pruebas en las diferentes muestras, se calculó el promedio de las métricas para evaluar el desempeño global del algoritmo en el conteo semiautomático de árboles, cuyos resultados se resumen en la Tabla 24. Los valores promedio obtenidos en las métricas generales del algoritmo reflejan un desempeño eficiente en el conteo semiautomático de árboles. La precisión global promedio del 79.2 % evidencia que el modelo logra una clasificación acertada en una alta proporción de los casos evaluados, mientras que la precisión promedio del 93.83 % indica que rara vez clasifica incorrectamente elementos no arbóreos como árboles. Por otro lado, la sensibilidad promedio del 83.80 % y el F1-score promedio del 88.32 % señala que el modelo logra identificar con éxito una alta proporción de los árboles presentes en las imágenes.

No obstante, se observan variaciones en la sensibilidad y precisión entre las muestras, esta disparidad puede ser atribuida a diferencias en las condiciones geomorfológicas, la densidad de la vegetación, y la resolución o iluminación de las imágenes aéreas utilizadas, factores que influyen directamente en el rendimiento de los algoritmos de detección y conteo. Ordóñez-Prado, et al., (2024).

Las variaciones observadas en las métricas de cada muestra reflejan la influencia de factores como la densidad de la vegetación circundante, las características espectrales de los árboles y las condiciones geomorfológicas y visuales de las imágenes aéreas utilizadas. Por ejemplo, en áreas donde la vegetación adyacente presenta firmas espectrales similares a las copas de los árboles, se incrementa la probabilidad de falsos positivos. Asimismo, en zonas con árboles jóvenes o copas menos desarrolladas, se observa un mayor número de falsos negativos, debido a que las copas menos desarrolladas pueden reducir la capacidad del algoritmo para diferenciar entre árboles y su entorno. Cerezo Rebé, D. (2023).

Al comparar los resultados de las métricas con investigaciones previas, se constata una coherencia en las métricas obtenidas. Por ejemplo, Osco, L. P., et al. (2021) desarrollaron un método basado en redes neuronales convolucionales para detectar y geolocalizar hileras de plantación y contar plantas en imágenes de UAV, logrando una precisión y sensibilidad superiores al 85 % en cultivos de maíz y cítricos. De manera similar Verdiguier, E. I. (2011). implementó un método para identificar y clasificar automáticamente plantaciones de árboles utilizando imágenes de alta resolución, obteniendo una precisión del 95 % en la detección de árboles. Kumar, et al. (2021) igualmente alcanzó una precisión del 95% en su investigación enfocada

a detectar individuos arbóreos en cultivos de maíz, con la diferencia que en esta investigación se empleó el uso de imágenes multiespectrales la cuales brindan una información más detallada y facilita la labor de segmentación del algoritmo utilizado.

Tabla 24.

Resultado de cálculo promedio métricas.

METRICA	VALOR
Precisión global	79.2 %
Precisión	93.8 %
Sensibilidad	83.8 %
F1-score	88.3 %

12. CONCLUSIONES

El desarrollo y evaluación del algoritmo para la cuantificación semiautomática de árboles en cultivos cítricos, aplicado al caso de estudio en Dagua, Valle del Cauca, evidenció efectividad del uso de herramientas tecnológicas en la optimización de censos arbóreos en la agricultura. Los resultados obtenidos reflejan que la metodología implementada, que combinó fotogrametría mediante UAVs, georreferenciación con equipos GNSS y algoritmos de detección semiautomática, logró un desempeño general satisfactorio, con una precisión global promedio de 79.2 % y métricas de sensibilidad y F1-score de 83.8 % y 88.3 % respectivamente, muestra una buena capacidad para identificar árboles en la mayoría de los escenarios evaluados. Además, se logró una significativa reducción en los tiempos de procesamiento en comparación con los métodos manuales.

Este estudio permitió implementar un algoritmo capaz de procesar imágenes aéreas y generar predicciones para el conteo arbóreo en cultivos arbustivos, produciendo información gráfica de las detecciones e información vectorial georreferenciada de la ubicación de estas, también se utilizó un conjunto de métricas que validaron el rendimiento del modelo. El algoritmo permitió identificar el contorno típico de los árboles presentes en las zonas evaluadas, adicionalmente, la extracción de características específicas, como el número de árboles en áreas fue efectiva, mostrando mayor precisión en zonas donde las copas estaban claramente definidas y menos interferencia de vegetación circundante, logrando resultados consistentes que fueron evaluados y validados mediante métricas estadísticas. La comparación de los resultados generados por el algoritmo con los datos recolectados en campo confirmó la capacidad del modelo para realizar conteos arbóreos confiables, aunque se identificaron limitaciones en condiciones específicas, como áreas con árboles jóvenes o con elementos no arbóreos que compartían características espectrales similares, igualmente se destaca la importancia de los parámetros configurados en el algoritmo, como el tamaño de región mínimo, que influyó directamente en la calidad de las detecciones. Se observó que un ajuste adecuado de estos parámetros, sumado a una selección heterogénea de puntos de entrenamiento, mejora considerablemente los resultados obtenidos, especialmente en áreas con variaciones en las condiciones geomorfológicas o en la densidad del cultivo.

Se logró identificar limitaciones relacionadas con el desempeño del algoritmo en mosaicos de gran tamaño, donde la capacidad de procesamiento del algoritmo se ve afectada al intentar procesar imágenes con grandes volúmenes de datos, lo que podría limitar su aplicabilidad en áreas extensas; igualmente en escenarios donde la información espectral no es suficiente para discriminar adecuadamente entre árboles y otros elementos, lo que resultó en un mayor número de falsos positivos en áreas con vegetación circundante similar y de falsos negativos en árboles jóvenes o con copas menos definidas. Las muestras con puntos de entrenamiento con selecciones más heterogéneas mostraron mejores resultados, igualmente se evidenciaron más precisión de detecciones en imágenes donde el contorno de la copa de los árboles estaba claramente definido; La calidad de las predicciones depende directamente de los datos utilizados como insumos

La aplicación del algoritmo desarrollado no solo optimiza el proceso de conteo arbóreo con altos niveles de precisión, sino que también evidencia el potencial de integrar tecnologías como el uso de UAV en técnicas fotogramétricas y receptores GNSS para geolocalización, permitiendo a los agricultores acceder a información cuantitativa, georreferenciada y oportuna, facilitando la toma de decisiones fundamentadas en datos objetivos. En un contexto como el de Dagua, donde predomina una agricultura de carácter tradicional y con baja incorporación de herramientas tecnológicas, esto puede representar un avance en la transición de una agricultura tradicional hacia una agricultura más técnica y eficiente, abriendo la posibilidad de incorporar estas metodologías no solo a cultivos cítricos sino también a otras especies arbóreas o arbustivas presentes en la región, favoreciendo la reducción de los tiempos asociados a labores de monitoreo y el incremento en la calidad del control productivo. Además, este estudio contribuye al campo de la agricultura de precisión al validar la viabilidad de modelos de detección semiautomática en contextos rurales con baja tecnificación.

Finalmente, se recomienda como línea futura de investigación la aplicación del modelo hacia diferentes especies arbóreas, la integración de sensores multiespectrales que permitan mejorar la discriminación espectral entre coberturas, y la aplicación del algoritmo en diferentes tipos de cultivos y condiciones geomorfológicas, con la finalidad de analizar el comportamiento y la eficacia de modelos de cuantificación semiautomáticas en contextos heterogéneos. También sería relevante explorar técnicas de inteligencia artificial, como redes neuronales profundas (*deep learning*), que podrían mejorar la precisión y robustez del sistema de detección especialmente en escenarios de grandes extensiones agrícolas

13. BIBLIOGRAFÍA

- Alcaldía Municipal de Dagua. (2022a). Geografía de Dagua. Municipio. [Ver aquí](#)
- Avitt, A. (2020). Tree census and a wealth of public data. USDA Forest Service. [ver aquí](#)
- Banco Mundial. (2022). Colombia: Agricultura y desarrollo rural. [Ver aquí](#)
- Bassine, F.; Errami, A.; Khaldoun, M. (2019). Vegetation Recognition Based on UAV Image Color Index. IEEE Xplore. [Ver aquí](#)
- Bejarano, D.; García, D. (2018). Inventario arbóreo en ecosistemas de páramo a partir de técnicas de percepción remota [Universidad del Valle]. [Ver aquí](#)
- Beltrán Barreto, G. X. (2023). Antecedentes, uso y aplicación de drones en Colombia como herramienta estratégica de análisis en la agricultura de precisión. [Ver aquí](#)
- Berrío, V.; Mosquera, J.; Alzate, D. (2015). Uso de drones para el analisis de imágenes multiespectrales en agricultura de precisión. Ciencia y Tecnología Alimentaria @limentech, 13(1). [Ver aquí](#)
- Borja-Robalino, R., Monleon-Getino, A., & Rodellar, J. (2020). Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning. Revista Ibérica de Sistemas e Tecnologías de Informação, (E30), 184-196. [Ver aquí](#)
- Breiman, L. (2001). Random forests. Machine learning, 45, 5-32. [Ver aquí](#)
- Cánovas-García, F., Alonso-Sarría, F., & Gomariz-Castillo, F. (2016). Modificación del algoritmo Random Forest para su empleo en clasificación de imágenes de teledetección. In Aplicaciones de las Tecnologías de la Información Geográfica (TIG) para el desarrollo económico sostenible XVII Congreso Nacional de Tecnologías de Información Geográfica. [Ver aquí](#)
- Cerezo Rebé, D. (2023). Identificación de cultivos mediante teledetección y técnicas de machine learning en el ámbito territorial de la comarca de la Ribera Baja, Valencia. [Ver aquí](#)
- Congalton, R. G., & Green, K. (2019). Assessing the accuracy of remotely sensed data: principles and practices. CRC press. [Ver aquí](#)

- Csillik, O., Cherbini, J., Johnson, R., Lyons, A., & Kelly, M. (2018). Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. *Drones*, 2(4), 39. [Ver aquí](#)
- CVC—Corporación Autónoma Regional del Valle del Cauca. (2014). Portafolio de Estrategias para la Mitigación y Adaptación al Cambio Climático. municipio de Dagua Valle del Cauca. [Ver aquí](#)
- DANE. (2015). Cultivo de limón o lima Tahití (*Citrus latifolia* Tanaka) frente a los efectos de las condiciones climáticas adversas. *Boletín Mensual Insumos y Factores Asociados a La Producción Agropecuaria*, 41, 1–91. [Ver aquí](#)
- Datos Abiertos Colombia. (2020). Producción frutales Valle del Cauca. Datos Abiertos Colombia. [Ver aquí](#)
- De Castro, A. I., Torres-Sánchez, J., Peña, J. M., Jiménez-Brenes, F. M., Csillik, O., & López-Granados, F. (2018). An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. *Remote Sensing*, 10(2), 285. [Ver aquí](#)
- Dronelink. (2023). Automated drone mission planning and control. Recuperado el 28 de enero de 2025, [Ver aquí](#)
- El Imanni, H.; El Harti, A.; Bachaoui; Eddassouqui, F.; Achraf, M.; Zinelabidine, M. (2023). Multispectral UAV data for detection of weeds in a citrus farm using machine learning and Google Earth Engine: Case study of Morocco. *Remote Sensing Applications: Society and Environment*. [Ver aquí](#)
- Elmendorf, W. (2022). Conducting a Community Tree Inventory. PennState Extension. [Ver aquí](#)
- Eng, L. S., Ismail, R., Hashim, W., & Baharum, A. (2019). The use of VARI, GLI, and VIgreen formulas in detecting vegetation in aerial images. *International Journal of Technology*, 10(7), 1385-1394. [Ver aquí](#)
- Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996, August). A density-based algorithm for discovering clusters in large spatial databases with noise. In *kdd* (Vol. 96, No. 34, pp. 226-231). [Ver aquí](#)
- Falk, D.; Campos, A. (2014). Algoritmo semi-automático para el conteo de árboles en plantaciones forestales mediante el uso de imágenes aéreas. *SEDICI*, 186–194. [Ver aquí](#)

- FAO—Food and agriculture organization of the United Nations. (2016). The state of food and agriculture Climate change, agriculture and food security. [Ver aquí](#)
- FAO—Food and agriculture organization of the United Nations. (2021). Employment indicators 2000-20021. [Ver aquí](#)
- FAO. (2004). Inventario Forestal Nacional. Manual de campo modelo. [Ver aquí](#)
- Fernández Requelme, J. L., & Narro Mantilla, V. A. (2024). Evaluación de los costos y tiempos del levantamiento fotogramétrico con dron versus topografía convencional con estación total para la delimitación de la faja marginal del río Chicama - La Libertad, 2023 [Tesis de licenciatura, Universidad Privada del Norte]. [Ver aquí](#)
- Finagro. (2023). Crecimiento del sector agropecuario en Colombia. [Ver aquí](#)
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. Remote sensing of environment, 80(1), 185-201. [Ver aquí](#)
- Gago, J., Douthe, C., Coopman, R. E., Gallego, P. P., Ribas-Carbo, M., Flexas, J., ... & Medrano, H. (2015). UAVs challenge to assess water stress for sustainable agriculture. Agricultural water management, 153, 9-19. [Ver aquí](#)
- Gaitán García, C. A. (2017). Diseño de un sistema robótico móvil aéreo no tripulado equipado con sensores de percepción remota para estimar descriptores de un cultivo de caña de azúcar en el Valle del Cauca (Master's thesis, Universidad Autónoma de Occidente). [Ver aquí](#)
- Geoinnova, A. (2021). Los 9 principales índices de vegetación más usados en teledetección. Geoinnova. [Ver aquí](#)
- Gillies, S. (2019). rasterio Documentation. MapBox: San Francisco, CA, USA, 23. [Ver aquí](#)
- Global Mediterránea Geomática. (2020). Fotogrametría: Qué es, ventajas y metodología. Global Mediterránea Geomática. [Ver aquí](#)
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., ... & Toulmin, C. (2010). Food security: the challenge of feeding 9 billion people. science, 327(5967), 812-818. [Ver aquí](#)

- Gómez, C., White, J. C., & Wulder, M. A. (2011). Characterizing the state and processes of change in a dynamic forest environment using hierarchical spatio-temporal segmentation. *Remote Sensing of Environment*, 115(7), 1665-1679. [Ver aquí](#)
- González, A.; Amarillo, G.; Amarillo, M.; Sarmiento, F. (2016). Drones Aplicados a la Agricultura de Precisión. *Publicaciones e Investigación UNAD*, 10, 23–37. [Ver aquí](#)
- Hasan, M. M., Islam, M. U., & Sadeq, M. J. (2022). Towards technological adaptation of advanced farming through AI, IoT, and Robotics: A Comprehensive overview. *arXiv preprint arXiv:2202.10459*. [Ver aquí](#)
- Hernández, D. R., Mateus, D., & Orduz-Rodríguez, J. O. (2014). Características climáticas y balance hídrico de la lima ácida Tahití (*Citrus latifolia* Tanaka) en cinco localidades productoras de Colombia. *Revista Colombiana de Ciencias Hortícolas*, 8(2), 217-229. [ver aquí](#)
- IAASTD. (2009). Agriculture at a crossroads: Global report. International Assessment of Agricultural Knowledge, Science and Technology for Development. Food and Agriculture Organization of the United Nations (FAO). [Ver aquí](#)
- Instituto Geográfico Nacional. (2020). Fotogrametría. [Ver aquí](#)
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: a review. *ACM computing surveys (CSUR)*, 31(3), 264-323. [Ver aquí](#)
- Khanal, S., Kc, K., Fulton, J. P., Shearer, S., & Ozkan, E. (2020). Remote sensing in agriculture—accomplishments, limitations, and opportunities. *Remote sensing*, 12(22), 3783. [Ver aquí](#)
- Koc-San, D., Selim, S., Aslan, N., & San, B. T. (2018). Automatic citrus tree extraction from UAV images and digital surface models using circular Hough transform. *Computers and electronics in agriculture*, 150, 289-301. [Ver aquí](#)
- Kumar, A., Desai, S. V., Balasubramanian, V. N., Rajalakshmi, P., Guo, W., Naik, B. B., ... & Desai, U. B. (2021). Efficient maize tassel-detection method using UAV based remote sensing. *Remote Sensing Applications: Society and Environment*, 23, 100549. [Ver aquí](#)
- Marote, M. (2010). Agricultura de precisión. *Ciencia y Tecnología*, 10, 143–167. [Ver aquí](#)
- McClain, B. P. (2022). *Python for Geospatial Data Analysis*. " O'Reilly Media, Inc."

- Minagricultura. (2017). Principales Cultivos por Área Sembrada en 2017. Valle del Cauca. [Ver aquí](#)
- Minagricultura. (2020). Cadena del cítricos, Indicadores e instrumentos. [Ver aquí](#)
- Mitsikostas, E. (2017). Monitorización y optimización de tierras con drones y fotogrametría aérea para aplicaciones de precisión en agricultura [Universidad Politécnica de Valencia]. [Ver aquí](#)
- Municipio de Dagua. (2009). Plan Básico de Ordenamiento Territorial (PBOT). Alcaldía Municipal de Dagua.
- Oliveira, R.; Nasi, R.; Niemelainen, O.; Nyholm, L.; Alhonoja, K.; Kaivosoja, J.; Jauhiainen, L.; Viljanen, N.; Nezami, S.; Markelin, L.; Hakala, T. (2020). Machine learning estimators for the quantity and quality of grass swards used for silage production using drone-based imaging spectrometry and photogrammetry. Remote Sensing of Enviroment, 246. [Ver aquí](#)
- Ordóñez-Prado, C., Valdez-Lazalde, J. R., Flores-Magdaleno, H., Ángeles-Pérez, G., Santos-Posadas, H. M., & Buendía-Rodríguez, E. (2024). Operational implications of spatial resolution of drone imagery in vegetation mapping for forestmanagement. Revista Chapingo serie ciencias forestales y del ambiente, 30(2). [Ver aquí](#)
- Ortega, V. (2018). Procedimiento para la captura de datos fotogramétricos con la ayuda de aparatos controlados remotamente, como herramienta para la evaluación en estabilidad de taludes y difusión con realidad aumentada [Universidad Nacional de Colombia]. [Ver aquí](#)
- Oscó, L. P., de Arruda, M. D. S., Gonçalves, D. N., Dias, A., Batistoti, J., de Souza, M., ... & Gonçalves, W. N. (2021). A CNN approach to simultaneously count plants and detect plantation-rows from UAV imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 174, 1-17. [Ver aquí](#)
- Over, J. S. R., Ritchie, A. C., Kranenburg, C. J., Brown, J. A., Buscombe, D. D., Noble, T., ... & Wernette, P. A. (2021). Processing coastal imagery with Agisoft Metashape Professional Edition, version 1.6—Structure from motion workflow documentation (No. 2021-1039). US Geological Survey. [Ver aquí](#)
- Pal, M. (2005). Random forest classifier for remote sensing classification. International journal of remote sensing, 26(1), 217-222. [Ver aquí](#)

- Palacio, J.; Pedraza, C. (2012). Inventario e identificación del componente arbóreo de la sede del Poblado del Politécnico Jaime Isaza Cadavid. *Revista Politécnica*, 14, 85–95. [Ver aquí](#)
- Pederi, Y.; Cheporniuk, H. (2015). Unmanned aerial vehicles and new technological methods of monitoring and crop protection in precision agriculture. 2015 IEEE International Conference Actual Problems of Unmanned Aerial Vehicles Developments (APUAVD). [Ver aquí](#)
- QGIS. (2023). Documentación QGIS. Software QGIS. [Ver aquí](#)
- Recio, J.; Hermosilla, T.; Ruiz, L; Palomar, J. (2013). Automated extraction of tree and plot-based parameters in citrus orchards from aerial images. *Computers and Electronics in Agriculture*, 90, 23–34. [Ver aquí](#)
- Riaño Rodríguez, E. R. (2018). Metodología para el diseño de un vuelo fotogramétrico usando UAV´ S. [Ver aquí](#)
- Rímolo Donadio, R., Arriola Valverde, S., Umaña Soto, J., López-Sampson, A., Sepúlveda, N., Villalobos Avellán, L. C., ... & Monge Mora, J. C. (2021). Fotogrametría digital con sistemas aéreos no tripulados para el análisis de sistemas agroforestales. Tutorial. Programa de Investigación sobre Bosques, Árboles y Agroforestería (CGIAR) [Ver aquí](#)
- Schubert, E., Sander, J., Ester, M., Kriegel, H. P., & Xu, X. (2017). DBSCAN revisited, revisited: why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems (TODS)*, 42(3), 1-21. [Ver aquí](#)
- SECOP I. (2018). Detalle del Proceso Número: MD-CMC-113-2018. [Ver aquí](#)
- Solórzano, J. L., Neira Cuadra, O. A., Altamirano Guerrero, R., Guevara Flores, R. S., García, M. Á., Osejo, N., ... & Bárcenas Castillo, J. A. (2016). Perspectivas sobre la seguridad alimentaria en Nicaragua en el contexto del cambio climático. Reflexiones y propuestas. UCA Publicaciones. [Ver aquí](#)
- UEIA, U. (2014). Catálogo virtual de flora del Valle de Aburrá. [Ver aquí](#)
- Vásquez, A.; Restrepo, C. (2019). Sistema de gestión de la información del inventario arbóreo del Tecnológico de Antioquia [Tecnológico de Antioquia Institución Universitaria]. [Ver aquí](#)
- Verdiguier, E. I. (2011). Detección y clasificación automática de plantaciones de árboles de cultivo en imágenes de alta resolución espacial. [Ver aquí](#)

- Wardana, T. K., Arkeman, Y., Priandana, K., Kurniawan, F., Prabowo, G. S., & Hasim, F. (2024). Implementation of DBSCAN and K-Means Algorithm for Clustering Agricultural Drone Flying Areas. En The 18th IMT-GT International Conference on Mathematics, Statistics and their Applications (pp. 117–122). [Ver aquí](#)
- Zhang, J., Huang, Y., Pu, R., Gonzalez-Moreno, P., Yuan, L., Wu, K., & Huang, W. (2019). Monitoring plant diseases and pests through remote sensing technology: A review. Computers and Electronics in Agriculture, 165, 104943. [Ver aquí](#)

14. ANEXOS

14.1. ANEXO A

Demostración de ejecución y funcionamiento del algoritmo

En el siguiente enlace, se puede visualizar un video que muestra cómo se ejecuta el código desarrollado para este proyecto, así como su funcionamiento, interacción usuario-interfaz y resultados:

Amador, M., & Guerrero, C. (2025, 17 de febrero). *Algoritmo para cuantificación semiautomática de árboles en cultivos* [Video]. YouTube. [Ver aquí](#)

Este recurso audiovisual complementa la información presentada en el documento y ofrece una guía para la implementación del código en entornos similares. El código fuente no se publica en repositorios abiertos debido a que forma parte de la propiedad intelectual de los autores, resguardándose así su uso y derechos asociados.