

**ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL**

**Facultad de Ingeniería en Electricidad y Computación**

Distribución poblacional de plantaciones de Banano mediante  
visión por Computadora e Imágenes Aéreas por dron.

**PROYECTO DE TITULACIÓN**

Previo la obtención del Título de:

**Magister en Ciencias de Datos**

**Presentado por:**

Freddy Arturo Paladines Larco

**GUAYAQUIL - ECUADOR**

**Año: 2024**

## DEDICATORIA

A mis padres.

## **AGRADECIMIENTOS**

Agradezco principalmente a mis padres por el apoyo incondicional que he recibido durante toda mi vida.

A mi jefe Oscar Ponce Parra para llevar con éxito este proyecto, dándome total apertura y apoyo en el trabajo.

A todos aquellos que brindaron su apoyo de manera indirecta, amigos y familiares, se les agradece enormemente.

## DECLARACIÓN EXPRESA

Yo Freddy Arturo Paladines Larco acuerdo y reconozco que: La titularidad de los derechos patrimoniales de autor Freddy Arturo Paladines Larco del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores. El o los estudiantes deberán procurar en cualquier caso de cesión de sus derechos patrimoniales incluir una cláusula en la cesión que proteja la vigencia de la licencia aquí concedida a la ESPOL.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, secreto empresarial, derechos patrimoniales de autor sobre software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí/nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al autor que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 12 de diciembre del 2024.

---

Freddy Paladines Larco

## Evaluadores

---

**Ph.D. Miguel Realpe**  
Profesor Tutor

---

**Ph.D. Eduardo Cruz**  
Profesor Evaluador

## RESUMEN

La industria bananera en Ecuador ha enfrentado diversas amenazas en los últimos años, siendo el Moko una de las más devastadoras para los agricultores. Para mantener su competitividad en el mercado global y garantizar la estabilidad económica de miles de familias, es crucial optimizar la gestión de las plantaciones de banano mediante el uso de tecnologías avanzadas. En este contexto, la agricultura de precisión y los drones multiespectrales ofrecen nuevas oportunidades para mejorar el monitoreo y la cuantificación de las plantaciones, ayudando a prevenir la propagación de enfermedades.

Este proyecto propone desarrollar un sistema automatizado basado en visión por computadora y análisis multiespectral, utilizando el Índice de Vegetación de Diferencia Normalizada (NDVI) para aumentar la precisión en el conteo de plantas de banano y evaluar el estado de salud de los cultivos. El sistema se implementa en tres fases: recolección de imágenes aéreas, entrenamiento de un modelo de visión por computadora y análisis de los datos obtenidos, todo ello integrado en una plataforma web para su visualización y consulta.

La solución propuesta proporcionará a los productores bananeros en Ecuador una herramienta avanzada para el monitoreo y manejo eficiente de grandes extensiones de cultivo, contribuyendo al desarrollo sostenible del sector. Además, la implementación de este sistema reducirá los costos operativos asociados con los métodos tradicionales, como el conteo manual de plantas. Esto permitirá a los agricultores tomar decisiones basadas en datos precisos y en tiempo real, mejorando la sostenibilidad de sus operaciones y fortaleciendo la competitividad del banano ecuatoriano en los mercados internacionales.

**Palabras clave:** Agricultura de precisión, visión por computadora, drones multiespectrales, plantaciones de banano, monitoreo automatizado, NDVI.

## **ABSTRACT**

*In recent years, Ecuador's banana industry has been affected by various diseases, with Moko being one of the most devastating for farmers. To remain competitive in the global market and ensure the economic stability of thousands of families, it is essential to enhance the management of banana plantations through advanced technologies. In this context, precision agriculture and the use of multispectral drones offer new possibilities to optimize the quantification and monitoring of these plantations, helping to prevent the spread of such diseases.*

*This project proposes the development of an automated system using computer vision and multispectral analysis, employing the Normalized Difference Vegetation Index (NDVI) to improve the accuracy of banana plant population counts and assess the health of the crops. The system consists of three phases: aerial image collection, training of a computer vision model, and analysis of the collected data, all integrated into a web platform for visualization and consultation.*

*The proposed solution will provide banana producers in Ecuador with an advanced tool for efficient monitoring and management of large crop areas, contributing to the sustainable development of the sector. Furthermore, the implementation of this project will reduce operational costs associated with traditional monitoring methods, such as manual plant counting. This will allow farmers to make data-driven, real-time decisions, improving the sustainability of their operations and strengthening the competitiveness of Ecuadorian bananas in international markets.*

**Keywords:** Precision agriculture, computer vision, multispectral drones, banana plantations, automated monitoring, NDVI.

# Contents

CAPITULO 1.....	13
1. INTRODUCCIÓN .....	13
1.1. Descripción del Problema. ....	13
1.2 Justificación del problema. ....	14
1.3 Solución Propuesta. ....	15
1.4. Objetivos. ....	16
1.5 Metodología.....	17
1.6. Resultados Esperados .....	18
1.7 Dataset .....	19
CAPITULO 2.....	21
2. ESTADO DE ARTE.....	21
2.1 Deep Learning en la agricultura. ....	21
2.2 Definiciones .....	23
2.3 Soluciones iniciales .....	28
2.4 Elección del modelo basado en el problema .....	31
CAPITULO 3.....	33
3. DISEÑO E IMPLEMENTACIÓN .....	33
3.1 Desarrollo del Pipeline del Entrenamiento del Modelo .....	33
3.2 Desarrollo del Pipeline de la implementación .....	35
3.3 Infraestructura necesaria.....	38
3.4 Restricciones / Limitaciones.....	39
3.5 Resultado del entrenamiento del modelo.....	40
3.6 Enviar el modelo entrenado al Backend .....	46
3.7 Procesamiento del Front-End.....	47



CAPÍTULO 4.....	49
4. ANÁLISIS DE RESULTADOS .....	49
4.1 Tiempos de ejecución y desempeño.....	50
4.2 Validación de resultados .....	51
4.3 Análisis de resultados .....	51
4.4 Evaluación de la solución propuesta.....	52
5. CONCLUSIONES Y RECOMENDACIONES .....	56
5.1 Conclusiones.....	56
5.2 Recomendaciones .....	57
5.3 Discusión.....	57
6. Referencia Bibliográficas.....	58

## ABREVIATURAS

NDVI	Índice de Vegetación de Diferencia Normalizada.
GNDVI	Índice Verde de Vegetación de Diferencia Normalizada.
ML	Machine Learning.
OSAVI	Índice de Vegetación Resistente a la Sombra.
LCI	Índice de Carbono en la Hoja.
NDRE	Índice de Diferencia Normalizada del Borde Rojo.
Geotiff	Archivo de imagen que incluye información geoespacial
CNN	red neuronal convolucional
JSON	Notación de Objetos de JavaScript
API	Interfaz de Programación de Aplicaciones
GPUs	Unidades de Procesamiento Gráfico
RAM	Memoria de Acceso Aleatorio
Mbps	Megabits por segundo
RGB	Rojo, Verde, Azul

## INDICE DE FIGURA

Figura 1 red neuronal artificial profunda.....	25
Figura 2 red neuronal convolucional .....	26
Figura 3 Pipeline del proceso de entrenamiento y publicación del modelo .....	35
Figura 4. Diagrama tecnico del funcionamiento del modelo .....	38
Figura 5. Flujo de la infraestructura web .....	39
Figura 6. Grafica del tamaño y cantidad de plantas para el modelo.....	41
Figura 7. Matriz de confusión .....	42
Figura 8 Rendimiento del train vs validation.....	<b>Error! Bookmark not defined.</b>
Figura 9. Rendimiento de aprendizaje (Total) .....	44
Figura 10. Curva de confianza - precisión.....	45
Figura 11. Curva de confianza -recuperación .....	46
Figura 12. Página principal web, orto mosaico RGB de la finca georreferenciado. ....	48
Figura 13. Página web mostrando los objetos captados por visión por computadora y clasificándolos por %NDVI .....	49
Figura 14. Página web mostrando los objetos captados por visión por computadora en fondo NDVI .....	49

## INDICE DE TABLAS

Tabla 1. Dataset del proyecto.....	20
Tabla 2. Tiempos de ejecución.....	50
Tabla 3. Resultados del modelo de visión por computadora .....	51
Tabla 4. Costo mensual de la nube.....	52
Tabla 5. Costo On-premise .....	53

# CAPITULO 1

## 1. INTRODUCCIÓN

### 1.1. Descripción del Problema.

La industria del banano es primordial en la economía nacional del Ecuador, país que se destaca como uno de los mayores exportadores de banano a nivel mundial. El banano es uno de los principales productos ecuatorianos de exportación, contribuyendo significativamente al Producto Interno Bruto y al empleo en regiones agrícolas. La sostenibilidad y eficiencia de esta industria son cruciales para mantener la competitividad en un mercado globalizado y para asegurar la estabilidad económica de miles de familias que dependen de este cultivo. Por ello, mejorar las técnicas de gestión y producción a través de tecnologías avanzadas es esencial para fortalecer este sector clave en Ecuador.

La agricultura de precisión ha revolucionado el manejo y la monitorización de grandes cultivos, permitiendo una gestión más eficiente y sostenible. En el contexto de las plantaciones de banano, uno de los principales desafíos es la cuantificación y evaluación precisa del área cultivada, vital para la planificación y ejecución de estrategias agronómicas.

Tradicionalmente, la estimación de la extensión de estos cultivos se ha realizado mediante métodos que pueden ser imprecisos o costosos en tiempo y recursos. Con la introducción de tecnologías avanzadas como los drones multiespectrales, se abre la posibilidad de superar dichos desafíos. Estos drones pueden capturar imágenes aéreas de alta resolución (2 pixel/cm) y analizar diversas bandas del espectro electromagnético, lo que potencialmente permite una identificación más precisa y detallada de las plantaciones de banano. La tecnología implica enfrentar desafíos técnicos y metodológicos, como la correcta interpretación de los índices de vegetación OSAVI (Índice de Vegetación Resistente a la Sombra), NDVI (Índice de Vegetación de Diferencia Normalizada.), LCI (Índice de Carbono en la Hoja), GNDVI (Índice Verde de Vegetación de Diferencia Normalizada), NDRE (Índice de Diferencia Normalizada

del Borde Rojo) y la integración de estos datos en modelos que puedan estimar confiablemente el área y la salud del cultivo. Es fundamental desarrollar métodos optimizados que mejoren la identificación y cuantificación de las plantaciones de banano con esta tecnología avanzada, asegurando que los agricultores obtengan una evaluación exacta y útil de sus cultivos para una mejor toma de decisiones.

## **1.2 Justificación del problema.**

El avance en técnicas de visión por computadora y la creciente disponibilidad de imágenes aéreas de alta resolución han abierto nuevas posibilidades para la agricultura de precisión, especialmente en la gestión de cultivos a gran escala como las plantaciones de banano. En Ecuador, la implementación de estas tecnologías puede conducir a mejoras significativas en la eficiencia y sostenibilidad de los procesos agrícolas. Tradicionalmente, el conteo y la evaluación de la salud de las plantas de banano se han realizado manualmente o mediante métodos que no proporcionan la precisión requerida para una gestión óptima, como por ejemplo el conteo manual (con papel y lápiz) de plátano por hectárea o sector, en el que un grupo de personas van anotando uno por uno las plantaciones y el estado de la misma, otro método común es tomar una pequeña muestra de un sector en específico que de una hectárea y luego multiplicarlo por el total de las hectáreas que tiene la hacienda. Este proyecto de tesis propone visión por computadora y Deep Learning para procesar imágenes obtenidas por drones multiespectrales, para automatizar y mejorar la precisión del conteo de población de plantas de banano.

El uso de drones multiespectrales permite capturar datos detallados del estado de las plantas a través de diferentes bandas del espectro, que pueden analizarse con técnicas avanzadas de visión por computadora. Estos métodos aumentan la precisión del conteo poblacional y permiten la detección temprana de enfermedades o deficiencias en las plantas, cruciales para tomar medidas correctivas a tiempo y mejorar el rendimiento de las cosechas. Además, la automatización de este proceso reduce la necesidad de intervención humana directa en las plantaciones, minimizando el riesgo de daño a las plantas y aumentando la seguridad laboral.

### **1.3 Solución Propuesta.**

La solución propuesta consta de tres fases detalladas a continuación:

En la primera fase de este proyecto se recogerán imágenes aéreas de plantaciones de banano ubicadas en fincas de Ecuador. Esta recolección se realizará usando drones con cámaras de alta resolución, capaces de capturar imágenes detalladas de grandes extensiones de terreno. Obtenidas las imágenes, se procederá a la etapa de etiquetado, donde se identificarán y marcarán manualmente las plantas de banano presentes en cada fotografía. Este proceso incluirá la consideración de diversas características como el tamaño y la agrupación de las plantas, lo que permitirá crear un conjunto de datos robusto y representativo. El objetivo de esta fase es generar un dataset extenso y de alta calidad, compuesto por aproximadamente 1000 imágenes etiquetadas, que servirá como base para el entrenamiento del modelo de visión por computadora en las fases posteriores.

La segunda fase se centra en el entrenamiento de un modelo de visión por computadora y Deep Learning, diseñado para detectar y analizar las plantas de banano en las imágenes aéreas recolectadas. Inicialmente, las imágenes geotiff de gran tamaño se dividirán en sub-imágenes más pequeñas para facilitar su manejo y procesamiento. Durante esta etapa, se implementarán métodos de superposición en los bordes de las sub-imágenes para asegurar que no se pierda información crucial durante la segmentación. Después, el modelo se entrenará con datos etiquetados previamente, ajustando parámetros para optimizar la precisión y la eficiencia de las predicciones. Este proceso de ajuste y refinamiento del modelo es crucial para garantizar que pueda identificar correctamente las plantas de banano en distintos contextos y densidades poblacionales.

La tercera y última fase del proyecto implica el análisis detallado del estado de cada planta de banano y la publicación de los resultados obtenidos. Para llevar a cabo el análisis, se utilizarán drones multiespectrales que proporcionarán datos adicionales sobre el estado de salud de las plantas, mediante el cálculo del NDVI (Índice de Vegetación de Diferencia Normalizada). Este índice permitirá evaluar la vitalidad y el vigor de cada planta, proporcionando una visión detallada de su estado general y de salud individual. Además, se realizará un conteo exhaustivo de la población de plantas

y se analizará su distribución y agrupación en las diferentes áreas monitoreadas. Finalmente, se desarrollará una plataforma web especializada para desplegar los resultados del análisis, en donde se presentarán de manera accesible y comprensible, permitiendo a los usuarios visualizar el conteo y el estado de las plantas en áreas específicas de interés. Esta plataforma web servirá como una herramienta valiosa para agricultores, investigadores y otros interesados en la monitorización y gestión de plantaciones de banano.

Con esta solución se plantea dar al productor una herramienta que le permita monitorear los cultivos de banano de grandes extensiones con su computadora o celular inteligente.

#### **1.4. Objetivos.**

##### **1.4.1 Objetivo general**

- Desarrollar un sistema automatizado basado en visión por computadora que permita el conteo, monitoreo y visualización de la distribución poblacional de plantaciones de banano para facilitar la gestión de cultivos.

##### **1.4.2 Objetivos específicos**

- Desarrollar algoritmos de Procesamiento de Imágenes que permitan el conteo automático de plantas de banano a partir de los datos capturados por los drones.
- Validar la precisión del algoritmo de conteo automatizado comparando los resultados obtenidos con contabilización manual en varias hectáreas de cultivo.
- Desarrollar un dashboard interactivo e intuitivo que permita a los usuarios la visualización de mapas y datos de conteo de población, estado de salud y distribución de las plantas en tiempo real, facilitando la toma de decisiones.
- Evaluar los costos de implementación y operación del sistema basado en drones y visión computacional en comparación con métodos tradicionales de monitoreo y conteo.



## **1.5 Metodología.**

La metodología de este proyecto se enfoca en la recolección y etiquetado de imágenes aéreas, proporcionando un conjunto de datos sólido y representativo para el entrenamiento del modelo. Posterior se enfocará en el entrenamiento de un modelo de visión por computadora, optimizando sus parámetros para asegurar una alta precisión en la detección y análisis de las plantas de banano. Finalmente, se involucrará el análisis del estado de salud de las plantas, utilizando índices de vegetación obtenidos a través de drones multiespectrales, y la publicación de los resultados en una plataforma web accesible. Con esto, las fases que va a seguir el proyecto son las siguientes:

### **Primera fase: Captura y preprocesamiento de datos.**

Se sobrevolarán distintas plantaciones de banano usando drones aéreos equipados con cámaras multiespectrales, obteniendo imágenes con resolución de 2 píxeles/cm. Luego de producir imágenes ortomosaicas de distintas fincas, se aplicarán técnicas de procesamiento de imágenes para mejorar la calidad. Esto incluye corrección de distorsiones, normalización de intensidades entre diferentes bandas espectrales, y eliminación de ruido. Estos procesos involucran temas vistos en la materia de ciencia de datos y Machine Learning. Luego, se procederá a realizar el etiquetado de plantas de banano; en este proyecto se plantean obtener al menos 1000 etiquetas de banano de los ortomosaicos extraídos de las visitas en campo.

### **Segunda fase: Desarrollo de modelos de Machine Learning.**

El siguiente paso es la segmentación basada en DL para identificar y diferenciar plantas de banano dentro de las imágenes. En este caso se plantea el uso de Redes Neuronales Convolucionales (CNN) para clasificar los píxeles de las imágenes en categorías como planta, suelo, o maleza. Luego, se usarán técnicas de detección de objetos o segmentación semántica para contar el número de plantas de banano en las imágenes con las etiquetas e imágenes obtenidas con los datos.

### **Tercera fase: Validación y optimización de modelos.**

En esta fase se utilizan técnicas de validación cruzada para evaluar la precisión y la generalización de los modelos de DL. Esto ayuda a asegurar que los modelos sean robustos y fiables en diferentes condiciones de iluminación, densidades de plantación, y tipos de cultivo. Se prueba con distintas imágenes y se valida el porcentaje del real vs la predicción. Para el presente proyecto se propone que no exceda el 5 % del total por hectárea, ya que esto puede conducir a un producto final sin mucha aportación para el productor.

#### **Cuarta fase: Integración y aplicación de resultados.**

En esta etapa, se desarrolla un dashboard que permite a los usuarios visualizar de manera intuitiva y dinámica la información sobre la distribución poblacional de las plantaciones de banano, así como el estado de salud de cada planta individual. Este dashboard incluirá diversas métricas y visualizaciones, como mapas de calor de densidad poblacional, gráficos de estado de salud basados en el NDVI, y estadísticas detalladas de cada área monitoreada.

Para la implementación del portal web se plantea usar Flutter como frontend y para el almacenamiento de datos no estructurado Firebase, lo que asegura una experiencia al usuario de manera fluida y accesible. El portal no solo presenta los resultados del análisis de manera comprensible, sino que también permite a los usuarios interactuar con los datos, realizando consultas específicas y descargando informes personalizados. La integración de estos resultados en una plataforma web accesible pretende proporcionar una herramienta valiosa para agricultores, investigadores y otros interesados en gestionar y monitorizar las plantaciones de banano. Esta fase final asegura que los datos recolectados y analizados se utilicen de manera efectiva, promoviendo una toma de decisiones informada y una gestión más eficiente de los recursos agrícolas.

### **1.6. Resultados Esperados**

La finalidad principal de este proyecto es ofrecer una herramienta de monitoreo avanzado para los productores de banano en Ecuador, una de las industrias agrícolas más importantes del país. Se busca dar una solución integral que permita a los

agricultores monitorear la salud y la distribución de sus plantaciones de manera eficiente. Esta herramienta no solo facilitará la detección temprana de problemas, como enfermedades o plagas, sino que también permitirá una gestión más efectiva de los recursos agrícolas, optimizando las prácticas de cultivo y mejorando la productividad general.

Este proyecto se basa en los conocimientos adquiridos durante la maestría en ciencia de datos, aplicando técnicas avanzadas de procesamiento y análisis de imágenes, así como metodologías de aprendizaje automático. Al integrar estas tecnologías en una plataforma accesible, se espera contribuir significativamente al desarrollo y sostenibilidad del sector bananero en Ecuador. La implementación de esta herramienta permitirá a los productores tomar decisiones informadas basadas en datos concretos, mejorando la rentabilidad y promoviendo prácticas agrícolas más sostenibles y eficientes.

### 1.7 Dataset

El dataset de este proyecto se basa principalmente en la extracción de datos no estructurados de gran tamaño, ya que se usa muchos tipos de datos Geotiff y JPG. La fuente de datos a usarse en este proyecto se describe a continuación:

<b>Fuente de Datos</b>	<b>Variabes</b>	<b>Descripción Campos</b>	<b>Tipo de Datos</b>
Imágenes obtenidas con dron Mavic 3 ME.	Fotos aéreas de distintas fincas.	Archivos no estructurados de imágenes obtenidas (2 cm/pixel). Con el dron que siguen un trayecto hasta completar el ortomosaico de la finca o de un área en concreto para el estudio, estas incluyen las imágenes multiespectrales con sus cuatro bandas (verde, rojo, borde rojo e Infrarrojo).	GeoTiff, tiff, jpg.
Etiquetado manual de imágenes aéreas.	Etiquetas de Plantas de Banano	Anotaciones manuales de las ubicaciones y características de las plantas de banano en las imágenes aéreas.	JSON, XML, CSV.
Datos de dron y de visitas técnicas a fincas.	Datos Geoespaciales	Información geográfica de fincas, incluyendo límites de parcelas y características topográficas.	txt, GeoJSON

Datos obtenidos en visitas de campo	Producción y Gestión Agrícola	Información sobre las prácticas de cultivo y producción en las fincas de banano.	CSV, Excel.
-------------------------------------	-------------------------------	--	-------------

*Tabla 1 Dataset del proyecto*

# CAPITULO 2

## 2. ESTADO DE ARTE

En el floreciente campo de la agricultura de precisión, el uso de tecnologías de vanguardia como el Deep Learning y la Visión Computacional ha abierto un abanico de posibilidades para optimizar la producción y gestión de cultivos. En este capítulo se explorará el potencial de estas tecnologías en la detección y análisis de cultivos de banano, con un enfoque en el uso de drones multiespectrales y algoritmos de aprendizaje profundo. Se analizará cómo estas herramientas convergen para abordar desafíos clave en la agricultura, como la identificación temprana de enfermedades, la estimación precisa de la producción y la evaluación del estado de salud de las plantaciones.

### 2.1 Deep Learning en la agricultura.

El aumento de la población mundial ha magnificado los desafíos a la seguridad alimentaria. Estudios prospectivos han indicado que será necesario aumentar la producción agrícola en aproximadamente un 70% para alimentar a los habitantes del planeta en 2050 (Popp, 2013). Las Naciones Unidas informan que en los últimos años la seguridad alimentaria ha enfrentado desafíos debido a muchos factores, como cambio climático y recesiones económicas, entre otros (Wilbur N. Chiuyari Veramendi \*, 2024). Tradicionalmente, los agricultores dependen de especialistas agrícolas humanos para identificar y diagnosticar plagas y enfermedades. Los países en desarrollo carecen de expertos humanos en la industria agrícola. Para superar los desafíos en la agricultura, el conocimiento empírico de los agricultores es menos efectivo (Nagayets, 2005). Por tanto, la identificación temprana de plagas y enfermedades es crucial en las cadenas de suministro agrícola y alimentario para prevenir interrupciones y garantizar un flujo estable de productos.

En el cultivo de banano, el monitoreo constante y personalizado ayuda a detectar problemas en etapas iniciales, mejorando la calidad y minimizando pérdidas. Por lo consiguiente, es necesario desarrollar sistemas automatizados de diagnóstico para apoyar a los agricultores (M. Nandhini a, 2022).

Tradicionalmente, los agricultores dependen de especialistas agrícolas humanos para identificar y diagnosticar plagas y enfermedades. Los países en desarrollo carecen de expertos humanos en la industria agrícola. Para superar estos desafíos, el conocimiento empírico de los agricultores es menos efectivo (Nagayets, 2005). Por tanto, la identificación temprana de plagas y enfermedades es crucial en las cadenas de suministro agrícola y alimentario para prevenir interrupciones y garantizar un flujo estable de productos. En el cultivo de banano, el monitoreo constante y personalizado ayuda a detectar problemas en etapas iniciales, mejorando la calidad y minimizando pérdidas. Por lo consiguiente, es necesario desarrollar sistemas automatizados de diagnóstico para apoyar a los agricultores (M. Nandhini a, 2022).

La agricultura moderna, en su búsqueda constante por optimizar la producción y garantizar la salud de los cultivos, ha adoptado tecnologías de vanguardia como la visión por computadora (CV) y el análisis de índices de vegetación. Aunque se han utilizado sistemas de imágenes terrestres para evaluar el recuento de rodales de cultivos, como se evidencia en los estudios de Jin et al. (2017) y Liu et al. (2017), estas metodologías presentan limitaciones en la producción a gran escala, como la lentitud y la susceptibilidad a las condiciones del suelo (Aijing Fenga, 2020).

La visión por computadora, ampliamente utilizada en la automatización agrícola (Jhonn Pablo Rodríguez a, 2020), ofrece una alternativa prometedora. Esta tecnología permite el monitoreo del crecimiento saludable de los cultivos, la detección temprana de enfermedades y plagas, así como la clasificación y gestión automatizada de las granjas. En este contexto, el índice de vegetación de diferencia normalizada (NDVI) se convierte en una herramienta crucial.

El Índice de Vegetación de Diferencia Normalizada (NDVI) es una medida que utiliza la teledetección para evaluar la salud y el vigor de la vegetación. Este índice se calcula a partir de la diferencia entre la reflectancia de la luz roja e infrarroja cercana, ya que las plantas absorben la luz roja para la fotosíntesis y reflejan la infrarroja cercana. Un valor de NDVI más alto indica una mayor cantidad de vegetación verde y saludable, mientras que un valor más bajo sugiere una menor cantidad o vegetación estresada. El NDVI es ampliamente utilizado en agricultura, gestión forestal y estudios ambientales para monitorear la vegetación, identificar áreas de sequía o estrés hídrico y evaluar la productividad de los cultivos.

La combinación de la visión por computadora con el análisis del NDVI a través de drones multiespectrales ofrece una solución escalable y eficiente para el monitoreo de cultivos a gran escala, superando las limitaciones de los sistemas terrestres y permitiendo una gestión más precisa y sostenible de los recursos agrícolas (Bhandaria, 2012).

## **2.2 Definiciones**

### **2.2.1 Visión por computadora y su importancia en la agricultura.**

La visión por computadora (VC) es un campo multidisciplinario que se enfoca en capacitar a las computadoras para interpretar y comprender el mundo visual de manera similar a como lo hacen los humanos. Esto implica el desarrollo de algoritmos y modelos que permiten a las máquinas analizar imágenes y videos, identificar objetos, reconocer patrones, clasificar escenas y extraer información relevante.

La VC se ha convertido en una aliada indispensable de la agricultura de precisión, revolucionando cómo se supervisan y administran los cultivos. Gracias a la VC, es posible extraer información crucial de imágenes y videos de forma automatizada, lo que facilita tareas como la detección y clasificación de plantas, el seguimiento de su crecimiento y la identificación de enfermedades (Kamilaris & Prenafeta-Boldú, 2018). Mediante el análisis de imágenes de alta resolución, los algoritmos de VC pueden detectar patrones sutiles que revelan la presencia de enfermedades o plagas, incluso antes de que sean perceptibles a simple vista (Mohanty, Hughes & Salathé, 2016).

Además de la detección de enfermedades, la VC también se utiliza para estimar el rendimiento de los cultivos, evaluar la calidad de los productos y optimizar la gestión de recursos como el agua y los fertilizantes (Mulla, 2013). La integración de la VC con drones y robots agrícolas ha permitido la automatización de tareas como la pulverización de pesticidas y la cosecha selectiva, mejorando la eficiencia y reduciendo los costos de producción (Zhang & Kovacs, 2012).

### 2.2.2 Deep Learning

El Deep Learning (DL), un subcampo del aprendizaje automático ha revolucionado la inteligencia artificial al utilizar redes neuronales artificiales (RNA) profundas para aprender representaciones jerárquicas de los datos (LeCun, Bengio & Hinton, 2015). Estas RNA pueden procesar grandes cantidades de datos no estructurados, como imágenes, texto y sonido, para realizar tareas complejas como reconocimiento de objetos, traducción automática y generación de texto (Goodfellow, Bengio & Courville, 2016).

El éxito del DL se debe en gran medida a los avances en algoritmos de aprendizaje y optimización, así como a la disponibilidad de grandes cantidades de datos y poder computacional. Los algoritmos de retropropagación y descenso de gradiente estocástico permiten a las RNA ajustar sus parámetros de manera eficiente para minimizar el error en sus predicciones (Ruder, 2016). Además, el uso de unidades de procesamiento gráfico (GPU) ha acelerado significativamente el entrenamiento de modelos de DL, lo que ha permitido el desarrollo de arquitecturas más complejas y profundas (Schmidhuber, 2015).

El DL ha tenido un impacto significativo en diversas áreas, como la medicina, donde se utiliza para el diagnóstico de enfermedades a partir de imágenes médicas (Litjens et al., 2017), la robótica, donde permite a los robots aprender a realizar tareas complejas de manera autónoma (Levine et al., 2016), y las finanzas, donde se aplica para la detección de fraudes y la predicción de mercados (Sirignano, Sadhwani & Giesecke, 2016). A pesar de los desafíos pendientes, como la interpretabilidad de los modelos y la necesidad de datos etiquetados, el DL sigue siendo un área de investigación activa y prometedora con el potencial de transformar aún más nuestra sociedad y economía.






Figura 1 red neuronal artificial profunda

La Figura 1 muestra una representación visual de una red neuronal artificial profunda, el componente central del DL. Cada círculo representa un nodo o neurona artificial, y las líneas representan las conexiones entre ellos.

- **Capa de entrada:** Los nodos de esta capa reciben los datos de entrada sin procesar, como píxeles de una imagen.
- **Capas ocultas:** Estas capas intermedias procesan la información de manera jerárquica, extrayendo características cada vez más abstractas. Por ejemplo, en una red entrenada para reconocer imágenes de gatos, las primeras capas ocultas podrían detectar bordes y formas simples, mientras que las capas posteriores podrían identificar rasgos más complejos como orejas y bigotes.
- **Capa de salida:** Los nodos de esta capa producen la predicción final del modelo, como la probabilidad de que la imagen de entrada sea un gato.

### 2.2.3 Redes neuronales convolucionales.

Las Redes Neuronales Convolucionales (CNN o ConvNet) son un tipo de red neuronal artificial diseñadas específicamente para procesar datos con una estructura de cuadrícula, como las imágenes. Son especialmente efectivas para tareas de visión artificial, como el reconocimiento de objetos, la clasificación de imágenes y la detección de características.

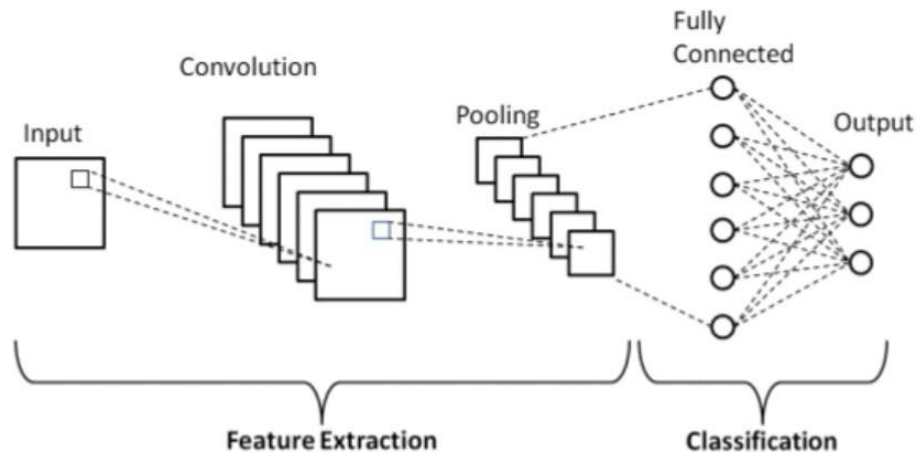


Figura 2 red neuronal convolucional

La Figura 2 muestra la arquitectura de una red neuronal convolucional (CNN). Las CNN están diseñadas para procesar datos con una estructura de cuadrícula, como imágenes. El proceso comienza con la capa de entrada, que recibe la imagen en forma de una matriz de píxeles. Luego, la imagen pasa a través de múltiples capas convolucionales, donde se aplican filtros para extraer características relevantes. Estos filtros aprenden a detectar patrones específicos en la imagen, como bordes, esquinas y texturas. Después de las capas convolucionales, la imagen se reduce en tamaño mediante una operación de agrupación (pooling). Esto ayuda a reducir la dimensionalidad de los datos y a hacer que el modelo sea más robusto a pequeñas variaciones en la posición de los objetos. Finalmente, la imagen procesada se pasa a una o más capas completamente conectadas, que realizan la clasificación final. Estas capas combinan la información de las características extraídas para determinar la categoría a la que pertenece la imagen.

Las CNN han demostrado ser muy efectivas en una amplia gama de tareas de visión por computadora, como el reconocimiento de objetos, la detección de objetos y la clasificación de escenas. Su capacidad para aprender automáticamente características relevantes de los datos las convierte en una herramienta poderosa para analizar y comprender imágenes.

#### 2.2.4 Análisis multiespectral y NDVI:

Los drones multiespectrales son herramientas tecnológicas que permiten capturar imágenes en múltiples bandas del espectro electromagnético, incluyendo bandas visibles e infrarrojas. Esta capacidad es fundamental para la agricultura de precisión, ya que diferentes longitudes de onda revelan información específica sobre la salud y el estado de los cultivos. Las bandas infrarrojas cercanas son útiles para evaluar la actividad fotosintética y el contenido de clorofila en las plantas, detectando problemas como estrés hídrico, deficiencias nutricionales o enfermedades antes de que sean visibles a simple vista.

El NDVI es una de las métricas más utilizadas en el análisis de imágenes multiespectrales. Se calcula a partir de la diferencia entre la reflectancia en las bandas roja e infrarroja cercana, y sus valores varían entre -1 y 1. Un NDVI alto indica una vegetación saludable y vigorosa, mientras que un NDVI bajo sugiere estrés o daño en las plantas.

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

*NIR=Banda infrarojo*

*RED= Banda Roja*

El NDVI es una herramienta valiosa para los agricultores, ya que permite monitorear el estado de los cultivos a lo largo del tiempo, identificar áreas problemáticas y tomar decisiones informadas sobre la gestión de recursos como el riego y la fertilización. Además, el NDVI se puede utilizar para estimar el rendimiento de los cultivos y predecir la producción, lo que ayuda a los agricultores a planificar y optimizar sus operaciones.

## **2.3 Soluciones iniciales**

### **2.3.1 Muestreo y Extrapolación**

El muestreo y extrapolación es una técnica ampliamente utilizada para estimar la población de plantas en un área determinada. Este método implica la selección cuidadosa de áreas representativas dentro del terreno de estudio, conocidas como parcelas de muestreo. En dichas parcelas, se realiza un conteo exhaustivo de las plantas presentes, ya sea de forma manual o mediante herramientas de apoyo. Luego, se extrapola el número de plantas encontradas en las parcelas al área total del terreno.

La principal ventaja de este método radica en su simplicidad y bajo costo, ya que no requiere de tecnología avanzada ni de conocimientos especializados en programación o análisis de datos. Además, es relativamente fácil de implementar en campo, lo que lo convierte en una opción atractiva para estudios preliminares o en áreas con recursos limitados. Sin embargo, hay que considerar que la precisión de este método depende de la correcta selección de las parcelas de muestreo y de la representatividad de estas respecto al área total. Un muestreo inadecuado puede llevar a estimaciones sesgadas y poco fiables de la población de plantas.

### **2.3.2 Modelos de Deep Learning Pre-entrenados.**

Los modelos de Deep Learning pre-entrenados han revolucionado el campo de la inteligencia artificial al ofrecer una forma eficiente y accesible de abordar tareas complejas como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la detección de objetos. Estos modelos, entrenados en grandes conjuntos de datos, han aprendido a reconocer patrones y características relevantes, lo que les permite realizar predicciones precisas sin necesidad de partir desde cero.

Una de las principales ventajas de los modelos pre-entrenados es su capacidad para acelerar el desarrollo de aplicaciones de inteligencia artificial. En lugar de invertir tiempo y recursos en entrenar un modelo desde cero, los desarrolladores pueden aprovechar el conocimiento adquirido por estos modelos en tareas similares, lo que

reduce significativamente el tiempo y el costo de desarrollo. Además, los modelos pre-entrenados suelen ofrecer un rendimiento superior al de los modelos entrenados en conjuntos de datos más pequeños, gracias a su exposición a una mayor diversidad de ejemplos.

Sin embargo, es importante tener en cuenta que los modelos pre-entrenados no son una solución universal. Su rendimiento puede variar dependiendo de la tarea específica y del conjunto de datos utilizado. Además, es fundamental evaluar cuidadosamente la calidad y la procedencia de los datos de entrenamiento utilizados para evitar sesgos y resultados imprecisos. A pesar de estas consideraciones, los modelos de Deep Learning pre-entrenados siguen siendo una herramienta poderosa y versátil para impulsar la innovación en el campo de la inteligencia artificial.

### **VGG (Visual Geometry Group):**

Arquitectura: Red neuronal convolucional profunda con capas de convolución y pooling.

Aplicaciones: Clasificación de imágenes, detección de objetos.

Ventajas: Arquitectura simple y efectiva, buen rendimiento en tareas de clasificación.

Desventajas: Puede ser lento en comparación con otros modelos más recientes.

### **ResNet (Residual Network):**

Arquitectura: Red neuronal convolucional profunda con conexiones residuales (atajos) que permiten el flujo de información a través de las capas.

Aplicaciones: Clasificación de imágenes, detección de objetos, segmentación semántica.

Ventajas: Permite entrenar redes muy profundas sin problemas de degradación, excelente rendimiento en una variedad de tareas.

Desventajas: Puede ser complejo de implementar y entrenar.

### **Inception:**

Arquitectura: Red neuronal convolucional profunda con módulos Inception que utilizan múltiples filtros de diferentes tamaños en paralelo.

Aplicaciones: Clasificación de imágenes, detección de objetos.

Ventajas: Arquitectura eficiente en términos de parámetros, buen rendimiento en tareas de clasificación.

Desventajas: Puede ser difícil de interpretar y ajustar.

### **YOLOv8 (You Only Look Once):**

Arquitectura: YOLO divide la imagen de entrada en una cuadrícula. Cada celda de la cuadrícula es responsable de predecir un conjunto de cajas delimitadoras y sus probabilidades de clase. Las cajas delimitadoras indican la ubicación y el tamaño de los objetos detectados, mientras que las probabilidades de clase indican la probabilidad de que cada caja contenga un objeto de una clase específica.

Aplicaciones: Sistemas de vigilancia, Vehículos autónomos, Robótica y realidad aumentada.

Ventajas: YOLO es mucho más rápido que otros métodos de detección de objetos, lo que lo hace ideal para aplicaciones en tiempo real. Por otra parte, ha demostrado una alta precisión en la detección de objetos, especialmente en objetos pequeños y ocluidos.

Desventajas: YOLO puede tener dificultades para detectar objetos pequeños, especialmente cuando están agrupados.

## 2.4 Elección del modelo basado en el problema

La detección de banano mediante drones no tripulados presenta desafíos únicos debido a la densidad de los cultivos y la falta de datos de entrenamiento específicos. La extrapolación de modelos existentes no es viable debido a la variabilidad en las condiciones de crecimiento y la apariencia visual de los bananos en diferentes regiones. Además, la ausencia de conjuntos de datos aéreos de banano preexistentes impide el uso de modelos pre-entrenados.

Para abordar estos desafíos, se propone utilizar Redes Neuronales Convolucionales (CNN) como base para un modelo de detección personalizado. Su capacidad para aprender características relevantes de los datos de forma automática las hace ideales para este escenario, donde la apariencia de los bananos puede variar significativamente.

El modelo se entrenará utilizando un conjunto de datos de imágenes aéreas de banano recopiladas por la empresa. Estas imágenes capturarán la diversidad de condiciones de crecimiento, etapas de maduración y ángulos de visión, proporcionando al modelo una representación completa de los patrones visuales relevantes para la detección de banano. El entrenamiento se llevará a cabo utilizando técnicas de aprendizaje supervisado, donde se etiquetarán manualmente las imágenes para indicar la ubicación y el tamaño de los racimos de banano. Una vez entrenado, el modelo podrá detectar bananos en nuevas imágenes aéreas con alta precisión, lo que permitirá una evaluación rápida y eficiente de los cultivos.

### 2.4.1 Librerías y software a utilizar

Las librerías y software para utilizar en el proyecto son las siguientes:

- **Etiquetado:** Para el etiquetado de las imágenes de manera manual se propone el uso de la librería Labelme, que es una herramienta de anotación de imágenes de código abierto escrita en Python y que utiliza Qt para su interfaz gráfica. Su propósito principal es facilitar el etiquetado de imágenes para entrenar modelos de visión por computadora, como los utilizados en la

detección de objetos. Con esto se facilita mucho el etiquetado de banano de manera poligonal y con vista satelital

- **Entrenamiento:** Para el entrenamiento del modelo de detección de banano, se utilizará la potente combinación de YOLOv8 y OpenCV. se encargará del aprendizaje profundo y la detección de objetos en las imágenes aéreas. Su arquitectura eficiente y rápida permitirá entrenar un modelo preciso y capaz de identificar racimos de banano en tiempo real. OpenCV, por su parte, desempeñará un papel crucial en el preprocesamiento de las imágenes y la visualización de los resultados. Esta biblioteca de visión por computadora facilitará la carga, transformación y manipulación de las imágenes aéreas, asegurando que estén en el formato adecuado para el entrenamiento de YOLOv8. Además, OpenCV permitirá visualizar las detecciones del modelo en las imágenes, superponiendo cuadros delimitadores y etiquetas sobre los racimos de banano identificados, lo que ayudará a evaluar el rendimiento del modelo y realizar ajustes si es necesario.
- **Despliegue:** Flutter será la herramienta elegida para crear una interfaz web interactiva y atractiva que permita visualizar el proceso de entrenamiento del modelo de detección de banano. Gracias a su capacidad para compilar código nativo para múltiples plataformas, incluyendo la web, Flutter permitirá mostrar gráficos en tiempo real del progreso del entrenamiento, métricas de rendimiento del modelo y ejemplos de imágenes con las detecciones de banano. Además, su flexibilidad y facilidad de uso facilitarán la creación de una interfaz intuitiva y personalizable, adaptada a las necesidades específicas del proyecto.



# CAPITULO 3

## 3. DISEÑO E IMPLEMENTACIÓN

En el capítulo 3 se detalla en el diseño de la arquitectura y modelo que hay por detrás de la distribución poblacional de plantaciones mediante visión por computadora y como este se enrola a una página web.

### 3.1 Desarrollo del Pipeline del Entrenamiento del Modelo

El flujo de trabajo para entrenar el modelo se compone de varias etapas secuenciales, donde cada tarea se basa en los resultados de la etapa anterior. A medida que el proyecto avanza, estas etapas se desarrollan de la siguiente manera:

#### 1. Preparación de Datos

- Obtención de datos de distintas fuentes, en este caso visitas de diferentes haciendas bananeras donde se realizó distintos vuelos en diferentes alturas y condiciones climáticas.
- Aplicación de etiqueta de los objetos que se quiere identificar.
- Entrenamiento de modelo
- Se divide el conjunto de datos etiquetado en tres partes: entrenamiento, validación y prueba.
- Convertir las etiquetas en el formato que necesita el algoritmo de detección de objetos.

#### 2. Entrenamiento del Modelo

- Iniciar el proceso de entrenamiento utilizando el conjunto de datos de entrenamiento y validación.
- Realizar ajustes en los hiperparámetros si es necesario para mejorar el rendimiento.

### **3. Evaluación del Modelo**

- Evaluar el modelo entrenado en el conjunto de datos de prueba para obtener métricas de rendimiento finales.
- Examina los resultados de la evaluación y realiza ajustes adicionales si es necesario.

### **4. Aplicar el modelo entrenado**

- Exporta el modelo entrenado a un formato adecuado para la inferencia.
- Enviar los datos y aplicar la detección de objetos a los datos de la finca del cliente.

### **5. Publicación en la Web**

- Enviar resultados del Backend mediante API para la recepción en la página web Front-end.
- Crear una página web donde se pueda mostrar los resultados obtenidos.
- Aloja la página web en un servidor web para que sea accesible públicamente.

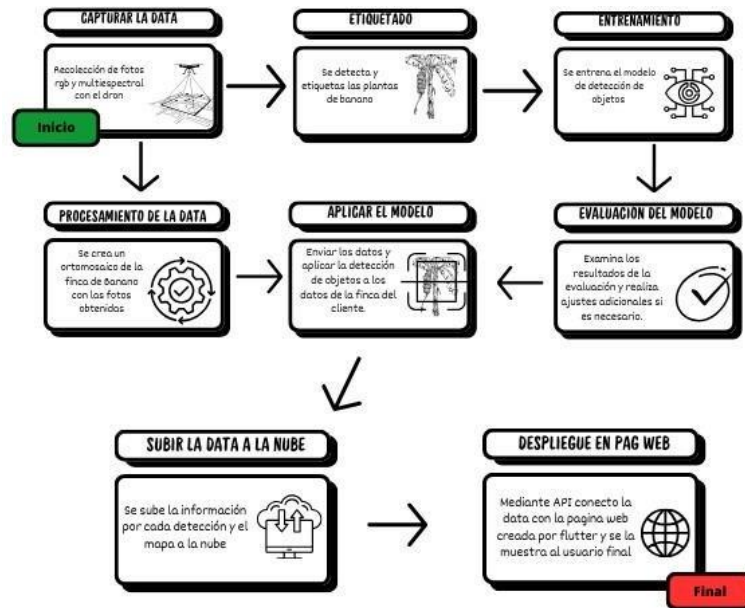


Figura 3 Pipeline del proceso de entrenamiento y publicación del modelo

### 3.2 Desarrollo del Pipeline de la implementación

En el anterior punto se dio una guía de acción para la creación del modelo de visión por computadora, ahora se detallará la implementación del proyecto

#### 1. Preparación de los Datos:

- Se toma fotos a partir de un vehículo aéreo no tripulado, de distintas distancias referente al suelo, estas fotos deben tener mínimo 2 px por cm para la calidad del modelo.
- Seleccionar las fotos que mejor identifica las plantas de banana, las fotos tienen que estar con un ángulo de 90 grados hacia abajo.
- Para el proyecto se usó librería Labelme para dibujar cuadros delimitadores o polígonos alrededor de los objetos en cada imagen y asignarles las etiquetas correspondientes. Esto generará archivos de anotaciones en formato JSON junto con las imágenes.
- Se divide el conjunto de datos en tres partes: entrenamiento con un 80%, validación con un 10 % y prueba con un 10% del total de fotos.

## **2. Configuración del Entorno**

- Para el entrenamiento del modelo usaremos el servicio de la nube de Kaggle ya que en el podemos usar GPUs para el entrenamiento como de su amplia RAM, en este caso se creó una cuenta y se subió la data de entrenamiento en un entorno.
- Descargamos la versión de YOLOv8 y agregamos en la notebook a trabajar.
- Ajustamos los hiperparámetros (tasa de aprendizaje, número de épocas, tamaño del lote, etc.) según sea necesario.

## **3. Entrenamiento del Modelo**

- Ejecución del Entrenamiento utilizando el conjunto de datos de entrenamiento y validación.
- El modelo se entrenará durante el número de épocas especificado (epochs=100). En cada época, el modelo procesará lotes de imágenes (batch=64), calculará la pérdida, y actualizará el archivo del modelo entrenado utilizando el optimizador y la tasa de aprendizaje especificada (lr=0.0001).
- Después de cada época, el modelo evaluará su rendimiento en el conjunto de datos de validación para monitorear el progreso y detectar posibles problemas de sobreajuste.
- Al final del entrenamiento, YOLOv8 guardará el archivo del modelo entrenado que obtuvo el mejor rendimiento en el conjunto de validación.

## **4. Selección del modelo entrenado y Procesamiento en Backend**

- Se carga el modelo YOLOv8 al backend utilizando el archivo del mejor modelo entrenado.
- Se recibe el mapa ortomosaico del cliente a través de un archivo compartido y subido manualmente al backend.
- Ejecuta la detección de objetos en el mapa ortomosaico utilizando el modelo cargado.
- Extrae las coordenadas geográficas de los objetos detectados en el mapa, asegurándose de realizar la transformación adecuada de coordenadas de

píxeles a coordenadas geográficas. En este caso se aplica el NDVI en el mapa posterior para saber el estado de cada planta de Banano.

- Se organiza la información de los objetos detectados (coordenadas, etiquetas, etc.) junto con el mapa procesado (opcionalmente, puedes superponer los resultados de la detección en el mapa).

## **5. Publicación en la Web (con Flutter y Firebase)**

- Integración con Firebase:
  - Autenticación: Implementación de autenticación de usuarios utilizando Firebase Authentication para gestionar el acceso a la aplicación y los datos.
  - Firestore: Uso de Firestore (la base de datos NoSQL de Firebase) para almacenar la información de los objetos detectados, las coordenadas geográficas, y cualquier otra información relevante por usuario.
  - Storage: Uso de Firebase Storage para almacenar los mapas ortomosaicos cargados por los usuarios.
  - Firebase Hosting: Hosting para desplegar tu aplicación web de Flutter de manera sencilla y escalable.
- Visualización de Resultados:
  - Una vez cargado en Firebase se muestra el mapa en la plataforma web junto con los objetos detectados por visión por computadora en un mapa georeferenciado.

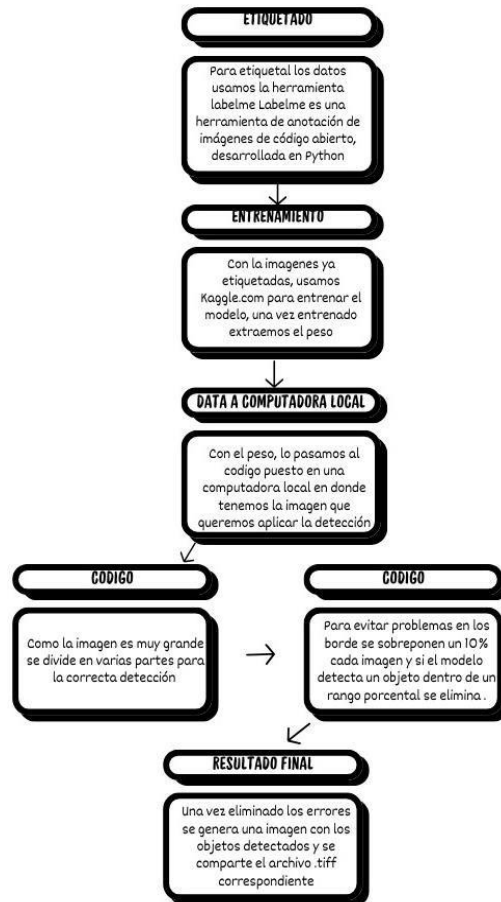


Figura 4. Diagrama técnico del funcionamiento del modelo

### 3.3 Infraestructura necesaria

Para la infraestructura de este proyecto se apoya bastante del procesamiento en la nube dado que se requiere recursos muy altos para el procesamiento adecuado, la infraestructura se detalla a continuación:

**Almacenamiento Local:** Necesitarás espacio en disco para almacenar tus imágenes, etiquetas, modelos entrenados, y otros archivos relacionados con el proyecto. Como son imágenes pesadas se requiere mínimo 1 tb para bajar y luego subir imágenes a la nube.

**Kaggle:** Kaggle se utilizará inicialmente como plataforma gratuita para el entrenamiento del modelo ya que este nos proporciona algunas librerías ya incorporadas necesarias para la detección de objetos. Posteriormente, se buscará migrar a un servidor que cumpla con los requisitos mínimos de hardware, incluyendo

una GPU y al menos 16 GB de RAM, para asegurar un rendimiento óptimo en el entrenamiento y la ejecución del modelo.

### Servicios Firebase:

- Base de datos: Para almacenar la información de los objetos detectados, las coordenadas geográficas, y cualquier otra información relevante por usuario. Firestore es una base de datos NoSQL escalable y flexible que se integra fácilmente con Firebase y Flutter.
- Firebase Authentication: Utiliza Firebase Authentication para gestionar la autenticación de usuarios de la aplicación.
- **Firebase Cloud Functions:** Firebase Cloud Functions va a ejecutar el código Python ( backend) sin necesidad de gestionar un servidor propio.
- **Firebase Hosting:** Se va a utilizar Firebase Hosting para desplegar la aplicación web de Flutter de manera sencilla y escalable.

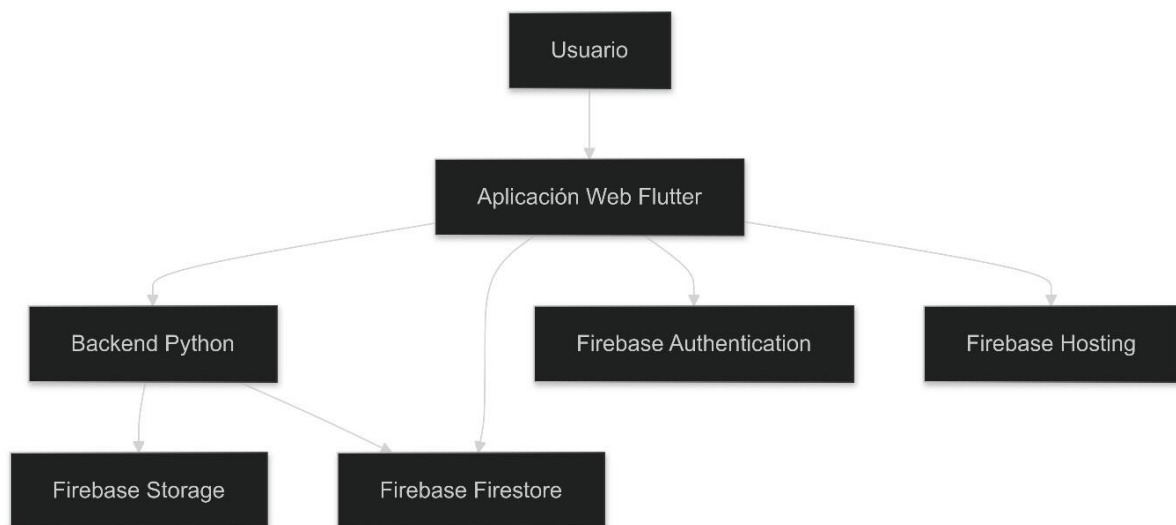


Figura 5. Flujo de la infraestructura web

### 3.4 Restricciones / Limitaciones

Las limitaciones del proyecto dependen en su mayoría de la mayoría del servicio en la nube, dado que en términos de Hardware se evita mucho la dependencia de esta más que en un par de código y almacenamiento local, de igual forma exponemos las más importantes:

- El procesamiento de mapas ortomosaicos muy grandes puede llevar un tiempo considerable, lo que podría afectar la experiencia del usuario si la aplicación no está diseñada para manejar tiempos de espera largos. Lo ideal sería no exceder de 50 hectáreas a 2 píxeles por cm.
- La detección de objetos en mapas ortomosaicos puede ser más desafiante que en imágenes convencionales debido a la variabilidad de la escala, la resolución, y las condiciones de iluminación. Esto podría afectar la precisión del modelo, especialmente si no se cuenta con un conjunto de datos de entrenamiento adecuado y representativo.
- Almacenamiento en la nube: Una de las limitantes es el espacio en la nube para almacenar las imágenes pesadas, pues requerirá de una memoria alta, por lo que puede generar limitaciones en el presupuesto o costo.
- Página web: Aunque Flutter Web ha mejorado significativamente, aún puede haber algunas limitaciones de rendimiento en comparación con aplicaciones web nativas, especialmente al manejar gráficos complejos o animaciones intensivas.

### **3.5 Resultado del entrenamiento del modelo**

Para el entrenamiento del modelo se usaron 122 fotos en total, donde fueron tomadas en 8 fincas distintas de Banano en toda la región costera del país. Las fotos fueron tomadas en distintas alturas con el dron Mavic 3M, y cada una tiene un promedio de 30 etiquetas de la planta de Banano, habiendo un total 1177 individuos para el entrenamiento. En este caso la etiqueta de la planta de banano se denominará “Banano” para el entrenamiento del modelo.



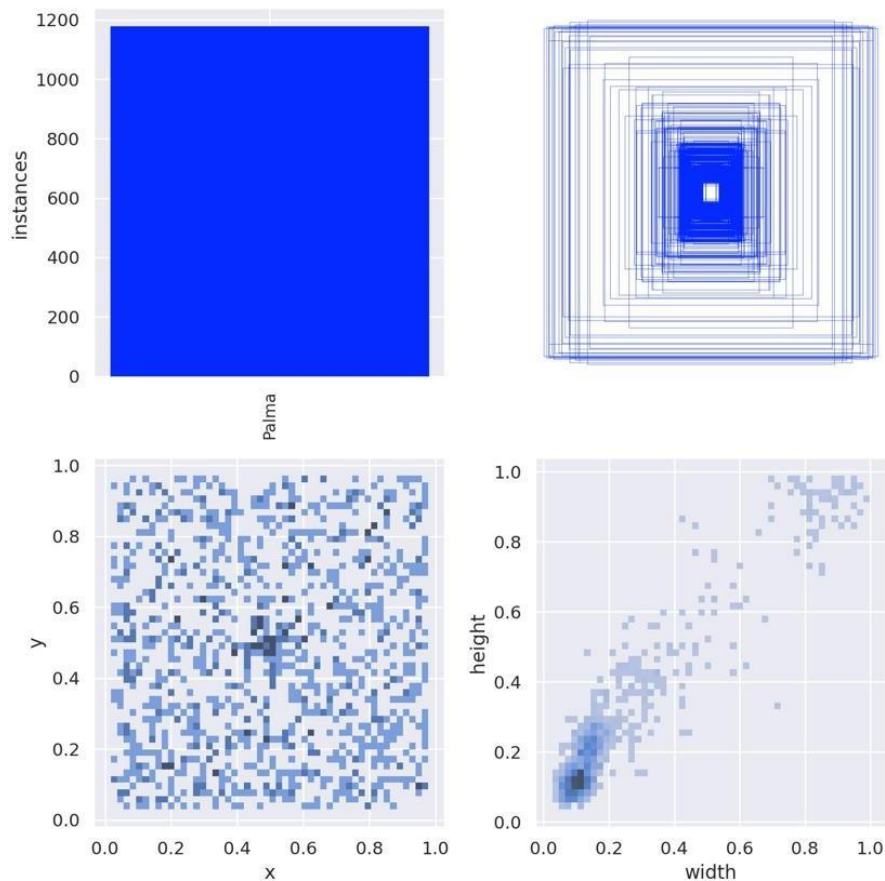


Figura 6. Grafica del tamaño y cantidad de plantas para el modelo

En la Figura 6 se puede observar la naturaleza de las plantas de banano desde el dron con una inclinación de la cámara a 90 grados, Esta perspectiva permite observar que la relación entre el ancho y el largo de las plantas es casi uniforme, reflejándose en un valor de clúster cercano a 1 para el tamaño horizontal y vertical de las detecciones. En total, se identificaron y etiquetaron 1177 plantas de banano durante el proyecto.

Para la matriz de confusión el objetivo es evitar cierto grado de porcentaje de falsos negativos y positivos ya que en el contexto de detectar una distribución poblacional densa es muy posible que se dupliquen valores o no se tome en cuenta algunos objetos, los resultados del entrenamiento fueron los siguientes:

- **Verdaderos Positivos (VP):** 1125 instancias fueron clasificadas correctamente como "Banano". Esto sugiere que el modelo es bastante bueno en la identificación de palmeras.

- **Verdaderos Negativos (VN):** La matriz muestra que no hay Verdaderos Negativos. Lo que indicaría que el modelo también es bueno en identificar lo que *no* es una palmera.
- **Falsos Positivos (FP):** 58 instancias fueron clasificadas incorrectamente como "Banano" cuando en realidad eran fondo. Esto indica cierto nivel de falsas alarmas o sobredetección de palmeras.
- **Falsos Negativos (FN):** 52 instancias fueron clasificadas incorrectamente como "fondo" cuando en realidad eran "Banano". Esto representa detecciones perdidas o subdetección de palmeras.

El modelo parece tener una buena precisión general, especialmente en la identificación de palmeras. Por otro lado, la presencia, tanto de falsos positivos como de falsos negativos indica que hay margen de mejora (Figura 7).




Figura 7. Matriz de confusión

Para este proyecto el entrenamiento fue de 100 épocas.

### Tendencias de Pérdida:

- “Train” generalmente disminuyen a lo largo de las épocas, lo que indica que el modelo está aprendiendo y mejorando sus predicciones, como también las de “Val” que muestran una tendencia decreciente, lo cual es una buena señal de que el modelo se está generalizando bien a datos no vistos. En la Figura 8 se puede ver la evolución del train y val.
- Puede haber algunas fluctuaciones menores en las pérdidas de validación, pero en general, no muestran signos de sobreajuste significativo.

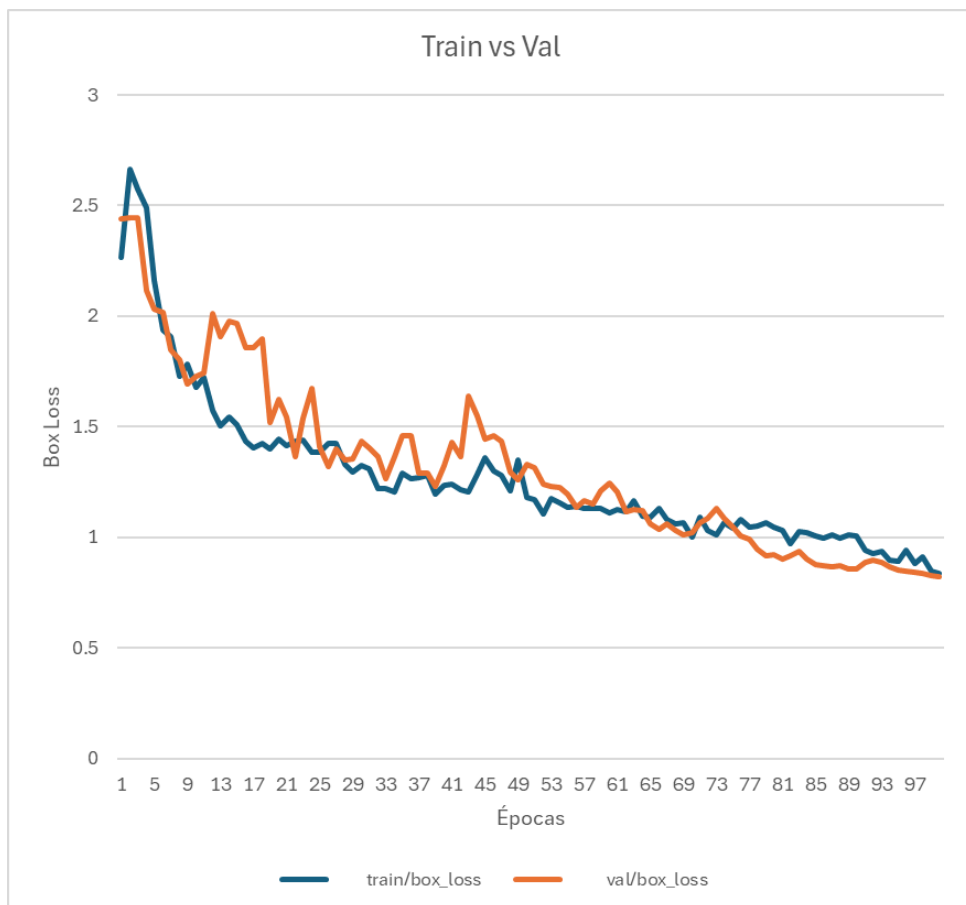


Figura 8 Rendimiento del train vs validation

### Métricas de Evaluación:

- metrics/precision(B) y metrics/recall(B) para la clase 'B' (probablemente 'fondo') son relativamente altas y estables, lo que sugiere un buen rendimiento en la identificación de la clase de fondo.

- `metrics/mAP50(B)` y `metrics/mAP50-95(B)` también muestran valores decentes, lo que respalda aún más la capacidad del modelo para detectar la clase de 'fondo'.

Con estos datos se puede decir que los valores de pérdida decrecientes indican que el modelo está aprendiendo con éxito de los datos de entrenamiento y mejorando su capacidad para predecir cuadros delimitadores y clasificar objetos.

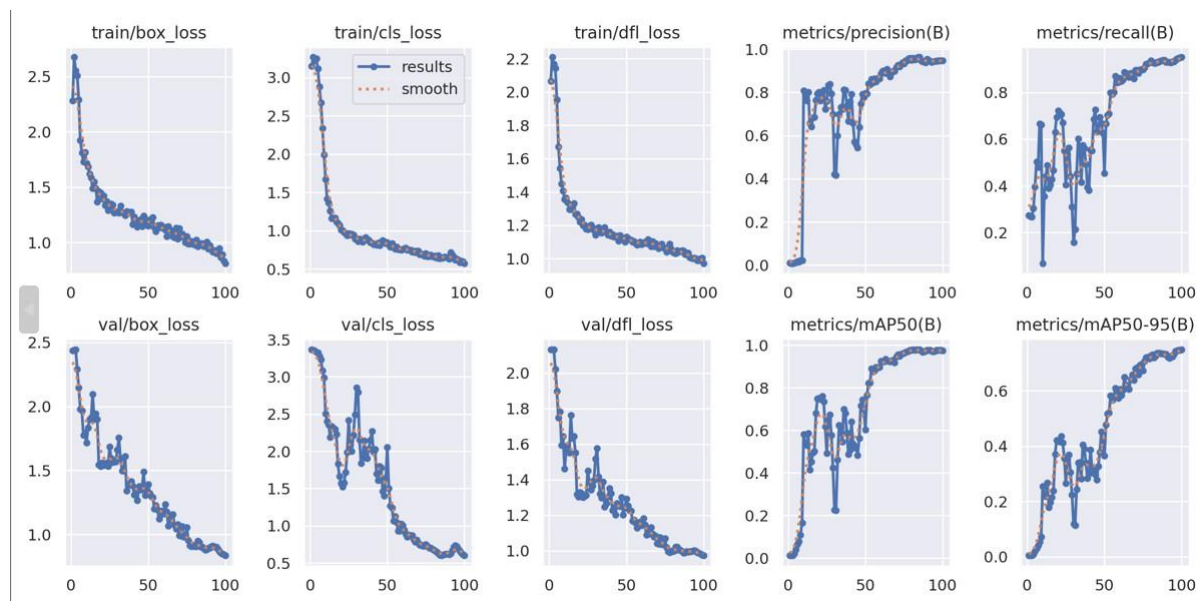


Figura 9. Rendimiento de aprendizaje (Total)

En las gráficas de precisión y recall (Figura 9 y Figura 10) sugieren que el modelo tiene un rendimiento excelente en la detección de la clase planta. Tiene un alto recall, lo que significa que encuentra la mayoría de las palmeras reales, y una alta precisión en niveles de confianza altos, lo que indica que sus detecciones confiables son muy precisas.

En la curva de precisión, la precisión es perfecta (1.0) para niveles de confianza altos (alrededor de 0.3 y superiores). Esto significa que cuando el modelo está seguro de una detección, casi siempre es correcta, pero hay errores dado que se detecta una cantidad grande por recuadro, lo que se hace visible al realizar una prueba a gran escala.




Figura 10. Curva de confianza - precisión

Por otro lado, la curva del recall desciende suavemente a medida que disminuye la confianza, lo que indica que el modelo pierde algunas detecciones al ser más estricto con su criterio de confianza (Figura 11).




Figura 11. Curva de confianza -recuperación

### 3.6 Enviar el modelo entrenado al Backend

Una vez obtenidos los pesos generados por el entrenamiento, se hace la detección de objetos en el mapa ortomosaico generado por el cliente, este mapa ortomosaico se dividirá en varias partes para que el modelo pueda detectar la totalidad de las plantas, luego se recopila la información que es el espacio georeferenciado de la planta y el % de NVDI por píxel de cada objeto detectado, esto se logra con el orto mosaico NDVI generado con el mismo dron. Estos puntos se detallan a continuación

Para que la detección de objetos funcione correctamente hay que enviar dos datos fundamentales, el orto mosaico que es la imagen completa vista de manera satelital y el peso del entrenamiento, esta información se sube a través de una plataforma o directamente al servidor donde se encuentra el código. En este caso, el mayor costo incurre en el almacenamiento de dichas imágenes ortomosaicas ya que estas suelen pesar más de 1 GB por fotos por lo que entre más grande sea las hectáreas más incurrirá en costos.

El procesamiento una vez se hayan subido los datos al servidor se basa en la segmentación de las imágenes y el procesamiento uno a uno, dado que estas

imágenes son muy grandes se las divide según el tamaño de esta, por ejemplo, para una imagen de 16 hectáreas se dividió la imagen en 9 x 9, y se procesó una cada una detectando los objetos que se tiene en cada una, y guardando los resultados de la ubicación en "X" y "Y" como de las coordenadas en una lista. También se obtiene el porcentaje NDVI dentro de los objetos, estos se clasifican entre 0 a 1, y se lo obtiene a partir de las coordenadas de los objetos encontrados en un orto mosaico NDVI previamente subido.

Por otra parte, se aplicó la segmentación por superposición dado que al ser imágenes con alta densidad de objetos en los límites de cada segmento los objetos se cortaban o no se detectaban, por lo cual se aplicó superposición de un 10% en cada límite.

El tiempo de procesamiento varía según el procesador, la RAM, la tarjeta gráfica del servidor, para el ejercicio de este proyecto se usó la computadora previamente comentada en el capítulo 1, por lo que para el ejercicio de 16 hectáreas se demoró un aproximado de una hora.

Una vez procesada la data, se envía la información de la ubicación de los objetos en coordenadas (Latitud y longitud), porcentaje NDVI, como del total encontrado a la base de datos. Para este proyecto se usó Firebase NoSQL para el almacenamiento de la data, esta información se guarda bajo el usuario administrativo y los usuarios clientes siguiendo las normas de buenas prácticas de protección de datos.

### **3.7 Procesamiento del Front-End**

Una vez enviada la información procesada con todos los ítems, se envía al Firebase, NoSQL y se enlaza a la cuenta del cliente, esta información se muestra en la plataforma web a través de Firebase, al estar la información en Firebase esta no necesita de API puesto que hay una integración directa con Flutter para el manejo de datos. En la página principal se ve el mapa ortomosaico RGB junto con los resultados multiespectrales NDVI, GNDVI, LCI, NDRE Y OSAVI en la parte inferior en medio, estas se pueden cambiar de espectro para una mejor visualización multiespectral del mapa y comparar los resultados que se muestran en la parte izquierda como se muestra en la Figura 12 En la parte izquierda se puede observar la estadística resultado del modelo de detección de objetos, en él se detalla el total de plantas detectado en el ortomosaico y se clasifica cada planta en un %NDVI donde a partir

del recuadro que detecto la visión por computadora, sacar el NDVI por píxel y toma un promedio de este:

- De 1 a 0.9 en porcentaje: Se considera la planta como excelente.
- De 0.9 a 0.8 en porcentaje: Se considera la planta como buena.
- 0.8 a 0.7 en porcentaje: Se considera la planta como regular.
- 0.7 a 0.3 en porcentaje: Se considera la planta como enferma o mala.
- 0.3 a 0 en porcentaje: Se considera estructuras o suelo dentro del ortomosaico.

Bajo estos parámetros podemos hacer una distribución poblacional de las plantas que presentan problemas ya sea por temas de riego, enfermedades o falta de nutrientes, he identificar posibles causas como se muestra en la Figura 13.




Figura 12. Página principal web, orto mosaico RGB de la finca georreferenciado.





Figura 13. Página web mostrando los objetos captados por visión por computadora y clasificándolos por %NDVI

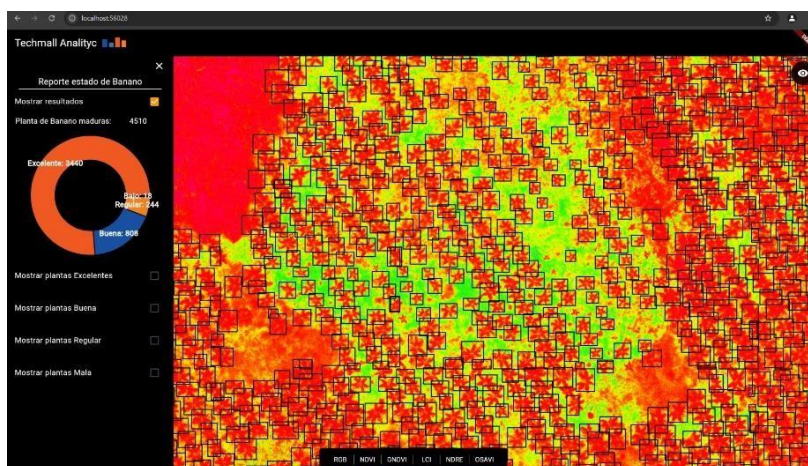


Figura 14. Página web mostrando los objetos captados por visión por computadora en fondo NDVI

## CAPÍTULO 4

### 4. ANÁLISIS DE RESULTADOS

En el análisis de resultados se considerará el tiempo de ejecución en cada fase, desde la generación del mapa hasta la publicación web. Asimismo, se evaluará el desempeño del modelo de visión por computadora, comparando los errores frente a

un conteo manual. Finalmente, se revisarán los costos asociados a la implementación de la plataforma para el conteo poblacional de banano.

#### 4.1 Tiempos de ejecución y desempeño

Proceso	Tiempos
Generar ortomosaico (4 hectáreas aproximadamente)	~ 1 hora
Entrenamiento de modelo	20 minutos
Recorte de varios segmentos de imágenes	30 segundos
Detectar plantas de las imágenes y aplicar el algoritmo de superposición	10 minutos
Subir la información de las imágenes y datos recolectados al servidor (100 Mbps de subida en promedio)	30 minutos
<b>Total:</b>	2 horas en promedio

*Tabla 2. Tiempos de ejecución*

En la Tabla 2 se detalla el tiempo aproximado para cada proceso. En primer lugar, la generación del ortomosaico puede tardar 1 hora en promedio para las 4 hectáreas, dependiendo de las características de la computadora. Paralelamente, se entrenó el modelo de visión por computadora utilizando el servidor de Kaggle; este entrenamiento solo se considera una vez, ya que el modelo será reutilizado para otros clientes, salvo que sea necesaria una actualización.

El proceso de recorte y detección de plantas, utilizando el modelo entrenado, tarda aproximadamente 10 minutos. Finalmente, la carga de la información georreferenciada de cada planta de banano identificada, junto con los mapas ortomosaicos de la finca en formatos RGB, NDVI y otros índices multiespectrales, puede demorar alrededor de dos horas, asumiendo una conexión a internet constante de 100 Mbps, aunque este tiempo puede variar según el servicio de internet disponible.

## 4.2 Validación de resultados

Para la validación de resultado, de la prueba final se detectaron 4510 plantas de banano para una extensión de 4 hectáreas, de las cual se observaron los siguientes patrones de errores (Tabla 3):

Descripción	Cantidad de plantas	Porcentaje sobre plantas detectadas
Plantas duplicadas: Plantas contadas dos veces por el modelo.	26	0.57
Falsos Positivos: Detectadas incorrectamente como Banano, pero que en realidad no son Banano.	3	0.06
Falsos Negativos: Plantas de Banano que debieron ser seleccionadas por el modelo, pero se omitieron.	3	0.06
Plantas eliminadas por superposición: Imágenes eliminadas por superposición.	69	1.53
<b>Total:</b>	101	2.24

Tabla 3. Resultados del modelo de visión por computadora

En esta prueba no se incluyeron las plantas de banano que apenas tenían unas semanas de haber brotado, ya que su pequeño tamaño dificulta su detección por parte del modelo. El principal reto encontrado fue la superposición de imágenes. Debido a que el modelo de visión por computadora requiere que la imagen se divida en varias secciones para identificar todas las plantas, los bordes de estas secciones generaban duplicados. Para solucionar este problema, se implementó un algoritmo de superposición que elimina los duplicados en los bordes. Esta solución mejoró considerablemente el rendimiento, aunque en algunos casos se eliminaron plantas correctamente detectadas que no tenían duplicados.

## 4.3 Análisis de resultados

El presente modelo presenta un error del 2.24% en el resultado final, por lo que esta diferencia se podría incrementar o decrecer dependiendo de las condiciones de la finca, en este proyecto se detectó lo siguiente:

- El modelo de visión por computadora presenta mayor error dependiendo de la densidad por metro cuadrado que se tenga de la hacienda, si la planta de

Banano no se muestra más del 50% al dron con vista aérea, esta no se tomara como una planta si no como parte de otra planta de Banano.

- El mayor error se presenta en los bordes de cada imagen recortada del orto mosaico puesto que ahí se aplica la superposición de imágenes para la eliminación de duplicados, aunque este genere error lo compensa frente a los errores que generaría si no se hiciera superposición y se tomara los duplicados en los bordes de cada imagen.
- Si en las imágenes existen vegetación similar al Banano, puede que el modelo tome como planta de Banano, por lo que se debe limitar bien los bordes georreferenciados a la hora de aplicar visión por computadora.
- Si la planta es muy joven, el modelo no podrá detectar, ya que el entrenamiento se usó plantas de Banano ya maduras.

#### 4.4 Evaluación de la solución propuesta

Los costos se centran en el costo de procesamiento del modelo y mantenimiento y levantamiento del servidor web.

Costo del Servidor Firebase mensual:

<b>Firestore</b>	<b>Servicio</b>	<b>Costo</b>
Autenticación	300 usuarios activos	\$ 3.75
Cloud Storage	1000 gb de almacenamiento	\$ 25.87
	195 gb de transferencia	\$ 19.80
<b>Total:</b>		\$ 49.42

*Tabla 4. Costo mensual de la nube*

Para el presupuesto de Firestore, se ha considerado el servicio de autenticación para proteger los datos personales de los clientes. Al utilizar Firestore Authentication, se garantiza la seguridad y privacidad de la información de los usuarios, gracias a sus robustas medidas de seguridad, como el cifrado de datos tanto en tránsito como en reposo, la autenticación multifactor y la posibilidad de personalizar los flujos de autenticación.

En cuanto al manejo de la información, se plantea usar Cloud Storage, que representa el costo más alto del proyecto, ya que se requiere almacenar imágenes de gran tamaño. Por ello, es necesario un servicio de almacenamiento que supere 1 terabyte.

Para la publicación de la página web, también se utilizará Firebase, aunque el flujo de usuarios será bajo, lo que permitirá mantenerse dentro del límite gratuito que ofrece la plataforma. Por último, el costo del dominio se estima en \$30 por año.

On-premise:

PC	Servicio	Costo
Lenovo legion 5	Se generará el orto mosaico y generará los datos por visión por computadora para luego enviar al servidor de Firebase	\$ 1200 costo único

*Tabla 5. Costo On-premise*

En este caso se opta por el On-premise en primera instancia ya que tener un servidor con las características que requiere para la construcción de mapas y aplicación del modelo por visión por computadora puede generar costos elevados por lo que se manejaría localmente.

#### 4.4.1 Propuesta de solución

Con base en lo presentado en este proyecto, la opción más viable es comercializar este producto como un servicio. Esto se debe tanto a los costos mensuales asociados con el almacenamiento de datos en servidores web, como al gran volumen de información que se generaría en la nube. La propuesta es ofrecer un servicio de suscripción mensual, donde el cliente tenga acceso a los datos capturados por el dron y al análisis realizado mediante visión por computadora. El servicio web estaría bajo un dominio de la empresa, permitiendo el acceso a un máximo de 4 usuarios por suscripción e incluiría lo siguiente:

- Mapa ortomosaico mensual: un equipo especializado de la empresa recopilaría la información mensual, o el propietario podría cargar los datos a través de la plataforma para su procesamiento.
- Análisis multiespectral acompañado de gráficos detallados.
- Conteo de la población de plantas de banano utilizando nuestro modelo.
- Análisis individual de las plantas basado en las imágenes multiespectrales.

- Seguridad de la información respaldada por los protocolos de Firebase.

#### **4.4.2 Ventajas de la aplicación distribución poblacional de plantaciones de Banano en una página Web.**

- El modelo presenta un bajo porcentaje de error por lo que puede estimar con cierto grado de precisión el total poblacional de Banano y así poder estimar la producción por sector de la hacienda de Banano.
- Se puede apreciar la distribución poblacional de las plantas separadas por rangos NDVI, donde se visualiza que regiones dentro de la finca tienen bajo nivel de NDVI, en este caso en la parte central se visualiza un NDVI más bajo del promedio, y con esto tomar medidas al respecto.
- El tiempo de aplicar para 4 hectáreas el conteo no demora más de 4 horas, y no requiere de esfuerzo físico, o de múltiples personas, por lo que se agiliza el proceso manual.
- El dashboard muestra la cantidad de planta y el contenido de NDVI individual y general, lo que ayuda de mejor manera al cliente ver de mejor manera el estado de cultivo, como también consta de un histórico dependiendo de la fecha en que se tomó los datos.

#### **4.4.3 Desventajas de la propuesta**

- El tiempo en todo el proceso puede llegar a demorar más de un día en procesar y subir mucha información al servidor por lo que este tiempo tiene que estar contemplado.
- El sitio web tiende a consumir mucha memoria RAM del cliente dado que se muestra el orto mosaico más los resultados finales, lo cual puede ralentizar las operaciones que se quiera mostrar en la página.

#### **4.4.4 Costos de la plataforma frente a costos de conteo manual**

La propuesta es ofrecer un servicio web que realiza el conteo de plantas mediante drones, con un costo mensual aproximado de \$12 por hectárea, en comparación con el conteo manual, que oscila entre \$20 hectárea. El costo del conteo manual incluye

la mano de obra de 3 a 4 personas para mapear una hectárea, con la capacidad de cubrir hasta 4 hectáreas por día. Este costo se calcula en función del salario y los beneficios asociados de los trabajadores.

Además, el servicio web ofrece una serie de herramientas digitales avanzadas que superan las limitaciones del conteo manual, como un mejor control y proyección de plagas gracias a la vista aérea, lo que genera un ahorro significativo en términos de tiempo y recursos.

# CAPÍTULO 5

## 5. CONCLUSIONES Y RECOMENDACIONES

Este proyecto impulsaría considerablemente la detección de MOKO y otras enfermedades que afectan de manera crítica a la agricultura del país, ya que permitiría una identificación más precisa del estado clorótico de las plantas, un indicador clave del deterioro en la salud vegetal. Sumado a esto, la integración de la tecnología para la detección de plantas individuales descrita en este trabajo permitiría determinar de forma minuciosa el grado de afectación de cada planta, así como la distribución exacta de la enfermedad dentro de la finca. Este avance tecnológico sería de gran ayuda para mitigar las enormes pérdidas económicas que han azotado al sector agrícola en los últimos años, como resultado de estas enfermedades devastadoras. Asimismo, la implementación de este tipo de herramientas podría optimizar las estrategias de manejo y control, permitiendo una intervención más oportuna y efectiva, lo que, en última instancia, contribuiría al fortalecimiento de la seguridad alimentaria del país y a la estabilidad de las familias agricultoras.

### 5.1 Conclusiones

Entre las principales conclusiones que tenemos del proyecto están:

- El modelo detecta con un margen de error inferior al 5 % la mayoría de las plantas de banano, presentando imprecisiones únicamente en los bordes de cada imagen segmentada. Sin embargo, es capaz de proporcionar una excelente precisión general al tomar en cuenta la distribución poblacional de las plantas dentro de una finca.
- Con la detección por el modelo de visión por computador se pudo determinar el estado de salud individual de las plantas presentes en la finca reportando un valor porcentual individual y general de la recepción de clorofila de la planta y de posibles enfermedades o falta de nutrientes en la misma, lo cual permite al cliente tomar decisiones he identificar las zonas afectadas.



- Con el servicio propuesto, se logró una mejora significativa tanto en el ahorro de recursos como en la reducción del esfuerzo requerido para el conteo manual de plantas de banano. Gracias al uso del modelo de visión por computadora de nuestro proyecto y un dron multiespectral, es posible obtener en un solo día el total poblacional de 20 hectáreas de banano, optimizando así el tiempo y la precisión del proceso.

## 5.2 Recomendaciones

Entre las principales recomendaciones que se tiene del proyecto están:

- En la reconstrucción del orto mosaico el dron no puede bajar de más de 2 pixeles ni exceder los 3, ya que al acercarse más el dron genera problemas en la reconstrucción y alejarlo se pierde la nitidez
- Si la finca tiene una hectárea superior a 20, se recomienda segmentar la finca para no sobrepasar este número, ya que podría generar problemas a la hora de mostrar la data en el servidor web, pero no se descarte que se pueda optimizar el manejo de imágenes y objetos para evitar el excesivo consumo de ram para mostrar estas imágenes de gran tamaño.
- El modelo de visión por computadora desarrollado está específicamente entrenado para banano. Detectar otras especies, como la teca en contextos forestales, puede ser un desafío, ya que su aspecto seco y fino puede confundirse con el entorno, lo que dificultaría que el modelo identifique un único árbol con precisión.

## 5.3 Discusión

Una de las principales problemáticas del proyecto fue la detección de plantas de banano en zonas muy densas, por lo que no se tomaron en cuenta algunas plantas que estaban parcialmente cubiertas, aunque existe la posibilidad de sacar mayor calidad a la imagen para detectar este tipo de planta, un mayor acercamiento repercute en un mayor consumo de recursos lo que podría afectar en la viabilidad del proyecto, al menos con los equipos actuales, por lo que tal vez en un futuro exista

mejores equipos que ayuden agilizar el proceso o algoritmos de detección más eficientes.

Por otro lado, una de las limitaciones importantes es la cantidad de hectáreas que se pueden procesar. Aunque en este proyecto se lograron procesar 4 hectáreas bajo las condiciones descritas, en la práctica, los propietarios de fincas interesados en este servicio suelen poseer superficies de al menos 50 hectáreas. Esto podría aumentar significativamente tanto el tiempo de generación del orto mosaico como el análisis total. Además, el proceso podría verse afectado por un incremento en los errores, especialmente si se considera la diversidad vegetal de las plantaciones. Estos factores pueden generar tiempos de procesamiento más largos y volúmenes de datos muy grandes, lo que podría comprometer la entrega inmediata del servicio. De igual forma se pone a discusión los parámetros de tamaño y resolución con las que se tomaron las imágenes para el modelo expuestos en este proyecto ya que varía dependiendo de las necesidades y problemas de cada hacienda.

## 6. REFERENCIA BIBLIOGRÁFICAS

- \*, W. Z. (2024). UV-NDVI for real-time crop health monitoring in vertical farms. *Scopus*.
- Aijing Fenga, J. Z. (2020). *Evaluation of cotton emergence using UAV-based imagery and deep learning*. *Scopus*.
- Bhandaria, A. K. (2012). Feature Extraction using Normalized Difference Vegetation. *ELSEVIER*.
- Dairong Chen a, d. ., (2023). Crop NDVI time series construction by fusing Sentinel-1, Sentinel-2, and environmental data with an ensemble-based framework . *Scopus*.
- Erika ´ Akemi Saito Moriya a, N. N. (2021). Detection and mapping of trees infected with citrus gummosis using UAV hyperspectral data. *Scopus*.

- Fabianna Resende Vieira, Cristiano Christofaro. (2024). Contributions of the vegetation index (NDVI) in water quality prediction models in a semi-arid tropical watershed. *Scopus*.
- Fengyun Wu a, Z. Y. (2023). Detection and counting of banana bunches by integrating deep learning and classic image-processing algorithms. *Scopus*.
- Imane Bouacida a, \*, ., (2024). *Innovative deep learning approach for cross-crop plant disease detection: A generalized method for identifying unhealthy leaves*. *Scopus*.
- Jhonn Pablo Rodríguez a, \*, .,-N. (2020). A computer vision system for automatic cherry beans detection on coffee trees. *Scopus*.
- L. Matas-Granados a, b. (2022). Long-term monitoring of NDVI changes by remote sensing to assess the. *Scopus*.
- Lanhui Fu a, b. ,. (2022). Fast detection of banana bunches and stalks in the natural environment based on deep learning. *Scopus*.
- M. Nandhini a, K. K. (2022). Deep Learning model of sequential image classifier for crop disease detection in plantain tree cultivation. *Scopus*.
- Ramsha Shahid a, W. S. (2024). Aerial imagery-based tobacco plant counting framework for efficient crop emergence estimation. *Scopus*.
- Walid CHOUARla. (2023). Assessment of vegetation cover changes and the contributing factors. *SCOPUS*.
- Wilbur N. Chiuyari Veramendi \*, P. E. (2024). Method for maize plants counting and crop evaluation based on multispectral images analysis. *Scopus*.
- Zhiqin Zhang, J. R. (2023). A multi-species pest recognition and counting method based on a density map in the greenhouse. *Scopus*.