

**ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL**

**Facultad de Ingeniería en Electricidad y Computación<sup>a</sup>**

**Facultad de Ciencias de la Vida<sup>b</sup>**

Cuantificación de plantas de banano usando imágenes de UAV,  
técnicas SIG y de aprendizaje profundo

**PROYECTO INTEGRADOR**

Previo la obtención del Título de:

**Nombre de la titulación**

**Ingeniero/a en Ciencias de la Computación<sup>a</sup>**

**Ingeniera Agrícola y Biológica<sup>b</sup>**

Presentado por:

Ricardo Alejandro Villacis Rivadeneira<sup>a</sup>

Evelyn Nohelia Mejia Murillo<sup>a</sup>

Sara Alejandra Nieto Pisco<sup>b</sup>

GUAYAQUIL - ECUADOR

Año: 2022

## **DEDICATORIA**

El presente proyecto lo dedico por apoyarnos en las buenas y en las malas a nuestros padres y amigos, y por darnos ayuda fuera de horas laborales a nuestro tutor Miguel Realpe.

**Ricardo Villacis**

## **DEDICATORIA**

El presente proyecto le dedico a mi padre, quién ya no me acompaña en esta vida, pero siempre estará en mi memoria.

**Evelyn Mejia**

## DEDICATORIA

El presente proyecto está dedicado a mis queridos padres Sara Pisco y Jose Nieto, quienes me han acompañado durante toda mi vida académica, brindándome su amor, palabras de aliento y apoyo incondicional para culminar esta etapa. Mi trabajo y esfuerzo fue para ellos y con ellos a mi lado.

De la misma forma, a mi abuelita quien ya no se encuentran físicamente a mi lado, pero continua con mucho cariño en mi corazón, gracias por ser un ejemplo de amor y bondad durante muchos años, para ti Sara Mantilla.

**Sara Nieto**

## **AGRADECIMIENTOS**

Mi más sincero agradecimiento a mi mamá por siempre estar pendiente de mi en todo, a mi padre por darme conocimiento de computación, y a mi novia por acompañarme siempre.

**Ricardo Villacis**

## **AGRADECIMIENTOS**

Agradezco de todo corazón a mi familia por apoyarme en todo lo que he necesitado. A mis amigos, por ser el escape de mis obligaciones académicas. Y, por último, pero no menos importante, a profesores y demás personas que hicieron de mi vida universitaria más amena.

**Evelyn Mejia**

## **AGRADECIMIENTOS**

Agradezco a Dios por ser mi guía y compañía durante este periodo, doy fe de que sin su consentimiento y bendición nada de esto fuera posible.

Mi más sincero agradecimiento a mi tutora de tesis María Fernanda Calderón PhD. por su continuo apoyo durante el desarrollo de este proyecto hasta su culminación, donde fue una gran guía dedicando su tiempo y conocimientos para que sea efectuado con éxito, valoro sus palabras de aliento, gracias por ser una excelente docente.

Agradezco a la PhD. María Isabel Jiménez por su continuo interés para el desarrollo eficiente del trabajo, aportando ideas y conocimientos que me brindaron recursos para un mejor desempeño.

A mis amigos que estuvieron conmigo durante este tiempo, quienes con su presencia llenaron de alegría este proceso.

**Sara Nieto**

## DECLARACIÓN EXPRESA

"Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; *Ricardo Alejandro Villacis Rivadeneira, Evelyn Nohelia Mejia Murillo y Sara Alejandra Nieto Pisco* damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual"



---

Evelyn Nohelia  
Mejia Murillo



---

Ricardo Alejandro  
Villacis Rivadeneira



---

Sara Alejandra  
Nieto Pisco



# EVALUADORES INGENIERÍA EN COMPUTACIÓN

---

**Boris Xavier Vintimilla Burgos, Ph.D.**

PROFESOR DE LA MATERIA

---

**Miguel Andres Realpe Robalino, Ph.D.**

PROFESOR TUTOR

# EVALUADORES INGENIERÍA AGRÍCOLA Y BIOLÓGICA

---

**María Isabel Jiménez Feijoo, Ph.D.**

PROFESOR DE LA MATERIA

---

**María Fernanda Calderón Vega, Ph.D.**

PROFESOR TUTOR

## RESUMEN

El banano representa uno de los productos de mayor exportación en el Ecuador, pues aporta el 2% al PIB general y cerca del 35% al PIB agrícola. Además, su producción busca ser sostenible y alcanzar un sistema de mejora continua. Una necesidad en los campos agrícolas que manejan cultivos extensivos, como el banano, es conocer la densidad real de plantas. Esta tarea se trata de una actividad laboriosa, costosa en tiempo y dinero y propensa al error humano cuando se hace de forma manual. El fortalecimiento de las bananeras implica la adopción de herramientas como la agricultura de precisión, que integra tecnologías para la explotación eficiente del campo. El presente proyecto validó la precisión de técnicas SIG y de aprendizaje profundo para la cuantificación de plantas de banano. Adicionalmente, se determinó el porcentaje de cobertura de las plantas y se generó mapas de vigor y un análisis relacional mediante índices de vegetación para el espectro visible, estableciendo que variables estiman con mayor precisión la cobertura vegetal. En un submuestreo de 50 imágenes bajo parámetros de densidad de población alta, media y baja, se obtuvo que los resultados de la aplicación de la técnica SIG (81%) fueron superiores en un 5% en comparación con los resultados de la aplicación de aprendizaje profundo (76%), correspondiente al *IoU Score*. La diferencia radica en que el modelo de aprendizaje profundo no detecta plantas muy pequeñas o plantas que se visualizan parcialmente, mientras que con SIG no se detecta plantas con baja vigorosidad.

**Palabras Clave:** Sistemas de información geográfica, SIG, aprendizaje profundo, cuantificación de plantas, segmentación semántica, localización de objetos.

## **ABSTRACT**

*The banana represents one of the largest export products in Ecuador, contributing 2% to the general GDP and about 35% to the agricultural GDP. In addition, its production seeks to be sustainable and achieve a system of continuous improvement. A necessity in agricultural fields that manage extensive crops, such as bananas, is to know the real density of plants. This is a laborious, costly, and time-consuming activity that is prone to human error when done manually. The strengthening of banana-producing fields implies the adoption of tools such as precision agriculture, which integrates technologies for the efficient exploitation of the field. This project validated the accuracy of GIS and deep learning techniques for the quantification of banana plants. Additionally, the percentage of plant cover was determined, and plant vigor maps and a relational analysis were generated using vegetation indices for the visible spectrum, determining which variables estimate plant cover with greater precision. In a subsampling of 50 images under parameters of high, medium, and low population density, it was obtained that the results of applying GIS techniques (81%) were higher by 5% compared to the results of applying deep learning techniques (76%), corresponding to the IoU Score. The difference is that the deep learning model does not detect very small plants or plants that are just partially visible, while plants with low vigor are not detected by GIS.*

**Keywords:** *Geographic Information Systems, GIS, deep learning, plant quantification, semantic segmentation, object location.*

# ÍNDICE GENERAL

RESUMEN .....	I
ABSTRACT .....	II
ÍNDICE GENERAL .....	III
ABREVIATURAS .....	VI
SIMBOLOGÍA.....	VII
ÍNDICE DE FIGURAS .....	VIII
ÍNDICE DE TABLAS .....	X
CAPÍTULO 1 .....	1
1. Introducción .....	1
1.1 Descripción del problema .....	1
1.2 Justificación del problema .....	2
1.3 Objetivos .....	3
1.3.1 Objetivo General .....	3
1.3.2 Objetivos Específicos .....	3
1.4 Marco teórico .....	3
1.4.1 Generalidades del banano.....	3
1.4.2 Agricultura de Precisión.....	5
1.4.2.1 Sensores remotos .....	5
1.4.2.2 Sistemas de información geográfica SIG.....	6
1.4.2.3 Índices de vegetación.....	8
1.4.3 Aprendizaje profundo en la agricultura de precisión .....	9
1.4.3.1 Segmentación semántica de imágenes plantas de banano .....	9
1.4.3.2 Localización en imágenes de plantas de banano .....	11
CAPÍTULO 2 .....	14
2. Metodología .....	14

2.1	Contextualización del problema.....	14
2.1.1	Área de estudio .....	14
2.1.2	Alcance del proyecto .....	15
2.1.3	Descripción del <i>dataset</i> .....	16
2.1.4	Entorno de trabajo .....	18
2.2	Determinación del porcentaje del área de cobertura de plantas .....	18
2.2.1	Preprocesamiento de imágenes .....	19
2.2.2	Etiquetado de imágenes del <i>dataset</i> .....	20
2.2.3	Creación de máscaras.....	22
2.2.4	Segmentación semántica de plantas de banano .....	23
2.2.5	Métricas seleccionadas para la segmentación semántica .....	24
2.2.6	Uso de modelo UNET.....	25
2.3	Cuantificación de plantas de banano.....	26
2.3.1	Modelo de aprendizaje profundo .....	26
2.3.1.1	Detector de objetos .....	27
2.3.1.2	Métricas seleccionadas .....	28
2.3.1.3	Uso de YOLOV5 .....	28
2.3.2	Técnicas de Sistemas de Información Geográfica (SIG) .....	30
2.3.2.1	Cuantificación de plantas de banano .....	31
2.4	Generación de mapas de vigor.....	34
2.4.1	Modelo estadístico.....	34
CAPÍTULO 3 .....		37
3.	Resultados y análisis .....	37
3.1	Estimación del área de plantas de banano.....	37
3.2	Cuantificación de plantas de banano.....	40
3.2.1	Aprendizaje profundo .....	40
3.2.2	Sistemas de Información Geográfica .....	44

3.2.3	Comparación entre técnicas .....	47
3.3	Mapas de vigor.....	48
3.4	Análisis estadístico.....	50
CAPÍTULO 4 .....		55
4.	Conclusiones y recomendaciones.....	55
4.1	Conclusiones.....	55
4.2	Recomendaciones.....	56
4.3	Trabajos futuros .....	57
4.3.1	Etiquetado en forma de polígono.....	57
4.3.2	Evaluar plantaciones de diferente tipo .....	57
BIBLIOGRAFÍA .....		58
APÉNDICES .....		65

## ABREVIATURAS

ESPOL	Escuela Superior Politécnica del Litoral
AP	Agricultura de Precisión
SIG	Sistemas de Información Geográfica
PIB	Producto Interno Bruto
UAV	<i>Unmanned Aerial Vehicle</i>
GLI	<i>Green Leaf Index</i>
VARI	<i>Visible Atmospherically Resistant Index</i>
NGRDI	<i>Normalized Green Red Difference Index</i>
DSM	<i>Digital Surface Models</i>
DTM	<i>Digital Terrain Models</i>
AGROBAN	Asociación de Productores Bananeros del Ecuador
ASISBANE	Asociación de la Industria Bananera del Ecuador
AEBE	Asociación de Exportadores de Banano del Ecuador
FOB	<i>Incoterm Free On Board</i>
IV	Índice de Vegetación
RGB	<i>Red Green Blue</i>
FPS	Fotogramas Por Segundo
ROI	<i>Region of Interest</i>
RPN	<i>Region Proposal Network</i>
sRGB	<i>Standard Red Green Blue</i>
mAP	<i>Mean Average Precision</i>
CSV	<i>Comma Separated Values</i>
TP	<i>True Positives</i>
FP	<i>False Positives</i>
FN	<i>False Negatives</i>



## **SIMBOLOGÍA**

mm	Milímetros
cm	Centímetros
m	Metros
Ha	Hectáreas
px	Píxeles
s	Segundos

## ÍNDICE DE FIGURAS

Figura 1.1 Participación del banano en Ecuador [3].	4
Figura 1.2 Participación de los países de destino del banano de exportación [4].	4
Figura 1.3 Dron portando una cámara modelo FC6310R [11].	6
Figura 1.4 Aplicaciones SIG en la agricultura [13].	7
Figura 1.5 Arquitectura del modelo UNET [28].	10
Figura 1.6 Arquitectura del modelo LinkNet [29].	11
Figura 1.7 Arquitectura Faster R-CNN [34].	12
Figura 1.8 Detección de objetos YOLOv4 [36].	13
Figura 2.1 Mapa de localización de la plantación de banano.	14
Figura 2.2 Diagrama de actividades – Determinación del área de las plantas.	16
Figura 2.3 Diagrama de actividades – Cuantificación de plantas.	16
Figura 2.4 Procesos para realizar segmentación semántica.	19
Figura 2.5 Diagrama de subprocesos de etiquetado de imágenes.	21
Figura 2.6 Coordenadas de las plantas de banano.	22
Figura 2.7 Comparación de etiquetado con la máscara generada.	23
Figura 2.8 Esquema general de segmentación semántica.	23
Figura 2.9 Esquema general de implementación del modelo.	27
Figura 2.10 Esquema general del detector de objetos.	27
Figura 2.11 Arquitectura general del modelo YOLO [32].	29
Figura 2.12 Diagrama de los procesos aplicados en la propuesta metodológica.	30
Figura 2.13 Flujo de trabajo en <i>Agisoft Metashape Professional</i> .	31
Figura 2.14 Submuestreo de la finca bananera.	32
Figura 2.15 Metodología aplicada para la cuantificación de plantas de banano.	33
Figura 2.16 Procesos para la obtención de datos para el análisis estadístico.	35
Figura 3.1 Diagrama de valor de <i>Jaccard Loss</i> contra épocas.	37
Figura 3.2 Diagrama de valor de <i>IoU Score</i> contra épocas.	38
Figura 3.3 Imagen poco poblada, máscara original y predicción.	38
Figura 3.4 Imagen medianamente poblada, máscara original y predicción.	39
Figura 3.5 Imagen muy poblada, máscara original y predicción.	39
Figura 3.6 Imagen original segmentada en comparación a la predicción.	40

Figura 3.7 Imagen original segmentada en comparación al etiquetado. ....	40
Figura 3.8 Mejores entrenamientos de YOLOv5m y sus métricas. ....	41
Figura 3.9 Resultados de las pérdidas del modelo. ....	41
Figura 3.10 Resultados de las métricas del modelo. ....	42
Figura 3.11 Imagen poco poblada y su predicción - Aprendizaje profundo. ....	42
Figura 3.12 Imagen de mediana población y su predicción - Aprendizaje profundo. ..	43
Figura 3.13 Imagen muy poblada y predicción - Aprendizaje profundo. ....	43
Figura 3.14 Reconocimiento erróneo de otras especies. ....	44
Figura 3.15 Imagen poco poblada y su predicción - SIG. ....	44
Figura 3.16 Imagen medianamente poblada y su predicción - SIG. ....	45
Figura 3.17 Imagen muy poblada y su predicción - SIG. ....	45
Figura 3.18 Error en detección de plantas con menor verdor (círculos negros). ....	46
Figura 3.19 Error en detección de plantas de menor altura (círculos amarillos). ....	47
Figura 3.20 Índice de hoja verde (GLI). ....	48
Figura 3.21 Índice de resistencia atmosférica visible (VARI) ....	49
Figura 3.22 Índice de diferencia verde-rojo normalizado (NGRDI). ....	49
Figura 3.23 Diagramas de dispersión. ....	51
Figura 3.24 Errores de VARI y NGRDI en la categorización de la cobertura vegetal. .	53

## ÍNDICE DE TABLAS

Tabla 1.1 Requerimientos edafoclimáticos [4].	5
Tabla 1.2 Formulación de los índices de vegetación para el espectro visible .	8
Tabla 1.3 Comparación de modelos FASTER R-CNN vs YOLO .	13
Tabla 2.1 Características de la imagen .	17
Tabla 2.2 Características de la cámara .	17
Tabla 2.3 Componentes de hardware .	18
Tabla 2.4 Componentes de software .	18
Tabla 2.5 Técnicas de <i>data augmentation</i> .	20
Tabla 2.6 Resumen total de imágenes .	20
Tabla 2.7 Resumen total de imágenes .	22
Tabla 2.8 Configuración del modelo .	30
Tabla 2.10 Reclasificación aplicada a la clasificación no supervisada .	33
Tabla 3.1 Resumen de técnicas SIG y aprendizaje profundo .	47
Tabla 3.2 Resultados del <i>test</i> de correlación .	52
Tabla 3.3 Resultado del análisis relacional .	52

# CAPÍTULO 1

## 1. INTRODUCCIÓN

En la actualidad, existen fincas bananeras que utilizan agricultura de precisión (AP) para determinar métricas como el porcentaje de cobertura vegetal o la población total de las plantas mediante el uso de Sistemas de Información Geográfica (SIG). Los resultados obtenidos con técnicas SIG son generalizables a la mayoría de las plantaciones, sin embargo, cuando existen características muy específicas de la plantación pueden llegar a ser imprecisos.

Por lo tanto, el presente proyecto valida la precisión de técnicas con SIG en comparación al uso de aprendizaje profundo para la cuantificación del número de plantas presentes en una plantación de banano. Adicionalmente, se generan mapas de vigor a partir de la determinación de índices de vegetación para el espectro visible y así definir cuál de ellos estima o predice con mayor fuerza la cobertura vegetal del área de estudio.

En este capítulo se detalla la descripción y justificación del problema, los objetivos y el marco teórico que sustenta el proyecto agrupado en tres módulos: generalidades del banano, agricultura de precisión y el aprendizaje profundo en la agricultura de precisión.

### 1.1 Descripción del problema

Uno de los problemas que aqueja el sector bananero, es conocer la densidad poblacional real de plantas, debido a su alto impacto en la planificación de los recursos disponibles en términos económicos y de insumos. Ya que convencionalmente, se realiza esta actividad de forma manual por lo que está sujeta al error humano además de suponer una actividad laboriosa en tiempo y costos.

Para responder a esta necesidad y aportar al fortalecimiento de las bananeras, la adopción de la agricultura 4.0 permite integrar tecnologías para el manejo eficiente de los cultivos, dado que, se optimizan recursos y disminuyen costos de producción. A medida que las áreas de producción se vuelven extensivas, el periodo

de tiempo que toma identificar alguna anomalía es más prolongado, causando pérdidas por diversos motivos tales como: la presencia de plagas y enfermedades, escasa disponibilidad de agua o drenaje, deficiencia de macro o micronutrientes, entre otros.

En consecuencia, se requiere identificar otras técnicas para la cuantificación de unidades de producción y la determinación de índices de vegetación claves que ayuden a detectar anomalías en la vegetación utilizando imágenes RGB de alta resolución capturadas con drones.

## **1.2 Justificación del problema**

El banano en la actualidad representa uno de los productos de mayor exportación en el Ecuador. Esto se debe a que aporta un 2% al PIB general y cerca del 35% al PIB agrícola. Además, este sector beneficia a alrededor del 6% de la población total concentrada en las provincias de El Oro, Guayas y Los Ríos [1].

Es importante conocer la densidad de la población en áreas de producción para realizar proyecciones del rendimiento, determinar mortalidad de plantas y una planificación más acertada de los recursos disponibles [2]. Por lo tanto, el presente proyecto pretende mostrar metodologías para la cuantificación de plantas de banano en imágenes capturadas por drones mediante la aplicación de técnicas SIG y de aprendizaje profundo; ofreciendo información del panorama real de la plantación, mejorando así las intervenciones y toma de decisiones del productor.

Además, se generan mapas de vigor y se realiza un análisis relacional entre las variables dependientes: altura, VARI y NGRDI, con el fin de definir cuál de ellas estima o predice con mayor fuerza la cobertura vegetal, teniendo como variable predictora el índice de vegetación de hoja verde GVI. Esto beneficia no solo a haciendas bananeras sino también a plantaciones con características similares que requieran los resultados que se expondrán en el proyecto para un manejo automatizado desde un ordenador o móvil.

### **1.3 Objetivos**

#### **1.3.1 Objetivo General**

Identificar el número de plantas en un sistema de producción bananero ubicado en el cantón Pueblo Viejo de la provincia de Los Ríos para la determinación de la densidad de plantas, proyección de la producción y mejora en la optimización de prácticas agrícolas mediante herramientas SIG y de aprendizaje profundo.

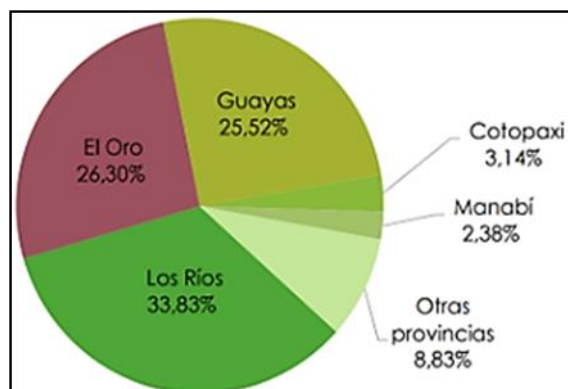
#### **1.3.2 Objetivos Específicos**

- Entrenar un modelo de segmentación semántica para determinar el porcentaje de píxeles que ocupan los cultivos de banano dentro de una imagen aérea obtenida por drones (Ingeniería en Computación).
- Entrenar un modelo de localización para realizar la cuantificación de plantas de banano en una imagen aérea obtenida por drones (Ingeniería en Computación).
- Determinar que metodología a nivel de SIG es aplicable para la cuantificación de plantas de banano mediante imágenes obtenidas por drones (Ingeniería biológica y agrícola).
- Identificar índices de vegetación para el espectro del visible para la generación de mapas de vigor del cultivo (Ingeniería biológica y agrícola).
- Analizar a nivel estadístico el comportamiento de los índices espectrales y la variable altura mediante un modelo de correlación y regresión lineal (Ingeniería biológica y agrícola).

### **1.4 Marco teórico**


#### **1.4.1 Generalidades del banano**

Las producciones bananeras en el Ecuador durante el 2020 ocuparon un total de 165.080 hectáreas, teniendo una participación en la superficie plantada a nivel nacional de 10.97% las cuales en su mayoría se concentran en la región Costa [3]. El rendimiento del banano reportado en el 2020 mantiene un rango de (15.8 – 46.9) Tm/ha [4]. En la Figura 1.1 se puede ver la participación de banano en el Ecuador.



**Figura 1.1 Participación del banano en Ecuador [3].**

Entre las principales asociaciones exportadoras de banano en el Ecuador se ubica AGROBAN (Asociación de Productores Bananeros del Ecuador), ASISBANE (Asociación de la Industria Bananera del Ecuador) y AEBE (Asociación de Exportadores de Banano del Ecuador). La producción total de banano de exportación en Ecuador en el año 2020 obtuvo un total de \$3,682,435.56 MM FOB destinada y distribuida como lo muestra la Figura 1.2 a los siguientes países:



**Figura 1.2 Participación de los países de destino del banano de exportación [4].**

El banano precisa de condiciones favorables en cuanto a variables climáticas y propiedades del suelo para un mejor desarrollo durante sus etapas fenológicas, las cuales se muestran en la Tabla 1.1 a continuación.



**Tabla 1.1 Requerimientos edafoclimáticos [5].**

Altitud	(0-300) msnm.
Temperatura	(21-30) °C
Precipitación	(100 -180) mm
Luminosidad	(3-4) horas/luz/diaria
Suelo	Franco arenoso y franco arcilloso
pH	6– 7

### **1.4.2 Agricultura de Precisión**

La agricultura de precisión reconoce, ubica, cuantifica y registra la variabilidad espacial y temporal de la unidad agrícola con la finalidad de la optimización de recursos disponibles, esto lo logra mediante la recopilación de datos capturados por un dispositivo, los mismos que serán procesados por un programa que evidencia el estado de interés de la plantación identificando posibles problemas que requieran la intervención del productor [6].

Dichos datos mencionados provienen de sensores ópticos (RGB, multiespectrales o hiperespectrales, térmicos, de fluorescencia de clorofila y 3D) que facilitan la obtención de diferentes tipos de imágenes digitales, las cuales se representan como matrices bidimensionales en la que cada píxel corresponde la unidad más pequeña en un área de coordenadas geográficas. En la agricultura, este tipo de aplicaciones son orientadas a la detección temprana de zonas problemáticas (áreas con déficit de nutrientes, presencia de plagas y enfermedades, mala gestión del riego o drenaje, etc.) que permitan mejoras en la intervención y control del productor [7].

#### **1.4.2.1 Sensores remotos**

Los sensores remotos son equipos capaces de detectar y registrar la radiación electromagnética emitida o reflejada por la superficie de un cuerpo en determinada banda del espectro electromagnético [8], por lo que no entran en contacto directo con el objeto o zona de estudio, estos son transportados por plataformas como vehículos aéreos tripulados y no tripulados o satélites. La información detectada puede transformarse en un producto pasible de interpretación, sea en forma de imagen, de

gráfico, u otros, los mismos que pueden digitalizarse para posteriormente ser procesadas en un programa especializado [9].

Hoy en día una de las principales plataformas que se manejan en la agricultura de precisión son los drones (vehículos aéreos no tripulados), como se muestra en la Figura 1.3, los cuales portan cámaras espectrales y térmicas que obtienen información clave para explotar distintos campos a nivel del suelo, generándose imágenes que no sufren de la presencia de nubosidad además de no necesitar tantas correcciones radiométricas como aquellas obtenidas por satélites [10].



**Figura 1.3 Dron portando una cámara modelo FC6310R [11].**

#### **1.4.2.2 Sistemas de información geográfica SIG**

SIG es un sistema que crea, analiza y representa a nivel cartográfico todo tipo de datos integrados como imágenes, vectores o mapas bases, para la generación de patrones espaciales que permiten facilitar la interpretación y comprensión de los resultados frente a un problema en particular o que se desconocía en tiempo real [12].

El empleo de los Sistemas de Información Geográfica en ramas como la agricultura son de gran utilidad en la reducción de muchas prácticas agrícolas puesto que incorpora herramientas para la visualización de la variabilidad del terreno definiendo con mayor exactitud futuras decisiones que aumenten la productividad de la plantación.

La aplicación de los SIG en la agricultura de precisión permite una gestión más eficiente de los recursos e insumos utilizados, mejorando el rendimiento de la plantación y a su vez reduciendo costos de producción, esto gracias a los múltiples procesos geolocalizados para la obtención de información clave para el productor. Entre las más relevantes en cuanto al monitoreo de la vegetación se enuncian en la Figura 1.4.

Análisis del rendimiento del cultivo.	Se obtienen estimaciones de varios parámetros del cultivo, como el vigor de la cobertura vegetal, monitoreo del crecimiento de plantas, pérdidas del área foliar, por lo que se logra segmentar regiones problemáticas que afectan el rendimiento.
Detección de estrés hídrico o deficiencia de nutrientes	Las mediciones de la reflectancia espectral de la vegetación logran seleccionar longitudes de onda sensibles a la deficiencia de agua y nutrientes, proporcionando información de aquellas áreas problemáticas.
Uso de suelo y cobertura de suelo	El mapeo del uso y cobertura del suelo se compone de información en cuanto a las características de la superficie donde se identifican los cambios en el tiempo, permitiendo además, clasificar la cobertura puesta en análisis.
Infestación de plagas y enfermedades	La generación de mapas en función de imágenes obtenidas por sensores permiten la evaluación de las respuestas espectrales a la presencia de clorosis y la reducción del follaje por defoliación de insectos.
Gestión de recursos hídricos	La aplicación de los SIG y las tecnologías de teledetección proporcionan una mejor comprensión de la información espacial de fuentes de agua, nivel de precipitaciones, humedad, temperatura, cuencas hidrográficas, entre otros, que facilitan la gestión del recurso hídrico.

**Figura 1.4 Aplicaciones SIG en la agricultura [13].**

Dado el caso de estudio y según bibliografía consultada, los procesos a nivel de SIG para la cuantificación de plantas se centran en las características morfológicas de las copas arbóreas ubicando su posición en el espacio para tareas agrícolas más precisas; existen diversas metodologías para la detección de una unidad vegetal tal y como lo anuncian los autores [14] donde se extraen características de una gran cantidad de datos para predecir un conteo o ubicación de un cuerpo en específico. Programas como *Qgis*, *Arcgis* y *eCognition Developer* contienen complementos que facilitan el conteo de unidades de plantas e incluso permiten el ingreso de lenguaje de programación dentro de una consola que ya viene integrada [15].

Varios estudios presentan diversas maneras de cuantificar el número de plantas en una imagen de UAV basados en la detección del objeto de estudio, entre las cuales están: Formación de grupos “*k-means*”, capa *vóxel* y algoritmo de modelado de árbol único, *Random Forest*, detección de máximos locales, segmentación basada en modelos geométricos de copas de árboles, entre otros.

Estos tipos de métodos mencionados son parte de los complementos que se encuentran en programas SIG o en su defecto, pueden ser descargados dentro de la plataforma, sin embargo, su resultado dependerá del agrupamiento de las plantas en el marco de siembra [16].

### 1.4.2.3 Índices de vegetación

Un Índice de Vegetación (IV) se puede definir como una expresión paramétrica calculada a partir de valores de reflectancia a distintas longitudes de onda [17]. Los IV son descritos como parámetros sensibles a la cubierta vegetal puesto que, extrae información de la vegetación despreciando la influencia de perturbaciones atmosféricas además de ser insensible al brillo y el color del suelo [18].

El presente proyecto hace uso de una plataforma UAV o dron que integra una cámara del espectro visible, por lo cual se calcularán los índices de vegetación que se formulan a partir de la composición de bandas RGB. La Tabla 1.2 muestra los índices a utilizar.

**Tabla 1.2 Formulación de los índices de vegetación para el espectro visible.**

VARI: <i>Visible Atmospherically Resistant Index</i> [19]	$VARI = \frac{G - R}{G + R - B}$
GLI: <i>Green Leaf Index</i> [20]	$GLI = \frac{2 * G - R - B}{2 * G + R + B}$
NGRDI: <i>Normalized Green Red Difference Index</i> [21]	$NGRDI = \frac{G - R}{G + R}$

Nota: rojo (R), verde (V) y azul (B) son los valores de reflectancia de cada banda.

Los modelos de correlación y regresión comúnmente se utilizan para evaluar el comportamiento de los índices de vegetación en relación con una variable agronómica, sea esta el contenido de clorofila (asociado al suministro de N), rendimiento, altura de la planta, y cantidad de biomasa. El índice de hoja verde GVI fue creado para ajustar el verdor y amarillamiento de la cosecha, pudiéndose utilizar para cultivos en todas las etapas de crecimiento [22], GVI logra identificar categóricamente las coberturas vegetales sin verse perturbada por el efecto de las sombras de los cuerpos [23], convirtiéndose en una opción viable para el reconocimientos de la vegetación en imágenes RGB; índices como VARI y NGRDI son fuertes predictores de los índices derivados del Yara N-Sensor el cual a pesar de estar optimizado para cuantificar la absorción de N tienen un enfoque prometedor para la estimación de biomasa [24].

### **1.4.3 Aprendizaje profundo en la agricultura de precisión**

El aprendizaje profundo o *Deep Learning* es un subcampo del aprendizaje automático también conocido como *Machine Learning* [25] que utiliza el modelo de red neuronal para aprender de datos masivos. En aplicaciones agrícolas, las técnicas de aprendizaje profundo son principalmente utilizadas para obtener información de los cultivos mediante el procesamiento de imágenes de UAV [26] .


El enfoque del presente proyecto se orienta a dos aplicaciones específicas: la determinación del porcentaje de cobertura del área de las plantas y la cuantificación de las plantas de banano haciendo uso de modelos de segmentación y localización respectivamente.

#### **1.4.3.1 Segmentación semántica de imágenes plantas de banano**

La segmentación semántica es un algoritmo de aprendizaje profundo que relaciona categorías y clasifica cada uno de los píxeles presentes en una imagen mediante el uso de redes neuronales con la finalidad de diferenciar áreas de mayor importancia. Además, es utilizado en diferentes campos tales como comprensión de imágenes, la conducción autónoma, generación de imágenes médicas y realidad aumentada [27].

Una de las arquitecturas de modelos de segmentación semántica más conocidas es UNET. La arquitectura UNET ha demostrado tener éxito cuando realiza segmentación semántica biomédica, mostrando una precisión de 92% al segmentar células PhC-U373 luego de ser entrenado con 30 imágenes donde se encuentra esta célula [28].

También se ha visto su potencial fuera del campo de la medicina como en la agricultura, donde se usa la segmentación semántica para encontrar el área que ocupa la vegetación dentro de una imagen. Se ha encontrado una precisión del 96% al localizar vegetación de imágenes provenientes del *dataset Leaf Segmentation Challenge* [27]. La arquitectura del modelo UNET se muestra en la Figura 1.5.



**Figura 1.5** Arquitectura del modelo UNET [28].

Otra arquitectura conocida para realizar segmentación semántica es LinkNet. LinkNet es una arquitectura que ha sido usada para segmentar dentro de imágenes tomadas por cámaras de auto diferentes objetos siendo estas aceras, calle, arboles, edificios, entre otros [29]. Con un *dataset* de 701 imágenes de cámara de auto se obtuvo una precisión de 76%.

Adicionalmente, se ha usado esta arquitectura para localizar células dentro de una imagen, donde LinkNet tuvo una precisión de 89.8%, mayor que UNET [30]. La arquitectura del modelo LinkNet se muestra en la Figura 1.6.

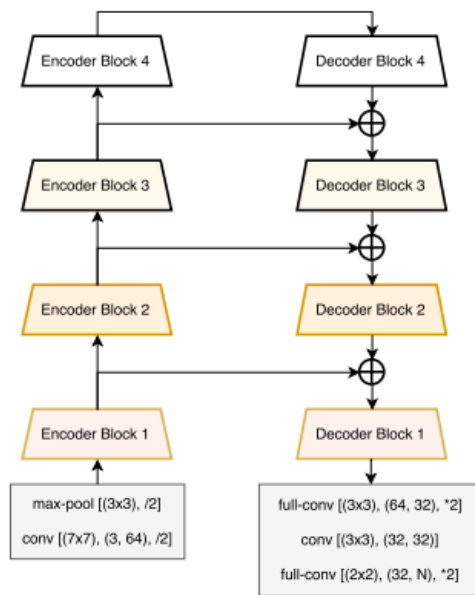


Figura 1.6 Arquitectura del modelo LinkNet [29].


### 1.4.3.2 Localización en imágenes de plantas de banano

La localización de objetos se utiliza para detectar uno o varios objetos en imágenes e indicar su ubicación con un cuadro delimitador [31]. En este caso particular, la localización se aplica para detectar únicamente plantas de banano.

La localización de objetos está inmersa en la detección de objetos que involucra junto con la clasificación de objetos. En general, los algoritmos de detección de objetos encuentran objetos para luego clasificarlos por un tipo o clase y posteriormente estiman su tamaño con un cuadro delimitador. Aquellos algoritmos que realizan estas tareas por separado se conocen como detectores de dos etapas, mientras aquellos algoritmos que combinan ambas tareas se dominan detectores de una sola etapa [32].

Debido a los numerosos pasos de inferencia por imagen, el rendimiento (fotogramas por segundo o FPS) de los algoritmos de dos etapas no es tan bueno como el de los detectores de una etapa, sin embargo, logran mayor precisión. En contraste, los detectores de una etapa son más rápidos, pero no tan buenos para reconocer objetos pequeños o de forma irregular [33].

Los algoritmos más populares utilizados para realizar la detección de objetos incluyen redes neuronales convolucionales Faster R-CNN por parte de la familia de detectores de dos etapas y YOLO (solo miras una vez) por parte de la familia de detectores de una sola etapa. La arquitectura de la red Faster R-CNN se muestra en la Figura 1.7.



**Figura 1.7 Arquitectura Faster R-CNN [34].**

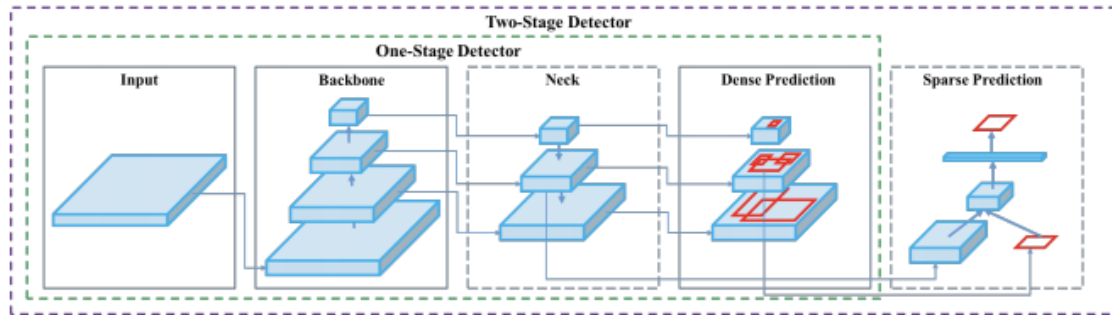
Faster R-CNN está compuesto los módulos RPN (Region Proposal Network) y Fast R-CNN que funcionan del siguiente modo: Inicialmente, la RPN genera propuestas de región; luego, por cada propuesta de región se obtiene un vector de características de longitud fija por medio de la capa de agrupación de región de interés (ROI); después, utilizando se clasifican los vectores de características; finalmente, retorna los cuadros delimitadores y las puntuaciones de clase de los objetos detectados [34].

Por otro lado, YOLO consta de tres piezas principales [35]:

- *Backbone*: una red neuronal convolucional que añade características de la imagen en distintas granularidades.
- *Neck*: una serie de capas para fusionar características de imagen para traspasarlas a la predicción.
- *Head*: usa las características del *Neck* y realiza la predicción del cuadro delimitador y la clase.



En la Figura 1.8 se ilustran las partes principales de YOLO v4.



**Figura 1.8 Detección de objetos YOLOv4 [36]**

En la Tabla 1.3 se la muestran los resultados de trabajos anteriores relacionados a este proyecto utilizando los modelos Faster R-CNN y YOLO.

**Tabla 1.3 Comparación de modelos FASTER R-CNN vs YOLO.**

Ref	Método	Backbone	Planta	Sensor	Altura m	Precision %	Recall %	F1- Score
[37]	Faster R-CNN	Inception- v2	Banana	RGB	40	99.3	96.4	97.82
					50	97.9	85.1	91.05
					60	98.5	75.8	85.67
					40+50	98.3	99	98.64
					40+50	97.9	98.6	98.24
[38]	Faster R-CNN	Inceptionv2	Oil	Multi- espectral		94	84	
[39]	YOLO v3	DarkNet53	-	RGB	120	95	85	
[39]	YOLO v5m	CSPDarknet	-	RGB	120	91	92	

En el siguiente capítulo se define la metodología de trabajo del proyecto donde se muestran los métodos y procesos que involucra la determinación del porcentaje de área de las plantas. Además, se muestran los resultados de la implementación de la técnica de aprendizaje profundo y la técnica SIG respecto a la cuantificación de plantas para una futura comparación.

# CAPÍTULO 2

## 2. METODOLOGÍA

Este capítulo describe la metodología utilizada para el desarrollo del proyecto. Al inicio se contextualiza el problema detallando el área de estudio, alcance del problema, el *dataset* disponible y los entornos de trabajo utilizados. Después, se detalla el procedimiento realizado para la determinación del área de cultivo y la cuantificación de las plantas. Finalmente, se concluye con la descripción de cómo se realizó la generación de mapas espectrales y el modelo estadístico respectivo.

### 2.1 Contextualización del problema

#### 2.1.1 Área de estudio

El presente caso de estudio fue realizado en una finca bananera ubicada en el cantón Pueblo Viejo de la provincia de Los Ríos. Situado geográficamente entre las coordenadas 1°34'8.66" Latitud Sur y 79°31'43.20" de Longitud Oeste, a 17 msnm. La temperatura media del sector oscila entre 22 y 26° C, sus precipitaciones anuales son de 1500-2000 mm [40], y corresponde a un área de 110 Ha aproximadamente. La finca bananera se puede observar en la Figura 2.1.

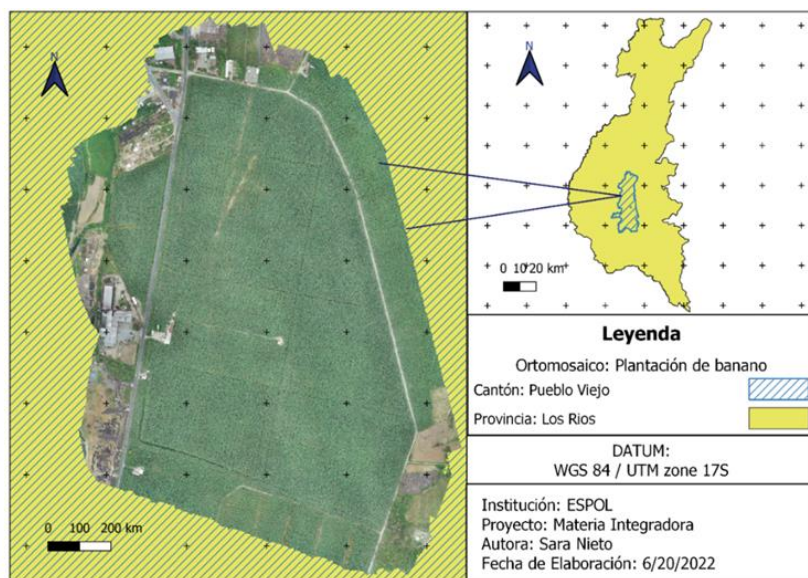


Figura 2.1 Mapa de localización de la plantación de banano.

### **2.1.2 Alcance del proyecto**

El proyecto se distribuyó en tres módulos: determinación del porcentaje de área de cobertura de plantas de banano, cuantificación de plantas de banano y por último generación de mapas de vigor del cultivo de banano y análisis relacional entre variables que determinan la vigorosidad de la cobertura vegetal.

1. Determinación del porcentaje de área de cobertura de plantas dentro de una imagen mediante un modelo de aprendizaje profundo. En la Figura 2.2 se muestra que el proceso requiere de una imagen que deberá ser procesada por el sistema para predecir el área que ocupan las plantas de banano en la imagen y posteriormente retornar el valor resultante al usuario. (Ing. en Computación)
2. Cuantificación del número de plantas de banano mediante el uso de técnicas SIG (Ing. Agrícola y Biológica) y un modelo de aprendizaje profundo (Ing. en Computación) para la determinación de la densidad de siembra y proyección de la producción. En la Figura 2.3 se ilustra que el proceso que corresponde al modelo de aprendizaje profundo requiere dar al sistema una imagen que deberá ser procesada para realizar la cuantificación de plantas de banana en la imagen, y luego retornar esa cantidad al usuario junto con imágenes con las plantas localizadas.
3. Mapas de vigor del cultivo de banano para la estimación del estado de las plantas y un análisis relacional entre la variable predictora: GLI y las variables dependientes: altura de plantas, VARI y NGRDI con el fin de evaluar cuál de éstas discrimina con mayor precisión la vigorosidad de la cobertura vegetal. (Ing. Agrícola y Biológica)

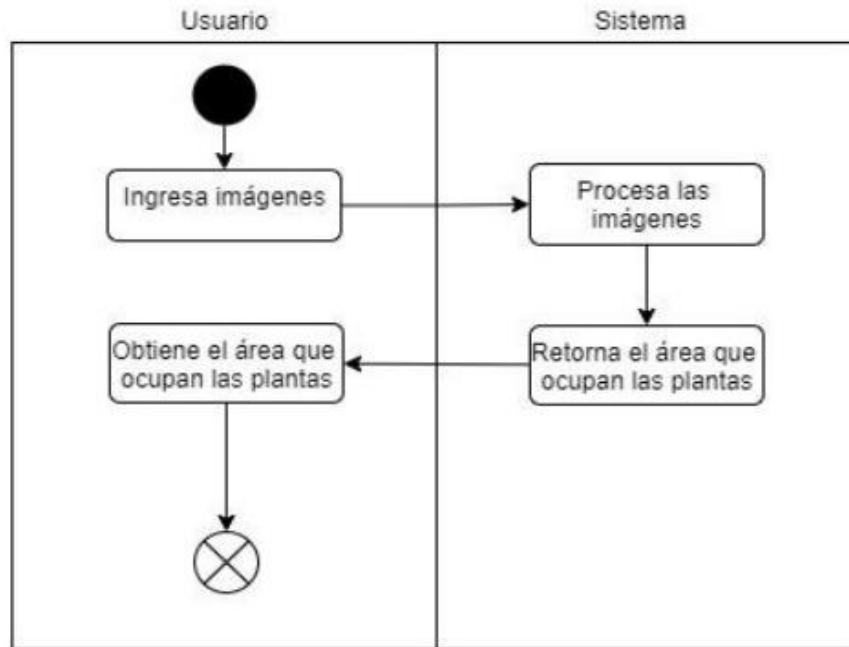


Figura 2.2 Diagrama de actividades – Determinación del área de las plantas.

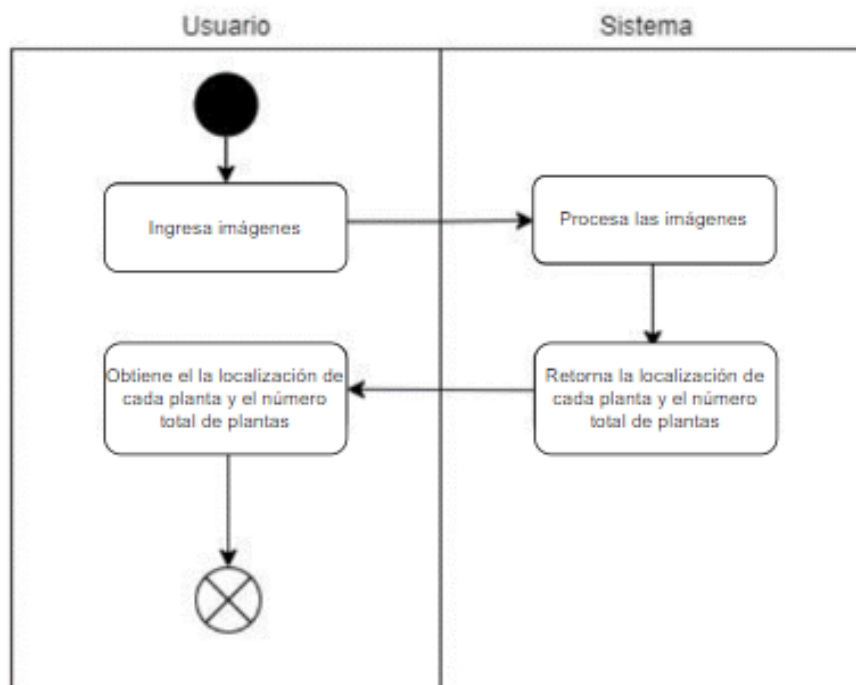


Figura 2.3 Diagrama de actividades – Cuantificación de plantas.

### 2.1.3 Descripción del *dataset*

El *dataset* se compone por 781 imágenes de UAV obtenidas mediante el dispositivo *PHANTOM 4 PRO* del área descrita en la sección 2.1; las características de

la cámara del dispositivo se pueden observar en la Tabla 2.2. En la Tabla 2.1 se muestran las características de las imágenes, donde se observa que tienen una dimensión de 5472 m de ancho y 3648 m de alto con una representación de color de sRGB.

**Tabla 2.1 Características de la imagen.**

Propiedades	Descripción
Dimensiones	5472 x 3648 píxeles
Ancho	5472 píxeles
Alto	3648 píxeles
Altura de vuelo	155.1 m
Resolución horizontal	72ppp
Resolución vertical	72ppp
Profundidad en bits	24
Representación del color	sRGB

**Tabla 2.2 Características de la cámara.**

Propiedades	Descripción
Fabricante de cámara	DJI
Modelo de cámara	FC6310R
Punto F	f/4.5
Tiempo de exposición	1/160 s
Velocidad ISO	ISO-100
Distancia focal	9mm
Apertura máxima	2.97
Modo de medición	Promedio
Modo de <i>flash</i>	Sin función de <i>flash</i>
Longitud focal de 35mm	24

#### 2.1.4 Entorno de trabajo

Para poder realizar las actividades dentro del proyecto se usaron los siguientes componentes hardware de la Tabla 2.4 y los componentes software de la Tabla 2.5.

**Tabla 2.3 Componentes de hardware.**

Componentes Hardware	Descripción
Procesador	Intel i5 décima generación
Tarjeta grafica	Nvidia GTX 1660 6GB
Memoria RAM	16 GB

**Tabla 2.4 Componentes de software**

Componentes Software	Descripción
Sistema Operativo	Windows 10
Lenguaje de programación	Python 3.8
Framework	<i>Tensorflow y Pytorch</i>
Plataforma de programación	<i>Google Colab</i>

#### 2.2 Determinación del porcentaje del área de cobertura de plantas

Para la determinación del área de cultivo se realizó el preprocesamiento de imágenes y la generación de máscaras para el posterior entrenamiento del modelo de aprendizaje profundo. En el diagrama de la Figura 2.4 se muestra los procesos que involucra la segmentación semántica, donde se tienen 6 fases:

1. Generación de máscaras del *dataset*. En base a archivos CSV y librerías de *Python* se generaron máscaras para entrenar el modelo.
2. Implementar el modelo UNET. Requiere importar librerías para implementar un modelo UNET, elegir su *backbone* y compilar sus configuraciones.
3. Preparar las imágenes y máscaras para entrenar el modelo UNET. Se localizan y se cargan las imágenes en representación de matrices para luego preprocesarlas según el backbone.
4. Entrenar el modelo UNET en base a las imágenes de la fase 3.
5. Predecir y graficar resultado.
6. Visualizar la segmentación semántica de las imágenes.



Figura 2.4 Procesos para realizar segmentación semántica.

### 2.2.1 Preprocesamiento de imágenes

Cada imagen de 5472 x 3648 px se dividió en imágenes de tamaño 480 x 480px, como se ve en la Figura 2.5, con la finalidad de obtener solo las aquellas que evidencien contener plantas de banano. Realizado el filtrado de las imágenes se seleccionaron 526 en total.



Figura 2.5 Corte de imagen original a 480x480 px.

Se realizó *data augmentation* para adaptar nuestro modelo a diferentes contextos donde se podría realizar la adquisición de nuevas imágenes y así poder tener una alta precisión sin requerir obtener patrones para dichos contextos, que podrían producirse al adquirir las imágenes en otras horas del día donde la luz no sea la misma

o tomar fotos con otra cámara. Se realizarán las técnicas de *data augmentation* de la Tabla 2.5.

**Tabla 2.5 Técnicas de *data augmentation*.**

Técnica	Cambio
Contraste	(-15%, +15%)
Brillo	(-15%, +15%)
Rotación	(-15%, +15%)
Exposición	(-15°, +15°)
Voltear	Horizontal, Vertical

La Tabla 2.6 resume la totalidad de imágenes que forman el *dataset* general divididos entre categorías: entrenamiento, validación y pruebas.

**Tabla 2.6 Resumen total de imágenes.**

Fase	Categoría	Cantidad de imágenes
Entrenamiento	Entrenamiento	560
	Validación	80
Pruebas	Pruebas	50
Total		690

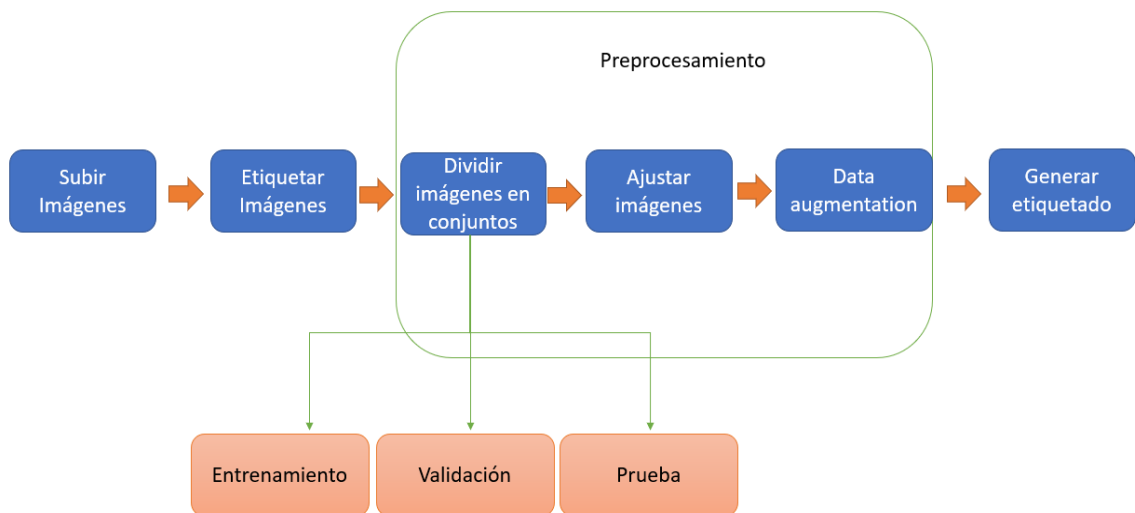
### 2.2.2 Etiquetado de imágenes del *dataset*

Para poder entrenar los modelos de segmentación semántica y de localización se necesitó etiquetar las plantas de banano dentro de las imágenes UAV del *dataset*. La herramienta para realizar el etiquetado será Roboflow. Roboflow es una aplicación web que brinda una manera sencilla de realizar el etiquetado de objetos dentro de una imagen, además de preprocesamiento de las imágenes y aumento de datos.

Para comenzar el proceso de etiquetado mediante la herramienta se deberán realizar 6 subprocesos que se pueden observar en la Figura 2.5:



1. Subir las imágenes UAV a la aplicación.
2. Selección de objetos, en este caso se etiquetó a todas las plantas de banana dentro de las imágenes.
3. Definir que imágenes van a ir dentro del conjunto de entrenamiento, prueba, y validación.
4. Definir con la opción de preprocesamiento cuál será el tamaño fijo de todas las imágenes, en este caso se elegirá el tamaño original de las imágenes siendo 480x480 px.
5. Elegir los tipos de *data augmentation* que se quiera utilizar, en este caso se utilizaron los que se explicaron en la sección 2.4.2.
6. Utilizar la opción de generar para producir el *dataset* mediante todo lo definido anteriormente.



**Figura 2.5 Diagrama de subprocesos de etiquetado de imágenes.**

Una vez generado el etiquetado se procederá a exportar el *dataset* de imágenes JPEG y el formato en CSV *Tensorflow Object Detection*. En la Tabla 2.7 se puede observar cómo se dividirán los conjuntos de imágenes en tres secciones, entrenamiento, validación y prueba.

**Tabla 2.7 Resumen total de imágenes.**

Fase	Categoría	Cantidad de etiquetas
Entrenamiento	Entrenamiento	5460
	Validación	1560
Total		7020

### 2.2.3 Creación de máscaras

Para la realización del script generador de máscaras se utilizará el formato CSV *Tensorflow Object Detection*, donde cada fila contiene el nombre de un archivo de imagen del *dataset* y las coordenadas de una planta de banano presente en dicha imagen. Si una imagen contiene varias plantas, el archivo contendrá una fila para cada planta, repitiendo el nombre del archivo de imagen en filas consecutivas.

Para crear las máscaras se comenzará con la creación de una matriz nula con la librería Numpy [41] que representará el fondo negro; la matriz tendrá las mismas dimensiones que la imagen. Luego, se recorren las filas del archivo CSV *Tensorflow Object Detection* y se extraen las coordenadas de las plantas de banano para dibujar un rectángulo de color blanco con la librería OpenCV2 [42]. Cuando se recorran las filas se podrá observar que el nombre de la imagen donde se indican las coordenadas de la planta se repetirá hasta que ya no existan más plantas de banano para esa imagen. Esto significa que mientras se dibuje una máscara no se generará una nueva desde cero hasta que el nombre de la imagen ya no sea la misma. En la Figura 2.6 se puede observar las coordenadas de las plantas de banano del archivo CSV mientras que en la Figura 2.7 se puede observar el resultado del etiquetado junto con su máscara generada.

1	filename,width,height,class,xmin,ymin,xmax,ymax
2	100_0221_0138_1920_2400_JPG.rf.0aa39d04d2d8498d7d5850b127dfac2d.jpg,480,480,Banana-plant,117,253,217,334
3	100_0221_0138_1920_2400_JPG.rf.0aa39d04d2d8498d7d5850b127dfac2d.jpg,480,480,Banana-plant,38,409,134,480
4	100_0221_0138_1920_2400_JPG.rf.0aa39d04d2d8498d7d5850b127dfac2d.jpg,480,480,Banana-plant,187,187,254,265
5	100_0221_0138_1920_2400_JPG.rf.0aa39d04d2d8498d7d5850b127dfac2d.jpg,480,480,Banana-plant,77,332,119,378
6	100_0221_0138_1920_2400_JPG.rf.0aa39d04d2d8498d7d5850b127dfac2d.jpg,480,480,Banana-plant,149,0,231,38
7	100_0221_0138_1920_2400_JPG.rf.0aa39d04d2d8498d7d5850b127dfac2d.jpg,480,480,Banana-plant,74,2,128,45

**Figura 2.6 Coordenadas de las plantas de banano.**



Figura 2.7 Comparación de etiquetado con la máscara generada.

### 2.2.4 Segmentación semántica de plantas de banano

Para realizar la segmentación semántica se necesitó un modelo de segmentación que reciba un conjunto de imágenes de entrenamiento y validación para ser entrenado. Luego de que ser entrenado, este modelo recibió una imagen del conjunto de imágenes de prueba para poder predecir la máscara correspondiente. Se puede ver el siguiente proceso plasmado en el diagrama de la Figura 2.8

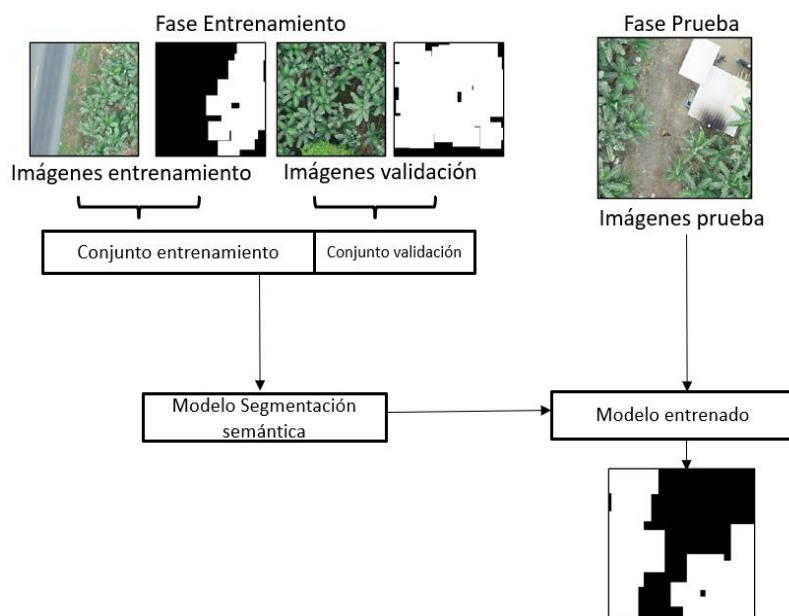


Figura 2.8 Esquema general de segmentación semántica.

Una librería que contiene modelos para realizar segmentación semántica es *Segmentation Models*. Esta librería provee cálculos matemáticos, parámetros, modelos y *backbones* necesarios para la segmentación de imágenes por medio del proceso de

convolución. Es usado por varias arquitecturas como *Gated-SCNN*, *Deeplab. Segmentation Models* contiene 4 modelos listos para utilizar siendo *UNet*, *LinkNet*, *FPN*, y *PSPNet*, y 32 *backbones* incluyendo *VGG*, *ResNet* y *MobileNet*. Todos los modelos están pre-entrenados con la base de datos de imágenes *ImageNet*, lo que hará que los modelos puedan encontrar de manera más efectiva a los objetos [43].

### 2.2.5 Métricas seleccionadas para la segmentación semántica

Las métricas que se utilizaron para evaluar el modelo fueron el *Jaccard Loss* y el *IoU Score*. Se escogió *Jaccard Loss* dado que este calcula el error de la unión sobre la intersección de la máscara predichas sobre la máscara original, esto quiere decir que calculará el error en base a si el área predicha del modelo no sigue la misma forma, posición, o si ocupa más o menos área de la que tomo la máscara original. Se puede ver la fórmula de *Jaccard Loss* en la ecuación 2.1.

$$Jq = 1 - \frac{A \cap B}{A \cup B} \quad (2.1)$$

Donde,

*A*: Área real

*B*: Área obtenida

Por otra parte, se escogió el *IoU Score* debido a que se calcula la precisión en base al mismo principio que el *Jaccard Loss*, pero este en vez de calcular el error calculará los aciertos que se tuvo en la predicción. Se puede ver la fórmula de *IoU Score* en la Ecuación 2.2.

$$IoU = \frac{TP}{TP + FN + FP} = \frac{A \cap B}{A \cup B} \quad (2.2)$$

Donde,

*TP*: verdadero positivo

*FN*: falso negativo

*FP*: falso positivo

*A*: Área real

*B*: Área obtenida

### 2.2.6 Uso de modelo UNET

Antes de crear el modelo se debe importar la librería *Segmentation Models* ya que esta posee el modelo UNET pre-entrenado, además de importar la librería *TensorFlow* debido a que esta es una dependencia de *Segmentation Models*.

Al incluir estas librerías al proyecto se utilizó la función “sm\_Unet” incluida en *Segmentation Models* para crear el modelo UNET, dicha función usará 5 parámetros:

1. El *backbone* del modelo UNET, en este caso se utilizó *resnet18*.
2. El número de clases que se segmentaran semánticamente solo será uno, debido a que exclusivamente se identificó las plantas de banano.
3. Los pesos del codificador, en este parámetro se ingresó la cadena de texto “imagenet” debido a que *Segmentation Models* automáticamente carga los pesos de la red convolucional entrenadas con el *dataset Imagenet*.
4. La función de activación del modelo, en este caso se utilizó la función sigmoideal.
5. La opción de evitar que se entrenen nuevamente los pesos del codificador al momento de entrenar el modelo UNET, se activó esta función debido a que ya se tienen pesos entrenados, y además para no necesitar tantos recursos computacionales [43].

Además, se necesitó usar la función “*compile*” para poder definir la función de pérdida, la función de precisión, y el optimizador del modelo. Esta función usa los siguientes 3 parámetros:

1. El optimizador, se utilizará el optimizador *Adam* dado que este viene de manera predeterminada, este optimizador tiene una tasa de entrenamiento por defecto de 0.001 [44].
2. Función de pérdida, se utilizará la función *Jaccard Loss*.
3. Función de precisión, se utilizará *IoU Score*.

Para poder entrenar el modelo se usó la función “*fit*”, dicha función usó 6 parámetros.

1. El conjunto de imágenes y máscaras de entrenamiento, este parámetro recibe una lista de imágenes representadas por medio de matrices “*numpy*”, la lista estuvo dividida en imágenes originales y de máscaras de las imágenes. Estas

imágenes se cargaron en matrices de “numpy” con la función “imread” de openCV2 [45].

2. El tamaño de pasos por época que recibirá el modelo son la cantidad de imágenes del conjunto de entrenamiento sobre los lotes que se utilizaron, en este caso se usaran 32 lotes.
3. La cantidad de épocas del entrenamiento, se usaron 20 épocas para el entrenamiento.
4. La función *callback* del entrenamiento, se utilizó una función *callback* para guardar el modelo apenas se encuentre en su mejor estado, este estado será cuando tenga los pesos que den como resultado el menor error.
5. Representa el primer parámetro, pero para el conjunto de imágenes de entrenamiento.
6. Representa el segundo parámetro, pero esta vez para el conjunto de imágenes de validación [46].

Para poder evaluar el modelo antes de la predicción se usó la función “*evaluate*”, esta función recibe el conjunto de imágenes de prueba y a partir de esta calcula el error y precisión promedio del modelo [46].

Para concluir con el uso del modelo UNET usó la función “*predict*” que recibe una imagen para poder predecir una máscara a partir de ella. La función “*predict*” retorna una máscara representada por un arreglo de “numpy”. Mediante la librería Matplotlib se muestra el arreglo de numpy como una imagen mediante la función “*imshow*” [47] y guardar en el dispositivo mediante la función “*imsave*” [48].

## **2.3 Cuantificación de plantas de banano**

### **2.3.1 Modelo de aprendizaje profundo**

Para la cuantificación de plantas de banano mediante un modelo de aprendizaje profundo, se realizó el mismo preprocesamiento de imágenes de la sección 2.4.1 y etiquetado de la sección 2.4.2 que se utilizó para la segmentación semántica con la única excepción de que el formato en el que se debe exportar las anotaciones generadas por Roboflow es TXT YOLOv5 PyTorch.

En base a lo descrito anteriormente, esta sección trata de la descripción del modelo YOLOV5, la configuración de este, el proceso de entrenamiento y por último las métricas utilizadas. En la Figura 2.9 se puede ver el esquema general de implementación del modelo YOLOV5.

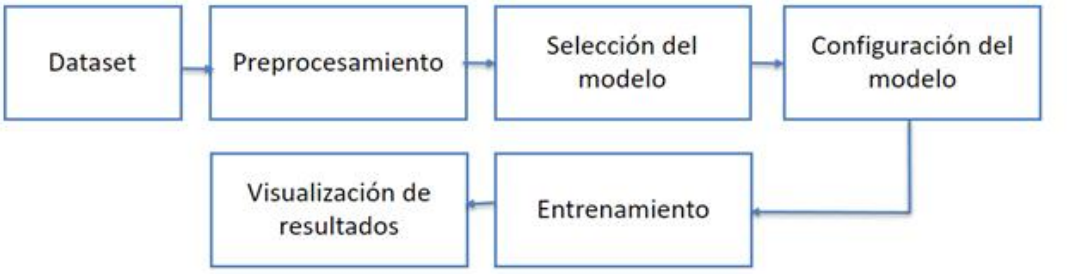


Figura 2.9 Esquema general de implementación del modelo.

### 2.3.1.1 Detector de objetos

El modelo de aprendizaje profundo para la detección de objetos fue entrenado mediante el algoritmo YOLOv5 para localizar una sola clase, en este caso únicamente fueron detectadas las plantas de banano. En la Figura 2.10 se puede observar el esquema general de localización.

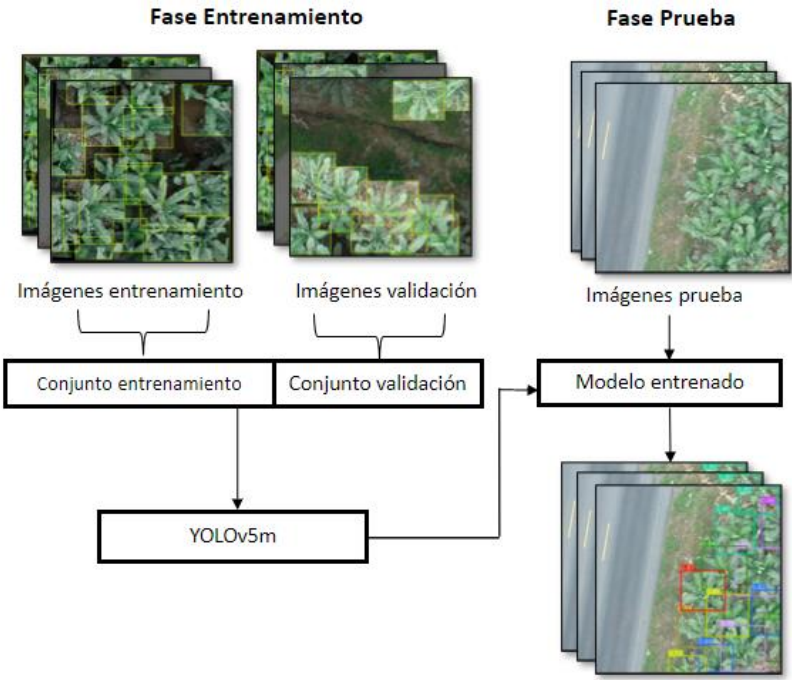


Figura 2.10 Esquema general del detector de objetos.

### 2.3.1.2 Métricas seleccionadas

Para evaluar el modelo se tendrán en cuenta tres métricas: *precision*, *recall* y *mAP*. La métrica *precisión*, mostrada en la Ecuación 2.3, describe qué proporción de identificaciones positivas fueron realmente correctas.

$$Precision = \frac{TP}{TP + FP} \quad (2.3)$$

Donde,

*TP*: verdadero positivo

*FP*: falso positivo

La métrica *recall*, mostrada en la Ecuación 2.4, indica qué proporción de positivos reales se identificó correctamente.

$$Recall = \frac{TP}{TP + FN} \quad (2.4)$$

Donde,

*TP*: verdadero positivo

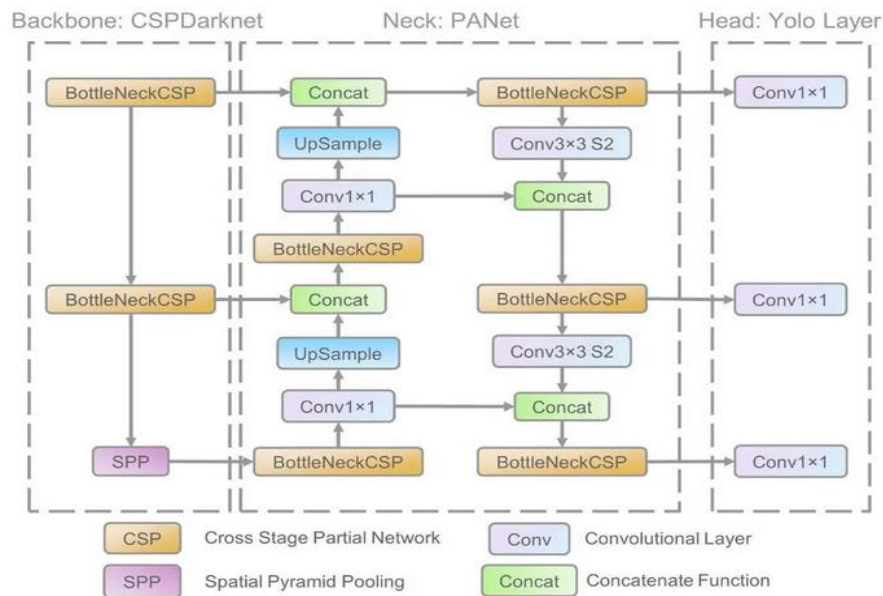
*FN*: falso negativo

Por otra parte, también se escogió el *IoU Score* ya explicado anteriormente en las métricas de evaluación para la segmentación semántica.

### 2.3.1.3 Uso de YOLOV5

YOLOV5 posee cinco modelos pre-entrenados. En base al marco teórico presentado, el modelo que se escogió fue YOLOv5m por ser un modelo lo necesariamente ligero y rápido para la necesidad del proyecto. En la imagen. Se muestra la arquitectura general del modelo YOLO en la Figura 2.11.





**Figura 2.11** Arquitectura general del modelo YOLO [32].

En cuanto a las funciones de activación YOLO v5 usa Leaky ReLU en las capas intermedias/ocultas y sigmoide en la capa de detección final. Respecto a la función de pérdida utiliza *Binary cross-entropy* con *logits loss*. Adicionalmente posee dos opciones como funciones de optimización SGD y ADAM, en este caso se dejó la función que posee por defecto la cual es SDG.

Para entrenar el modelo se necesita especificar el *dataset*, *batch-size*, *image size*, y los pesos pre-entrenados, en este caso se utilizará COCO128. A continuación, se detallan los argumentos del script de entrenamiento.

--*data*: Ruta al archivo YAML del conjunto de datos

--*weights*: este argumento acepta el modelo que se requiere usar para el entrenamiento.

--*img*: Tamaño de la imagen que se redimensionará antes de enviarse a la red.

--*epochs*: Número de épocas.

--*batch-size*: Número de muestras que se cargarán en un lote durante el entrenamiento.

--*name*: Nombre de directorio personalizado donde se guardarán todos los resultados.

--*hyp*: Archivo YAML que describe opciones de hiperparámetros.

--*workers*: Número de CPUs.

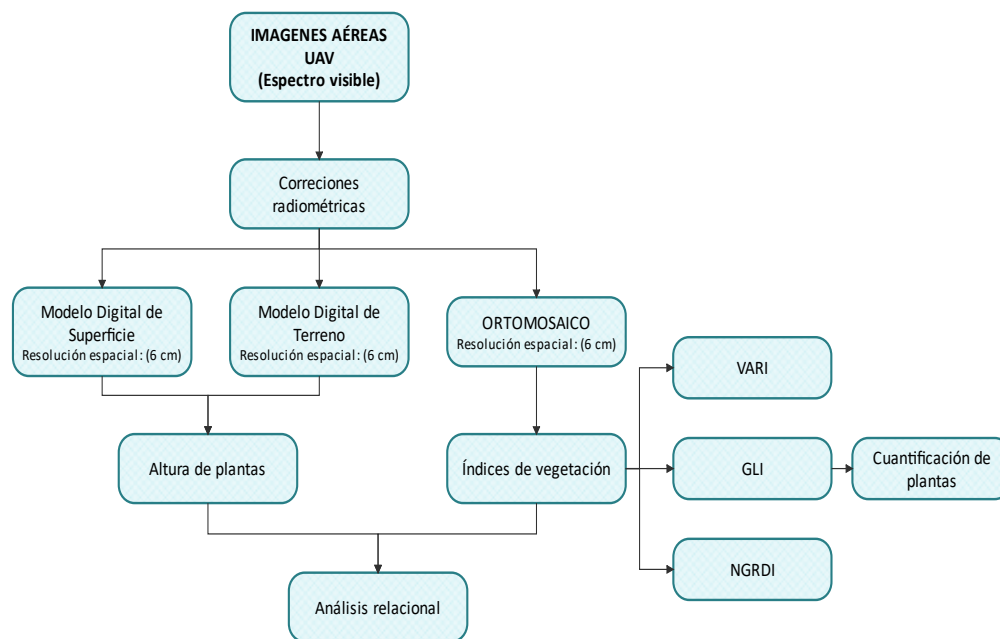
En la Tabla 2.8 se presentan los valores de los parámetros a utilizar. Los valores marcados con asterisco (\*) de la Tabla 2.8 pertenecen a los hiperparámetros que se configuran en el archivo data/hyp.scratch.yaml

**Tabla 2.8 Configuración del modelo.**

<b><i>Epoch</i></b>	20
<b><i>Batch size</i></b>	32
<b><i>Image size</i></b>	456
<b><i>Weights</i></b>	Yolov5m.pt
<b><i>*Learning-rate</i></b>	0.001
<b><i>*Decay</i></b>	0.0005
<b><i>*Momentum</i></b>	0.9

### 2.3.2 Técnicas de Sistemas de Información Geográfica (SIG)

En esta sección se detallan los procesos para la obtención del número de plantas, mapas de vigor y el comportamiento estadístico de los índices espectrales mediante el uso de técnicas de Sistemas de Información Geográfica (SIG) como se muestra en la figura Figura 2.12.

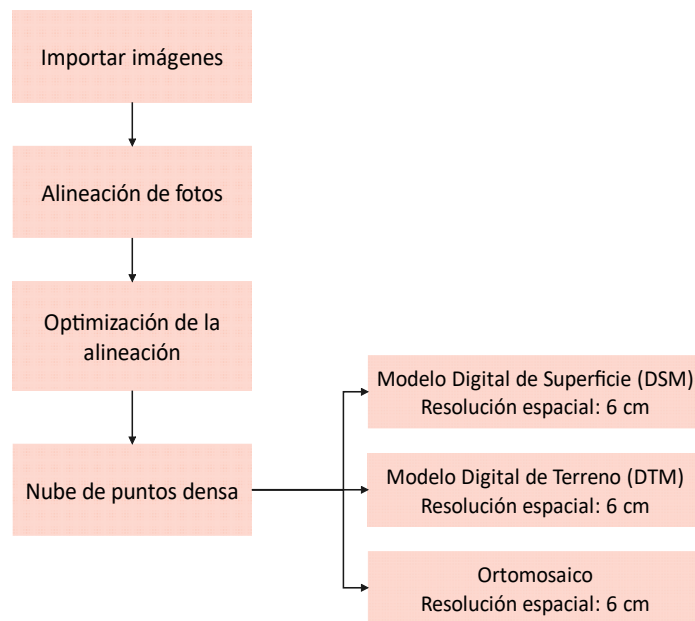


**Figura 2.12 Diagrama de los procesos aplicados en la propuesta metodológica.**

### 2.3.2.1 Cuantificación de plantas de banano

Para la cuantificación de plantas de banano se contó con una base de datos de 781 imágenes en el espectro del visible, obtenidas con una cámara modelo Phantom 4 pro FC6310R [49] integrado en un dron. Tabla 2.1 y Tabla 2.2 muestran las características de las imágenes y de la cámara respectivamente con las que se trabajó.

El procesamiento de imágenes se realizó con el programa Agisoft metashape profesional versión 1.8.2 [50], donde, se aplicó correcciones radiométricas a las 781 imágenes UAV tomadas en una finca bananera de 110 Ha aproximadamente. Los tres productos que se obtuvieron como resultado se observan en la Figura 2.13 con una resolución espacial de 6 cm/píxel cada uno.




**Figura 2.13 Flujo de trabajo en *Agisoft Metashape Professional*.**

Para el procesamiento de los productos obtenidos en *Agisoft Metashape Professional* se utilizó el programa de código abierto QGIS [51]. El análisis espacial comprendió un submuestreo de 50 imágenes (cuadrillas amarillas) bajo parámetros de densidad de población alta, media y baja de la Tabla 2.9, extraídas a partir de una malla con dimensión 480x480 px dentro de los lotes de producción de la finca bananera en la Figura 2.14.

**Tabla 2.9 Parámetros para la selección de imágenes.**

Parámetro	Característica
Densidad alta	Cobertura vegetal de la imagen >70%
Densidad media	50%<Cobertura vegetal de la imagen >70%
Densidad baja	Cobertura vegetal de la imagen <50%



**Figura 2.14 Submuestreo de la finca bananera.**

Con el fin de identificar con mayor eficiencia la vegetación de otras coberturas del suelo se determinó el índice espectral GLI, mediante la ecuación 2.5:

$$GLI = \frac{2 \cdot G - R - B}{2 \cdot G + R + B} \quad (2.5)$$

Al índice de vegetación GLI se le aplicó una clasificación no supervisada para identificar las diferentes clases espectrales presentes en el área de estudio mediante la herramienta “*k-means clustering for grid*” por el método de “Distancia mínima iterativa” en cuatro grupos identificados como: hoja bandera, hojas laterales, suelo, caminos. Luego con la herramienta “*Reclass for table*” se discriminó la hoja bandera de la planta

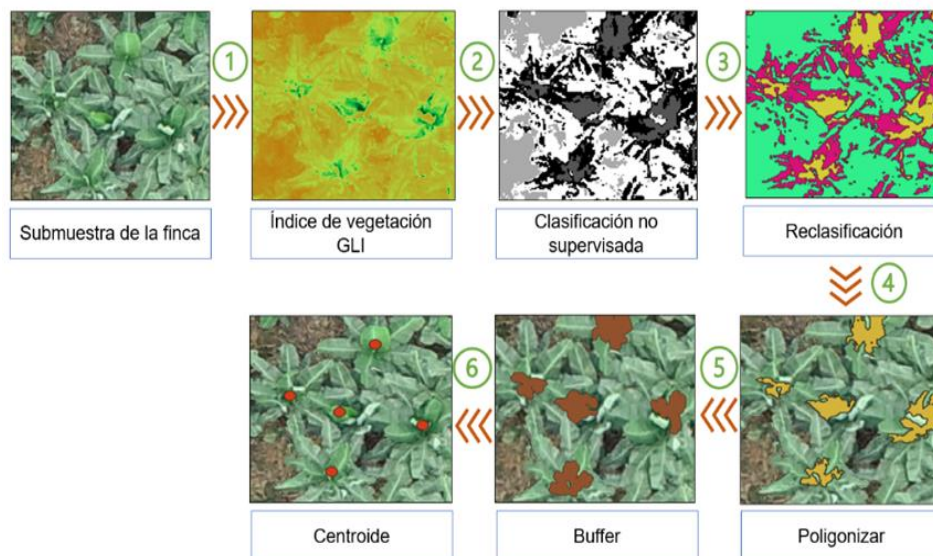
de banano de los demás cuerpos (hojas laterales, suelo y caminos) en dos clases Tabla 2.10.

**Tabla 2.10 Reclasificación aplicada a la clasificación no supervisada.**

min	Max	Valor de clase	Descripción
0	3	1	Hojas laterales, suelo y caminos
3	4	2	Hoja bandera

Una vez identificada las clases se vectorizó la reclasificación mediante la herramienta “Polygonize (raster to polygon)”, para luego exportar la clase 3 (hoja bandera) y calcular la superficie de los polígonos depurando aquellos menores a 0.1 m<sup>2</sup> puesto que, no constituyen el cuerpo de interés. Posteriormente, se utilizó la herramienta “buffer” para definir la geometría de los polígonos que representan la hoja bandera, con una distancia de 0.07 m.

Por último, a la capa vector resultante se le aplicó la herramienta “centroid”, la cual crea una capa de puntos que representan el centro de las geometrías ingresadas, donde, cada planta fue representada por un punto y su cuantificación se realizó bajo el número de objetos espaciales que contiene su tabla de atributos. Se puede ver todo el proceso en la Figura 2.15.



**Figura 2.15 Metodología aplicada para la cuantificación de plantas de banano.**

## 2.4 Generación de mapas de vigor

Los índices de vegetación cumplen la funcionalidad de determinar las características de la cantidad de biomasa en una zona en específico discriminando otras coberturas.

Las cámaras del espectro visible detectan las reflectancias de las bandas rojas, verdes y azules, las cuales son ingresadas en la “calculadora ráster” para la obtención de los índices de vegetación GLI, VARI y NGRDI en el programa QGIS, en función de las ecuaciones 2.5, 2.6, y 2.7 respectivamente:

$$VARI = \frac{G-R}{G+R-B} \quad (2.6)$$

$$NGRDI = \frac{G-R}{G+R} \quad (2.7)$$

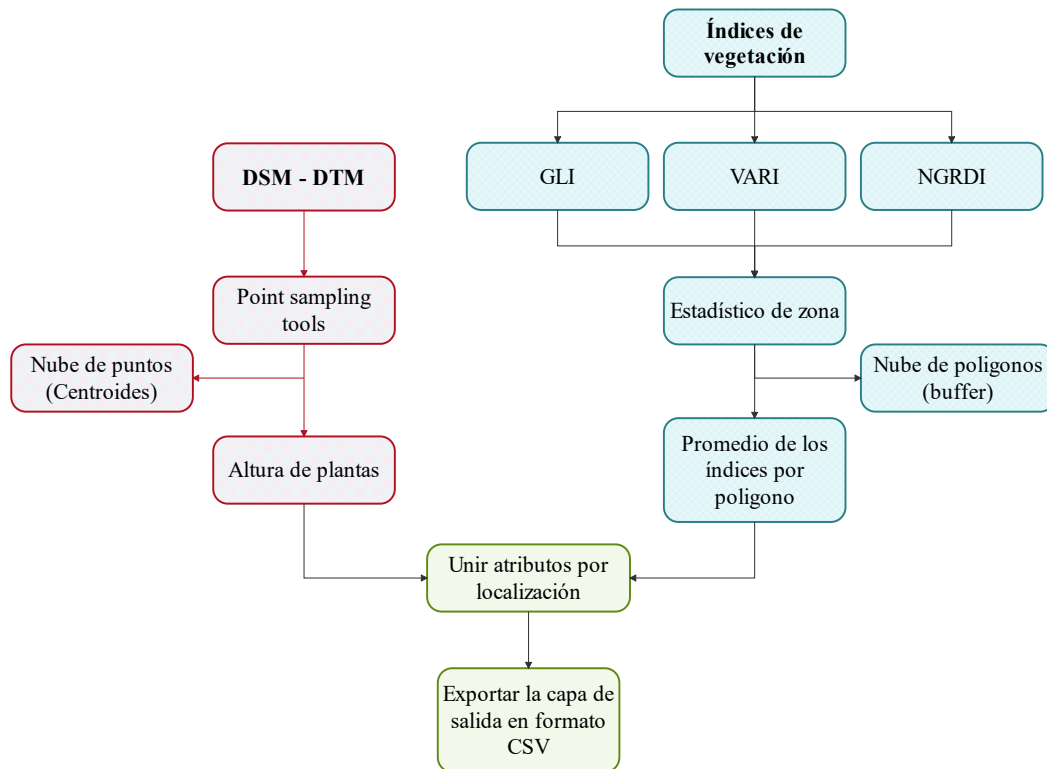
Los índices de vegetación generados fueron representados con una simbología a pseudocolor monobanda para diferenciar la vigorosidad de las plantas de banano en 4 clases.

### 2.4.1 Modelo estadístico

Para el análisis del comportamiento estadístico se evaluaron las siguientes variables: altura de plantas (m) y los índices de vegetación: GLI, VARI, NGRDI mediante el uso de las herramientas que se observan en la Figura 2.16.

La variable agronómica de altura de plantas se obtuvo mediante la herramienta “*Point sampling tool*”, donde se asoció la capa de los centroides o puntos que corresponde al número de plantas de banano, con el modelo de representación ráster que contiene información de las alturas de todos los cuerpos de la superficie de la finca, generado a partir de la diferencia entre el DSM y el DTM.

Para la obtención de los datos de GLI, VARI y NGRDI se extrajo el promedio de los valores a cada polígono generado durante la metodología de la cuantificación de plantas Figura 2.15, mediante el uso de las herramientas que se muestran en la Figura 2.16.



**Figura 2.16 Procesos para la obtención de datos para el análisis estadístico.**

Se realizó un análisis relacional empleando el programa *RStudio Desktop* para explicar el comportamiento de las variables dependientes: altura de planta y los índices de vegetación VARI y NGRDI, en función de la variable predictora: índice de vegetación GLI. Se ejecutó la prueba de correlación lineal para el cual se tomó un nivel de significancia de 0.05 para la validación de las siguientes hipótesis:

$$H_0: \text{No hay correlacion lineal}$$

$$H_1: \text{Hay correlacion lineal}$$

Una vez generados los coeficientes de correlación y los diagramas de dispersión, se procedió al análisis del modelo de regresión lineal para aquellas variables que rechazaron la hipótesis nula a favor de la alterna con un 95% de confianza. Los

resultados del modelo de regresión lineal determinaron que conjunto de variables analizadas predice con mayor fuerza el índice GLI, ya que es aquel que mejor identifica la vigorosidad de la cobertura vegetal.

En el siguiente capítulo se mostrarán los resultados de la segmentación semántica mediante el modelo de *Segmentation Models* y la cuantificación de la técnica SIG junto al modelo de Yolov5m, además de la una comparación de la precisión entre las técnicas SIG y Yolov5m y el respectivo análisis.



# CAPÍTULO 3

## 3. RESULTADOS Y ANÁLISIS

En este capítulo se detallan los resultados y análisis para la estimación del área mediante segmentación semántica y la cuantificación de plantas mediante técnicas SIG y de aprendizaje profundo. Para realizar el entrenamiento de los modelos de aprendizaje profundo se utilizaron los conjuntos de imágenes de entrenamiento y validación propuestos en la Tabla 2.7, además de la misma tabla propuesta se utilizó el conjunto de imágenes de prueba para evaluar y comparar las técnicas SIG con las de aprendizaje profundo.

### 3.1 Estimación del área de plantas de banano

Para obtener la estimación del área de plantas de banano en imágenes de UAV se realizó el entrenamiento del modelo de segmentación semántica con la librería *Segmentation Models*. Se encontró que en la mejor época el modelo obtuvo un 35.43% en porcentaje de error *Jaccard Loss* y un 87.87% de precisión *IoU Score*, alrededor de esta época las métricas comienzan a oscilar dando a entender que con el *dataset* obtenido no se puede ni decrementar el error ni mejorar la precisión de manera significativa a partir de este punto. En las Figura 3.1 y Figura 3.2 se puede observar el cambio de los valores que obtuvieron la función de pérdida, *Jaccard Loss*, y la función de precisión, *Iou Score*, a lo largo de las 20 épocas propuestas.

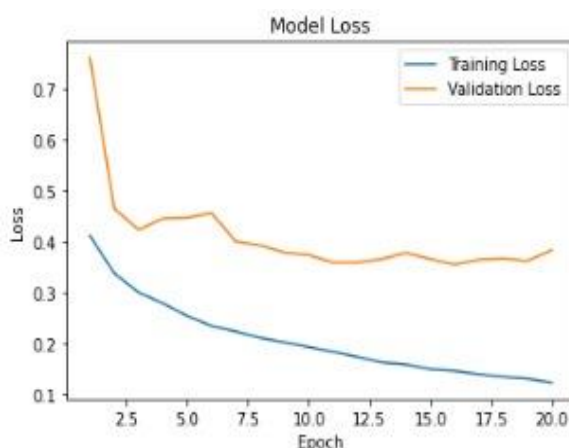




Figura 3.1 Diagrama de valor de *Jaccard Loss* contra épocas.

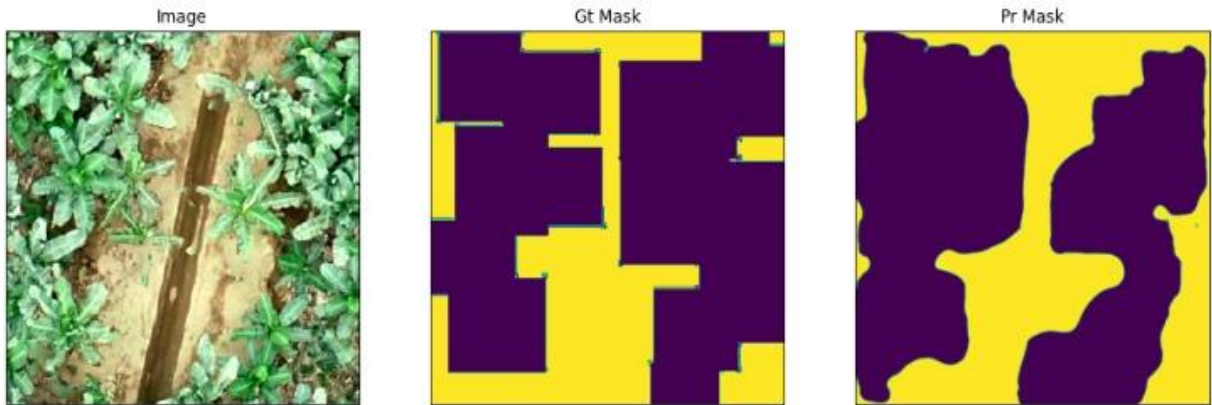


**Figura 3.2 Diagrama de valor de *IoU Score* contra épocas.**

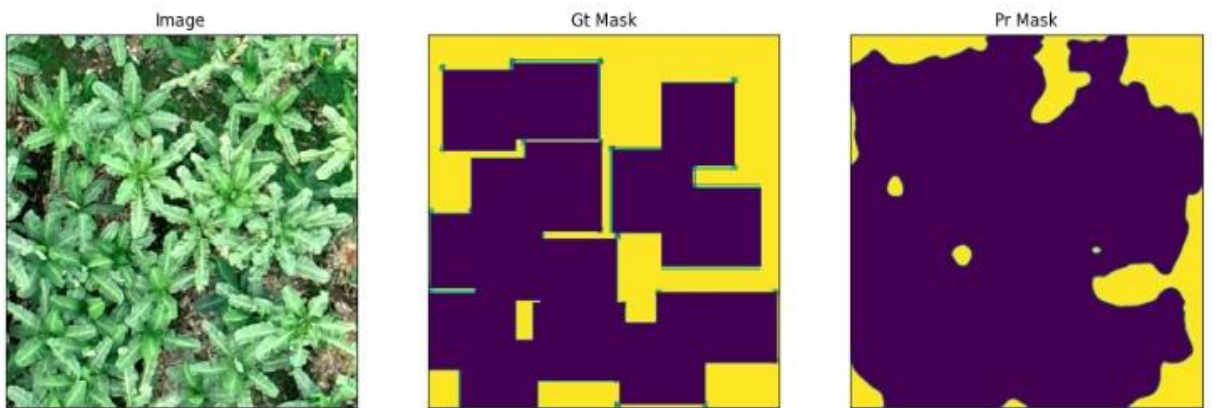
Al momento de evaluar el modelo de segmentación semántica con el conjunto de imágenes de prueba se pudo encontrar un 44.45% de porcentaje de error *Jaccard Loss* y un 87.24% de precisión *IoU Score*. Se puede observar en las Figura 3.3, Figura 3.4, y Figura 3.5 las predicciones de imágenes que representan a los tres grupos mencionados en la metodología, donde la Figura 3.3 representa a las imágenes con poca población de plantas de banano, la Figura 3.4 representa las imágenes con mediana población de plantas de banano, y la Figura 3.5 representa a las imágenes con alta población de plantas de banano.



**Figura 3.3 Imagen poco poblada, máscara original y predicción.**



**Figura 3.4 Imagen medianamente poblada, máscara original y predicción.**



**Figura 3.5 Imagen muy poblada, máscara original y predicción.**

Se pudo observar que, aunque el *Jaccard Loss* sea grande, la predicción no es mala en comparación a la imagen original. El modelo de segmentación semántica como se muestra en la Figura 3.6 predijo permitiendo formas diferentes a rectángulos frente a las máscaras que solo permiten figuras rectangulares como se muestra en la Figura 3.7. Teniendo en cuenta lo anteriormente dicho, los resultados de *Jaccard Loss* crecieron significativamente debido a que el modelo fue evaluado frente a mascararas que por limitaciones en la forma del etiquetado pueden tomar el área de forma incorrecta.




Figura 3.6 Imagen original segmentada en comparación a la predicción.




Figura 3.7 Imagen original segmentada en comparación al etiquetado.

### 3.2 Cuantificación de plantas de banano

Para la cuantificación de plantas de banano se utilizaron técnicas SIG y de aprendizaje profundo. A continuación, se detallan los resultados de cada una de estas técnicas.

#### 3.2.1 Aprendizaje profundo

Se emplearon redes neuronales convolucionales mediante la utilización del modelo YOLOv5m. Se iniciaron los entramientos con cortes de 456 x 456 con *padding* horizontal hasta alcanzar 480 x 480, sin embargo, lo máximo que se llegó a obtener de mAP fue 0.80. Luego, se optó por realizar nuevos cortes de 480 x 480 directamente sin añadir ningún *padding* y se obtuvieron mejores resultados en menos épocas. En la Figura 3.8 se presentan los tres mejores entramientos con sus respectivas métricas, resultando

como mejor el etiquetado como yolo\_480\_25, obteniendo 0.94 de *mAP\_0.5*, 0.86 de *precision* y 0.90 de *recall*.

Name (3 visualized)	Runtime	batch_si	data_dic	epochs	hyp.lr0	imgsz	optimizer	weights	workers	best/epoc	best/mAP_0.5	best/preci	best/recall
● yolo_banana_plant_480_25	7h 4m 4s	32	1	25	0.01	480	SGD	yolov5m.pt	8	17	0.9357	0.8551	0.897
● yolo_banana_plant_480_50	13h 28m 25	32	1	50	0.001	480	SGD	yolov5m.pt	8	21	0.925	0.8582	0.886
● yolo_banana_plant_456_40	4h 30m 3s	32	1	40	0.001	456	SGD	yolov5m.pt	8	34	0.8024	0.7549	0.7661

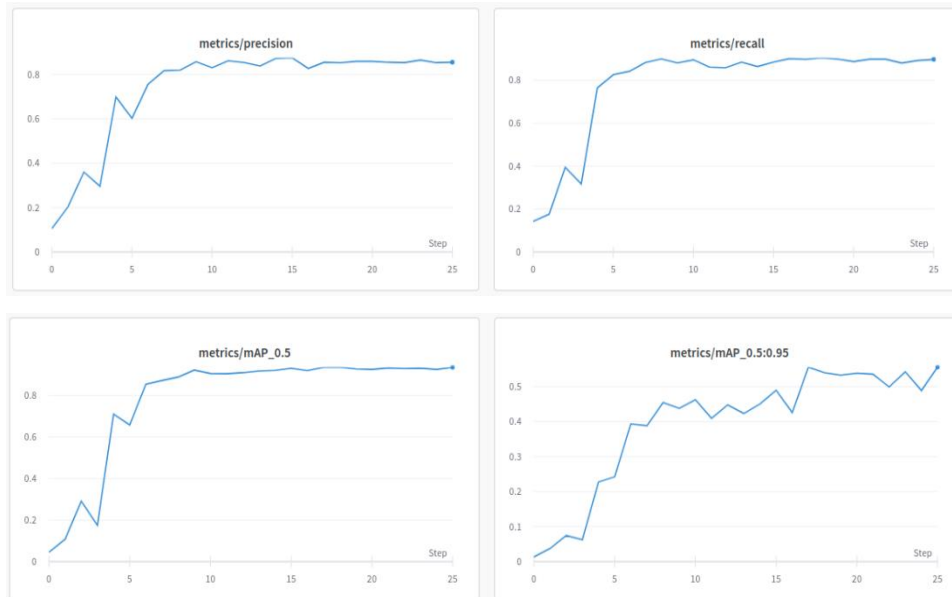
**Figura 3.8 Mejores entrenamientos de YOLOv5m y sus métricas.**

En la Figura 3.9 se muestra las gráficas correspondientes a las pérdidas de la mejor configuración del modelo. En la época 25 el *box\_loss* en entrenamiento es 0.04 mientras que en validación llega a 0.02. Por otro lado, el *obj\_loss* en entrenamiento es 0.07 mientras que en la validación llega a 0.06. Se omite *class\_loss* tanto en entrenamiento como en validación ya que solo se está entrenando el modelo para una sola clase.



**Figura 3.9 Resultados de las pérdidas del modelo.**

Respecto a las métricas de la mejor configuración del modelo, en la Figura 3.10 se muestra las gráficas de *precision*, *recall*, [mAP@0.5](#) y *mAP@0.5-0.95*



**Figura 3.10 Resultados de las métricas del modelo.**


Al evaluar el modelo se obtuvieron diferentes resultados según la categorización inicial. La Figura 3.11 muestra el ejemplo de localización de plantas en una zona con baja población. Después en la Figura 3.12 se muestra la localización con mediana población, y por último se muestra el ejemplo de localización con alta población en la Figura 3.13.



**Figura 3.11 Imagen poco poblada y su predicción - Aprendizaje profundo.**



**Figura 3.12 Imagen de mediana población y su predicción - Aprendizaje profundo.**



**Figura 3.13 Imagen muy poblada y predicción - Aprendizaje profundo.**

En general, el modelo predijo correctamente las plantas que están total o medianamente desarrolladas. En el caso de plantas muy pequeñas el modelo no fue capaz de detectarlas lo que aumenta los falsos negativos. También hay ocasiones en que se detectaron plantas en los bordes donde se no se llega a visualizar el centro, lo cual basado en las consideraciones del etiquetado son verdaderos negativos.

Además, el modelo también reconoció especies de planta que tuvieron características similares a las del banano como las palmeras de coco. Esto es debido a que los pesos con el cual el modelo fue pre-entrenado proveniente del *dataset* MS COCO el cual aporta a la discriminación entre 80+ clases, sin embargo, ninguna de estas clases son especies de plantas. Por lo tanto, el modelo no tiene como distinguir las plantas de banano de esas otras especies como se muestra en la Figura 3.14 donde el cuadro rojo representa la planta de banano y el verde es otra especie.



**Figura 3.14 Reconocimiento erróneo de otras especies.**

### **3.2.2 Sistemas de Información Geográfica**

La depuración de los elementos sobre la imagen que no pertenecen a la hoja bandera a través de la generación de polígonos logró discriminar satisfactoriamente objetos de carácter vegetal con características similares como arbustos y palmeras. Además, se eliminó elementos que representan arvenses dentro de los lotes de producción para las diferentes densidades de población analizadas como se muestran en la Figura 3.15, Figura 3.16, Figura 3.17.



**Figura 3.15 Imagen poco poblada y su predicción - SIG.**





**Figura 3.16 Imagen medianamente poblada y su predicción - SIG.**



**Figura 3.17 Imagen muy poblada y su predicción - SIG.**

Las imágenes que se agrupan dentro del parámetro de baja población mostraron una cobertura vegetal inferior al 50% con un distanciamiento de las plantas influenciadas por la presencia de canales y un manejo del hijuelo acertado. Las imágenes que pertenecen al parámetro de población media y alta de plantas de banano mostraron una cobertura vegetal superior al 50% dentro de la cual se observó arvenses y un distanciamiento entre plantas afectado por la presencia de más de un hijuelo por planta madre, deduciendo que la práctica del deshijado hallado no es uniforme afectando indirectamente la cuantificación por parte de ambas técnicas, al no permitir detectar por la gran cantidad de biomasa que se genera, el número real de plantas.

Al aplicarse la herramienta de *clasificación no supervisada* sobre las imágenes de submuestra, en todos los casos encasilló la copa o el centro de las plantas donde se ubica la hoja bandera como una clase en particular, la cual se identificó como el cuerpo

de mayor vigorosidad en cuanto a la cobertura vegetal detectada, esto ocurrió ya que la hoja bandera es la parte de la planta que más tarda en ser afectada por enfermedades, provocando que en caso de haber daños de este tipo, ésta mantenga su verdor por mayor tiempo en relación a las otras clases [52].

La técnica expuesta presentó limitaciones para detectar o identificar plantas en deterioro de su verdor, debido a que, la herramienta de *clasificación no supervisada* generó las clases de los distintos elementos en la imagen aérea, a partir del índice de vegetación GVI; el cual, asignó valores en dependencia de la vigorosidad de la cobertura vegetal. Si el elemento de interés para detectar una unidad de planta de banano es la hoja bandera y ésta presentó deterioro en su verdor como se muestra en la Figura 3.18 causado por deficiencias nutricionales, mal manejo del riego o por la presencia de plagas y enfermedades, no fue considerada dentro de su clase y, por tanto, no se cuantificó.



**Figura 3.18 Error en detección de plantas con menor verdor (círculos negros).**

El objetivo del proyecto buscó cuantificar la densidad poblacional del cultivo de banano, considerándose los diferentes estadios o etapas fenológicas en los que se encontró la planta. Sin embargo, se evidencian casos como en la

Figura 3.19 en los que no se aprecian con éxito todas las plantas de banano en las imágenes aéreas, puesto que, las plantas de mayor dominancia cubren parte de las plantas de menor altura, no logrando ser detectadas y por ende cuantificadas.



**Figura 3.19 Error en detección de plantas de menor altura (círculos amarillos).**

### 3.2.3 Comparación entre técnicas

Con la muestra de 50 imágenes que fueron seleccionadas del ortomosaico obtenido a partir de las imágenes de UAV, se procedió a hacer una valoración de los resultados con ambas técnicas. En la Tabla 3.1 se muestra el resumen de los resultados de ambas técnicas considerando TP (verdaderos positivos), TF (verdaderos negativos), FP (false positive), FN (falsos negativos), y *IoU score*.

**Tabla 3.1 Resumen de técnicas SIG y aprendizaje profundo.**

Técnica	Original	Predicción	TP	FP	FN	<i>IoU Score</i>
SIG	1069	1181	1010	171	59	0.81
Aprendizaje profundo	1069	1040	949	217	91	0.76

Ambas técnicas tienen *IoU Score* cercanos, siendo solo 5% mejor la técnica de SIG. Sin embargo, se debe tener en cuenta que la técnica SIG se basó en detectar la hoja bandera según su verdor, mientras que con aprendizaje profundo se etiquetó completamente toda la planta haciendo que el modelo aprenda color y forma, lo cual afectó en la detección de falsos negativos cuando las plantas se ubican en los bordes o no se ven completas debido al traslape de las plantas y en los falsos positivos al cuantificar especies con morfología semejante.

La detección mediante las técnicas SIG pudo detectar la planta ubicando la hoja bandera o la copa del banano, en dependencia de su vigor logrando reconocer plantas ubicadas en los bordes de las imágenes o en donde hay una densidad poblacional alta,

lo que con aprendizaje profundo es una limitante. Sin embargo, con aprendizaje profundo se logró detectar plantas en distintos estados (saludables, enfermas) lo cual con SIG en el caso de presentar afectaciones no las detecta.

### 3.3 Mapas de Vigor

Los valores de GLI como se muestra en la leyenda del mapa de la Figura 3.20, oscilaron de [-0.05, 0.25] donde se categorizó áreas urbanas, cuerpos de agua y vegetación en dependencia de su vigor; valores cercanos a 1 hacen referencia a altos niveles de vigor. GLI es ideal para identificar enfermedades que afectan la parte aérea de las plantas [53]; en el caso de estudio se encontró que cerca del 16% del total de plantas no se detectaron por el deterioro de verdor en las hojas, pudiendo atribuirse a afectaciones por deficiencias de micronutrientes como Mg, S, Zn y B ya que en ausencia provocan decoloración y deformaciones foliares [54], o en su defecto por la presencia de enfermedades que causen síntomas de este tipo; la aplicación de diagnósticos in situ o análisis en laboratorio son útiles para corroborar agentes causales o deficiencias nutricionales [55], definiendo así las causas frente al cuadro sintomático que presentan algunas plantas.

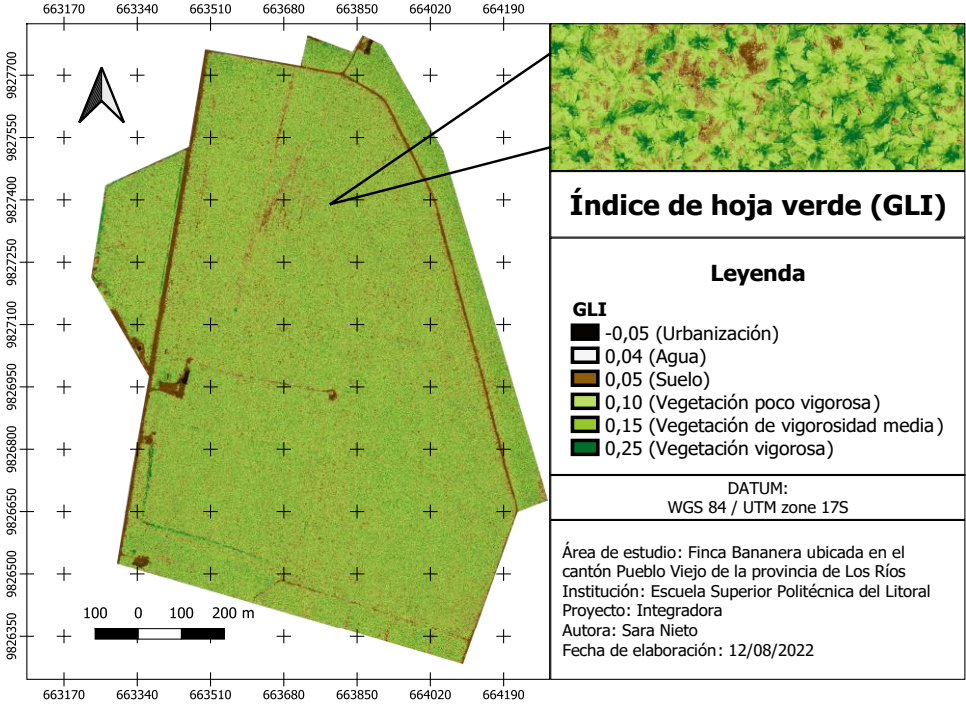


Figura 3.20 Índice de hoja verde (GLI).

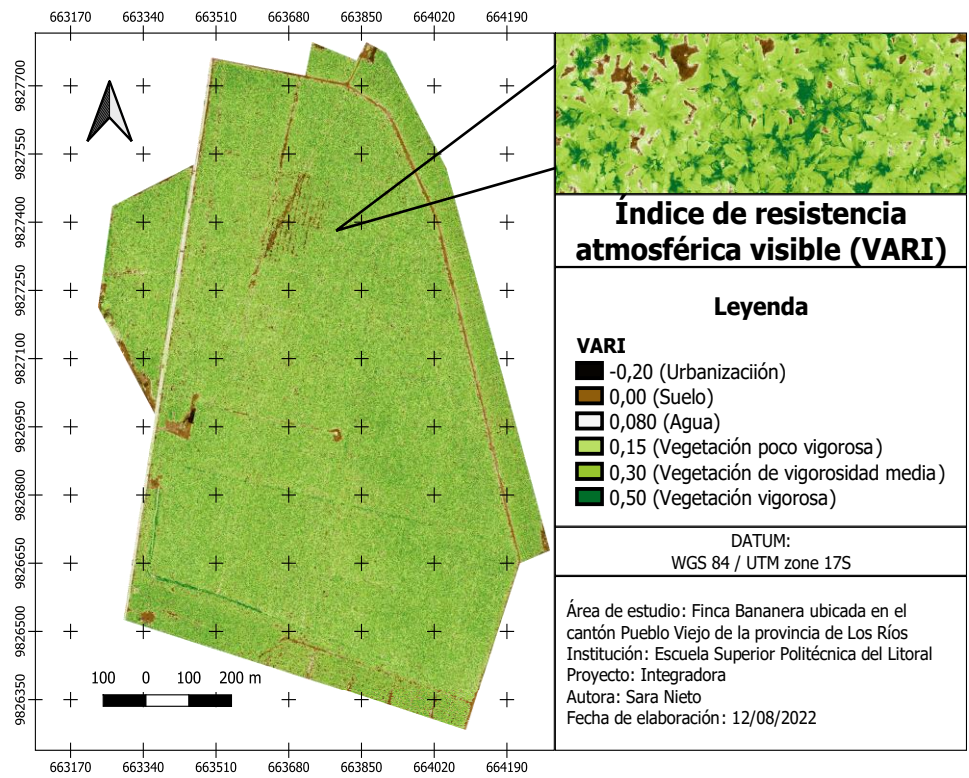


Figura 3.21 Índice de resistencia atmosférica visible (VARI)

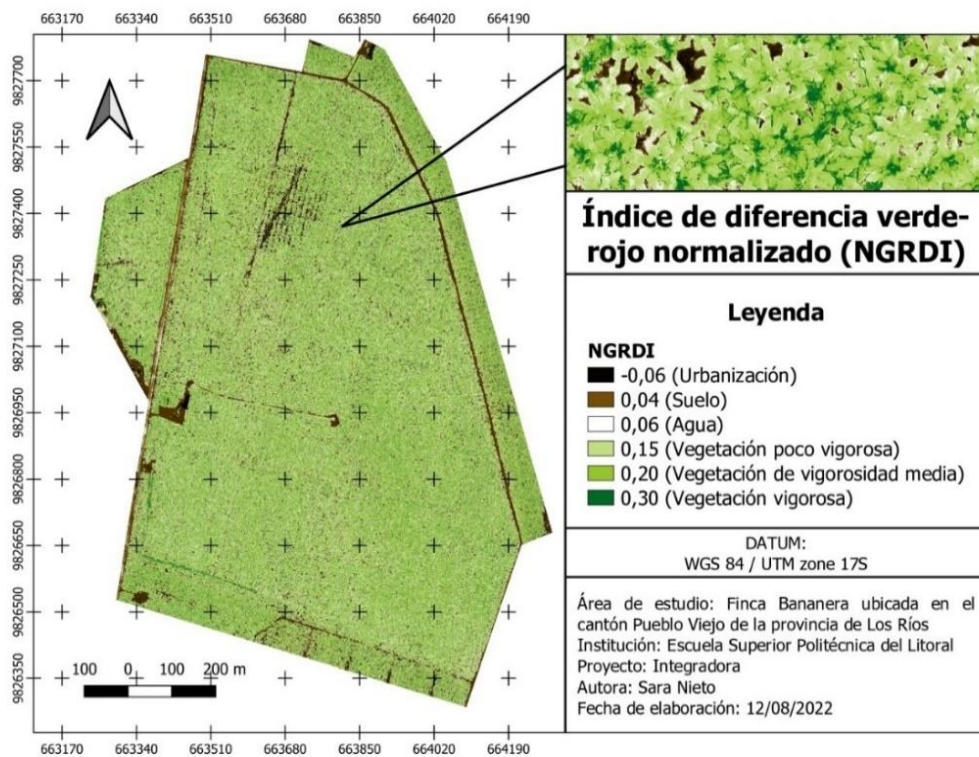


Figura 3.22 Índice de diferencia verde-rojo normalizado (NGRDI).

Los índices VARI de la Figura 3.21 y NGRDI de la Figura 3.22 asignó rangos de valores de [-0.20, 0.50] y [-0.06, 0.30] respectivamente, categorizando las coberturas que se observan en las leyendas de cada mapa. Ambos índices son buenos estimadores del contenido de Nitrógeno en las plantas [24], se podría aseverar, según los mapas obtenidos que las dosis nitrogenadas suministradas a las plantas de banano son aceptables y no hay deficiencias, ya que, predomina una vegetación medianamente vigorosa en ambos índices.

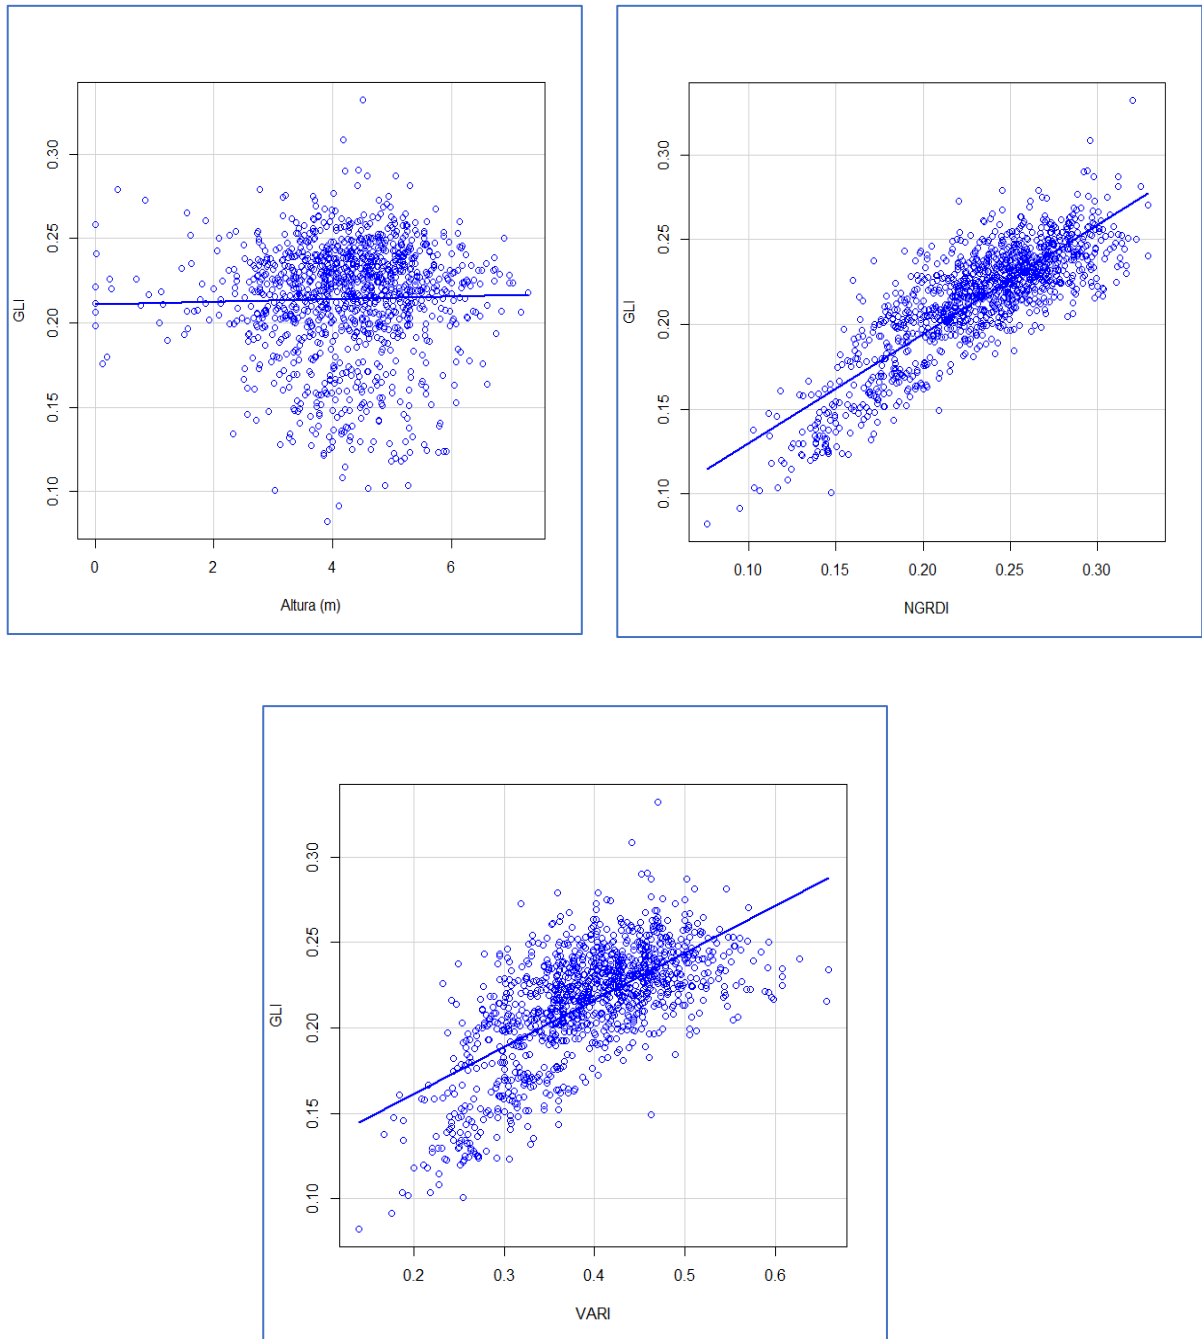
El cálculo de los índices de vegetación mostró que los valores de GLI, VARI y NGRDI difieren al caracterizar la cobertura vegetal, el suelo, cuerpos de agua y urbanización. Además, la asignación de la simbología permitió visualizar que valores representaban con mayor precisión la cobertura vegetal clasificándolas a partir de la intensidad de su verdor, resultando ser la hoja bandera el elemento de mayor vigorosidad en la planta y, por tanto, de mayor valor numérico.

Comúnmente el índice GLI asigna valores bajos de vigorosidad respecto a las imágenes que analiza [56], esto se evidenció en la generación de los mapas, puesto que clasificó la vegetación con valores inferiores en comparación con los índices NGRDI y VARI. Sin embargo, el índice que clasificó con mayor fidelidad la cobertura vegetal del ortomosaico fue GLI, diferenciándolo exitosamente de los demás cuerpos de la imagen, a diferencia de los índices VARI y NGRDI que presentaron valores de cobertura vegetal que coincide con ambientes urbanos como carreteras y autos.

### **3.4 Análisis estadístico**

Los diagramas de dispersión de la Figura 3.23 obtenidos a partir de los valores extraídos que se muestran en el Apéndice A

, indicaron que la variable altura no presenta una relación lineal con el índice GLI, por lo que su información no predice ni estima la cobertura vegetal en plantaciones de banano, en cuanto a, VARI y NGRDI, presentan una correlación positiva.



**Figura 3.23 Diagramas de dispersión.**

Según la Tabla 3.2 Con un 95% de confianza, hay evidencia estadística suficiente para afirmar que existe una relación lineal entre las variables GLI, NGRDI y VARI. En el caso de las variables de GLI y altura de plantas el valor  $p$  es mayor que 0.05, lo que indica que no existe una relación lineal.

**Tabla 3.2 Resultados del test de correlación.**

<b>Variables</b>	<b>Estadístico de prueba</b>	<b>Grados de libertad</b>	<b>Valor p</b>
GLI y Altura de plantas	0.82524	1179	0.4094
GLI y VARI	30.098		< 2.2e-16
GLI y NGRDI	51.59		< 2.2e-16

La altura de plantas no presentó una correlación con la variable predictora GLI, pudiendo deberse a que el estudio abarco el conteo en cualquier etapa fenológica del banano, por lo que se consideró plantas en etapa vegetativa, reproductiva y productiva, donde existe una alta variabilidad del vigor de las plantas que afecta el comportamiento de las respuestas espectrales [57], dado que se ven influenciadas por diferentes picos en la acumulación de materia seca y contenido de clorofila en dependencia de la etapa en la que se encuentre la planta. Al no especificarse un rango de alturas o clasificar el conteo en función del estadio en el que se encuentre la planta, los datos obtenidos no siguieron un patrón lineal de su verdor.

El coeficiente de correlación de 0.8325 de la Tabla 3.3 indica que la variable GLI presenta mayor afinidad con NGRDI en comparación a VARI, sin embargo, ambos presentan limitaciones para solo categorizar vegetación, ya que les asignan los mismos valores a ambientes urbanos como carreteras y autos Figura 3.24.

**Tabla 3.3 Resultado del análisis relacional.**


	<b>GLI</b>			
	<b>r</b>	<b>R<sup>2</sup></b>	<b>Ecuación de la recta</b>	<b>RMSE</b>
<b>Altura</b>	0.0240	0.0006	$y=0.0007392x+0.21113$	4.18295
<b>NGRDI</b>	0.8325	0.6928	$y=0.64391x+0.06581$	0.02947
<b>VARI</b>	0.6592	0.4345	$y=0.275393x+0.10635$	0.18892

Según un estudio donde se evaluó la cobertura vegetal observada por los índices de vegetación para el espectro visible en maíz [58], se observó que NGRDI presentó un



error mínimo en la estimación de la vegetación del 1.8% puesto que el índice es sensible a las primeras etapas de crecimiento de la planta por lo que posiblemente le asigne valores de vigor durante ese estadio a otras coberturas que no correspondan a la vegetación; VARI presento la misma limitación pero con un menor desempeño en la estimación de cobertura vegetal, esto ocurre porque VARI es sensible a los cambios del cultivo en diferentes etapas de crecimiento, siendo una de las causas por las que VARI al estar influenciada en el análisis de un conjunto de población de banano en cualquier edad, presentó valores erróneos para asignar la vegetación de las imágenes de submuestra.

Asimismo, un estudio evaluó los índices espectrales RGB para la identificación de coberturas vegetales [23] en ambientes urbanos y rurales, se demostró que NGRDI y VARI asocian valores de vegetación a otros elementos identificados como suelo desnudo y sombras, situación que ocurre en el presente caso de estudio, ya que, se asignó valores de cobertura vegetal a otros cuerpos que no corresponden, sean estas áreas oscuras (ventanas de autos) y suelos desnudos como se observa en la Figura 3.24.



*Nota: de izquierda a derecha: Imagen real, GLI, NGRDI y VARI*

**Figura 3.24 Errores de VARI y NGRDI en la categorización de la cobertura vegetal.**

En el siguiente capítulo se discutirán las conclusiones en base a la comparación de las dos técnicas, SIG y aprendizaje profundo, para concluir cuál de las dos es más efectiva localizando y cuantificando plantas de banano. También se darán recomendaciones para proyectos similares al actual proyecto y propuestas de futuros proyectos que se podrían implementar en base a partir del mismo.

# CAPÍTULO 4

## 4. CONCLUSIONES Y RECOMENDACIONES

En este capítulo se discute las conclusiones a partir de los resultados obtenidos en la predicción del área y cuantificación de plantas de banano mediante técnicas SIG y de aprendizaje profundo. Además, se detalla recomendaciones para proyectos con características similares.

### 4.1 Conclusiones

- Al realizar las predicciones con el modelo de segmentación semántica, se observó que *Jaccard Loss* dio un valor alto. Esto implica que casi la mitad de la predicción es errónea. Esto se debe a que las predicciones del *Jaccard Loss* comparan la curvatura de las plantas de banano con máscaras del área. Dichas máscaras se organizan por medio de rectángulos y no consideran la curvatura.
- Al realizar las predicciones con el modelo de segmentación semántica, se observó que el valor de *IoU Score* fue alto. Esto significa que el modelo incluye un área que puede exceder la ocupada por las plantas de banano.
- Los resultados obtenidos por segmentación semántica fueron afectados por la forma en la que se etiquetó las plantas de banano. Dado que se etiquetó por medio de rectángulos en vez de polígonos. Esta última figura permite especificar la forma exacta de los bordes, mientras que los rectángulos no se ajustaron a la forma de las plantas.
- El resultado de cuantificación de plantas de banano mediante técnicas SIG presenta un 81% de *IoU Score*. Esto evidencia dificultades para detectar con éxito plantas con vigorosidad baja, es decir, permite la cuantificación de las plantas de banano cuando éstas están sanas o medianamente sanas, limitando el análisis en plantas con fuertes afectaciones cloróticas. Por otro lado, la técnica de aprendizaje profundo logra el 76% de *IoU Score*. Resultó 5% menor que SIG, debido a que, no detecta plantas en los bordes de las imágenes o plantas extremadamente pequeñas. SIG requiere el ajuste de valores de forma

manual (depuración de polígonos), lo que lo hace muy sensible a variaciones en los resultados.

- El análisis relacional demostró que la variable altura no es un potencial recurso para estimar la cobertura vegetal en banano. El índice de vegetación NGRDI es el que mejor se ajusta a la variable predictora GLI. De igual manera, VARI presenta una linealidad significativa, pero de menor grado. El motivo es que no categoriza correctamente la cobertura vegetal, al asociarla con zonas expuestas a sombras.
- La práctica del deshijado en este caso de estudio no es uniforme. Se encontró lotes de producción donde predominan dos hijuelos por planta de banano. Esto afectó indirectamente la cuantificación por parte de ambas técnicas, al no permitir detectar, por la gran cantidad de biomasa que se genera, el número real de plantas.

#### **4.2 Recomendaciones**

- Antes de realizar el etiquetado de las imágenes consultar con un experto en identificar el tipo de objeto que se quiere localizar y cuantificar para evitar falsos positivos y falsos negativos por mal etiquetado y reincidir en corregir el etiquetado.
- Se recomienda evaluar cual es la mejor forma de etiquetar con respecto a la segmentación semántica, dado que puede ser que la forma en la que se etiquetó no fue la óptima para el modelo.
- Para la cuantificación de plantas de banano mediante técnicas SIG, se recomienda ir a campo para hacer una inspección del promedio de las alturas, para una mejor entrega de resultados, clasificando el número de plantas que corresponden a las plantas madre y el número de plantas que representan los hijuelos o discriminándolos de no ser del interés del productor.
- Para la cuantificación de plantas de banano mediante aprendizaje profundo, se recomienda ser riguroso con el etiquetado y ser lo más equitativo posible en cuanto a ciertas características de las plantas como son: desarrollo (pequeñas, medianas, grandes), distribución (muy cercanas, medianamente cercanas, separadas), estado (sanas, enfermas). Además, puede usarse otro tipo de etiquetado.

### **4.3 Trabajos futuros**

Esta sección tiene como propósito dar a conocer proyectos que puedan nacer a partir del presente proyecto por medio de mejoras, dándole un enfoque distinto al que se tomó, o en base a dudas que surgieron mientras se investigaba.

#### **4.3.1 Etiquetado en forma de polígono**

En base a los resultados que se obtuvieron en el presente proyecto con respecto a la segmentación semántica surgió la duda de si etiquetar mediante rectángulos era la forma óptima para realizar el etiquetado, dado esto se propone realizar una investigación para verificar si etiquetar mediante polígonos tiene una diferencia significativa contra etiquetar las plantas de banano mediante rectángulos.

#### **4.3.2 Evaluar plantaciones de diferente tipo**

Como esta investigación se basó específicamente en segmentar área, localizar y cuantificar plantas de banano sería interesante mediante el uso de la misma metodología de etiquetado, entrenamiento y evaluación, entrenar a los modelos con un *dataset* que contenga imágenes aéreas con otro tipo de cultivo. Este proyecto evaluaría si los resultados que se dieron en el presente proyecto se dieron debido al tipo de cultivo que se trató de segmentar, localizar y cuantificar y no por el tipo de metodología que se utilizó.

# BIBLIOGRAFÍA

- [1] Ministerio de Comercio Exterior, «Informe Sector Bananero Ecuatoriano,» 12 2017. [En línea]. Available: <https://www.produccion.gob.ec/wp-content/uploads/2019/06/Informe-sector-bananero-espac%C3%B1ol-04dic17.pdf>. [Último acceso: 07 2022].
- [2] C. Hub Bajío, «La importancia de una densidad de siembra óptima,» Julio 2021. [En línea]. Available: <https://idp.cimmyt.org/la-importancia-de-una-densidad-de-siembra-optima/#:~:text=La%20densidad%20de%20siembra%20es,consecuentemente%2C%20un%20alto%20rendimiento%E2%80%9494.> [Último acceso: 2022].
- [3] INEC, «Encuesta de Superficie y Producción Agropecuaria Continua 2020 Contenido,» 5 2020. [En línea]. Available: [https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas\\_agropecuarias/espac/espac-2020/Presentacion%20ESPAC%202020.pdf](https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_agropecuarias/espac/espac-2020/Presentacion%20ESPAC%202020.pdf). [Último acceso: 06 2022].
- [4] CFN, «Agricultura e industria manufacturera: cultivo de bananos y plátanos. venta al por mayor de banano y plátano,» Agosto 2021. [En línea]. Available: <https://www.cfn.fin.ec/wp-content/uploads/downloads/biblioteca/2021/fichas-sectoriales-3-trimestre/Ficha-Sectorial-Banano.pdf>. [Último acceso: 2022].
- [5] INIAP, «Banano,» 2014. [En línea]. Available: <http://tecnologia.iniap.gob.ec/index.php/explore-2/mmusa/rbanano>. [Último acceso: 06 2022].
- [6] I. Cisternas, I. Velásquez, A. Caro y A. Rodríguez, «ScienceDirect,» *Computers and Electronics in Agriculture*, vol. 176, p. 105626, 2020.
- [7] María Fernanda Cuevas-Rivera, Gema Matzil Olguin-Utrera, Andrés Lira-Noriega y Randy Ortiz-Castro, «Agricultura de precisión, análisis de imágenes aplicada a la producción agrícola,» 2021. [En línea]. Available: <https://www.inecol.mx/inecol/index.php/es/ct-menu-item-1/redes-tematicas/17-ciencia-hoy/1431-agricultura-de-precision-analisis-de-imagenes-aplicada-a-la-produccion-agricola>. [Último acceso: 06 2022].

- [8] P. Rodolfo Bongiovanni, P. Evandro Chartuni Mantovani, P. Stanley Best y P. Álvaro Roel, «Agricultura de precisión,» 2006. [En línea]. Available: <http://www.gisandbeers.com/RRSS/Publicaciones/Agricultura-Moderna-Precision.pdf>. [Último acceso: 06 2022].
- [9] J. Veneros, L. García, E. Morales, V. Gómez, M. Torres y F. López-Morales, «Aplicación de sensores remotos para el análisis de cobertura vegetal y cuerpos de agua,» *Idesia (Arica)*, vol. 38, nº 4, pp. 99-107, 2020.
- [10] Rodolfo Ríos Hernández \* y C. GEOCUBA Investigación y consultoría, «La Agricultura de Precisión. Una necesidad actual,» 2020. [En línea]. Available: <https://www.redalyc.org/journal/5862/586269368010/html/>. [Último acceso: 2022].
- [11] DJI, «Category:Taken with DJI FC6310,» 2018. [En línea]. Available: <https://truevirtualtours.com/panoramas/list?sort=-rating&tagged=dji-phantom-4-pro>. [Último acceso: 2022].
- [12] ESRI, «¿Qué son los SIG? | Tecnología de representación cartográfica con sistemas de información geográfica,» 28 09 2021. [En línea]. Available: <https://www.esri.com/es-es/what-is-gis/overview>. [Último acceso: 26 07 2022].
- [13] M. N. Gebeyehu y others, «Remote sensing and GIS application in agriculture and natural resource management,» *International Journal of Environmental Sciences & Natural Resources*, vol. 19, nº 2, pp. 45--49, 2019.
- [14] H. Pathak, C. Igathinathane, Z. Zhang, D. Archer y J. Hendrickson, «A review of unmanned aerial vehicle-based methods for plant stand count evaluation in row crops,» *Computers and Electronics in Agriculture*, vol. 198, p. 107064, 05 2022.
- [15] G. Meinel y M. Neubert, «A comparison of segmentation programs for high resolution remote sensing data,» *International Archives of Photogrammetry and Remote Sensing*, vol. 35, nº Part B, pp. 1097-1105, 2004.
- [16] P. Tong, P. Han, S. Li, N. Li, S. Bu, Q. Li y K. Li, «Counting trees with point-wise supervised segmentation network,» *Engineering Applications of Artificial Intelligence*, vol. 100, p. 104172, 4 2021.
- [17] Pedro Muñoz, «Apuntes de Teledetección: Índices de vegetación,» 2013. [En línea]. Available: [https://www.researchgate.net/publication/327558326\\_Apuntes\\_de\\_Teledeteccion\\_Indices\\_de\\_vegetacion](https://www.researchgate.net/publication/327558326_Apuntes_de_Teledeteccion_Indices_de_vegetacion). [Último acceso: 06 2022].

- [18] M. A. Gilabert, J. Gonzalez-Piqueras y J. García-Haro, «Acerca de los índices de vegetación View project LSA SAF View project,» 1997. [En línea]. Available: <http://www.ermes-fp7space.eu/en/homepage/>. [Último acceso: 07 2022].
- [19] A. A. Gitelson, Y. J. Kaufman, R. Stark y D. Rundquist, «Novel algorithms for remote estimation of vegetation fraction,» *Remote Sensing of Environment*, vol. 80, nº 1, pp. 76-87, 4 2002.
- [20] N. Gobron, B. Pinty, M. M. Verstraete y J. L. Widlowski, «Advanced vegetation indices optimized for up-coming sensors: design, performance, and applications,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, nº 6, pp. 2489-2505, 11 2000.
- [21] C. J. Tucker, «Red and photographic infrared linear combinations for monitoring vegetation,» *Remote Sensing of Environment*, vol. 8, nº 2, pp. 127-150, 5 1979.
- [22] ADSU Filmaciones, «Herramientas de Análisis,» 2016. [En línea]. Available: <http://sitioftp.com/ADSU/herramientas-analisis.pdf>. [Último acceso: 07 2022].
- [23] M. Novara, S. Estergaard, D. Olmos, J. Rasjido y A. Soto, «Comparación de índices espectrales RGB, a partir de imágenes VANT, para la identificación de coberturas vegetales en ambientes urbanos y rurales patagónicos esteparios,» 15 Noviembre 2019. [En línea]. Available: [https://www.researchgate.net/publication/337292177\\_Comparacion\\_de\\_indices\\_espectrales\\_RGB\\_a\\_partir\\_de\\_imagenes\\_VANT\\_para\\_la\\_identificacion\\_de\\_coberturas\\_vegetales\\_en\\_ambientes\\_urbanos\\_y\\_rurales\\_patagonicos\\_esteparios](https://www.researchgate.net/publication/337292177_Comparacion_de_indices_espectrales_RGB_a_partir_de_imagenes_VANT_para_la_identificacion_de_coberturas_vegetales_en_ambientes_urbanos_y_rurales_patagonicos_esteparios). [Último acceso: 26 07 2022].
- [24] U. Lussem, A. Bolten, M. Gnyp, J. Jasper y G. Bareth, «Evaluation of RGB-based vegetation indices from UAV imagery to estimate forage yield in grassland,» *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 42, nº 3, p. 1215, 2018.
- [25] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu y M. S. Lew, «Deep learning for visual understanding: A review,» *Neurocomputing*, vol. 187, pp. 27-48, 2016.
- [26] H. S. Abdullahi and R. E. Sheriff, "Chapter 3 - Introduction to deep learning in precision agriculture: Farm image feature detection using unmanned aerial vehicles through classification and optimization process of machine learning with convolution neural network," in *Deep Learning for Sustainable Agriculture*, R. C. Poonia, V. Singh and S. R. Nayak, Eds., Academic Press, 2022, pp. 81-107.



- [27] E.-i. Jeon, S. Kim, S. Park, J. Kwak y I. Choi, «Semantic segmentation of seagrass habitat from drone imagery based on deep learning: A comparative study,» *Ecological Informatics*, vol. 66, p. 101430, 21 Septiembre 2021.
- [28] O. Ronneberger, P. Fischer y T. Brox, «U-net: Convolutional networks for biomedical image segmentation,» de *International Conference on Medical image computing and computer-assisted intervention*, 2015, pp. 234-241.
- [29] A. Chaurasia y E. Culurciello, «Linknet: Exploiting encoder representations for efficient semantic segmentation,» de *2017 IEEE Visual Communications and Image Processing (VCIP)*, 2017, pp. 1-4.
- [30] N. V. Anantha, P. Rizwan, K. M. Sunil y S. Kallam, «<https://www.researchgate.net>,» Septiembre 2020.
- [31] J. Brownlee, «Machine Learning Mastery,» 2 Enero 2021. [En línea]. Available: <https://machinelearningmastery.com/object-recognition-with-deep-learning/#:~:text=Object%20localization%20refers%20to%20identifying,more%20objects%20in%20an%20image..> [Último acceso: 10 Julio 2022].
- [32] A. Lohia, K. D. Kadam, R. R. Joshi, A. M. Bongale y M. Anupkumar, «Bibliometric Analysis of One-stage and Two-stage Object Detection,» *Library Philosophy & Practice*, vol. 4910, 2021.
- [33] P. Soviany y R. T. Ionescu, «Optimizing the trade-off between single-stage and two-stage deep object detectors using image difficulty prediction,» de *2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*, 2018, pp. 209-214.
- [34] S. Ren, K. He, R. Girshick y J. Sun, «Faster r-cnn: Towards real-time object detection with region proposal networks,» *Advances in neural information processing systems*, vol. 28, 2015.
- [35] J. Solawetz, «roboflow,» 29 Junio 2020. [En línea]. Available: <https://blog.roboflow.com/yolov5-improvements-and-evaluation/>. [Último acceso: 10 Julio 2022].
- [36] A. Bochkovskiy, C.-Y. Wang y H.-Y. M. Liao, «Yolov4: Optimal speed and accuracy of object detection,» *arXiv preprint arXiv:2004.10934*, 2020.
- [37] B. Neupane, «Deep Learning based Banana Plant Detection and Counting for UAV collected High Resolution RGB Images,» 11 Abril 2019. [En línea]. Available:

- <https://doi.org/10.6084/m9.figshare.7981547.v1>. [Último acceso: Septiembre 2022].
- [38] A. Ammar, A. Koubaa y B. Benjdira, «Deep-learning-based automated palm tree counting and geolocation in large farms from aerial geotagged images,» *Agronomy*, vol. 11, nº 8, p. 1458, 2020.
- [39] T. Jintasuttisak, E. Edirisinghe y A. Elbattay, «Deep neural network based date palm tree detection in drone imagery,» *Computers and Electronics in Agriculture*, vol. 192, p. 106560, Enero 2022.
- [40] Gobierno autonomo descentralizado cantón Pueblo Viejo, «Plan de desarrollo y ordenamiento territorial 2015-2025,» 2015. [En línea]. Available: [http://app.sni.gob.ec/sni-link/sni/PORTAL\\_SNI/data\\_sigad\\_plus/sigadplusdocumentofinal/1260023860001\\_PDyOT%20SAN%20JUAN%20ACTUALIZACION%202015\\_18-05-2016\\_08-12-31.pdf](http://app.sni.gob.ec/sni-link/sni/PORTAL_SNI/data_sigad_plus/sigadplusdocumentofinal/1260023860001_PDyOT%20SAN%20JUAN%20ACTUALIZACION%202015_18-05-2016_08-12-31.pdf). [Último acceso: 6 2022].
- [41] numpy, «numpy,» numpy, [En línea]. Available: <https://numpy.org/doc/stable/reference/generated/numpy.zeros.html>. [Último acceso: 17 Julio 2022].
- [42] doxygen, «docs.opencv.org,» opencv, [En línea]. Available: [https://docs.opencv.org/4.x/dc/da5/tutorial\\_py\\_drawing\\_functions.html](https://docs.opencv.org/4.x/dc/da5/tutorial_py_drawing_functions.html). [Último acceso: 8 julio 2022].
- [43] qubvel, «github.com,» 10 Enero 2020. [En línea]. Available: [https://github.com/qubvel/segmentation\\_models](https://github.com/qubvel/segmentation_models). [Último acceso: 17 julio 2022].
- [44] Keras, «keras,» Keras, [En línea]. Available: <https://keras.io/api/optimizers/adam/>. [Último acceso: 27 Julio 2022].
- [45] doxygen, «docs.opencv.org,» OpenCV, 7 Julio 2022. [En línea]. Available: [https://docs.opencv.org/3.4/d4/da8/group\\_\\_imgcodecs.html#ga288b8b3da0892bd651fce07b3bbd3a56](https://docs.opencv.org/3.4/d4/da8/group__imgcodecs.html#ga288b8b3da0892bd651fce07b3bbd3a56). [Último acceso: 8 Julio 2022].
- [46] Keras, «keras,» Keras, [En línea]. Available: [https://keras.io/api/models/model\\_training\\_apis/](https://keras.io/api/models/model_training_apis/). [Último acceso: 27 Julio 2022].
- [47] matplotlib, «matplotlib,» matplotlib, [En línea]. Available: [https://matplotlib.org/stable/api/\\_as\\_gen/matplotlib.pyplot.imshow.html](https://matplotlib.org/stable/api/_as_gen/matplotlib.pyplot.imshow.html). [Último acceso: 27 Julio 2022].

- [48] matplotlib, «matplotlib,» matplotlib, [En línea]. Available: [https://matplotlib.org/stable/api/\\_as\\_gen/matplotlib.pyplot.imshow.html](https://matplotlib.org/stable/api/_as_gen/matplotlib.pyplot.imshow.html). [Último acceso: 27 Julio 2022].
- [49] DJI, «Phantom 4 Pro - Product Information,» [En línea]. Available: <https://www.dji.com/phantom-4-pro/info>. [Último acceso: 07 2022].
- [50] Agisoft LLC, «Agisoft Metashape,» 2006. [En línea]. Available: <https://www.agisoft.com/>. [Último acceso: 18 Julio 2022].
- [51] Open Source Geospatial Foundation (OSGeo), «QGIS,» 06 2002. [En línea]. Available: <https://www.qgis.org/es/site/>. [Último acceso: 16 07 2022].
- [52] DANE, «Enfermedades y plagas del plátano (*Musa paradisiaca*) y el banano (*Musa acuminata*; *M sapientum*) en Colombia,» Septiembre 2016. [En línea]. Available: [https://www.dane.gov.co/files/investigaciones/agropecuario/sipsa/Bol\\_Insumos\\_sep\\_2016.pdf](https://www.dane.gov.co/files/investigaciones/agropecuario/sipsa/Bol_Insumos_sep_2016.pdf). [Último acceso: 09 2022].
- [53] V. Piscitelli, A. Felipe, W. César, R. Araújo y J. Dória, «Use of RGB images from unmanned aerial vehicle to estimate lettuce growth in root-knot nematode infested soil,» *Smart Agricultural Technology*, vol. 3, 28 Julio 2022.
- [54] J. E. Antonio López, «Manual de nutrición y fertilización de banano,» 2000. [En línea]. Available: [http://nla.ipni.net/ipniweb/region/nla.nsf/e0f085ed5f091b1b852579000057902e/c093707b0327c2fe05257a40005f359f/\\$FILE/N%20F%20Banano.002.002.pdf/N%20F%20Banano.pdf](http://nla.ipni.net/ipniweb/region/nla.nsf/e0f085ed5f091b1b852579000057902e/c093707b0327c2fe05257a40005f359f/$FILE/N%20F%20Banano.002.002.pdf/N%20F%20Banano.pdf). [Último acceso: 10 9 2022].
- [55] M. Riley, M. W. Williams y O. Maloy, «Diagnóstico De Enfermedades En Plantas,» 2002. [En línea]. Available: <https://www.apsnet.org/edcenter/disimpactmngmnt/casestudies/Pages/DiagnosticoEnfermedadesPlantas.aspx>. [Último acceso: 10 9 2022].
- [56] C. Ramirez, «Uso de un vehículo aéreo no tripulado como alternativa para evaluar el estado nutricional de una plantación de *Gmelina arborea*,» Septiembre 2019. [En línea]. Available: [https://repositoriotec.tec.ac.cr/bitstream/handle/2238/11154/uso\\_vehiculo\\_aereo\\_no\\_tripulado.pdf?sequence=1&isAllowed=y](https://repositoriotec.tec.ac.cr/bitstream/handle/2238/11154/uso_vehiculo_aereo_no_tripulado.pdf?sequence=1&isAllowed=y). [Último acceso: 07 2022].
- [57] O. Pardo, «Respuestas espectrales a la fertilización con nitrógeno y potasio en el cultivo del banano (*Musa AAA simmonds*), caso municipio zona bananera,» 2015.

[En línea]. Available:  
<https://repositorio.unal.edu.co/bitstream/handle/unal/56137/oscarfradiqueescobarparado.2015.pdf?sequence=1&isAllowed=y>. [Último acceso: 06 2022].

- [58] H. García-Martínez, H. Flores-Magdaleno, A. Khalil-Gardezi, R. Ascencio-Hernández, L. Tijerina-Chávez, M. A. Vázquez-Peña y O. R. Mancilla-Villa, «Estimación de la fracción de cobertura de la vegetación en maíz (*Zea mays*) mediante imágenes digitales tomadas por un vehículo aéreo no tripulado (UAV),» *Revista Fitotecnica Mexicana*, vol. 43, nº 4, p. 399, 2020.

# APÉNDICES

Apéndice A: Tabla de valores para el análisis relacional

Datos	GLI	NGRDI	VARI	Alturas	Datos	GLI	NGRDI	VARI	Alturas
1	0.2260	0.2679	0.4702	4.314	2	0.1962	0.2217	0.3863	3.765
3	0.2726	0.2982	0.4887	3.695	4	0.2292	0.2507	0.4217	4.063
5	0.2428	0.2721	0.4601	4.895	6	0.2008	0.1869	0.3024	3.992
7	0.2401	0.2968	0.5304	4.303	8	0.2487	0.2459	0.3833	3.452
9	0.2314	0.2803	0.4940	4.348	10	0.1545	0.1863	0.3441	4.042
11	0.2443	0.3154	0.5838	3.470	12	0.2169	0.2506	0.4380	2.943
13	0.2122	0.2630	0.4775	4.418	14	0.2169	0.2289	0.3842	3.571
15	0.1685	0.2091	0.3904	4.451	16	0.1344	0.1426	0.2561	3.713
17	0.2409	0.2802	0.4851	3.844	18	0.2177	0.2424	0.4163	2.805
19	0.2569	0.2757	0.4512	5.249	20	0.2245	0.2606	0.4556	2.592
21	0.2209	0.2641	0.4728	3.471	22	0.2131	0.2486	0.4384	3.146
23	0.2304	0.2675	0.4657	5.060	24	0.1693	0.1757	0.3038	3.338
25	0.2497	0.2717	0.4519	4.145	26	0.1793	0.1719	0.2866	3.101
27	0.2385	0.2716	0.4689	4.188	28	0.1478	0.1115	0.1774	2.921
29	0.2199	0.2534	0.4400	2.990	30	0.1900	0.1858	0.3085	2.672
31	0.1519	0.1844	0.3442	3.456	32	0.1763	0.1631	0.2689	3.347
33	0.2362	0.2617	0.4427	5.187	34	0.1628	0.1658	0.2856	4.523
35	0.2066	0.2497	0.4524	3.711	36	0.1886	0.1613	0.2578	3.742
37	0.2395	0.2575	0.4277	3.365	38	0.1673	0.1702	0.2922	3.269
39	0.2245	0.2504	0.4356	4.765	40	0.1387	0.1354	0.2358	3.762
41	0.1501	0.1429	0.2447	4.468	42	0.1935	0.2309	0.4179	2.596
43	0.2374	0.2621	0.4431	5.050	44	0.2099	0.2260	0.3837	2.906
45	0.2427	0.2863	0.4981	4.246	46	0.2024	0.2137	0.3620	3.360
47	0.2383	0.2943	0.5249	2.957	48	0.2099	0.2182	0.3657	3.643
49	0.2491	0.2809	0.4728	3.606	50	0.2031	0.1880	0.3023	3.158
51	0.1725	0.2152	0.4033	4.322	52	0.2367	0.2529	0.4174	3.835
53	0.1006	0.1470	0.2543	3.024	54	0.2019	0.2270	0.3947	4.194
55	0.2396	0.2909	0.5150	3.718	56	0.2269	0.2141	0.3388	4.265
57	0.2418	0.2881	0.5035	3.276	58	0.2016	0.2156	0.3636	4.345
59	0.2369	0.2569	0.4284	3.155	60	0.2116	0.2490	0.4406	2.116
61	0.2385	0.2748	0.4739	3.937	62	0.2192	0.2265	0.3749	3.932
63	0.2425	0.2776	0.4771	2.056	64	0.2155	0.2215	0.3680	3.456
65	0.2359	0.2668	0.4565	3.639	66	0.2228	0.2622	0.4619	3.041
67	0.1490	0.2087	0.4624	3.449	68	0.2025	0.2102	0.3541	3.339
69	0.1975	0.2176	0.3772	4.785	70	0.2262	0.2484	0.4145	2.671
71	0.1935	0.2304	0.4157	4.641	72	0.1505	0.1585	0.2803	3.737
73	0.2386	0.3040	0.5511	6.728	74	0.2085	0.1834	0.2888	2.405
75	0.2285	0.2608	0.4657	6.984	76	0.1903	0.2039	0.3495	3.133
77	0.2459	0.2931	0.5142	5.561	78	0.2454	0.2491	0.3980	2.816

79	0.2317	0.2707	0.4748	6.746	80	0.2100	0.2056	0.3333	3.307
81	0.2322	0.2775	0.4912	5.321	82	0.1890	0.1789	0.2948	3.997
83	0.2315	0.2772	0.4903	5.306	84	0.1879	0.1663	0.2670	3.799
85	0.2314	0.2756	0.4953	5.974	86	0.1867	0.1791	0.2966	2.862
87	0.1406	0.1645	0.3063	5.811	88	0.1693	0.1774	0.3077	3.098
89	0.2393	0.2707	0.4655	5.691	90	0.1525	0.1567	0.2731	4.527
91	0.2095	0.2521	0.4534	5.514	92	0.2054	0.2227	0.3808	4.773
93	0.2311	0.2586	0.4426	6.513	94	0.2083	0.2500	0.4469	5.545
95	0.2227	0.2590	0.4541	5.224	96	0.2289	0.2566	0.4378	4.311
97	0.2458	0.3093	0.5615	5.310	98	0.2021	0.2244	0.3905	6.037
99	0.2252	0.2762	0.4944	5.953	100	0.2013	0.2429	0.4370	6.027
101	0.2246	0.2475	0.4211	5.581	102	0.2310	0.2653	0.4564	6.463
103	0.2351	0.2962	0.5391	6.586	104	0.1297	0.1310	0.2309	3.998
105	0.2251	0.2690	0.4761	6.264	106	0.2209	0.2200	0.3592	6.165
107	0.1236	0.1570	0.3057	5.777	108	0.2474	0.2751	0.4594	5.728
109	0.1773	0.2061	0.3649	6.313	110	0.2469	0.2751	0.4620	5.566
111	0.2062	0.2209	0.3765	7.170	112	0.1703	0.1870	0.3283	5.021
113	0.2600	0.2830	0.4663	6.142	114	0.1718	0.1967	0.3517	3.181
115	0.2088	0.2695	0.5160	5.461	116	0.1713	0.1834	0.3182	5.325
117	0.2250	0.3107	0.6080	5.399	118	0.1296	0.1285	0.2269	4.695
119	0.2546	0.3009	0.5167	5.388	120	0.2319	0.2715	0.4757	5.308
121	0.2245	0.2792	0.5069	2.775	122	0.2034	0.2455	0.4428	6.268
123	0.2342	0.3113	0.6585	6.334	124	0.2456	0.2584	0.4219	4.567
125	0.2428	0.2878	0.5040	4.781	126	0.2049	0.2117	0.3537	3.213
127	0.2166	0.2537	0.4517	4.820	128	0.2104	0.1986	0.3193	3.102
129	0.1985	0.2338	0.4290	5.984	130	0.1181	0.1130	0.1994	4.983
131	0.1996	0.2642	0.5051	4.634	132	0.2274	0.2240	0.3601	3.338
133	0.2210	0.2877	0.5435	4.646	134	0.2263	0.2362	0.3900	4.222
135	0.2583	0.2845	0.4723	4.548	136	0.2350	0.2335	0.3715	3.912
137	0.1356	0.1718	0.3323	4.196	138	0.2043	0.1916	0.3101	3.306
139	0.2309	0.2649	0.4563	2.249	140	0.2019	0.2209	0.3818	3.759
141	0.2267	0.2779	0.4999	4.105	142	0.2171	0.2193	0.3616	3.433
143	0.2357	0.2667	0.4550	4.069	144	0.2028	0.2064	0.3444	2.473
145	0.2243	0.2746	0.4926	3.862	146	0.1343	0.1378	0.2437	4.157
147	0.2533	0.2850	0.4788	3.618	148	0.2333	0.2343	0.3770	3.629
149	0.2138	0.2610	0.4705	1.767	150	0.2115	0.1918	0.3041	0.006
151	0.2221	0.2629	0.4646	4.315	152	0.2324	0.2197	0.3469	4.459
153	0.2445	0.2888	0.5022	3.109	154	0.2201	0.2091	0.3342	3.975
155	0.2498	0.3020	0.5345	3.693	156	0.1977	0.2026	0.3410	2.858
157	0.1321	0.1701	0.3294	3.268	158	0.2158	0.2258	0.3781	3.032
159	0.1911	0.2393	0.4425	2.746	160	0.2084	0.2030	0.3322	3.181
161	0.1856	0.2305	0.4253	4.410	162	0.2196	0.2317	0.3867	3.586
163	0.1932	0.2084	0.3575	3.875	164	0.2004	0.1985	0.3288	3.580
165	0.1644	0.1602	0.2697	3.011	166	0.1995	0.1890	0.3043	2.343
167	0.1595	0.1803	0.3213	4.247	168	0.2051	0.2066	0.3433	3.305
169	0.1816	0.2230	0.4084	3.217	170	0.2303	0.2241	0.3579	3.900

171	0.1641	0.2019	0.3782	3.874	172	0.2279	0.2365	0.3863	3.841
173	0.1261	0.1449	0.2683	3.980	174	0.1377	0.1026	0.1669	4.249
175	0.1891	0.1900	0.3161	2.576	176	0.1486	0.1688	0.3069	4.213
177	0.2022	0.2345	0.4157	5.129	178	0.1462	0.1491	0.2605	4.145
179	0.2198	0.2539	0.4449	4.618	180	0.1575	0.1924	0.3601	3.538
181	0.2280	0.2497	0.4221	4.637	182	0.1630	0.1772	0.3112	4.746
183	0.2291	0.2626	0.4514	4.668	184	0.1711	0.1759	0.3001	4.579
185	0.2245	0.2495	0.4261	3.617	186	0.2202	0.2028	0.3185	1.997
187	0.2325	0.2911	0.5259	3.952	188	0.2244	0.2519	0.4290	5.507
189	0.2516	0.2677	0.4360	5.868	190	0.2356	0.2576	0.4308	5.013
191	0.1973	0.2270	0.3992	5.052	192	0.2208	0.2563	0.4474	5.125
193	0.1812	0.2289	0.4320	5.516	194	0.2303	0.2577	0.4388	5.188
195	0.2155	0.2458	0.4289	3.922	196	0.2117	0.2398	0.4161	4.698
197	0.2153	0.2693	0.4926	5.137	198	0.2029	0.2255	0.3924	4.493
199	0.1840	0.2106	0.3752	4.979	200	0.2317	0.2459	0.4080	4.937
201	0.2162	0.2464	0.4290	4.199	202	0.1710	0.2097	0.3872	4.415
203	0.2147	0.2511	0.4420	5.122	204	0.2323	0.2670	0.4596	4.326
205	0.2125	0.2857	0.5467	4.725	206	0.2436	0.2781	0.4672	4.855
207	0.2505	0.2825	0.4851	4.967	208	0.2099	0.2531	0.4548	5.026
209	0.1968	0.2481	0.4608	4.716	210	0.2378	0.2479	0.4073	4.298
211	0.2257	0.2709	0.4798	4.407	212	0.2233	0.2708	0.4866	3.847
213	0.1988	0.2431	0.4425	4.815	214	0.2075	0.2236	0.3806	4.106
215	0.2309	0.2580	0.4379	4.560	216	0.2162	0.2402	0.4118	4.957
217	0.2123	0.2672	0.4861	5.135	218	0.2195	0.2672	0.4803	4.889
219	0.2242	0.2914	0.5438	5.699	220	0.1960	0.2620	0.5052	5.556
221	0.2445	0.2989	0.5306	6.165	222	0.1248	0.1452	0.2704	4.329
223	0.2301	0.2619	0.4498	5.570	224	0.1558	0.1744	0.3140	4.846
225	0.2271	0.2994	0.5633	4.057	226	0.2210	0.2592	0.4586	2.773
227	0.1844	0.2519	0.4895	3.970	228	0.2563	0.2738	0.4417	4.059
229	0.2113	0.2429	0.4266	4.635	230	0.2488	0.2740	0.4544	4.901
231	0.1830	0.1827	0.3090	5.362	232	0.2038	0.2360	0.4173	4.971
233	0.2186	0.2237	0.3733	5.922	234	0.2229	0.2237	0.3664	2.896
235	0.2423	0.2698	0.4557	5.640	236	0.2623	0.2867	0.4702	5.181
237	0.1995	0.2458	0.4516	5.569	238	0.2385	0.2309	0.3656	3.252
239	0.2251	0.2570	0.4449	6.725	240	0.2503	0.2523	0.4023	5.180
241	0.2050	0.2326	0.4085	5.278	242	0.2481	0.2672	0.4433	4.190
243	0.2386	0.2699	0.4602	4.666	244	0.2549	0.2410	0.3691	4.482
245	0.2558	0.2989	0.5107	4.926	246	0.2257	0.2458	0.4149	3.862
247	0.2049	0.2827	0.5533	3.498	248	0.1367	0.1499	0.2701	3.658
249	0.1732	0.1917	0.3387	2.527	250	0.2337	0.2530	0.4219	3.258
251	0.2187	0.2495	0.4321	4.656	252	0.2426	0.2393	0.3819	5.050
253	0.2014	0.2018	0.3346	3.615	254	0.2209	0.2324	0.3932	4.536
255	0.2060	0.2115	0.3531	4.155	256	0.2200	0.2065	0.3287	0.267
257	0.1939	0.2185	0.3827	5.109	258	0.1228	0.1385	0.2553	5.035
259	0.1923	0.1901	0.3151	3.205	260	0.2361	0.2715	0.4669	4.676
261	0.2471	0.2534	0.4080	4.545	262	0.2171	0.2375	0.4042	2.350

263	0.2031	0.2495	0.4547	2.820	264	0.2115	0.2263	0.3843	1.865
265	0.2189	0.2239	0.3682	3.752	266	0.1479	0.1404	0.2394	3.351
267	0.1799	0.1782	0.3005	3.051	268	0.2009	0.1943	0.3177	2.388
269	0.2086	0.2512	0.4489	4.305	270	0.1340	0.1118	0.1885	2.322
271	0.1982	0.2091	0.3534	4.531	272	0.2047	0.1858	0.2975	2.089
273	0.2138	0.2447	0.4263	3.692	274	0.2020	0.1756	0.2775	1.917
275	0.2278	0.2028	0.3151	2.382	276	0.2028	0.1984	0.3255	3.031
277	0.2472	0.2546	0.4132	3.241	278	0.2112	0.1801	0.2757	1.135
279	0.2364	0.2263	0.3580	2.795	280	0.2070	0.1896	0.3035	1.663
281	0.2398	0.2216	0.3467	3.384	282	0.2788	0.2661	0.4034	0.373
283	0.2271	0.2265	0.3639	3.667	284	0.2574	0.3094	0.5383	3.516
285	0.2154	0.2335	0.3937	3.191	286	0.2212	0.2210	0.3601	3.919
287	0.2267	0.2173	0.3453	3.335	288	0.1381	0.1384	0.2427	4.228
289	0.2321	0.2419	0.3971	2.699	290	0.2079	0.2165	0.3650	3.759
291	0.2247	0.2843	0.5232	2.151	292	0.2129	0.2398	0.4158	3.785
293	0.2339	0.2200	0.3496	3.192	294	0.2127	0.2210	0.3687	3.537
295	0.2193	0.2338	0.3933	2.637	296	0.1950	0.1937	0.3228	4.398
297	0.2308	0.2592	0.4408	4.237	298	0.1341	0.1404	0.2518	3.289
299	0.1897	0.1915	0.3221	1.211	300	0.2167	0.2340	0.3951	3.912
301	0.1303	0.1383	0.2499	4.287	302	0.2399	0.2591	0.4303	4.581
303	0.1728	0.1963	0.3493	2.762	304	0.2159	0.2310	0.3925	3.389
305	0.1537	0.1517	0.2618	3.406	306	0.2345	0.2626	0.4479	4.276
307	0.1581	0.1309	0.2122	3.911	308	0.1432	0.1465	0.2575	4.475
309	0.1996	0.1832	0.2921	2.261	310	0.2119	0.2513	0.4474	3.863
311	0.1941	0.1912	0.3174	3.622	312	0.2132	0.2432	0.4246	4.343
313	0.2224	0.2210	0.3599	3.332	314	0.2065	0.2449	0.4377	5.057
315	0.2177	0.2873	0.5424	5.674	316	0.1966	0.2502	0.4654	4.264
317	0.2450	0.2987	0.5270	6.148	318	0.2336	0.2539	0.4248	4.768
319	0.2298	0.3163	0.6074	5.417	320	0.2153	0.2340	0.3976	4.741
321	0.2508	0.3176	0.5691	4.770	322	0.1406	0.1380	0.2396	3.441
323	0.2390	0.2779	0.4860	4.513	324	0.2006	0.2333	0.4122	4.795
325	0.2206	0.3033	0.5929	5.703	326	0.1914	0.2241	0.4009	4.754
327	0.2565	0.2826	0.4662	4.136	328	0.2212	0.2680	0.4819	3.973
329	0.2334	0.2979	0.5447	4.574	330	0.2161	0.2785	0.5196	4.830
331	0.2391	0.3127	0.5758	5.190	332	0.1294	0.1439	0.2632	4.461
333	0.2342	0.2548	0.4275	3.022	334	0.2290	0.2537	0.4305	4.509
335	0.2156	0.2984	0.6571	5.378	336	0.2222	0.2096	0.3362	3.105
337	0.2188	0.2864	0.5445	5.438	338	0.2299	0.2101	0.3243	2.812
339	0.2343	0.3164	0.6079	5.705	340	0.2442	0.2595	0.4246	4.853
341	0.2289	0.2923	0.5370	5.592	342	0.2491	0.2350	0.3665	4.455
343	0.2676	0.2880	0.4561	5.736	344	0.2409	0.2374	0.3774	4.549
345	0.2389	0.2419	0.3958	4.497	346	0.2340	0.2340	0.3787	4.672
347	0.2285	0.2718	0.4805	4.775	348	0.2523	0.2836	0.4757	5.419
349	0.2178	0.3003	0.5963	5.492	350	0.2501	0.2337	0.3612	4.643
351	0.2445	0.2825	0.4872	4.357	352	0.2267	0.2006	0.3112	5.933
353	0.2445	0.2829	0.4848	4.764	354	0.2363	0.2362	0.3791	5.068



355	0.2525	0.3140	0.5607	4.761	356	0.2411	0.2552	0.4225	3.949
357	0.2523	0.2968	0.5254	4.815	358	0.2350	0.2730	0.4693	5.388
359	0.2665	0.3003	0.4994	4.039	360	0.1761	0.2159	0.3972	5.580
361	0.2404	0.3287	0.6267	6.240	362	0.2146	0.1874	0.2936	6.233
363	0.2192	0.2754	0.5036	5.479	364	0.1798	0.1623	0.2605	3.704
365	0.2165	0.3028	0.5983	5.034	366	0.2111	0.2135	0.3530	4.418
367	0.2258	0.2485	0.4257	4.605	368	0.2051	0.2020	0.3300	2.731
369	0.2241	0.2787	0.5089	6.221	370	0.1712	0.1848	0.3243	4.425
371	0.2416	0.2615	0.4378	5.221	372	0.2626	0.2968	0.5002	4.994
373	0.1996	0.2550	0.4748	4.594	374	0.2567	0.3009	0.5169	5.001
375	0.1990	0.2329	0.4363	5.261	376	0.2162	0.2282	0.3821	4.683
377	0.1927	0.2106	0.3656	5.020	378	0.2495	0.2652	0.4346	4.479
379	0.2706	0.3286	0.5705	4.908	380	0.2393	0.2113	0.3248	3.882
381	0.2504	0.3222	0.5923	5.548	382	0.2636	0.2841	0.4675	3.990
383	0.2316	0.2894	0.5209	5.159	384	0.2419	0.2516	0.4126	3.249
385	0.2421	0.2982	0.5289	4.553	386	0.2367	0.2665	0.4536	3.712
387	0.2249	0.2789	0.5076	3.633	388	0.2296	0.2177	0.3457	4.678
389	0.2321	0.2960	0.5373	4.550	390	0.1827	0.2240	0.4143	4.819
391	0.2354	0.2887	0.5107	5.328	392	0.2579	0.2944	0.5024	5.186
393	0.2464	0.2772	0.4659	5.157	394	0.2506	0.2595	0.4209	4.612
395	0.2338	0.2699	0.4657	6.193	396	0.2667	0.2971	0.5052	3.984
397	0.2386	0.2739	0.4698	5.376	398	0.2628	0.2902	0.4802	4.679
399	0.2289	0.2858	0.5130	5.627	400	0.2341	0.2952	0.5393	4.544
401	0.2282	0.2730	0.4819	4.730	402	0.2170	0.1942	0.3052	4.419
403	0.2602	0.2851	0.4691	5.585	404	0.1902	0.2241	0.4025	4.819
405	0.2135	0.2660	0.4873	6.044	406	0.1956	0.2017	0.3414	4.279
407	0.2479	0.3138	0.5545	5.970	408	0.2015	0.2142	0.3635	4.498
409	0.2063	0.2702	0.5069	6.407	410	0.2871	0.3116	0.5021	5.062
411	0.2386	0.2819	0.4907	4.261	412	0.2598	0.2970	0.5043	4.425
413	0.2240	0.2832	0.5181	4.421	414	0.2543	0.2210	0.3307	2.363
415	0.2542	0.2882	0.4827	4.273	416	0.2185	0.2061	0.3293	2.690
417	0.2477	0.2743	0.4572	5.160	418	0.2422	0.2164	0.3300	3.496
419	0.2425	0.2702	0.4549	4.309	420	0.2287	0.2075	0.3234	3.129
421	0.2396	0.2862	0.4996	5.044	422	0.2163	0.1635	0.2419	3.398
423	0.2480	0.3103	0.5550	4.018	424	0.2212	0.2045	0.3234	0.000
425	0.2424	0.3049	0.5420	5.272	426	0.2137	0.1656	0.2464	2.116
427	0.2569	0.2938	0.4982	4.195	428	0.2250	0.2053	0.3220	2.385
429	0.2346	0.2811	0.4938	5.221	430	0.2522	0.2270	0.3471	3.186
431	0.2580	0.2876	0.4749	5.247	432	0.2249	0.1993	0.3082	3.274
433	0.2227	0.2997	0.5725	3.767	434	0.2089	0.2349	0.4078	3.906
435	0.2276	0.2912	0.5281	4.979	436	0.2533	0.2481	0.3900	3.413
437	0.2519	0.3044	0.5317	4.845	438	0.2257	0.2317	0.3811	3.028
439	0.1631	0.2023	0.3772	6.057	440	0.2086	0.2096	0.3459	4.202
441	0.1619	0.1914	0.3461	5.575	442	0.2278	0.2122	0.3352	3.516
443	0.1762	0.2021	0.3622	4.432	444	0.1973	0.1544	0.2370	3.024
445	0.2211	0.3030	0.5884	3.846	446	0.2449	0.2313	0.3608	4.073

447	0.2446	0.3069	0.5495	4.461	448	0.2031	0.1910	0.3100	4.850
449	0.2291	0.2535	0.4301	4.188	450	0.2028	0.1825	0.2932	4.309
451	0.2167	0.2259	0.3761	5.244	452	0.2546	0.2535	0.4013	3.794
453	0.2257	0.2303	0.3779	3.881	454	0.2566	0.2550	0.4023	4.284
455	0.2520	0.2918	0.4961	5.062	456	0.2633	0.2556	0.3983	3.764
457	0.2323	0.2331	0.3798	4.825	458	0.2376	0.2493	0.4114	4.547
459	0.2261	0.2410	0.4026	2.989	460	0.2362	0.2589	0.4331	4.775
461	0.2289	0.2420	0.4016	4.791	462	0.1676	0.1831	0.3229	4.752
463	0.2306	0.2440	0.3995	4.844	464	0.2475	0.2522	0.4022	4.599
465	0.1020	0.1060	0.1936	4.598	466	0.2726	0.2611	0.4017	4.776
467	0.1796	0.1776	0.2981	3.722	468	0.2548	0.2511	0.3961	4.064
469	0.1909	0.1692	0.2704	3.430	470	0.2500	0.2191	0.3311	2.078
471	0.1741	0.1839	0.3170	4.800	472	0.1327	0.1434	0.2590	3.934
473	0.1803	0.2037	0.3659	2.996	474	0.2613	0.3016	0.5137	5.039
475	0.2039	0.1948	0.3154	3.287	476	0.2081	0.2650	0.4875	5.540
477	0.2091	0.2131	0.3527	5.183	478	0.2239	0.2459	0.4175	4.108
479	0.1980	0.2025	0.3390	3.845	480	0.2419	0.2488	0.4049	4.301
481	0.2205	0.2571	0.4519	3.347	482	0.2381	0.2679	0.4549	5.366
483	0.2195	0.2242	0.3691	5.490	484	0.2540	0.2794	0.4602	5.551
485	0.2521	0.2508	0.3963	5.231	486	0.2257	0.2636	0.4585	3.955
487	0.2240	0.2456	0.4104	4.985	488	0.1298	0.1256	0.2199	3.334
489	0.2435	0.2556	0.4185	5.188	490	0.2324	0.2528	0.4247	4.579
491	0.1236	0.1302	0.2341	5.304	492	0.2195	0.2335	0.3912	2.766
493	0.1880	0.2207	0.3947	4.928	494	0.1391	0.1519	0.2736	4.336
495	0.2157	0.2492	0.4345	4.935	496	0.2375	0.2806	0.4892	4.650
497	0.2308	0.2572	0.4379	5.138	498	0.2473	0.2737	0.4566	4.839
499	0.2104	0.2405	0.4178	6.604	500	0.2415	0.2286	0.3587	3.845
501	0.1602	0.1743	0.3091	4.640	502	0.1645	0.1991	0.3709	4.025
503	0.2544	0.2626	0.4209	5.254	504	0.1619	0.1956	0.3617	4.387
505	0.2464	0.2701	0.4503	5.526	506	0.1587	0.1574	0.2658	3.984
507	0.2229	0.2297	0.3740	6.213	508	0.1507	0.1640	0.2928	5.283
509	0.2749	0.2679	0.4137	4.947	510	0.2334	0.2546	0.4296	3.785
511	0.1238	0.1458	0.2714	5.924	512	0.2768	0.2883	0.4620	4.013
513	0.2196	0.2431	0.4141	5.257	514	0.2905	0.2939	0.4578	4.442
515	0.2192	0.2382	0.4030	5.756	516	0.2811	0.3119	0.5105	5.311
517	0.2501	0.2747	0.4569	6.885	518	0.2897	0.2921	0.4517	4.210
519	0.2288	0.2765	0.4877	6.819	520	0.2647	0.2860	0.4700	4.816
521	0.2188	0.2550	0.4414	5.760	522	0.2259	0.1599	0.2315	0.698
523	0.2532	0.2848	0.4793	6.111	524	0.2728	0.2204	0.3180	0.850
525	0.2203	0.2603	0.4581	5.594	526	0.1984	0.1714	0.2687	2.842
527	0.2300	0.2284	0.3673	6.060	528	0.2384	0.2024	0.3055	2.894
529	0.2303	0.2245	0.3574	3.178	530	0.2434	0.1988	0.2951	3.039
531	0.2426	0.2577	0.4255	5.022	532	0.2585	0.2562	0.3965	0.000
533	0.2259	0.2509	0.4270	0.249	534	0.2594	0.2570	0.3982	3.386
535	0.2342	0.2442	0.4029	5.704	536	0.2755	0.2947	0.4755	3.209
537	0.2114	0.2128	0.3515	5.329	538	0.2333	0.2013	0.3074	3.787

539	0.2378	0.2500	0.4117	4.508	540	0.2463	0.2046	0.3034	2.503
541	0.2325	0.2639	0.4540	1.456	542	0.2375	0.1718	0.2486	3.757
543	0.2505	0.2844	0.4816	4.792	544	0.2542	0.2496	0.3952	3.667
545	0.2424	0.2598	0.4306	2.866	546	0.2344	0.2373	0.3823	4.345
547	0.2133	0.2720	0.5000	5.504	548	0.2694	0.2608	0.4015	3.711
549	0.2398	0.2703	0.4558	5.157	550	0.2340	0.2332	0.3752	5.122
551	0.2146	0.2559	0.4532	5.851	552	0.2606	0.2348	0.3527	4.272
553	0.2205	0.2482	0.4276	4.654	554	0.2240	0.2278	0.3753	4.158
555	0.1869	0.1804	0.2982	3.444	556	0.1889	0.1902	0.3192	4.446
557	0.1610	0.1908	0.3506	4.483	558	0.2336	0.2412	0.3921	4.403
559	0.1827	0.2414	0.4603	6.159	560	0.2364	0.2580	0.4317	4.644
561	0.1916	0.2234	0.3975	5.411	562	0.2587	0.2727	0.4416	4.625
563	0.2871	0.2975	0.4626	4.588	564	0.2261	0.1969	0.3017	3.878
565	0.2557	0.2821	0.4689	3.434	566	0.2410	0.2022	0.3040	0.020
567	0.2530	0.3075	0.5483	3.382	568	0.2031	0.1638	0.2532	2.666
569	0.1909	0.2256	0.4059	4.608	570	0.2340	0.2286	0.3668	2.755
571	0.2162	0.2307	0.3883	3.455	572	0.2281	0.1929	0.2950	2.844
573	0.2311	0.2754	0.4852	3.893	574	0.2182	0.1871	0.2886	1.109
575	0.2393	0.2651	0.4452	3.309	576	0.1953	0.1709	0.2696	4.158
577	0.2319	0.2581	0.4391	2.993	578	0.2355	0.2081	0.3193	2.852
579	0.2339	0.2616	0.4451	2.676	580	0.2372	0.2132	0.3267	3.538
581	0.2316	0.2728	0.4799	3.688	582	0.2419	0.1980	0.2951	4.148
583	0.2530	0.2959	0.5056	2.727	584	0.2323	0.2313	0.3710	4.195
585	0.2350	0.2215	0.3493	4.638	586	0.2442	0.2169	0.3304	3.900
587	0.2309	0.2618	0.4484	3.520	588	0.2306	0.2547	0.4314	4.554
589	0.2316	0.2593	0.4461	5.046	590	0.2481	0.2562	0.4159	3.459
591	0.2274	0.2855	0.5203	5.061	592	0.2279	0.2422	0.4030	4.463
593	0.1036	0.1033	0.1872	4.878	594	0.2480	0.2447	0.3877	3.967
595	0.1363	0.1306	0.2247	4.017	596	0.1988	0.2235	0.3923	5.297
597	0.1416	0.1499	0.2669	4.774	598	0.2674	0.2454	0.3712	3.862
599	0.1911	0.1601	0.2541	3.522	600	0.1389	0.1423	0.2513	5.795
601	0.1935	0.2159	0.3786	3.816	602	0.2811	0.3249	0.5458	4.421
603	0.1923	0.1628	0.2573	4.373	604	0.2181	0.2501	0.4328	3.695
605	0.1969	0.1991	0.3330	2.822	606	0.1771	0.2006	0.3578	2.972
607	0.1228	0.1305	0.2361	3.846	608	0.2361	0.2197	0.3438	4.873
609	0.1875	0.2321	0.4269	4.562	610	0.2411	0.2861	0.4999	4.333
611	0.1650	0.1686	0.2911	4.427	612	0.2348	0.2512	0.4156	4.343
613	0.1600	0.1696	0.2938	5.295	614	0.2425	0.2712	0.4557	5.471
615	0.2268	0.2610	0.4534	4.819	616	0.2315	0.2519	0.4259	4.623
617	0.2456	0.2690	0.4493	4.088	618	0.2344	0.2424	0.4012	4.044
619	0.2578	0.2607	0.4134	5.258	620	0.2591	0.2981	0.5038	5.050
621	0.2229	0.2741	0.4955	3.366	622	0.2247	0.2962	0.5565	3.444
623	0.2221	0.2432	0.4152	4.280	624	0.0917	0.0950	0.1751	4.105
625	0.2191	0.2331	0.3919	3.830	626	0.1481	0.1724	0.3153	4.293
627	0.2456	0.2666	0.4435	4.818	628	0.1084	0.1221	0.2273	4.167
629	0.2411	0.2603	0.4329	5.106	630	0.1284	0.1436	0.2626	4.961

631	0.1655	0.1986	0.3655	5.507	632	0.1458	0.1680	0.3070	5.203
633	0.2355	0.2705	0.4693	4.058	634	0.1981	0.2443	0.4444	3.641
635	0.2254	0.2519	0.4317	3.624	636	0.2542	0.2729	0.4497	2.739
637	0.2258	0.2728	0.4916	4.837	638	0.2744	0.2707	0.4181	3.157
639	0.2154	0.2540	0.4465	4.314	640	0.2619	0.2789	0.4508	3.319
641	0.2345	0.2507	0.4170	4.935	642	0.2085	0.1850	0.2909	4.330
643	0.2593	0.2831	0.4645	5.397	644	0.2453	0.2520	0.4083	3.824
645	0.2444	0.2801	0.4777	5.289	646	0.2482	0.2322	0.3599	3.559
647	0.2199	0.2728	0.4921	5.298	648	0.2591	0.2436	0.3750	4.316
649	0.2225	0.2964	0.5683	4.582	650	0.2430	0.1892	0.2777	5.277
651	0.2242	0.2701	0.4799	5.296	652	0.2497	0.2550	0.4098	4.255
653	0.2192	0.2492	0.4433	4.885	654	0.2311	0.2584	0.4412	3.329
655	0.2085	0.2337	0.4064	5.834	656	0.2489	0.2169	0.3270	4.314
657	0.2487	0.2836	0.4821	4.785	658	0.2532	0.2823	0.4731	5.544
659	0.2442	0.2841	0.4923	4.615	660	0.2349	0.2510	0.4165	2.905
661	0.2389	0.2751	0.4760	4.804	662	0.2621	0.2387	0.3608	4.758
663	0.2297	0.2822	0.5057	3.884	664	0.2400	0.2407	0.3864	5.151
665	0.2403	0.2883	0.5085	5.175	666	0.2580	0.2749	0.4479	4.279
667	0.2491	0.2840	0.4861	5.341	668	0.2748	0.3054	0.5003	3.671
669	0.2261	0.2706	0.4769	5.793	670	0.2494	0.2784	0.4725	4.499
671	0.2068	0.2102	0.3507	5.040	672	0.2528	0.3119	0.5530	5.028
673	0.1201	0.1354	0.2507	5.207	674	0.2482	0.2369	0.3711	4.323
675	0.2687	0.2861	0.4670	4.853	676	0.2477	0.2718	0.4569	4.358
677	0.2135	0.2289	0.3874	5.017	678	0.2688	0.2905	0.4687	4.969
679	0.2163	0.2751	0.5063	5.230	680	0.2544	0.2736	0.4498	5.076
681	0.2455	0.2797	0.4730	6.188	682	0.2482	0.2240	0.3426	4.724
683	0.2238	0.2500	0.4272	7.033	684	0.2466	0.2725	0.4572	5.020
685	0.2086	0.2326	0.4009	5.248	686	0.2615	0.2709	0.4362	4.154
687	0.2270	0.2706	0.4760	5.469	688	0.2366	0.2471	0.4062	4.407
689	0.2228	0.2451	0.4160	6.486	690	0.2573	0.2705	0.4385	3.904
691	0.2329	0.2760	0.4824	5.705	692	0.2534	0.2671	0.4340	5.879
693	0.2076	0.2299	0.3980	5.908	694	0.2053	0.1805	0.2836	3.924
695	0.1757	0.2013	0.3594	6.529	696	0.2418	0.2298	0.3618	4.673
697	0.2043	0.2161	0.3655	6.481	698	0.1913	0.2052	0.3538	4.360
699	0.2070	0.2608	0.4783	6.373	700	0.1477	0.1445	0.2488	4.570
701	0.2122	0.2256	0.3821	5.387	702	0.2190	0.2154	0.3490	4.264
703	0.2096	0.2148	0.3577	4.547	704	0.2060	0.2158	0.3647	2.730
705	0.2409	0.2508	0.4083	5.211	706	0.1426	0.1739	0.3259	4.775
707	0.2077	0.2169	0.3649	2.871	708	0.2043	0.2078	0.3479	3.201
709	0.2190	0.2485	0.4306	5.330	710	0.2154	0.2247	0.3771	3.784
711	0.2310	0.2495	0.4162	5.666	712	0.2409	0.2734	0.4661	3.212
713	0.1913	0.2273	0.4126	5.087	714	0.2335	0.2507	0.4174	3.476
715	0.1039	0.1167	0.2178	5.271	716	0.2273	0.2417	0.4072	4.774
717	0.2208	0.2302	0.3829	5.521	718	0.2047	0.2466	0.4431	4.996
719	0.2057	0.2163	0.3638	4.696	720	0.2128	0.2595	0.4653	4.483
721	0.2076	0.2298	0.3922	5.305	722	0.2206	0.2694	0.4810	4.993

723	0.2271	0.2402	0.4000	4.595	724	0.2233	0.2522	0.4351	4.200
725	0.2500	0.2914	0.5019	4.568	726	0.2249	0.2311	0.3818	4.132
727	0.1240	0.1536	0.2922	5.869	728	0.2152	0.2302	0.3881	4.561
729	0.1515	0.1771	0.3241	5.664	730	0.2266	0.2616	0.4538	4.498
731	0.2313	0.2612	0.4469	6.706	732	0.2470	0.2940	0.5077	4.642
733	0.2196	0.2593	0.4572	5.895	734	0.1954	0.2300	0.4133	5.134
735	0.2317	0.2637	0.4528	3.880	736	0.1573	0.1730	0.3085	3.755
737	0.2383	0.2865	0.5040	5.332	738	0.1363	0.1580	0.2919	4.145
739	0.1583	0.1696	0.2992	5.009	740	0.1518	0.1780	0.3270	4.494
741	0.2265	0.2454	0.4154	4.991	742	0.1296	0.1384	0.2495	5.230
743	0.1972	0.2518	0.4715	5.089	744	0.2460	0.2716	0.4513	4.542
745	0.2363	0.2768	0.4789	5.118	746	0.2273	0.2673	0.4686	3.387
747	0.1251	0.1457	0.2714	4.642	748	0.2390	0.2528	0.4176	3.790
749	0.2229	0.2378	0.3991	4.894	750	0.2405	0.2635	0.4408	3.739
751	0.2239	0.2553	0.4392	6.007	752	0.1884	0.2269	0.4117	3.097
753	0.2331	0.2536	0.4246	5.821	754	0.2351	0.2641	0.4499	4.158
755	0.1183	0.1202	0.2154	5.153	756	0.2630	0.2838	0.4636	3.760
757	0.2152	0.2639	0.4754	5.619	758	0.2405	0.2930	0.5195	3.729
759	0.2452	0.2392	0.3779	5.116	760	0.2269	0.2506	0.4260	3.372
761	0.2038	0.2152	0.3638	5.671	762	0.2404	0.2934	0.5207	3.588
763	0.2467	0.2445	0.3900	5.582	764	0.1575	0.1731	0.3084	3.804
765	0.2256	0.2644	0.4608	4.062	766	0.2299	0.2321	0.3773	3.802
767	0.2463	0.2528	0.4070	5.170	768	0.2388	0.2759	0.4745	4.742
769	0.1535	0.1735	0.3139	5.140	770	0.1898	0.1875	0.3128	3.476
771	0.2426	0.2455	0.3943	5.634	772	0.2308	0.2653	0.4599	3.355
773	0.2133	0.2701	0.4978	5.241	774	0.2561	0.3031	0.5189	3.679
775	0.2150	0.2569	0.4552	6.148	776	0.2323	0.2322	0.3741	4.059
777	0.2183	0.2637	0.4728	5.045	778	0.1696	0.1742	0.3007	3.647
779	0.1928	0.2124	0.3680	5.182	780	0.2474	0.2744	0.4594	4.889
781	0.2048	0.2002	0.3291	5.198	782	0.2087	0.2007	0.3253	3.078
783	0.1639	0.1953	0.3579	5.504	784	0.2320	0.2686	0.4673	2.337
785	0.1926	0.2105	0.3637	5.558	786	0.2230	0.2514	0.4385	3.422
787	0.2309	0.2618	0.4489	4.605	788	0.2578	0.2821	0.4641	4.973
789	0.2427	0.2899	0.5097	4.119	790	0.2367	0.2373	0.3864	3.748
791	0.2243	0.2348	0.3895	4.782	792	0.2254	0.2215	0.3580	3.470
793	0.1689	0.1855	0.3274	5.865	794	0.2335	0.2489	0.4132	3.790
795	0.2288	0.2394	0.3953	4.988	796	0.2253	0.2466	0.4171	3.092
797	0.2067	0.2212	0.3746	6.845	798	0.2430	0.2538	0.4191	4.416
799	0.2400	0.2672	0.4506	5.395	800	0.2303	0.2512	0.4222	3.993
801	0.2064	0.2252	0.3873	4.717	802	0.1590	0.1771	0.3160	4.503
803	0.2122	0.2315	0.3946	5.278	804	0.1660	0.1747	0.3045	4.124
805	0.2180	0.2485	0.4304	7.290	806	0.1529	0.1655	0.2933	3.726
807	0.2172	0.2350	0.3972	6.004	808	0.2652	0.2397	0.3617	1.540
809	0.1935	0.2054	0.3510	6.755	810	0.1929	0.1653	0.2623	2.586
811	0.1898	0.2063	0.3563	5.594	812	0.2377	0.1952	0.2928	2.891
813	0.1445	0.1401	0.2413	3.632	814	0.2791	0.2454	0.3585	2.773

815	0.1976	0.1851	0.3010	4.870	816	0.1789	0.1563	0.2522	3.649
817	0.1515	0.1487	0.2558	4.633	818	0.2377	0.2223	0.3478	3.163
819	0.2286	0.1993	0.3058	5.899	820	0.2378	0.2281	0.3605	4.061
821	0.1938	0.2337	0.4239	4.587	822	0.2245	0.1841	0.2773	4.191
823	0.0822	0.0760	0.1388	3.919	824	0.2182	0.2099	0.3370	2.750
825	0.2043	0.2434	0.4363	3.973	826	0.2009	0.1885	0.3043	2.569
827	0.2136	0.1961	0.3119	4.765	828	0.2168	0.2181	0.3581	2.835
829	0.1602	0.1689	0.2950	3.166	830	0.2377	0.2346	0.3753	2.743
831	0.1149	0.1244	0.2279	4.209	832	0.2052	0.2043	0.3352	2.827
833	0.1947	0.2081	0.3562	4.539	834	0.2261	0.2082	0.3279	2.805
835	0.1983	0.1839	0.2979	4.223	836	0.2522	0.2448	0.3810	1.606
837	0.2163	0.2193	0.3619	3.590	838	0.2610	0.2345	0.3537	3.689
839	0.2171	0.2328	0.3920	4.351	840	0.2203	0.1947	0.3023	3.431
841	0.2396	0.2711	0.4628	4.701	842	0.2358	0.2200	0.3444	2.615
843	0.2032	0.2127	0.3583	5.301	844	0.2517	0.2395	0.3743	2.260
845	0.2190	0.2240	0.3695	4.324	846	0.1664	0.1520	0.2529	4.052
847	0.2014	0.1775	0.2812	4.374	848	0.2137	0.2195	0.3643	4.562
849	0.1841	0.1901	0.3234	3.370	850	0.1753	0.1585	0.2601	2.771
851	0.2098	0.2261	0.3856	2.619	852	0.2144	0.1892	0.2951	4.343
853	0.2268	0.2372	0.3928	4.192	854	0.2605	0.2578	0.4059	1.859
855	0.2108	0.2069	0.3374	4.894	856	0.2182	0.1843	0.2838	4.079
857	0.2056	0.1980	0.3235	2.882	858	0.2633	0.2561	0.4012	3.166
859	0.2211	0.2466	0.4247	3.393	860	0.2614	0.2687	0.4295	3.677
861	0.2281	0.2408	0.4005	2.742	862	0.2494	0.2215	0.3372	3.477
863	0.1325	0.1389	0.2501	5.349	864	0.2271	0.2110	0.3324	4.655
865	0.1798	0.1612	0.2636	4.052	866	0.1589	0.1399	0.2323	3.589
867	0.1675	0.1924	0.3473	5.317	868	0.1614	0.1469	0.2449	2.559
869	0.1433	0.1831	0.3598	5.262	870	0.2373	0.2363	0.3776	4.370
871	0.1705	0.1820	0.3155	4.221	872	0.2494	0.2450	0.3858	2.759
873	0.1666	0.1345	0.2156	2.504	874	0.2352	0.2547	0.4262	2.998
875	0.1440	0.1660	0.3082	4.073	876	0.1792	0.1835	0.3129	2.657
877	0.2089	0.2270	0.3883	3.884	878	0.2294	0.2543	0.4311	3.605
879	0.1252	0.1395	0.2565	3.940	880	0.2456	0.2674	0.4438	3.913
881	0.2065	0.2858	0.5583	0.000	882	0.1454	0.1494	0.2635	3.776
883	0.2382	0.2585	0.4304	3.944	884	0.2383	0.2453	0.4008	3.590
885	0.1994	0.2365	0.4247	4.373	886	0.1687	0.1895	0.3391	4.309
887	0.1547	0.1496	0.2569	4.288	888	0.1734	0.1867	0.3263	4.028
889	0.2233	0.2852	0.5237	1.795	890	0.2436	0.2577	0.4200	3.945
891	0.2236	0.2224	0.3601	5.043	892	0.1516	0.1602	0.2823	3.805
893	0.2351	0.3132	0.5921	1.619	894	0.2542	0.2768	0.4572	3.718
895	0.1520	0.1905	0.3601	4.832	896	0.2436	0.2412	0.3837	3.308
897	0.2329	0.2494	0.4134	4.576	898	0.2243	0.2271	0.3728	3.113
899	0.2367	0.2684	0.4554	4.711	900	0.2401	0.2460	0.3986	3.709
901	0.2360	0.2439	0.3979	5.146	902	0.1599	0.1695	0.2976	3.869
903	0.1508	0.1672	0.3005	4.833	904	0.2448	0.2612	0.4303	3.616
905	0.1483	0.1456	0.2525	3.994	906	0.2286	0.2520	0.4238	5.330

907	0.2174	0.2306	0.3872	3.890	908	0.2237	0.2263	0.3710	3.286
909	0.2249	0.2782	0.4978	4.929	910	0.1477	0.1627	0.2926	3.425
911	0.2242	0.2194	0.3506	4.040	912	0.2288	0.1962	0.3000	3.788
913	0.1216	0.1377	0.2541	3.858	914	0.2161	0.2168	0.3554	4.449
915	0.1893	0.2427	0.4565	5.629	916	0.2342	0.2218	0.3487	3.827
917	0.2212	0.2240	0.3681	5.197	918	0.2389	0.2576	0.4263	4.309
919	0.2135	0.2530	0.4497	4.901	920	0.1695	0.1844	0.3232	3.400
921	0.2147	0.2606	0.4682	3.740	922	0.2275	0.2636	0.4583	4.708
923	0.1767	0.1838	0.3165	4.512	924	0.2498	0.2376	0.3693	3.474
925	0.2245	0.2354	0.3918	4.751	926	0.1466	0.1554	0.2763	3.781
927	0.2215	0.2349	0.3927	4.550	928	0.2300	0.2671	0.4633	3.949
929	0.1196	0.1188	0.2107	5.058	930	0.1693	0.1937	0.3471	4.898
931	0.2296	0.2646	0.4568	4.979	932	0.2275	0.2378	0.3928	4.338
933	0.2148	0.2382	0.4087	4.323	934	0.1656	0.1845	0.3289	4.724
935	0.2366	0.2623	0.4391	4.579	936	0.2332	0.2552	0.4284	4.954
937	0.1324	0.1448	0.2622	4.296	938	0.2275	0.2161	0.3421	2.723
939	0.2164	0.2236	0.3655	3.283	940	0.1774	0.2008	0.3580	5.063
941	0.2435	0.2295	0.3573	4.053	942	0.2290	0.2079	0.3251	2.884
943	0.2328	0.2490	0.4148	3.318	944	0.2299	0.2706	0.4751	3.430
945	0.1420	0.1393	0.2416	2.710	946	0.2334	0.2447	0.4035	3.577
947	0.1984	0.2674	0.5127	0.003	948	0.2479	0.2906	0.4995	2.759
949	0.2173	0.2583	0.4594	3.170	950	0.2382	0.2303	0.3647	4.016
951	0.2075	0.2402	0.4223	4.411	952	0.2166	0.2414	0.4132	3.592
953	0.2268	0.2622	0.4543	3.366	954	0.2225	0.2196	0.3553	3.905
955	0.1375	0.1459	0.2600	5.289	956	0.2292	0.2279	0.3706	4.094
957	0.2326	0.2422	0.3965	4.227	958	0.2267	0.2338	0.3838	3.207
959	0.2366	0.2290	0.3626	4.832	960	0.2025	0.2097	0.3510	4.509
961	0.2191	0.2475	0.4271	3.796	962	0.1824	0.1788	0.2995	3.417
963	0.2323	0.2454	0.4079	4.013	964	0.2026	0.2147	0.3652	4.188
965	0.2219	0.2190	0.3558	4.641	966	0.2022	0.1928	0.3144	4.518
967	0.2101	0.2072	0.3397	4.204	968	0.2068	0.2391	0.4201	5.979
969	0.2274	0.2496	0.4236	5.424	970	0.1658	0.1859	0.3318	3.950
971	0.2312	0.2369	0.3889	5.662	972	0.2077	0.2351	0.4052	5.226
973	0.2353	0.2366	0.3808	4.083	974	0.2438	0.2910	0.5114	5.322
975	0.1281	0.1501	0.2796	3.111	976	0.1757	0.2002	0.3549	4.751
977	0.2022	0.2180	0.3730	5.813	978	0.2282	0.2672	0.4689	4.599
979	0.2239	0.2419	0.4057	6.980	980	0.2411	0.2565	0.4231	6.006
981	0.1991	0.1856	0.3007	2.711	982	0.2007	0.2398	0.4312	3.349
983	0.1930	0.1755	0.2827	3.233	984	0.2302	0.2647	0.4533	3.909
985	0.2344	0.2243	0.3530	5.186	986	0.2098	0.2179	0.3618	4.916
987	0.2027	0.2143	0.3639	3.225	988	0.2085	0.2237	0.3802	3.932
989	0.2243	0.2297	0.3765	6.279	990	0.2171	0.2304	0.3858	4.306
991	0.2000	0.1723	0.2710	3.374	992	0.2401	0.2764	0.4717	3.876
993	0.2226	0.2158	0.3457	5.391	994	0.2198	0.2197	0.3585	4.185
995	0.1944	0.1963	0.3281	3.882	996	0.2117	0.2140	0.3540	3.560
997	0.2125	0.1897	0.2987	5.728	998	0.1924	0.2011	0.3424	4.044

999	0.2077	0.1957	0.3164	1.721	1000	0.2206	0.2333	0.3893	4.818
1001	0.2406	0.2599	0.4260	5.769	1002	0.1886	0.2360	0.4379	4.869
1003	0.2177	0.1941	0.3009	5.843	1004	0.2003	0.2197	0.3785	3.630
1005	0.1242	0.1418	0.2604	5.595	1006	0.2079	0.2348	0.4070	4.514
1007	0.1460	0.1162	0.1885	2.563	1008	0.2109	0.2401	0.4186	3.342
1009	0.1745	0.1510	0.2434	4.009	1010	0.2113	0.2155	0.3575	4.230
1011	0.1819	0.1525	0.2440	3.786	1012	0.2065	0.2374	0.4147	4.634
1013	0.1586	0.1292	0.2081	3.878	1014	0.1977	0.2157	0.3720	2.727
1015	0.1766	0.1533	0.2484	4.120	1016	0.1490	0.1604	0.2843	3.336
1017	0.1554	0.1738	0.3121	4.789	1018	0.1981	0.2306	0.4097	3.652
1019	0.2161	0.2335	0.3962	4.630	1020	0.2175	0.2333	0.3911	4.320
1021	0.1966	0.1647	0.2592	1.558	1022	0.1944	0.2027	0.3449	4.404
1023	0.1961	0.2088	0.3572	4.949	1024	0.2392	0.2373	0.3758	4.667
1025	0.1585	0.1357	0.2225	3.710	1026	0.2075	0.2208	0.3726	3.527
1027	0.2163	0.2182	0.3586	4.242	1028	0.1919	0.1856	0.3066	3.612
1029	0.2205	0.1968	0.3065	2.362	1030	0.1728	0.1842	0.3216	4.021
1031	0.2395	0.2364	0.3773	5.201	1032	0.2201	0.2472	0.4248	4.204
1033	0.2068	0.1807	0.2850	1.548	1034	0.2222	0.2301	0.3800	4.042
1035	0.2077	0.2446	0.4366	2.884	1036	0.2072	0.2115	0.3513	3.576
1037	0.2302	0.2344	0.3813	5.048	1038	0.2318	0.2494	0.4124	4.939
1039	0.1778	0.1674	0.2782	3.669	1040	0.2015	0.2128	0.3610	4.015
1041	0.2122	0.1843	0.2877	3.019	1042	0.2027	0.2181	0.3739	5.254
1043	0.2254	0.2235	0.3631	4.514	1044	0.2166	0.2168	0.3551	4.293
1045	0.2050	0.1801	0.2839	3.290	1046	0.2523	0.2568	0.4084	4.435
1047	0.2089	0.2060	0.3376	4.598	1048	0.2100	0.2438	0.4301	3.812
1049	0.2168	0.1790	0.2734	0.910	1050	0.2297	0.2664	0.4610	4.301
1051	0.2106	0.1776	0.2755	0.774	1052	0.2120	0.2478	0.4377	4.057
1053	0.2002	0.1746	0.2762	1.083	1054	0.2025	0.2386	0.4254	4.570
1055	0.2268	0.2453	0.4123	3.074	1056	0.1691	0.1712	0.2938	3.953
1057	0.2153	0.2155	0.3547	2.517	1058	0.2414	0.2377	0.3751	3.436
1059	0.2233	0.2359	0.3937	3.969	1060	0.2165	0.2357	0.3989	5.124
1061	0.2067	0.1918	0.3082	2.847	1062	0.2415	0.2582	0.4253	4.461
1063	0.2198	0.2267	0.3756	4.529	1064	0.2366	0.2474	0.4049	3.861
1065	0.1611	0.1181	0.1840	2.680	1066	0.2097	0.2220	0.3761	5.296
1067	0.1619	0.1999	0.3705	5.009	1068	0.1713	0.1903	0.3366	4.602
1069	0.1617	0.1434	0.2370	3.274	1070	0.2055	0.2038	0.3360	4.563
1071	0.2341	0.2493	0.4141	4.660	1072	0.1593	0.1685	0.2957	4.105
1073	0.2431	0.2503	0.4065	3.924	1074	0.2110	0.2183	0.3648	3.896
1075	0.2151	0.1908	0.2999	3.672	1076	0.2128	0.2177	0.3588	3.900
1077	0.1991	0.1841	0.2977	4.794	1078	0.2057	0.2468	0.4437	2.884
1079	0.2152	0.2211	0.3648	4.703	1080	0.1800	0.1762	0.2955	0.194
1081	0.1529	0.1475	0.2518	6.077	1082	0.2046	0.2024	0.3328	3.818
1083	0.1968	0.2081	0.3534	4.866	1084	0.1980	0.2138	0.3665	3.564
1085	0.2136	0.2000	0.3193	4.202	1086	0.2183	0.2589	0.4571	3.713
1087	0.2070	0.2217	0.3769	4.369	1088	0.2024	0.2120	0.3569	3.114
1089	0.2082	0.1909	0.3049	3.394	1090	0.1702	0.1880	0.3328	4.159



1091	0.2028	0.1758	0.2773	3.419	1092	0.1997	0.2147	0.3669	4.772
1093	0.1928	0.1903	0.3171	1.495	1094	0.1936	0.2060	0.3504	4.596
1095	0.2024	0.1785	0.2833	2.757	1096	0.1959	0.2262	0.4004	4.509
1097	0.2085	0.2098	0.3468	4.090	1098	0.1272	0.1244	0.2198	3.637
1099	0.2266	0.2229	0.3564	4.347	1100	0.2267	0.2554	0.4341	4.803
1101	0.1844	0.1912	0.3276	4.845	1102	0.1617	0.1733	0.3045	3.571
1103	0.2310	0.2377	0.3880	4.950	1104	0.2063	0.2262	0.3858	4.950
1105	0.1827	0.1627	0.2614	3.349	1106	0.1931	0.2056	0.3525	3.675
1107	0.1779	0.1579	0.2565	3.440	1108	0.2013	0.2228	0.3857	4.936
1109	0.1845	0.1605	0.2585	4.250	1110	0.2202	0.2409	0.4097	3.978
1111	0.1756	0.1765	0.3001	0.119	1112	0.2407	0.2472	0.4014	4.276
1113	0.1772	0.1954	0.3440	6.081	1114	0.2312	0.2244	0.3590	4.115
1115	0.1931	0.1748	0.2823	2.986	1116	0.2383	0.2474	0.4051	4.219
1117	0.2076	0.1783	0.2795	3.039	1118	0.2479	0.2868	0.4920	3.581
1119	0.1844	0.2097	0.3694	6.115	1120	0.2333	0.2686	0.4614	4.755
1121	0.2237	0.2537	0.4349	6.186	1122	0.2394	0.2548	0.4181	5.109
1123	0.1993	0.2345	0.4189	6.078	1124	0.2380	0.2846	0.5022	2.514
1125	0.2272	0.2492	0.4188	5.427	1126	0.2521	0.2780	0.4624	3.521
1127	0.2029	0.2301	0.4021	6.279	1128	0.2379	0.2668	0.4550	4.036
1129	0.2159	0.2231	0.3714	4.649	1130	0.2503	0.2719	0.4496	4.679
1131	0.2235	0.2180	0.3527	4.855	1132	0.2503	0.2597	0.4195	4.470
1133	0.2219	0.2427	0.4087	5.748	1134	0.2503	0.2710	0.4475	3.709
1135	0.2198	0.2318	0.3876	4.986	1136	0.2639	0.2699	0.4284	4.528
1137	0.2155	0.2290	0.3851	4.614	1138	0.2376	0.2448	0.3993	3.753
1139	0.2336	0.2698	0.4666	5.214	1140	0.2601	0.2732	0.4403	3.952
1141	0.2294	0.2534	0.4267	6.019	1142	0.2093	0.2414	0.4210	3.822
1143	0.2262	0.2140	0.3401	5.321	1144	0.1711	0.1869	0.3301	3.609
1145	0.2313	0.2352	0.3819	6.105	1146	0.2395	0.2581	0.4295	3.498
1147	0.2051	0.2230	0.3807	4.845	1148	0.2373	0.2314	0.3682	4.317
1149	0.1279	0.1443	0.2656	5.540	1150	0.2605	0.2695	0.4319	4.459
1151	0.1982	0.1872	0.3051	5.261	1152	0.2272	0.2484	0.4164	5.274
1153	0.2035	0.1824	0.2899	3.799	1154	0.3084	0.2956	0.4413	4.186
1155	0.2183	0.2305	0.3853	5.120	1156	0.3324	0.3201	0.4697	4.508
1157	0.1639	0.1968	0.3596	6.601	1158	0.2353	0.2757	0.4781	4.411
1159	0.1741	0.1832	0.3120	4.267	1160	0.1663	0.1821	0.3221	3.963
1161	0.1651	0.1466	0.2422	4.818	1162	0.2645	0.3068	0.5205	5.230
1163	0.1579	0.1715	0.3053	5.578	1164	0.2447	0.2477	0.3984	4.290
1165	0.2252	0.2256	0.3620	6.385	1166	0.2324	0.2469	0.4092	3.639
1167	0.2245	0.2236	0.3629	4.313	1168	0.2422	0.2715	0.4591	4.320
1169	0.1998	0.2209	0.3827	3.970	1170	0.2332	0.2625	0.4475	2.900
1171	0.2218	0.2126	0.3411	6.318	1172	0.2370	0.2557	0.4262	3.541
1173	0.1976	0.1897	0.3114	4.145	1174	0.2570	0.2674	0.4291	4.581
1175	0.2339	0.2290	0.3613	3.926	1176	0.2184	0.2547	0.4488	5.303
1177	0.2076	0.2114	0.3519	3.200	1178	0.2593	0.2839	0.4725	3.848
1179	0.2271	0.2544	0.4301	3.859	1180	0.2417	0.2422	0.3869	4.187
1181	0.2094	0.2064	0.3376	3.382					

