



# ESCUELA POLITÉCNICA NACIONAL



FACULTAD DE INGENIERÍA MECÁNICA

## DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN EN LENGUAJE PYTHON PARA EL ESTUDIO DE ZONAS FORESTALES

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE  
MAGÍSTER EN DISEÑO Y SIMULACIÓN

PUGA GALLEGOS DIANA SOFÍA  
diana.puga@epn.edu.ec

DIRECTOR: Ing. VÍCTOR HUGO HIDALGO, D.Sc.  
victor.hidalgo@epn.edu.ec

CODIRECTOR: Ing. ESTEBAN ALEJANDRO VALENCIA, Ph.D.  
esteban.valencia@epn.edu.ec

Quito, abril 2019

## **CERTIFICACIÓN**

Certifico que el presente trabajo fue desarrollado por la señorita **DIANA SOFÍA PUGA GALLEGOS**, bajo mi supervisión.

---

Ing. Víctor Hugo Hidalgo, D.Sc.

**DIRECTOR DEL PROYECTO**

---

Ing. Esteban Alejandro Valencia, Ph.D.

**CODIRECTOR DEL PROYECTO**

## DECLARACIÓN

Yo, **Diana Sofía Puga Gallegos**, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración cedo mis derechos de propiedad intelectual correspondiente a este trabajo, a la Escuela Politécnica Nacional, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normativa institucional vigente.

---

Diana Sofía Puga Gallegos

## DEDICATORIA

A mis padres y hermano,  
por su amor y apoyo incondicional.

Diana

## **AGRADECIMIENTO**

A la Escuela Politécnica Nacional por la valiosa formación profesional, de manera especial al Dr. Víctor Hidalgo por su apoyo, tiempo, conocimiento y experiencia al dirigir la presente tesis, y al Dr. Esteban Valencia por su colaboración y guía.

Al Ministerio de Agricultura, Ganadería, Acuacultura y Pesca (MAGAP), Ministerio del Ambiente y Agua del Ecuador (MAE) y al Fondo para la Protección del Agua (FONAG), instituciones que han facilitado el acceso a la información referente al área de estudio.

A mis padres y hermano por motivarme a ser cada día mejor, a luchar para alcanzar las metas propuestas, por enseñarme a nunca renunciar a mis sueños aun cuando el camino no sea fácil.

A Dios por darme la fortaleza necesaria para seguir.

Diana

# ÍNDICE

Certificación .....	i
Declaración .....	ii
Dedicatoria .....	iii
Agradecimiento .....	iv
Resumen.....	xii
Abstract.....	xiii
Introducción .....	1
Pregunta de investigación .....	2
Objetivo general.....	2
Objetivos específicos.....	2
1. MARCO TEÓRICO .....	3
1.1. Revisión bibliográfica .....	3
1.2. Humedad del suelo.....	9
1.2.1. Capacidad de campo (F.C).....	9
1.2.2. Punto de marchitamiento permanente (P.W.P).....	10
1.2.3. Contenido de agua disponible (A.W.C).....	10
2. METODOLOGÍA .....	12
2.1. Estrategia metodológica.....	12
2.2. Procesamiento de imagen.....	13
2.2.1 Procesamiento de imagen en escala de grises .....	16
2.2.1.1 Adquisición de la imagen .....	16
2.2.1.2 Mejoramiento de la imagen .....	16
2.2.1.3 Análisis de la imagen .....	17
2.2.1.4 Reconocimiento de objetos .....	24
2.2.2 Procesamiento de imagen a color .....	24
2.2.2.1 Adquisición de la imagen .....	24
2.2.2.2 Mejoramiento de la imagen .....	25
2.2.2.3 Análisis de la imagen .....	25
2.2.2.4 Reconocimiento de objetos .....	33
3. RESULTADOS Y DISCUSIÓN.....	35
3.1 Validación de la metodología de procesamiento de imagen en escala de grises	35
3.2 Validación de la metodología de procesamiento de imagen a color .....	37
3.3 Selección de la metodología para el procesamiento de imagen de zonas forestales	38
3.4 Aplicación de la metodología para el procesamiento de imagen de zonas forestales al Refugio de Vida Silvestre La Chiquita .....	41
4. CONCLUSIONES .....	51
4.1 Trabajos futuros.....	51
Referencias Bibliográficas .....	53
Anexos .....	57
Anexo I. ....	58
Anexo II.....	62
Anexo III.....	63
Anexo IV. ....	64

Anexo V. ....	66
---------------	----

## ÍNDICE DE ECUACIONES

Ecuación 2.1 .....	17
Ecuación 2.2 .....	17
Ecuación 2.3 .....	18
Ecuación 2.4 .....	18
Ecuación 2.5 .....	19
Ecuación 2.6 .....	20
Ecuación 2.7 .....	20
Ecuación 2.8 .....	20
Ecuación 2.9 .....	25
Ecuación 3.1 .....	36
Ecuación 3.2 .....	36
Ecuación 3.3 .....	36
Ecuación 3.4 .....	36



## ÍNDICE DE FIGURAS

Figura 1.1. Representación de una imagen digital. (a) Cuadrícula 2D. (b) Cuboide 3D. ....	4
Figura 1.2. Representación del contenido de agua en el suelo. ....	10
Figura 1.3. Textura del suelo y contenido de agua. ....	11
Figura 2.1. Metodología de desarrollo del código de programación para el estudio de zonas forestales. ....	12
Figura 2.2. Metodología de procesamiento de imagen. ....	15
Figura 2.3. Proceso de análisis de imagen. ....	15
Figura 2.4. (a) Imagen de la zona de estudio. (b) Imagen original del satélite Pleiades. ....	16
Figura 2.5. Rango de segmentación para la zona de interés y la zona alpha de la imagen en escala de grises. ....	18
Figura 2.6. Rango de segmentación para las zonas 1, 2 y 3 en escala de grises. ....	20
Figura 2.7. (a) Máscara Zona 1 no vegetación o vegetación dispersa. (b) Máscara Zona 2 vegetación media - baja. (c) Máscara Zona 3 vegetación media - alta. (d) Resultados de la clasificación de la vegetación del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery". ....	21
Figura 2.8. Zonas forestales procesamiento en escala de grises (resultados del procesamiento de imagen aplicando el código desarrollado en Python). ....	23
Figura 2.9. Rango de tonalidad de la zona de interés. ....	27
Figura 2.10. Rango de segmentación de tonalidad para las zonas 1, 2 y 3. ....	27
Figura 2.11. (a), (b) Sub-máscaras de la Zona 1. (c) Máscara resultante de la Zona 1. (d) Resultados de la clasificación de la vegetación del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery". ....	28
Figura 2.12. (a) Máscara Zona 1 no vegetación o vegetación dispersa. (b) Máscara Zona 2 vegetación media - baja. (c) Máscara Zona 3 vegetación media - alta. (d) Resultados de la clasificación de la vegetación del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery". ....	30
Figura 2.13. Zonas forestales procesamiento a color (resultados del procesamiento de imagen aplicando el código desarrollado en Python). ....	32
Figura 3.1. (a) Máscara Zona 1 Escala de Grises. (b) Máscara Zona 1 Color. (c) Máscara Zona 2 Escala de Grises. (d) Máscara Zona 2 Color. (e) Máscara Zona 3 Escala de Grises. (f) Máscara Zona 3 Color. (g) Resultados de la clasificación de la	

vegetación del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".....	40
Figura 3.2. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight_003-005. ....	43
Figura 3.3. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight_003-012. ....	44
Figura 3.4. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight_003-028. ....	45
Figura 3.5. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight_003-050. ....	46
Figura 3.6. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight_003-121. ....	47
Figura 3.7. Barra de color y porcentaje de humedad del suelo. ....	50

## ÍNDICE DE GRÁFICAS

Gráfica 3.1.Comparación de resultados de las diferentes metodologías del procesamiento de imagen. ....	39
Gráfica 3.2.Desviación estándar de resultados. ....	49

## ÍNDICE DE TABLAS

Tabla 1.1. Humedad del suelo según su textura. ....	10
Tabla 2.1. Resultados del procesamiento de imagen en escala de grises aplicando el código desarrollado en Python. ....	22
Tabla 2.2. Resultados del procesamiento de imagen a color aplicando el código desarrollado en Python. ....	31
Tabla 3.1. Comparación de resultados del procesamiento de imagen en escala de grises aplicando el código desarrollado en Python con los resultados del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery". ....	37
Tabla 3.2. Comparación de resultados del procesamiento de imagen a color aplicando el código desarrollado en Python con los resultados del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery". ....	38
Tabla 3.3. Comparación del error obtenido aplicando la metodología de procesamiento de imagen en escala de grises y a color. ....	39
Tabla 3.4. Propiedades de las imágenes del Refugio de Vida Silvestre La Chiquita. ....	42
Tabla 3.5. Rangos de segmentación. ....	43
Tabla 3.6. Resumen de resultados del procesamiento de imágenes del Refugio de Vida Silvestre La Chiquita. ....	48
Tabla 3.7. Rangos de humedad para cada zona de segmentación. ....	50

## RESUMEN

La presente tesis tiene por objetivo estudiar zonas forestales mediante el desarrollo de un código de programación en lenguaje Python capaz de determinar cobertura vegetal mediante el procesamiento de imágenes, para lo cual se propusieron dos alternativas que son el procesamiento de imagen en escala de grises y el procesamiento de imagen a color de una zona forestal previamente estudiada por Bambang Trisakti en su artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery”. Se comparó los resultados obtenidos de las dos metodologías propuestas con los resultados del estudio realizado por el autor mencionado para definir y validar la metodología óptima para el estudio de zonas forestales. Después de definir que la metodología más apropiada para el estudio de zonas forestales es el procesamiento de imagen a color usando el modelo HSV ya que presentó el menor error y sus resultados se aproximaron más a los resultados obtenidos en el artículo usado para la validación, esta metodología se aplicó en imágenes del Refugio de Vida Silvestre La Chiquita. A partir del análisis estadístico realizado en los resultados del procesamiento de imágenes de La Chiquita se concluyó que la metodología desarrollada presentó los resultados esperados. Finalmente, se determinó que sí es posible estudiar los parámetros físico-térmicos de las zonas forestales mediante el procesamiento de imagen, esto se obtuvo luego de relacionar la humedad del suelo con los resultados del procesamiento de imagen realizado al área de estudio.

**Palabras clave:** código Python, correlación de parámetros físico-térmicos, metodología de procesamiento de imagen a color, procesamiento de imagen, zonas forestales.

## ABSTRACT

The aim of this thesis is to study forest zones through the development of a programming code in Python language capable of determining plant cover by image processing. To achieve this goal two methodologies were proposed, the first one was grayscale image processing and the second one was color image processing of a forest zone previously studied by Bambang Trisakti in his paper "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery". First, the results of the two methodologies were obtained. Then, these results were compared with the results of the previously study made by mentioned author. This comparison was made in order to define and validate the optimal methodology for the study of forest zones. Color image processing using HSV model was defined as the appropriate methodology for forest zones analysis because it presented the least error and its results were closer to the results obtained in the article used for the validation. Afterwards, the color methodology was applied in images of the Wildlife Refuge La Chiquita and a statistical analysis was performed in the image processing results to conclude that the developed methodology gave the expected results. Finally, this thesis showed that it is possible to study physical-thermal parameters of forest zones using image processing because the results of the image processing was related with the soil moisture in the study area.

**Keywords:** Python code, correlation of physical-thermal parameters, color image processing methodology, image processing, forest zones.

# DESARROLLO DE UN CÓDIGO DE PROGRAMACIÓN EN LENGUAJE PYTHON PARA EL ESTUDIO DE ZONAS FORESTALES

## INTRODUCCIÓN

Actualmente el procesamiento de imagen es una técnica ampliamente utilizada en distintos campos como robótica, comunicaciones, sensores remotos, biomedicina, automatización industrial, sistemas de inspección, navegación, mediciones ópticas, entre otras [1].

El desarrollo tecnológico y científico ha permitido que el ordenamiento territorial, la cartografía temática, la planificación ambiental, estudios de una zona geográfica como análisis termodinámicos, determinación de áreas desérticas, reconocimiento digital de tipo de cultivos, entre otros se lleven a cabo utilizando fotos del territorio objeto del estudio junto con software especializado y costoso para el procesamiento de la información obtenida de las imágenes [2]. Esta nueva tecnología está dejando atrás los estudios de campo y mediciones directas para la estimación de la cobertura vegetal debido a que son procesos poco prácticos, costosos y consumen mucho tiempo [3]. El uso de imágenes satelitales junto con índices de vegetación son métodos ampliamente usados en la estimación de la cobertura vegetal debido a su precisión [4].

Sin embargo, el uso de imágenes satelitales tiene sus desventajas como el costo de adquisición de las imágenes satelitales, la necesidad de personal capacitado y software especializado para su uso e interpretación. Adicionalmente, las imágenes satelitales tienen disponibilidad limitada debido a condiciones climáticas (presencia de nubes) que impiden el monitoreo continuo [5].

El uso de cámaras multiespectrales para la adquisición de información es una alternativa al uso de imágenes satelitales, a pesar de ser una opción bastante prometedora presentan el alto costo de adquisición y reposición en caso de daño como desventaja, por lo tanto, el uso de fotografías digitales para el estudio de zonas forestales se ha convertido en una opción práctica y económica [3] junto con la utilización de software libre [6] para el procesamiento de las imágenes antes adquiridas.

En este contexto, la presente tesis se enfoca en el desarrollo de un código de programación en lenguaje Python para el estudio de zonas forestales con la finalidad de contar con un software libre como alternativa económica y funcional para el procesamiento de imágenes de zonas forestales y su relación con propiedades físico-térmicas.

## **Pregunta de investigación**

¿Es posible obtener información de las propiedades físico-térmicas de las zonas forestales a partir del procesamiento de imagen?

## **Objetivo general**

Estudiar zonas forestales mediante el desarrollo de un código de programación en lenguaje Python que permita el procesamiento de imágenes.

## **Objetivos específicos**

- Realizar el procesamiento de imagen en escala de grises para obtener índices que se relacionen con las propiedades físicas y térmicas de las zonas forestales.
- Realizar el procesamiento de imagen a color para obtener índices que se relacionen con las propiedades físicas y térmicas de las zonas forestales.
- Comparar los índices obtenidos del procesamiento de imagen en escala de grises y a color para identificar la mejor correlación entre características físicas y térmicas de zonas forestales.
- Optimizar y validar el código de programación con estudio de campo.
- Establecer una metodología de procesamiento de imagen para el estudio de zonas forestales.



# 1. MARCO TEÓRICO

En esta sección se presenta la revisión bibliográfica del estado del arte dentro del procesamiento de imagen para el estudio de zonas forestales, en la cual se menciona el uso de imágenes satelitales, cámaras multispectrales y cámaras digitales junto con vehículos aéreos no tripulados (UAV) como herramientas ampliamente usadas en la actualidad para la adquisición de datos y monitoreo de zonas forestales, se realiza una discusión de sus ventajas, desventajas y aplicaciones, para finalmente mencionar su relación con la metodología que se desarrollará en la presente tesis para el estudio de zonas forestales. Posteriormente, se explican conceptos sobre la humedad del suelo debido a que esta es la propiedad físico-térmica motivo de estudio de la presente tesis y es necesario entenderla para poder relacionarla con los resultados obtenidos del procesamiento de imagen.

## 1.1. Revisión bibliográfica

La clasificación y el mapeo de la vegetación dan la información valiosa para entender los entornos naturales y artificiales mediante la cuantificación de la cobertura vegetal desde escalas locales a globales en un momento dado o durante un período continuo de tiempo [7], en la actualidad el procesamiento de imagen es una herramienta ampliamente usada para realizar esta tarea.

Una imagen es la representación de un objeto, una imagen digital está compuesta por un número finito de elementos que tienen una ubicación dentro de la cuadrícula bidimensional y un valor particular, estos elementos se denominan píxeles. Cada píxel representa una región rectangular y su posición está dada en la notación matricial común. Dónde el primer índice  $m$ , indica la posición de la fila, y el segundo índice  $n$ , la posición de la columna. Si la imagen digital contiene  $M \times N$  píxeles, se representa por una matriz  $M \times N$ . El índice  $n$  va desde 0 a  $N - 1$ , y el índice  $m$  desde 0 a  $M - 1$ .  $M$  indica el número de filas y  $N$  el número de columnas. De acuerdo con la notación matricial, el eje vertical (eje  $y$ ) va de arriba hacia abajo, y el eje horizontal (eje  $x$ ) de izquierda a derecha. Espacios tridimensionales (e incluso espacios de dimensiones superiores) son de interés en el procesamiento de imagen. En imágenes tridimensionales, el píxel se convierte en vóxel (elemento de volumen) y representa el valor gris medio de un cuboide. La posición de un vóxel está dada por tres índices. El primero,  $l$ , indica la profundidad,  $m$  la fila, y  $n$  la columna. Una cuadrícula

cartesiana es la representación más general para datos digitales porque es la única geometría que puede extenderse fácilmente a dimensiones arbitrarias [8].




Figura 1.1. Representación de una imagen digital. (a) Cuadrícula 2D. (b) Cuboide 3D. (Fuente:[8])

El procesamiento de imagen digital comprende los procesos cuyas entradas y salidas son imágenes, abarcando procesos de extracción de atributos y reconocimiento de objetos a partir de imágenes. [9]

El concepto de imagen antes mencionado es necesario para entender que las entradas, salidas del procesamiento de imagen son arreglos matriciales, y que las operaciones que se desarrollan durante el procesamiento de imagen son operaciones entre matrices.

El procesamiento de imagen en la agricultura es una herramienta efectiva, no invasiva y de alta precisión en el análisis de parámetros agrícolas [10]. La aplicación del procesamiento de imagen más común en el campo agrícola es la detección de maleza [11–16].

Por otro lado, la estimación de la cobertura vegetal en distintos lugares del planeta es un tema que ha despertado el interés de la sociedad actual, en este ámbito el procesamiento de imagen resulta muy útil para monitorear zonas forestales y analizar sus parámetros. Zhang & Feng presentaron un estudio en el cual desarrollan un método orientado a objetos para obtener la distribución de la vegetación en un entorno urbano a partir de imágenes obtenidas del sensor remoto IKONOS logrando una precisión de más del 97%, en su estudio realizan dos segmentaciones una fina y una más gruesa, aplican también el cálculo de índices NDVI y VI [17]. Valdez et al. realizaron una comparación entre datos obtenidos en campo y procedimientos que utilizan imágenes satelitales de alta y mediana resolución

obtenidos de IKONOS, QuickBird, SPOT y LANDSAT para estimar la cobertura arbórea y evaluar la utilidad de las imágenes de alta resolución, de este análisis concluyen que las imágenes de alta resolución obtenidas de los satélites IKONOS y QuickBird son adecuadas para determinar el porcentaje de cobertura de copas en vegetaciones de pino [18]. Kumar et al. analizan el potencial de los datos obtenidos del sensor multitemporal de campo amplio IRS (WiFS) para el mapeo de los tipos de cobertura vegetal, concluyendo que el mapeo derivado del WiFS es útil como entrada de modelos biogeoquímicos que requieren estimaciones oportunas del área forestal y su tipo. El monitoreo de vegetación en una escala espacial menor a 1 Km y datos multitemporales son esenciales para comprender la dinámica de un territorio a escala regional, el sensor de campo ancho (WiFS es un sensor óptico espacial con mejor resolución que AVHRR, SPOT y MODIS) satisface estos requerimientos debido a sus características de resolución espacial y temporal [5]. Amiri et al. analizan la efectividad de los datos obtenidos de sensores remotos ASTER y el cálculo de índices de vegetación en el estudio de la cobertura vegetal. Los índices de vegetación (VI) combinan mediciones de reflectancia de diferentes partes del espectro electromagnético para proporcionar información sobre la cobertura vegetal del suelo, estos índices miden la actividad fotosintética de la vegetación y las relacionan con propiedades biofísicas como el índice de área foliar, la cobertura de vegetación fraccionada y la biomasa. El NDVI es el índice que muestra una correlación significativa con la cobertura vegetal incluso en tierras áridas, donde la vegetación no es verde y sus especificaciones de reflexión se parecen mucho a las del suelo [19]. Bambang Trisakti describe el uso de imágenes del satélite PLEAIDES de alta y media resolución para la clasificación de los tipos de vegetación y estimación del porcentaje de cobertura vegetal usando una combinación de NDVI y banda azul, los métodos de clasificación usados son no supervisados y supervisados obteniendo precisiones de 97,9% y 98,9% respectivamente. Este autor aplica el criterio de segmentación por color para separar la zona de vegetación de la zona de no vegetación y clasificar los tipos de vegetación [4].

Los autores antes mencionados utilizan imágenes satelitales con distintas clases espectrales para estimar la cobertura vegetal de la zona de estudio mediante el cálculo de índices de vegetación, esta metodología es ampliamente utilizada en la actualidad debido a su precisión, a la rapidez con la que los satélites escanean grandes áreas, a su bajo costo ya que los costos referentes a construcción, lanzamiento y operación de un satélite se dividen para los miles de usuarios que compran las imágenes, facilitan la detección de cambios lentos o repentinos en una zona de estudio, entregan información confiable y repetible con precisión medible, y al ser información digital es fácilmente analizable y

comparable [20]. Sin embargo, el uso de imágenes satelitales tiene sus desventajas como el costo de compra de las imágenes y la necesidad de personal capacitado y software especializado para su uso e interpretación. Además, las imágenes satelitales tienen disponibilidad limitada debido a condiciones climáticas, por ejemplo, presentan presencia de nubes que impiden el monitoreo continuo y es imposible registrar los cambios que ocurren en periodos muy cortos de tiempo ya que el satélite cumple un ciclo de monitoreo y pasa cada cierto tiempo por un punto particular. El uso de imágenes satelitales no es adecuado para aplicaciones en las que se requiere una alta resolución espacial, por ejemplo, el estudio de árboles como elementos individuales o incluso hojas [21].

Como se mencionó anteriormente el costo de una imagen satelital es relativamente bajo si se analiza todo el proceso que se encuentra detrás de la obtención de esta imagen (construcción, lanzamiento y operación del satélite), pero la inversión que se realiza para adquirir una imagen satelital es alta y se debe tener en cuenta que dependiendo de la dimensión de la zona de estudio se puede necesitar más de una imagen satelital. Existen algunos satélites monitoreando la superficie terrestre (como mencionan los autores citados previamente) y cada uno de ellos tiene características particulares, la resolución es la más importante al momento de monitorear la cobertura vegetal, mientras más fina es la resolución de la imagen su costo incrementa, y el requerimiento de resolución depende de la aplicación.

La selección del índice de vegetación adecuado para el análisis de la zona vegetal objeto de estudio es un problema común y de gran importancia ya que de esto depende la fiabilidad de los resultados del estudio.

Con la finalidad de reducir costos y la complejidad en el procesamiento de imágenes satelitales manteniendo la precisión de los resultados se ha explorado el uso de imágenes digitales adquiridas mediante vehículos aéreos no tripulados para el estudio de cobertura vegetal. Por ejemplo, en su esfuerzo por abaratar los costos de la adquisición de imágenes, Chitra, et al. desarrollan un sistema construido con un globo aéreo de alta eficiencia para la adquisición de imágenes suborbitales a color con una alta resolución [22]. Xian & Tian plantean el uso de vehículos aéreos no tripulados (UAVs) para la obtención de imágenes de alta resolución y bajo costo, los UAVs tienen un peso ligero y velocidad baja adecuada para la recolección de información, operan bajo las nubes por lo que son una solución viable a las limitaciones que presentan los satélites, pueden desplegarse rápida y repetidamente, y presentan flexibilidad en cuanto a altura de vuelo, es tecnología poco invasiva y no destructiva, su consumo energético es bajo y son dispositivos seguros ya que

no requieren de un piloto a bordo [23, 24]. Por otro lado, Zhang et al. mencionan que los UAVs presentan como limitaciones la restringida extensión espacial que pueden cubrir en cada vuelo, poca capacidad de carga y baja resolución espectral. A pesar de esto último, el uso de drones en el monitoreo forestal está revolucionando la ecología espacial.[25]

Entre las principales aplicaciones forestales de los UAVs están el mapeo de bosques y biodiversidad, medición de altura y atributos del dosel forestal, monitoreo de la restauración de bosques, predicción de la altura de dosel, monitoreo de la biomasa sobre el suelo, clasificación de especies de árboles, cuantificación de las brechas en el dosel, monitoreo de vida silvestre y poblaciones de plantas, identificación de cazadores furtivos, estudio de la estructura de la vegetación, mapeo del cambio de la cobertura del suelo, entre otros [21, 24, 25].

Uno de los procesos dentro del procesamiento de imagen es la adquisición de imágenes, esta etapa es muy importante ya que la toma de decisiones se deriva del análisis de las imágenes adquiridas. Los UAVs son los elementos a los cuales se integrará la cámara que realizará la adquisición de las imágenes, por lo que su selección se debe realizar de acuerdo con su aplicación. Los criterios de clasificación de los UAVs según Berie & Burud incluyen tamaño, capacidad de carga o carga útil, resistencia de vuelo, rango de vuelo, altitud y otras capacidades [24]. Sin embargo, Banu, G. Borlea & C. Banu mencionan que la clasificación más común de los drones según el tipo de despegue y aterrizaje es UAVs de despegue y aterrizaje horizontal (comprende drones de ala fija) cuya ventaja es cubrir grandes áreas por vuelo, y UAVs de despegue y aterrizaje vertical (comprende drones de ala rotatoria) presentan mejor estabilidad y por lo tanto alta resolución espacial, pero cubren áreas reducidas por vuelo. Tanto la estabilidad de los drones como el área que cubren en cada vuelo son factores determinantes en aplicaciones de teledetección, es necesario considerar el tipo de fuente de alimentación y generalmente se prefiere la eléctrica ya que presenta bajas vibraciones y bajo costo. [21]

Los parámetros que se debe considerar para garantizar una adquisición de imágenes de calidad de acuerdo con Suziedelyte et al. son [26]:

- Los límites del área a ser fotografiada: el tiempo de operación del UAV es el que determina la dimensión del área de estudio y depende de su autonomía.
- El modelo de la cámara, sus parámetros y la escala esperada de las imágenes fotográficas: el modelo de la cámara y sus características definen el tamaño de las imágenes fotográficas que se obtendrá.
- El solapamiento longitudinal y transversal de las fotografías: el tamaño de las imágenes fotografiadas es necesario para calcular la superposición tanto

longitudinal como transversal de las imágenes durante el vuelo y evitar así dejar fuera algún área dentro de la zona de estudio.

- La dirección de vuelo: se define una trayectoria que cubra toda la zona de estudio de la forma más eficaz posible para cumplir la misión optimizando los recursos.
- La velocidad de vuelo: depende de la velocidad del viento.
- La altura de vuelo: se obtiene con la distancia de muestra en tierra (GSD) o conociendo el tamaño de terreno representado por un píxel. Este parámetro depende de la distancia focal de la cámara, del sensor de la cámara y de la distancia cubierta en suelo por una imagen. Para definir la altura de vuelo se considera también la nebulosidad y la niebla presentes.
- El sistema de coordenadas de los datos: es necesario para facilitar el procesamiento de las imágenes y análisis de resultados.

Existen algunos criterios negativos sobre el impacto del uso de drones en la sociedad, según Sandbrook la violación de la privacidad, la contaminación acústica producida por los drones, la cuestionable seguridad de los datos obtenidos, la confusión, hostilidad y miedo de las comunidades que desconocen esta tecnología o a su vez la relacionan con conflictos bélicos son algunos de ellos [27], Paneque, J. et al. enfatiza la pérdida de identidad cultural de las comunidades y conflictos internos debido a la modernización tecnológica que trae consigo la introducción de drones para el monitoreo de zonas forestales [28].

A pesar de los aspectos negativos antes mencionados, el uso de UAVs para el monitoreo de zonas forestales tiene más beneficios que desventajas ya que permite la adquisición de imágenes de zonas poco accesibles o peligrosas a bajo costo y con alta calidad, esto provoca que el proceso de monitoreo se agilite y se optimice. La introducción de nueva tecnología en zonas rurales despierta el interés de la población y su empoderamiento al participar activamente en el manejo sustentable de los recursos forestales.

Salas & Paz estimaron el índice de área foliar usando fotografías digitales y un código de programación en lenguaje Python para automatizar el procesamiento de imágenes. En su estudio mencionan que las mediciones directas del índice de área foliar son imprácticas por su dificultad, tiempo consumido y costo de los equipos de medición, siendo la fotografía digital una alternativa por su bajo costo, mejor resolución, y menos requerimientos de iluminación. Los autores desarrollan también un código en Python que es más eficiente que los softwares comerciales de clasificación [3]. Posteriormente, Salas Aguilar et al.

estiman la cobertura de dosel y la cobertura vegetal en sotobosque utilizando la fotografía digital debido a que esta técnica es confiable y fácil de emplear para extraer información de cobertura vegetal en diferentes condiciones fisiográficas. Una de las desventajas del uso de fotografía digital es su aplicación en áreas pequeñas y homogéneas [29].

El procesamiento de imágenes es importante para determinar la cobertura vegetal, existen algunos softwares comerciales que realizan esta función como LandWorks GIS, ArcGIS, Maptitude, entre otros [2]. En lugar de software propietario, existen softwares libres de código abierto con la filosofía de que el código principal debe ser abierto para que los investigadores aprovechen las ventajas que esto representa, en este contexto el reto de un investigador no está solamente en encontrar un modelo numérico capaz de predecir un fenómeno, sino también el uso e implementación de un software libre de código abierto [6].

En base a estos estudios, la presente tesis trata de desarrollar un código de programación en lenguaje Python cuya función es el procesamiento de imágenes digitales de zonas forestales como una alternativa de bajo costo, en una plataforma de software libre que permita la mejora y adaptación del código principal a las necesidades particulares de futuros investigadores, para realizar un monitoreo constante de zonas forestales garantizando alta precisión en los resultados.

## **1.2. Humedad del suelo**

La clasificación del potencial hídrico del suelo se basa en la disponibilidad de agua para las plantas en el ambiente del suelo. Para comprender la dinámica de la humedad del suelo es necesario conocer los conceptos que se mencionan a continuación [30].

### **1.2.1. Capacidad de campo (F.C)**

La capacidad de campo es una aproximación a la cantidad de agua que se mantiene en el suelo después de que este se ha humedecido por completo y el agua en exceso se haya drenado, por lo general se alcanza entre uno y dos días después de que las lluvias o el riego hayan cesado. En un suelo de textura gruesa como arena franca se alcanza mucho más rápido que en uno de textura fina como la arcilla pesada.

En la capacidad de campo el suelo contiene la cantidad máxima de agua que puede ser almacenada y que las plantas pueden usar, también cuenta con espacio suficiente de poro

con aire, lo que permite la aireación necesaria para que se lleve a cabo la actividad microbiana aeróbica y el crecimiento de las plantas. Si existe mayor cantidad de agua que la de capacidad de campo el suelo se convierte en lodo lo cual lo hace inviable.

Cuanta más superficie tenga el suelo, mayor es la cantidad de agua que absorbe. Un suelo arcilloso puede contener mayor cantidad de agua que un suelo arenoso.

### 1.2.2. Punto de marchitamiento permanente (P.W.P)

Es la humedad mínima del suelo en la cual una planta se marchita y no puede recuperar su turgencia, visualmente el suelo en P.W.P luce polvoriento y seco. Es necesario aclarar que hay agua presente en los microporos y en finas películas alrededor de las partículas del suelo. Esta agua se mantiene unida al suelo debido a las fuerzas de adhesión y las plantas y microbios no pueden usarla.

### 1.2.3. Contenido de agua disponible (A.W.C)

Es la cantidad de agua contenida entre el punto de marchitamiento permanente y la capacidad de campo, esta cantidad de agua en el suelo está potencialmente disponible para las plantas.




Figura 1.2. Representación del contenido de agua en el suelo.  
(Fuente: [http://www.terragis.bees.unsw.edu.au/terraGIS\\_soil/sp\\_water-soil\\_moisture\\_classification.html](http://www.terragis.bees.unsw.edu.au/terraGIS_soil/sp_water-soil_moisture_classification.html))

El contenido de humedad según la textura del suelo se detalla en la Tabla 1.1.

Tabla 1.1. Humedad del suelo según su textura.

TEXTURA DEL SUELO	HUMEDAD DEL SUELO (cm <sup>3</sup> /cm <sup>3</sup> )		
	F.C	P.W.P	A.W.C
<b>Arena</b>	0,07-0,17	0,02-0,07	0,05-0,10
<b>Arena Arcillosa</b>	0,11-0,19	0,03-0,10	0,08-0,09
<b>Arena Franca</b>	0,18-0,28	0,06-0,16	0,12-0,14



<b>Marga</b>	0,20-0,30	0,07-0,17	0,13-0,13
<b>Marga Limosa</b>	0,22-0,36	0,09-0,21	0,11-0,15
<b>Limo</b>	0,28-0,36	0,12-0,22	0,14-0,14
<b>Marga de Arcilla Limosa</b>	0,30-0,37	0,17-0,24	0,13-0,13
<b>Arcilla Limosa</b>	0,30-0,42	0,17-0,29	0,13-0,13
<b>Arcilla</b>	0,32-0,40	0,20-0,24	0,12-0,16

(Fuente: [http://www.terragis.bees.unsw.edu.au/terraGIS\\_soil/sp\\_water-soil\\_moisture\\_classification.html](http://www.terragis.bees.unsw.edu.au/terraGIS_soil/sp_water-soil_moisture_classification.html))

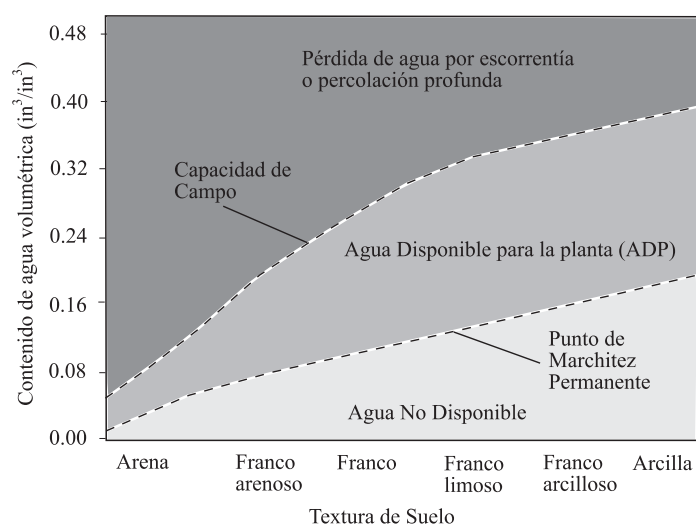


Figura 1.3. Textura del suelo y contenido de agua.  
(Fuente: [31])

En la Figura 1.3 se muestra la relación entre la textura del suelo, su contenido de agua, el punto de marchitamiento permanente, el agua disponible y la capacidad de campo. Como se puede observar el contenido de agua es mayor mientras más cerca está de la capacidad de campo.

Para la presente tesis se establece que la vegetación más verde se encuentra en un suelo cuya humedad es igual a la capacidad de campo, la vegetación menos verde o amarillenta se encuentra en un suelo cuya humedad es igual al agua disponible y la humedad para el suelo desnudo corresponde al punto de marchitamiento permanente. Estos criterios se establecen para relacionar los resultados obtenidos del procesamiento de imagen con la humedad del suelo que es la propiedad físico-térmica que se analiza en la presente tesis.

## 2. METODOLOGÍA

En esta sección se detalla la metodología general para el desarrollo del código de programación para el estudio de zonas forestales, y posteriormente, la metodología empleada para el procesamiento de imágenes tanto en escala de grises como a color.

### 2.1. Estrategia metodológica

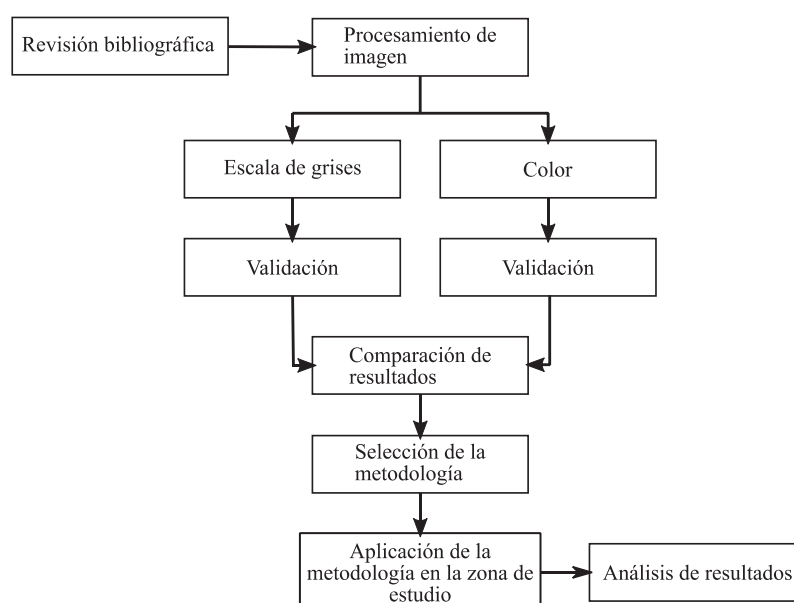


Figura 2.1. Metodología de desarrollo del código de programación para el estudio de zonas forestales.  
(Fuente: Propia)

En la Figura 2.1 se detalla la metodología seguida para el desarrollo del código de programación para el estudio de zonas forestales. En primera instancia se realiza la revisión bibliográfica referente al procesamiento de imagen y sus aplicaciones forestales, en base a la revisión bibliográfica realizada se desarrolla el código de programación en lenguaje Python que se divide en dos metodologías. En la primera metodología se desarrolla un código para el procesamiento de imágenes en escala de grises, y en la segunda un código para el procesamiento de imágenes a color. Las dos metodologías se validan mediante comparación, para esto se ha seleccionado el artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery” [4]. En este artículo se realiza la estimación del porcentaje de cobertura vegetal usando imágenes satelitales, NDVI junto con banda azul, y métodos supervisados

y no supervisados para la clasificación. Una vez validadas las metodologías desarrolladas se selecciona la metodología óptima para el estudio de zonas forestales en función de los resultados que cada una entrega. Finalmente, se aplica la metodología seleccionada al procesamiento de imágenes del Refugio de Vida Silvestre La Chiquita (zona de estudio de la presente tesis) y se analizan los resultados obtenidos.

La optimización del código de programación responde a la necesidad de mejorar la eficiencia y calidad del código, logrando así, menor consumo de memoria, energía y tiempo [32, 33]. La optimización puede realizarse por un optimizador (software) o por el programador, y generalmente se lleva a cabo al finalizar el desarrollo del código. Se clasifican en [32]:

- Optimizaciones de alto nivel: realizadas generalmente por el programador que conoce el objetivo que se debe cumplir y maneja funciones, procedimientos, clases, entre otros elementos del código fuente para optimizar el diseño del sistema.
- Optimizaciones de bajo nivel: se realizan durante la compilación del código fuente en un conjunto de instrucciones de la máquina y por lo general se emplea la optimización automatizada.

En la presente tesis la optimización se realiza manualmente y consiste en reducir al máximo las líneas del código con la finalidad de eliminar redundancias y código innecesario para obtener un código refinado, como parte de la optimización del código se utilizan dos modelos de color, se compara sus resultados y se elige el mejor para obtener un código robusto, efectivo y funcional. En el Anexo I se indica el código optimizado para el procesamiento de imagen en escala de grises y a color para el estudio de zonas forestales.

## **2.2. Procesamiento de imagen**

El desarrollo de un código de programación para el estudio de zonas forestales tiene como parte fundamental el procesamiento de imágenes, ya que el procesamiento de imágenes transforma datos en información útil.

Deenan & SatheeshKumar en su artículo “Métodos de Procesamiento de Imagen y su Rol en el Sector de la Agricultura – Estudio A” mencionan que el procesamiento de imagen comprende [34]:

- Adquisición de la imagen: adquirir la imagen y almacenarla en un medio digital.
- Mejoramiento de la imagen: manipulación de la imagen para mejorar su calidad (pre y post procesamiento), pueden ser:

- Técnicas espaciales: manipulación directa en los píxeles de la imagen.
- Técnicas en el dominio de la frecuencia: manipulación indirecta usando convolución o núcleos.

El filtrado o mejoramiento de una imagen se aplica para suprimir o enfatizar ciertos detalles de la imagen, si la imagen contiene alguna señal o estructura con variaciones no interesantes o no deseadas, estas se suprimen [35]. El filtrado de una imagen hace referencia a la aplicación de operadores que mejoran la detectabilidad de detalles importantes u objetos, ejemplos de operaciones de filtrado incluyen:

- Reducción de ruido
- Suavizado
- Estiramiento de contraste
- Realce de bordes

Existen variedad de operadores de filtrado de imágenes como convolución 2D, suavizado promedio, suavizado Gaussiano, entre otros [36].

La utilización y selección del tipo de filtro es particular para cada caso y depende del mejoramiento que se quiera realizar en la imagen.

- Análisis de la imagen: análisis cuantitativo y cualitativo de la información obtenida de la imagen, comprende extracción de características, segmentación, clasificación, mediciones e interpretaciones. Se separa la zona de interés del resto de la imagen (región no deseada) basándose en el tamaño, color, forma y textura de un objeto dentro de la imagen. La extracción de características tiene como objeto extraer información relevante que caracterice a cada clase, es decir, obtiene información discriminante para distinguir a los objetos que pertenecen a una clase de los objetos que pertenecen a otra clase. Las características pueden ser locales (generalmente son geométricas) y globales (topológicas) [37].
- Reconocimiento de objetos: la zona de interés se convierte en información útil para interpretación y toma de decisiones. Se usan métodos como clasificadores estadísticos, redes neuronales, máquinas de vectores de soporte, transformación de características en escala invariante y características robustas aceleradas.

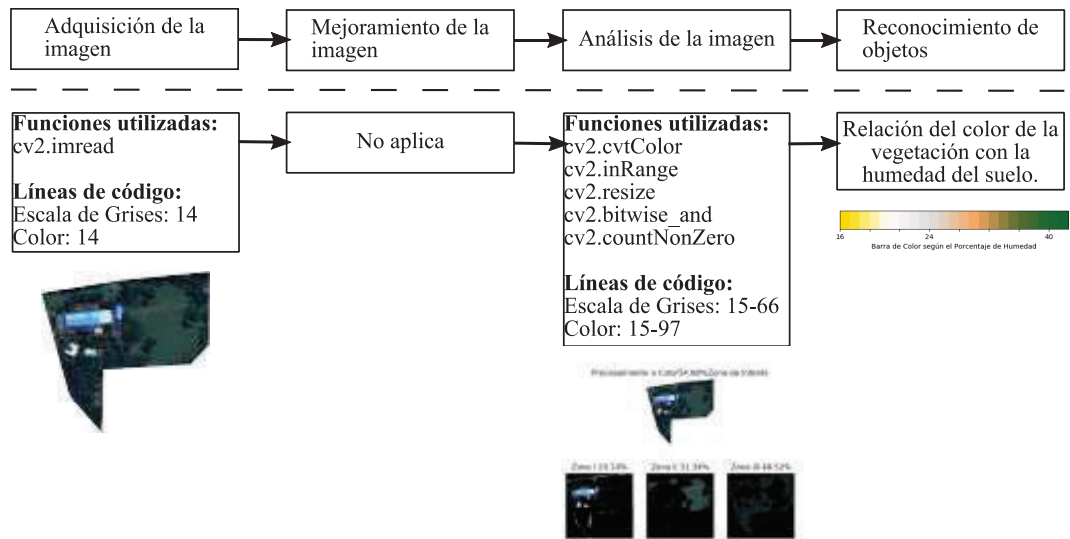


Figura 2.2. Metodología de procesamiento de imagen.  
(Fuente: Propia)




Figura 2.3. Proceso de análisis de imagen.  
(Fuente: Propia)

En la parte superior de la Figura 2.2 se indica la metodología utilizada para el procesamiento de imagen. En la parte inferior de la Figura 2.2 se indican las funciones, las líneas de código utilizadas y el resultado de cada proceso que conforma la metodología antes mencionada, el código se puede ver en el Anexo I. En las secciones siguientes esta metodología se desarrollará tanto para el procesamiento de imagen en escala de grises como para el procesamiento de imagen a color.

En la Figura 2.3 se indica el proceso de análisis de imagen que se aplicará durante el procesamiento de imagen en escala de grises y a color de zonas forestales, este contiene operaciones de segmentación y de extracción de características.

## 2.2.1 Procesamiento de imagen en escala de grises

### 2.2.1.1 Adquisición de la imagen

La imagen digital con la que se realiza la validación de la metodología propuesta para el procesamiento de imagen en escala de grises de una zona forestal se obtiene del artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery” y corresponde a una parte del aeropuerto Halim Perdana Kusuma.

Python es el programa en el cual se realizará el procesamiento de imagen y se utilizan las librerías OpenCv, Numpy y Matplotlib.

Una vez que se tiene la imagen digital que se va a procesar, se procede a importarla usando para esto la librería OpenCv con el segundo argumento como UNCHANGED (esto permite la lectura del canal alpha).



Figura 2.4.(a) Imagen de la zona de estudio. (b) Imagen original del satélite Pleiades.  
(Fuente: [4])

### 2.2.1.2 Mejoramiento de la imagen

En la presente tesis no se aplica ninguna de las técnicas de filtrado porque como se menciona en la sección 2.2 al aplicar filtros se suprimen ciertos detalles de la imagen, esto último no es deseable en el desarrollo de un código de programación para el estudio de zonas forestales ya que se necesita considerar toda la información para entender a detalle el fenómeno que se está analizando. Acorde a estudios previos donde se utiliza el procesamiento de imagen para validar la simulación en CFD [38], se concluye que la pérdida de datos en las imágenes como resultado del filtrado es una de las causas de la falta de exactitud numérica del método, con el objetivo de reducir la inexactitud numérica

del método de procesamiento de imágenes de zonas forestales en la presente tesis no se aplican filtros en las imágenes motivo de análisis.

El pre-procesamiento de imagen que se aplica en la presente tesis consiste en extraer la zona de estudio de la imagen del aeropuerto Halim Perdana Kusuma, esto se evidencia en la Figura 2.4. A pesar de que la zona de estudio es irregular, la imagen que la contiene es un rectángulo (82x79 píxeles), por esta razón y debido a que la información fuera de la zona de estudio no es de interés se le asigna píxeles alpha que son totalmente transparentes y no contribuyen en nada a la imagen resultante.

### 2.2.1.3 Análisis de la imagen

El siguiente paso es convertir la imagen de entrada a RGB para imprimir los resultados usando la librería Matplotlib. La única diferencia que existe entre BGR (modo de color por defecto de OpenCv) y RGB es el orden de sus componentes, para la conversión a RGB únicamente se reordenan los componentes.

Posteriormente, se convierte la imagen de entrada a escala de grises para su procesamiento y se contabiliza el número de píxeles que la conforman. Para la conversión a escala de grises se utiliza la ecuación 2.1 [39]. Cada píxel de la imagen importada a Python tiene un color dado por los componentes  $B$ ,  $G$  y  $R$ , los valores de cada uno de estos componentes se introducen en la ecuación 2.1 para obtener su equivalente en escala de grises ( $Y$ ) que puede tomar un valor entre 0 y 255. Este cálculo lo realiza internamente Python y como resultado se obtiene una imagen en escala de grises.

El contador devuelve el número de elementos que no son cero dentro de un arreglo de un solo canal y está dado por la ecuación 2.2 [40], debido a que trabaja con arreglos de un solo canal, se aplica el contador a la imagen una vez que se la ha transformado a escala de grises. La expresión del contador indica la sumatoria de todos los píxeles cuyo valor es 1 dentro de un arreglo, el valor de 1 indica que el píxel forma parte del arreglo.

$$Y = 0,299 \cdot R + 0,587 \cdot G + 0,114 \cdot B \quad \text{Ecuación 2.1}$$

$$\sum_{I:src(I) \neq 0} 1 \quad \text{Ecuación 2.2}$$

A continuación, se separa la zona de interés de la zona alpha, para lo cual se realiza la primera segmentación de la imagen y se contabiliza la cantidad de píxeles que corresponden a cada zona. El rango de intensidad de una imagen en escala de grises va

desde 0 a 255. La primera segmentación de la imagen en escala de grises con la que se separa la zona de interés de la zona alpha se muestra en la Figura 2.5.




Figura 2.5. Rango de segmentación para la zona de interés y la zona alpha de la imagen en escala de grises.  
(Fuente: Propia)

La función que se utiliza para la segmentación es `inRange`, en la cual se definen los límites de cada zona en la que se quiere segmentar la imagen [40]. Esta función separa los elementos definidos entre e incluyendo los límites superior e inferior del resto de elementos de la matriz.

`cv2.inRange(src, lowerb, upperb[, dst]) → dst`

Dónde:

- `src`: primera matriz de entrada.
- `lowerb`: límite inferior inclusivo puede ser una matriz o un escalar.
- `upperb`: límite superior inclusivo puede ser una matriz o un escalar.
- `dst`: matriz de salida de la misma dimensión que la matriz de entrada y tipo `CV_8U`.

La función verifica el rango de la siguiente manera:

- Para cada elemento de una matriz de entrada de un solo canal:

$$dst(I) = lowerb(I)_0 \leq src(I)_0 \leq upperb(I)_0 \quad \text{Ecuación 2.3}$$

- Para una matriz de dos canales y así sucesivamente si el número de canales de la matriz de entrada aumenta:

$$dst(I) = lowerb(I)_0 \leq src(I)_0 \leq upperb(I)_0 \wedge lowerb(I)_1 \leq src(I)_1 \leq upperb(I)_1 \quad \text{Ecuación 2.4}$$

La ecuación 2.3 se aplica para la segmentación de la imagen durante el procesamiento en escala de grises, debido a que la matriz de entrada es de un solo canal, para lo cual se fijan los límites inferior y superior de cada una de las zonas de segmentación y la matriz de entrada corresponde a la imagen en escala de grises. La detección de los píxeles que están incluidos dentro de los límites fijados es un proceso interno y como resultado se obtiene la



máscara que se aplicará a la imagen original, en esta máscara los pixeles blancos indican los elementos dentro de los límites fijados y que se visibilizarán en la imagen original.

Debido a que la imagen que se está procesando es muy pequeña porque se extrae desde un artículo es necesario incrementar su escala a fin de facilitar la comparación visual del procesamiento usando Python con el procesamiento desarrollado en el artículo. La interpolación bicúbica es la interpolación más adecuada para amplificar imágenes porque preserva detalles finos y es el estándar usado en programas comerciales de edición de imagen [41], esta amplificación se aplica solamente a la imagen que se va a imprimir, esto último para no alterar la imagen original. La interpolación bicúbica está dada por la ecuación 2.5 [41, 42], y utiliza los dieciséis vecinos más cercanos al punto  $(x, y)$  para evaluar la función de interpolación, este proceso ocurre internamente y su resultado es la imagen ampliada. En la función `resize` se introduce la imagen que se requiere ampliar, la escala de ampliación para  $x$  y  $y$ , y el tipo de interpolación que se va a aplicar, en este caso `INTER_CUBIC`.

$$v(x, y) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij} x^i y^j$$

$$v(x, y) = \begin{bmatrix} x^3 & x^2 & x & 1 \end{bmatrix} \begin{bmatrix} a_{3,3} & a_{3,2} & a_{3,1} & a_{3,0} \\ a_{2,3} & a_{2,2} & a_{2,1} & a_{2,0} \\ a_{1,3} & a_{1,2} & a_{1,1} & a_{1,0} \\ a_{0,3} & a_{0,2} & a_{0,1} & a_{0,0} \end{bmatrix} \begin{bmatrix} y^3 \\ y^2 \\ y \\ 1 \end{bmatrix}$$

Ecuación 2.5

Una vez que se ha definido la zona de interés, se procede a segmentarla en tres zonas que son: zona de no vegetación o con vegetación dispersa, zona de vegetación media – baja y zona de vegetación media – alta. Los rangos de segmentación de cada zona se indican en la Figura 2.6 y las máscaras de cada una de las zonas de segmentación en la Figura 2.7. Las máscaras se generan usando la función `inRange` y mediante la función `bitwise_and` se unen con la imagen original, en donde los pixeles blancos de la máscara representan la parte visible de la imagen original mientras que los pixeles negros representan la parte no visible de la imagen original. La función `bitwise_and` se desempeña igual que el operador lógico “y”, que cuando los dos operandos son verdaderos la condición es verdadera, es decir, cuando los pixeles de la imagen coinciden con los pixeles blancos de la máscara la condición es verdadera. La función `bitwise_and` se utiliza para unir dos arreglos o un escalar y un arreglo [40].

`cv2.bitwise_and(src1, src2[, dst[, mask]]) → dst`

Dónde:

- src1: primera entrada puede ser un arreglo o un escalar.
- src2: segunda entrada puede ser un arreglo o un escalar.
- dst: arreglo de salida que tiene la misma dimensión y tipo que los arreglos de entrada.
- mask: operación de máscara opcional, matriz de un solo canal de 8 bits que especifica los elementos de la matriz de salida a ser cambiados.

La función calcula la unión lógica bitwise por elemento para:

- Dos matrices cuando src1 y src2 tienen la misma dimensión.

$$dst(I) = src1(I) \wedge src2(I), \text{ si } mask(I) \neq 0 \quad \text{Ecuación 2.6}$$

- Una matriz y un escalar cuando src2 se construye de un escalar o tiene el mismo número de elementos que src1.channels().

$$dst(I) = src1(I) \wedge src2, \text{ si } mask(I) \neq 0 \quad \text{Ecuación 2.7}$$

- Un escalar y una matriz cuando src1 se construye de un escalar o tiene el mismo número de elementos que src2.channels().

$$dst(I) = src1 \wedge src2(I), \text{ si } mask(I) \neq 0 \quad \text{Ecuación 2.8}$$

Cuando se tienen arreglos multicanal, cada canal se procesa independientemente.

En el procesamiento de imagen en escala de grises se aplica la ecuación 2.6 debido a que tanto la imagen como la máscara son arreglos matriciales.




Figura 2.6. Rango de segmentación para las zonas 1, 2 y 3 en escala de grises.  
(Fuente: Propia)

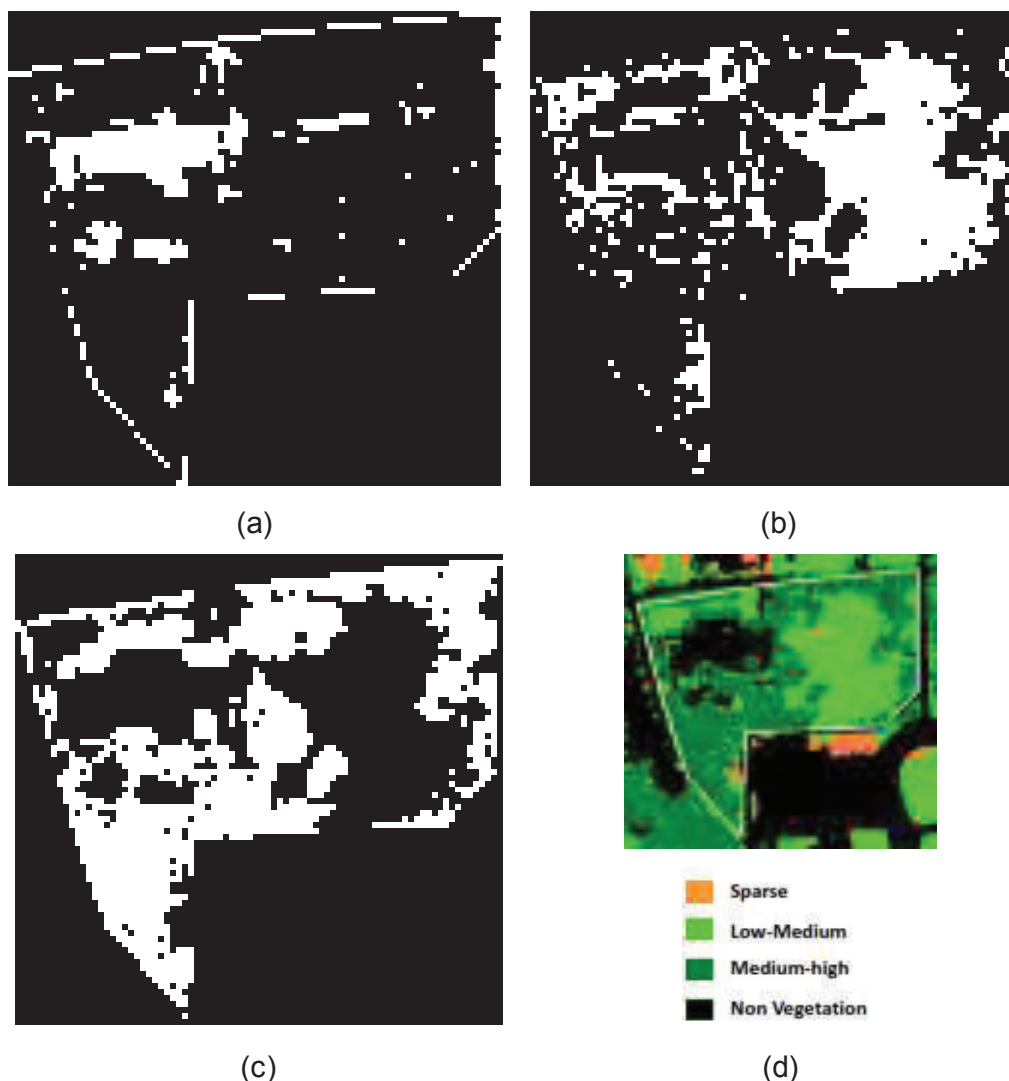


Figura 2.7.(a) Máscara Zona 1 no vegetación o vegetación dispersa. (b) Máscara Zona 2 vegetación media - baja. (c) Máscara Zona 3 vegetación media - alta. (d) Resultados de la clasificación de la vegetación del artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery”.  
(Fuente: Propia (a), (b), (c); [4] (d))

En la Figura 2.7 (a) en la parte superior izquierda se observa en blanco una forma rectangular, bajo esta se observan dos formas irregulares más pequeñas, y sobre esta se observa una forma irregular, todas estas regiones corresponden a la zona de no vegetación que se indica en negro en la Figura 2.7 (d). En las Figuras 2.7 (a) y (d) se observa en blanco la línea que delimita la zona de interés. La pequeña región blanca que se encuentra a la derecha de la región rectangular y la región irregular que se encuentra en la parte inferior izquierda de la Figura 2.7 (a) corresponden a la zona de vegetación dispersa que se indica en naranja en la Figura 2.7 (d).

La Figura 2.7 (b) indica en el lado derecho la región de mayor tamaño que corresponde a la región de media – baja vegetación indicada en color verde claro en la Figura 2.7 (d),

también se observa en la parte superior izquierda una región irregular de gran tamaño, bajo esta última se observan algunas regiones irregulares de tamaños distintos y en la parte inferior izquierda una región irregular aislada, todas estas regiones corresponden a la región de media – baja vegetación.

La Figura 2.7 (c) indica la mayor concentración de píxeles blancos en la parte inferior izquierda de la imagen, el resto de los píxeles bordean las regiones indicadas en las Figuras 2.7 (a) y (b) y corresponden a la zona de media – alta vegetación que se indica en la Figura 2.7 (d) en color verde oscuro.

Al comparar visualmente las regiones descritas en las Figuras 2.7 (a), (b) y (c) con las zonas de la Figura 2.7 (d) se observa que la segmentación realizada describe aceptablemente la zona de interés y cada una de sus zonas de segmentación.

Posteriormente se realiza el conteo de los píxeles correspondientes a cada una de las zonas de segmentación para obtener el porcentaje de cada tipo de vegetación obtenido mediante el procesamiento de imagen con el código desarrollado en Python.

Tabla 2.1. Resultados del procesamiento de imagen en escala de grises aplicando el código desarrollado en Python.

<b>ZONA</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona3</b>	<b>Σ</b>	<b>Zona de</b>	<b>Zona</b>	<b>Imagen Escala</b>
					<b>Interés</b>	<b>Alpha</b>	<b>de Grises</b>
<b>Nº Píxeles</b>	597	1389	1798	3784	3720	2758	6478
<b>Porcentaje (%)</b>	15,78	36,71	47,52	58,41	57,43	42,57	100

(Fuente: Propia)

Los valores indicados en la Tabla 2.1 correspondientes al número de píxeles de cada zona de segmentación y al porcentaje que representan son el resumen de resultados que se obtienen del procesamiento de imagen en escala de grises.

Procesamiento Escala de Grises 58.41% Zona de Interés

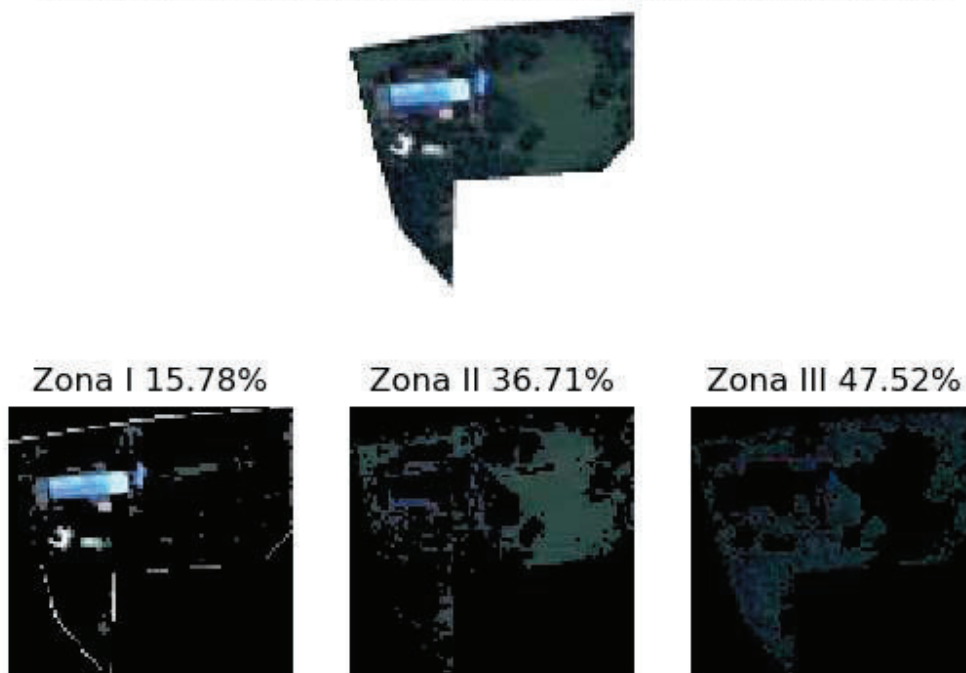


Figura 2.8. Zonas forestales procesamiento en escala de grises (resultados del procesamiento de imagen aplicando el código desarrollado en Python).  
(Fuente: Propia)

En la Figura 2.8 se observa cada una de las zonas de segmentación, la Zona 1 corresponde a la zona de no vegetación o vegetación dispersa, la Zona 2 a la zona de media – baja vegetación y la Zona 3 a la zona de media – alta vegetación. La sumatoria de los porcentajes de las tres zonas constituyen el 100% de pixeles dentro de la zona de interés. En la parte superior de la Figura 2.8 se observa el porcentaje que ocupa la zona de interés dentro de la imagen de 82x79 pixeles de dimensión que se utiliza en el presente análisis.

El rasgo distintivo de cada zona de segmentación es el color, a pesar de que la segmentación por color de una zona forestal es complicada debido a que la coloración general es verde se observa que existen diferentes tipos de verde que sirven para diferenciar una zona de otra. Al convertir la imagen a escala de grises este particular se conserva y se traduce en distintas tonalidades de gris, por lo que el color es adecuado como característica de segmentación de la imagen. La determinación del color como factor discriminante durante la segmentación corresponde a la extracción de características que es una operación dentro del proceso de análisis de la imagen.

#### **2.2.1.4 Reconocimiento de objetos**

Como se menciona en la sección 2.2 en el reconocimiento de objetos la zona de interés se convierte en información útil para la interpretación y la toma de decisiones, por lo tanto, en este paso se relaciona la humedad del suelo con el color de la vegetación. Esta relación se desarrolla únicamente para el área de estudio del Refugio de Vida Silvestre La Chiquita que se describe en las próximas secciones luego de definir la metodología adecuada para el procesamiento de imágenes de zonas forestales y aplicarla al procesamiento de imágenes del área de estudio seleccionada.

En la Tabla 2.1 se observa que la sumatoria de los pixeles de las tres zonas de segmentación es de 3784, mientras que el número de pixeles de la zona de interés es de 3720. Tanto la sumatoria de pixeles de las tres zonas de segmentación como el número de pixeles de la zona de interés deberían ser valores iguales, que la sumatoria de pixeles de las tres zonas de segmentación sea mayor que el número de pixeles de la zona de interés indica que ciertos pixeles de las tres zonas se sobreponen, incrementando así el número de pixeles de la zona de interés. Con la finalidad de resolver el particular antes mencionado se realiza el procesamiento de imagen a color a pesar de que los resultados obtenidos del procesamiento de imagen en escala de grises son aceptables.

La validación de la metodología para el procesamiento de imágenes en escala de grises de zonas forestales se detalla en la sección 3.1.

### **2.2.2 Procesamiento de imagen a color**

#### **2.2.2.1 Adquisición de la imagen**

La imagen digital con la que se realiza la validación de la metodología propuesta para el procesamiento de imagen a color de una zona forestal es la misma que se utiliza en la sección 2.2.1, también se utilizan las librerías OpenCv, Numpy y Matplotlib.

Una vez que se tiene la imagen digital que se va a procesar, se procede a importarla usando para esto la librería OpenCv con el segundo argumento como UNCHANGED.

### 2.2.2.2 Mejoramiento de la imagen

En la presente tesis no se aplica ninguna de las técnicas de filtrado para evitar la pérdida de datos en base a los criterios expuestos en la sección 2.2.1.2. Al igual que en la sección anterior, el pre-procesamiento consiste en extraer la zona de estudio de la imagen del aeropuerto Halim Perdana Kusuma (ver Figura 2.4).

### 2.2.2.3 Análisis de la imagen

La segmentación de una imagen en color tiene como objeto su descomposición en particiones significativas, dependiendo de las aplicaciones existen diferentes tipos de técnicas de segmentación. Por otro lado, la elección del espacio de color influye significativamente en el resultado de la segmentación de la imagen. Existen algunos espacios de color incluyendo RGB, YCbCr, YUV, HSV, CIE L\*a\*b, y CIE L\*u\*v. A pesar de que RGB, YCbCr, y YUV se usan comúnmente en datos en bruto y normas de codificación, no se acercan a la percepción humana. Por otro lado, los espacios de color CIE son perceptualmente uniformes, pero necesitan cálculos complicados. HSV presenta mejores resultados en segmentación de imagen que RGB, es capaz de enfatizar la percepción visual humana en tonalidad y es fácilmente reversible a RGB [23]. Por lo antes mencionado en la presente tesis se utiliza el modelo de color HSV para realizar el procesamiento de imagen a color.

El siguiente paso es convertir la imagen de entrada a RGB y a HSV. Como se menciona en la sección 2.2.1.3, para la conversión a RGB solamente se reordenan sus componentes, mientras que para la conversión a HSV los valores de cada uno de los componentes RGB de la imagen se introducen en la ecuación 2.9 para obtener su equivalente en HSV [39].

$$V = \max(R, G, B)$$
$$S = \begin{cases} \frac{V - \min(R, G, B)}{V}, & \text{si } V \neq 0 \\ 0, & \text{de otra manera} \end{cases}$$
$$H = \begin{cases} \frac{60(G - B)}{(V - \min(R, G, B))}, & \text{si } V = R \\ 120 + \frac{60(B - R)}{(V - \min(R, G, B))}, & \text{si } V = G \\ 240 + \frac{60(R - G)}{(V - \min(R, G, B))}, & \text{si } V = B \end{cases}$$

Ecuación 2.9

Si  $H < 0$  entonces  $H = H + 360$ .

En las salidas se tiene:  $0 \leq V \leq 1$   
 $0 \leq S \leq 1$   
 $0 \leq H \leq 360$

Los valores pueden convertirse al tipo de datos de destino, con lo que se obtiene:

- Imágenes de 8 bits (0 – 255)

$$V = 255V$$

$$S = 255S$$

$$H = \frac{H}{2}$$

- Imágenes de 16 bits (actualmente no es compatible)

$$V < -65535V$$

$$S < -65535S$$

$$H < -H$$

- Imágenes de 32 bits: H, S y V se dejan tal como se calcularon con la Ecuación 2.9.

La imagen RGB se utiliza para aplicar en ella las máscaras debido a que es el formato de color en el que trabaja Matplotlib que se utiliza para mostrar los resultados obtenidos, mientras que la imagen en HSV se utiliza para definir los límites superior e inferior de las máscaras para cada una de las zonas porque este es el modelo de color que se ha seleccionado para realizar el procesamiento de imagen a color.

A continuación, se separa la zona de interés de la zona alpha que viene a ser la primera segmentación de la imagen. Para lo cual se definen un límite inferior y un límite superior aplicando el modelo HSV que consta de tres argumentos, tonalidad (hue), saturación (saturation) y brillo (value). Para contabilizar la cantidad de pixeles que corresponden a cada zona se utiliza el contador definido con la ecuación 2.2.

HSV es un espacio de color cilíndrico en donde la tonalidad (hue) se expresa en la dimensión angular que gira alrededor de un eje central vertical, la saturación define los tonos de matiz desde menos saturado en el centro hasta lo más saturado que se encuentra en la porción del cilindro más alejada del centro, y el valor o brillo va desde la oscuridad en la parte inferior del cilindro hasta la luz en la parte superior [43]. En el código que se desarrolla en la presente tesis los valores de tonalidad, saturación y brillo van desde 0 hasta 255 ya que se usa el código de caracteres de 8 bits para su representación.



El rango de tonalidad que ocupa la zona de interés en el procesamiento de imagen a color aplicando el modelo HSV se indica en la Figura 2.9.




Figura 2.9. Rango de tonalidad de la zona de interés.  
(Fuente: Propia)

La función que se utiliza para la segmentación es `inRange` (definida en la sección anterior) para definir los límites de cada zona en la que se quiere segmentar la imagen y se aplica la forma de la ecuación 2.4 para tres canales (HSV). Para ampliar la escala de las imágenes que se imprimen y facilitar la comparación visual se aplica la interpolación bicúbica definida en la ecuación 2.5.

Una vez que se ha definido la zona de interés, se procede a segmentarla en las tres zonas definidas en la sección 2.2.1.3. Los rangos de segmentación en tonalidad de cada zona se indican en la Figura 2.10.




Figura 2.10. Rango de segmentación de tonalidad para las zonas 1, 2 y 3.  
(Fuente: Propia)

En la segmentación de la zona de no vegetación o vegetación dispersa la máscara se compone de dos sub-máscaras, esto debido a que la primera sub-máscara que se genera deja fuera algunos datos. Las dos sub-máscaras se superponen y forman una máscara resultante que corresponde a la zona de no vegetación o vegetación dispersa. Las sub-máscaras y la máscara que conforman la zona 1 se indican en la Figura 2.11.

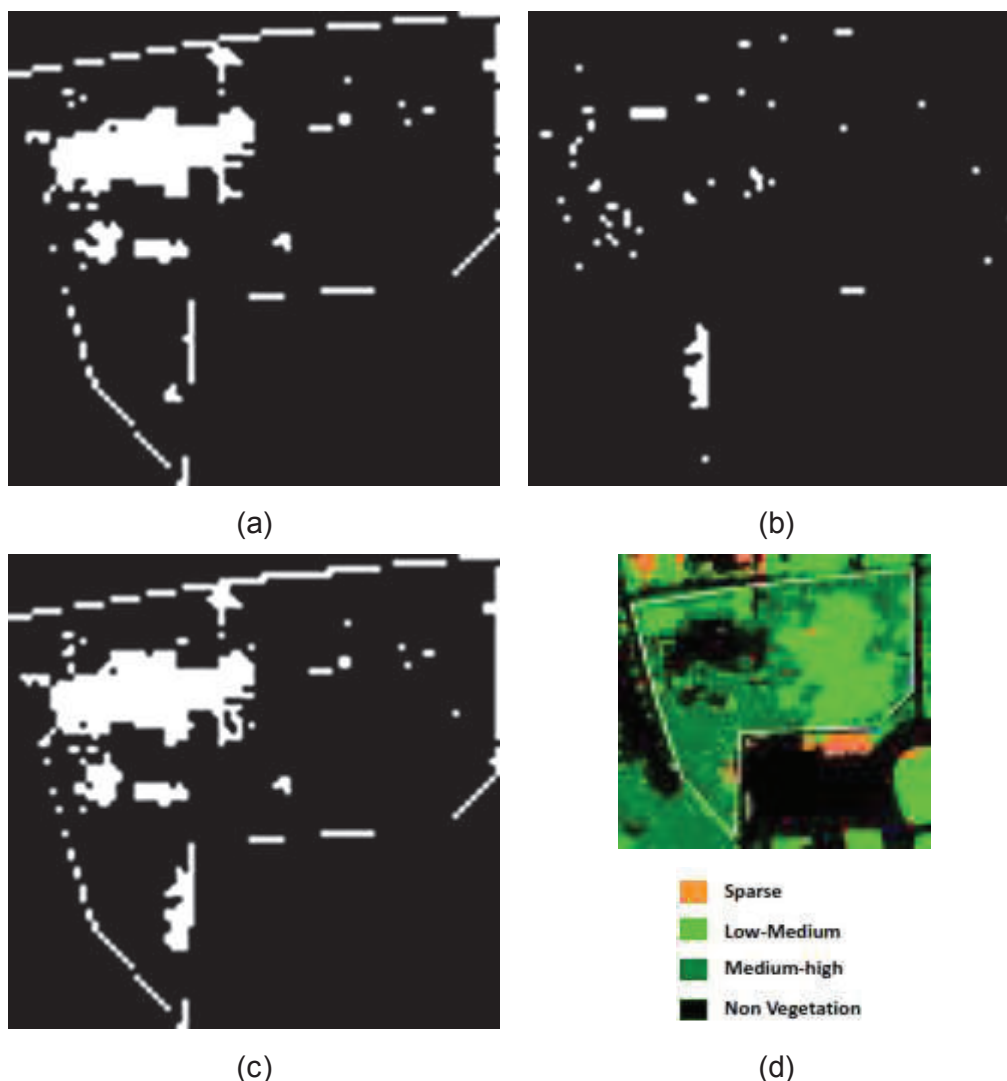


Figura 2.11. (a), (b) Sub-máscaras de la Zona 1. (c) Máscara resultante de la Zona 1. (d) Resultados de la clasificación de la vegetación del artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery”.  
(Fuente: Propia (a), (b), (c); [4] (d))

En la Figura 2.11 (a) se observa que los píxeles blancos representan la mayor parte de la región de no vegetación y vegetación dispersa que se indica en negro y naranja respectivamente en la Figura 2.11 (d), también es evidente que a la región rectangular de la parte superior izquierda de la Figura 2.11 (a) le falta una parte en el borde superior para asemejarse mejor a la región rectangular de la Figura 2.11 (d), así también la parte inferior derecha de la región rectangular de la Figura 2.11 (a) está abierta mientras que en la Figura 2.11 (d) se evidencia cerrada ya que rodea a una pequeña región circular de vegetación media – alta. Además, es notorio que la pequeña región ubicada en la parte inferior izquierda de la Figura 2.11 (a) corresponde a la región de vegetación dispersa que se indica en color naranja en la Figura 2.11 (d), pero no se describe la zona de no vegetación que se ubica sobre esta región de vegetación dispersa.

La Figura 2.11 (b) indica los píxeles en blanco que se adicionarán a la primera sub-máscara indicada en la Figura 2.11 (a).

En la Figura 2.11 (c) se observa la máscara resultante de la unión de las dos sub-máscaras que la componen. Es evidente que la región rectangular de la Figura 2.11 (c) se asemeja más a la región de no vegetación de la Figura 2.11 (d) que la región indicada en la Figura 2.11 (a), la forma de las pequeñas regiones bajo la región rectangular es más parecida entre las Figuras 2.11 (c) y (d) que las que se muestran en la Figura 2.11 (a). El único inconveniente que se evidencia es que en la parte inferior izquierda en donde se encuentra una región de no vegetación junto con una región de vegetación dispersa se mezcla con la región de vegetación media – baja que está alrededor de la pequeña zona de no vegetación incrementando su tamaño, pero debido a que la región correspondiente a vegetación media – baja es una región pequeña, este incremento se considera insignificante en el análisis global de la imagen.

Las máscaras de cada una de las zonas de segmentación se generan usando la función `inRange` para tres canales y mediante la función `bitwise_and` se unen con la imagen original al igual que se desarrolló en la sección anterior al realizar el procesamiento de imagen en escala de grises. Las máscaras de cada una de las zonas de segmentación se indican en la Figura 2.12.

En la Figura 2.12 (a) en la parte superior izquierda se observa en blanco una forma rectangular, bajo esta se observan dos formas irregulares más pequeñas, y sobre esta se observa una forma irregular, todas estas regiones corresponden a la zona de no vegetación que se indica en negro en la Figura 2.12 (d). La región ubicada en la parte inferior izquierda de la Figura 2.12 (a) corresponde a la zona compuesta por vegetación dispersa y no vegetación de la Figura 2.12 (d) junto con la pequeña zona de media – baja vegetación que bordea las otras dos zonas mencionadas. En las Figuras 2.12 (a) y (d) se observa en blanco la línea que delimita la zona de interés. Los píxeles blancos dispersos que se encuentran a la derecha de la región rectangular de la Figura 2.12 (a) corresponden a la zona de vegetación dispersa que se indica en naranja en la Figura 2.12 (d).

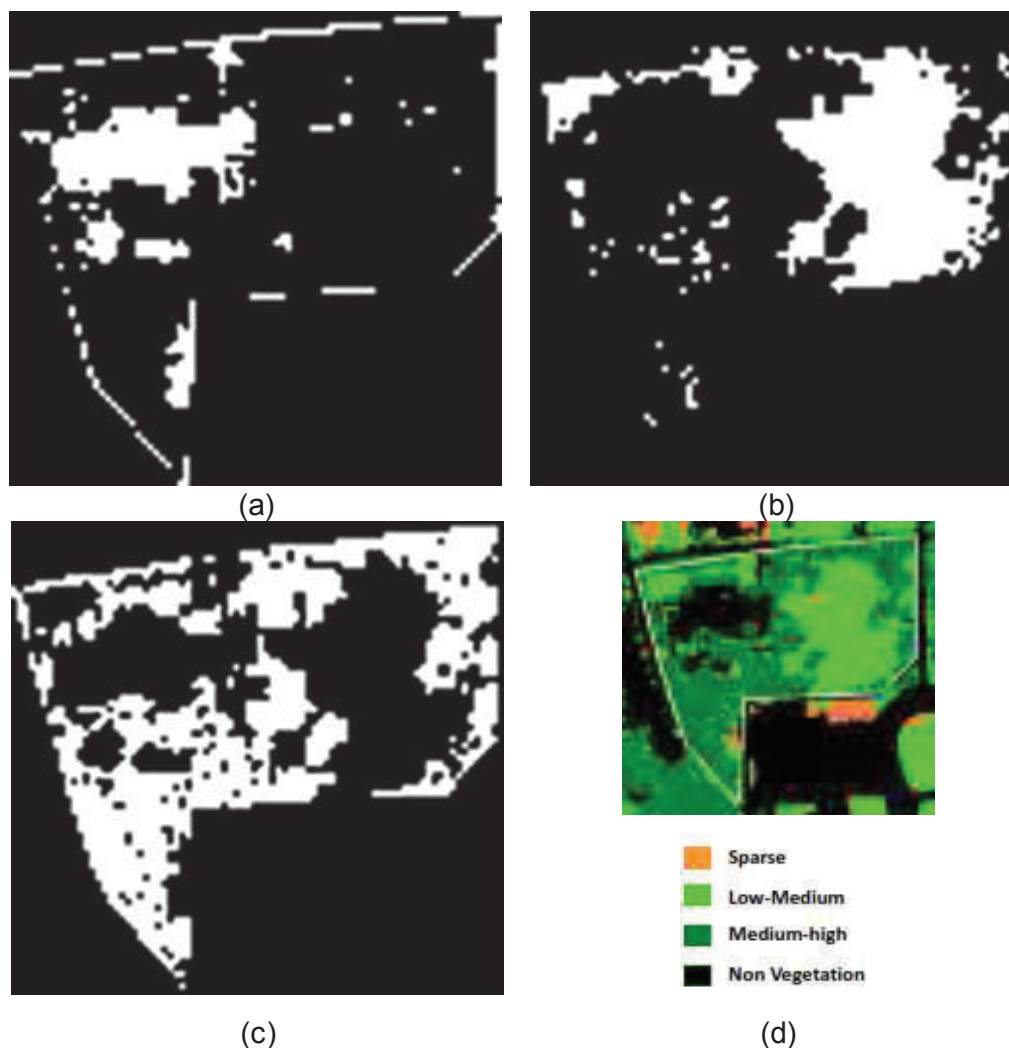


Figura 2.12.(a) Máscara Zona 1 no vegetación o vegetación dispersa. (b) Máscara Zona 2 vegetación media - baja. (c) Máscara Zona 3 vegetación media - alta. (d) Resultados de la clasificación de la vegetación del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".  
(Fuente: Propia (a), (b), (c); [4] (d))

La Figura 2.12 (b) indica en el lado derecho la región de mayor tamaño que corresponde a la región de media – baja vegetación indicada en color verde claro en la Figura 2.12 (d), también se observa en la parte superior izquierda una región irregular alargada de gran tamaño, bajo esta última se observan algunas pequeñas regiones irregulares dispersas y en la parte inferior izquierda una región irregular aislada en forma de “c” que está alrededor de la zona de vegetación dispersa, todas estas regiones corresponden a la región de media – baja vegetación.

La Figura 2.12 (c) indica la mayor concentración de píxeles blancos en la parte inferior izquierda de la imagen, el resto de los píxeles bordean las regiones indicadas en las Figuras 2.12 (a) y (b) y corresponden a la zona de media – alta vegetación que se indica en la

Figura 2.12 (d) en color verde oscuro. Se debe considerar que en la región correspondiente a la vegetación media – alta indicada en la Figura 2.12 (c) se evidencia pérdida de datos en forma de pixeles negros dentro de la región blanca que al ser comparada con la Figura 2.12 (d) no deberían estar presentes.

Al comparar visualmente las regiones descritas en las Figuras 2.12 (a), (b) y (c) con las zonas de la Figura 2.12 (d) se observa que la segmentación realizada describe aceptablemente la zona de interés y cada una de sus zonas.

Una vez concluida la segmentación de la zona de interés, se realiza el conteo de los pixeles correspondientes a cada una de las zonas de segmentación para obtener el porcentaje de cada tipo de vegetación.

Es necesario obtener el número de pixeles de toda la imagen para determinar el porcentaje que ocupa la zona de interés dentro de la imagen, la sumatoria de los pixeles que conforman cada una de las zonas de segmentación es necesaria para determinar si se han considerado todos los pixeles de la zona de interés en el procesamiento de imagen o si ha habido pérdida de datos durante la segmentación.

Los valores indicados en la Tabla 2.2 correspondientes al número de pixeles de cada zona de segmentación y al porcentaje que representan son el resumen de resultados que se obtienen del procesamiento de imagen a color.

Tabla 2.2. Resultados del procesamiento de imagen a color aplicando el código desarrollado en Python.

<b>ZONA</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona3</b>	<b><math>\Sigma</math> Zonas</b>	<b>Zona de Interés</b>	<b>Zona Alpha</b>	<b>Imagen a Color</b>
<b>Nº Pixeles</b>	716	1114	1725	3555	3720	2758	6478
<b>Porcentaje (%)</b>	20,14	31,34	48,52	54,88	57,43	42,57	100

(Fuente: Propia)

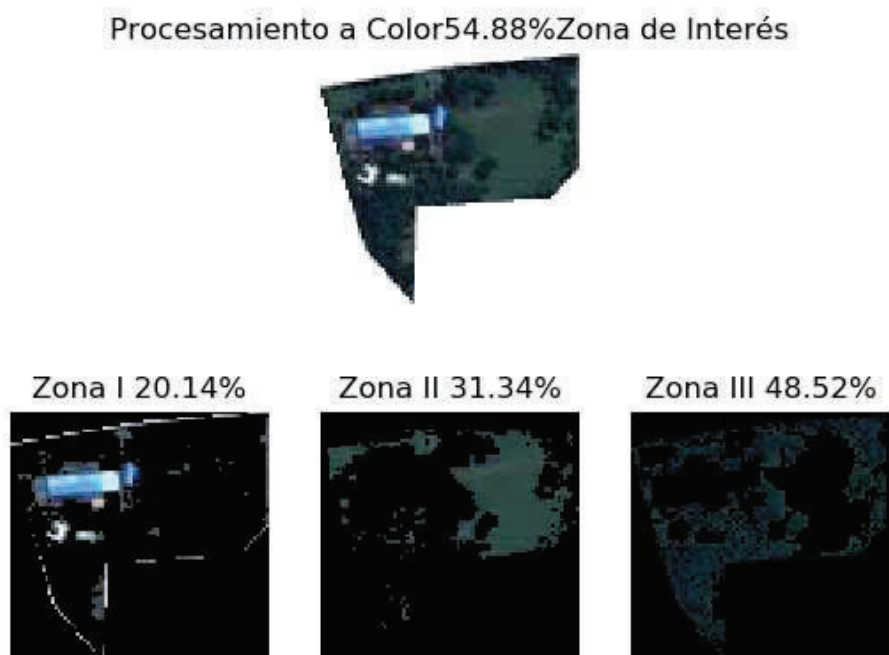


Figura 2.13. Zonas forestales procesamiento a color (resultados del procesamiento de imagen aplicando el código desarrollado en Python).  
(Fuente: Propia)

En la Figura 2.13 se observa cada una de las zonas de segmentación, la Zona 1 corresponde a la zona de no vegetación o vegetación dispersa, la Zona 2 a la zona de media – baja vegetación y la Zona 3 a la zona de media – alta vegetación. La sumatoria de los porcentajes de las tres zonas constituyen el 100% de pixeles dentro de la zona de interés. En la parte superior de la Figura 2.13 se observa el porcentaje que ocupa la zona de interés dentro de la imagen de 82x79 pixeles de dimensión que se utiliza en el presente análisis.

El rasgo distintivo de cada zona de segmentación es el color, a pesar de que la segmentación por color de una zona forestal es complicada debido a que la coloración general es verde se observa que existen diferentes tipos de verde que sirven para diferenciar una zona de otra. La determinación del color como factor discriminante durante la segmentación corresponde a la extracción de características que es una operación dentro del proceso de análisis de la imagen.

#### 2.2.2.4 Reconocimiento de objetos

Al igual que en la sección 2.2.1.4 la relación de la humedad del suelo con el color de la vegetación se desarrolla únicamente para el área de estudio del Refugio de Vida Silvestre La Chiquita luego de definir la metodología adecuada para el procesamiento de imágenes de zonas forestales y se describe en las próximas secciones.

En la Tabla 2.2 la sumatoria de los pixeles de las tres zonas de segmentación es de 3555 mientras que el número de pixeles de la zona de interés es de 3720. Tanto la sumatoria de pixeles de las tres zonas de segmentación como el número de pixeles de la zona de interés deberían ser valores iguales, que la sumatoria de pixeles de las tres zonas de segmentación sea menor que el número de pixeles de la zona de interés indica que durante el procesamiento de imagen a color existe pérdida de datos de un 2,55% (esto se evidencia en la Figura 2.12 (c) y el cálculo en el Anexo II).

El error truncado ocurre cuando se utilizan aproximaciones para representar formulaciones matemáticas exactas [44]. Existe un error inherente o incertidumbre en los resultados en las soluciones de simulaciones realizadas con códigos de computador [45]. La habilidad para simular fenómenos complejos con precisión está limitada por las aproximaciones numéricas que gobiernan las ecuaciones, capacidad computacional, y la falta del entendimiento completo de las leyes físicas. La evaluación de un modelo solo está completa cuando todas las fuentes de error se cuantifican, las mejoras a los modelos son posibles únicamente cuando los errores numéricos son significativamente más pequeños que el error aceptable del modelo. Desafortunadamente, los métodos para calcular el error numérico aún se encuentran en investigación.

Se puede minimizar el impacto de los errores en los resultados de la simulación, por ejemplo, los errores debidos al código se eliminan mediante procesos de verificación, los errores del modelo se eliminan mediante procesos de validación, solamente quedan pendientes los errores debidos a factores incontrolables (como son el uso de longitudes finitas y métodos discretos para representar sistemas continuos). El objetivo de los investigadores es minimizar y limitar estos factores incontrolables. En conclusión, si se obtiene un código verificado y un modelo validado se puede afirmar que una cantidad predicha dada  $f(x, y, z, t)$  es verdadera más menos una magnitud de incertidumbre.

Uno de los supuestos básicos de la simulación es que se desarrolla en un medio continuo, los códigos desarrollados para procesar imágenes son aproximaciones de la realidad, por

lo tanto, existe un error truncado que de acuerdo con los autores antes mencionados aún no se puede cuantificar. Los autores mencionan que las mejoras a los modelos son posibles únicamente cuando los errores numéricos son significativamente más pequeños que el error aceptable del modelo, el error aceptable del modelo se define en 20% de acuerdo con Hidalgo et al. [46], entonces aplicando lo mencionado por Freitas [45] se establece un error truncado aceptable del 3%. Según lo antes expuesto, se considera a la pérdida de datos en el procesamiento de imagen a color como error truncado que se encuentra dentro del valor aceptable antes establecido.

La validación de la metodología para el procesamiento de imágenes a color de zonas forestales se detalla en la sección 3.2.



### 3. RESULTADOS Y DISCUSIÓN

#### 3.1 Validación de la metodología de procesamiento de imagen en escala de grises

Para la validación de la metodología de procesamiento de imagen en escala de grises se procede a comparar los resultados obtenidos aplicando la metodología propuesta con los resultados obtenidos en el artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery”.

Una vez finalizado el procesamiento de imagen en escala de grises se realiza la validación de la metodología por comparación. Si el error es menor al 20% entonces la metodología está validada, y si el error es mayor al 20% entonces es necesario redefinir los rangos de segmentación propuestos en el procesamiento de imagen.

En el artículo “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery” [4] los resultados obtenidos del procesamiento de la imagen de la zona de interés son:

- Porcentaje de cobertura vegetal de 84,8%.
- Porcentaje de vegetación dispersa de 2,9%.
- Porcentaje de vegetación media – baja de 32,4%.
- Porcentaje de vegetación media – alta de 49,5%.

En el código desarrollado en Python se consideran solamente tres zonas, por lo que la zona de vegetación dispersa se une con la zona de no vegetación, entonces de acuerdo con los datos del artículo el porcentaje de esta zona es la suma del porcentaje de vegetación dispersa y el porcentaje no cubierto por la zona de cobertura vegetal que es igual a 18,1%.

Para estimar el error es necesario tener clara su definición, las definiciones de error se detallan a continuación [44, 47]:

El error verdadero es la diferencia entre el valor verdadero y la aproximación, y el error absoluto es el valor absoluto del error verdadero.

El error verdadero relativo fraccional está dado por la ecuación 3.1, mientras que el error relativo por la ecuación 3.2.

$$\text{Error verdadero relativo fraccional} = \frac{\text{Valor verdadero} - \text{Aproximación}}{\text{Valor Verdadero}}$$

Ecuación 3.1

$$\begin{aligned} \varepsilon_t &= \text{Error verdadero relativo fraccional} * 100\% \\ \varepsilon_t &= \frac{\text{Valor verdadero} - \text{Aproximación}}{\text{Valor Verdadero}} * 100\% \end{aligned}$$

Ecuación 3.2

Las definiciones de error anteriormente mencionadas consideran que se conoce el valor verdadero, si este no es el caso se realizan iteraciones sucesivas usando la aproximación porcentual del error relativo como se indica en las ecuaciones 3.3 y 3.4.

$$\varepsilon_a = \frac{\text{Aproximación del Error}}{\text{Aproximación}} * 100\%$$

Ecuación 3.3

$$\varepsilon_a = \frac{\text{Aproximación presente} - \text{Aproximación previa}}{\text{Aproximación presente}} * 100\%$$

Ecuación 3.4

Para lo cual se define una tolerancia  $\varepsilon_s$ , entonces las iteraciones sucesivas se realizan hasta que  $\varepsilon_a \leq \varepsilon_s$ .

En el cálculo del error de la presente tesis se aplica la ecuación 3.2 ya que se considera como valor verdadero al porcentaje del artículo y como aproximación al porcentaje obtenido al aplicar la metodología de procesamiento de imagen en escala de grises.

Al calcular el error entre los resultados obtenidos en el artículo y los resultados obtenidos aplicando la metodología de procesamiento de imagen en escala de grises desarrollada con un código de programación en lenguaje Python obtenemos los errores que se indican en la Tabla 3.1 (en el Anexo II se desarrolla un ejemplo de cálculo).

Tabla 3.1. Comparación de resultados del procesamiento de imagen en escala de grises aplicando el código desarrollado en Python con los resultados del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".

<b>ZONA</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona3</b>
<b>Resultados Python Escala de Grises (%)</b>	15,78	36,71	47,52
<b>Resultados Artículo (%)</b>	18,1	32,4	49,5
<b>%Error</b>	12,83	13,29	4,01

(Fuente: Propia)

Hidalgo et al. mencionan en su artículo "Implicit large eddy simulation of unsteady cloud cavitation around a plane-convex hydrofoil" que la precisión de la predicción es bastante buena, aunque el error esté cerca del 20% y que un error experimental de alrededor del 5% puede ser razonable [46]. Aplicando este criterio y al tener un error máximo del 13,29% se considera a la predicción obtenida al aplicar la metodología de procesamiento de imagen en escala de grises desarrollada con un código de programación en lenguaje Python para el estudio de zonas forestales aceptable, con lo que queda validada la metodología empleada mediante la comparación de resultados obtenidos aplicando la metodología propuesta con los resultados del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".

### **3.2 Validación de la metodología de procesamiento de imagen a color**

Para la validación de la metodología de procesamiento de imagen a color se procede a comparar los resultados obtenidos aplicando la metodología propuesta con los resultados obtenidos en el artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".

Una vez finalizado el procesamiento de imagen a color se realiza la validación de la metodología por comparación. Si el error es menor al 20% entonces la metodología está validada, y si el error es mayor al 20% entonces es necesario redefinir los rangos de segmentación propuestos en el procesamiento de imagen.

Al calcular el error entre los resultados obtenidos en el artículo (el cálculo del error se menciona detalladamente en la sección 3.1) y los resultados obtenidos aplicando la

metodología de procesamiento de imagen a color desarrollada con un código de programación en lenguaje Python mediante la aplicación de la ecuación 3.2, obtenemos los errores que se indican en la Tabla 3.2.

Tabla 3.2.Comparación de resultados del procesamiento de imagen a color aplicando el código desarrollado en Python con los resultados del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".


<b>ZONA</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona3</b>
<b>Resultados Python a Color (%)</b>	20,14	31,34	48,52
<b>Resultados Artículo (%)</b>	18,1	32,4	49,5
<b>%Error</b>	11,27	3,27	1,98

(Fuente: Propia)

Aplicando el criterio de Hidalgo et al. [46] y al tener un error máximo del 11,27% se considera a la predicción obtenida al aplicar la metodología de procesamiento de imagen a color desarrollada con un código de programación en lenguaje Python para el estudio de zonas forestales aceptable, con lo que queda validada la metodología empleada mediante la comparación de resultados obtenidos aplicando la metodología propuesta con los resultados del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery" [4].

### **3.3 Selección de la metodología para el procesamiento de imagen de zonas forestales**

Una vez desarrolladas la metodología de procesamiento de imagen en escala de grises y la metodología de procesamiento de imagen a color, es necesario establecer cuál de las dos metodologías desarrolladas y validadas en las secciones 2.2.1, 2.2.2, 3.1 y 3.2 respectivamente, es la mejor para el estudio de zonas forestales. Para la selección de la metodología más adecuada se realizará una comparación en base a los resultados obtenidos.



Gráfica 3.1. Comparación de resultados de las diferentes metodologías del procesamiento de imagen.  
(Fuente: Propia)

En la Gráfica 3.1 se puede evidenciar que los porcentajes obtenidos para cada una de las zonas de segmentación aplicando la metodología de procesamiento de imagen a color son más cercanos a los porcentajes considerados como valores verdaderos obtenidos del artículo del autor Bambang Trisakti [4], que los porcentajes obtenidos aplicando la metodología de procesamiento de imagen en escala de grises.

Tabla 3.3. Comparación del error obtenido aplicando la metodología de procesamiento de imagen en escala de grises y a color.

ZONA	Zona 1	Zona 2	Zona3
<b>%Error Procesamiento en Escala de Grises</b>	12,83	13,29	4,01
<b>%Error Procesamiento a Color</b>	11,27	3,27	1,98

(Fuente: Propia)

En la Tabla 3.3 se evidencia que el procesamiento de imagen a color presenta errores menores que los obtenidos al aplicar el procesamiento de imagen en escala de grises. Incluso, en el procesamiento de imagen a color las zonas 2 y 3 presentan errores menores al 5%.

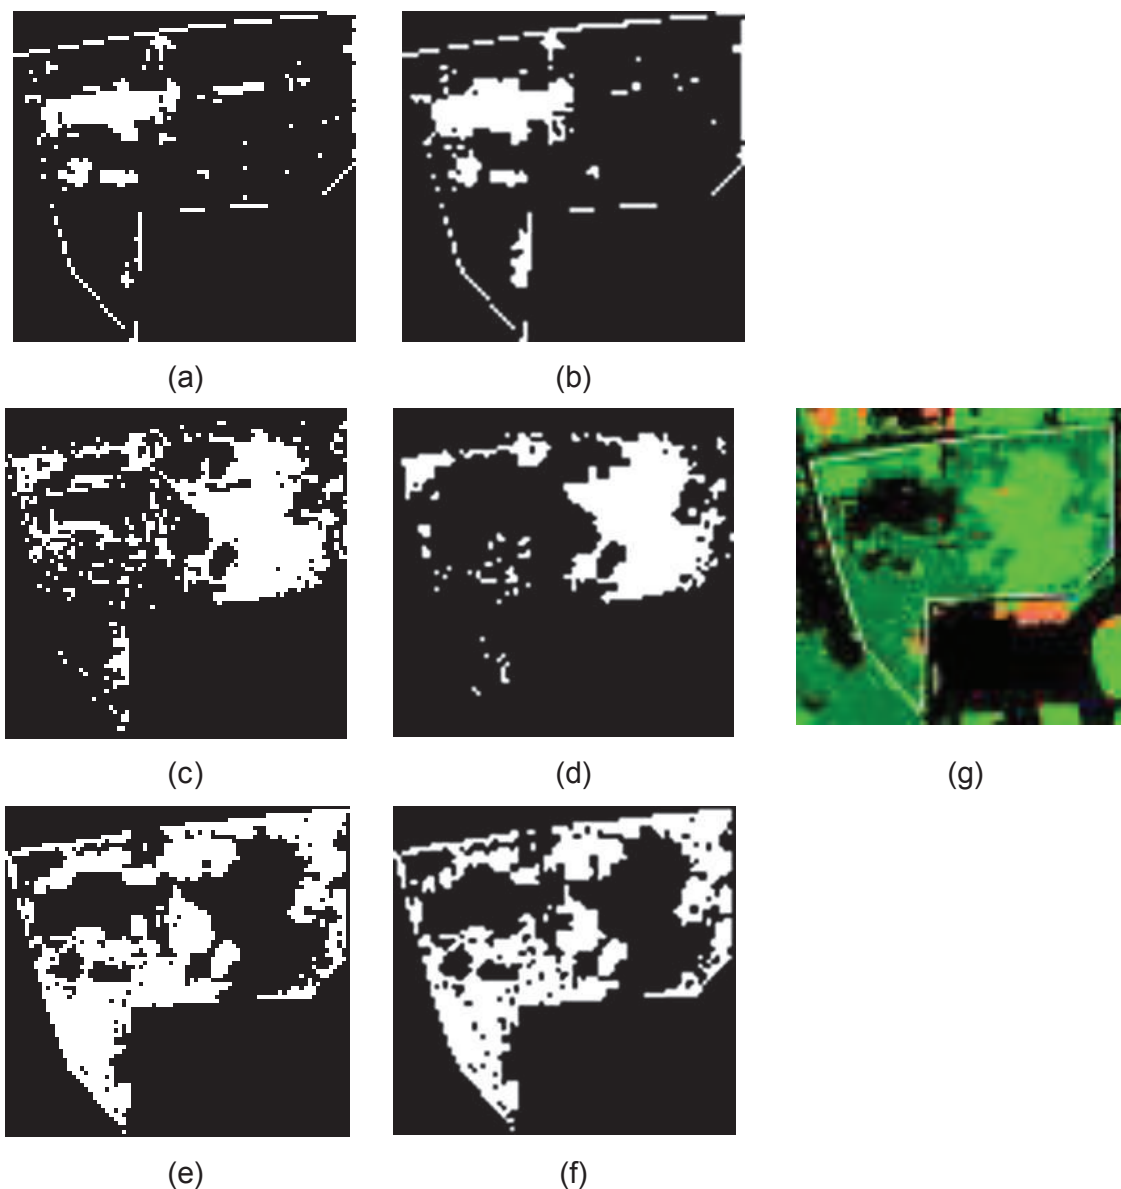


Figura 3.1.(a) Máscara Zona 1 Escala de Grises. (b) Máscara Zona 1 Color. (c) Máscara Zona 2 Escala de Grises. (d) Máscara Zona 2 Color. (e) Máscara Zona 3 Escala de Grises. (f) Máscara Zona 3 Color. (g) Resultados de la clasificación de la vegetación del artículo "Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery".

(Fuente: Propia (a), (b), (c), (d), (e), (f); [4] (g))

Al comparar visualmente la Figura 3.1 (a) y la Figura 3.1 (b) con la Figura 3.1 (g) se observa que las regiones de la Figura 3.1 (b) presentan mayor homogeneidad y parecido con las regiones que conforman la zona de no vegetación que se muestra en color negro en la Figura 3.1 (g).

La comparación visual de la Figura 3.1 (c) y la Figura 3.1 (d) con la Figura 3.1 (g) indica que las regiones de la Figura 3.1 (d) presentan más similitud con la zona de vegetación media – baja que se indica en la Figura 3.1 (g) en color verde claro. En la parte central

izquierda de la Figura 3.1 (c) se observan regiones que no pertenecen a la zona de media – baja vegetación indicada en la Figura 3.1 (g), también es evidente que en la parte inferior izquierda de la Figura 3.1 (c) se considera parte de la región de media – baja vegetación a la región conformada por una mezcla de vegetación dispersa, no vegetación y media – baja vegetación en donde la parte más representativa corresponde a la región de vegetación dispersa que se indica en naranja en la Figura 3.1 (g).

La Figura 3.1 (f) en comparación con la Figura 3.1 (e) describe mejor a la zona de vegetación media – alta que se indica en color verde oscuro en la Figura 3.1 (g), a pesar de que en la parte izquierda inferior de la Figura 3.1 (f) se observa la presencia indeseada de píxeles negros que implican la pérdida de datos en esta zona.

Por los análisis realizados a los datos expuestos en la Gráfica 3.1, en la Tabla 3.3 y en la Figura 3.1 se determina que la mejor metodología para el estudio de zonas forestales es la que utiliza el procesamiento de imágenes a color.

### **3.4 Aplicación de la metodología para el procesamiento de imagen de zonas forestales al Refugio de Vida Silvestre La Chiquita**

En esta sección se aplica la metodología de procesamiento de imagen definida en la sección 3.3 a fotografías tomadas por dron del Refugio de Vida Silvestre La Chiquita y se analiza la capacidad de relacionar los resultados obtenidos del procesamiento de imagen con la humedad del suelo (propiedad físico-térmica) de esta zona forestal.

El Refugio de Vida Silvestre La Chiquita es el área de estudio en la cual se aplicará la metodología para el procesamiento de imagen a color desarrollada en la presente tesis, el mismo se encuentra en la provincia de Esmeraldas, cantón San Lorenzo, parroquia Tululbí. Las fotografías tomadas por dron del Refugio de Vida Silvestre La Chiquita han sido proporcionadas por el FONAG, y la ubicación de las fotografías dentro del refugio se indica en el Anexo III.

Las imágenes que se procesan presentan zonas boscosas, plantaciones y caminos bien diferenciados. No se cuenta con información precisa del tipo de cultivo que se muestra en

las fotografías debido a que el Refugio de Vida Silvestre La Chiquita es un área protegida y restringida, de la información proporcionada por el IEE-MAGAP se determina que la zona boscosa corresponde al bosque húmedo tropical de la región del Chocó y en base a la fotointerpretación y comparación morfológica se determina que los cultivos corresponden a palma africana (ver Anexo IV).

La metodología de procesamiento de imagen a color se aplica a cinco imágenes tomadas al azar de la zona de estudio para determinar la aplicabilidad del código desarrollado para el estudio de zonas forestales, esta metodología se aplica únicamente a cinco imágenes debido a que es la cantidad de datos con la que se cuenta. En estas imágenes no se realiza la identificación de la zona de interés debido a que toda la imagen es la zona de interés, entonces se realiza la segmentación de toda la imagen en tres zonas que son:

- Zona de no vegetación (Znv I).
- Zona de vegetación húmeda (Zvh II).
- Zona de vegetación muy húmeda (Zvmh III).

Las características de las imágenes analizadas se indican en la Tabla 3.4, y los rangos de color que se aplican para la segmentación de estas imágenes se indican en la Tabla 3.5.

Para la zona de no vegetación se realizan dos sub-máscaras y la máscara resultante se genera al extraer los datos contenidos en la sub-máscara Z1' de los datos de la sub-máscara Z1 con la finalidad de separar la vegetación con mayor contenido de humedad (verde) de la vegetación con menor contenido de humedad (amarillo).

Tabla 3.4. Propiedades de las imágenes del Refugio de Vida Silvestre La Chiquita.

<b>PROPIEDADES</b>		<b>VALOR</b>
<b>Dimensiones</b>	Ancho	2592 píxeles
	Alto	1944 píxeles
<b>Resolución</b>	Horizontal	72 ppp
	Vertical	72 ppp
<b>Profundidad</b>		24 bits
<b>Unidad de resolución</b>		2
<b>Tamaño</b>		1,28 MB
<b>Tipo de elemento</b>		JPEG

(Fuente: Propia)



Tabla 3.5. Rangos de segmentación.

ZONA		RANGO DE SEGMENTACIÓN HSV	
<b>Zona de no vegetación I</b>	Z1	Límite Inferior	0 0 0
		Límite Superior	40 255 255
	Z1'	Límite Inferior	21 80 0
		Límite Superior	40 255 255
<b>Zona de vegetación húmeda II</b>		Límite Inferior	21 80 0
		Límite Superior	40 255 255
<b>Zona de vegetación muy húmeda III</b>		Límite Inferior	40 0 0
		Límite Superior	100 255 150

(Fuente: Propia)

Los resultados obtenidos del procesamiento de las imágenes se indican en las Figuras 3.2, 3.3, 3.4, 3.5 y 3.6 y se resumen en la Tabla 3.6.

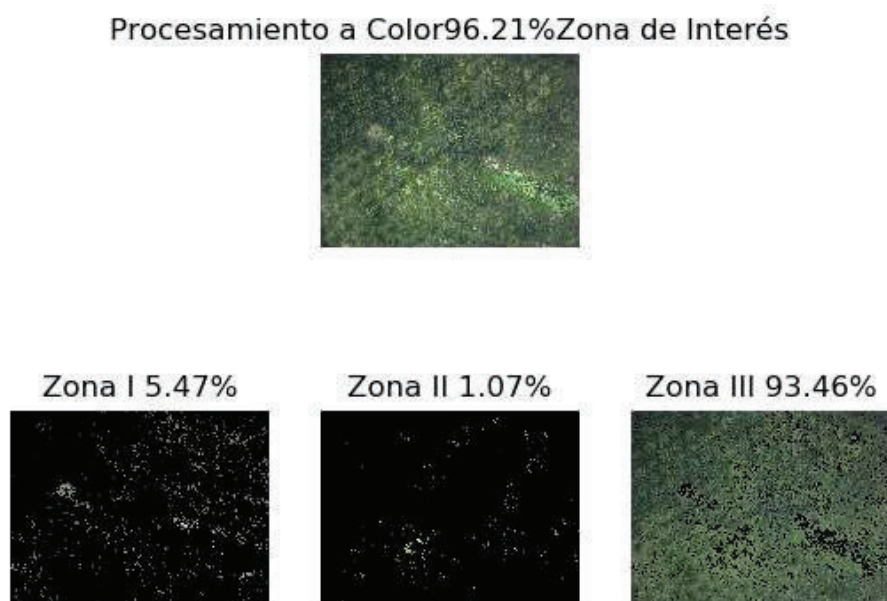


Figura 3.2. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight\_003-005. (Fuente: Propia)

En la Figura 3.2 la zona 1 muestra los pixeles correspondientes a los surcos de tierra que se encuentran alrededor de los cultivos, los pixeles se ven bastante dispersos debido a que como se observa en la imagen 2016-01-27-flight\_003-005 sin segmentar (parte superior de la Figura 3.2) no existe gran cantidad de suelo desnudo en esta imagen, las regiones de suelo desnudo son pequeñas y se encuentran diseminadas en la imagen.

En la zona 2 se muestran los píxeles que corresponden a la vegetación de color amarillo, que en la imagen analizada es escasa.

La zona 3 muestra los píxeles que corresponden a la vegetación verde que ocupa la mayor parte de la imagen.

En la parte inferior derecha de la imagen 2016-01-27-flight\_003-005 se puede observar un tipo distinto de vegetación, esta vegetación no se describe en ninguna de las zonas de segmentación, como se puede observar en la zona 3 el lugar en el que esta vegetación se encuentra se muestra con píxeles negros, es decir, no se considera y lo mismo ocurre en las otras dos zonas de segmentación. Por lo tanto, el área que ocupa esta vegetación no considerada corresponde al porcentaje de error truncado debido a la pérdida de datos. La pérdida de datos es evidente en el porcentaje que ocupa la imagen analizada que es de 96,21%, al considerar que toda la imagen es la zona de interés, este porcentaje debería ser igual al 100% si no hubiera pérdida de datos.

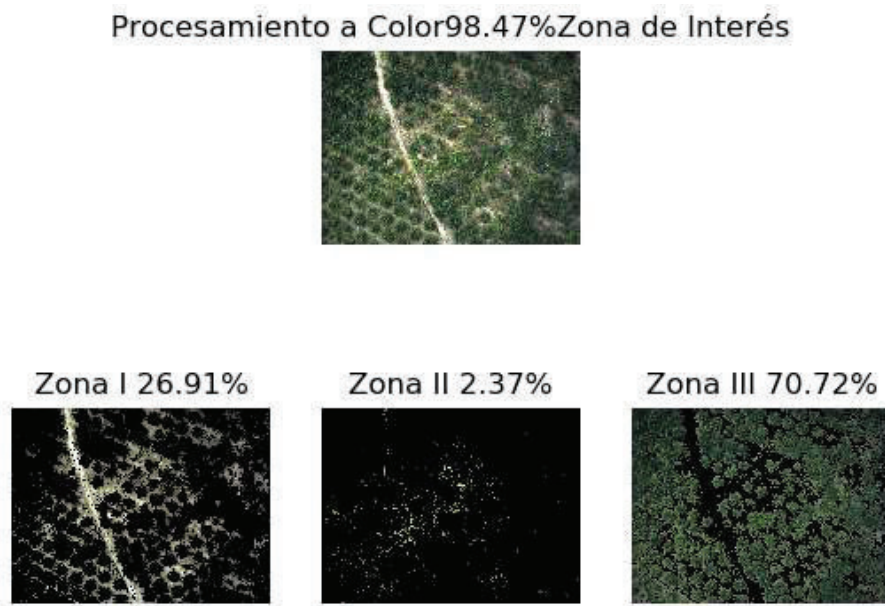


Figura 3.3. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight\_003-012.  
(Fuente: Propia)

En la Figura 3.3 la zona 1 muestra los píxeles correspondientes a los surcos de tierra que se encuentran alrededor de los cultivos y al camino que en la imagen 2016-01-27-flight\_003-012 están claramente definidos. En la zona 1 se evidencia pérdida de datos en el camino ya que se visualizan ciertos píxeles negros que indican que en esos puntos no hay información, esto no coincide con la imagen sin segmentar. En la parte superior izquierda de la imagen junto al camino se observa un charco de agua, que no se describe en la zona de no vegetación.

En la zona 2 se muestran los píxeles que corresponden a la vegetación de color amarillo, esta vegetación se encuentra en la parte externa de ciertos cultivos, es bastante escasa y dispersa.

La zona 3 muestra los píxeles que corresponden a la vegetación verde que en la imagen 2016-01-27-flight\_003-012 corresponden a cultivos de palma africana.

El porcentaje que ocupa la imagen analizada es de 98,47%.

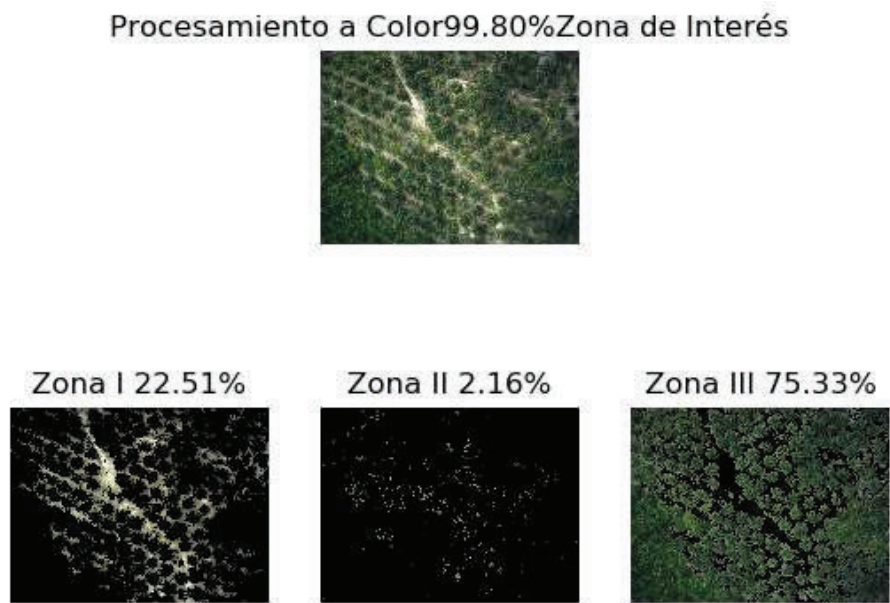


Figura 3.4. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight\_003-028. (Fuente: Propia)

En la Figura 3.4 la zona 1 muestra los píxeles correspondientes a los surcos de tierra y al camino irregular que se muestra en la imagen 2016-01-27-flight\_003-028. En la parte más ancha del camino se evidencia pérdida de datos en forma de píxeles negros.


En la zona 2 se muestran los píxeles que corresponden a la vegetación de color amarillo, esta vegetación se encuentra en la parte externa de ciertos cultivos, es escasa y dispersa. La zona 3 muestra los píxeles que corresponden a la vegetación verde, en la parte inferior izquierda se observa una zona totalmente cubierta por vegetación sin la presencia de suelo desnudo entre las filas de cultivos.

El porcentaje que ocupa la imagen analizada es de 99,80%.


### Procesamiento a Color 98.43% Zona de Interés



Zona I 18.13%



Zona II 2.90%



Zona III 78.97%




Figura 3.5. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight\_003-050.  
(Fuente: Propia)

En la Figura 3.5 la zona 1 muestra los píxeles correspondientes a los surcos de tierra y al camino que se muestra en la imagen 2016-01-27-flight\_003-050. En la rama izquierda del camino se evidencia pérdida de datos en forma de píxeles negros, la estructura blanca con azul que se encuentra a un lado de la rama izquierda del camino no se describe en esta zona a pesar de ser parte de la región de no vegetación.

En la zona 2 se muestran los píxeles que corresponden a la vegetación de color amarillo, que se ubica en la parte externa de los cultivos, en esta imagen se distinguen claramente sus formas circulares y se concentran en la parte inferior derecha de la imagen.


La zona 3 muestra los píxeles que corresponden a la vegetación verde, en la parte superior derecha se observa una zona totalmente cubierta por vegetación sin la presencia de suelo desnudo entre los cultivos.

El porcentaje que ocupa la imagen analizada es de 98,43%.

### Procesamiento a Color 97.84% Zona de Interés



Zona I 26.41%



Zona II 3.16%



Zona III 70.44%




Figura 3.6. Resultados del procesamiento de imagen a color. Imagen 2016-01-27-flight\_003-121.  
(Fuente: Propia)

En la Figura 3.6 la zona 1 muestra los píxeles correspondientes a los surcos de tierra y al camino que se muestra en la imagen 2016-01-27-flight\_003-121. En dirección Norte – Sur de la imagen antes de la curva del camino existen charcos de agua que no se describen en la zona de segmentación correspondiente a no vegetación. En el camino se pueden observar píxeles negros que corresponden a la pérdida de datos.

En la zona 2 se muestran los píxeles que corresponden a la vegetación de color amarillo, en la imagen 2016-01-27-flight\_003-121 conforman un área mayor que en el resto de las imágenes analizadas en esta sección, los píxeles que conforman esta zona se distribuyen a lo largo de la imagen y se concentran a la derecha del camino.

La zona 3 muestra los píxeles que corresponden a la vegetación verde, en la imagen 2016-01-27-flight\_003-121 se observa la presencia de cultivos y bosque húmedo tropical, y los dos tipos de vegetación son reconocidos por el código desarrollado. El bosque húmedo tropical se ubica en la esquina inferior derecha de la imagen, donde se observan algunos píxeles negros que indican la pérdida de datos.

El porcentaje que ocupa la imagen analizada es de 97,84%.

Tabla 3.6. Resumen de resultados del procesamiento de imágenes del Refugio de Vida Silvestre La Chiquita.

N° Imagen	N° Fotografía	ZONAS			Σ Zonas	Total de Píxeles	% Error Truncado
		Znv I	Zvh II	Zvmh III			
1	2016-01-27- flight_003- 005	265075	51908	4531114	4848097	5038848	3,79
2	2016-01-27- flight_003- 012	1335171	117605	3509179	4961955	5038848	1,53
3	2016-01-27- flight_003- 028	1132087	108563	3787994	5028644	5038848	0,20
4	2016-01-27- flight_003- 050	899141	143833	3916860	4959834	5038848	1,57
5	2016-01-27- flight_003- 121	1301783	155552	3472459	4929794	5038848	2,16

(Fuente: Propia)

En la Tabla 3.6 se indica la cantidad de píxeles que conforman cada una de las zonas de segmentación, el sumatorio de los píxeles de las tres zonas de segmentación, la cantidad total de píxeles que conforman la imagen sin segmentar y el porcentaje de error truncado calculado para cada imagen que se analizó en la presente sección.

Al observar la Tabla 3.6 es evidente que el error truncado de cuatro de las cinco imágenes analizadas en esta sección es menor al valor de error truncado fijado como aceptable (3%).

El error truncado indicado en la Tabla 3.6 se estima a partir de la pérdida de datos durante el procesamiento de imagen, la pérdida de datos se obtiene de la diferencia del total de píxeles y el sumatorio de píxeles de las tres zonas de segmentación, y se representa como porcentaje. El método de estimación del error truncado que se aplica a la imagen 2016-01-27-flight\_003-005 se emplea con todas las imágenes analizadas en esta sección.

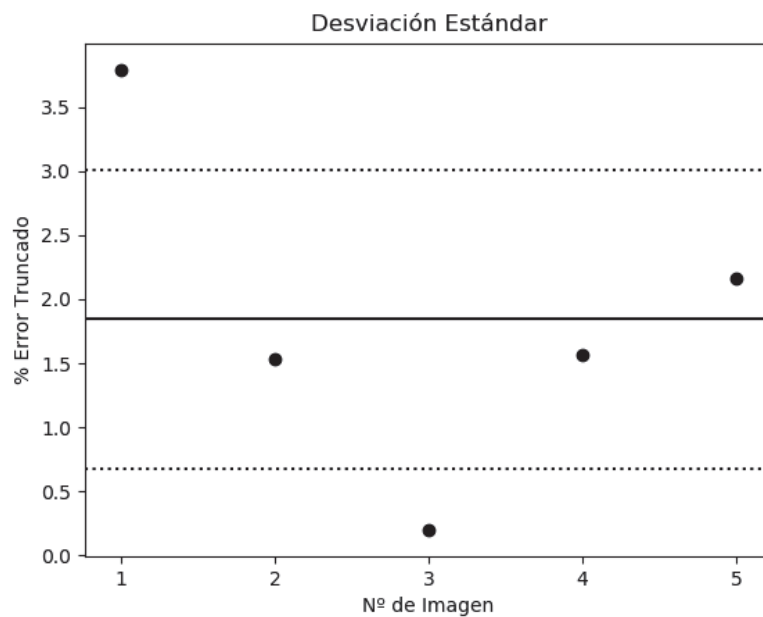
#### **Estimación del error truncado de la imagen 2016-01-27-flight 003-005**

$$\% \text{ Error Truncado} = \frac{(\text{Total píxeles} - \sum \text{Zonas})}{\text{Total de píxeles}} * 100\%$$

$$\% \text{ Error Truncado} = \frac{(5038848 - 4848097)}{5038848} * 100\%$$

$$\% \text{ Error Truncado} = 3,79\%$$

La ecuación aplicada para realizar el cálculo del error truncado tiene la forma de la ecuación 3.2 correspondiente al cálculo del error relativo, donde el número total de píxeles hace referencia al valor verdadero y el número de píxeles resultantes del sumatorio de los píxeles que conforman cada una de las zonas de segmentación hace referencia a la aproximación.



Gráfica 3.2. Desviación estándar de resultados.  
(Fuente: Propia)

En la Gráfica 3.2 se observan los valores del error truncado de cada imagen analizada. Tres de las cinco imágenes procesadas presentan errores truncados ubicados dentro de los límites superior e inferior calculados con la desviación estándar, por lo tanto, la metodología de procesamiento de imagen desarrollada en la presente tesis para el estudio de zonas forestales funciona de acuerdo con lo esperado. Es decir, aplicando la metodología se puede determinar el porcentaje de área de una imagen que contiene cobertura vegetal e inclusive es posible clasificar esta cobertura vegetal.

Relacionar los resultados obtenidos del procesamiento de imágenes con la humedad del suelo (propiedad físico-térmica) de la zona forestal objeto de estudio es posible debido a que la segmentación por color permite la clasificación de la vegetación presente en la imagen en zonas que tienen propiedades similares. En base a la información

proporcionada por el IEE-MAGAP proveniente del Proyecto Nacional generado por cantones desde 2009 hasta 2015 se conoce que la textura del suelo del Refugio de Vida Silvestre La Chiquita es arcillosa, considerando esta información y los datos teóricos mencionados en la sección 1.2 se establecen los rangos de humedad para cada zona de segmentación que se indican en la Tabla 3.7 debido a que instituciones como el MAGAP, MAE y el IEE no tienen datos de la humedad del suelo se emplean estos datos teóricos y generales de acuerdo a la textura del suelo.

Tabla 3.7. Rangos de humedad para cada zona de segmentación.

ZONA DE SEGMENTACIÓN	HUMEDAD DEL SUELO (cm <sup>3</sup> /cm <sup>3</sup> )	
Znv I	0,24	P.W.P
Zvh II	0,16	A.W.C
Zvmh III	0,40	F.C

(Fuente: Propia)

Los rangos de humedad considerados son los valores máximos de la Tabla 1.1. El rango de humedad de la zona de no vegetación (Znv I) corresponde al valor de humedad del punto de marchitamiento permanente, para la zona de vegetación húmeda (Zvh II) el valor de humedad corresponde al del contenido de agua disponible y para la zona de vegetación muy húmeda (Zvmh III) la humedad tiene el valor de la capacidad de campo, estos valores se han establecido considerando las definiciones de la sección 1.2 y las características de la vegetación de las imágenes analizadas.

En la Figura 3.7 se indica la barra de color extraída de las imágenes analizadas del Refugio de Vida Silvestre La Chiquita con los respectivos valores de humedad establecidos en la Tabla 3.7.




Figura 3.7. Barra de color y porcentaje de humedad del suelo.  
(Fuente: Propia)



## **4. CONCLUSIONES**

En la presente tesis se desarrolló un código de programación en lenguaje Python, cuya función es el procesamiento de imágenes digitales siendo una opción de bajo costo y alta precisión para el estudio de zonas forestales. Para lo cual se utilizaron las librerías OpenCv, Numpy y Matplotlib, junto con la aplicación de máscaras que permiten la segmentación de la zona de interés, y el conteo de píxeles para estimar el área que ocupa cada zona de segmentación dentro de la imagen analizada.

Se desarrolló una metodología para el procesamiento de imágenes en escala de grises y a color, y se determinó que la metodología óptima para el estudio de zonas forestales es la metodología de procesamiento de imagen a color utilizando el modelo de color HSV. La validación de la metodología propuesta se realizó mediante comparación con un estudio previamente realizado, alcanzando un error máximo del 11,27%, siendo aceptable en base a estudios previos.

El color como característica de segmentación presenta resultados deseables al ser un rasgo distintivo entre las zonas de segmentación establecidas, a pesar de que se aplica a una zona forestal cuya coloración es la misma (verde) la variación en la tonalidad, saturación y brillo en el modelo de color HSV permite que el color trabaje adecuadamente como parámetro característico de cada zona de segmentación.

Se ha determinado que es posible relacionar los resultados obtenidos del procesamiento de imagen con la humedad del suelo, ya que la segmentación de las imágenes clasifica la vegetación en grupos que presentan características similares como color, textura, forma, tamaño de los objetos, entre otros.

### **4.1 Trabajos futuros**

El procesamiento de imagen es un campo poco desarrollado a nivel mundial y en el país, es recomendable profundizar en el estudio del procesamiento de imagen y sus aplicaciones principalmente enfocadas al sector forestal y agrícola, para hacer uso eficiente de los recursos empleados en el monitoreo de zonas agrícolas y forestales con altas precisiones que favorezcan la toma de decisiones.

Es recomendable realizar un monitoreo en sitio de los parámetros físico-térmicos que se pretende estudiar mediante el procesamiento de imagen durante al menos un año para refinar y robustecer el código de programación en base a los datos de campo levantados durante las distintas estaciones del año para incrementar la precisión de la predicción.

Aplicar el procesamiento de imagen a distintos tipos de zonas forestales, para verificar su aplicabilidad en el reconocimiento de distintos tipos de vegetación y relacionar los resultados con varios parámetros físico-térmicos.

Comparar los resultados obtenidos al procesar imágenes digitales e imágenes satelitales junto con datos tomados en campo para contar con un código robusto capaz de entregar resultados mucho más fiables.

Realizar un estudio que ayude a estimar la magnitud del error truncado en el procesamiento de imágenes de zonas forestales para disminuir la incertidumbre numérica en este tipo particular de simulación.

Estudiar la relación entre los mecanismos de adquisición de imágenes (UAVs) y sus parámetros (tipo de dron, parámetros de operación, plan de vuelo, etc.) con la calidad de imágenes obtenidas, para establecer las características óptimas que debe tener un UAV apto para el estudio de zonas forestales.

Analizar a profundidad los impactos económico, social, ecológico y tecnológico que conlleva el uso de UAVs y el procesamiento de imagen en el Ecuador para definir claramente las ventajas y desventajas de su uso.

## Referencias Bibliográficas

- [1] A. F. Jiménez, M. C. Pelayo, and Á. Ramírez, “Enseñanza del Procesamiento de Imágenes en Ingeniería usando Python,” *Vaep-Rita*, vol. 3, no. 4, pp. 179–186, 2015.
- [2] Capterra, “GIS Software.” [Online]. Available: <https://www.capterra.com/gis-software/>. [Accessed: 09-Feb-2019].
- [3] V. M. Salas and F. Paz Pellat, “Estimación de la fracción de la cubierta forestal con el uso de fotografía digital en bosques de referencia del Estado de México,” 2016, no. March.
- [4] Bambang Trisakti, “Vegetation type classification and vegetation cover percentage estimation in urban green zone using pleiades imagery,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 54, no. 1, 2017.
- [5] P. K. Kumar Joshi, P. S. Roy, S. Singh, S. Agrawal, and D. Yadav, “Vegetation cover mapping in India using multi-temporal IRS Wide Field Sensor (WiFS) data,” *Remote Sens. Environ.*, vol. 103, no. 2, pp. 190–202, 2006.
- [6] V. H. Hidalgo Diaz, “Numerical study on unsteady cavitating flow and erosion based on homogeneous mixture assumption,” Tsinghua University, 2016.
- [7] Y. Xie, Z. Sha, and M. Yu, “Remote sensing imagery in vegetation mapping: a review,” *J. Plant Ecol.*, vol. 1, no. 1, pp. 9–23, 2008.
- [8] B. Jähne, *Digital Image Processing*, 6th ed. 2005.
- [9] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 2 nd. New Jersey.
- [10] S. Vibhute, A. & Bodhe, “Application of image processing in agriculture: A survey,” *Int. J. Comput. Appl.*, vol. 2, no. 4, pp. 153–159, 2012.
- [11] X. P. Burgos-Artizzu, A. Ribeiro, M. Guijarro, and G. Pajares, “Real-time image processing for crop/weed discrimination in maize fields,” *Comput. Electron. Agric.*, vol. 75, no. 2, pp. 337–346, 2011.
- [12] J. M. Guerrero *et al.*, “Automatic expert system based on images for accuracy crop row detection in maize fields,” *Expert Syst. Appl.*, vol. 40, no. 2, pp. 656–664, 2013.
- [13] M. Guijarro, I. Riomoros, G. Pajares, and P. Zitinski, “Discrete wavelets transform for improving greenness image segmentation in agricultural images,” *Comput. Electron. Agric.*, vol. 118, pp. 396–407, 2015.
- [14] C. A. Pulido-Rojas, M. A. Molina-Villa, and L. E. Solaque-Guzmán, “Machine vision system for weed detection using image filtering in vegetables crops,” *Rev. Fac. Ing. Univ. Antioquia*, no. 80, pp. 124–130, 2016.
- [15] J.-L. Tang, X.-Q. Chen, R.-H. Miao, and D. Wang, “Weed detection using image

- processing under different illumination for site-specific areas spraying,” *Comput. Electron. Agric.*, vol. 122, no. 3, pp. 103–111, 2016.
- [16] I. Vidović, R. Cupec, and Ž. Hocenski, “Crop row detection by global energy minimization,” *Pattern Recognit.*, vol. 55, pp. 68–86, 2016.
- [17] X. Zhang and X. Feng, “Detecting urban vegetation from IKONOS data using an object-oriented approach,” *Proceedings. 2005 IEEE Int. Geosci. Remote Sens. Symp. 2005. IGARSS '05.*, vol. 2, no. C, pp. 1475–1478, 2005.
- [18] J. Valdez, M. González, and H. De los Santos, “Estimación de cobertura arbórea mediante imágenes satelitales multiespectrales de alta resolución,” *Agrociencia*, vol. 40, no. 3, pp. 383–394, 2006.
- [19] F. Amiri and A. R. B. Mohamed Shariff, “Using Remote Sensing Data for Vegetation Cover Assessment in Semi-Arid Rangeland of Center Province of Iran,” *World Applied Sci. J.*, vol. 11, no. 12, pp. 1537–1546, 2010.
- [20] Government of Canada, “Why does remote sensing work so well?” [Online]. Available: <https://www.nrcan.gc.ca/node/9499>. [Accessed: 09-Feb-2019].
- [21] Tiberiu Paul Banu, Gheorghe Florian Borlea, and Constantin Banu, “The Use of Drones in Forestry,” *J. Environ. Sci. Eng. B*, vol. 5, no. 11, pp. 23–29, 2016.
- [22] S. Chitra, R. Subash, and C. Premalatha, “Vegetation of Low Cost Remote Sensing Images by Mean Shift Algorithm,” vol. 3, no. 2, pp. 349–353, 2014.
- [23] H. Xiang and L. Tian, “Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV),” *Biosyst. Eng.*, vol. 108, no. 2, pp. 174–190, 2011.
- [24] H. T. Berie and I. Burud, “Application of unmanned aerial vehicles in earth resources monitoring: Focus on evaluating potentials for forest monitoring in Ethiopia,” *Eur. J. Remote Sens.*, vol. 51, no. 1, pp. 326–335, 2018.
- [25] J. Zhang, J. Hu, J. Lian, Z. Fan, X. Ouyang, and W. Ye, “Seeing the forest from drones: Testing the potential of lightweight drones as a tool for long-term forest monitoring,” *Biol. Conserv.*, vol. 198, pp. 60–69, 2016.
- [26] J. S. Visockiene, R. Puziene, A. Stanionis, and E. Tumeliene, “Unmanned Aerial Vehicles for Photogrammetry: Analysis of Orthophoto Images over the Territory of Lithuania,” vol. 2016, no. i, 2016.
- [27] C. Sandbrook, “The social implications of using drones for biodiversity conservation,” *Ambio*, vol. 44, no. 4, pp. 636–647, 2015.
- [28] J. Paneque-Gálvez, M. K. McCall, B. M. Napoletano, S. A. Wich, and L. P. Koh, “Small drones for community-based forest monitoring: An assessment of their feasibility and potential in tropical areas,” *Forests*, vol. 5, no. 6, pp. 1481–1507, 2014.

- [29] V. Salas-Aguilar, C. Sánchez-Sánchez, F. Rojas-García, F. Paz-Pellat, J. R. Valdez-Lazalde, and C. Pinedo-Alvarez, “Estimation of vegetation cover using digital photography in a regional survey of central Mexico,” *Forests*, vol. 8, no. 10, pp. 1–18, 2017.
- [30] terraGis UNSW, “Soil Moisture Classification,” 2007. [Online]. Available: [http://www.terragis.bees.unsw.edu.au/terraGIS\\_soil/sp\\_water-soil\\_moisture\\_classification.html](http://www.terragis.bees.unsw.edu.au/terraGIS_soil/sp_water-soil_moisture_classification.html). [Accessed: 25-Jan-2019].
- [31] L. Zotarelli, M. D. Dukes, and K. T. Morgan, “Interpretación del contenido de la humedad del suelo para determinar capacidad de campo y evitar riego excesivo en suelos arenosos utilizando sensores de,” *Interpret. Humed.*, vol. 1, no. 1, pp. 2–5, 2013.
- [32] PVS-Studio, “Code Optimization,” 2019. [Online]. Available: <https://www.viva64.com/en/t/0084/>. [Accessed: 04-Apr-2019].
- [33] ApacheBooster, “What is code optimization and its types?” [Online]. Available: <http://apachebooster.com/kb/what-is-code-optimization-and-its-types/>. [Accessed: 04-Apr-2019].
- [34] S. P. Deenan and J. SatheeshKumar, “Image processing methods and its Role in agricultural sector – A study,” vol. 03, no. 01, pp. 366–373, 2014.
- [35] Stockman and Shapiro, *Filtering and Enhancing Images*, no. 1. 2000.
- [36] OpenCV dev team, “OpenCV 2.4.13.7 documentation,” 2019. [Online]. Available: <https://docs.opencv.org/2.4/modules/imgproc/doc/imgproc.html>. [Accessed: 03-Feb-2019].
- [37] G. Kumar and P. Kumar Bhatia, “A detailed review of feature extraction in image processing systems,” *Int. Conf. Adv. Comput. Commun. Technol. ACCT*, no. February, pp. 5–12, 2014.
- [38] V. Hidalgo, X. Luo, and B. Ji, “Numerical study of unsteady cavitation on 2D NACA0015 hydrofoil using free / open source software,” vol. 59, pp. 3276–3282, 2014.
- [39] OpenCV, “Color conversions,” 2017. [Online]. Available: [https://docs.opencv.org/3.3.0/de/d25/imgproc\\_color\\_conversions.html](https://docs.opencv.org/3.3.0/de/d25/imgproc_color_conversions.html). [Accessed: 03-Feb-2019].
- [40] OpenCV dev team, “Operations on Arrays,” 2014. [Online]. Available: [https://docs.opencv.org/3.0-beta/modules/core/doc/operations\\_on\\_arrays.html?highlight=inrange](https://docs.opencv.org/3.0-beta/modules/core/doc/operations_on_arrays.html?highlight=inrange). [Accessed: 03-Feb-2019].
- [41] P. R. Rajarapollu and V. R. Mankar, “Bicubic Interpolation Algorithm Implementation

- for Image Appearance Enhancement,” *IJCST*, vol. 8, no. 2, pp. 23–26, 2017.
- [42] Electrical and Computer Engineering McMaster University Canada, “Bicubic Interpolation,” 2014. [Online]. Available: [http://www.ece.mcmaster.ca/~xwu/interp\\_1.pdf](http://www.ece.mcmaster.ca/~xwu/interp_1.pdf). [Accessed: 15-Feb-2019].
- [43] R. Stone, “Image Segmentation Using Color Spaces in OpenCv+Python,” *Real Python*, 2018. [Online]. Available: <https://realpython.com/python-opencv-color-spaces/>. [Accessed: 01-Jan-2019].
- [44] Choi Hae Jin, “Chapter 4: Roundoff and Truncation Errors,” *Department of Mechanical Engineering*. [Online]. Available: <http://isd1.cau.ac.kr/education.data/numerical.analysis/Lecture2.pdf>. [Accessed: 27-Jan-2019].
- [45] C. J. Freitas, “The issue of numerical uncertainty,” *Appl. Math. Model.*, vol. 26, no. 2, pp. 237–248, 2002.
- [46] V. Hidalgo, X. W. Luo, X. Escaler, B. Ji, and A. Aguinaga, “Implicit large eddy simulation of unsteady cloud cavitation around a plane-convex hydrofoil,” *J. Hydrodyn.*, vol. 27, no. 6, pp. 815–823, 2015.
- [47] B. Chen, “Roundoff and Truncation Errors,” *Department of Computer Science & Information Engineering National Taiwan Normal University*. [Online]. Available: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.722.1388&rep=rep1&type=pdf>. [Accessed: 25-Jan-2019].