



UNIVERSIDAD DEL AZUAY
FACULTAD DE CIENCIA Y TECNOLOGÍA
ESCUELA DE INGENIERÍA ELECTRÓNICA

**“Sistema Inteligente para Medición de Áreas a través del
Procesamiento de Imágenes Obtenidas por UAV’s.”**

Trabajo de graduación previo a la obtención del título de:

INGENIERO ELECTRÓNICO

Autor:

EDISON FABIAN ENRIQUEZ JARAMILLO

Director:

Mst. GABRIEL DELGADO OLEAS

CUENCA, ECUADOR

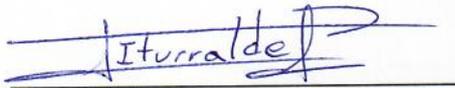
2019

Sistema Inteligente para Medición de Áreas a través del Procesamiento de Imágenes Obtenidas por UAV's.

RESUMEN

En esta investigación se presenta un método para realizar el dimensionamiento de áreas de ortofotografías, para lo cual se desarrolla una segmentación no supervisada mediante K-means para cada pixel, y así reconstruir una imagen con menor número de colores, con lo que se puede realizar una medición de área. Cabe señalar que se estudia además el índice de Calinski-Harabasz (CHI) que permite escoger de mejor manera el espacio de color en el cuál se va a ejecutar el algoritmo. Los resultados en cuanto a tiempo de ejecución y dimensionamiento son favorables, obteniendo aproximadamente un error de 0.08% en medición de áreas.

Palabras clave: K-means, dimensionamiento, áreas, clustering, ortofotografía, espacios de color.



Ing. Daniel Iturralde Piedra. Ph.D.
Coordinador de Carrera.



Mst. Gabriel Delgado Oleas.
Director de Trabajo de Titulación



Edison Fabian Enriquez Jaramillo
Autor

Smart Area Measurement System Through Processing of Images Obtained by UAVs.

ABSTRACT

This research presents a method to perform the measurement of orthophotography areas. An unsupervised segmentation was developed using K-means for each pixel to reconstruct an image with fewer colors in order to perform an area measurement. The Calinski-Harabasz index (CHI) was also studied, which allows a better choice of the color space in which the algorithm will be executed. The results in terms of execution time and sizing are favorable, obtaining approximately 0.08% error in area measurement.

Keywords: K-means, sizing, areas, clustering, orthophotography, color spaces.

Ing. Daniel Iturralde Piedra. Ph.D.
Faculty Coordinator

Mst. Gabriel Delgado Oleas.
Thesis Director

Edison Fabian Enriquez Jaramillo
Author



Translated by
Ing. Paúl Arpi

Sistema Inteligente para Medición de Áreas a través del Procesamiento de Imágenes Obtenidas por UAV's

Enriquez Fabian
Escuela de Ingeniería Electrónica
Universidad del Azuay
Cuenca, Ecuador
efejaramillo@hotmail.com

Resumen— En esta investigación se presenta un método para realizar el dimensionamiento de áreas de ortofotografías, para lo cual se desarrolla una segmentación no supervisada mediante K-means para cada pixel, y así reconstruir una imagen con menor número de colores, con lo que se puede realizar una medición de área. Cabe señalar que se estudia además el índice de Calinski-Harabasz (CHI) que permite escoger de mejor manera el espacio de color en el cual se va a ejecutar el algoritmo. Los resultados en cuanto a tiempo de ejecución y dimensionamiento son favorables, obteniendo aproximadamente un error de 0.08% en medición de áreas.

Palabras clave — *K-means, dimensionamiento, áreas, clustering, ortofotografía, espacios de color.*

I. INTRODUCCIÓN

La necesidad de tener medidas de ciertas áreas urbanas o rurales ayudarán a futuras investigaciones en el ámbito de la ingeniería civil, ingeniería en minas, tendido de cables de alta tensión, biología, reservas y parques naturales, y un sinnúmero de aplicaciones en la agricultura. Estas medidas se las realiza comúnmente mediante tele observación por satélite, la cual actualmente sigue teniendo grandes limitaciones en el uso de aplicaciones de gestión de terrenos, así como para determinar patrones característicos del mismo, todo esto debido a que las imágenes capturadas por satélite son de muy baja calidad, ya que poseen una gran cantidad de gris, por lo cual se dificulta realizar un procesamiento preciso, sin embargo, con el avance tecnológico y la gran cantidad de información existente sobre la inteligencia artificial es posible implementar nuevos sistemas de mediciones [1].

La Inteligencia Artificial no es más que la captación de datos analizados y procesados para que, con dicho conocimiento, se pueda realizar un manejo más eficiente del conocimiento colectivo, lo que permite realizar un sinnúmero de aplicaciones basadas en la segmentación de imágenes [2].

La segmentación de imágenes es un proceso fundamental, y al mismo tiempo es un problema clásico para la mayoría de las aplicaciones de visión artificial. La segmentación tradicional se realiza a escala de grises, es decir, que solo puede utilizar la información de intensidad, en cambio la segmentación de imágenes en color puede contener más niveles de discriminación que alcanzan los millones [3].

Los métodos más utilizados en la segmentación de imágenes se basan en histogramas y la agrupación de

colores. El método de agrupación de colores incluye dos ramas: supervisada y no supervisada. Los algoritmos supervisados son fáciles, ya que están capacitados con datos que proporcionan vectores de entrada, así como sus vectores objetivo correspondientes, o la salida que se espera después de que se procesen los datos, pero poseen una gran desventaja ya que pueden perder parte de la información del color. Los métodos no supervisados, por otro lado, se entrenan utilizando datos que consisten solo en vectores de entrada, sin tener en mente un objetivo específico. En lugar de decirle a un algoritmo no supervisado lo que debería estar buscando en los datos, el algoritmo hace el trabajo por sí mismo, es decir, encuentra la estructura de forma independiente dentro de los datos, por lo que tienen una baja tasa de error y una mejora potencial en la tasa de éxito de la segmentación, pero con un mayor coste computacional [3] [4].

Este tipo de sistemas de clasificación ayudan a desarrollar algoritmos capaces de generar una búsqueda y clasificación de patrones por colores presentes en fotografías y, en éste caso en concreto, en ortofotografías.

II. ESTADO DEL ARTE

- En la Escuela de Electricidad e Ingeniería Informática de la “University Shiraz” se desarrolló una investigación que consiste en aplicar morfología matemática en el procesamiento de las imágenes para poder mejorar la detección de objetos pequeños, para lo cual utilizan un filtro gaussiano que puede simultáneamente suprimir el ruido y el desorden de fondo y al mismo tiempo mejorar la intensidad del objetivo [5].

- Guamán, Córdova & Quezada realizaron un trabajo enfocado en la detección de objetos que se encuentran en movimiento, utilizando un método llamado umbralización, que convierte una imagen a escala de grises, para lograr la extracción de las características y la posterior búsqueda de objetos basada en dichas características [6].

- Tatavarti, Papadakis & desarrollaron un algoritmo que mejora la eficiencia de la segmentación de datos en una región plana, dicho proceso de manera general consiste en 3 pasos: primero se detecta un conjunto de superficies planas para su selección, luego se agrupan estas superficies planas combinando modelos de planos redundantes, y por último se segmenta mediante la imposición de un filtro MRF (de sus siglas, *Markov Random*) [7].

- Hébert & Macaire presentaron un trabajo sobre la segmentación de los colores de una imagen, mediante la clasificación de píxeles por colores espaciales. La

agrupación espectral logra una descomposición de una matriz con la finalidad de crear un espacio propio en el cual se pretende que cada grupo este bien separado [8].

- En el 2013 se realizó un estudio en donde el objetivo fue informar sobre el desarrollo de un sistema capaz de analizar imágenes digitales del terreno e identificar posibles invasiones, cambios no autorizados en la tierra y deforestación en algunas zonas urbanas especiales. Las imágenes son capturadas por una cámara conectada a un helicóptero autónomo, volando alrededor de la zona. Para el procesado de las imágenes se utiliza una técnica de red neuronal artificial [9].

III. METODOLOGÍA

La investigación se centra en realizar un sistema capaz de medir áreas mediante *machine learning* y algoritmos no supervisados tal como se muestra en Fig. 1, para lo cual es necesario realizar una reconstrucción fotográfica de las zonas en las cuales se van a realizar las pruebas y, mediante software especializado, obtener la ortofotografía del sector para luego generar un algoritmo que involucre y clasifique a cada píxel, dependiendo de sus componentes de color, y obtener matices similares ejecutando un modelo matemático que ayude a delimitar las áreas a partir de la cantidad de píxeles encontrados.

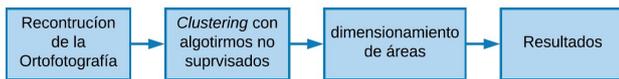


Fig. 1 Metodología.

A. Ortofotografía

La ortofotografía define las fotografías y mapas aéreos, los cuales sirven para registrar y analizar información geográfica, sin embargo, las cámaras capturan imágenes planas, mientras que la tierra es curva y posee variaciones de nivel [10].

Para Konstantaras las ortofotografías digitales logran representar correctamente la geometría de un área, y el proceso para la obtención de ortofotografías digitales se divide en varias fases:

- **Vuelo fotogramétrico:** Tiene por objetivo, sobrevolar una zona a altura y velocidad constante para así obtener las fotografías necesarias para cubrir una porción de territorio
- **Apoyo Topográfico:** Obtención de una sucesión de puntos con coordenadas conocidas e identificables en las fotografías aéreas.
- **Aerotriangulación:** Determinar las coordenadas terrestres de los modelos estereoscópicos(3D) para obtener un mapa digital del terreno
- **Obtención del Modelo Digital de Elevaciones:** Generado a partir de las fotografías aéreas orientadas produciendo un relieve del terreno.
- **Obtención de la Ortofotografía:** Se lleva a cabo un proceso de ortoproyección, el cual proporciona una imagen georreferenciada, y a escala del territorio.

La ortofotografía se obtiene mediante el software “*Agisoft PhotoScan*” que realiza el procesamiento fotogramétrico de imágenes digitales y genera datos

espaciales (3D), este proceso se realiza mediante restitución por coincidencia espacial y el solapamiento de las imágenes (*Stitching*) [11].

De una manera general el algoritmo para realizar el *Stitching* o solapamiento de imágenes se fragmenta en 4 pasos [12].

- **Detección de puntos clave:** La precisión que se tenga para encontrar puntos que puedan combinarse en una imagen dependen directamente del valor más pequeño de la matriz de Hessian de la imagen [13]. Para esto se utiliza un algoritmo de visión artificial SIFT (de sus siglas, *Scale-Invariant Feature Transform*), que es el encargado de extraer características más distintivas de las imágenes [14], en la Fig. 2 se observa como el algoritmo SIFT realiza la extracción de puntos clave y a su vez se obtienen las matrices de orientación de cada una.

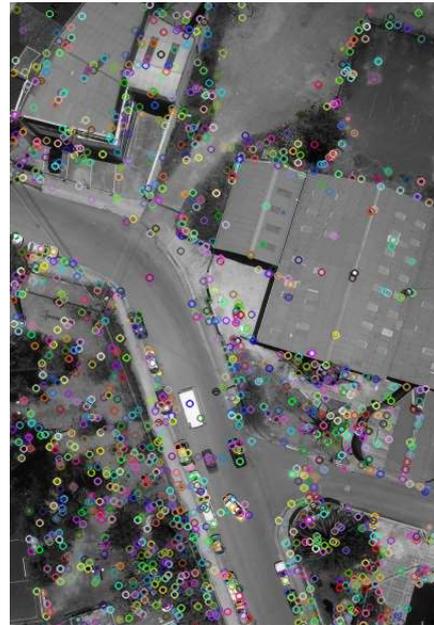


Fig. 2 Región donde se observan los vectores descriptores.

- **Coincidencia de características:** Extraídas las características o puntos clave, se debe combinarlas, es decir, determinar las ubicaciones correspondientes de cada una de las características en diferentes imágenes, como se observa en la Fig. 3 [15]. Debido a que los puntos característicos pueden no estar ubicados exactamente, se puede calcular una coincidencia más precisa utilizando el método de Lucas-Kanade que aplica el criterio de mínimos cuadrados, sin embargo, esto puede aumentar el tiempo, y el costo computacional [16].



Fig. 3 Coincidencia de características

- **Estimación de la homografía:** Una vez que se tiene calculado el conjunto inicial de características, se procede a encontrar un conjunto capaz de producir una alineación con una alta precisión, para esto se utiliza el método de RANSAC (de sus siglas, *RANdom SAmple Consensus*), el cual comienza seleccionando un subconjunto al azar de n correspondencias, utilizado para calcular una estimación de movimiento, en la Fig. 4 se muestra la reconstrucción de dos imágenes utilizando los vectores obtenidos mediante RANSAC [14].



Fig. 4 homografía de 2 imágenes.

- **Proyección sobre una superficie y mezclado:** La primera elección que se debe considerar es cómo y dónde se va a representar la imagen final, si solo son unas pocas imágenes que se unen, la manera más sencilla es tomar una de las imágenes como base y luego deformar todas las demás imágenes en el sistema de coordenadas de referencia. Las proyecciones sobre la superficie final siguen siendo una proyección en perspectiva, es decir, en un solo plano, véase la Fig. 5 [14].



Fig. 5 Proyección y mezclado de las imágenes.

En la Fig. 6, se observa el resultado de realizar una ortofotografía mediante 250 imágenes aéreas, cubriendo un área aproximada de 13.8 hectareas, cabe señalar que en un solo vuelo de la aeronave se pudieron recopilar todos estos datos. El resultado que se observa tiene una resolución de aproximadamente 26780x25331.



Fig. 6 Ortofotografía sector Tres Puentes.

B. Clasificación de píxeles - Clustering

El proceso de agrupar objetos abstractos o físicos dentro de clases de similares objetos, es denominado agrupamiento [17]. La agrupación de objetos puede clasificarse en 2 grupos: agrupamiento sólido y agrupamiento difuso.

El agrupamiento sólido asigna cada vector de características a solo uno de los *clusters*, es decir con un grado de pertenencia igual a uno y con los límites bien definidos entre cada *cluster*. El agrupamiento difuso en cambio permite que cada vector de características pertenezca a uno o varios *clusters* con diferentes niveles de pertenencia (entre 0 y 1), lo que genera límites difusos entre agrupamientos [18].

Por lo tanto, un *cluster* es una agrupación de datos que poseen similitudes entre sí, y al mismo tiempo son totalmente diferentes a los de otros *clusters*, ya que los grupos de objetos se pueden considerar como un solo grupo

muchos investigadores como Willian y Edelsbrunner lo consideran una forma de compresión de datos [19].

Realizar una clasificación para distinguir un objeto de otros puede ser el método más eficaz, sin embargo, este proceso requiere la recolección y el etiquetado de los datos que a menudo resultan en un gran consumo de memoria, ya que el clasificador utiliza varios conjuntos de tuplas o en algunos casos patrones de entrenamiento para así modelar cada uno de los grupos, por lo que es más recomendable utilizar el método de manera inversa, es decir, primero dividir todo el conjunto de datos en pocos subconjuntos de datos con similitudes, y asignar etiquetas a los subconjuntos creados [19].

En este trabajo de investigación se realiza la clasificación sobre dos espacios de color RGB, HSV para luego determinar cuál es el más óptimo para este tipo de análisis.

C. Espacios de color RGB

Este espacio de color es el más utilizado que se basa al mezcla de tres colores primarios rojo (R), verde (G), azul (B), se puede obtener varios colores (X) por la suma algebraica de cada canal ecuación (1) [20].

$$X = R + G + B \quad (1)$$

Este espacio de color básico se representa en un plano cartesiano de tres dimensiones, tal como muestra la Fig. 7, donde cada color es representado por un punto tridimensional perteneciente al interior o a la superficie del cubo [21].

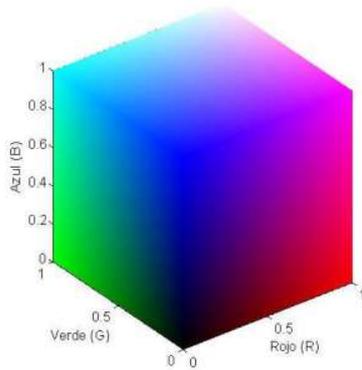


Fig. 7 Cubo de color RGB.

Unos de los principales inconvenientes que presenta el espacio de color RGB es que la segmentación de imágenes tiene una gran dependencia con la variación de los niveles de luz, por lo cual se normalizo el espacio de color RGB formulando las ecuaciones(2, 3, 4, 5) [20].

$$L = C_1 R + C_2 G + C_3 B \quad (2)$$

$$T_1 = \frac{R}{(R+G+B)} \quad (3)$$

$$T_2 = \frac{G}{(R+G+B)} \quad (4)$$

$$C_1 + C_2 + C_3 = 1 \quad (5)$$

Donde C_1 , C_2 y C_3 son contantes, L es la luminancia de la imagen, T_1 y T_2 son las variables cromáticas independientes de la iluminación. En la Fig. 8 se muestra lo que ocurre al separar cada uno de los tres canales RGB.

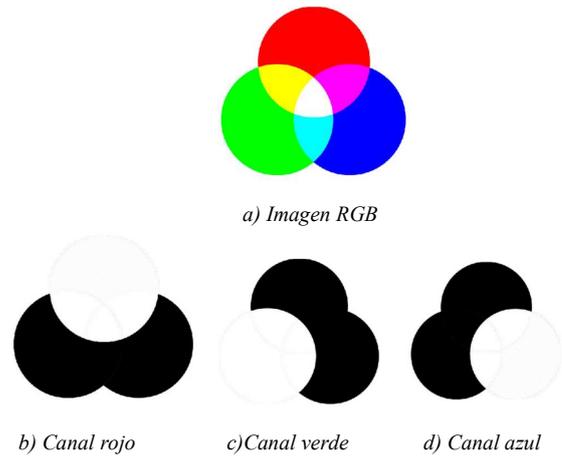


Fig. 8 Descomposición de los tres canales RGB.

D. Espacio de color HSV

El espacio de color HSV, es una representación matemática de colores en coordenadas cartesianas tridimensionales, como matiz (H), saturación (S) y valor (V). El matiz representa el tipo de color o el tono del color por lo cual se puede distinguir fácilmente un color de otro. El tono o matiz varia en un ángulo de 0 a 360 grados, de esta manera, se puede representar todos los colores en el espacio de color HSV. La saturación define la pureza del color, es decir, qué cantidad de color blanco se mezcla con el tono, y el tercer componente es el valor que representa el brillo del color, este puede oscilar entre 0 y 100, en la Fig. 9 se puede observar los 3 componentes del espacio de color representador de forma cónica. Por lo mencionado anteriormente, este espacio de color es el más usado en la segmentación de imágenes, el reconocimiento de objetos y el análisis de imágenes [22].

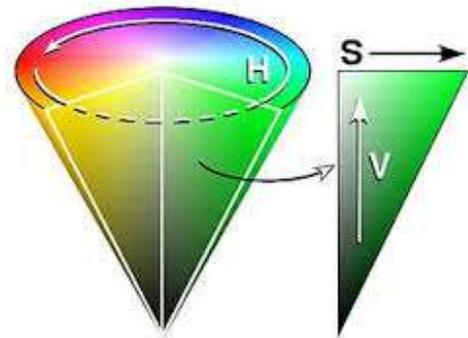


Fig. 9 Espacio de color HSV.

La transformación del espacio de color RGB al espacio de color HSV se da mediante la aplicación de 3 ecuaciones (6, 7, 8) [17].

$$H = \cos^{-1} \frac{(2R-G-B)}{\sqrt{(R-G)^2 - (R-B)(G-B)}} \quad (6)$$

$$S = \frac{\max(R,G,B) - \min(R,G,B)}{\max(R,G,B)} \quad (7)$$

$$V = \max(R, G, B) \quad (8)$$

En la Fig. 10 se muestra la conversión de una imagen RGB a HSV y la respectiva descomposición de cada uno de sus tres canales HSV.

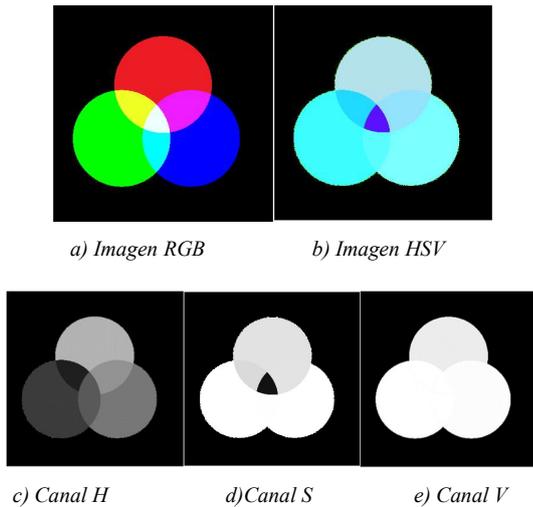


Fig. 10 Descomposición de los tres canales HSV.

E. Calidad de medida e índice de validación

Para corroborar que espacio de color tiene un mejor resultado se utiliza el índice de Calinski-Harabasz (CHI), el cual es un "criterio de relación de varianza" que da una idea de la estructura de los datos. Este método se describe en la ecuación 9 [23].

$$CHI = \frac{SS_B}{SS_W} \times \frac{N-k}{K-1} \quad (9)$$

Donde N representa el número total de observaciones (datos), k el número total de agrupaciones, SS_B es la varianza entre conglomerados y SS_W la varianza dentro del conglomerado [23]. Los valores del índice CHI indican que, si el valor de criterio es más alto, la agrupación será la más óptima [24].

F. Diagrama de flujo

Se debe considerar que la profundidad de color que ofrece una cámara 4K puede ir desde los 8, 10, 12 bits por cada canal RGB, es decir, que para una cámara profesional de 12 bits se tendrá 68.719 billones de colores diferentes dentro de la imagen [25], los cuales serán reducidos a k conjuntos con la aplicación del algoritmo de *K-means*, dicho de otra manera, ahora la imagen solo tendrá k colores con los cuales se trabajará.

En la Fig. 11 se muestra mediante un diagrama de flujo los pasos necesarios para obtener el dimensionamiento de las áreas de una manera global para luego explicar cada uno de manera más detallada.

Al iniciar el algoritmo se debe especificar la cantidad de colores (k -clusters) que se obtendrán al final en la imagen, acorde a la investigación realizada, se procede a cambiar los espacios de color de la imagen de RGB a HSV, ya que este último es el más utilizado en aplicaciones de *clustering*, ya que es independiente de la intensidad que posee la imagen, lo que resulta muy útil cuando se posee ruido o iluminación no uniforme como las sombras, sin embargo, como se mencionó en la sección anterior, también se realizará un análisis con imágenes RGB [24].

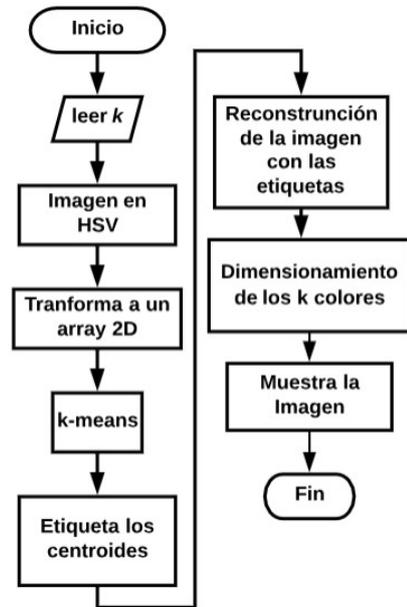


Fig. 11 Diagrama de flujo del sistema de dimensionamiento.

Además, es necesario convertir la imagen en una matriz 2D con punto flotante (64 bits), cada elemento de dicha matriz será dividido para una constante $b=255$ para que cada elemento este en un rango de 0 a 1, ya que la librería utilizada para mostrar la imagen (*Matplotlib*) recorta la imagen si está fuera de dicho rango, posteriormente se procede a realizar una toma de datos aleatorios de la matriz bidimensional, ya que dichos valores serán utilizados por el algoritmo de *machine learning* - *K-means* que realizará las diferentes agrupaciones, esto se explica más a detalle en la sección F. A los centroides calculados por el algoritmo se les concede una etiqueta para realizar la posterior reconstrucción de la imagen con solo los k colores etiquetados, el algoritmo para recrear la imagen se explica con mayor profundidad en la sección G, y con dicha imagen se procede a realizar el cálculo de las áreas pertenecientes a cada uno de los colores agrupados.

G. K-means

Es uno de los algoritmos de aprendizaje no supervisado más utilizados para el análisis de *clusters* o agrupamientos. Este término fue empleado por primera vez en 1967 por MacQueen, aunque ya había sido propuesto por Lloyd en 1957 como una técnica para la modulación por pulsos. El objetivo de este algoritmo es la agrupación sólida de los datos en k conjuntos, de manera que la segmentación se da agrupando los datos con la media más cercana, dando como resultado una separación del espacio de datos en celdas de Voronoi [18].

El resultado de *K-means* es tal que agrupa datos con una alta similitud entre sí y, al mismo tiempo, muy diferentes a los datos de los demás *clusters* [20]. La similitud de los datos se calcula obtenido el valor de la media de los datos de un grupo con respecto al centroide o centro de gravedad del conjunto. El procedimiento que sigue el algoritmo básico de *K-means* se puede definir en 4 pasos.

- **Paso 1:** El objetivo principal es definir el número de centroides deseados (k), uno para cada grupo. Estos centroides deben ubicarse de tal forma que estén lo más lejos posible unos de otros, ya que una diferente ubicación

causara un resultado diferente [4]. En la Fig. 12 se observa que los centroides se ubican de una manera aleatoria dentro de los datos, en este caso con número de centroides $k = 3$, representados por el color azul, rojo y verde [4] [20].

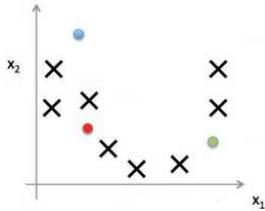


Fig. 12 Inicialización de los k centroides.

- **Paso 2:** Se toma cada punto perteneciente al conjunto de datos y se asocia al centroide más cercano. Cuando no hay ningún punto pendiente, se completa el primer paso y se realiza una agrupación temprana [4]. En función de la distancia se asignan los datos a los diferentes centroides, tal como muestra la Fig. 13 [4] [20].

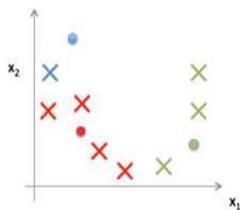


Fig. 13 Asignación de los datos con sus respectivos centroides.

- **Paso 3:** Se debe recalculer los nuevos centroides de los k grupos resultantes del paso anterior. Una vez obtenida la nueva posición de estos k centroides, se procede a reubicarlos generando nuevos enlaces entre los datos y el nuevo centroide. En la Fig. 14 se muestra la reasignación de los nuevos centroides que fueron calculados como la media de todos los elementos que estaban asignados a ese conjunto [4] [20].

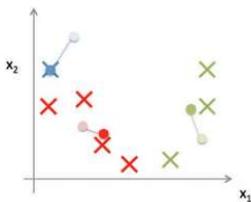


Fig. 14 Reubicación de los centroides.

- **Paso 4:** Se genera un bucle, en el cual se repiten los pasos 2 y 3 hasta que los centroides no cambien de posición, es decir que todos los puntos convergen [4] [20].

Entonces se puede expresar este algoritmo mediante la ecuación (10), la cual construye una distribución de los datos en k conjuntos con el afán de reducir la suma de los cuadrados dentro de cada conjunto [4].

$$J = \sum_{j=1}^k \sum_{i=1}^n \|X_i^{(j)} - C_j\|^2 \quad (10)$$

Donde $\|X_i^{(j)} - C_j\|^2$ es la medida de distancia existente entre un punto de datos $X_i^{(j)}$ y su respectivo centroide C_j . El método de agrupamiento de K -means se encuentra representado mediante un diagrama de flujo en la Fig. 15.

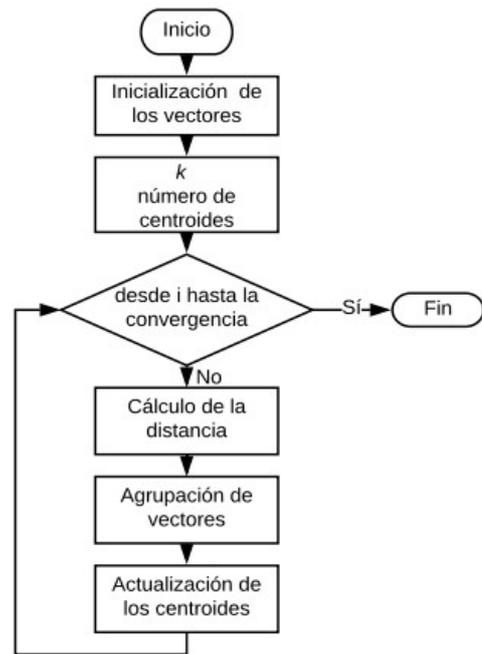


Fig. 15 Diagrama de flujo del método K -means.

H. Reconstrucción de la imagen

La reconstrucción de la imagen, hace referencia a recrear la imagen original con un número limitado de colores, los cuales han sido previamente obtenidos por el método de K -means. Para realizar este procedimiento se construye una matriz de ceros bidimensional, cuyo tamaño está dada por el ancho (w) y alto (h) de la fotografía original, estos valores también son utilizados para crear un bucle anidado que recorre cada vector y al mismo tiempo lo reemplaza con el valor del centroide correspondiente, en la Fig. 16 se muestra el diagrama de flujo que detalla este proceso.

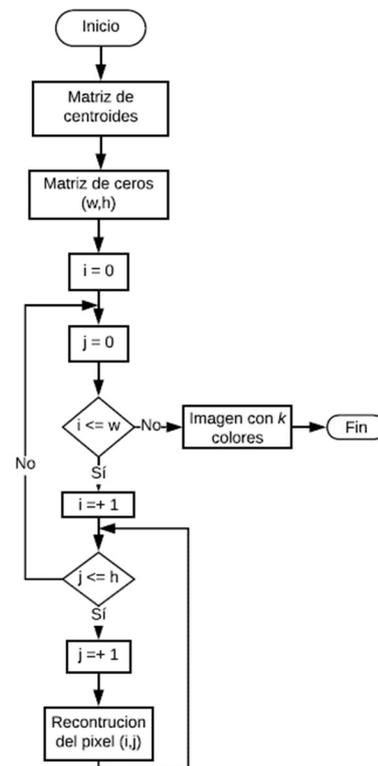


Fig. 16 Diagrama de bloques de la reconstrucción de la imagen.

I. Algoritmo de dimensionamiento con imágenes binarias

El dimensionamiento de áreas, hace referencia al conteo de los píxeles de un mismo color, para posteriormente poder convertirlos a unidades de superficie (cm^2, m^2, Km^2), este proceso se detalla mediante un diagrama de flujo en la Fig. 17.

Para realizar el conteo de los píxeles, el sistema se basa en algoritmos de código abierto que mejoran la eficiencia computacional, y tienen un fuerte enfoque en aplicaciones en tiempo real [26]. En un inicio se establece una tolerancia para cada color, el cual se utiliza para realizar una máscara de umbralizado y así generar una imagen binaria, es decir, una imagen con dos niveles de intensidad (0 y 1). La ecuación (11) es la representación matemática para la discriminación de los dos niveles de intensidad, donde LS es el valor más alto del color, LI es el valor más bajo del color, P_i es el valor del píxel original, y P_o es el valor final del píxel [20].

$$P_o = \begin{cases} 0 & \text{si } LI < P_i(i,j) < LS \\ 1 & \text{si } LI \leq P_i(i,j) \geq LS \end{cases} \quad (11)$$

Para eliminar el ruido de la imagen binaria, se aplican transformaciones morfológicas básicas, entre la cual está la transformada de cierre, que aplica simultáneamente dilatación y erosión, muy útil para rellenar los intersticios de una imagen [20].

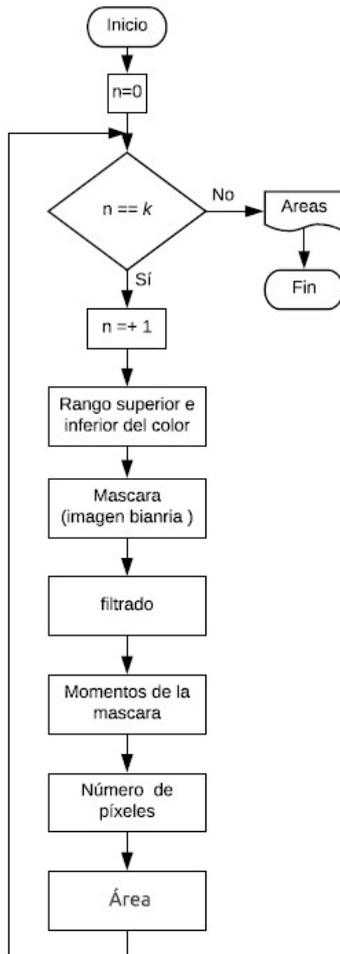


Fig. 17 Diagrama de flujo del dimensionamiento de áreas.

De las imágenes binarias se puede extraer la forma característica de un objeto mediante la cuantificación de sus momentos, los cuales describen la distribución de los píxeles de un objeto sobre un plano. Un momento de orden cero $M(0,0)$, no es más que la suma de todos los píxeles de valor 1, tal como se indica en la ecuación (12), con lo cual se obtiene de manera exacta el número de píxeles blancos presentes en una imagen [27].

$$M(0,0) = \sum_x \sum_y f(x,y) \quad (12)$$

En contexto, el cálculo del área del presente trabajo de investigación es el resultado de la aplicación de la ecuación (13), donde D_p es la dimensión del píxel dada en cm^2 , que depende tanto de la altura del vuelo programado como de la calidad de generación de la ortofotografía determinada por el software, además de, la velocidad mínima de vuelo, la distancia mínima del solapamiento de las imágenes, resolución de la cámara y su velocidad de obturación [28].

$$\text{Área} = \frac{M(0,0) \times (D_p)^2}{10000} \quad (13)$$

J. Algoritmo de dimensionamiento mediante bucles

Como se detalla en la anterior sección, para el dimensionamiento de áreas en unidades de superficie se aplica el modelo matemático de la ecuación (7), que se basa en la cantidad de píxeles que posee un determinado color dentro de la imagen.

En este caso el conteo de píxeles se lo realiza mediante sentencias de programación de tipo bucles (*For* y *While*) que recorren cada píxel (x, y) de la imagen y los compara con los valores de la matriz resultante obtenida mediante *K-means*, dando como resultado otra matriz de igual dimensión, donde cada elemento mostrara la cantidad de píxeles total de un determinado color, todo esto se expresa mediante un diagrama de flujo mostrado en la Fig. 18

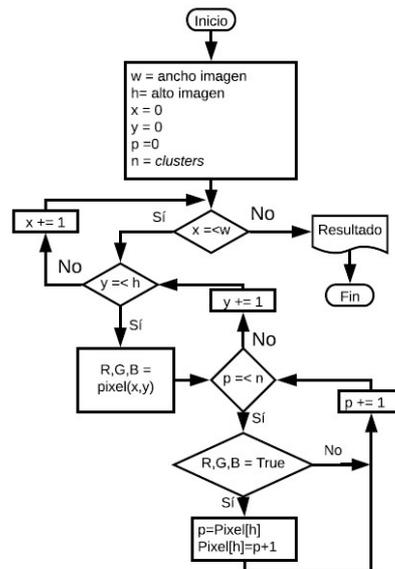


Fig. 18 Conteo de píxeles mediante bucles.

IV. RESULTADOS

Los datos analizados fueron obtenidos de una ortofotografía con diferentes resoluciones espaciales 1.78 cm/píxel y 10 cm/píxel, y un área de aproximadamente 2.1 hectáreas, con una segmentación (*k-means*) de $k = 12$.

La Fig. 19 muestra las ortofotografías del sector de la Universidad del Azuay con diferentes resoluciones espaciales. En la Fig. 20 se observa los resultados obtenidos al realizar la reconstrucción de la imagen con los valores que el algoritmo entrega al finalizar el *clustering* (agrupamiento) sobre las ortofotografías con un espacio de color HSV.

Cabe señalar que, dentro de las 12 agrupaciones finales, está incluido el color blanco, el cual se descarta en las máscaras, ya que este pertenece al fondo de las imágenes Fig. 19.

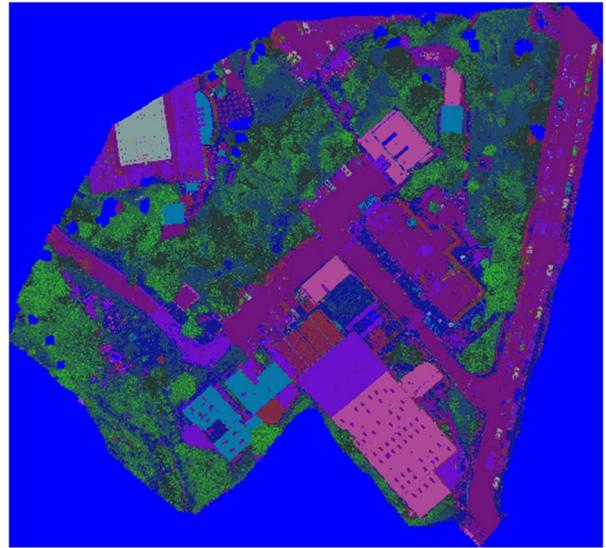


a) Resolución espacial de 1.78 cm/píxel.



b) Resolución espacial de 10 cm/píxel.

Fig. 19 Ortofotografías sector UDA con diferentes resoluciones espaciales.



b) Resolución espacial de 1.78 cm/píxel.



b) Resolución espacial de 10 cm/píxel.

Fig. 20 Resultado de la reconstrucción de la ortofotografía (HSV) sector UDA con diferentes resoluciones espaciales y con $k=12$.

Como se esperaba, los valores de la reconstrucción (centroides *k-means*) de la Fig. 20a y la Fig. 21b son similares, aunque su resolución espacial sea diferente.

Con cada uno de dichos valores, se realiza el cálculo del área correspondiente a cada una de las agrupaciones obtenidas, y se lo segmenta de la imagen original, a su vez la imagen resultante es presentada al usuario ya que, como se indicó anteriormente, el algoritmo de machine learning utilizado es no supervisado, por lo que el cálculo total del área de interés será evaluado por el usuario.

En la Fig. 21 se muestran las máscaras obtenidas al segmentar el espacio de color HSV de la ortofotografía con una resolución espacial de 1.78 cm/píxel además de su área calculada.



354.515m²

a) Mascara HSV [130.24, 158.39, 157.33].



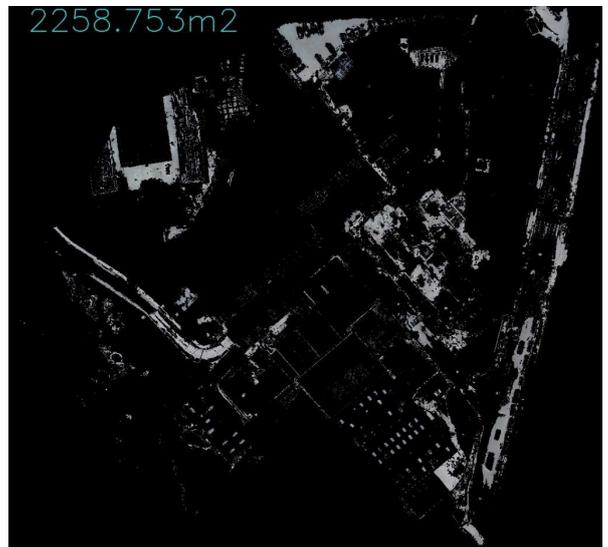
3975.951m²

d) Mascara HSV [112.31, 23.22, 112.71].



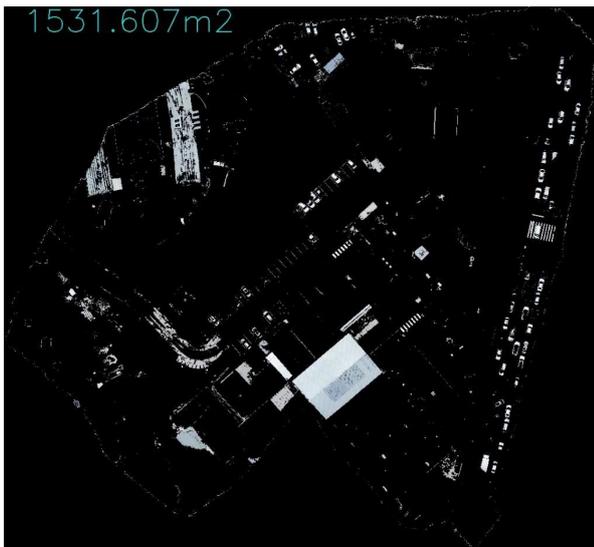
708.174m²

b) Mascara HSV [120.93, 49.87, 57.16].



2258.753m²

e) Mascara HSV [113.07, 14.5, 153.39].



1531.607m²

c) Mascara HSV [104.14, 19.77, 214.25].

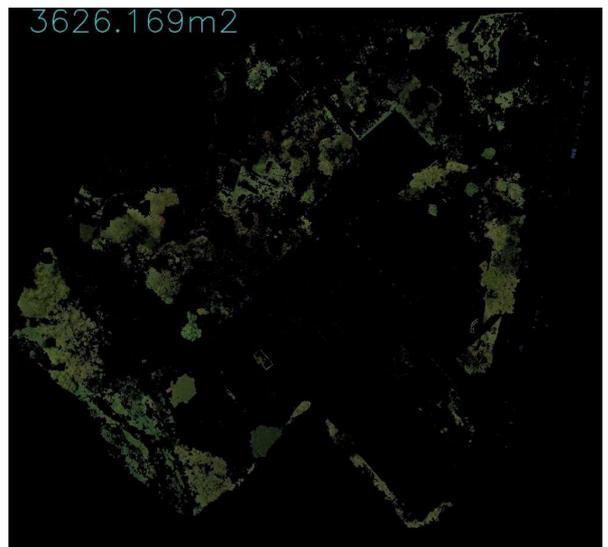


2497.520m²

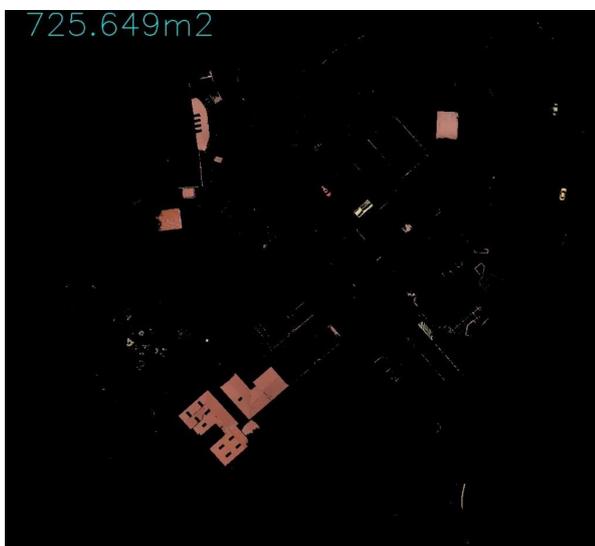
f) Mascara HSV [18.01, 24.95, 145.85].



g) Mascara [173.89, 74.43, 152.11]



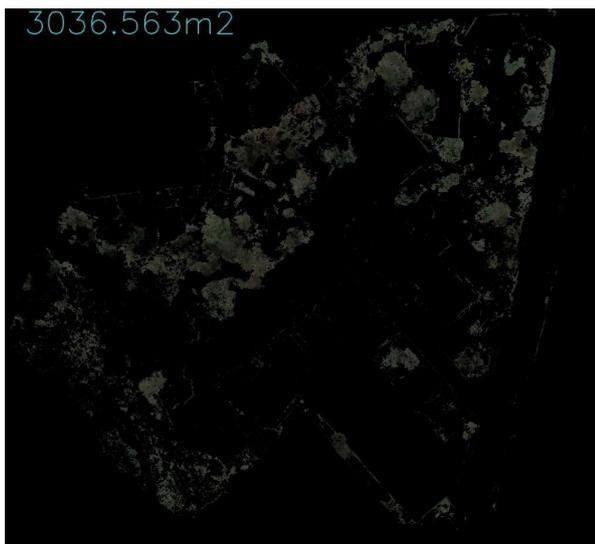
j) Mascara HSV [41.74, 114.40, 66.29].



h) Mascara HSV [6.725, 116.47, 167.55].



k) Mascara HSV [33.83, 67.94, 103.65].



i) Mascara HSV [38.36, 63.62, 54.26].

Fig. 21 Mascaras de la segmentación del espacio de color HSV para la ortofotografía de 1.78 cm/píxel.

En la TABLA I podemos encontrar las dimensiones que posee cada una de las máscaras mostradas en la Fig. 21 con su respectivo valor de segmentación HSV.

TABLA I. DIMENSIONES DEL LAS MÁSCARAS EN HSV (1.78CM/PÍXEL)

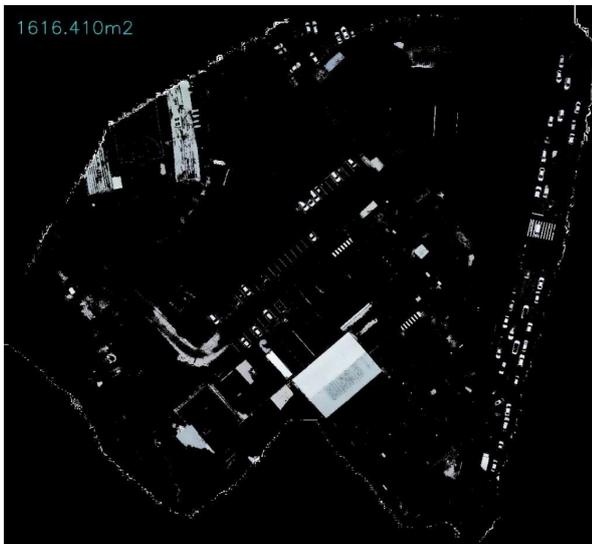
HSV	Dimensión (m ²)
[130.24, 158.39, 157.33]	354.514
[120.93, 49.87, 57.16]	708.173
[104.14, 19.77, 214.25]	1531.60
[112.31, 23.22, 112.71]	3975.951
[113.07, 14.5, 153.39]	2258.753
[18.01, 24.95, 145.85]	2497.51
[173.89, 74.43, 152.11]	1584.269
[6.725, 116.47, 167.55]	725.649
[38.36, 63.62, 54.26]	3036.562

HSV	Dimensión (m ²)
[41.74, 114.40, 66.29]	3626.169
[33.83, 67.94, 103.65]	3887.056

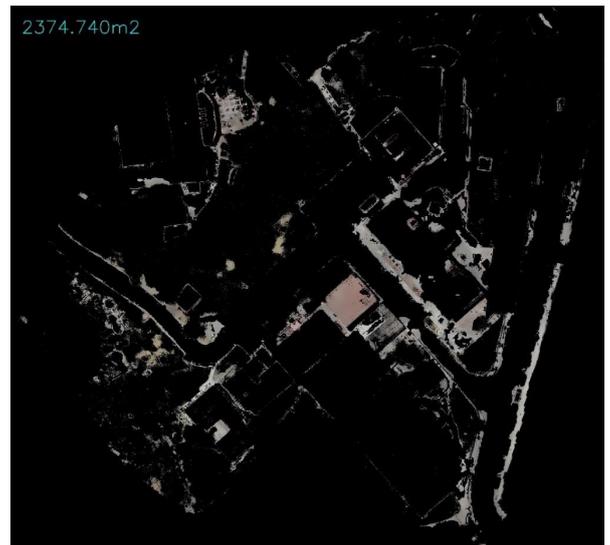
De igual manera se realiza el mismo procedimiento para segmentar el espacio de color HSV de la ortofotografía que posee una resolución espacial de 10cm/píxel, dando como resultados las imágenes mostradas en la Fig. 22.



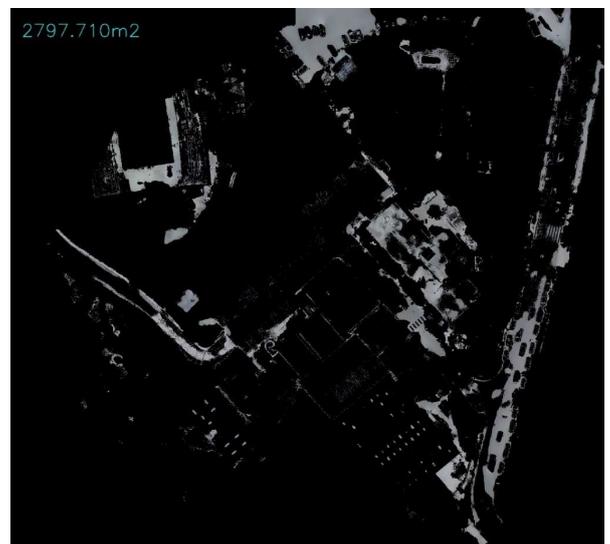
a) Mascara HSV [127.80, 150.98, 156.83].



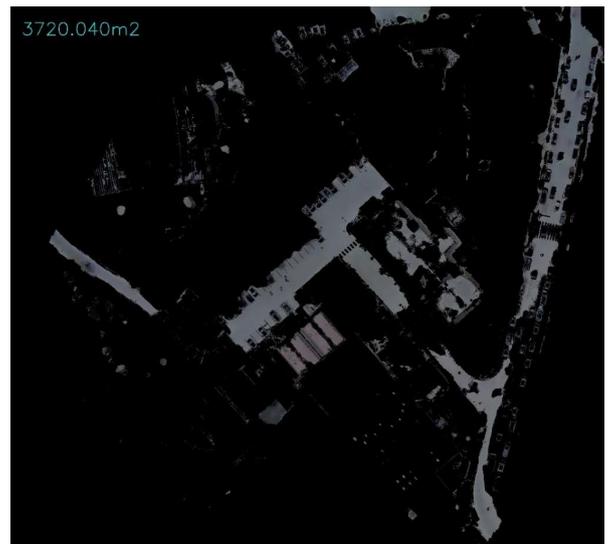
b) Mascara HSV [103.787, 17.03, 214.59].



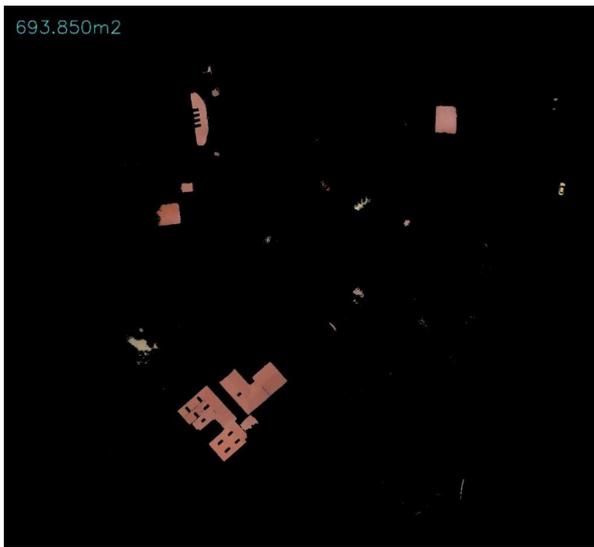
c) Mascara HSV [19, 19.93, 146.04].



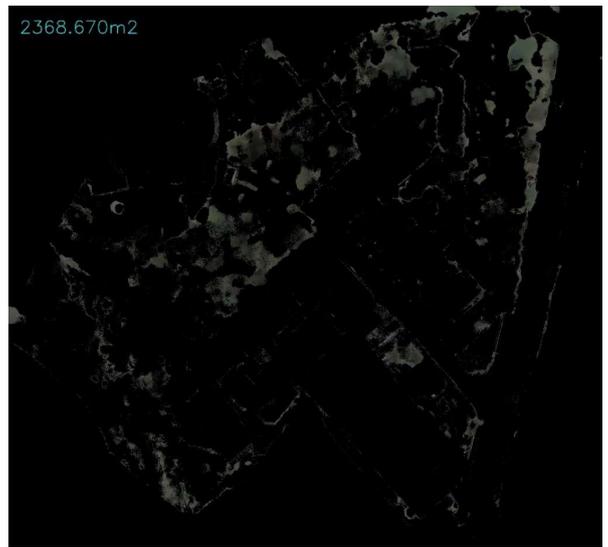
d) Mascara HSV [106.38, 14.86, 143.77].



e) Mascara HSV [111.86, 26.30, 103.79].



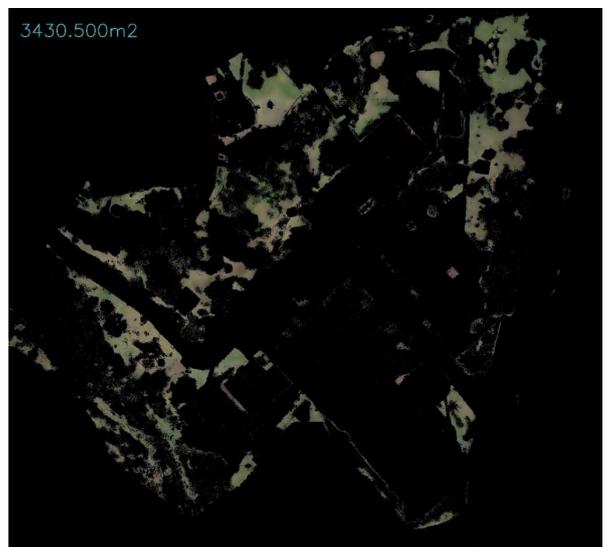
f) Mascara HSV [6.26, 109.07, 168.84].



i) Mascara HSV [39.39, 41.41, 68.23].



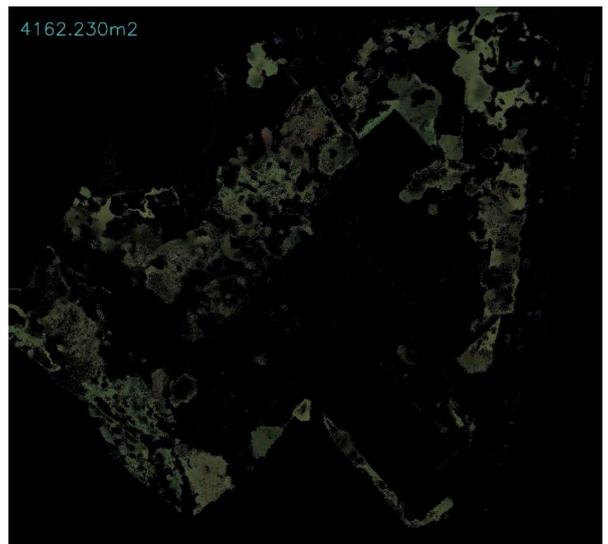
g) Mascara HSV [173.17, 58.38, 146.36].



j) Mascara HSV [32, 63.17, 107.38].



h) Mascara HSV [40.75, 128.71, 57.96].



k) Mascara HSV [41.28, 84.55, 65.03].

Fig. 22 Mascaras de la segmentación del espacio de color HSV para la ortofotografía de 10 cm/pixel.

De igual manera la TABLA II muestra las dimensiones de las máscaras mostradas en la Fig. 22 con su respectivo valor de segmentación HSV.

TABLA II. DIMENSIONES DEL LAS MÁSCARAS EN HSV (10CM/PIXEL)

HSV	Dimensión (m ²)
[127.80, 150.98, 156.83]	335.21
[103.787, 17.03, 214.59]	1616.41
[19, 19.93, 146.04]	2374.74
[106.38, 14.86, 143.77]	2797.71
[111.86, 26.30, 103.79]	3720.04
[6.26, 109.07, 168.84]	693.85
[173.17, 58.38, 146.36]	1988.89
[40.75, 128.71, 57.96]	1717.4
[39.39, 41.41, 68.23]	2368.67
[32, 63.17, 107.38]	3430.5
[41.28, 84.55, 65.03]	4162.23

Uno de los objetivos de esta investigación, es analizar las diferentes áreas dentro de una imagen, mediante la segmentación de colores, por este motivo se procede a utilizar el algoritmo sobre el espacio de color RGB, este resultado se muestra en la Fig. 23.



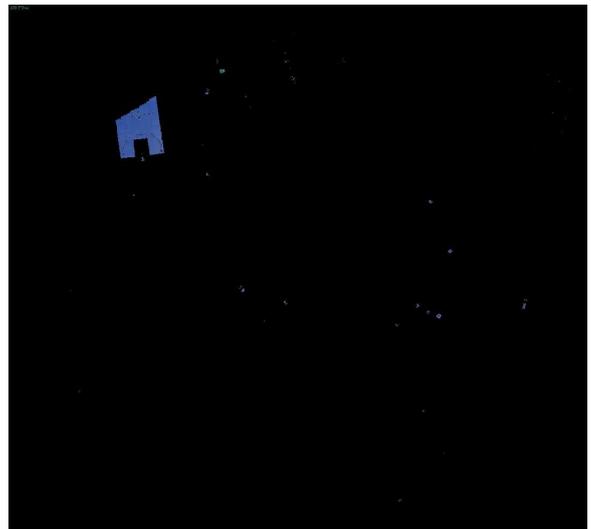
a) Imagen con resolución de 1.78 cm/píxel.



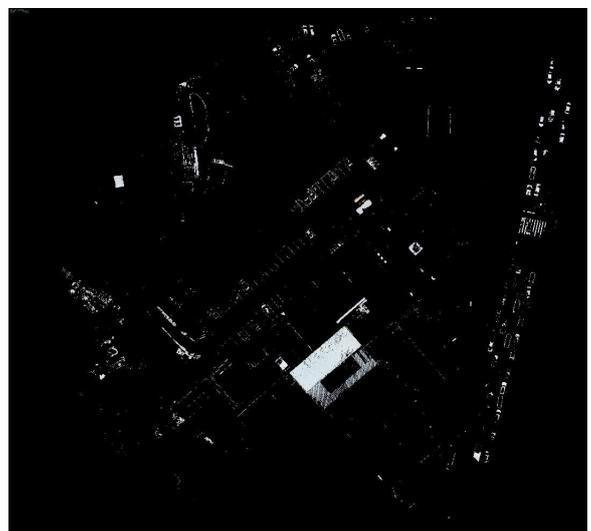
b) Imagen con resolución de 10 cm/píxel.

Fig. 23 Resultado de la reconstrucción de la ortofotografía (RGB) sector UDA con diferentes resoluciones espaciales y con k=12.

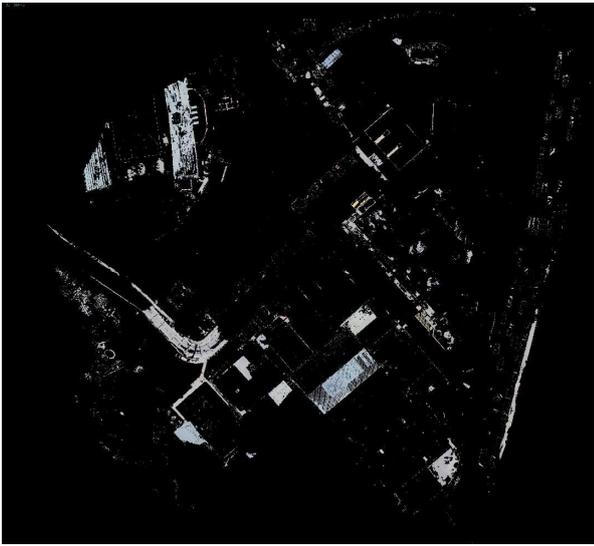
Las máscaras mostradas en la Fig. 24 son resultado de aplicar el algoritmo para realizar la segmentación RGB sobre la ortofotografía.



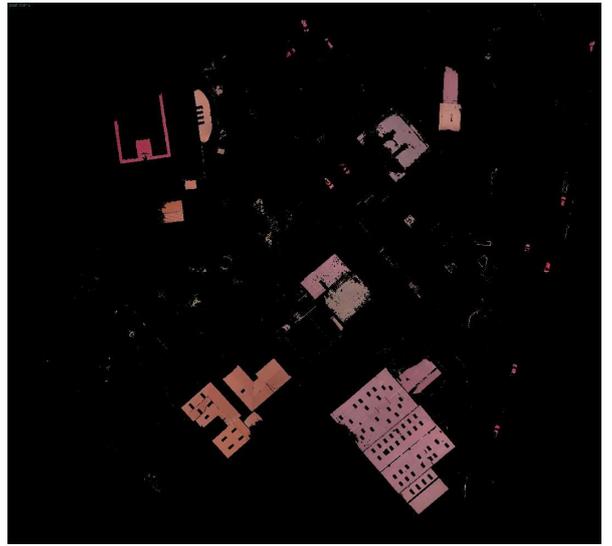
a) Mascara RGB [61.45, 90.45, 159.35].



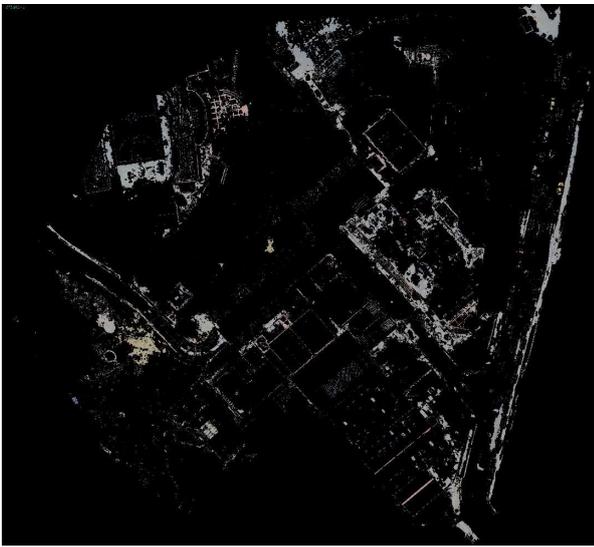
b) Mascara RGB [212.31, 220.94, 225.7].



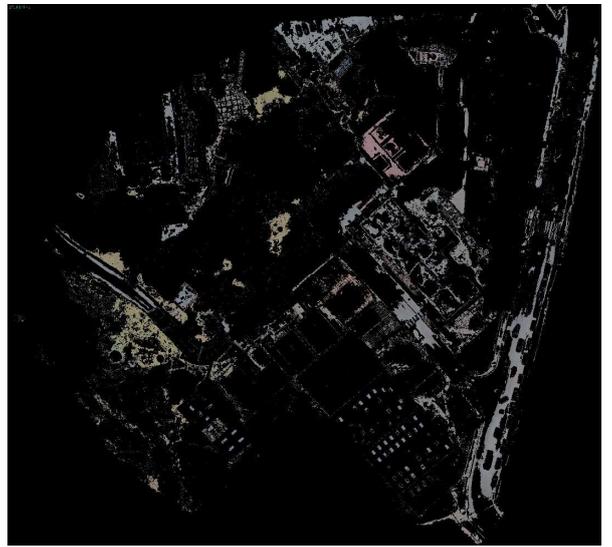
c) Mascara RGB [180.99, 185.86, 189.43].



f) Mascara RGB [156.68, 103.14, 104.85].



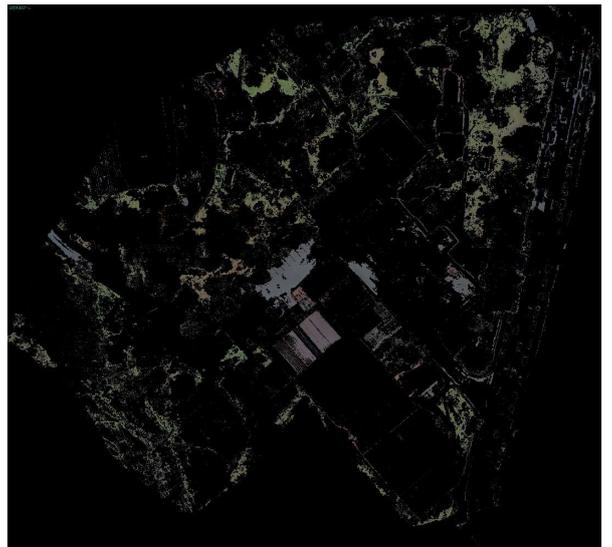
d) Mascara RGB [155.44, 153.93, 153.43].



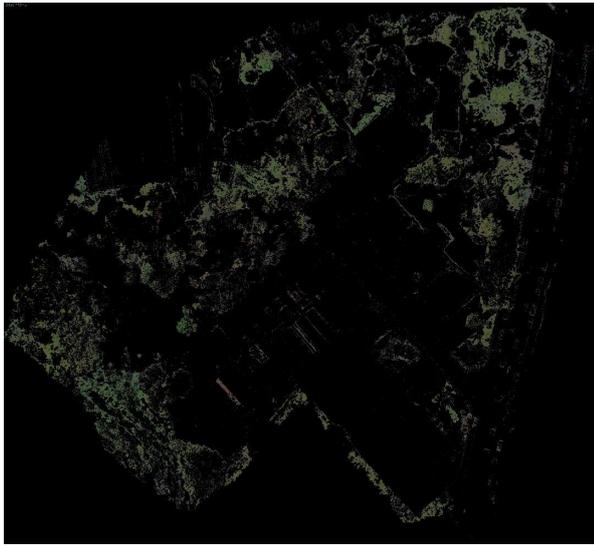
g) Mascara RGB [132.45, 130.98, 128.16].



e) Mascara RGB [32.30, 36.92, 25.84].



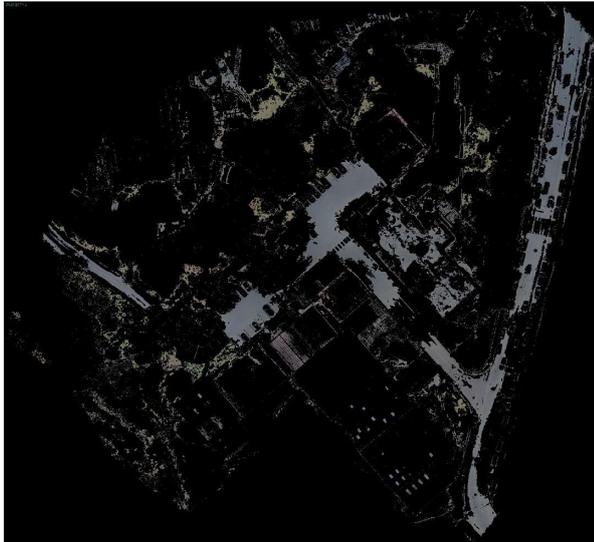
h) Mascara RGB [94.92, 97.20, 82.26].



i) Mascara RGB [74.13, 82.26, 57.87].



j) Mascara RGB [54.05, 61.27, 41.45].



k) Mascara RGB [108.11, 110.35, 109.56].

Las dimensiones obtenidas para cada mascara RGB de la ortofotografía de 1.78 cm/píxel, se muestran en la TABLA III.

TABLA III. DIMENSIONES DEL LAS MÁSCARAS EN RGB

RGB	Dimensión (m ²)
[61.45, 90.45, 159.35]	233.372
[212.31, 220.94, 225.7]	597.777
[180.99, 185.86, 189.43]	1391.565
[155.44, 153.93, 153.43]	1873.262
[32.30, 36.92, 25.84]	2166.686
[156.68, 103.14, 104.85]	2207.307
[132.45, 130.98, 128.16]	2794.846
[94.92, 97.20, 82.26]	2834.28
[74.13, 82.26, 57.87]	3105.772
[54.05, 61.27, 41.45]	3265.765
[108.11, 110.35, 109.56]	3607.206

Se repite el procedimiento aplicando el algoritmo sobre la ortofotografía RGB con una resolución espacial de 10 cm/píxel, dando como resultado las máscaras de la Fig. 25.



a) Mascara RGB [66.25, 95.86, 159.32].

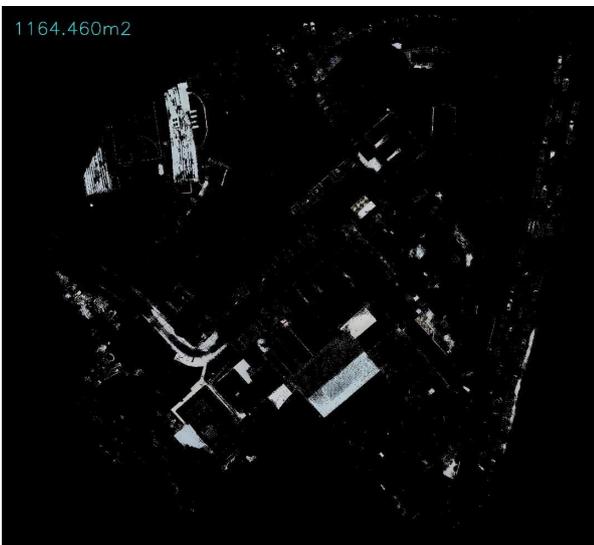
Fig. 24 Máscaras de la segmentación del espacio de color RGB para la ortofotografía de 1.78 cm/píxel.



b) Mascara RGB [220.86, 227.14, 231.21].



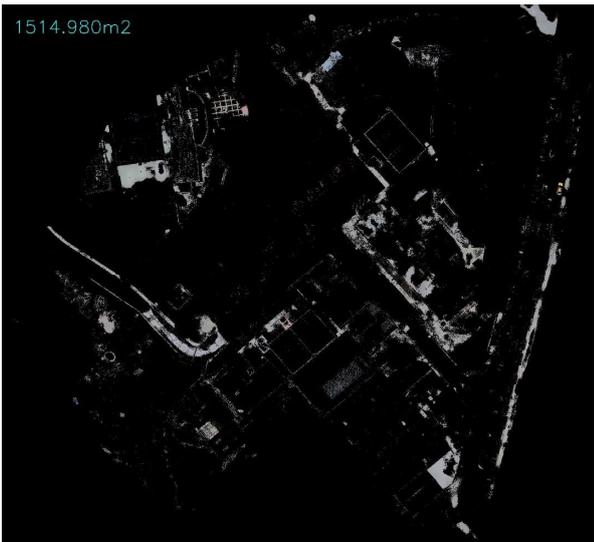
e) Mascara RGB [157.45, 107.42, 107.73].



c) Mascara RGB [184.93, 191.12, 194.56].



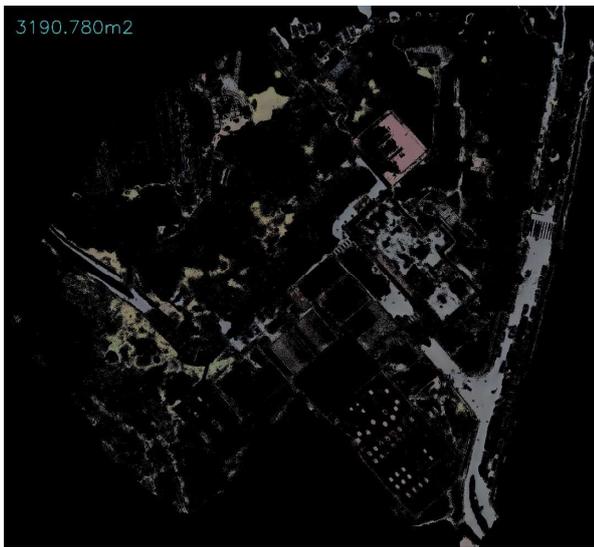
f) Mascara RGB [137.44, 136.05, 135.21].



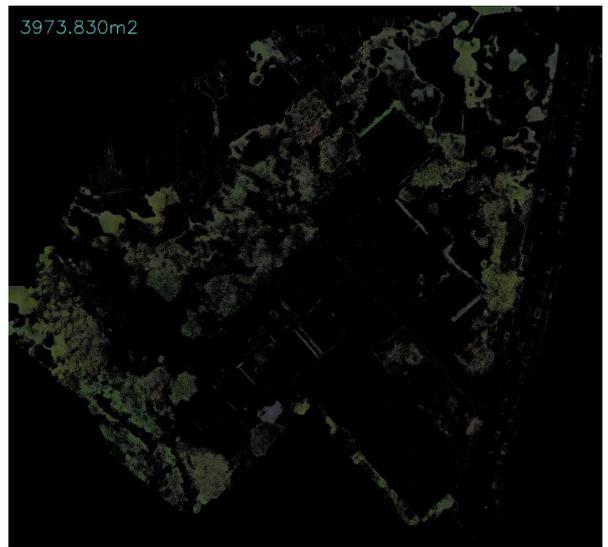
d) Mascara RGB [160.49, 160.38, 161.03].



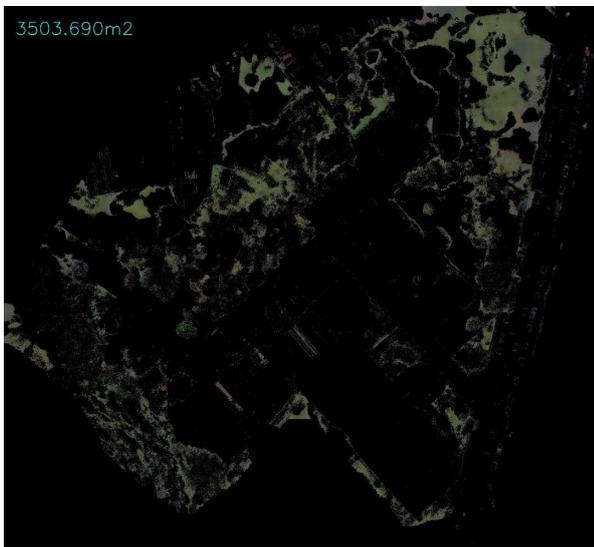
g) Mascara RGB [37.78, 43.10, 28.94].



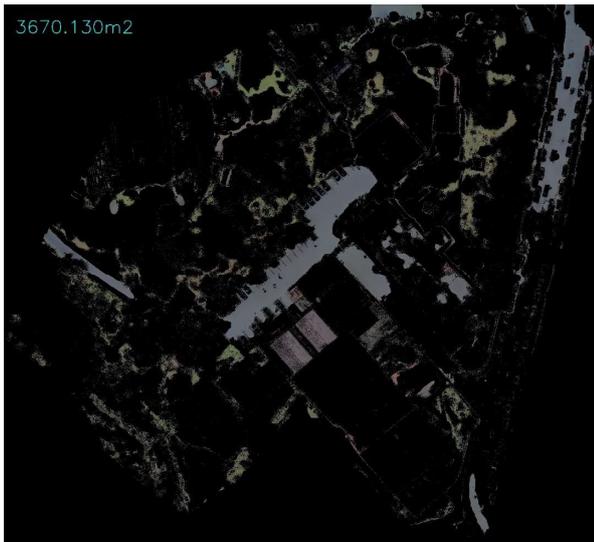
h) Mascara RGB [118.55, 117.16, 114.22].



k) Mascara RGB [59.76, 66.24, 46.56].



i) Mascara RGB [81.63, 87.32, 66.40].



j) Mascara RGB [99.84, 102.06, 97.71].

Fig. 25 Mascaras de la segmentación del espacio de color RGB para la ortofotografía de 10 cm/pixel

El dimensionamiento obtenido para las imágenes de la Fig. 25 se muestra en la TABLA IV.

TABLA IV. DIMENSIONES DEL LAS MÁSCARAS EN RGB

RGB	Dimensión (m ²)
[66.25, 95.86, 159.32]	221.94
[220.86, 227.14, 231.21]	516.35
[184.93, 191.12, 194.56]	1164.46
[160.49, 160.38, 161.03]	1514.98
[157.45, 107.42, 107.73]	2028.77
[137.44, 136.05, 135.21]	2662.22
[37.78, 43.10, 28.94]	2669.1
[118.55, 117.16, 114.22]	3190.78
[81.63, 87.32, 66.40]	3503.69
[99.84, 102.06, 97.71]	3670.13
[59.76, 66.24, 46.56]	3973.83

Una variable muy importante es el tiempo que el algoritmo tarda en realizar todo el dimensionamiento, desde el ajuste de una submuestra de datos hasta obtener el dimensionamiento. En las TABLAS V y VI se presenta el tiempo de ejecución del algoritmo, mediante máscaras y simples bucles respectivamente, este tiempo es la suma de los diferentes subprocessos existentes a lo largo de todo el algoritmo.

TABLA V. TIEMPOS DE EJECUCIÓN MEDIANTE MÁSCARAS Y ESPACIOS DE COLOR HSV

Cm/ pixel	Tiempos de ejecución (s)				total
	<i>t</i> Ajuste	<i>t</i> Etiquetado	<i>t</i> Recons.	<i>t</i> Dimen.	
1.78	82,713	22,542	116,397	103,809	325,461
10	3,313	0,729	2,827	2,717	9,586

TABLA VI. TIEMPOS DE EJECUCIÓN MEDIANTE BUCLES Y ESPACIOS DE COLOR HSV

Cm/ píxel	Tiempos de ejecución (s)				
	<i>t</i>	<i>t</i>	<i>t</i>	<i>t</i>	total
	<i>Ajuste</i>	<i>Etiquetado</i>	<i>Recons.</i>	<i>Dimen.</i>	
1.78	92,739	19,683	110,721	3665,639	3888,782
10	2,115	0,603	2,935	123,534	129,187

De igual manera en las TABLAS VII y VIII se almacena los tiempos de ejecución del algoritmo tanto para el espacio de color RGB y HSV.

TABLA VII. TIEMPOS DE EJECUCIÓN MEDIANTE MÁSCARAS Y ESPACIOS DE COLOR RGB

Cm/ píxel	Tiempos de ejecución (s)				
	<i>t</i>	<i>t</i>	<i>t</i>	<i>t</i>	total
	<i>Ajuste</i>	<i>Etiquetado</i>	<i>Recons.</i>	<i>Dimen.</i>	
1.78	85,385	18,965	265,753	62,127	432,23
10	5,546	0,729	2,91	2,816	12,001

TABLA VIII. TIEMPOS DE EJECUCIÓN MEDIANTE BUCLES Y ESPACIOS DE COLOR RGB

Cm/ píxel	Tiempos de ejecución (s)				
	<i>t</i>	<i>t</i>	<i>t</i>	<i>t</i>	total
	<i>Ajuste</i>	<i>Etiquetado</i>	<i>Recons.</i>	<i>Dimen.</i>	
1.78	93,739	19,693	110,721	3665,659	3889,812
10	2,115	0,603	2,935	123,623	129,276

La TABLA IX muestra el valor de los índices obtenidos al utilizar el criterio de *Calinski-Harabasz* (CHI), cabe señalar que la agrupación más óptima será la que tiene como resultado un índice más elevado.

TABLA IX. VALORES DE ÍNDICE DE AGRUPAMIENTOS OBTENIDOS UTILIZANDO K-MEANS PARA LA ORTOFOTOGRAFIA

Cm/ píxel	Índice de Calinski-Harabasz	
	HSV	RGB
1.78	17847,223	10090,756
10	52981,274	29955,421

En la TABLA X se muestra el resultado de agrupación del usuario de los tonos verdes para obtener el dimensionamiento total de dicha área.

TABLA X. COMPARACIONES DE DIMENSIONES Y TIEMPOS DE EJECUCION DEL ALGORITMO

color	Cm/ píxel	Dimensionamiento con máscaras			
		HSV		RGB	
		<i>Dimensión</i>	<i>tiempo</i>	<i>Dimensión</i>	<i>tiempo</i>
Verde	1.78	10549.79	325,461	8538.22	432,23
	10	11679.07	9,586	10146.62	12,001

Para calcular los errores se tomó como medida real la obtenida mediante aproximaciones de polígonos tal como se observa en la Fig. 26, dando como resultado un área para los espacios verdes de 10558.4 m².



Fig. 26 Aproximación de áreas mediante polígonos.

V. CONCLUSIONES

Se realizó un análisis de las TABLAS I, II, III, IV, en las que se observa que los valores de los centroides cambian ya que, al cambiar la resolución espacial de la imagen, también se modifica la cantidad de información (colores) que tiene un determinado píxel. El valor de los centroides también se modificará por el cambio de los espacios de color, al ser el espacio de color HSV una transformación no lineal del espacio de color RGB.

Como consecuencia del análisis de los datos expuestos en las TABLAS V, VI, VII, VIII se determinó que utilizar métodos de programación básicos como son los condicionales y bucles para el conteo de los píxeles resulta ineficiente, ya que el tiempo de ejecución del algoritmo incrementa en un 1300% en comparación con el método de máscaras (imágenes binarias).

El tiempo entre realizar el clustering entre RGB y HSV es muy similar, sin embargo, no se puede decir lo mismo de las dimensiones obtenidas de éstos dos, por lo que se realiza una interpretación de los valores mostrados en la TABLA IX, los cuales indican que el espacio de color HSV tiene agrupaciones más óptimas, ya que el CHI obtenido es mucho mayor en comparación con el del espacio de color RGB.

Al comparar los valores de dimensionamiento mostrados en la TABLA X con el valor obtenido mediante el software "*agisoft photoscan*", se determina que el error es de 0.08% para la imagen que tiene una resolución espacial de 1.78 cm/píxel, y de 10.61% si la resolución espacial es de 10cm/píxel, por lo que el error es directamente proporcional a la resolución espacial de la ortofotografía.

El resultado de ésta investigación es una herramienta para que los estudios en diferentes áreas del conocimiento de la Ingeniería Civil sean más eficiente y rápida y poder estimar dimensiones que muchas de las veces son demasiado complicadas de realizarlas.

VII. AGRADECIMIENTOS

Este trabajo fue desarrollado como parte del proyecto de investigación (Sistema de Reconocimiento de Patrones sobre suelos UDA 2017-153), programa de la Escuela de Ingeniería Electrónica de la Universidad del Azuay.

VIII. REFERENCIAS

- [1] C. Lear, «Digital orthophotography: mapping with pictures,» *IEEE Computer Graphics and Applications*, vol. 17, n° 5, pp. 12-14, 1997.
- [2] A. Serrano, Inteligencia Artificial. Fundamentos, práctica y aplicaciones, Madrid: Grupo RC, 2012.
- [3] L. Jing, W. Junzheng y M. Jiali, «Color moving object detection method based on automatic color clustering,» *Proceedings of the 33rd Chinese Control Conference*, pp. 7232-7235, 2014.
- [4] V. Dehariya, S. Shrivastava y R. Jain, «Clustering of Image Data Set Using K-Means and Fuzzy K-Means Algorithms,» *2010 International Conference on Computational Intelligence and Communication Networks*, pp. 386-391, 2010.
- [5] L. Alireza y M.-S. Mohammad Ali, «Aerial Target Detection and Tracking in Infrared Image Sequences by using Morphological Operations, Kalman Filtering and Elliptical Representation,» *Iranian Conference on Electrical Engineering (ICEE)*, pp. 1841-1847, 2016.
- [6] L. Guamán, C. Cordova y P. Quezada, «Detección de objetos en movimiento a través de la umbralización del color,» *2017 12th Iberian Conference on Information Systems and Technologies (CISTI)*, pp. 1-6, 2017.
- [7] A. Tatavarti, J. Papadakis y A. Willis, «Towards Real-Time Segmentation of 3D Point Cloud Data into Local Planar Regions,» *SoutheastCon 2017*, pp. 1-6, 2017.
- [8] P. A. Hébert y L. Macaire, «Spatial-color pixel classification by spectral clustering for color image segmentation,» *2008 3rd International Conference on Information and Communication Technologies: From Theory to Applications*, pp. 1-5, 2008.
- [9] L. F. Felizardo, R. L. Mota, E. H. Shiguemori, M. T. Neves, A. C. Ramos y F. A. Mora, «Using ANN and UAV for Terrain Surveillance : A Case Study for Urban Areas Observation,» *2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013)*, vol. 13th International Conference on Hybrid Intelligent Systems, pp. 516-520, Diciembre 2013.
- [10] A. Konstantaras, J. Kilty y E. Maravelakis, «Coalescing terrestrial laser scanning and aerial orthophotography for urban 3D modelling,» *2015 6th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pp. 1-5, 2015.
- [11] Agisoft LLC, «Agisoft,» 2018. [En línea]. Available: <http://www.agisoft.com/>.
- [12] D. Hoiem, «Image Stitching,» *University of Illinois*, pp. 1-5, 2011.
- [13] H. Moravec, «The Stanford Cart and the CMU Rover,» *Proceedings of the IEEE*, pp. 872-884, 1983.
- [14] R. Szeliski, «Image Alignment and Stitching,» *Foundations and Trends in Computer Graphics and Vision*, pp. 43-61, 2006.
- [15] C. Feichtenhofe y A. Pinz, «Spatio-temporal Good Features to Track,» *2013 IEEE International Conference on Computer Vision Workshops*, pp. 246-253, 2013.
- [16] M. Brown, R. Szeliski y S. Winder, «Multi-image matching using multi-scale oriented patches,» *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, pp. 510-217, 2005.
- [17] P. Arabie, L. Hubert y G. De Soete, «Clustering and Classification,» *World Scientific*, 1998.
- [18] S. Agarwal, S. Yadav y K. Singh, «K-means versus k-means ++ clustering technique,» *2012 Students Conference on Engineering and Systems*, pp. 1-6, 2012.
- [19] W. Day y H. Edelsbrunner, «Efficient algorithms for agglomerative clustering methods,» *Journal of classification*, pp. 7-24, 1984.
- [20] E. Alegre, G. Pajares y A. de la Escalera, Conceptos y Métodos en Visión por Computador, España: Comité Español de Automática (CEA), 2016, p. 169.
- [21] S. Patil, U. Bhangale y N. More, «Comparative study of color iris recognition: DCT vs. vector quantization approaches in rgb and hsv color spaces,» *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 1600-1603, 2017.
- [22] P. Ganesan y V. Rajini, «Assessment of satellite image segmentation in RGB and HSV color space using image quality measures,» *2014 International Conference on Advances in Electrical Engineering (ICAEE)*, pp. 1-5, 2014.
- [23] S. Łukasik, P. Kowalski, M. Charytanowicz y P. Kulczycki, «Clustering using flower pollination algorithm and Calinski-Harabasz index,» *2016 IEEE Congress on Evolutionary Computation (CEC)*, pp. 2724-2728, 2016.
- [24] G. Kumar, P. Sarthi, P. Ranjan y R. Rajesh, «Performance of k-means based satellite image clustering in RGB and HSV color space,» *2016 International Conference on Recent Trends in Information Technology (ICRTIT)*, 2016|1-5.
- [25] L. Ochoa y F. Utray, Guía 4K 709, Madrid: 709 MediaRoom Grafismo y diseño de portada, 2015.
- [26] OpenCV team, «OpenCV,» [En línea]. Available: <https://opencv.org/>. [Último acceso: 30 11 2018].
- [27] S. Domínguez, «Análisis de imágenes mediante el método de los momentos usando funciones de base continuas a intervalos (PCBF),» *Revista Iberoamericana de Automática e Informática industrial*, vol. 12, pp. 69-78, 2015.
- [28] L. Hernández, E. Rodríguez, A. Martínez, H. Álvarez y S. Kharuf, «LEVANTAMIENTO FOTOGRAMETRICO DE LA UBPC "DESEMBARCO DEL GRANMA" UTILIZANDO AVIONES NO TRIPULADOS, SOLUCIÓN DE BAJO COSTO PARA LA AGRICULTURA NACIONAL,» *VII Edición de la Conferencia Científica Internacional sobre Desarrollo Agropecuario y Sostenibilidad*, pp. 1-14, 2016.