



**UNIVERSIDAD
DE ANTIOQUIA**

**ANÁLISIS DE DISTINTOS TIPOS DE COBERTURAS MEDIANTE
EL USO DE IMÁGENES DE CÁMARA MULTIESPECTRAL
TOMADAS DESDE DRON EN EL VALLE DE ABURRÁ**

Autor:

José Alejandro Lozano Arias

Universidad de Antioquia
Facultad de Ingeniería, Escuela Ambiental
Medellín, Colombia
2021



Análisis de distintos tipos de coberturas mediante el uso de cámara multiespectral tomadas desde dron en el Valle de Aburrá

José Alejandro Lozano Arias

Trabajo de grado presentado como requisito parcial para optar al título de:
Ingeniero Ambiental

Asesoras:

Ángela María Rendón Pérez
Doctora en Ingeniería Ambiental

Gisel Guzmán Echavarría
Magíster en Recursos Hidráulicos

Universidad de Antioquia
Facultad de Ingeniería, Escuela Ambiental.
Medellín, Colombia
2021

Agradecimientos

A mis padres, que aunque ya no estén físicamente a mi lado, su amor, paciencia, comprensión y enseñanzas permanecen siempre conmigo.

A mis asesoras Ángela Rendón y Gisel Guzmán, por todo el tiempo dedicado y su apoyo incondicional para aclarar cualquier tipo de duda que iba surgiendo en el camino y fomentar mi espíritu investigativo. Gracias por su paciencia.

A SIATA por brindarme todos los medios para realizar este Trabajo de Grado. Al equipo de Teledetección con Drones, a Julián Urán que me sugirió la idea de esta investigación. A Lina Ceballos y Alejandra Ochoa por estar siempre pendientes y brindarme constante retroalimentación.

A mis compañeros del equipo operacional, especialmente a Valentina, Monica y a Los Capos (Óscar, Juan Diego, Santiago, Dubán y Andrés) que siempre me escucharon, apoyaron y mostraron interés en conocer lo que estaba trabajando.

A la Universidad de Antioquia, por ser mi alma máter.

A la vida, por todo.

Resumen

El uso de la teledetección, cada vez más común para el análisis y la gestión de los recursos naturales, aún está condicionado, entre varias cosas, a la resolución espacial, espectral y temporal de los datos disponibles. Sin embargo, con la incorporación al mundo civil de los Vehículos Aéreos No Tripulados (VANT) -más conocidos como drones- y el desarrollo continuo de microsensores, se ha abierto la puerta a nuevos avances en esta rama de las ciencias ambientales.

Una de las funciones más importantes en la teledetección es la elaboración de mapas de uso y cobertura del suelo, productos que normalmente se crean mediante un proceso denominado clasificación de imágenes.

En el presente Trabajo de Grado se evalúa y analiza el desempeño en la identificación de coberturas terrestres a partir de datos de la cámara multiespectral ALTUM de la empresa Micasense, originalmente pensada para labores de agricultura de precisión. Los datos empleados fueron tomados en zonas urbanas y periurbanas del Valle de Aburrá, y proporcionados por el proyecto de ciencia y tecnología del Área Metropolitana del Valle de Aburrá, el Departamento Administrativo de Gestión del Riesgo de Desastres DAGRD y la alcaldía de Medellín, SIATA -Sistema de Alerta Temprana de Medellín y el Valle de Aburrá-

En una primera fase de acercamiento a los datos, se identificaron las coberturas de las clases más comunes en las imágenes -y que posteriormente serviría para definir la clases en la clasificación supervisada- y de estas se trazaron polígonos de entrenamiento; luego se encontró el valor de la reflectancia en las cinco bandas espectrales que maneja el sensor ALTUM y ya con este insumo como entrada se desarrolló un algoritmo de clasificación basado en umbrales. Dicho algoritmo es altamente susceptible a ser mejorado, incorporando la firma espectral de más elementos y revisando con mayor agudeza los umbrales establecidos con el fin de disminuir las falsas alarmas o las no detecciones.

En una segunda parte del trabajo, se evaluó el desempeño de la clasificación de coberturas presentes en una imagen utilizando los métodos supervisados y no supervisados más comunes y referenciados en la literatura. En el caso de los métodos supervisados, se escogieron los métodos de Máxima Verosimilitud Gaussiana, Bosques Aleatorios o Random Forest y K-Vecinos más cercanos, implementados a través de complementos del software QGIS.

Los métodos de clasificación no supervisados, ISODATA y K-Means, incluidos en el software SAGA, también fueron probados y analizados. El resultado final de las clasificaciones supervisadas y no supervisadas se evaluaron en conjunto obteniendo como producto un cuadro comparativo, con las bondades de cada método en cuanto a los resultados obtenidos, el cual servirá de insumo para análisis posteriores.

Finalmente se abordó, a modo de discusión y de planteamiento de trabajos futuros, las implicaciones que tienen en términos de planificación, meteorología urbana y modelación ambiental, una caracterización detallada de la superficie lograda a partir de teledetección con sensores multiespectrales de alta resolución.

Tabla de contenido

1. Introducción	1
2. Objetivos	2
2.1 Objetivo general	2
2.2 Objetivos específicos	2
3. Marco teórico	3
4. Metodología	14
4.1 Manejo y tratamiento de datos	14
4.1.1 Toma de datos	14
4.1.2 Procesamiento de datos	15
4.1.3 Post-procesamiento de los datos	15
4.1.4 Área de estudio y datos empleados	16
4.2 Clasificación supervisada	17
4.2.1 Obtención de la firma espectral de los elementos más comunes presentes en las imágenes.	17
4.2.2 Clasificación supervisada basada en algoritmo por umbrales	19
4.2.3 Clasificación Supervisada basada en los métodos de clasificador de Máxima Verosimilitud Gaussiana, Random Forest y K-Vecinos más cercanos.	25
4.3 Clasificación no supervisada	30
5. Resultados y análisis	33
5.1 Firma espectral de los elementos más comunes presentes en las imágenes	33
5.2 Clasificación supervisada basada en algoritmo por umbrales	36
5.2.1 Unidad Deportiva Atanasio Girardot	37
5.2.2 Institución Educativa CASD	38
5.2.3 Jardín Botánico Joaquín Antonio Uribe	39
5.3 Clasificación Supervisada basada en los métodos de clasificador de Máxima Verosimilitud Gaussiana, Random Forest y K-Vecinos más cercanos.	40
5.3.1 Institución Educativa CASD	40
5.3.2 Jardín Botánico Joaquín Antonio Uribe	44
5.3.3 Unidad Deportiva Atanasio Girardot	48
5.3.4 Barrio Tricentenario	51
5.4 Clasificación No Supervisada basada en los métodos de ISODATA clustering y K-Means Clustering	55
5.4.1 Institución Educativa CASD	55
5.4.2 Jardín Botánico Joaquín Antonio Uribe	57
5.4.3 Unidad Deportiva Atanasio Girardot	60
5.4.4 Barrio Tricentenario	61
Discusión	59
Conclusiones y trabajos futuros	65
Referencias	66

Lista de Figuras

Figura 1. Relación de bandas capturadas del Espectro Electromagnético tomado con cámara digital, cámara multispectral y cámara hiperespectral, las cuales pueden ser montadas a un dron para captura de datos. Fuente: equipo Teledetección con Drones SIATA	5
Figura 2. Izquierda: Cámara multispectral ALTUM, Derecha: Cámara multispectral ALTUM adaptada al dron. En la parte de arriba del dron se adapta el sensor DSL de irradiancia. Modificado a partir de (Hutton et al., 2020)	7
Figura 3. Funciones de densidad de probabilidad definidas por un clasificador de Máxima Verosimilitud Gaussiana. Los valores de A, B y C hacen referencia a superficies, por ejemplo, cuerpos de agua, vegetación y asfalto. Modificado a partir de (Gopinath & Heights, 1997)	10
Figura 4. División de set de datos en varios sub-sets de datos, distribuidos en Árboles de decisión. Modificado a partir de (Vasilakos et al., 2020)	11
Figura 5. Resultado de la clasificación supervisada después de aplicar la Regla de la mayoría a los Árboles de decisión. Modificado a partir de (Vasilakos et al., 2020).	12
Figura 6. Clasificación con el método de K-NN. En el punto de consulta del círculo, según el valor k de 1, 5 o 10, el punto de consulta puede ser un rectángulo en (a), un diamante en (b) o un triángulo en (c). Modificado a partir de (Kim et al., 2012).	13
Figura 7. Izquierda: mapa de Medellín con la ubicación de los sitios donde se hizo captura de datos con cámara ALTUM y que se usaron en este trabajo. Derecha: imágenes RGB de los sobrevuelos utilizados en este estudio. Fuente: equipo Teledetección con Drones SIATA	17
Figura 8. Ejemplo de superficies escogidas en IECASD para posterior clasificación.....	18
Figura 9. Polígonos de entrenamiento trazados en QGIS sobre las superficies escogidas en IECASD.	18
Figura 10. Firmas espectrales obtenidas trazando polígonos en las canchas de la UDAG. Las que tienen mayor porcentaje de reflectancia en la banda del rojo de borde y el NIR corresponden a pasto natural y las de menor reflectancia a pasto sintético.	19
Figura 11. Firma espectral de pastos y árboles (vegetación) obtenida en la Institución Educativa CASD y el Jardín Botánico Joaquín Antonio Uribe.	19
Figura 12. Firma espectral de concreto obtenida en la Institución Educativa CASD.....	20
Figura 13. Firma espectral de asfalto obtenidas en la Institución Educativa CASD y en la Unidad Deportiva Atanasio Girardot.	21
Figura 14. Firma espectral para Ladrillo cerámico o Teja cerámica obtenido en la Institución Educativa CASD.	22
Figura 15. Firma espectral para techo blanco obtenido en la Institución Educativa CASD23	
Figura 16. Firma espectral para canchas de polipropileno o Pasto sintético, obtenida en la Unidad Deportiva Atanasio Girardot.	23
Figura 17. Firma espectral para agua con algas y/o sedimentos, obtenida en el lago del Jardín Botánico Joaquín Antonio Uribe.	24
Figura 18. Firma espectral para el agua de piscinas, obtenida en la Unidad Deportiva Atanasio Girardot.	25
Figura 19. Funcionalidades para construir ráster virtual en QGIS.....	26
Figura 20. Funcionalidades para editar y construir ráster virtual.....	27
Figura 21. Funcionalidad para crear una Nueva capa de archivo shape.	27

Figura 22. Menú de configuración para la Nueva capa de archivo shape (tipo polígono), que luego será utilizado como capa de entrada para realizar la clasificación.	28
Figura 23. Funcionalidad del plugin Dzetsaka, el círculo azul es el ráster de composición previamente construido, el círculo naranja la capa de los polígonos de entrenamiento y el círculo verde el discretizador que recibirá el modelo.	29
Figura 24. Métodos de clasificación supervisada que se pueden realizar con el plugin Dzetsaka. Nota: el método de Máquinas de Vectores de Soporte (Support Vector Machine) no funcionó.....	29
Figura 25. Menú Simbología. Se escoge como tipo de rasterizador Pseudocolor monobanda, de tal forma que se puedan crear intervalos iguales (para cada una de las clases escogidas) para posteriormente asignarle un color representativo a cada categoría.	30
Figura 26. Funcionalidad para abrir cualquier capa de archivo shape, para este caso se abrirá la composición multispectral creada previamente en QGIS.	30
Figura 27. Ruta en SAGA para realizar clasificaciones no supervisadas. Notar que hay dos opciones: ISODATA clustering y K-Means clustering; ambos se realizaron en este Trabajo de Grado.	31
Figura 28. Cuadro de diálogo para realizar la Clasificación No Supervisada por el método ISODATA.	31
Figura 29. Cuadro de diálogo para realizar la Clasificación No Supervisada por el método de K-Means.	32
Figura 30. Firmas espectrales de las coberturas más comunes identificadas en los vuelos, obtenidas a partir de polígonos de entrenamiento.	34
Figura 31. Firmas espectrales teóricas del concreto, el asfalto y el techo de teja cerámico. Modificado a partir de (Kotthaus et al., 2014).	36
Figura 32. Resultado de la clasificación por umbrales en la Unidad Deportiva Atanasio Girardot. Izquierda: imagen RGB de la Unidad Deportiva Atanasio Girardot. Derecha: resultado de la clasificación por umbrales. Fuente: equipo Teledetección con Drones SIATA	37
Figura 33. Resultado de la clasificación por umbrales en la Institución Educativa CASD. Izquierda: imagen RGB de la Institución Educativa CASD. Derecha: resultado de la clasificación por umbrales. Fuente: equipo Teledetección con Drones SIATA	38
Figura 34. Resultado de la clasificación Jardín Botánico Joaquín Antonio Uribe. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación por umbrales. Fuente: equipo Teledetección con Drones SIATA	39
Figura 35. Matriz apilada sobrevuelo, Institución Educativa CASD.....	40
Figura 36. Resultado de la clasificación de IECASD utilizando el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB de la Institución Educativa CASD. Derecha: resultado de la clasificación.	41
Figura 37. Resultado de la clasificación de IECASD utilizando el método de Random Forest. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.....	42
Figura 38. Resultado de la clasificación de IECASD utilizando el método de K-Vecinos más cercanos. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.....	43
Figura 39. Matriz apilada sobrevuelo Jardín Botánico Joaquín Antonio Uribe.....	44
Figura 40. Resultado de la clasificación del Jardín botánico utilizando el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.	45

Figura 41. Resultado de clasificación del Jardín Botánico utilizando el método de Random Forest. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.	46
Figura 42. Resultado de clasificación del Jardín Botánico utilizando el método de K-Vecinos más cercanos. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.	47
Figura 43. Matriz apilada sobrevuelo UDAG.	48
Figura 44. Resultado de la clasificación de la UDAG con el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB de la UDAG. Derecha: resultado de la clasificación.	49
Figura 45. Resultad de la clasificación de la UDAG con el método de K-Vecinos más cercanos. Izquierda: imagen RGB de la UDAG. Derecha: resultado de la clasificación. ...	50
Figura 46. Matriz apilada del sobrevuelo barrio Tricentenario.	51
Figura 47. Resultado de la clasificación del barrio Tricentenario con el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.	52
Figura 48. Resultado de la clasificación del barrio Tricentenario con el método de "Random Forest" o Bosques aleatorios. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.	53
Figura 49. Resultados de la clasificación del barrio Tricentenario con el método de K-Vecinos más cercanos. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.	54
Figura 50. Resultado de la clasificación de la IECASD con el método ISODATA. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.	55
Figura 51. Resultado de la clasificación de la IECASD con el método K-Means. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.	56
Figura 52. Resultado de la clasificación del Jardín Botánico con el método ISODATA. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.	57
Figura 53. Resultado de la clasificación del Jardín botánico con el método K-Means. Izquierda: imagen RGB del Jardín botánico. Derecha: resultado de la clasificación.	59
Figura 54. Resultado de la clasificación del barrio Tricentenario con el método ISODATA. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.	61
Figura 55. Resultado de la clasificación del barrio Tricentenario con el método k-Means. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.	62
Figura 56. Aerofotografía y Modelo de Elevación Digital obtenido desde cámara adaptada a un dron, sector La Harenala, Itagüí. Material proporcionado por el equipo de Hidrología de SIATA.	62
Figura 57. Polígonos trazados de superficies para ingresar al modelo de inundación. Sector La Harenala, Itagüí. Material proporcionado por el equipo de Hidrología de SIATA.	63
Figura 58. Mancha de inundación de un tramo de la Quebrada La Harenala, Itagüí. Material proporcionado por el equipo de Hidrología de SIATA.	64

Lista de Tablas

Tabla 1. Atributos de los datos usados en este estudio.	16
Tabla 2. Resumen de los resultados obtenidos con los métodos de clasificación supervisados y no supervisados utilizados en este estudio.	58

1. Introducción

En las últimas décadas, los sistemas de observación geográfica se han convertido en una valiosa y poderosa herramienta para monitorear la tierra y han tenido un impacto significativo en la adquisición y el análisis de datos ambientales (Rosenqvist et al., 2003). En la actualidad, los datos de observación terrestre desempeñan un papel importante en el apoyo a la toma de decisiones y el control del cumplimiento de varios tratados medioambientales multilaterales, como el Protocolo de Kioto, el Convenio sobre la Diversidad Biológica o la iniciativa europea de Vigilancia Mundial del Medio Ambiente y la Seguridad (GMES) (Rosenqvist et al., 2003), o en otros más recientes como el Acuerdo de París o el Acuerdo de Escazú (Actalianza, 2018). A escala local, los datos de observación terrestre son útiles en procesos de planificación urbana y en la gestión del riesgo en diversos campos como meteorología, geotecnia, hidrología, entre otros (Cheng & Byun, 2008).

La evolución de las tecnologías de observación de la tierra, junto con los requisitos y normas derivados de su uso, exigen algoritmos cada vez más hábiles, especialmente en el ámbito de la clasificación de la cobertura terrestre. En el contexto de las políticas internacionales y los problemas del cambio global, las clasificaciones de la cobertura terrestre son uno de los productos de observación de la tierra más utilizados y el desarrollo de métodos de clasificación adecuados es un campo de investigación aún en auge.

La precisión de los resultados de la clasificación de los datos y la sensibilidad en estos ante el uso de diferentes algoritmos tienen una importancia crítica en la comunidad científica, ya que las imágenes clasificadas proporcionan información base para muchas aplicaciones y modelos (Ustuner et al., 2015). La disponibilidad de imágenes con resolución submétrica, que poseen algunos sensores satelitales o cámaras multispectrales adaptables a drones como la cámara ALTUM de Micasense, brindan nuevas oportunidades para el mapeo detallado de la cobertura del suelo urbano a nivel de objeto (Zhao et al., 2017). La información detallada sobre la cobertura del suelo no solo es esencial para comprender los cambios del entorno, sino también para ayudar a los gobiernos a tomar decisiones sobre la gestión, expansión y planificación urbana (Lynch et al., 2020; Qian et al., 2020; Xu et al., 2019).

La mayoría de las investigaciones sobre clasificación de la cobertura y el uso del suelo se basan tradicionalmente en imágenes de baja y media resolución, como MODIS (Nguyen et al., 2020; Sulla-Menashe et al., 2019; Xu et al., 2019), Landsat (Zeferino et al., 2020) y SPOT1/4 (Colkesen & Kavzoglu, 2017). Sin embargo, la cobertura de la superficie urbana presenta una heterogeneidad de alta frecuencia, lo que da lugar a un gran número de píxeles mezclados en las imágenes de media y baja resolución. Con el rápido desarrollo de la tecnología de sensores, es cada vez más común acceder a un gran número de imágenes de alta resolución obtenidas por teledetección (IKONOS, Quickbird, GeoEye-1, WorldView-1-4, GF-1/2, etc.) (Benediktsson et al., 2013) lo que permite que se compensen las deficiencias de la mezcla de píxeles en las imágenes de baja y media resolución en la clasificación de la cobertura del suelo urbano (Momeni et al., 2016). Con imágenes cuya resolución espacial

sea igual o superior a 4 metros, es posible realizar la cartografía de la compleja superficie urbana.

La cámara multiespectral ALTUM fue desarrollada por la empresa Micasense principalmente para apoyar labores de agricultura de precisión (Hutton et al., 2020). En este trabajo de investigación se quiso sacar provecho de la resolución de 50 cm, en escenas previamente procesadas a reflectancia con un área de extensión máxima de 50 hectáreas, para analizar la respuesta de los algoritmos de clasificación supervisados y no supervisados más usados en la práctica. Para este propósito se utilizaron imágenes de referencia tomadas en distintos sitios urbanos y periurbanos del Valle de Aburrá y se realizaron varios procesos de clasificación supervisada (clasificación por umbrales, Máxima Verosimilitud Gaussiana, Bosques Aleatorios o Random Forest y K-Vecinos más cercanos) y no supervisada (ISODATA, K-Means). Se propendió el uso de imágenes donde se distinguieran distintos tipos de cobertura en superficie comunes en la región, con el fin de evaluar la mayor cantidad de desempeños por categoría posibles.

El trabajo de investigación se organizó así: en la sección 2 se muestra el objetivo general y los objetivos específicos que se propusieron para la investigación. El marco y los detalles de la estrategia metodológica propuesta, basada en los métodos de clasificación más comunes en la literatura y en la utilización de software de información geográfica, se presentan en las secciones 3 y 4. Los resultados se muestran en la sección 5. En la sección 6 se hace una discusión de los resultados obtenidos y se proponen alcances, en términos de meteorología urbana, planificación y modelación ambiental y, por último, en la sección 7 se exponen las conclusiones y trabajos futuros.

2. Objetivos

2.1 Objetivo general

Identificar y clasificar distintos tipos de coberturas de la superficie en el Valle de Aburrá, mediante el análisis de imágenes obtenidas a partir del procesamiento de datos de una cámara multiespectral de alta resolución.

2.2 Objetivos específicos

- Delimitar las magnitudes y la variación espacial de la reflectancia en diferentes bandas espectrales con el fin de identificar comportamientos distintivos por tipo de cobertura o material.
- Implementar algoritmos de clasificación de distintos tipos de coberturas según la firma espectral de los materiales de interés.
- Evaluar los resultados de los algoritmos propuestos respecto a su precisión para clasificar las coberturas usando información real de la superficie.

- Analizar los resultados de las coberturas obtenidas y su efecto en aspectos de meteorología urbana en el Valle de Aburrá.
- Discutir acerca de la importancia de la caracterización detallada de la superficie en estudios futuros de planificación y de meteorología urbana.

3. Marco teórico

La teledetección, es la traducción al español de la expresión inglesa *Remote Sensing*, que comenzó a usarse a principios de la década de 1960 para designar “cualquier método de observación remota de la superficie terrestre” (Pérez & Muñoz, 2006). Luego, la Organización de las Naciones Unidas extendió su significado a “(...) la detección de la superficie terrestre desde el espacio mediante el uso de las propiedades de las ondas electromagnéticas emitidas, reflejadas o difractadas por los objetos detectados, para el propósito de mejorar el manejo de los recursos naturales, el uso del terreno y la protección del ambiente” (Castillo, 2014).

La teledetección basa su funcionamiento en la disposición de una fuente de energía, que habitualmente es el sol. Los rayos solares son reflejados con diferente intensidad, según las características de la superficie terrestre. La radiación reflejada es detectada por un sensor y en el caso de datos satelitales, este transmite dicha información a una estación receptora, donde se reciben y procesan posteriormente estos datos en un soporte digital. En el caso de datos tomados por sensores adaptados a drones, en su mayoría estos se extraen en tierra directamente del sensor, y son procesados en computadores de diferentes características. Es en este punto donde comienza la interpretación de imágenes que puede ser visual o digital, destinada a facilitar información de interés para los usuarios (Parody & Zapata, 2018). El flujo de energía aprovechado en aplicaciones de teledetección, además de ser sólo reflejado, también puede ser emitido directamente por la superficie terrestre en función de su temperatura -como es el caso de los sensores térmicos-. Los sensores que miden energía reflejada o emitida por la superficie son sensores pasivos, y conforman gran parte de los sensores multispectrales, los cuales son sujeto en esta investigación. También está el caso en el que el sensor tiene una fuente de emisión de energía -como los radares-, denominándose en este caso, sensores activos. Los sensores captan estas señales mediante un barrido electrónico, esto permite generar una retícula cuadrada donde cada una de las celdas de esta retícula se denomina pixel y corresponde a una superficie equivalente a la resolución espacial del sensor (Pérez & Muñoz, 2006). En el caso de los sensores multispectrales las imágenes contienen tantos valores numéricos por pixel como bandas del espectro electromagnético detectadas. En definitiva, de la misma zona se detectan varios intervalos de longitudes de onda, lo que permite seguir distintos fenómenos de interés (Yuste Martín et al., 2013).

La interpretación de la fotografía aérea ha sido usada como una herramienta práctica en teledetección desde hace casi un siglo. Por su parte, desde finales de 1990s, nuevas aplicaciones continuaron su desarrollo e implementación y como resultado, los sensores remotos se han convertido en una herramienta esencial en muchos aspectos de la ciencia, el gobierno, los negocios y la industria privada (Zeferino et al., 2020). Además, otro factor

que ha contribuido a la creciente aceptación de las imágenes de teledetección por parte de los usuarios finales ha sido el desarrollo y la adopción generalizada de sistemas de geovisualización fáciles de usar, como Google Maps, Google Earth, Nullschool, Windy y otros servicios de imágenes basados en la web (Congalton, 2015)

La teledetección puede hacerse a través del uso de muchos tipos de instrumentos, los cuales varían en su complejidad. Los más antiguos son la fotografía y el video aéreo con cámaras convencionales, los cuales tuvieron amplia difusión el siglo pasado.

Los satélites son otra herramienta de teledetección que ha tomado protagonismo, principalmente en el siglo XXI, aunque gran parte de la tecnología actual de teledetección por satélite procede directa o indirectamente del programa Landsat, iniciado en 1967 siendo la primera actividad formal de investigación y desarrollo civil destinada a utilizar los satélites para vigilar los recursos terrestres a nivel mundial (Congalton, 2015).

Los sensores multiespectrales normalmente operan dentro del espectro electromagnético entre los 0.3 μm y 14 μm . Este rango incluye las longitudes de onda del ultravioleta, el infrarrojo cercano, el medio y el térmico. También hay sensores que miden en la porción microondas del espectro (aproximadamente 1mm a 1m de longitud de onda). Las imágenes térmicas pueden considerarse como un tipo particular de imagen multiespectral que consiste en datos adquiridos sólo en la parte térmica del espectro (en una o más bandas) y cuya interpretación debe hacerse teniendo en cuenta los principios básicos de la radiación térmica (Parody & Zapata, 2018).

A nivel de detalle, hay muchas características técnicas de diseño y funcionamiento que pueden diferenciar un sistema de teledetección de otro en términos de idoneidad para una aplicación concreta (Martínez Vega & Martín Isabel, 2010). También hay muchos factores que un posible usuario de datos de teledetección debe tener en cuenta a la hora de seleccionar un sistema concreto para una aplicación determinada y que tienen que ver más con la disponibilidad de los datos que el diseño técnico del propio sistema.

Actualmente, **los satélites** más comunes utilizados en aplicaciones ambientales son (Martínez Vega & Martín Isabel, 2010):

- GOES: perteneciente al programa estadounidense del National Weather Service “NWS” adscrito a la NOAA, permite entre muchas cosas observar la cobertura de nubes del planeta.
- Landsat: observación de la superficie terrestre con una resolución de 30 metros en las bandas del 1 al 5 y de 120 metros en la banda 6 que corresponde a la térmica.
- MODIS: es un instrumento científico lanzado por la NASA. Cuenta con 36 bandas espectrales en longitudes de onda entre 0,4 μm y 14,4 μm . Su resolución espacial es de 250 m en las bandas 1 y 2, 500 m en las bandas de la 3 a la 7 y 1 km en las bandas de la 8 a la 36. Se usa principalmente para entregar medidas en gran escala de la dinámica global, cambio de cobertura de nubes, procesos del océano, atmósfera baja, entre otras cosas.
- Sentinel: es un proyecto de varios satélites desarrollado por la European Space Agency “ESA” en el marco del Programa Copérnico y su objetivo es la vigilancia

terrestre, oceánica y atmosférica de la tierra. Su resolución espacial varía de acuerdo con el satélite, por ejemplo, para el caso de Sentinel 2, este está formado por 13 bandas que operan desde el visible hasta el infrarrojo de onda corta y su resolución oscila entre los 10 m y los 60 m.

Por su parte, **los drones** de alta tecnología y bajo costo han aumentado en los últimos años el potencial operativo disponible para las labores de teledetección (Tang & Shao, 2015). Es importante mencionar que más allá del Vehículo Aéreo No Tripulado -VANT- que se use para el sobrevuelo, lo más importante es la cámara y/o sensor que captura los datos, además del software que los procesa. Las imágenes se crean cuantificando una señal eléctrica analógica, en un proceso conocido como conversión analógico-digital (A-D). La energía electromagnética que entra en el sensor montado al dron, se divide en múltiples bandas espectrales, y cada rango de longitud de onda se dirige a un detector específico. La respuesta eléctrica de cada detector es una señal analógica continua (Tang & Shao, 2015).

La figura 1 muestra el rango del espectro electromagnético que capturan varios de los sensores que pueden ser montados a un dron. Puede tratarse de una cámara digital que capture las longitudes del RGB, una cámara multispectral con datos en el espectro visible y no visible o una cámara hiperespectral conformada por un mayor número de bandas, más continuas entre ellas.

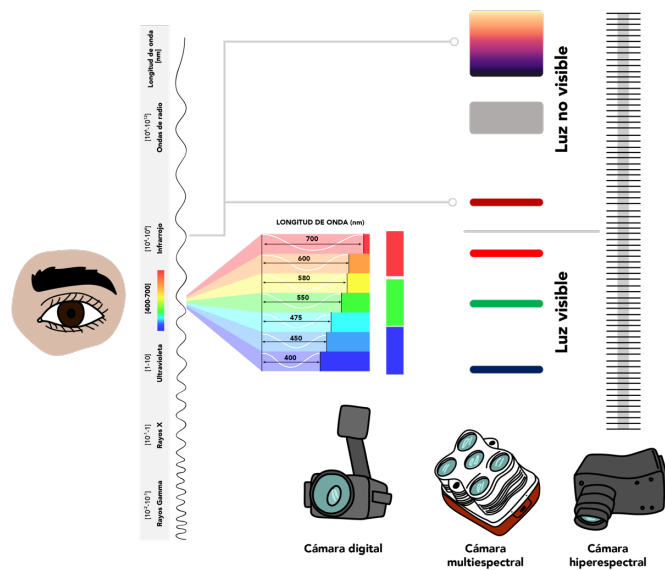


Figura 1. Relación de bandas capturadas del Espectro Electromagnético tomado con cámara digital, cámara multispectral y cámara hiperespectral, las cuales pueden ser montadas a un dron para captura de datos.
Fuente: equipo Teledetección con Drones SIATA

Es importante mencionar que, si no se cuenta con cámaras, sensores y software de procesamiento, los drones son sólo pequeños aviones de control remoto.

Algunos de los sensores que han sido diseñados para ser utilizados en el mercado de la teledetección con los Vehículos Aéreos No Tripulados o drones son (Franzini et al., 2019):

- **Sequoia de Parrot:** Parrot es un fabricante de drones y robots y tiene una cámara multiespectral ligera llamada Sequoia que cuenta con un sensor RGB de 16 megapíxeles, cuatro sensores de 1.2 megapíxeles que adquieren datos en el infrarrojo cercano -NIR-, rojo de borde -Red Edge-, rojo y verde. Además, cuenta con un sensor de luminosidad que mide la cantidad de luz procedente del sol, Sistema Global de Posicionamiento -GPS- y Unidad de Medición Inercial -IMU-. Ha sido pensada para labores de agricultura de precisión y dada su ligereza está diseñada para ser portada en todos los drones de ala fija o multirrotores.
- **MAPIR de Peau Productions:** el fabricante ha desarrollado una serie de cámaras de 12 megapíxeles, como la Survey3, con diferentes lentes que adquieren datos en rangos del espectro: visible (RGB), azul, verde, rojo, infrarrojo cercano (NIR). Igual que la cámara Sequoia, está pensada para labores de agricultura de precisión, especialmente para el cálculo del índice de vegetación NDVI. MAPIR ofrece además monturas para incorporar diferentes combinaciones en el dron, en función de la aplicación en la que se esté interesado.

Sumada a las anteriores, está la cámara multiespectral ALTUM, con la que se tomaron las imágenes insumo de este Trabajo de Grado. Este equipo se monta en un dron y toma valores de radiancia en 6 bandas del espectro electromagnético: azul (centro 475 nm, ancho de banda 32 nm), verde (centro 560 nm, ancho de banda de 27 nm), rojo (centro 668 nm, ancho de banda de 14 nm), rojo de borde (centro 717 nm, ancho de banda de 12 nm) e infrarrojo cercano (centro 842 nm, ancho de banda de 57 nm) y en una banda del infrarrojo térmico de 8-14 μm (Hutton et al., 2020).

Su propósito final es producir imágenes multiespectrales y RGB de alta resolución en un solo vuelo para análisis avanzado. El área máxima de los vuelos que se suele cubrir con este tipo de cámaras y drones multirrotores es hasta de 50 ha, con una resolución de 50 cm (Aldana, 2020; Hutton et al., 2020). Esta cámara cuenta con un sensor de luz para mediciones de irradiancia y ángulo solar para realizar correcciones, GPS y además el fabricante ofrece con la cámara un panel de reflectancia calibrado para poder realizar correcciones de radiancia a reflectancia en softwares comerciales. La siguiente figura muestra la cámara y un ejemplo del dron en el que normalmente es adaptada.



Figura 2. Izquierda: Cámara multispectral ALTUM, Derecha: Cámara multispectral ALTUM adaptada al dron. En la parte de arriba del dron se adapta el sensor DSL de irradiancia. Modificado a partir de (Hutton et al., 2020)

El fabricante del equipo, la empresa MicaSense, concibió la cámara para la agricultura de precisión. Es decir, labores de fenotipado, mapeo de salud de cultivos, gestión del riego, control de fugas, manejo de fertilizantes, identificación de enfermedades, clasificación y conteo de plantas, diferenciación de especies, detección de malezas, monitoreo avanzado de cultivos y modelado de terrenos (Aldana, 2020).

Teniendo en cuenta la presencia del sensor térmico calibrado y de la obtención de imágenes multispectrales y RGB de alta resolución, es posible extender el uso de esta cámara más allá de la agricultura de precisión. Por lo que usada en ambientes urbanos o en zonas de interfaz urbano-forestal, este equipo permite, entre muchas cosas, realizar clasificaciones de distintos tipos de la superficie con la alta resolución de los datos que se derivan de esta.

El objetivo global de los procedimientos de clasificación de imágenes es clasificar automáticamente la mayor cantidad de píxeles que sean posibles de una imagen en clases o temas de cobertura del suelo (Lynch et al., 2020). A menudo esto se hace utilizando patrones espectrales; es decir, los píxeles que comparten combinaciones similares de reflectancia o emisividad espectral se agrupan en clases que representan categorías particulares de características de la superficie. El término reconocimiento de patrones espectrales se refiere a la familia de procedimientos de clasificación que utiliza esta información espectral pixel a pixel como base para la clasificación automatizada de la superficie terrestre. Cada pixel se clasifica, individualmente, basándose en algún modelo estadístico o determinista que utiliza los valores de múltiples capas de datos para ese pixel. No se presta atención a los vecinos o a los alrededores del pixel que se clasifica. Es importante destacar que no existe una única manera “correcta” de abordar un problema de clasificación de imágenes. El enfoque concreto que se adopte dependerá de la naturaleza de los datos que se analicen, de los recursos informáticos disponibles y de la aplicación prevista de los datos clasificados (Congalton, 2015).

Históricamente se han utilizado dos enfoques para realizar la clasificación de imágenes multispectrales: *clasificación supervisada* y *clasificación no supervisada*.

En la Clasificación Supervisada, el analista de imágenes "supervisa" el proceso de categorización de los píxeles, especificando al algoritmo informático, los polígonos de entrenamiento de los distintos tipos de cobertura del suelo presentes en una escena. Para ello, se emplean sitios de muestra representativos de los tipos de cobertura conocidos, denominados *áreas o polígonos de entrenamiento*, los cuales se utilizan para compilar una "clave de interpretación" numérica que describe los atributos espectrales para cada tipo de entidad de interés. Cada píxel del conjunto de datos se compara numéricamente con cada categoría de la clave de interpretación y se etiqueta con el nombre de la categoría que "más se parece". Si el píxel no es suficientemente similar a cualquier conjunto de datos de entrenamiento, normalmente se etiqueta como "desconocido". Después de categorizar todos los píxeles de la imagen de entrada, los resultados se presentan en la etapa de salida. Tres formas típicas de productos de salida son mapas temáticos, tablas de estadísticas para las distintas clases de cobertura terrestre y archivos de datos digitales que pueden ser incluidos en un Sistema de Información Geográfico SIG. En este último caso, el resultado de la clasificación se convierte en la entrada de un "SIG" (Congalton, 2015).

Respecto a la Clasificación No Supervisada, no se utilizan datos de entrenamiento como base para la clasificación. Más bien, esta familia de clasificadores implica algoritmos que examinan los píxeles de una imagen y les asigna o caracteriza en un número de clases basadas en las agrupaciones naturales o clústeres presentes en los valores de imagen. La premisa básica es que los valores dentro de un tipo de cubierta determinado tienden a ser similares en el espacio de medición, de acuerdo a las características de su firma espectral, mientras que los datos en diferentes clases deben estar relativamente bien separados. *Las clases que resultan de la clasificación no supervisada son clases espectrales*. Dado que se basan únicamente en las agrupaciones naturales de los valores de las imágenes de entrada, por lo que la identidad de las clases espectrales no se conocerá inicialmente. El analista debe comparar los datos clasificados con algún tipo de datos de referencia (como imágenes a gran escala o mapas) para determinar la identidad y el valor informativo de las clases arrojadas por el algoritmo. Por lo tanto, en el enfoque supervisado se definen categorías de información útiles y luego se examina su separabilidad espectral; mientras que en el enfoque no supervisado se determinan clases espectralmente separables y luego se define su utilidad informativa (Enderle et al., 2005).

Existen, además, unos procedimientos de clasificación híbrida. Estas técnicas implican aspectos de clasificación supervisada y no supervisada y tienen por objeto mejorar la precisión o la eficiencia (o ambas) del proceso de clasificación (Congalton, 2015).

La mayor parte de los investigadores recurren a técnicas de clasificación supervisada debido a que cuentan con procesos de entrenamiento y aprendizaje antes de la clasificación real de las imágenes; pero también se observa interés en las no supervisadas que no usan datos de entrenamiento porque, dependiendo de la imagen, pueden representar un ahorro de tiempo para el analista, aunque pueda significar un sacrificio en la calidad de la clasificación.

Las técnicas supervisadas más empleadas (Congalton, 2015) y que se discutirán en este trabajo son el Modelo de Máxima Verosimilitud Gaussiana, Bosques aleatorios o Random Forest y K-Vecinos más cercanos.

El Modelo de Máxima Verosimilitud Gaussiana, recibe su nombre porque se basa en la Distribución Normal o Distribución Gaussiana para formular sus reglas de decisión en la categorización de los píxeles. Los parámetros necesarios para el modelo, como la media y la matriz de covarianza se obtienen de los datos de las áreas o polígonos de entrenamiento. Su fundamentación es la siguiente (Gopinath & Heights, 1997):

Se supone que una imagen posee un total de M clases espectrales, las cuales se representarán como:

$$C_i, \quad i = 1, \dots, M$$

Para determinar la clase a la que pertenece un píxel en la posición x , interesa fundamentalmente conocer las probabilidades condicionales:

$$p(C_i|x) \quad i = 1, \dots, M$$

El vector posición x es un vector columna de valores de brillo para el píxel. O sea que describe al píxel como un punto en un espacio multispectral con coordenadas definidas por el brillo. El término $p(C_i|x)$ da la probabilidad de que la clase correcta para un píxel en la posición x sea C_i . Luego, la clasificación se llevará a cabo así:

$$x \in C_i \text{ si } p(C_i|x) > p(C_j|x) \text{ para todo } j \neq i$$

El problema es que los $p(C_i|x)$ en la anterior ecuación son desconocidos. Ahora bien, si se tienen suficientes datos de entrenamiento se puede estimar una distribución de probabilidad $p(x|C_i)$ la cual es la probabilidad de encontrar un píxel de una clase C_i en la posición x . Habrá tantas $p(x|C_i)$ como cubiertas o clases presentes.

Para un píxel en una posición dada en un espacio multispectral existirá un conjunto de probabilidades relativas de que el píxel pertenezca a cada una de dichas clases. Esta probabilidad se puede estimar a partir de los datos de entrenamiento. Se tiene ahora una probabilidad desconocida $p(C_i|x)$ (que es la que interesa) y una conocida $p(x|C_i)$ que se obtiene a partir de los datos de entrenamiento. Ambas probabilidades están relacionadas por el Teorema de Bayes, así:

$$p(C_i|x) = p(x|C_i)p(C_i)/p(x)$$

Donde $p(C_i)$ es la probabilidad de que la clase C_i esté presente en la imagen. En la mayoría de los casos se asume que es la misma para todas las clases. Respecto a $p(x)$ es la probabilidad de encontrar un píxel de cualquiera de las clases en la posición x .

Considerando ahora la forma de la función de distribución de probabilidad $p(x|C_i)$. Asumiendo para dicha función el modelo normal multivariado. Para un caso de N bandas espectrales puede demostrarse que:

$$g_i(x) = -\ln \left| \sum_i i \right| - (x - m_i)^t \sum_i^{-1} (x - m_i)$$

Donde m_i y \sum_i son respectivamente la media y la matriz de covarianza de los datos de la clase C_i

Este clasificador asigna cada pixel desconocido a una clase dada de acuerdo a un criterio Gaussiano de probabilidad.

La figura 3 muestra un sistema multispectral bidimensional (bandas I y bandas II). El eje vertical mide la probabilidad de que un pixel esté contenido en alguna de las clases. Se generarán superficies en campana (Distribución Gaussiana), una para cada clase espectral.




Figura 3. Funciones de densidad de probabilidad definidas por un clasificador de Máxima Verosimilitud Gaussiana. Los valores de A, B y C hacen referencia a superficies, por ejemplo, cuerpos de agua, vegetación y asfalto. Modificado a partir de (Gopinath & Heights, 1997)

Otra técnica de algoritmo de clasificación supervisada es la de **Bosques Aleatorios o Random Forest**, por su nombre en inglés, la cual puede ser utilizada para datos de regresión como de clasificación (Horning, 2010). En este trabajo se utilizará el nombre de Random Forest. Dicha técnica usa la idea de árboles de decisión para construir sistemas de clasificación o regresión, ensamblando varios árboles de decisión. Un árbol de decisión permite establecer una serie de condiciones que llevan a una salida a partir de las características de entrada. Tienen algunas desventajas: pueden ocasionar sesgos en los modelos (los árboles de decisión tienen la dificultad de representar bien la función objetivo que representa los datos), además suelen

presentar alta varianza, es decir, cambios en el conjunto de datos en el proceso de entrenamiento puede producir cambios sustanciales en el modelo (Horning, 2010).

Su principio de funcionamiento supone que se tiene un set de datos N , es decir, N muestras en el set de datos y cada muestra tiene N_x características. Suponer además que se tiene m árboles de decisión en el ensamble. En el modelo de Random Forest se busca dividir el set de datos en secciones que se distribuyen en los árboles de decisión. Algunas muestras irán a un árbol, otras muestras irán a otro árbol; además se usarán algunas características para unos árboles y otras para otros. Es decir, cada árbol tendrá un sub-set de datos con dimensiones menores al set de datos original, tal como se muestra en la figura 4.

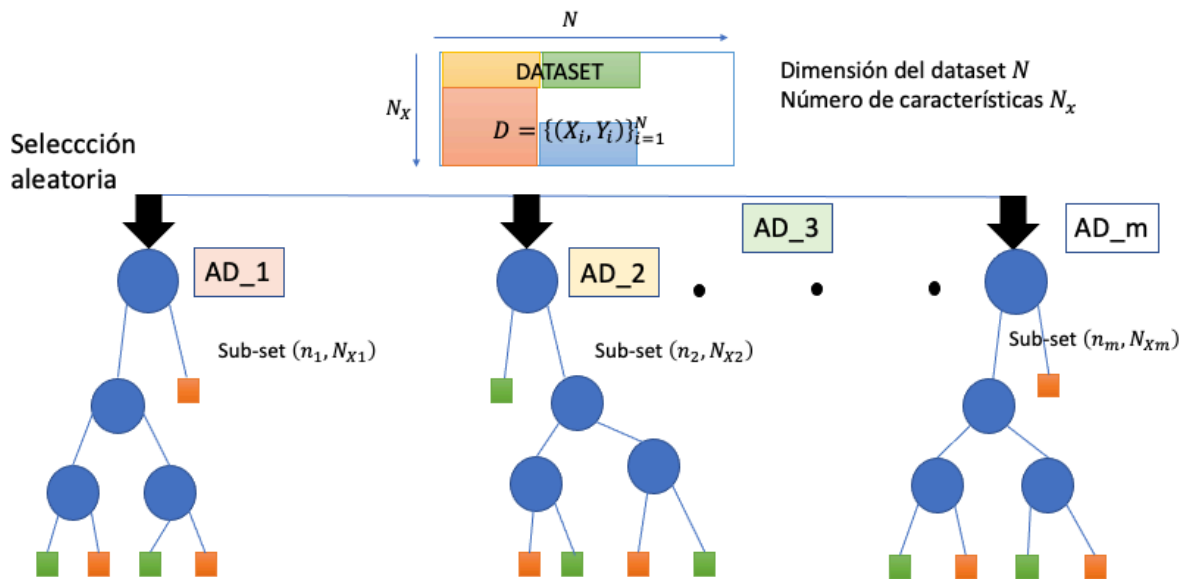


Figura 4. División de set de datos en varios sub-sets de datos, distribuidos en Árboles de decisión. Modificado a partir de (Vasilakos et al., 2020)

Para cada uno de los árboles, se establecerá un modelo que se construirá a partir de los sub-sets de datos. Ante una entrada particular cada uno de los árboles de decisión en el ensamble va a producir un resultado de clasificación (la variable categórica). La manera de decidir cuál será la salida total del ensamble, será aplicando la regla de la mayoría para los sistemas de clasificación. Lo anterior se esquematiza en la figura 5.

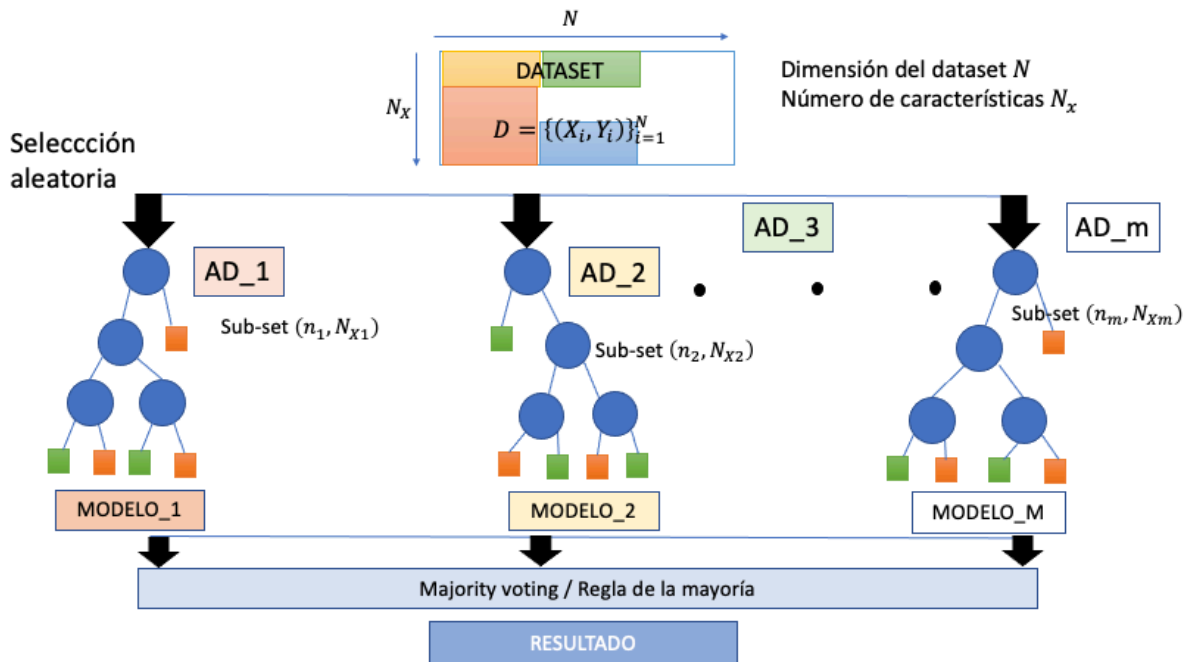


Figura 5. Resultado de la clasificación supervisada después de aplicar la Regla de la mayoría a los Árboles de decisión. Modificado a partir de (Vasilakos et al., 2020).

Para este caso, se están clasificando coberturas en superficies; si la mayoría de los modelos dice que el tipo de cobertura para las características que se ingresaron es Techo de cerámica o barro, consecuentemente la salida será Techo de cerámica o barro. Esta técnica permite tener un valor aceptable en la predicción general total, reduciendo la varianza (Horning, 2010).

El algoritmo tiene varias características (Horning, 2010), entre las que se encuentran: poder manejar grandes cantidades de datos con mayor dimensionalidad. Puede manejar miles de variables de entrada e identificar las variables más significativas, por lo que es considerado un método de reducción de dimensionalidad. Adicionalmente tiene un método efectivo para estimar datos faltantes y mantiene la precisión cuando falta una gran proporción de los datos. El algoritmo puede parecer como una caja negra, pues se tiene muy poco control sobre lo que hace el modelo.

El clasificador **K-vecinos más cercanos** es un método que se fundamenta en ejemplos o polígonos de entrenamiento más cercanos en el espacio multiespectral (Han et al., 2020). Es un tipo de aprendizaje basado en instancias o aprendizaje “perezoso” en el que la función solo se aproxima localmente y todos los cálculos se retrasan hasta la clasificación. Es la técnica de clasificación fundamental y más simple cuando hay poco o ningún conocimiento previo sobre la distribución de los datos. Funciona así (Kim et al., 2012):

- Se parte de un conjunto de entrenamiento: M vectores con N características cada uno.

- Se quiere clasificar un elemento nuevo, conocido como vector X , conformado por un conjunto de características $X = (X_1, X_2, \dots, X_n)$
- El primer paso es identificar las k muestras más cercanas al vector X , independientemente de su clase.
- El segundo paso es entre los K vecinos, contar los elementos que pertenecen a cada clase.
- El tercer paso es asignar a X a la clase más común entre los vecinos

Existen varias observaciones importantes que se pueden hacer en torno a este algoritmo de clasificación (Kim et al., 2012):

- La K significa la cantidad de “puntos vecinos” que se tienen en cuenta para clasificar los n grupos que ya se conocen, pues se trata de un *procedimiento supervisado*.
- El valor de K es importante, pues cuantos más “puntos k ” se le ingrese al algoritmo, más tardará en procesar y dar respuesta.
- K no debe ser un múltiplo del número de clases.

En la figura 6 se esquematiza, a modo de ejemplo, las observaciones más importantes para el método de K-Vecinos más cercanos.




Figura 6. Clasificación con el método de K-NN. En el punto de consulta del círculo, según el valor k de 1, 5 o 10, el punto de consulta puede ser un rectángulo en (a), un diamante en (b) o un triángulo en (c). Modificado a partir de (Kim et al., 2012).

Para encontrar los puntos similares más cercanos se utilizan medidas de distancias como: Distancia Euclidiana, Distancia de Hamming, Distancia Manhattan, entre otros.

De otro lado, existen numerosos algoritmos tipo **Clustering (No supervisados)** que se pueden utilizar para determinar las agrupaciones espectrales naturales presentes en un conjunto de datos. Una forma común de clustering, llamada **enfoque K-Means**, recibe del analista la cantidad de agrupaciones que se ubicarán en los datos (Congalton, 2015). A continuación, el

algoritmo “siembra” o localiza arbitrariamente ese número de centros de clúster en el espacio de medición multidimensional. Luego, cada pixel de la imagen se asigna al grupo cuyo vector medio arbitrario es el más cercano. Una vez clasificados todos los pixeles de esta manera, se calculan los vectores medios revisados para cada uno de los grupos. Los medios revisados se utilizan luego como base para reclasificar los datos de la imagen. El procedimiento continúa hasta que no hay un cambio significativo en la ubicación de los vectores medios de clase entre iteraciones sucesivas del algoritmo. Una vez que se alcanza este punto, se determina la identidad de la cobertura terrestre de cada clase espectral (Aldoski et al., 2013).

Una variante ampliamente utilizada del método K-Means para la agrupación de datos no supervisados es un algoritmo llamado **Técnicas Iterativas de Análisis de Datos Auto organizados A, o ISODATA** por sus siglas en inglés (Abbas et al., 2016). Este algoritmo permite que el número de clústeres cambie de una iteración a la siguiente, fusionando, dividiendo y eliminando clústeres. El proceso con este algoritmo sigue el descrito anteriormente para K-Means aunque, en cada iteración, después de la asignación de píxeles a los conglomerados, se evalúan las estadísticas que describen cada agrupación. Si la distancia entre los puntos medios de dos conglomerados es menor que una distancia mínima predefinida, los dos conglomerados se fusionan. Por otro lado, si un solo grupo tiene una desviación estándar (en cualquier dimensión) que es mayor que un valor máximo predefinido, el grupo se divide en dos. Se eliminan los clústeres con menos pixeles que el número mínimo especificado. Finalmente, todos los pixeles se reclasifican en el conjunto revisado de clústeres y el proceso se repite hasta que no hay cambios significativos en las estadísticas del clúster o se alcanza un número máximo de iteraciones (Abbas et al., 2016).

4. Metodología

4.1 Manejo y tratamiento de datos

4.1.1 Toma de datos

El proyecto Sistema de Alerta Temprana de Medellín y el Valle de Aburrá -SIATA-, planea operaciones aéreas con drones en los 10 municipios del Área Metropolitana del Valle de Aburrá y en otras subregiones del departamento de Antioquia. No fue potestad de este Trabajo de Grado, ni del estudiante que lo elaboró, la toma de los datos y su procesamiento hasta valores de reflectancia. Esta labor fue propia del equipo de Teledetección con Drones de SIATA, quienes prepararon los drones y las cámaras, cargaron las baterías, realizaron el montaje de la estación meteorológica local, programaron el recorrido del dron, solicitaron permiso ante Aerocivil y mapearon la zona de interés durante el sobrevuelo. Las zonas escogidas pueden responder a múltiples requerimientos: evaluación después de la ocurrencia de un incendio sobre cobertura vegetal, reconocimiento de zonas de interfaz, caracterización urbana, entre otras. Con el aval del director del proyecto SIATA, profesor

Carlos David Hoyos, y sumado al vínculo laboral del autor de este Trabajo de Grado con el proyecto, se obtuvo acceso a un banco amplio de imágenes de sobrevuelos históricos.

4.1.2 Procesamiento de datos

El equipo de Teledetección con Drones del SIATA, procesó las imágenes obtenidas de la cámara multiespectral en los diferentes sobrevuelos que han realizado a la fecha usando software comercial de la empresa Pix4D, que combina las imágenes tomadas por los sistemas aéreos remotamente pilotados, convirtiéndolas en mapas 2D o 3D, mediante la obtención de Nubes de puntos, Modelos Digitales del Terreno -DEM- y Ortomosaicos (Madawalagama et al., 2016).

El procesamiento del conjunto de datos, específicamente en el caso de los datos multiespectrales, incluye la calibración de la radiación, la corrección atmosférica, el registro geométrico, la orto-rectificación, la fusión de imágenes y el redimensionamiento de estas. La calibración de la radiación es el proceso de convertir los valores del número digital de los datos de la imagen a radiancia y luego a reflectividad aparente utilizando técnicas de corrección atmosférica. El propósito de la corrección atmosférica es poder obtener valores de reflectancia aparente en toda la imagen, con base en los datos de radiancia que se tienen de la escena (es decir, la radiación que es reflejada por las superficies) respecto con un panel de reflectancia conocida y la radiación incidente del sol (Hernández, 2011).

La corrección geométrica incluye el registro de imágenes y la orto-rectificación. El propósito de la corrección geométrica es corregir la deformación de la imagen causada por factores sistemáticos y no sistemáticos (Hernández, 2011).

La ortorectificación es el proceso de corrección de la distorsión geométrica del espacio de la imagen para generar una imagen ortográfica del plano de proyección multicéntrica. Además de corregir las distorsiones geométricas causadas por factores generales del sistema, también puede eliminar la distorsión geométrica causada por el terreno o la curvatura de la tierra. La fusión de imágenes es el proceso de generación de nuevas imágenes bajo el sistema de coordenadas geográficas prescrito según un determinado algoritmo (Congalton, 2015).

4.1.3 Post-procesamiento de los datos

Como software de Información Geográfica, se utilizaron QGIS -Quantum Geographic Information System- y SAGA -System for Automated Geoscientific Analyses- pues no requieren licencia, son libres, de código abierto y compatibles con todos los sistemas operativos, lo cual brinda un gran aporte en términos académicos, ya que garantiza la posible repetibilidad de este trabajo con datos similares. Para el manejo de archivos vectoriales y el análisis geoespacial, se usó Python como lenguaje de programación.

Cabe anotar que, durante el desarrollo del proceso de clasificación supervisada de este Trabajo de Grado, se utilizaron las mismas muestras etiquetadas de entrenamiento y de prueba como entradas de los clasificadores.

4.1.4 Área de estudio y datos empleados

Para la realización de este Trabajo de Grado, se escogieron imágenes de vuelos realizados en el Valle de Aburrá, en los cuales fueran distinguibles distintos tipos de coberturas, con el propósito de hacer posteriores comparaciones. Los lugares que se escogieron fueron:

Tabla 1. Atributos de los datos usados en este estudio.

	Lugar	Ubicación	Coordenadas	Descripción
1	Institución Educativa CASD.	Noroccidente de Medellín, comuna Doce de octubre.	6°17'49.01" N 75°34'28.42" O	Zona residencial. En el centro de la imagen se observa un núcleo arborizado y con pastos que corresponde a la Institución Educativa CASD.
2	Jardín Botánico Joaquín Antonio Uribe	Centro-orienté de Medellín, comuna Aranjuez.	6°16'12.67" N 75°33'47.18" O	Es un escenario en el corazón de la ciudad. Alta densidad de vegetación.
3	Unidad Deportiva Atanasio Girardot	Centro-occidente de Medellín, comuna Laureles Estadio	6°15'26.07" N 75°35'22.26" O	Escenario deportivo. Reúne en una misma área muchos lugares para la práctica de distintos deportes, es la imagen donde se logran identificar mayor cantidad de distintas coberturas.
4	Cerro de las Tres Cruces	Corregimiento de Altavista, Medellín	6°12'44.66" N 75°36'57.76" O	Interfaz urbano-forestal. En la imagen se distinguen distintos tipos de cobertura vegetal, entre ellas cobertura consumida por el fuego.
5	Barrio Tricentenario	Nororienté de Medellín, comuna Castilla	6°17'30.71" N 75°33'59.15" O	Se trata de un sitio residencial rodeado de árboles altos, con calles de asfalto que comunican las unidades.

Los sitios escogidos, con su correspondiente ubicación en Medellín se muestran en la siguiente imagen:

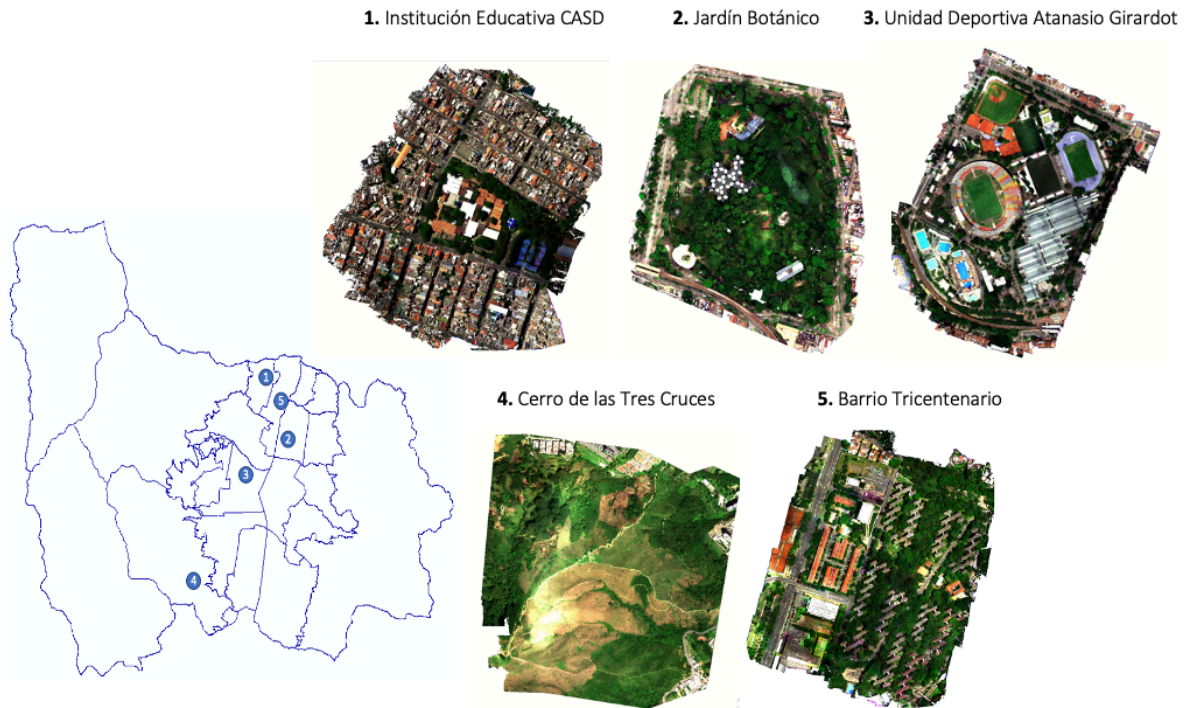


Figura 7. Izquierda: mapa de Medellín con la ubicación de los sitios donde se hizo captura de datos con cámara ALTUM y que se usaron en este trabajo. Derecha: imágenes RGB de los sobrevuelos utilizados en este estudio. Fuente: equipo Teledetección con Drones SIATA

4.2 Clasificación supervisada

Para la realización de la clasificación supervisada, se contó con datos de reflectancia en 5 bandas espectrales de los lugares previamente mencionados, por lo que cada uno de ellos tenía cinco (5) imágenes asociadas a las bandas espectrales que maneja la cámara (azul, verde, rojo, rojo de borde e infrarrojo cercano), en este caso omitiendo el uso de la banda térmica, la cual desde SIATA no se pudo procesar exitosamente a un ortomosaico desde el software comercial. Adicionalmente, en algunas de ellas también se contaba con el ortomosaico del vuelo en formato KML, para su visualización en Google Earth.

4.2.1 Obtención de la firma espectral de los elementos más comunes presentes en las imágenes.

Para encontrar la firma espectral de distintos materiales, lo primero que se hizo fue trazar polígonos de entrenamiento de superficies de las cuales, dada la resolución de la imagen y la labor en campo, se conoce a qué material pertenecen. Las figuras 8 y 9 muestran las

coberturas que se identificaron en la imagen correspondiente a la Institución Educativa CASD y los polígonos de entrenamiento asociados a dichas superficies.



Figura 8. Ejemplo de superficies escogidas en IECASD para posterior clasificación.




Figura 9. Polígonos de entrenamiento trazados en QGIS sobre las superficies escogidas en IECASD.

De cada uno de los polígonos se obtuvo la firma espectral, haciendo en QGIS un corte entre el polígono y las cinco (5) bandas del espectro electromagnético disponibles con la cámara. Se obtiene un valor de reflectancia -en porcentaje- por cada una de las bandas espectrales.

Con estos datos se construye la firma espectral, que se define como: “el comportamiento diferencial que presenta la radiación reflejada -reflectancia- o emitida desde algún tipo de superficie u objeto terrestre en los distintos rangos del espectro electromagnético” (Hernández, 2011); de tal forma que por cada uno de los polígonos trazados se obtuvo un gráfico como el siguiente:




Figura 10. Firmas espectrales obtenidas trazando polígonos en las canchas de la UDAG. Las que tienen mayor porcentaje de reflectancia en la banda del rojo de borde y el NIR corresponden a pasto natural y las de menor reflectancia a pasto sintético.

En la gráfica anterior se relaciona el porcentaje de Reflectancia (%) en el eje horizontal y Longitud de onda (μm) del espectro electromagnético en el eje vertical.

4.2.2 Clasificación supervisada basada en algoritmo por umbrales

Teniendo en cuenta las firmas espectrales obtenidas y en conjunto con el equipo de Teledetección con Drones de SIATA, se hizo un algoritmo en Python cuyo objetivo era la clasificación de coberturas basada en umbrales de las coberturas presentes en la imagen. Se hizo a partir de rasgos que fueran excluyentes entre sí (resultado de un ejercicio de observación y comparación) y después de un análisis por clases o categorías, así:

Clase: Vegetación




Figura 11. Firma espectral de pastos y árboles (vegetación) obtenida en la Institución Educativa CASD y el Jardín Botánico Joaquín Antonio Uribe.

Para esta categoría, los rasgos excluyentes fueron:

- Un valor alto para el índice de vegetación NDVI, el cual se utiliza para estimar la cantidad, calidad y desarrollo de la vegetación con base en la medición de la intensidad de la radiación de la banda roja e infrarrojo del espectro electromagnético. Se calcula mediante la diferencia entre la reflectancia de las bandas 4 (infrarrojo cercano) y 3 (visible-rojo), dividido por la suma de estas dos bandas (Qian et al., 2020). Se utilizó este criterio, porque se observó que, al hacer el cálculo del NDVI, la vegetación exhibía valores por encima de 0.25, lo que la diferenciaba de otros materiales verdes.
- Valores de NIR por encima de 0.13, este valor está por encima de otras superficies verdes, como las canchas de pasto sintético.

En línea de código se ingresó así:

```
vegetacion = np.logical_and((nir > 0.13),(ndvi > 0.25))
```

Clases Urbano/suelo: concreto

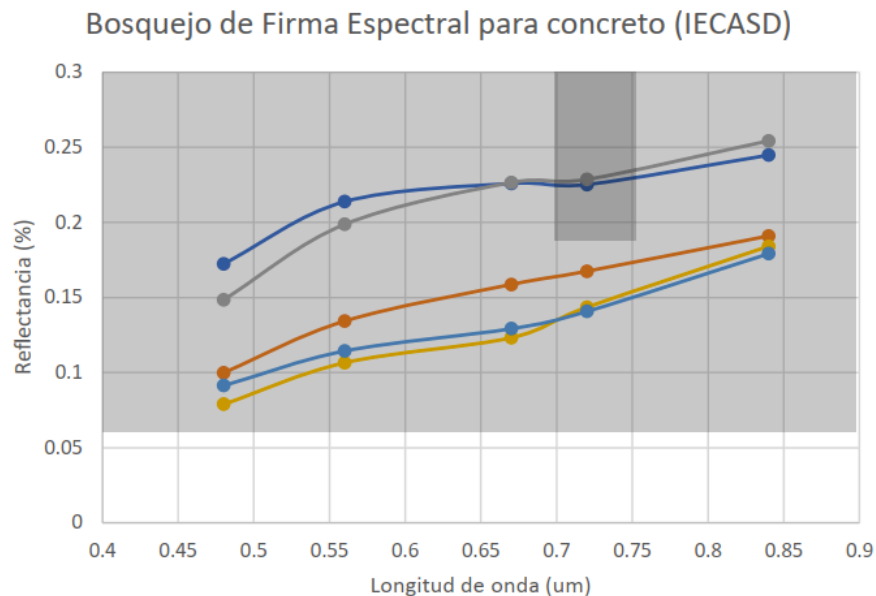


Figura 12. Firma espectral de concreto obtenida en la Institución Educativa CASD.

Para esta categoría los rasgos excluyentes fueron:

- Curvas relativamente poco inclinadas, con valores de reflectancia en las cinco bandas espectrales que oscilan entre 0.06 (mínimo en el azul) y 0.35 (máximo en el infrarrojo cercano).

- Valores más altos en el rojo de borde en comparación con el asfalto. Rojo de borde superior a 0.119

En líneas de código se escribió así:

```
concreto = np.logical_and((ref_min > 0.06),(ref_max < 0.35))
```

```
concreto = np.logical_and(concreto,red_edge > 0.119)
```

Clases Urbano/suelo: Asfalto




Figura 13. Firma espectral de asfalto obtenidas en la Institución Educativa CASD y en la Unidad Deportiva Atanasio Girardot.

Para esta categoría los rasgos excluyentes fueron:

- La firma espectral del asfalto, al igual que la del concreto, es una curva poco inclinada. Sin embargo, el valor de mayor reflectancia para el asfalto está por debajo del 0.14 (para el infrarrojo cercano), mientras que para el concreto este valor es superior a 0.14.
- Mínima diferencia en el porcentaje de reflectancia en la banda del rojo de borde y el infrarrojo cercano (se estimó como 0.04).
- La reflectancia del rojo, mayor a la reflectancia del verde, para evitar falsas alarmas con el color verde.
- Un valor de reflectancia del rojo de borde cercano es cercano e inferior a 0.1.

En líneas de código se escribió así:

```
asfalto1 = np.logical_and((ref_min > 0.04),(ref_max < 0.13))
```

```
asfalto2 = np.logical_and((green <= red),((nir-red_edge) < 0.04))
```

```
asfalto = np.logical_and(np.logical_and((asfalto1),(asfalto2)),red_edge < 0.119)
```

Clases Urbano/suelo: Ladrillo cerámico o Teja cerámica




Figura 14. Firma espectral para Ladrillo cerámico o Teja cerámica obtenido en la Institución Educativa CASD.

Para esta categoría los rasgos excluyentes fueron:

- La firma espectral es ascendente con baja reflectancia en el azul. Pendiente más inclinada entre los $0.55 \mu\text{m}$ y $0.7 \mu\text{m}$. Elementos de color naranja.
- Hay poca diferencia en el valor de reflectancia del rojo y el rojo de borde (se estimó menor a 0.05)
- Los valores de reflectancia del azul están por debajo de 0.1% y del rojo por encima de 0.15

En línea de código se escribió así:

```
ladrillo = np.logical_and(np.logical_and((blue<0.1),(red>0.15)),((red_edge-red)<0.05))
```

Clases Urbano/suelo: Techos blancos




Figura 15. Firma espectral para techo blanco obtenido en la Institución Educativa CASD

Para esta categoría los rasgos excluyentes fueron:

- La curva de firma espectral es relativamente plana, porque el blanco tiene una alta reflectancia en todas las longitudes de onda.
- Al ser de color blanco, son los elementos más reflectivos detectados en las imágenes. El rango de reflectancia de las cinco bandas espectrales tiene un valor mínimo de 0.35 y un valor máximo inferior a 0.8.

En línea de código se escribió así:

```
techos_blanco = np.logical_and((ref_min > 0.35), (ref_max < 0.8))
```

Clases Urbano/suelo: Cancha de polipropileno o Pasto sintético




Figura 16. Firma espectral para canchas de polipropileno o Pasto sintético, obtenida en la Unidad Deportiva Atanasio Girardot.

Para esta categoría los rasgos excluyentes fueron:

- Son materiales verdes con valores en el infrarrojo cercano muy por debajo del pasto natural ($NIR < 0.09$).
- Los valores del infrarrojo cercano siempre serán mayores que los del rojo de borde.
- Descartar lo que previamente se haya identificado como vegetación.

En líneas de código se escribió así:

```
cancha_plastica = np.logical_and(np.logical_and((green>blue),(green>red)),(nir<0.09))
```

```
cancha_plastica = np.logical_and(cancha_plastica,(red_edge<nir))
```

```
cancha_plastica = np.logical_and(cancha_plastica,~vegetacion)
```

Clases Agua: Agua con algas y/o sedimentos




Figura 17. Firma espectral para agua con algas y/o sedimentos, obtenida en el lago del Jardín Botánico Joaquín Antonio Uribe. .

Para esta categoría los rasgos excluyentes fueron:

- El agua con algas y/o presencia de sedimentos tiende a ser verdosa, sumado a valores bajos de reflectancia en general (inferiores a 0.07).
- El rojo de borde tiene valores altos, por encima del infrarrojo cercano.

En líneas de código se escribió así:

```
agua1 = np.logical_and((green>red),(ref_max<0.07))
```

```
agua1 = np.logical_and(agua1,(red_edge>nir))
```

Clases Agua: Agua piscinas

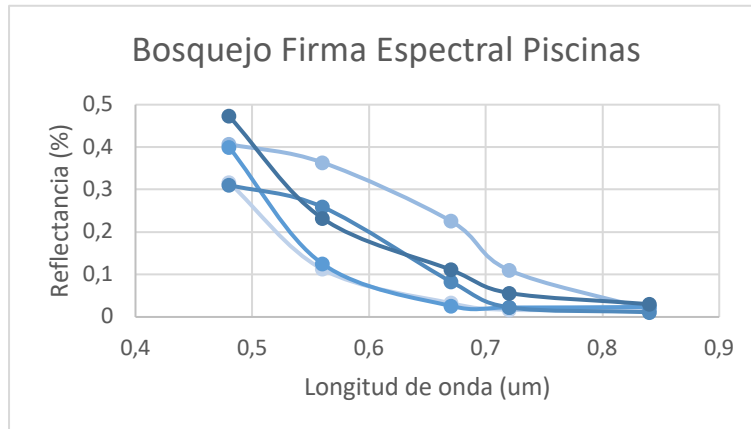


Figura 18. Firma espectral para el agua de piscinas, obtenida en la Unidad Deportiva Atanasio Girardot.

Para esta categoría los rasgos excluyentes fueron:

- Como el agua de la piscina es transparente, es muy importante el color del baldosín y el reflejo del cielo en el cuerpo de agua.
- La reflectancia en el azul es la más alta en comparación con las demás longitudes de onda. Los valores en el infrarrojo cercano son muy bajos.
- La firma espectral es descendente con máximo en el azul y mínimo en el infrarrojo cercano.

En líneas de código se escribió así:

```
piscina = np.logical_and((blue>0.25),(nir<0.05))
```

4.2.3 Clasificación Supervisada basada en los métodos de clasificador de Máxima Verosimilitud Gaussiana, Random Forest y K-Vecinos más cercanos.

Para realizar estas clasificaciones se utilizó QGIS, específicamente el plugin Dzetsaka, el cual es necesario instalar pues no viene por defecto con el software.

Adicionalmente, para poder realizar las clasificaciones y que el plugin funcione adecuadamente, se deben instalar las librerías Scikit-Learn, Rasterio y GDAL; que tampoco vienen por defecto en QGIS ni en Python3.

La imagen .tiff que recibe el complemento Dzetsaka, es la composición final de las cinco bandas espectrales en formato .tiff, que se obtiene con la cámara después de procesar los sobrevuelos. Esta composición también se hace en QGIS, de la siguiente manera:

- Se ingresa al menú Ráster, luego se escoge Miscelánea y a continuación la opción Construir ráster virtual.

Nota: el ráster que se obtenía con la opción Combinar salía defectuoso, por eso se trabajó con ráster virtual, el cual luego se exportaba y guardaba como capa definitiva.

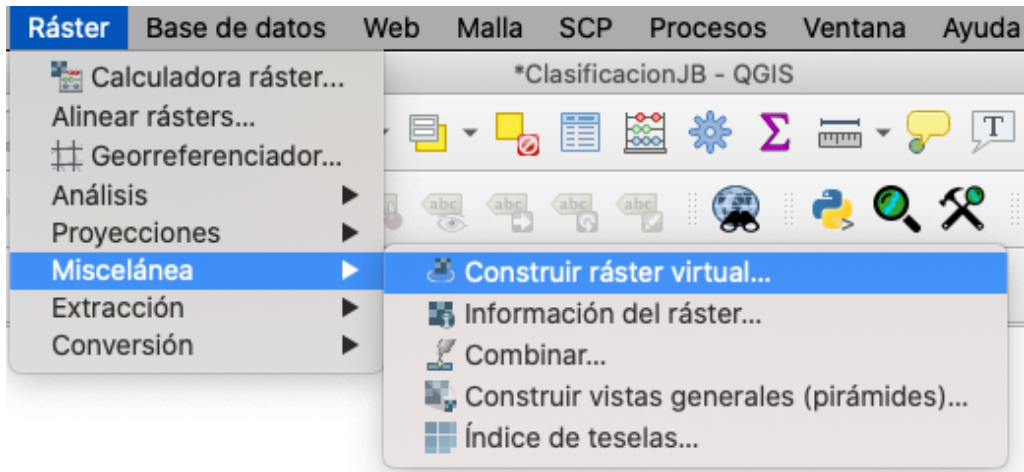


Figura 19. Funcionalidades para construir ráster virtual en QGIS.

- Una vez en Construir ráster virtual, en Input layers se ingresan las bandas espectrales que componen la imagen, para este caso son cinco. Deben ingresarse de mayor a menor longitud de onda, para que el programa las recibe y las procese bien, es decir, en este orden: NIR > Rojo de borde > Rojo > Verde > Azul. En la opción Resampling algorithm, se deja la que elige el programa por defecto, aunque hay 7 opciones distintas. Este ítem no se exploró en este Trabajo de Grado. Finalmente se selecciona la opción Ejecutar y así se obtiene la composición de la imagen.

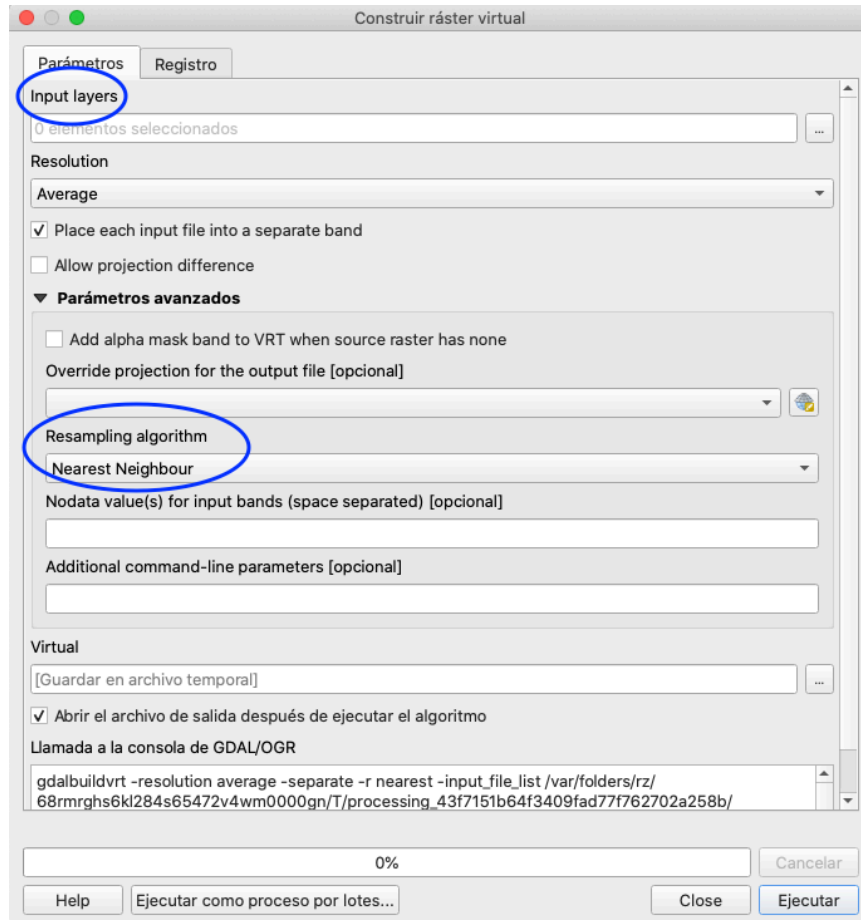


Figura 20. Funcionalidades para editar y construir ráster virtual

Además de la Composición multispectral, al plugin Dzetsaka se debe ingresar la capa de los polígonos de entrenamiento. Esta última se obtiene así:

- Se escoge la opción de Nueva capa de archivo shape:




Figura 21. Funcionalidad para crear una Nueva capa de archivo shape.

- En esta opción se escoge como tipo de geometría Polígono y el campo que se utilizará como discretizador será ID. Es decir, por cada composición sólo se elabora una capa de polígono y en dicha capa los polígonos se diferenciarán por el ID, vevigracia 1 para vegetación, 2 para asfalto, 3 para concreto, etc. Es importante en este punto tener especial cuidado con el sistema coordenado, ya que deben coincidir entre las capas que se ingresan para evitar resultados errados.

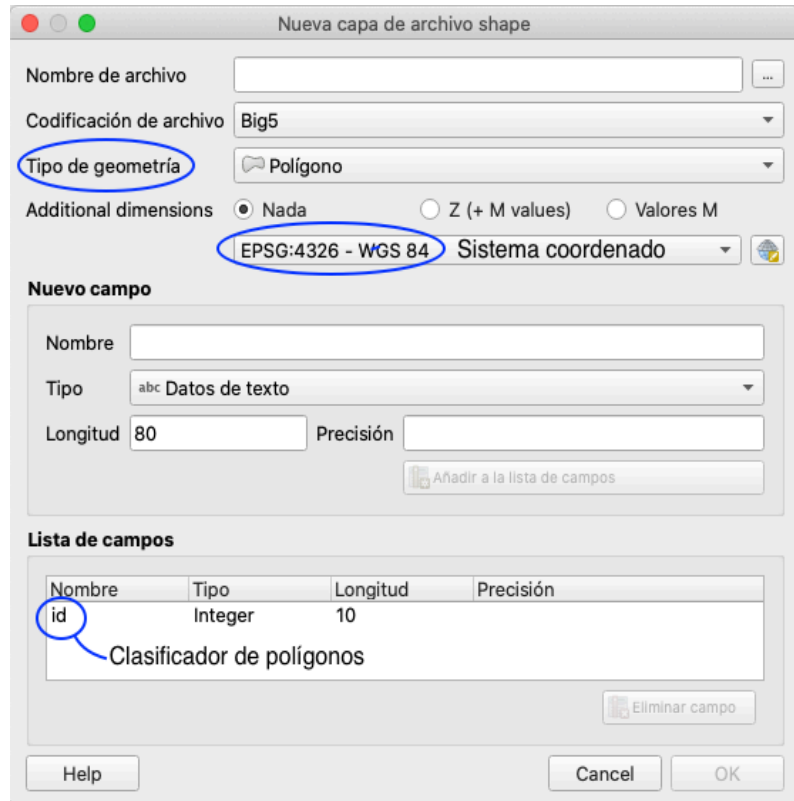


Figura 22. Menú de configuración para la Nueva capa de archivo shape (tipo polígono), que luego será utilizado como capa de entrada para realizar la clasificación.

- Una vez se tengan las capas creadas (la de Composición espectral y la de Polígonos de entrenamiento), se ingresan al plugin Dzetsaka, que es el que realizará la clasificación:

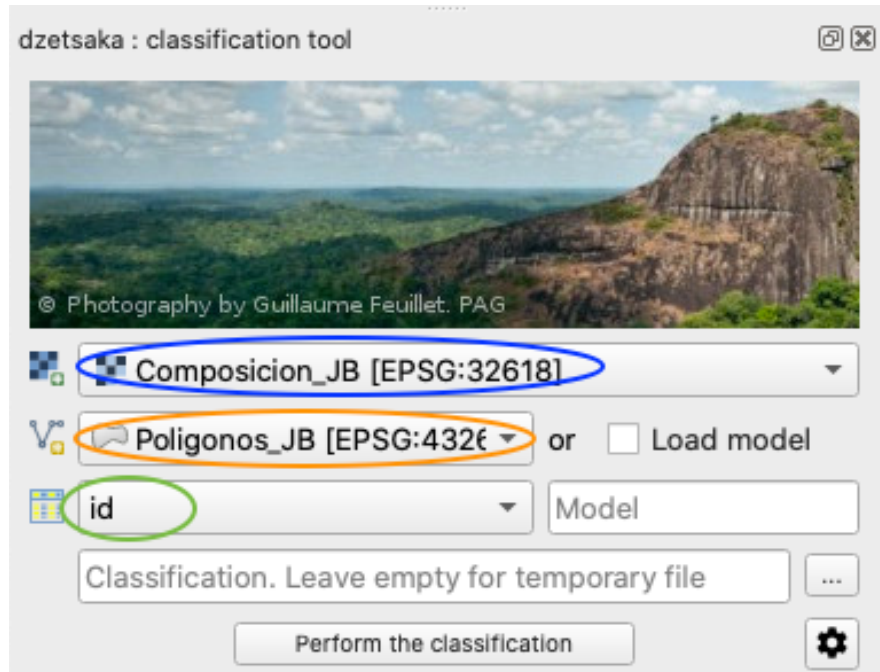


Figura 23. Funcionalidad del plugin Dzetsaka, el círculo azul es el ráster de composición previamente construido, el círculo naranja la capa de los polígonos de entrenamiento y el círculo verde el discretizador que recibirá el modelo.

- El plugin da la posibilidad de escoger el método para realizar la clasificación, de acuerdo con los más comunes en la literatura, las demás opciones se dejan por defecto como las muestra el software:

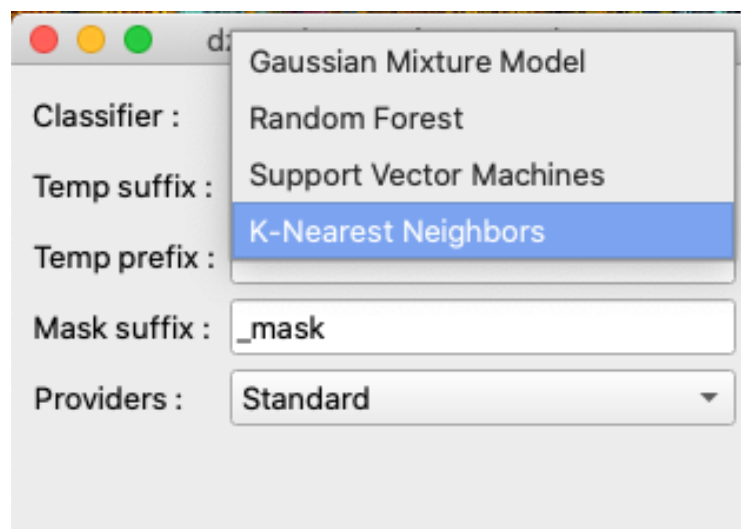


Figura 24. Métodos de clasificación supervisada que se pueden realizar con el plugin Dzetsaka. Nota: el método de Máquinas de Vectores de Soporte (Support Vector Machine) no funcionó.

- Finalmente, luego de esperar entre 16 minutos y 12 horas (dependiendo del método que se haya escogido) se obtiene la imagen clasificada.
- Es importante ajustar la simbología del resultado de la capa clasificada con el fin de observar mejor los resultados y facilitar el análisis.

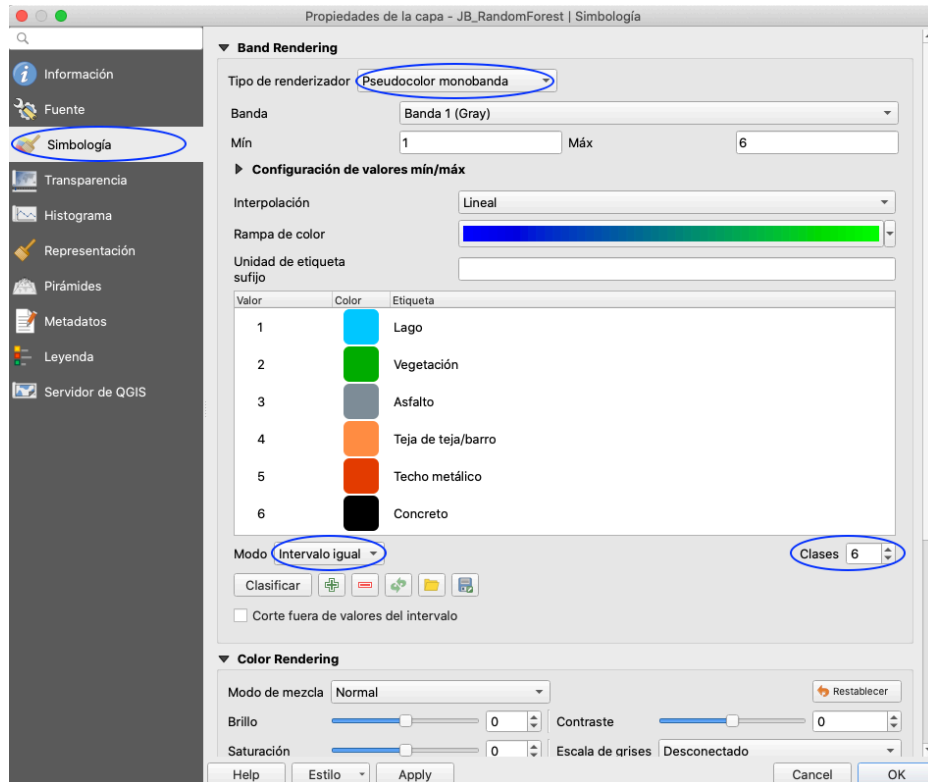


Figura 25. Menú Simbología. Se escoge como tipo de randerizador Pseudocolor monobanda, de tal forma que se puedan crear intervalos iguales (para cada una de las clases escogidas) para posteriormente asignarle un color representativo a cada categoría.

4.3 Clasificación no supervisada

Para la realización de esta clasificación se utilizó QGIS y SAGA. Lo primero que se requiere es la composición multiespectral de las imágenes, previamente obtenida en la Clasificación supervisada. Esta composición, como se mostró en el apartado 4.2.2, se realizó construyendo un ráster virtual en QGIS, el cual fue exportado posteriormente como una capa en formato .tiff

Con la capa guardada, ya se continúa el procesamiento en SAGA, que es otro software para análisis geográfico, de uso libre y que no requiere licencia para funcionar. SAGA puede ser integrado a QGIS, para trabajar en complemento el uno con el otro.

En SAGA, se abre la composición realizada en QGIS, desde el menú Open:




Figura 26. Funcionalidad para abrir cualquier capa de archivo shape, para este caso se abrirá la composición multiespectral creada previamente en QGIS.

- Con la composición multispectral ya cargada, ya es posible realizar la clasificación no supervisada, desde el módulo de Geoprocessing, tal como se observa en la figura 26.

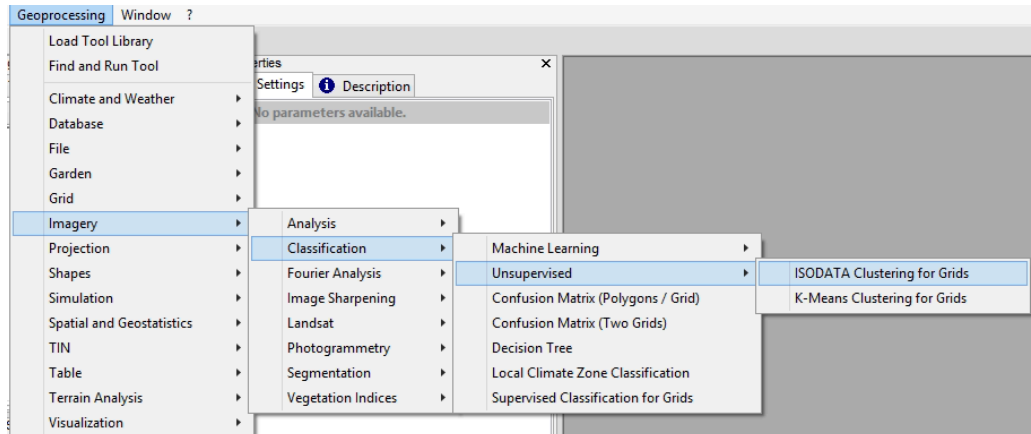


Figura 27. Ruta en SAGA para realizar clasificaciones no supervisadas. Notar que hay dos opciones: ISODATA clustering y K-Means clustering; ambos se realizaron en este Trabajo de Grado.

A las imágenes se les realizó ambas clasificaciones no supervisadas, que son las más comunes en la literatura.

- La opción ISODATA, muestra el siguiente cuadro:

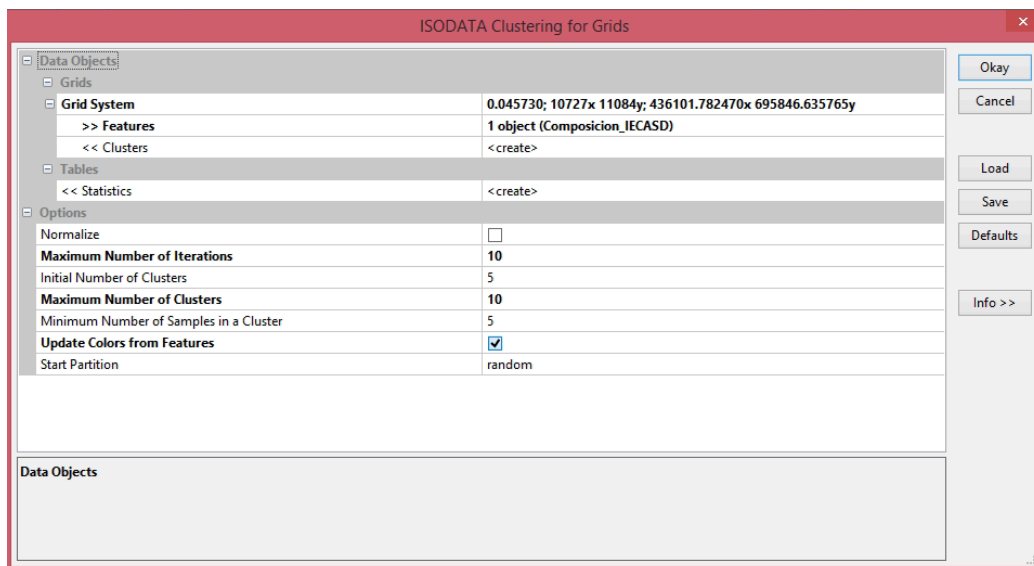


Figura 28. Cuadro de diálogo para realizar la Clasificación No Supervisada por el método ISODATA.

La opción Grid System se refiere al sistema coordinado, que normalmente el programa lo configura por defecto. En Features se escoge la imagen (la composición multispectral). Adicionalmente, se selecciona la opción para que cree los clústeres y las tablas de estadísticas. El máximo número de iteraciones se escogió diez, lo que

significa que el algoritmo pasa una vez, determina una estadística, y hace la agrupación; en una segunda iteración vuelve a analizar los píxeles y los vuelve a reacomodar. A mayor número de iteraciones, mayor es la fiabilidad de la clasificación y mayor tiempo de computación (Abbas et al., 2016).

El número inicial y máximo de clústeres se escogió teniendo en cuenta la cantidad de clases escogidas en las mismas imágenes cuando se realizó la clasificación supervisada. Adicionalmente, es importante tener en cuenta que, si se eligen muchos clústeres, el algoritmo puede identificar a una cobertura como dos o más clústeres diferentes, basándose en una mínima diferencia espectral.

Finalmente, se le da Okay, y comienza el procesamiento del algoritmo. El resultado es la clasificación no supervisada de la imagen y una tabla con el total de clústeres identificados. La imagen se exporta a QGIS y la tabla de las estadísticas se guarda como archivo de texto separable por comas .csv.

- La opción K-Means muestra el siguiente cuadro:

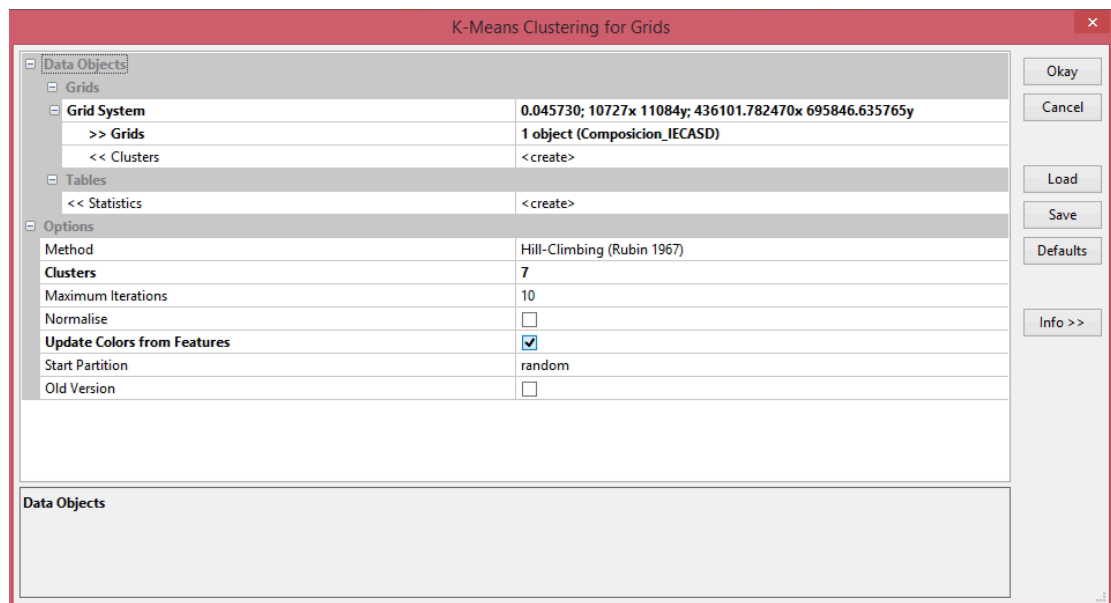


Figura 29. Cuadro de diálogo para realizar la Clasificación No Supervisada por el método de K-Means.

Las opciones de Grid System, Grids, Clusters y Statistics funcionan igual que para el método ISODATA. Usando K-Means lo que varía es la selección del método, el programa muestra varias opciones: Iterative Minimum Distance (Forgy 1965), Hill-Climbing (Rubin 1967) y Combined Minimum Distance / Hill Climbing. En este Trabajo de Grado sólo se exploró la opción Hill-Climbing (Rubin 1967), que por defecto el software escoge como opción. En Clústeres se ingresa el número de clústeres que se encontraron en el método de ISODATA, para poder realizar futuras comparaciones entre ambos métodos y que estén bajo las mismas condiciones. Para el máximo número de iteraciones se utilizó el mismo criterio descrito en el método ISODATA. La imagen de la clasificación y la tabla de estadísticas se guardan y exportan como archivo, para luego abrirlas en QGIS.

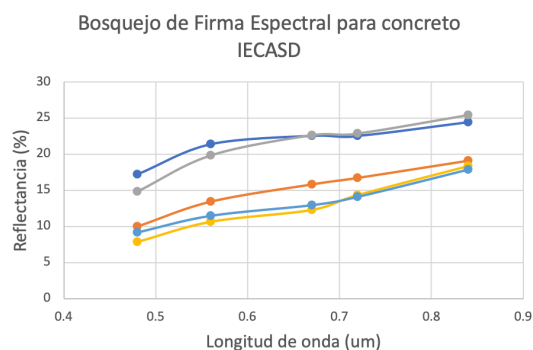
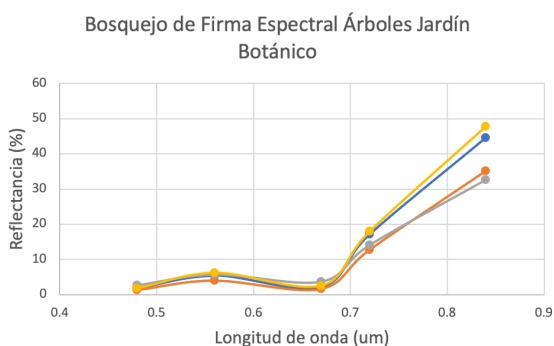


- La clasificación no supervisada requiere análisis posterior. Se carga el archivo entregado por SAGA en QGIS. El archivo viene con los clústeres escogidos, pero no identificados. Es necesario, desde el menú propiedades de QGIS, hacer la identificación de las categorías a qué superficie corresponde, una a una. Como se mencionó anteriormente, es un proceso netamente dependiente del analista.

5. Resultados y análisis

5.1 Firma espectral de los elementos más comunes presentes en las imágenes

A partir de los datos de los sobrevuelos, se encontró la firma espectral de los siguientes materiales: Techo cerámico/teja, Techo blanco, Árboles, Pastos, Concreto, Asfalto, Cuerpos de agua natural -lago- y Cuerpos de agua artificial -piscinas-.

La siguiente figura muestra un bosquejo de las firmas espectrales encontradas a partir de los polígonos de entrenamiento trazados:



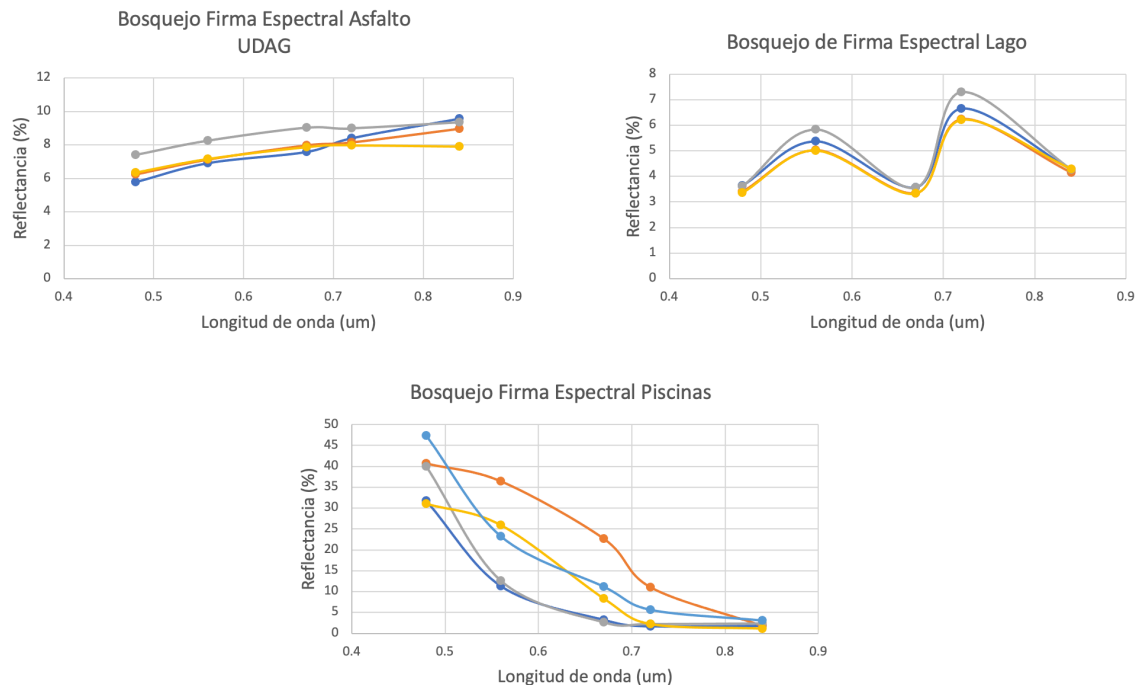


Figura 30. Firmas espectrales de las coberturas más comunes identificadas en los vuelos, obtenidas a partir de polígonos de entrenamiento.

En general, se pueden hacer las siguientes observaciones de las firmas espectrales encontradas:

- Los techos cerámicos o de teja: absorbieron en las longitudes de onda del azul y el verde y reflejaron en el rojo, rojo de borde e infrarrojo cercano. Curva ascendente en el espectro visible y relativamente plana en el rojo de borde y el infrarrojo cercano.
- Los techos blancos: tienen buena reflectancia -superior al 40%- en todas las bandas del espectro del sensor, por ello se observa que la forma de la curva es poco inclinada. Lo anterior se explica porque las superficies blancas reflejan, casi en el mismo porcentaje, la luz incidente en todas las longitudes de onda.
- Vegetación -árboles y pastos-: en general, la vegetación absorbió muy bien -valores por debajo del 10%- la energía electromagnética en la región visible. La clorofila absorbió la luz en longitudes de onda alrededor de 0.45 μm (azul) y 0.67 μm (rojo) y reflejó fuertemente la luz verde, lo que es consecuente con lo que percibe el ojo como verde. Se observó una alta reflectancia en el infrarrojo cercano entre 0,7 μm y 1,3 μm , lo que se debe principalmente a la estructura interna saludable de las hojas de las plantas (Qian et al., 2020). La forma de la curva para la vegetación, mostró que es cóncava hacia abajo en el espectro visible y de pendiente superior a 45° en el rojo de borde y el infrarrojo cercano.
- Concreto: es un material absorbente de la energía electromagnética, por eso la curva de reflectancia es relativamente plana en todas las longitudes de onda y la reflectancia no supera el 25%
- Asfalto: al igual que el concreto, el material tuvo una curva relativamente plana, con valores de reflectancia cercanos al 10% en todas las longitudes de onda. Este valor es

inferior a la reflectancia obtenida con el concreto, lo que significa que el asfalto absorbe más energía que el concreto.

- Cuerpos de agua natural -lago-: la firma espectral para el agua del lago en general mostró valores de reflectancia bajos -inferiores al 8%-, con mayor reflectancia en el verde, atribuible a la presencia de algas o plancton en el agua, sumado al color del fondo. La curva muestra picos de reflectancia en el verde y en el rojo de borde y valores mínimos en el azul y en el infrarrojo cercano.
- Cuerpos de agua artificial -piscinas-: contrario a lo observado en la curva de la firma espectral del lago, la firma espectral de las piscinas tiene valores de reflectancia muy altos -cercaos al 50% para el azul-. Tiene una alta absorción y prácticamente no tiene reflectancia en el rango de longitudes de onda del infrarrojo cercano. Se destaca que el agua turbia tiene una mayor reflectancia en la región visible que el agua clara, lo que se puede deber a la presencia de clorofila (Mobley, 1999). La forma, es una curva con fuerte pendiente negativa, con el valor de reflectancia más alto en el azul, seguido del verde, el rojo, el rojo de borde y finalmente el infrarrojo cercano.

Es importante mencionar que, se compararon las firmas espectrales obtenidas con la cámara ALTUM con las firmas espectrales teóricas de los materiales escogidos (Kotthaus et al., 2014) mostradas en la figura 31, y los resultados son consistentes, pues la forma de las curvas y los valores de las reflectancias en esas categorías son muy similares, lo que da confiabilidad al proceso realizado.

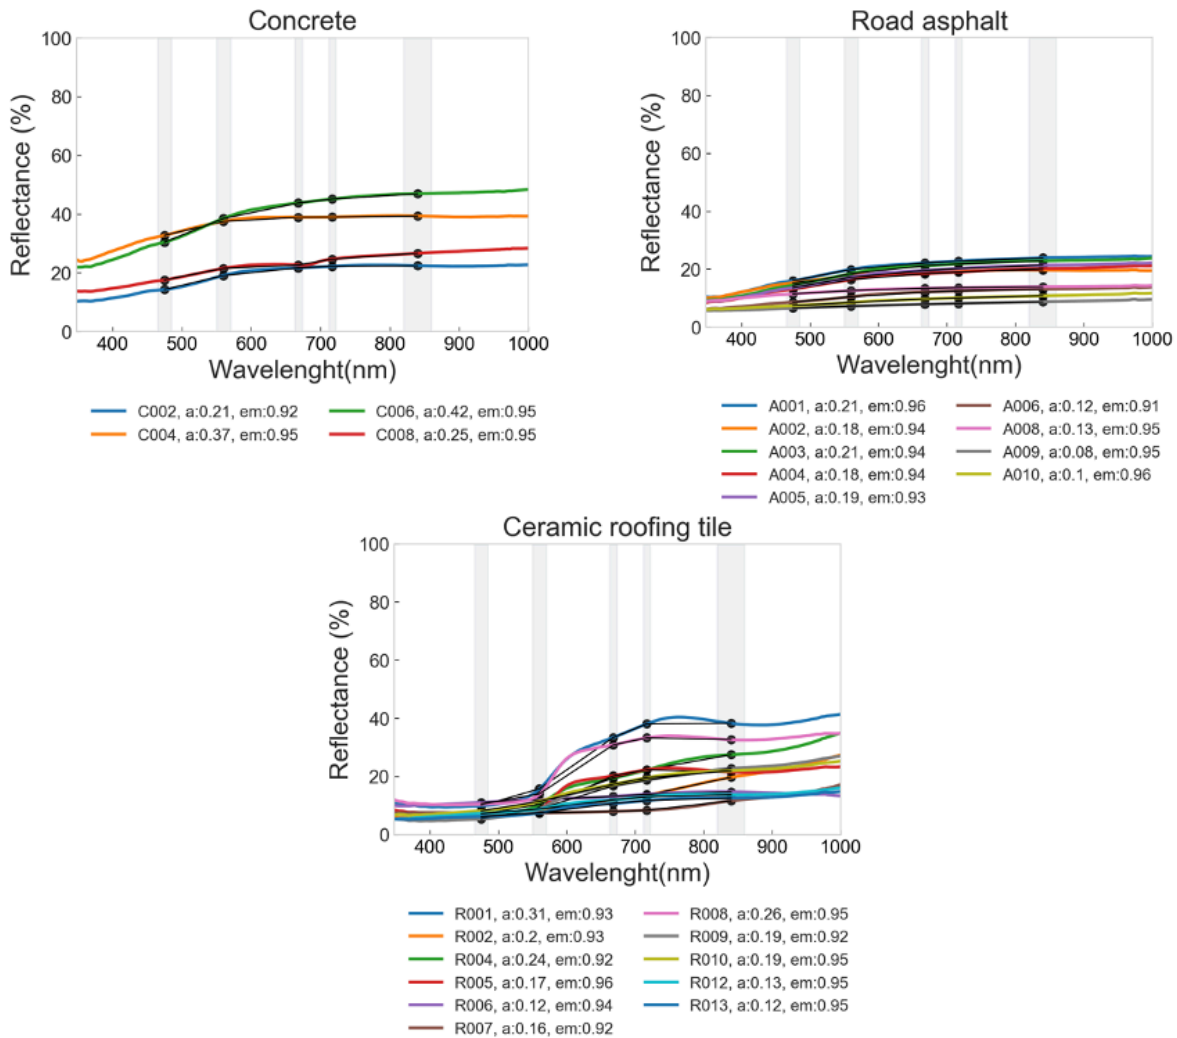


Figura 31. Firmas espectrales teóricas del concreto, el asfalto y el techo de teja cerámica. Modificado a partir de (Kotthaus et al., 2014).

Sumado a la anterior, fue posible encontrar que, elementos presentes en las imágenes y que al momento de la captura se mueven -como es el caso de los vehículos- pueden quedar registrados en alguna de las bandas espectrales del sensor, alterando los valores de reflectancia. Esto en particular se vio sobre las superficies identificadas como asfalto o concreto, debido a los carros que pasaban en el momento del vuelo.

5.2 Clasificación supervisada basada en algoritmo por umbrales

Para las imágenes con las que se testeó el algoritmo de clasificación por umbrales, se realizó clasificación utilizando 10 categorías específicas, de acuerdo a los sesgos descritos en la metodología. Teniendo en cuenta lo anterior, se escogieron las siguientes categorías: Grama o pasto artificial, Piscina (agua), Lago (agua), Suelo desnudo, Techos blancos, Ladrillo/Teja cerámica, Asfalto, Concreto, Pasto, Árboles. Los resultados obtenidos fueron:

5.2.1 Unidad Deportiva Atanasio Girardot.



Figura 32. Resultado de la clasificación por umbrales en la Unidad Deportiva Atanasio Girardot. Izquierda: imagen RGB de la Unidad Deportiva Atanasio Girardot. Derecha: resultado de la clasificación por umbrales. Fuente: equipo Teledetección con Drones SIATA

En la clasificación con 10 categorías, hay buen reconocimiento de la vegetación alrededor del núcleo de la unidad deportiva, la cancha del Atanasio Girardot, el diamante de béisbol y la pista de atletismo; sin embargo, dentro de esta categoría, hay una mala o nula diferenciación entre pastos y árboles. Las piscinas del complejo acuático son completamente identificadas como cuerpos de agua, observándose algunas falsas alarmas en el resto de la imagen. Las canchas de tenis las identifica parcialmente dentro de la categoría de Ladrillo/teja cerámica, lo que es un acierto porque el material del que están hechas es arcilla, polvo de ladrillo o tierra batida. Hay una buena identificación de asfalto en las vías alrededor de la Unidad Deportiva Atanasio Girardot, con pocas falsas alarmas. Con respecto al concreto, el desempeño es regular, porque en varios sitios de la imagen se confunde con techos. Los techos del coliseo de baloncesto Iván de Bedout y de voleibol Yesid Santos (de los cuales no se trazaron polígonos de entrenamiento).

5.2.2 Institución Educativa CASD

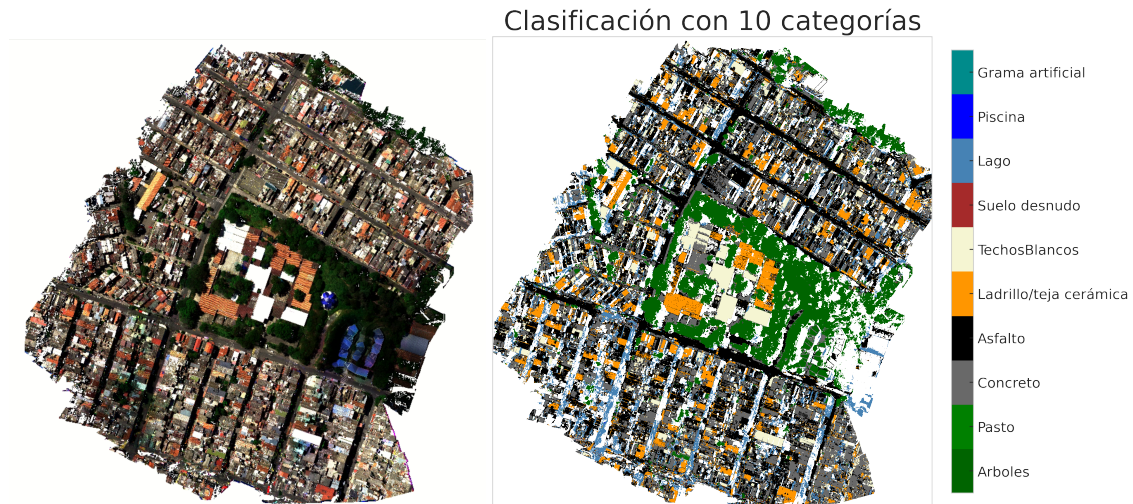


Figura 33. Resultado de la clasificación por umbrales en la Institución Educativa CASD. Izquierda: imagen RGB de la Institución Educativa CASD. Derecha: resultado de la clasificación por umbrales. Fuente: equipo Teledetección con Drones SIATA

En la clasificación con 10 categorías, es posible observar que se da una buena distinción de variedad de objetos. La vegetación (árboles y pastos) son bien identificados dentro y fuera del núcleo de la Institución Educativa CASD. Otra categoría que funciona bien, es la de teja cerámica, pues los elementos cuyas reflectancias son más altas en las longitudes de onda del rojo, rojo de borde e infrarrojo cercano quedan adecuadamente identificados en esta categoría. Los techos blancos, tienen reflectancias altas en todas las longitudes de onda y el algoritmo, en general, lo identifica bien. Hay un buen reconocimiento del asfalto principalmente en las calles, por su parte las falsas alarmas se dan en mayor medida sobre las carreras que son identificadas como cuerpos de agua en lugar de asfalto, atribuible a las sombras en la imagen. No es una imagen muy adecuada para evaluar concreto, porque se desconoce en campo qué está asociado a este tipo de cobertura.

5.2.3 Jardín Botánico Joaquín Antonio Uribe.




Figura 34. Resultado de la clasificación Jardín Botánico Joaquín Antonio Uribe. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación por umbrales. Fuente: equipo Teledetección con Drones SIATA

En la clasificación de 10 categorías, en general el desempeño del algoritmo por umbrales es bueno. Hay reconocimiento de la vegetación sin distinción entre pastos y árboles, el lago fue reconocido como un cuerpo de agua diferente a una piscina y la vía alrededor del Jardín botánico fue clasificado como asfalto con los senderos aledaños como concreto (en campo se observa que son adoquines de concreto). Los pocos techos de teja cerámica/barro son adecuadamente identificados, sin falsas alarmas. Los espacios muy oscuros (sombras entre árboles), no son reconocidas como cobertura.

Los resultados obtenidos empleando la clasificación supervisada basada en el Algoritmo por umbrales, muestra que éste separa de manera adecuada las clases de las coberturas escogidas, sin embargo, hay muchas falsas alarmas principalmente en los cuerpos de agua. Dado que el pasto y los árboles tienen una firma espectral muy similar, se puede mejorar esta clasificación combinando con un modelo de superficie y aplicar criterios adicionales o agregar texturas al algoritmo. Los umbrales de clasificación son altamente susceptibles de ser mejorados, ajustando los rangos de los valores de las reflectancias y adicionalmente aplicando filtros de moda. También es posible mejorar este algoritmo trazando otros polígonos en otras superficies comunes en las imágenes. Este algoritmo tiene la particularidad de ser rápido, poderse implementar completamente en Python y dar como resultado archivos livianos.

Dado que se seleccionan áreas o polígonos y se entrenan para refinar los resultados, este proceso de clasificación es considerado semi-automático.

5.3 Clasificación Supervisada basada en los métodos de clasificador de Máxima Verosimilitud Gaussiana, Random Forest y K-Vecinos más cercanos.

5.3.1 Institución Educativa CASD

Como se mencionó en la metodología, lo primero que se obtuvo fue la composición multispectral del sobrevuelo, como lo muestra la figura 35:



Figura 35. Matriz apilada sobrevuelo, Institución Educativa CASD.

Sobre esta imagen, se trazaron los polígonos de entrenamiento y se identificaron en total 7 superficies:

- Techo de barro/teja
- Techo blanco
- Techo de metal
- Árboles
- Pasto
- Asfalto
- Concreto

Estas superficies se identificaron con la siguiente paleta de colores:

■	Techo de barro/teja
■	Techo blanco
■	Techo de metal
■	Árboles
■	Pastos
■	Asfalto
■	Concreto

Luego, a esta imagen y usando los polígonos de entrenamiento se aplicaron los métodos de clasificación supervisados implementados, y estos fueron los resultados:

Máxima Verosimilitud Gaussiana



Figura 36. Resultado de la clasificación de IECASD utilizando el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB de la Institución Educativa CASD. Derecha: resultado de la clasificación.

Como resultado de esta clasificación se observa un buen reconocimiento de los techos de barro/teja y techos blancos en toda la imagen, sin embargo, respecto a los techos metálicos -o rojos- hay una sobreestimación en toda la imagen, en su gran mayoría mezclada con concreto. El algoritmo tiene dificultades para diferenciar pastos de árboles, de hecho, los árboles los reconoce como pastos mientras que lo que clasifica como árboles no lo son (se trata de techos, en su gran mayoría). Por su parte, las carreras y calles las reconoce adecuadamente en toda su extensión como asfalto, al parecer sin problemas asociados a sombras de la imagen. Puede haber una sobreestimación de concreto, sobre todo al confundirse con los techos metálicos.

Random Forest



Figura 37. Resultado de la clasificación de IECASD utilizando el método de Random Forest. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.

En esta imagen se observa una mejor diferenciación de árboles y pastos alrededor del núcleo central de la Institución Educativa CASD, en comparación con el método de Máxima Verosimilitud Gaussiana. Sin embargo, el algoritmo tiene dificultades con diferenciar árboles de asfalto a lo largo de las carreras, lo anterior, atribuible a la presencia de sombras inherentes a la toma de la imagen. Hay buen reconocimiento de las calles como asfalto, sin presencia de falsas alarmas con otros materiales a lo largo de las calles. Identifica el concreto, con menos sobreestimaciones, si se compara con el Método de Máxima Verosimilitud Gaussiana. Respecto a los techos de barro/teja en la imagen, hay una sobreestimación, adicionalmente una mezcla con falsas alarmas de árboles. La alta reflectancia del blanco, facilita el reconocimiento de los techos de este color en toda la imagen. No hay mezclas tan marcadas entre Techo de metal y concreto, como ocurre con el método de Máxima Verosimilitud Gaussiana. Este método tiene dificultades en el manejo de las sombras en la imagen.

K-Vecinos más cercanos



Figura 38. Resultado de la clasificación de IECASD utilizando el método de K-Vecinos más cercanos. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.

De acuerdo con la imagen, se observa un comportamiento muy similar al obtenido con Random Forest, aunque el método de K-Vecinos más cercanos es casi 1.5 veces más rápido computacionalmente. Respecto a los árboles y la vegetación, los logra separar adecuadamente únicamente en el núcleo central de la Institución Educativa CASD y en el resto de la imagen se confunde con sombras. Es menos sensible para los techos metálicos que el modelo de Random Forest (lo que significa que se mezcla con concreto, aunque de forma menos intensa si se compara con el método de Máxima Verosimilitud Gaussiana). La identificación de techos blancos es más precisa en este algoritmo en comparación con Bosques Aleatorios, pues tiene menos falsas alarmas con otros materiales. Su mayor desventaja, al igual que Bosques Aleatorios, es que exhibe el mismo problema con falsas alarmas que identifica al asfalto de las carreras como árboles.

5.3.2 Jardín Botánico Joaquín Antonio Uribe

Lo primero que se obtuvo fue la composición multispectral del sobrevuelo:




Figura 39. Matriz apilada sobrevuelo Jardín Botánico Joaquín Antonio Uribe.

Sobre esta imagen, se trazaron los polígonos de entrenamiento y se identificaron en total 6 superficies:

- Agua del lago
- Vegetación
- Asfalto
- Techo de teja/barro
- Techo metálico

Estas superficies se identificaron con la siguiente paleta de colores:

	Lago
	Vegetación
	Asfalto
	Techo de teja/barro
	Techo metálico
	Concreto

Luego, a esta imagen y usando los polígonos de entrenamiento se aplicaron los Métodos de Clasificación Supervisados ya mencionados, y estos fueron los resultados:

Máxima Verosimilitud Gaussiana




Figura 40. Resultado de la clasificación del Jardín botánico utilizando el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.

Para esta imagen, no se discretizó la vegetación trazando polígonos diferentes para pastos y árboles, pues en este caso no es de fácil separación ni distinción en la imagen RGB. Teniendo en cuenta lo anterior, se observa una buena identificación de vegetación (árboles) dentro y fuera del jardín botánico, que no da lugar a falsas alarmas o mezclas con otros materiales. Hay una buena clasificación del asfalto y del concreto en los alrededores del perímetro principal del Jardín Botánico, aunque en algunos puntos el concreto está sobreestimado, atribuible a la presencia de sombras que puede ocasionar que el algoritmo confunda la reflectancia del material con la reflectancia de la sombra. El lago se identifica plenamente y sin falsas alarmas en el resto de la imagen, el plancton que flota sobre el lago, el algoritmo lo identifica correctamente como vegetación. Dado la calidad de la imagen en los bordes, es difícil saber si hay sobreestimación del techo de cerámica/barro. Se desconoce el material del que está hecho el orquideorama. No se clasificó el viaducto del metro, por tal razón en la imagen sale como resultado de Techo de teja/barro y concreto.

Random Forest




Figura 41. Resultado de clasificación del Jardín Botánico utilizando el método de Random Forest. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.

En esta clasificación también se da una identificación de la vegetación que está dentro y fuera del Jardín Botánico, sin embargo, tiene mezclas con la categoría de agua del lago, lo que correspondería a una falsa alarma. En comparación con el método de Máxima Verosimilitud Gaussiana, tiene un mejor desempeño identificando el asfalto del concreto, porque las mezclas entre ambos materiales es menor. Respecto a los otros dos métodos (Bosques Aleatorios y K-Vecinos más cercanos), difiere en la identificación del material del que está hecho el orquideorama (que se desconoce cuál es). El algoritmo no muestra sensibilidad a los techos metálicos, pues no identifica otras superficies de este material aparte de la escogida al interior del Jardín Botánico (posiblemente no fueron suficientes los polígonos de entrenamiento trazados). La mayor dificultad del algoritmo está en la categoría del agua de lago, que se sobreestima en toda la imagen y adicionalmente muestra falsas alarmas con otros materiales.

K-Vecinos más cercanos




Figura 42. Resultado de clasificación del Jardín Botánico utilizando el método de K-Vecinos más cercanos. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.

Este método de clasificación también hace una identificación completa de la vegetación dentro y en los alrededores del Jardín Botánico. Al igual que los dos métodos anteriores hay una caracterización del lago, sin embargo, esta clase exhibe falsas alarmas en toda la imagen, aunque en menor medida que el método de Random Forest. La relación concreto/asfalto es mejor que los otros métodos, pues hay menos mezcla de ambos materiales. El material del orquideorama lo identifica como techo metálico, similar a como lo hace el método de Máxima Verosimilitud Gaussiana. La categoría de techos metálicos también es confusa y dado el tamaño de la imagen estimada con el sobrevuelo, es difícil estimar su desempeño.

5.3.3 Unidad Deportiva Atanasio Girardot

Lo primero que se obtuvo fue la composición multispectral del sobrevuelo:




Figura 43. Matriz apilada sobrevuelo UDAG.

Sobre esta imagen, se trazaron los polígonos de entrenamiento y se identificaron en total 8 superficies:

- Pasto
- Pasto sintético
- Árboles
- Asfalto
- Ladrillo (polvo)
- Cubierta metálica
- Agua piscinas
- Concreto

Estas superficies se identificaron con la siguiente paleta de colores:

	Pasto
	Pasto sintético
	Árboles
	Asfalto
	Ladrillo (polvo)
	Cubierta metálica
	Agua piscinas
	Concreto

Luego, a esta imagen y usando los polígonos de entrenamiento se aplicaron los Métodos de Clasificación Supervisados ya mencionados, y estos fueron los resultados:

Máxima Verosimilitud Gaussiana




Figura 44. Resultado de la clasificación de la UDAG con el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB de la UDAG. Derecha: resultado de la clasificación.

Como resultado de esta clasificación se observa una buena identificación del pasto natural de las canchas del Estadio Atanasio Girardot, la pista de atletismo y el diamante de baseball. Además, resalta la identificación del pasto sintético en las canchas Marte 1 y Marte 2, aunque con falsas alarmas en algunas partes de la imagen, que dada la cantidad de elementos presentes en la misma es difícil saber a qué se puede atribuir. Alrededor de la unidad deportiva en la imagen RGB solamente se aprecian árboles, sin embargo, el algoritmo identifica mezcla de pasto y árboles. Respecto al complejo acuático, hay una identificación completa de las piscinas, también con falsas alarmas en el resto de la imagen que pueden

deberse a elementos cuya tonalidad en el azul es muy similar al color que reflejan las piscinas. Las canchas de tenis, de polvo de ladrillo, se identifican bien y sin falsas alarmas en el resto de la imagen. Confusa identificación del concreto, atribuible a pocos polígonos de entrenamiento en esta categoría. La cubierta metálica del coliseo de voleibol y de baloncesto está bien diferenciada en la imagen, aunque con falsas alarmas difícil de determinar a qué se deben.

Random Forest

Para este método no se obtuvo ningún resultado, no se sabe con certeza a qué se debe, es posible que ocurra porque el algoritmo cuando hay muchos elementos o coberturas presentes en la imagen y muy cercanos unos de otros no funciona bien; o algún pixel o conjunto de pixeles le resulta confuso al método y le es imposible asociarlo a un grupo de polígonos de entrenamiento, por lo que entra en un ciclo infinito de procesamiento.

K-Vecinos más cercanos




Figura 45. Resultado de la clasificación de la UDAG con el método de K-Vecinos más cercanos. Izquierda: imagen RGB de la UDAG. Derecha: resultado de la clasificación.

Al igual que en el método de Máxima Verosimilitud Gaussiana, en este método se observa una buena identificación del pasto natural de las canchas del estadio, la pista de atletismo y el diamante de baseball. Adicionalmente, se dio una buena caracterización del pasto sintético de las canchas Marte 1 y Marte 2, aunque con más cantidad de falsas alarmas en comparación con el método de Máxima Verosimilitud Gaussiana. Por su parte hay una identificación completa de las piscinas del complejo acuático y de los canchas de polvo de ladrillo cerámico. Este método reconoce que rodeando la Unidad Deportiva sólo hay árboles

y no pastos, lo que hace que en esta categoría tenga un mejor desempeño que el método Gaussiano. La identificación del concreto en toda la imagen es mala y se confunde con superficies blancas, los malos resultados en esta categoría pudieron deberse a déficit de polígonos de entrenamiento. La cubierta metálica tiene un desempeño general malo, sobre todo porque se confunde con el asfalto en toda la imagen, generando muchas falsas alarmas.

5.3.4 Barrio Tricentenario

Lo primero que se obtuvo fue la composición multispectral del sobrevuelo:




Figura 46. Matriz apilada del sobrevuelo barrio Tricentenario.

Sobre esta imagen, se trazaron los polígonos de entrenamiento y se identificaron en total 7 superficies:

- Árboles
- Pasto
- Asfalto
- Concreto
- Techo de teja/barro
- Techo de fibrocemento
- Techo blanco

Estas superficies se identificaron con la siguiente paleta de colores:

■	Árboles
■	Pasto
■	Asfalto
■	Concreto
■	Techo de teja/barro
■	Techo de fibrocemento
■	Techo blanco

Luego, a esta imagen y usando los polígonos de entrenamiento se aplicaron los Métodos clasificación supervisados ya mencionados, y estos fueron los resultados:

Máxima Verosimilitud Gaussiana



Figura 47. Resultado de la clasificación del barrio Tricentenario con el método de Máxima Verosimilitud Gaussiana. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.

Con este método se da una buena separación entre pastos y árboles en toda la imagen, el asfalto también se reconoce bien, sobre todo a lo largo de la Autopista Norte y la Carrera 64, con algunas falsas alarmas con techo de Fibrocemento (Eternit), que se pueden atribuir a sombras. El desempeño del concreto es difícil de evaluar, porque a la hora de trazar polígonos de entrenamiento no es sencillo identificarlo desde la imagen y para mejores resultados se requeriría trabajo en campo. Los techos de cerámica/barro logran identificarse bien, aunque en algunas partes hay mezclas con techos blancos, que son la categoría con mayor cantidad de falsas alarmas, dado que están sobreestimados.

Random Forest



Figura 48. Resultado de la clasificación del barrio Tricentenario con el método de "Random Forest" o Bosques aleatorios. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.

El desempeño en esta imagen del algoritmo de Bosques aleatorios es muy similar al de Máxima Verosimilitud Gaussiana. Es más sensible a los techos de cerámica/barro porque tiene menos mezclas con otros materiales. También es más sensible al reconocimiento de los techos de fibrocemento, aunque esta clase en particular representa falsas alarmas sobretodo con el asfalto. El desempeño de las categorías árboles y pastos es bueno, pues el algoritmo es capaz de separar unos de otros. Hay una reducción en la sobreestimación de techos blancos, respecto al método Gaussiano. Como se especificó en el anterior algoritmo, es difícil evaluar los resultados para la categoría concreto.

K-Vecinos más cercanos



Figura 49. Resultados de la clasificación del barrio Tricentenario con el método de K-Vecinos más cercanos. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.

El resultado de esta clasificación es muy similar al método de Bosques Aleatorios, sólo difiere en unos pocos píxeles, por lo que no se considera relevante detallar cualitativamente el resultado.

De los resultados obtenidos con los métodos de clasificación supervisada estudiados, fue posible determinar que el modelo de Máxima Verosimilitud Gaussiana, en general, mostró una buena relación entre tiempo computacional y resultados de clasificación. Random Forest, a pesar de ser el que más tiempo consumió, no fue el que obtuvo los mejores resultados, siendo superado en casi todas las categorías por el modelo de K-Vecinos más cercanos. Los tres algoritmos exhiben problemas para diferenciar entre pastos y árboles. La mayor susceptibilidad a falsas alarmas en varias de las categorías se dio en el modelo de Random Forest, en comparación con los otros dos modelos. Se puede afirmar que una primera clasificación usando el modelo de Máxima Verosimilitud Gaussiana puede ser representativa, rápida y útil para el caso de imágenes multiespectrales de alta resolución. Respecto al tiempo de procesamiento o tiempo computacional, fue posible determinar que a mayor número de clases, mayor tiempo computacional, aunque no se observó la misma relación directamente proporcional entre el tiempo computacional y los polígonos de entrenamiento. En promedio el tiempo computacional que tomaba el algoritmo de Máxima Verosimilitud Gaussiana era de 15 minutos, el de Random Forest o Árboles de decisión de 12 horas y el de K-Vecinos más cercanos de 7 horas.

5.4 Clasificación No Supervisada basada en los métodos de ISODATA clustering y K-Means Clustering.

5.4.1 Institución Educativa CASD.

Método ISODATA









Figura 50. Resultado de la clasificación de la IECASD con el método ISODATA. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.

El algoritmo identificó las siguientes categorías:

- Pasto
- Asfalto
- Vegetación
- ¿Techo metálico?
- ¿Reflectancia en el azul?
- Techo de teja/barro

Estas superficies se identifican con la siguiente paleta de colores:

	Pasto
	Asfalto
	Vegetación
	¿Techo metálico?
	¿Reflectancia en el azul?
	Techo de teja/barro

Algunas de las superficies aparecen en signos de interrogación porque fueron el resultado del procesamiento del software y la clasificación se hace al criterio del analizador, pues al ser no supervisada no se cuentan con polígonos de entrenamiento, como en los métodos

supervisados. Luego, en todos los casos no se tiene certeza de cuál fue la clase o superficie que el algoritmo reconoció.

De acuerdo con las clases reconocidas por el analizador, hay una sobreestimación de Techo de teja/barro en toda la imagen, tanto dentro como fuera del núcleo de la Institución Educativa CASD. El algoritmo logra diferenciar Pasto de Vegetación tipo árboles, aunque es la categoría que representa mayor cantidad de falsas alarmas. El algoritmo reconoce adecuadamente el asfalto en las calles mientras que en las carreras el desempeño es pobre, debido a falsas alarmas con vegetación (algo similar a lo que ocurre con los métodos supervisados). El algoritmo identifica, aunque de forma muy limitada, lo que parece estar asociado a techos metálicos y, unos objetos que tienen reflectancia en el azul, los identifica y caracteriza como una superficie.

Método K-Means




Figura 51. Resultado de la clasificación de la IECASD con el método K-Means. Izquierda: imagen RGB de la IECASD. Derecha: resultado de la clasificación.

El algoritmo identificó las siguientes categorías:

- Vegetación
- Techo de teja/barro
- Techo blanco
- ¿Sombras?
- Pasto
- Asfalto

Estas categorías se identificaron con la siguiente paleta de colores:



De acuerdo con la clasificación realizada por el analista, se encontró que el algoritmo tiene un buen desempeño identificando techos blancos, contrario al método ISODATA que no lo hace. Respecto a los techos de cerámica/barro se observa una sobreestimación aunque en menor medida que en el método ISODATA. La distinción entre vegetación y pasto es buena en el centro de la Institución Educativa CASD y en los alrededores (con desempeño muy superior al método ISODATA). El algoritmo es sensible a las sombras, pues las identificó como una de las categorías. Respecto al asfalto, hay una sobreestimación en toda la imagen en contraste con la nula identificación de techos metálicos.

5.4.2 Jardín Botánico Joaquín Antonio Uribe

Método ISODATA




Figura 52. Resultado de la clasificación del Jardín Botánico con el método ISODATA. Izquierda: imagen RGB del Jardín Botánico. Derecha: resultado de la clasificación.

El algoritmo identificó las siguientes categorías:

- Techo metálico
- Vegetación
- Pasto/Vegetación baja

- Asfalto
- Concreto
- Techo de teja/barro

Estas categorías se identificaron con la siguiente paleta de colores:



La clasificación por éste método arrojó una alta sobreestimación de asfalto sumado a falsas alarmas de esta cobertura al interior del Jardín Botánico. Las falsas alarmas pueden deberse a las sombras de los árboles. Hay reconocimiento de asfalto, aunque con un mal desempeño, pues es la categoría con más falsas alarmas y mezclas con otros materiales. Llama la atención que no se identifica el lago como una cobertura distinta y sí como una falsa alarma de asfalto. Al interior del Jardín botánico se reconoce una superficie que el analista identificó como techo de teja/barro, que también se ve en los alrededores y que muestra sobreestimación de este material. Adicionalmente se reconoce una cobertura que correspondería a concreto, asociado a los adoquines del sendero de ingreso al Jardín botánico. En la imagen hay dos tipos de verde, lo que haría pensar que el algoritmo es capaz de diferenciar entre distintas formas de vegetación (pastos y árboles) dentro del Jardín botánico, lo que es difícil de evaluar en la imagen RGB. Otra cobertura que logra identificar es la de techos metálicos, por ejemplo, la estación Universidad y otras lugares en los alrededores.

Método K-Means




Figura 53. Resultado de la clasificación del Jardín botánico con el método K-Means. Izquierda: imagen RGB del Jardín botánico. Derecha: resultado de la clasificación.

El algoritmo identificó las siguientes categorías:

- Asfalto
- Techo metálico
- Concreto
- Techo de barro
- Vegetación
- Pasto/Vegetación baja

Estas categorías se identificaron con la siguiente paleta de colores:

■	Asfalto
■	Techo metálico
■	Concreto
■	Techa de barro
■	Vegetación
■	Pasto/Vegetación baja

De acuerdo a la clasificación obtenida con este método, se observa una sobreestimación de asfalto en toda la imagen, aunque en menor medida que con el método ISODATA. Al interior del Jardín botánico hay falsas alarmas de esta cobertura, pues el algoritmo reconoce como asfalto lo que son árboles y vegetación. Al igual que con el método anterior, no se identifica el lago como una cobertura distinta, sino como una falsa alarma de asfalto. En comparación con ISODATA se reconoce más concreto, aunque mezclado con otra cobertura que el analista

identificó como techo de cerámica/barro. El desempeño de ambas coberturas (concreto y techo de cerámica/barro) es difícil de evaluar, por tener muchos de los elementos en el borde de la imagen. K-Means también plantea que dentro del Jardín botánico hay dos categorías distintas de vegetación, asociadas a pastos y árboles, que como se mencionó anteriormente, es difícil de precisar en la imagen RGB con la que se cuenta. Adicionalmente, hay reconocimiento de lo que parece ser techo metálico, aunque no es posible precisar si se trata de dicho material, porque son algunos píxeles aislados y se requeriría de trabajo adicional en campo.

5.4.3 Unidad Deportiva Atanasio Girardot

No se obtuvieron resultados realizando esta clasificación, se cree que por las mismas razones por las que no se obtuvieron resultados con el método de Random Forest en la clasificación supervisada.

5.4.4 Barrio Tricentenario

Método ISODATA




Figura 54. Resultado de la clasificación del barrio Tricentenario con el método ISODATA. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.

El algoritmo identificó las siguientes categorías:

- Vegetación
- Asfalto
- Pasto
- Techo blanco 1
- Techo de Fibrocemento
- Techo blanco 2
- Techo de teja/barro

Estas categorías se identificaron con la siguiente paleta de colores:

	Vegetación
	Asfalto
	Pasto
	Techo blanco 1
	Techo de Fibrocemento
	Techo blanco 2
	Techo de teja/barro

De acuerdo a la clasificación asignada por el analista, hay una alta sobreestimación de asfalto en toda la imagen, sobretodo en las inmediaciones de los bloques de apartamentos, lo que se puede atribuir a sombras producidas por los árboles y por la altura de los mismos bloques.

Se identifican bien los techos de teja/barro en toda la imagen, con moderada sobreestimación. La separación entre pastos y árboles no es muy clara, por lo que el desempeño en estas categorías es regular. En la imagen RGB se observan techos blancos, que pertenecerían a una misma clase, sin embargo, el algoritmo identifica dos clases de esta cobertura, por eso se les asignó las etiquetas de Techo blanco 1 y Techo blanco 2. Hay reconocimiento de los techos de fibrocemento de los bloques de apartamentos, aunque en ciertas partes de la imagen el algoritmo lo confunde con asfalto, algo similar a lo que ocurre con los métodos supervisados. No identifica el concreto como una categoría o clase adicional.

Método K-Means



Figura 55. Resultado de la clasificación del barrio Tricentenario con el método k-Means. Izquierda: imagen RGB barrio Tricentenario. Derecha: resultado de la clasificación.

El algoritmo identificó las siguientes categorías:

- Vegetación
- Pasto
- Techo blanco 2
- Pasto 2
- Asfalto
- Techo de teja/barro
- Techo de Fibrocemento

Estas categorías se identificaron con la siguiente paleta de colores:



Los resultados de la clasificación usando este método muestran que hay menos sobreestimación de asfalto en toda la imagen en comparación con el método ISODATA, aunque persisten las falsas alarmas por sombras en los alrededores de los bloques de apartamentos. Se observa además que hay una buena identificación de los Techos de teja/barro, con un desempeño similar al método ISODATA. Hay mejor separación entre pastos y árboles y al parecer reconoce vegetación baja (etiquetado como Pasto 2), vegetación media (etiquetado como Pasto) y árboles (etiquetado como Vegetación). El techo blanco se distingue como una sola superficie y no como dos, como ocurre en el método ISODATA. El material de techo de fibrocemento, se reconoce adecuadamente en los bloques de apartamento aunque como ocurre con el algoritmo de ISODATA, se confunde con el asfalto. Adicionalmente, no reconoce al concreto como una de las categorías.

De los resultados obtenidos con los métodos de clasificación no supervisada, se encontró que el desempeño de ambos métodos de clasificación es muy similar y no son tan evidentes las diferencias en el resultado final como en los métodos supervisados, por lo que es difícil asegurar que uno sea mejor que otro. Las clasificaciones no supervisadas son “fáciles y rápidas” en término computacional. Sin embargo, la posterior identificación de las superficies requiere agudeza y tiempo en la observación. El hecho de no tener resultados con ninguno de los algoritmos aplicados a la imagen de la Unidad Deportiva Atanasio Girardot sugiere que ante una alta diversidad de coberturas con firmas espectrales diferentes, los algoritmos se pueden confundir y no arrojar ningún resultado. Con los métodos de clasificación no supervisada implementados, se notó que el tiempo computacional no fue una limitante (como sí ocurrió con los métodos de clasificación supervisados). La clasificación con el método de ISODATA, tuvo una duración promedio de 1 hora, mientras que con el método de K-Means osciló entre 2 y 3 horas.

En la siguiente tabla se muestra la generalización de los resultados obtenidos con los métodos de clasificación supervisados y no supervisados.

Tabla 2. Resumen de los resultados obtenidos con los métodos de clasificación supervisados y no supervisados utilizados en este estudio.

	Máxima Verosimilitud Gaussiana	Random Forest	K-Vecinos más cercanos
Métodos Supervisados	<ul style="list-style-type: none"> - Poco sensible a sombras en la imagen. - Presenta dificultades para diferenciar pastos de árboles. - Sobreestimación en todas las coberturas, especialmente con el asfalto y el concreto, que ocasionalmente los mezcla. - Computacionalmente, fue el método más rápido, tomando en promedio 16 minutos. - En general, buena relación entre tiempo de computación y resultados obtenidos. 	<ul style="list-style-type: none"> - Sensible a sombras en la imagen. - Es más susceptible a falsas alarmas, en comparación con los otros dos métodos. - Buen desempeño para concreto. - Buen resultado separando pastos y árboles. - Problemas con los cuerpos de agua por falsas alarmas. - Computacionalmente fue el método más demandante, tomando entre 10 y 12 horas dependiendo de la imagen. - Los resultados obtenidos NO son proporcionales al tiempo de computación. 	<ul style="list-style-type: none"> - Sensible a sombras en la imagen. - Buen desempeño con elementos blancos. - Buen desempeño con techos metálicos o rojos. - Computacionalmente toma entre 6 y 8 horas, dependiendo de la imagen. - Relación regular entre resultados obtenidos y tiempo de computación (aunque con mejor desempeño que Random Forest).
	ISODATA		K-Means
Métodos no Supervisados	<ul style="list-style-type: none"> - Muy sensible a sombras en la imagen. - No identifica la clase asociada a los cuerpos de agua, la confunde con cualquier otra clase. - Identifica los pastos y árboles como dos coberturas diferentes (ventaja). - Sobreestimación de material cerámico o barro. - Más susceptible a hacer sobreestimaciones de materiales con firma espectral relativamente plana y baja reflectancia, como asfalto o concreto, en comparación con K-Means. - Tiempo computacional promedio de 1 hora. 		<ul style="list-style-type: none"> - Muy sensible a sombras en la imagen - No identifica la clase asociada a los cuerpos de agua, la confunde con cualquier otra clase. - Más sensible que ISODATA en la identificación de pastos y árboles (ventaja). - Sobreestimación de materiales tipo asfalto y concreto. - Sobreestimación de material cerámico o barro, aunque en menos medida que ISODATA - Tiempo computacional promedio entre 2 y 3 horas.
Consideraciones generales	<ul style="list-style-type: none"> - Se identificó en ambos tipos de algoritmos de clasificación que las imágenes con muchos elementos, como la correspondiente a la Unidad Deportiva Atanasio Girardot, pueden confundir los algoritmos y arrojar resultados incoherentes o no arrojar resultados. - Una primera clasificación usando el Modelo de Mezclas Gaussianas puede ser representativa y muy útil para el caso de imágenes multiespectrales de alta resolución. - Los archivos resultantes de la composición no son pesados (alrededor de 150 MB), pero la imagen composición multiespectral .tiff sí lo es (Superior a 2 Gb). - Las clasificaciones No Supervisadas son “fáciles y rápidas” en términos computacionales, sin embargo, la posterior identificación de las superficies requiere agudeza y tiempo en la observación. - En el escenario de tener que escoger entre realizar una clasificación supervisada y no supervisada y que el factor decisivo sea la rapidez, el tiempo y no la calidad del resultado, se optaría por una clasificación no supervisada con el método ISODATA. 		

Discusión

La caracterización de la cobertura terrestre ha sido uno de los objetivos más importantes de la teledetección desde que ésta fue concebida. Dicha caracterización ha sido realizada a partir de imágenes tomadas con variedad de sensores equipados en helicópteros, globos aerostáticos, satélites o pequeños Vehículos Aéreos No Tripulados VANT, más conocidos como drones (Nguyen et al., 2020). En este Trabajo de Grado se encontró que la cámara ALTUM ofrece una buena respuesta, con determinados algoritmos, en la caracterización de la cobertura terrestre y tiene como ventaja una resolución espacial o tamaño de pixel, por debajo del metro; lo que con imágenes de satélites comerciales como Landsat, Sentinel, MODIS, Aster y otros no es posible, pues la resolución de estos es superior a los 10m (Castillo, 2014). Existen resoluciones más finas con otros satélites comerciales, pero no son gratuitas o de libre acceso para el público en general.

Los resultados de las clasificaciones supervisadas y no supervisadas obtenidas con datos de cámara multispectral ALTUM, muestra que ambos tipos de metodologías tienen sus puntos fuertes, débiles y por mejorar. Una primera clasificación, realizada a partir de las firmas espectrales de los elementos más comunes en las imágenes, permitió definir umbrales para la construcción de un algoritmo de clasificación semiautomática, al que solo bastará con ingresarle las imágenes en sus distintas bandas espectrales para obtener el resultado de las coberturas identificadas. Sin embargo, este algoritmo requiere que se refinen los valores de los umbrales, ser nutrido con más información a partir de polígonos de entrenamiento de más superficies e ingresarle información adicional, como variables de textura.

Los algoritmos supervisados en general responden bien a las clasificaciones. El modelo de Máxima Verosimilitud Gaussiana fue el que mostró mejor desempeño; se observó que es menos susceptible a la presencia de sombras y en general distingue bien las coberturas que se le ingresan a partir de los polígonos de entrenamiento, aunque en ocasiones sobreestima o mezcla varios tipos de cobertura, causando un efecto de sal y pimienta, lo que se traduce en ruido en la imagen resultante. El método de Random Forest funcionó bien identificando por separado pastos y árboles, adicionalmente disminuyó las sobreestimaciones y mezclas de concreto y asfalto que mostraba el modelo gaussiano; sus debilidades son la sensibilidad a las sombras, el mal desempeño con los cuerpos de agua -dado que crea falsas alarmas en toda la imagen- y el tiempo computacional es muy elevado y poco proporcional con los resultados que entrega. K-Vecinos más cercanos tuvo un desempeño similar a Random Forest, aunque con menos sobreestimaciones y falsas alarmas en algunas de las clases y mejor identificación de coberturas como elementos blancos o techos metálicos -rojizos-.

Los algoritmos no supervisados tuvieron un desempeño regular. Fueron en general muy susceptibles a las sombras en las imágenes, al punto de recomendar considerarla como una "clase" para ejercicios posteriores. Ambos métodos lograron diferenciar distintos tipos de vegetación (pastos, árboles), aunque K-Means de forma más sensible. ISODATA sobreestimó todas las clases y entregó falsas alarmas atribuibles a sombras. Igualmente, K-Means sobreestimó todas las coberturas, aunque en menor medida que ISODATA.

En general, se observaron mejores resultados con los métodos supervisados en comparación con los métodos no supervisados. Si se está interesado en obtener un primer acercamiento a una clasificación, sin necesidad de mucha precisión y que sea de forma rápida, se recomienda hacerlo con el método ISODATA. Si el interés es también algo rápido, pero más preciso, el método de Máxima Verosimilitud Gaussiana es una buena opción.

De acuerdo con los resultados obtenidos, la mejor alternativa para hacer clasificación de coberturas a partir de datos de cámara multiespectral de alta resolución ALTUM, es el método supervisado de Máxima Verosimilitud Gaussiana, porque a pesar de sobreestimar algunas de las coberturas, es poco sensible a las sombras, identifica las clases asociadas a los polígonos de entrenamiento ingresados y es rápido computacionalmente.

Los resultados comentados en los párrafos anteriores son importantes para muchas aplicaciones como la modelación de inundaciones y cálculos de coeficiente de escorrentía, el análisis del balance de energía superficial en suelos vegetales y sus relaciones con el cambio climático, observación de sequías, monitoreo de cambios de la cobertura y el uso de la tierra como las etapas de desarrollo de la vegetación, inundaciones, ocurrencia de incendios, monitoreo de emisiones de carbono debido a deforestación, degradación forestal, entre otras (Li et al., 2018).

Dado que es posible hacer caracterización de coberturas a partir de imágenes obtenidas con la cámara multiespectral ALTUM, su uso potencial puede ir más allá de la agricultura de precisión -que es su principal uso actualmente- y extenderse a nutrir y/o mejorar las entradas de los modelos de meteorología y micrometeorología urbana y modelos hidráulicos, que típicamente requieren alto detalle en la caracterización de los elementos superficiales y que en muchos casos, por carencia de este detalle, usan datos satelitales en el componente de coberturas. El uso de información de satélite puede dar lugar a subestimaciones o sobreestimaciones de variables ambientales por la resolución del pixel. Para mejorar los pronósticos de las condiciones atmosféricas en un entorno urbano, los procesos de la superficie terrestre deben describirse con precisión mediante el uso de datos detallados sobre el uso y la cobertura del suelo. Lo anterior si se tiene en cuenta que el crecimiento urbano ha acarreado una conversión de usos del suelo, reemplazando las coberturas naturales por superficies construidas, causando así cambios drásticos en las características radiativas, térmicas y aerodinámicas de la superficie terrestre (Guzmán, 2018). Los atributos de dicha superficie condicionan las características de las primeras capas de la atmósfera -ya que allí es donde se dan los intercambios de masa, momentum y energía- (Guzmán, 2018). Las superficies activas que componen el sistema urbano consisten en un rango de estructuras que tienen unas características climáticas que pueden agruparse así (Oke, 1988):

- **Radiativas:** geometría, absorptividad, reflectividad, transmisividad y emisividad.
- **Térmicas:** calor específico, capacidad térmica, conductividad térmica, difusividad térmica, admitancia térmica.
- **Relaciones con humedad:** capacidad de intercepción y almacenamiento, permeabilidad, naturaleza química, características estomáticas.
- **Aerodinámicas:** rugosidad, porosidad, zero-plane displacement.

En este Trabajo de Grado se encontró que una buena resolución espacial de una imagen multiespectral -como la tomada con la cámara ALTUM-, repercutirá en una mejor caracterización y clasificación de la cobertura a escala espacial reducida. Conocer con mayor certeza dichas coberturas en una escala urbana, permitiría nutrir los modelos meteorológicos a escala local con dicha información, lo que podría impactar principalmente las siguientes entradas (Li et al., 2018):

Temperatura superficial: los cambios en la cobertura del suelo provocan modificaciones en las propiedades físicas del terreno, como el albedo, que modifican la temperatura cercana a la superficie, así como las temperaturas máximas y mínimas diarias. El albedo junto con la emisividad impactan la emisión de radiación de onda larga (Guzmán, 2018; Li et al., 2018).

Para la temperatura, los cambios en el albedo, la cantidad de radiación incidente, el calor sensible y latente son los principales contribuyentes. En una clasificación más detallada, las áreas edificadas alterarán las características térmicas, radiativas, de permeabilidad y las vías de humedad, lo que agregará energía adicional a la región o substraerá la cantidad de radiación de onda larga emitida. La reducción de la vegetación y el suelo en las áreas urbanas disminuirá la evapotranspiración y su calor latente asociado. Esto mantendrá el calor en el suelo lo que provocará que la temperatura mínima diaria aumente debido a la reducción de uno de los mecanismos por los que el suelo pierde calor. La modificación del albedo en los modelos meteorológicos a escala urbana, producirá cambios en la cantidad de energía reflejada (y por ende la porción absorbida), afectando la cantidad de intercambio de calor entre la superficie y la atmósfera (López-Espinoza et al., 2020)

Velocidad del viento: en una clasificación de coberturas que permita distinguir más allá de superficies -y además sus posibles formas-, la velocidad del viento en un modelo para cobertura urbana mejor detallada disminuirá porque la altura de los edificios urbanos suele ser superior a la de la vegetación, lo que aumenta la rugosidad de la superficie, dificultando la circulación del aire y disminuyendo la velocidad del viento. Por ejemplo, en áreas donde la cobertura ingresada previamente al modelo eran pastos, la urbanización aumentará la fricción. Por otro lado, en regiones donde la cobertura anterior era bosques y ya son pastos, la fricción puede disminuir, dependiendo del tipo de bosque y las características promedio de la construcción (por ejemplo, la altura de las edificaciones). Esto es importante para que el modelo comience a identificar zonas de convergencia o divergencia, en donde se puedan comenzar a formar precipitaciones (Li et al., 2018; López-Espinoza et al., 2020)

Precipitación: los impactos de una cobertura del suelo detallada sobre la precipitación son complejas de precisar. Las modificaciones en la precipitación son más difíciles de atribuir a una causa, ya que varias escalas espaciales están involucradas en los procesos que conducen a cambios en la lluvia. La urbanización induce una serie de cambios complejos en la rugosidad de la superficie de la tierra, la humedad del suelo y el intercambio de agua y energía entre la tierra y la atmósfera. Estos cambios pueden compensarse o mejorarse entre sí y complicar los patrones espaciales de precipitación. En la incorporación de una superficie con mejor caracterización de la cobertura, los microclimas pueden verse modificados porque en la

urbanización la convección térmica local aumenta y modifica los patrones de circulación a pequeña escala. Además, los cambios en la circulación local también contribuyen a modificar la distribución espacial de la precipitación en modelos regionales (López-Espinoza et al., 2020).

Luego, es posible afirmar que una cobertura más detallada, como entrada a un modelo de micrometeorología a escala urbana, impactará de forma importante los datos de salida de un modelo atmosférico urbano.

Otra aplicación importante de la caracterización de las coberturas de la superficie, mencionada anteriormente, es en el campo de la modelación hidráulica, específicamente lo que tiene que ver con **manchas de inundación**.

Una mancha de inundación es un área de superficie adyacente a ríos o quebradas, sujeta a inundaciones recurrentes (Navas & del Jesus, 2017). Esta área es cambiante a lo largo del tiempo y debe ser evaluada con relativa frecuencia para precisar la manera en que puede afectar o verse afectada por el entorno. En términos de gestión del riesgo es importante proporcionar a los planificadores y a las instituciones de manejo de desastres una metodología práctica y costo-efectiva para identificar áreas susceptibles y evaluar el impacto del desastre.

Para la identificación y trazado de las manchas de inundación se necesita información de campo, que incluye una fotografía del terreno y el Modelo de Elevación Digital o DEM -por sus siglas en inglés-.




Figura 56. Aerofotografía y Modelo de Elevación Digital obtenido desde cámara adaptada a un dron, sector La Harenala, Itagüí. Material proporcionado por el equipo de Hidrología de SIATA.

Para realizar la modelación, que en SIATA el equipo de hidrología lo hace en el software de libre acceso y gratuito IBER, se deben tener en cuenta algunas consideraciones como:

- Dominio de la simulación: el proceso interno del modelo consiste en la solución de las ecuaciones que dictan cómo es el movimiento del agua ante ciertas circunstancias (inclinación del terreno, cantidad de agua, obstáculos, etc). Al modelo se le ingresa

un espacio que no sea exageradamente grande, pues si bien la información resultante podría ser de utilidad, el proceso sería mucho más lento.

- Uso y cobertura del suelo: el flujo del agua se ve condicionado al tipo de superficie por el que se desplaza; una superficie más rugosa hará que el agua se desplace con mayor dificultad que una superficie lisa. Quien realice la simulación debe definir a qué tipo de superficie corresponde aquella por donde podría circular el agua del dominio, por ejemplo, el río, las calles y algunos sectores con vegetación dispersa.
- Escenario de la simulación: se debe definir cómo y por dónde se quiere que ingrese el agua al dominio, para así ver cómo se comportaría según los parámetros definidos con anterioridad. En este sentido, debe plantearse un caso de caudal que podría presentarse en la realidad, pues lo que se pretende es encontrar el nivel que ocasiona un desbordamiento del río o quebrada.
- Mallado: la solución de las ecuaciones se realiza en las intersecciones de una malla. La malla la define quien realiza la modelación y mientras más fina sea, más ecuaciones debe resolver el modelo, por lo que más tiempo tomará el procesamiento. Debe escogerse una malla que permita obtener detalles suficientes pero que tome un tiempo moderado para resolverse.

El siguiente mapa muestra las categorías escogidas para uso y cobertura del suelo y los polígonos trazados de dichas categorías. Se usaron: río, vegetación dispersa y hormigón (concreto).



Figura 57. Polígonos trazados de superficies para ingresar al modelo de inundación. Sector La Harenala, Itagüí. Material proporcionado por el equipo de Hidrología de SIATA.

El resultado de la mancha de inundación que se obtiene con el modelo luce como la siguiente imagen; el calado se refiere a la profundidad que alcanzaría el nivel del agua en los sitios donde haya inundación:




Figura 58. Mancha de inundación de un tramo de la Quebrada La Harenala, Itagüí. Material proporcionado por el equipo de Hidrología de SIATA.

Como se mencionó anteriormente, para la construcción de una mancha de inundación se requiere la topografía del lugar -para precisar, por ejemplo, la dirección del flujo del agua- y una aerofoto. En el Valle de Aburrá muchas quebradas pasan cerca a zonas urbanizadas o son invadidas en su cauce natural por las comunidades; determinar estas características tan particulares desde imágenes satelitales o de sitios como Google Earth resulta muy complejo, porque la resolución de estas imágenes no es suficiente para el nivel de detalle requerido, sumado a que es muy difícil estimar el recorrido de los cauces. Las imágenes tomadas desde sensores equipados en drones son una muy buena alternativa para solucionar el inconveniente del detalle, además de tener la facilidad de poder ser tomadas con variedad de cámaras como la RGB o la multiespectral y en un solo vuelo.

Adicionalmente, como se mencionó anteriormente el modelo requiere que se ingresen usos/coberturas del suelo y que mientras más preciso sea lo que se ingrese en este aspecto, mejor será el resultado final de la mancha de inundación. Es posible entonces crear los insumos de coberturas para el modelo hidráulico derivado de la toma de datos con la cámara multiespectral y hacer uso de la clasificación semiautomática o de un algoritmo supervisado como Máxima Verosimilitud Gaussiana, algoritmo que mostró ser el más costo efectivo en términos de computación y la precisión de sus resultados. Actualmente la clasificación de las coberturas las hace el analista, imagen por imagen, “a ojo” y generalizando las coberturas en muchos casos, lo que sacrifica precisión a los resultados del modelo.

Conclusiones y trabajos futuros

La teledetección, como muchas de las ramas de las ciencias ambientales, ha evolucionado de forma importante en los últimos años y con la incorporación de sensores a Vehículos Aéreos No Tripulados -VANT- ha logrado incursionar en la obtención de datos de mejor resolución y menores costos.

La cámara multispectral ALTUM de alta resolución, originalmente pensada para labores de agricultura de precisión, también resulta útil en la clasificación de coberturas presentes en las imágenes. Como su resolución es muy superior -50 cm- a la resolución de los satélites convencionales usados en teledetección, el tiempo computacional de procesamiento de los datos es alto.

En este Trabajo de Grado se abordaron distintos métodos disponibles para realizar clasificación de coberturas o elementos a partir de un sensor multispectral de alta resolución. La clasificación semiautomática basada en las firmas espectrales arrojó un buen desempeño en algunas de las categorías y mostró que es susceptible a ser refinada, bien sea trazando más polígonos de entrenamiento en otras superficies, aplicando filtros de moda, agregando texturas o acotando aún más los umbrales de reflectancia.

La clasificación supervisada en general funcionó bien para algunas de las categorías y para otras mostró falsas alarmas o sobreestimación de alguna de las coberturas. Adicionalmente, se observó que para este tipo de datos, el tiempo computacional no fue directamente proporcional a un mejor desempeño del método utilizado, puesto que el algoritmo de Random Forest tomaba en promedio 12 horas y su desempeño cualitativo no era mejor que el método de Máxima Verosimilitud Gaussiana que tomaba 15 minutos. En general, con la clasificación semiautomática y los métodos supervisados se encontró que las imágenes de muy alta resolución conducen a un aumento de la varianza intraclase y a la disminución de la varianza interclase (Han et al., 2020)

Los métodos de clasificación no supervisada fueron en general más susceptibles a la presencia de sombras, falsas alarmas y sobreestimación de alguna cobertura que los métodos de clasificación supervisada. El resultado de estos métodos depende en gran medida de la cantidad de clústeres que el analista desee incorporar en su clasificación y del número de iteraciones por método. Los resultados obtenidos con la clasificación supervisada fueron regulares, aunque útiles si no se dispone de mucho tiempo o si lo que se quiere tener es una -visión general- de las coberturas.

Un reto importante en el uso de la alta resolución espacial para la cartografía urbana detallada, proviene del alto nivel de la variabilidad espectral intraclase, como los tejados de algunos edificios y el bajo nivel de variabilidad espectral interclase, como los cuerpos de agua y las sombras. Es por esto que los algoritmos tradicionales de clasificación basados en píxeles, como los usados en este Trabajo de Grado, pueden cometer fácilmente errores de clase y generar el efecto de sal y pimienta, es decir, que manchas de color más o menos homogéneas se encuentren salpicadas por píxeles asignados a otras categorías (Benediktsson et al., 2013), lo que puede reducir la precisión de la clasificación para las imágenes de muy alta resolución. Con este tipo de imágenes las sombras son uno de los grandes inconvenientes, porque a pesar de tomarse las precauciones y seguir las

recomendaciones del fabricante a la hora de tomar los datos en el sobrevuelo, es muy difícil garantizar que no estarán presentes.

Contar con cámaras multiespectrales de alta resolución adaptables a drones en un territorio como el Valle de Aburrá promueve la investigación científica y aporta valiosa información en temas ambientales, como es el caso de mejorar las coberturas de entrada a un modelo meteorológico de microescala o de un modelo hidráulico para precisar de una salida de un modelo de mancha de inundación más cercana a la realidad, lo que finalmente repercutirá en una mejor gestión de riesgo.

Respecto a esta investigación se pueden derivar varios trabajos futuros. Lo primero sería refinar los resultados trazando polígonos de entrenamiento en otro tipo de coberturas para nutrir la clasificación semiautomática basada en umbrales. Otro aporte importante sería calcular matrices de confusión para visualizar el desempeño cuantitativo de los algoritmos supervisados y no supervisados.

Se puede probar además hacer clasificación con otro tipo de métodos como el Vector de Máquinas Soporte, Redes neuronales; adicionalmente ver qué pasa si se agregan texturas a la imagen, Modelos de elevación, entre otras cosas.

Finalmente, es importante aclarar que para la mejora continua de los resultados, es necesario la validación en campo y/o la retroalimentación continua de la superficie real.

Referencias

- Abbas, A., Minallh, N., & Ahmad, N. (2016). *K-Means and ISODATA Clustering Algorithms for landcover Classification Using Remote Sensing*. 48(2), 315–318.
- Actalianza. (2018). *Hacia la implementación ambiciosa del Acuerdo de París*.
https://www.preventionweb.net/files/submissions/59502_spanishndctoolkitnationaladvocacy.pdf
- Al-doski, J., Mansor, S. B., Zulhaidi, H., & Shafri, M. (2013). *Image Classification in Remote Sensing*. 3(10), 141–148.
- Aldana, Y. A. (2020). Drones y procesamiento de imágenes, una alternativa a la erradicación de malezas. *Indagare*, 8. <https://doi.org/10.35707/indagare/821>
- Benediktsson, J. A., Chanussot, J., & Moon, W. M. (2013). Advances in very-high-resolution remote sensing [Scanning the Issue]. *Proceedings of the IEEE*, 101(3), 566–569. <https://doi.org/10.1109/JPROC.2012.2237076>
- Castillo, L. (2014). La teledetección directa por satélites y la solución de controversias. *Enl@ce: Revista Venezolana de Información, Tecnología y Conocimiento*, 11(1), 89–96.
- Cheng, F. Y., & Byun, D. W. (2008). Application of high resolution land use and land cover data for atmospheric modeling in the Houston-Galveston metropolitan area, Part I: Meteorological simulation results. *Atmospheric Environment*, 42(33), 7795–7811. <https://doi.org/10.1016/j.atmosenv.2008.04.055>
- Colkesen, I., & Kavzoglu, T. (2017). Ensemble-based canonical correlation forest (CCF)

- for land use and land cover classification using sentinel-2 and Landsat OLI imagery. *Remote Sensing Letters*, 8(11), 1082–1091.
<https://doi.org/10.1080/2150704X.2017.1354262>
- Congalton, R. G. (2015). Remote Sensing and Image Interpretation. 7th Edition. In *Photogrammetric Engineering & Remote Sensing* (Vol. 81, Issue 8).
<https://doi.org/10.14358/pers.81.8.615>
- Enderle, D. I., Weih Jr, R. C., Jr, R. C., IMenderle, D., & Weih Jr, R. C. (2005). Integrating Supervised and Unsupervised Classification Methods to Develop a More Accurate Land Cover Classification. *Journal of the Arkansas Academy of Science*, 59, 10.
<http://scholarworks.uark.edu/jaashttp://scholarworks.uark.edu/jaas/vol59/iss1/10>
- Franzini, M., Ronchetti, G., Sona, G., & Casella, V. (2019). Geometric and radiometric consistency of parrot sequoia multispectral imagery for precision agriculture applications. *Applied Sciences (Switzerland)*, 9(24).
<https://doi.org/10.3390/app9245314>
- Gopinath, R. A., & Heights, Y. (1997). *Maximul Likeligood Modeling with Gaussian distributions for classification*. 1–4. papers3://publication/uuid/752955EB-E90D-48F8-8160-7FBF4FCA5BC7
- Guzmán, G. (2018). *Análisis de la influencia del diseño urbano en la meteorología del Valle de Aburrá*. 144.
- Han, R., Liu, P., Wang, G., Zhang, H., & Wu, X. (2020). Advantage of combining ObiA and classifier ensemble method for very high-resolution satellite imagery classification. *Journal of Sensors*, 2020. <https://doi.org/10.1155/2020/8855509>
- Hernández, J. (2011). Procesamiento digital de imágenes. In *Percepción Remota* (Vol. 2007). <http://www.gep.uchile.cl/Publicaciones/Tratamiento Digital de Imágenes - Jaime Hernández 2011.pdf>
- Horning, N. (2010). Random Forests: An algorithm for image classification and generation of continuous fields data sets. *International Conference on Geoinformatics for Spatial Infrastructure Development in Earth and Allied Sciences 2010*, 1–6.
- Hutton, J. J., Lipa, G., Baustian, D., Sulik, J., & Bruce, R. W. (2020). High accuracy direct georeferencing of the altum multi-spectral uav camera and its application to high throughput plant phenotyping. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 43(B1), 451–456.
<https://doi.org/10.5194/isprs-archives-XLIII-B1-2020-451-2020>
- Kim, J., Kim, B.-S., & Savarese, S. (2012). Comparing Image Classification Methods: K-Nearest-Neighbor and Support-Vector-Machines. *Applied Mathematics in Electrical and Computer Engineering*, 133–138.
- Kotthaus, S., Smith, T. E. L., Wooster, M. J., & Grimmond, C. S. B. (2014). Derivation of an urban materials spectral library through emittance and reflectance spectroscopy. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94, 194–212.
<https://doi.org/10.1016/j.isprsjprs.2014.05.005>
- Li, J., Zheng, X., Zhang, C., & Chen, Y. (2018). Impact of land-use and land-cover change on meteorology in the Beijing-Tianjin-Hebei region from 1990 to 2010. *Sustainability (Switzerland)*, 10(1). <https://doi.org/10.3390/su10010176>
- López-Espinoza, E. D., Zavala-Hidalgo, J., Mahmood, R., & Gómez-Ramos, O. (2020). Assessing the impact of land use and land cover data representation on weather forecast quality: A case study in central mexico. *Atmosphere*, 11(11), 11–13.
<https://doi.org/10.3390/atmos11111242>

- Lynch, P., Blesius, L., & Hines, E. (2020). Classification of urban area using multispectral indices for urban planning. *Remote Sensing*, *12*(15).
<https://doi.org/10.3390/RS12152503>
- Madawalagama, S. L., Munasinghe, N., Dampegama, S. D. P. J., & Samarakoon, L. (2016). Low cost aerial mapping with consumer-grade drones. *37th Asian Conference on Remote Sensing, ACRS 2016*, *3*(June), 2309–2316.
- Martínez Vega, J., & Martín Isabel, M. P. (2010). Teledetección y Medio Ambiente. *Red Nacional de Teledetección Ambiental*, 208.
- Mobley, C. D. (1999). *Estimation of the remote-sensing reflectance from above-surface measurements*.
- Momeni, R., Aplin, P., & Boyd, D. S. (2016). Mapping complex urban land cover from spaceborne imagery: The influence of spatial resolution, spectral band set and classification approach. *Remote Sensing*, *8*(2). <https://doi.org/10.3390/rs8020088>
- Navas, S., & del Jesus, M. (2017). Análisis del riesgo de inundación mediante técnicas estadísticas avanzadas. *V Jornadas de Ingeniería Del Agua.*, 24–26.
<http://www.ingenieriadelagua.com/2004/JIA/Jia2017/wp-content/uploads/ponencias/posters/va10.pdf>
- Nguyen, L. H., Joshi, D. R., Clay, D. E., & Henebry, G. M. (2020). Characterizing land cover/land use from multiple years of Landsat and MODIS time series: A novel approach using land surface phenology modeling and random forest classifier. *Remote Sensing of Environment*, *238*(November 2018), 111017.
<https://doi.org/10.1016/j.rse.2018.12.016>
- Oke, T. R. (1988). The urban energy balance. *Progress in Physical Geography*, *12*(4), 471–508. <https://doi.org/10.1177/030913338801200401>
- Parody, A., & Zapata, E. de J. (2018). Agricultura De Precisión En Colombia Utilizando Teledetección De Alta Resolución. *Suelos Ecuatoriales*, *48*(1 y 2), 41–49.
http://unicauca.edu.co/revistas/index.php/suelos_ecuatoriales/article/view/94
- Pérez, C., & Muñoz, Á. (2006). *Teledetección: Nociones y Aplicaciones*.
- Qian, Y., Zhou, W., Nytch, C. J., Han, L., & Li, Z. (2020). A new index to differentiate tree and grass based on high resolution image and object-based methods. *Urban Forestry and Urban Greening*, *53*(March), 126661. <https://doi.org/10.1016/j.ufug.2020.126661>
- Rosenqvist, Å., Milne, A., Lucas, R., Imhoff, M., & Dobson, C. (2003). A review of remote sensing technology in support of the Kyoto Protocol. *Environmental Science and Policy*, *6*(5), 441–455. [https://doi.org/10.1016/S1462-9011\(03\)00070-4](https://doi.org/10.1016/S1462-9011(03)00070-4)
- Sulla-Menashe, D., Gray, J. M., Abercrombie, S. P., & Friedl, M. A. (2019). Hierarchical mapping of annual global land cover 2001 to present: The MODIS Collection 6 Land Cover product. *Remote Sensing of Environment*, *222*(November 2018), 183–194.
<https://doi.org/10.1016/j.rse.2018.12.013>
- Tang, L., & Shao, G. (2015). Drone remote sensing for forestry research and practices. *Journal of Forestry Research*, *26*(4), 791–797. <https://doi.org/10.1007/s11676-015-0088-y>
- Ustuner, M., Sanli, F. B., & Dixon, B. (2015). Application of support vector machines for landuse classification using high-resolution rapideye images: A sensitivity analysis. *European Journal of Remote Sensing*, *48*, 403–422.
<https://doi.org/10.5721/EuJRS20154823>
- Vasilakos, C., Kavroudakis, D., & Georganta, A. (2020). Machine learning classification ensemble of multitemporal Sentinel-2 images: The case of a mixed mediterranean

- ecosystem. *Remote Sensing*, 12(12). <https://doi.org/10.3390/rs12122005>
- Xu, Y., Du, B., Zhang, L., Cerra, D., Pato, M., Carmona, E., Prasad, S., Yokoya, N., Hansch, R., & Le Saux, B. (2019). Advanced multi-sensor optical remote sensing for urban land use and land cover classification: Outcome of the 2018 ieeegrss data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(6), 1709–1724. <https://doi.org/10.1109/JSTARS.2019.2911113>
- Yuste Martín, R., Vargas Velasco, N., & Moya Hernández, J. (2013). Teledetección Ambiental de Alta Resolución mediante aplicación de Vehículos Aéreos No Tripulados. *Sociedad Española de Ciencias Forestales*, 22. <http://dx.doi.org/10.1016/j.cirp.2016.06.001><http://dx.doi.org/10.1016/j.powtec.2016.12.055><https://doi.org/10.1016/j.ijfatigue.2019.02.006><https://doi.org/10.1016/j.matlet.2019.04.024><https://doi.org/10.1016/j.matlet.2019.127252><http://dx.doi.org/10.1016/j.cirp.2016.06.001>
- Zeferino, L. B., Souza, L. F. T. de, Amaral, C. H. do, Fernandes Filho, E. I., & Oliveira, T. S. de. (2020). Does environmental data increase the accuracy of land use and land cover classification? *International Journal of Applied Earth Observation and Geoinformation*, 91(May), 102128. <https://doi.org/10.1016/j.jag.2020.102128>
- Zhao, W., Du, S., & Emery, W. J. (2017). Object-Based Convolutional Neural Network for High-Resolution Imagery Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(7), 3386–3396. <https://doi.org/10.1109/JSTARS.2017.2680324>