CLASIFICACIÓN DE UNA NUBE DE PUNTOS DE ALTA DENSIDAD PARA LA IDENTIFICACIÓN DE VEGETACIÓN MEDIANTE UN ENFOQUE INTEGRADO



TESIS DE PREGRADO

Presentado por:

Dayana Lizeth Gomez Pedraza

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS
FACULTAD DE MEDIO AMBIENTE Y RECURSOS NATURALES
PROYECTO CURRICULAR DE INGENIERÍA TOPOGRÁFICA
BOGOTÁ D.C., COLOMBIA
9 FEBRERO

CLASIFICACIÓN DE UNA NUBE DE PUNTOS DE ALTA DENSIDAD PARA LA IDENTIFICACIÓN DE VEGETACIÓN MEDIANTE UN ENFOQUE INTEGRADO

Presentado por:

Dayana Lizeth Gomez Pedraza

Director:

ING. MSC WILLIAM BARRAGÀN ZAQUE

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS
FACULTAD DE MEDIO AMBIENTE Y RECURSOS NATURALES
PROYECTO CURRICULAR DE INGENIERÍA TOPOGRÁFICA
BOGOTÁ D.C., COLOMBIA

9 FEBRERO

Resumen

En este documento se presenta la validación de una nube de puntos generada mediante un levantamiento topográfico aéreo realizado con un vehículo aéreo no tripulado (UAV), inicialmente se generó un orto mosaico de alta resolución y georreferenciado para la validación visual de clasificación y proporciono un contexto geoespacial detallado de la zona de estudio.

La investigación se enfoca en la comparación de metodologías de clasificación de información en áreas con diferentes niveles de densidad vegetal: baja, media y alta. Como referencia, se empleó una clasificación manual de los elementos presentes en la nube de puntos, lo que permitió evaluar la precisión y consistencia de los resultados obtenidos mediante diez iteraciones basadas en métodos de aprendizaje profundo (Deep Learning) y reglas heurísticas. Los resultados incluyen una nube de puntos clasificada según las características del área de estudio, análisis estadístico detallado y la integración del orto mosaico como herramienta de validación y documentación, los cuales se describen en la sección metodológica del documento.

Palabras claves: Vehículo aéreo no tripulado, nubes de puntos, LiDAR, Clasificación, métodos de clasificación, Orto mosaico, validación de datos.

Abstract

This paper presents the validation of a point cloud generated by an aerial topographic survey conducted with an unmanned aerial vehicle (UAV), initially generating a high- resolution ortho-mosaic and georeferenced for visual validation of classification and providing a detailed geospatial context of the study area.

The research focuses on the comparison of information classification methodologies in areas with different levels of vegetation density: low, medium and high. As a reference, a manual classification of the elements present in the point cloud was used to evaluate the accuracy and consistency of the results obtained through ten iterations based on deep learning methods and heuristic rules. The results include a point cloud classified according to the characteristics of the study area, detailed statistical analysis and the integration of the ortho mosaic as a validation and documentation tool, which are described in the methodological section of the document.

Keywords: Unmanned aerial vehicle, Lidar, point clouds, Classification, Ortho Mosaic, classification métodos, data validation.

Tabla de contenido

1. Introducción 11
2. Planteamiento del problema 12
3. Justificación 13
4. Objetivos 14
   4.1. General 14
   4.2. Específicos 14
5. Marco teórico y estado del arte 15
   5.1. Marco teórico 15
      5.1.1. Vegetación Urbana 15
      5.1.2. LiDAR 15
      5.1.3. Ecuación LiDAR 16
      5.1.4. Nube de puntos 16
   5.2. Estado del arte 18
      5.2.1. Aprendizaje automático 18
      5.2.2. Red neuronal convolucional 19
      5.2.3. Algoritmo heurístico 20
      5.2.4. Algoritmo PointNet 20
      5.2.5. Arquitectura de PointNet 20
      5.2.6. Análisis de geometría 22
6. Materiales y método de estudio 23
   6.1. Área de estudio 23
   6.1.1. Datos 25
   6.1.2. Fotografías aéreas 25
   6.1.3. Levantamiento topográfico con vehículo aéreo no tripulado 25
6.2. Métodos 26
   6.2.1. Procesamiento preliminar 27
      6.2.2. Fase 1 Procesamiento de datos GNSS: 27
      6.2.3. Etapa 2. Creación de un Orto mosaico 28
      6.2.4. Procedimiento empleado 30
   7. Procesamiento 32
   7.1. Fase 1. Preparación de la información 32
   7.2. Fase 2 Aplicación de clasificación. 35

7.2.1. Algoritmo en Point Net 35
7.2.2. Clasificación - Regla heurística 42
8. Análisis estadístico 50
8.2. Clasificación de nube de puntos 50
8.2.1. Método regla heurístico 50
8.2.2. Método Algoritmo Point Net 61
8.3. Resultados estadísticos 71
9. Conclusiones 76
10. Bibliografía 77

Tabla de ilustraciones

Ilustración 1 Captura de Datos LiDAR. 15
Ilustración 2 Métodos de clasificación. 17
Ilustración 3. Arquitectura de aprendizaje profundo. 18
Ilustración 4. Ámbito de Deep Learning. 19
Ilustración 5. Arquitectura de Point Net. 22
Ilustración 6. Universidad Distrital Sede Aduanilla de Paiba. 23
Ilustración 7. Plano arquitectónico de la sede Aduanilla de Paiba. 24
Ilustración 8 Datos de la base recolectora. 26
Ilustración 9. Metodología de la investigación. 27
Ilustración 10. Creación de Orto mosaico. 28
Ilustración 11. Parámetros de alineación de fotos. 29
Ilustración 12. Parámetros de Modelo digital de superficie. 29
Ilustración 13. Orto Mosaico de la zona de estudio. 30
Ilustración 14. Diagrama de metodología empleada. 31
Ilustración 15. Categorización de las zonas con baja y alta densidad de vegetación. 33
Ilustración 16. Visualización de datos Lidar en el software Qt Modeler de áreas con baja densidad de vegetación. 33
Ilustración 17. Visualización de datos Lidar en el software Qt Modeler de áreas con alta densidad de vegetación. 34
Ilustración 18. Visualización de nube de puntos en el software MicroStation y verificación de pendiente. 34
Ilustración 19. Visualización de la zona de estudio en el software Visión Lidar. 35
Ilustración 20. Modelo digital de elevación. 36
Ilustración 21. Clasificación automática de nube de puntos 37
Ilustración 22. Interfaz de parámetros de iteración. 38
Ilustración 23. Resultado de la primera clasificación manual de la nube de puntos. 39
Ilustración 24. Resultado de la segunda clasificación manual de la nube de puntos. 40
Ilustración 25. Resultado de la tercera clasificación manual de la nube de puntos. 40
Ilustración 26. Resultado de la cuarta clasificación manual de la nube de puntos. 41
Ilustración 27. Resultado de la quinta clasificación manual de la nube de puntos. 41
Ilustración 28. Clases de clasificación en el método heurístico. 42
Ilustración 29. Clasificación de suelo. 43
Ilustración 30. Parámetros de clasificación de suelo. 44
Ilustración 31. Clasificación de la nube de puntos en la categoría suelo y vegetación. 46
Ilustración 32. Resultado de la primera clasificación según criterio de continuidad. 48
Ilustración 33. Resultado de la segunda clasificación según criterio de continuidad. 48
Ilustración 34. Resultado de la tercera clasificación según criterio de continuidad. 49
Ilustración 35. Resultado de la cuarta clasificación según criterio de continuidad. 49
Ilustración 36. Resultado de la quinta clasificación según criterio de continuidad. 50
Ilustración 37. Resultado de clasificación primera en categorìa baja vegetaciòn. 51
Ilustración 38. Resultado de clasificación segunda en categoría baja vegetación. 52
Ilustración 39. Resultado de clasificación tercera en categoría baja vegetación. 52
Ilustración 40. Resultado de clasificación cuarta en categoría baja vegetación. 53
Ilustración 41. Resultado de clasificación quinta en categoría baja vegetación. 54
Ilustración 42. Resultado de clasificación primera en categoría media vegetación. 55
Ilustración 43 Resultado de clasificación segunda en categoría media vegetación. 55
Ilustración 44. Resultado de clasificación tercera en categoría media vegetación. 56
Ilustración 45. Resultado de clasificación cuarta en categoría media vegetación. 56

Ilustración 46. Resultado de clasificación quinta en categoría media vegetación. 57
Ilustración 47. Resultado de la primera clasificación en categoría de alta vegetación. 58
Ilustración 48. Resultado de la segunda clasificación en categoría de alta vegetación. 58
Ilustración 49. Resultado de la tercera clasificación en categoría de alta vegetación. 59
Ilustración 50. Resultado de la cuarta clasificación en categoría de alta vegetación. 60
Ilustración 51. Resultado de la quinta clasificación en categoría de alta vegetación. 60
Ilustración 52. Resultado de primera clasificación en categoría baja vegetación..... 61
Ilustración 53 Resultado de segunda clasificación en categoría baja vegetación. 62
Ilustración 54. Resultado de tercera clasificación en categoría baja vegetación. 63
Ilustración 55. Resultado de cuarta clasificación en categoría baja vegetación. 63
Ilustración 56. Resultado de quinta clasificación en categoría baja vegetación. 64
Ilustración 57. Resultado de primera clasificación en categoría media vegetación. 65
Ilustración 58. Resultado de segunda clasificación en categoría media vegetación. 65
Ilustración 59. Resultado de tercera clasificación en categoría media vegetación. 66
Ilustración 60. Resultado de cuarta clasificación en categoría media vegetación. 67
Ilustración 61. Resultado de quinta clasificación en categoría media vegetación. 67
Ilustración 62. Resultado de primera clasificación en categoría alta vegetación. 68
Ilustración 63. Resultado de segunda clasificación en categoría alta vegetación. 69
Ilustración 64. Resultado de tercera clasificación en categoría alta vegetación. 69
Ilustración 65. Resultado de cuarta clasificación en categoría alta vegetación. 70
Ilustración 66. Resultado de quinta clasificación en categoría alta vegetación. 71
Ilustración 67. Diagrama estadístico de categorías de clasificación. 74
Ilustración 68. Diagrama estadístico de categorías de clasificación. 75

Contenido de tablas

Tabla 1. Lista de especies naturales. 25
Tabla 2: Niveles de clasificación de datos LiDAR. 35
Tabla 3. Parámetros de clasificación en las iteraciones. 38
Tabla 4. Parámetros de clasificación manual. 39
Tabla 5. Categorización de vegetación según altura relativa. 45
Tabla 6. Parámetros de ajuste de la nube de puntos. 46
Tabla 7. Criterios de clasificación. 47
Tabla 8. Densidad de punto en cada módulo de clasificación. 71
Tabla 9. Porcentajes de clasificación en la nube de puntos. 72
Tabla 10. Clasificación de nube de puntos según densidad. 73
Tabla 11. Análisis estadístico de clasificación. 73
Tabla 12. Análisis estadístico de clasificación. 74
Tabla 13. Comparación de métodos de clasificación. 74

Contenido de ecuaciones

Ecuación 1: Ecuación LiDAR....16
Ecuación 2: Algoritmo heurístico....20
Ecuación 3: Percepción Multicapa....20
Ecuación 4: Arquitectura en función de simetría....21
Ecuación 5: Diferencia entre DSM y DEM....37
Ecuación 6: Fórmula relativa....43
Ecuación 7: Fórmula de error medio cuadrático.....44
Ecuación 8: Ecuación de h relativa.....45
Ecuación 9: Fórmula de continuidad espacial. 47
Ecuación 10. Distribución de categorías....72

1. Introducción

La biodiversidad es la base fundamental de la vida en la tierra, debido a que provee innumerables beneficios al ser humano. En el caso de Colombia, existe una gran diversidad biológica, puesto que alberga una gran cantidad de especies únicas y endémicas. (Sociedad Sostenible, s.f.). Sin embargo, a pesar de su gran riqueza natural, la biodiversidad en el país enfrenta serias amenazas debido a: deforestación, la expansión de frontera agrícola y minería, lo que provoca la perdida de hábitats y la disminución de poblaciones de diversas especies.

Ante esta situación, se han propuesto diversas alternativas para la preservación de la biodiversidad. Actualmente, "el país cuenta con 34.948.444 hectáreas (ha) de áreas marinas y 35.391.348 hectáreas terrestres protegidas y conservadas" (ambiente, 2022) las cuales abarcan una gran variedad de ecosistemas, además se implementó la vegetación urbana, que en los últimos años ha sido considerada como alternativa para mitigar la contaminación del aire en las zonas urbanas, regular la humedad, prevenir la erosión del suelo y minimizar los efectos de isla de calor, creando así un entorno más saludable y sostenible para las ciudades. (Meza, 2020)

Por lo tanto, es necesario la realización de un monitoreo constante de las especies para su preservación y conservación. Una de las alternativas más efectivas es la tecnología LIDAR, que, mediante técnicas de teledetección, permite recopilar información sobre objetos localizados en la superficie terrestre a través de un sensor. Esta tecnología representa los datos con variadas resoluciones y diferentes escalas, convirtiéndose en una herramienta fundamental para el análisis y seguimiento de las diferentes cubiertas boscosas. (Sostenible, s.f.)

El objetivo principal de este informe es realizar la clasificación de nubes de puntos en una zona urbana del distrito de Bogotá, utilizando segmentación semántica. El propósito es obtener etiquetas para cada píxel mediante algoritmos de aprendizaje profundo, aplicando diversas técnicas de clasificación y validación de datos

2. Planteamiento del problema

La biodiversidad es un recurso invaluable que sustenta la vida en la Tierra, aportando beneficios cruciales a los seres humanos y al equilibrio ecológico. Sin embargo, Colombia, a pesar de ser uno de los países con mayor diversidad biológica del mundo, enfrenta una crisis ambiental significativa. Toda la biodiversidad existente en el país está en riesgo de desaparecer debido a la actividad humana tanto directa como indirecta, como explico María Cristina Martínez, docente del Departamento de Química y Biología de Uninorte. (Norte, 2015)

Las consecuencias indirectas están relacionadas con el calentamiento global causado por las grandes emisiones de carbono generadas por otros países. En contraste, las consecuencias directas se derivan de las acciones cotidianas de los habitantes. Una de las principales causas de disminución de biodiversidad en Colombia está vinculada con la agricultura y la ganadería expansiva.

A estos factores se suman el riesgo de invasiones biológicas, presencia de especies invasoras, la deforestación, la minería ilegal, los cultivos ilícitos, la sobreexplotación de especies silvestres, el tráfico de fauna, la caza, la depredación y expansión urbana e industrial, entre otras. (Colombia, s.f.)

Si bien se han implementado diversas estrategias para la conservación de la biodiversidad, como la creación de áreas protegidas y la promoción de la vegetación urbana, estas iniciativas requieren un seguimiento constante y efectivo para evaluar su impacto y eficacia. En este contexto, la recopilación precisa de información sobre la vegetación se vuelve fundamental, especialmente en el campo de la ingeniería topográfica, donde es esencial para la planificación y ejecución de proyectos, como la construcción de carreteras y edificaciones. Contar con datos precisos permite un diseño más sostenible y la mitigación del impacto ambiental.

Por lo tanto, el problema central de esta investigación es determinar la técnica de segmentación semántica más eficaz y precisa para la clasificación de vegetación en áreas urbanas, utilizando datos de LiDAR en el contexto específico de Bogotá.

La pregunta clave que guía este estudio es: ¿Cuál de los métodos de segmentación semántica aplicados a nubes de puntos de alta densidad proporciona la mayor precisión en la clasificación de vegetación en una zona de estudio en Bogotá? Abordar esta cuestión no solo contribuirá a la mejora del monitoreo de la biodiversidad urbana, sino que también facilitará la implementación de estrategias más efectivas para la conservación y gestión sostenible de los recursos naturales en un entorno en constante transformación.

3. Justificación

En la Ingeniería Topográfica, el procesamiento y análisis de nubes de puntos es una técnica que se utiliza para obtener una representación en tres dimensiones de cualquier objeto o estructura física (Software, 2023). Esta tecnología es crucial para diversas aplicaciones, incluyendo localización de obra de infraestructura e inventarios forestales (William Zaque, 2017)

Esta investigación busca explorar métodos de clasificación alternativos que mejoren la comprensión dinámica de cobertura vegetal del suelo, lo cual es esencial para su conservación y monitoreo ambiental (Quintana, 2024) de las zonas urbanas de la ciudad de Bogotá. Sin embargo, los modelos de clasificación son insuficientes en cuanto a la frecuencia de actualización, lo que limita el entendimiento y capacidad de respuesta ante cambios significativos (Foody, 2001). Es por ello que es esencial implementar técnicas de clasificación digital avanzada como los algoritmos de aprendizaje profundo que ofrecen clasificaciones más rápidas y con alta exactitud temática. (Yuan, 2020)

El aprendizaje profundo con redes neuronales ha traído la atención en los últimos años debido a que permite analizar y modelar características abstractas de forma automática y genera mejores resultados que otros algoritmos supervisados y no supervisados en visión por computadora. (Oscar Soto, 2019). Estos avances han mejorado la precisión y la eficiencia en la identificación de características dentro de nubes de puntos, revolucionando el campo al ofrecer soluciones más rápidas y precisas para problemas complejos.

El enfoque de esta investigación se centra en desarrollar una metodología que no solo mejore la conservación de los ecosistemas urbanos, sino que también ofrezca una comprensión más profunda de las ventajas y limitaciones de los métodos de clasificación de coberturas vegetales. Se espera que los resultados del estudio beneficien tanto al entorno urbano como a sus habitantes, proporcionando perspectivas valiosas para la aplicación de futuras tecnologías de inteligencia artificial

4. Objetivos

4.1. General

Implementar un método eficiente para clasificar nube de puntos de alta densidad y detectar vegetación.

4.2. Específicos

- Diseñar una metodología precisa para clasificar la vegetación en la zona de estudio, utilizando nubes de puntos de alta densidad y considerando resolución de datos y calidad de escaneo.

- Desarrollar e implementar un método de procesamiento para nubes de puntos de alta densidad que permita una clasificación rápida y precisa de la zona de estudio.

- Análisis de resultados de manera estadística de los métodos aplicados.

5. Marco teórico y estado del arte

Este capítulo se estructura en dos secciones principales con el objetivo de ofrecer una comprensión integral de la clasificación de la vegetación mediante el uso de tecnologías avanzadas. La primera parte se centra en los conceptos clave para la clasificación de coberturas del suelo, con énfasis en el aprendizaje profundo, y se analizan las métricas de exactitud utilizadas para evaluar la eficacia de estas técnicas. En la segunda parte, se revisan estudios previos sobre el uso del aprendizaje profundo en la clasificación de coberturas, destacando principalmente las arquitecturas empleadas en la investigación y los desafíos enfrentados.

5.1. Marco teórico

5.1.1. Vegetación Urbana

La cobertura vegetal en la ciudad de Bogotá se sustenta en la red de áreas verdes urbanas, que proporcionan hábitat, alimento, oxígeno y sombra, contribuyendo al bienestar físico y mental de los habitantes. Además, actúa como un filtro natural, ayudando a reducir diversos contaminantes urbanos y funciona como una barrera frente al ruido y material particulado proveniente de fuentes fijas, móviles y suelos protegidos (Jardin Botanico de Bogota, 2020).

Bogotá alberga aproximadamente 348 especies de flora silvestre, de las cuales el 70 % (245 especies) son nativas, mientras que el 30 % restante (103 especies) son exóticas, Sin embargo, a pesar de la dominancia de las especies nativas, es importante destacar que las especies exóticas son altamente invasoras, como las del género: Eugenia, eucaliptos, acacias, etc. (Henandez, 2017).

5.1.2. LiDAR

Lidar (Light Detection and Ranging) es un sistema nuevo de recolección de datos topográficos de alta resolución y densidad. Se basa en el uso de ondas electromagnéticas que permite estimar la distancia entre el sensor y cualquier objeto o superficie. (Charles R, 2017). Sin embargo, la obtención de los datos especifica un error medio cuadrático (EMC) vertical máximo de 15 cm. (Wilver Salinas, 2013). En la ilustración 1 se visualiza la captura de datos LiDAR mediante un vuelo aéreo no tripulado.

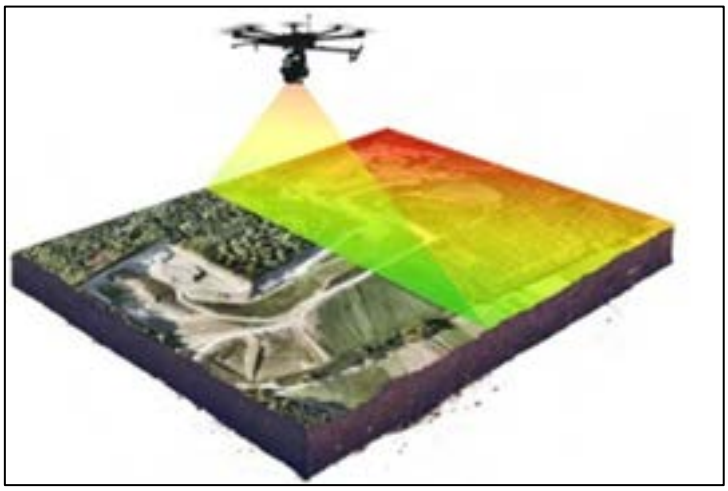


Ilustración 1 Captura de Datos LiDAR.

Fuente: (HALO ROBOTICS, 2022)

En los sensores LiDAR se conocen diferentes técnicas de captura de datos, las cuales serán descritos a continuación:

- **LiDAR aéreo**: Es empleado para la evaluación de grandes áreas, El sensor debe posicionarse en el avión que vuela normalmente a una altura de 400 a 2.500 metros sobre la superficie, permitiendo obtener una precisión entre 9.25 a 18.5 cm verticalmente y una precisión horizontal entre 20 cm a 1 m.

- **LiDAR aéreo de baja altitud:** Se utiliza para el estudio de vías e infraestructura lineal. El sensor debe ubicarse sobre helicópteros que sobrevuelan a una altura de 50 a 800 metros sobre la superficie, logrando densidades que oscilan entre los 20 y 100 puntos por metro cuadrado.

- **LiDAR móvil:** El equipo se coloca en la parte trasera de un vehículo, donde el láser puede rotar 360º durante toda la captura de datos mientras que el vehículo avanza. La precisión de la información es mayor dependiendo de la distancia máxima de alcance, que suele ser de hasta 200 metros desde el sensor.

- **LiDAR terrestre:** El sistema se basa en un dispositivo montado sobre un trípode, lo que permite estudiar un área concreta de interés. Aunque la precisión tiende a ser muy alta, este método es limitado por tratarse de un sistema estacionario (Florez, 2008).

5.1.3. Ecuación LiDAR

En general, la potencia retornada o señal LiDAR de un objeto sólido se expresa utilizando la ecuación LiDAR, la cual describe lo que ocurre cuando un pulso de luz láser viaja desde el emisor, interactúa con un objeto y regresa al receptor. Esta fórmula es crucial para analizar y comprender el comportamiento de un sistema LiDAR. A continuación, se presenta sus componentes:

$$Pr = \frac{Pt * F(R) * A * K * P * E^{-2\int_0^R AT\,(R')(DR')}}{\pi\, r^2}$$

Ecuación 1: Ecuación LiDAR

En donde:

- Pr corresponde a la potencia transmitida
- F(R) es el factor de cruce óptico transmitido con el campo de visión del telescopio en un rango r
- A es el área del telescopio en metros cuadrados
- K es la eficiencia óptica reflectiva del objeto (sr=1).
- R es el rango del objeto del coeficiente total de absorción (Km

En la ecuación mencionada la potencia recibida es proporcional a la potencia transmitida y al área de colección del telescopio y minimiza con respecto al rango 1/r 2 y la ley de Beer-Lambert.

5.1.4. Nube de puntos

Las nubes de puntos son conjuntos de datos tridimensionales que representan la superficie de un objeto o área de interés mediante la recopilación de coordenadas espaciales de
puntos. Este tipo de

datos es esencial porque proporciona información detallada y precisa sobre la forma, estructura y características de objetos físicos o entornos naturales.

El proceso de clasificación se basa en la resolución espacial y espectral de la imagen y se puede efectuar por medio de clasificadores de píxeles y por regiones. Los primeros se basan en la reflectancia de cada píxel, el cual será asignado a un tipo de clase, mientras que los segundos consisten en la agrupación de píxeles vecinos en determinadas regiones homogéneas, previo a la clasificación (Maria Alvarez).

Este procedimiento se lleva a cabo mediante diversas técnicas, incluyendo el uso de redes neuronales y/o aprendizaje profundo, entre otras. Sin embargo, las nubes de puntos presentan limitaciones inherentes, como la distribución irregular de los puntos 3D y la falta de estructura topológica, lo que a menudo requiere tratamientos de regularización espacial (Alejandro et al., 2022). En la ilustración 2 se especifican los métodos de clasificación que serán aplicados en el caso de estudio y se profundizarán a medida que avanza la investigación.

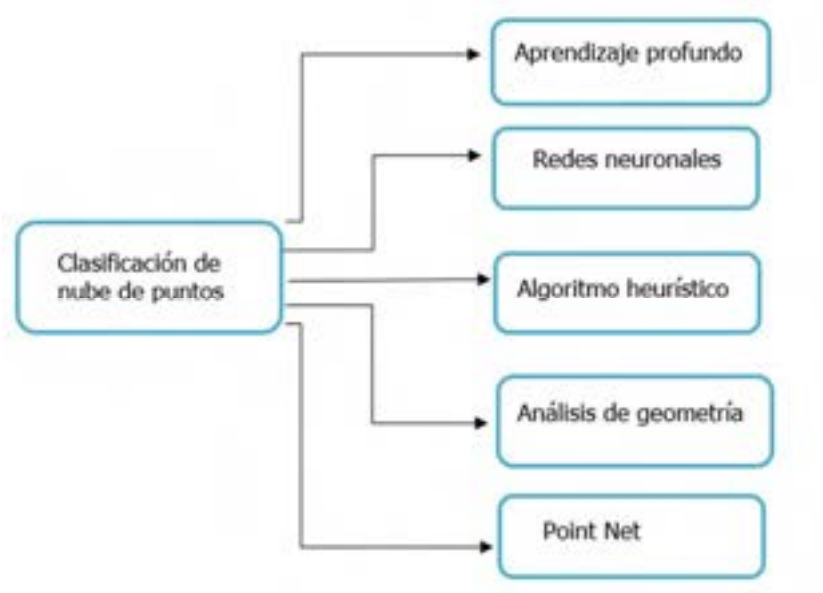


Ilustración 2 Métodos de clasificación.

Fuente. Elaboración propia.

5.2. Estado del arte

5.2.1. Aprendizaje profundo

El aprendizaje profundo permite que los modelos computacionales, compuestos de múltiples capas de procesamiento, aprendan representaciones de datos con múltiples niveles de abstracción (Cano, 2024). A diferencia del aprendizaje automático, que es una disciplina de la inteligencia artificial enfocada en crear programas capaces de aprender conforme con su experiencia (Stuart Russell, 2008), El aprendizaje profundo se caracteriza por su capacidad de estructurar conceptos más complejos a partir de los más simples. Si se construyese un grafo que representara cómo los conceptos complejos se posicionan por encima de los más simples, dicho grafo sería muy profundo (Medina, 2019). La ilustración 3 muestra esta estructura característica del aprendizaje profundo.

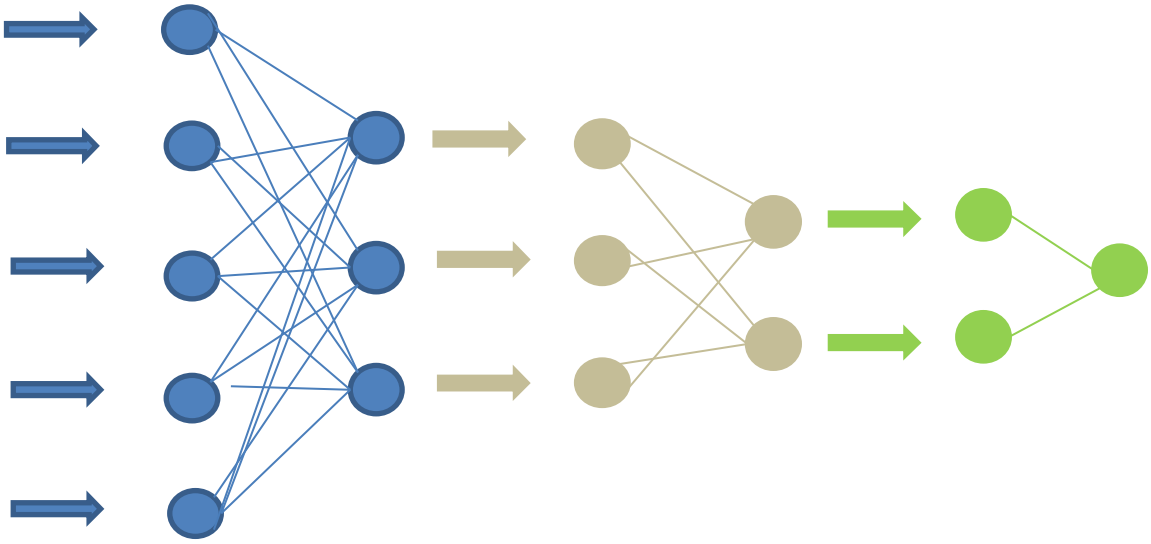


Ilustración 3. Arquitectura de aprendizaje profundo.

Fuente. Elaboración propia.

Algunas de las principales ventajas consisten en su elevada estabilidad de las redes, de manera que los resultados mejoran gradualmente a medida que incrementan los datos y modelos, que requieren mayor potencia computacional (Alejandro Espacio, 2021).

5.2.1. Aprendizaje automático

El aprendizaje automático es una disciplina que tiene por objetivo principal el desarrollo de métodos capaces de aprender sin la necesidad de ser programados específicamente (Rivera, 2022). Normalmente, la mejora del rendimiento se fundamenta en la aplicación del algoritmo sobre una serie de ejemplos de entrada que determinarían el tipo de aprendizaje. A medida que aumentan las iteraciones de aprendizaje, los resultados serán mejores. Existen tres tipos de aprendizaje según el tipo de realimentación, los cuales se describen a continuación:

- **Aprendizaje supervisado:** Consiste en aprender una función a partir de ejemplos de entradas y sus respectivas salidas.

- **Aprendizaje no supervisado**: Se basa en aprender mediante ejemplos de entrada, sin que se especifica el valor de salida.

- **Aprendizaje por refuerzo:** Se trata de aprender cómo se comporta el entorno mediante

refuerzos o castigos, derivándose del éxito o el fracaso.

En conclusión, el aprendizaje automático busca resolver problemas específicos, tales como: Clasificación, regresión, regresión ordinal y agrupamiento (Medina, 2019). En la siguiente ilustración se destacan las subramas del aprendizaje profundo, que incluyen el aprendizaje automático y la inteligencia artificial.



Ilustración 4. Ámbito de Deep Learning.

Fuente. Elaboración propia.

5.2.2. Red neuronal convolucional

La red neuronal convolucional consiste en un tipo de red de propagación capaz de extraer características de la información mediante estructuras de convolución (Charles R, 2017). Este tipo de red neuronal se desarrolla a partir de la clasificación de imágenes, con el fin de evitar parámetros para generar el diseño de una red en la que existe un canal para cada píxel en cada canal de la imagen (Medina, 2019).

Las CNN están constituidas por diferentes capas de neuronas, cuya finalidad principal es aprender características extraídas de los datos de entrada, lo que permite clasificar dichos datos (Larraga hugo, 2022). La arquitectura CNN está compuesta por una capa convolucional N dimensional, que es un tensor N+1 con N dimensiones y una única característica (Chris Zhang).

Cabe señalar que se diseñó la CNN multivista sobre redes de clasificación basada en imágenes, en donde se integran las vistas alrededor de un objeto en una vista en 3D por medio de la agrupación de vistas (Xiaoqing Ye). Asimismo, se puede aplicar un filtrado multi-resoluciòn en el espacio 3D para optimizar el rendimiento de las CNN multivista.

5.2.3. Algoritmo heurístico

Este algoritmo se emplea con distancias para identificar las características de cada objeto, donde es necesario realizar un etiquetado mediante la obtención de distancias euclidianas entre objetos consecutivos, como se indica en la siguiente ecuación:

$$Dj = \sqrt{(X_P^1 - X)^2 + (Y_P^1 - Y)^2}$$

Ecuación 2: Algoritmo heurístico

Es importante señalar que, si la distancia es menor a un umbral predefinido, se concluye que la característica corresponde al mismo objeto. Debido a que el barrido del sensor gira en sentido antihorario, lo cual permite comparar las distancias hasta la última medición (Icardo Urvina, 2023).

5.2.4. Algoritmo PointNet

PointNet ha servido como fundamento para numerosos métodos modernos de visión en 3D con nubes de puntos, basados en redes neuronales profundas (RNP). Este método trabaja directamente con los puntos de la nube, a los cuales se le aplican diferentes trasformaciones con el objetivo de lograr esa invariabilidad mencionada anteriormente (Alejandro Espacio, 2021).

En las fases iniciales, cada uno de los puntos es procesado de manera independiente. En la etapa de configuración básica, cada punto es representado en las dimensiones x, y, z; si existen dimensiones adicionales, estas se incorporan durante la propagación, enriqueciendo la tarea de segmentación o clasificación (Medina, 2019).

Una vez efectuado el proceso anterior, es fundamental aplicar la percepción multicapa (MLP, por sus siglas en inglés) para que el método aprenda la codificación espacial en alta dimensión de cada punto. La ecuación de percepción multicapa consiste en efectuar una agrupación global de las características, las cuales se duplican en N mosaicos y se concatena con las características puntuales para obtener el puntaje de predicción final (Xiaoqing Ye):

$$F(P1, P2, \dots PN) = MPL(C\{maxpool\{MLP\ I = 1\ (P1)\}, MLP\ I = 1\ (P2)\})$$

Ecuación 3: Percepción Multicapa

En esta ecuación C representa la operación de concatenación de los índices de los puntos de 1 a N aplicada por debajo de MLP, lo que demuestra que la operación de MPL es puntual.

5.2.5. Arquitectura de PointNet

A continuación, se describen los tres principales bloques que componen PointNet (Zewen Li):

5.2.5.1. Función de simetría para una entrada sin orden.

Esta etapa se subdivide en tres estrategias fundamentales para lograr un modelo invariable a las permutaciones de entrada, las cuales se describen a continuación:

- **Ordenar por entrada canónico:** Todos los conjuntos de entrada estarán definidas por el mismo operador de orden.

- **Red neuronal recurrente:** La entrada será una secuencia para entrenar una red neuronal, en donde es necesario el entrenamiento con todo tipo de permutaciones.

- **Función simétrica simple (max-pooling):** Esta función toma n puntos como entrada y genera como salida un nuevo vector que es invariable al orden de entrada.

La idea de esta arquitectura es aproximar una función general en un conjunto de puntos, aplicando una función simétrica a los elementos transformados en dicho conjunto:

$$f(\{X1, X2, \dots Xn\}) \approx g(h(X1), \dots (h(Xn))$$

Ecuación 4: Arquitectura en función de simetría

Empíricamente, el modelo estima el valor de h mediante una red de percepción multicapa, y calcula g utilizando una composición de una función en una variable junto con una función de max-pooling.

5.2.5.2. Agregación de información local y global.

El resultado obtenido del proceso anterior es un vector que representa características {F1, ... fx}, correspondiente a una representación del conjunto de entrada. Es posible entrenar este modelo de percepción multicapa para desarrollar tareas de clasificación. Sin embargo, este procedimiento requiere una combinación local y global (Medina, 2019).

Por lo anterior, es necesario realimentar las características por punto concatenado de las características globales con cada una de las características puntuales. Esta modificación permite que la red prediga las cantidades por punto, basándose en la geometría local y semántica global.

5.2.5.3. Red de conjunto de alineación.

El etiquetado semántico de la nube debe ser inalterable frente a transformaciones geométricas como: traslación, rotación y escalado. Para ello, predice una matriz de alineación (T-Net) que aplica una transformación sobre las coordenadas de los puntos.

La mini red (T-Net) está compuesta por características independientes basadas en max- pooling y fully-connected. Esto permite insertar otra red de alineación de características, que predice una transformación de las características de las entradas de las nubes de puntos (Medina, 2019).

La matriz de transformación se restringe con el objetivo de que sea semejante a la matriz ortogonal. En la ilustración 6 se evidencia la estructura de la arquitectura de PointNet, inicialmente se ingresa la nube de puntos en coordenadas x,y,z en un espacio tridimensional, cada punto puede incluir características adicionales como color o intensidad por consiguiente se realiza una transformación inicial en una red de transformación (T-NET) que alinea los puntos en las coordenadas espaciales para luego ajustar las características a otra red para mantener la invariación a rotaciones y traslaciones, luego cada punto de la nube procesa la red completamente conectada (MLP) compartida entre los puntos,

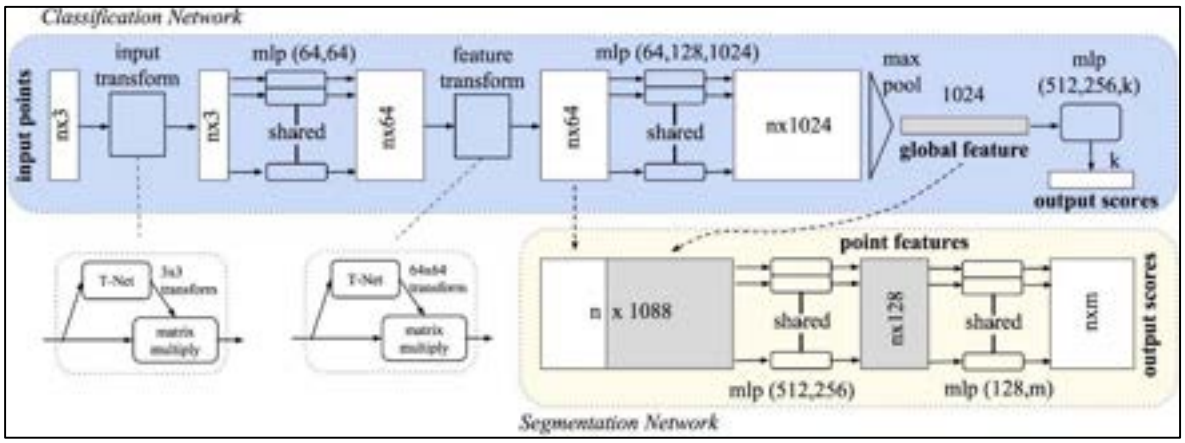


Ilustración 5. Arquitectura de Point Net.

Fuente: (Charles R, 2017)

5.2.6. Análisis de geometría

El análisis geométrico en la clasificación de nubes de puntos se fundamenta en una serie de principios que facilitan la identificación y categorización de las distintas características del terreno y de los objetos presentes en los datos LiDAR. A continuación, se mencionan los aspectos claves de este proceso:

- **Datos de entrada:** Las nubes de puntos se generan a partir de datos LiDAR que incluyen coordenadas tridimensionales (X, Y, Z), las cuales representan la posición y altitud de cada punto. Esta información es esencial para el análisis geométrico (Danysoft, 2020).

- **Estructura local:** Los algoritmos de clasificación se basan en analizar la estructura geométrica de la nube de puntos en un contexto local. Es decir, el algoritmo examina como se distribuyen los puntos en el espacio y busca los patrones que presenten características específicas como edificios, árboles, cuerpos de agua, entre otros.

Parámetros de clasificación

- **Altura mínima:** Se establece una altura mínima para que el algoritmo logre identificar y

clasificar los puntos como edificios o vegetación (14 blue).

- **Densidad y distribución:** Los algoritmos pueden diferenciar los objetos a partir de la densidad de la nube de puntos. Es decir, las zonas con altos índices de densidad corresponderán a áreas de vegetación o estructuras construidas, dependiendo de la distribución espacial de los puntos (Mapper, 2017).

- **Reclasificación manual:** El algoritmo permite desarrollar una reclasificación manual para ajustar las categorías asignadas en los puntos según observaciones visuales o criterios específicos.

6. Materiales y método de estudio

Esta sección se organiza en tres fases principales. En la primera, se describe de manera detallada la zona de estudio, proporcionando el contexto necesario para comprender el enfoque de la investigación. La segunda fase aborda los datos utilizados, destacando sus características y la metodología aplicada, con énfasis en los procedimientos desde la preparación de los datos hasta el modelado empleado. Finalmente, la tercera fase detalla los softwares utilizados en las distintas etapas de la investigación.

6.1. Área de estudio

La Aduanilla de Paiba es un edificio histórico que alberga la Biblioteca Aduanilla de Paiba, parte de la Universidad Distrital Francisco José de Caldas, en Bogotá, Colombia. Este espacio, situado en la localidad de Los Mártires, tiene una gran importancia tanto cultural como académica debido a su valor arquitectónico y patrimonial, así como por su función en el desarrollo de la educación en la ciudad.



Ilustración 6. Universidad Distrital Sede Aduanilla de Paiba.

Fuente: (Flechas, 2023)

El entorno urbano en el que se ubica la Aduanilla es diverso, ya que combina zonas residenciales con áreas comerciales e industriales. La revitalización de este sector ha sido un proceso gradual,

en el cual la Universidad Distrital ha desempeñado un papel clave mediante la creación de espacios académicos como este, que fomentan el desarrollo de la investigación y el conocimiento en la ciudad. En la siguiente ilustración se evidencia la distribución arquitectónica y cobertura vegetal de la edificación:



Ilustración 7. Plano arquitectónico de la sede Aduanilla de Paiba.

Fuente: (Blogger, 2014)

El entorno natural de la Aduanilla de Paiba, además de su valor patrimonial y académico, posee elementos vegetales que juegan un papel fundamental en la caracterización del sitio. La vegetación que rodea el edificio contribuye a crear un equilibrio entre el entorno urbano de la ciudad y los espacios verdes, proporcionando un área que promueve la reflexión y el estudio.

El campus y los alrededores de la Aduanilla de Paiba cuentan con una selección de árboles y plantas que han sido integrados a lo largo de los años. En la tabla 1 se especifica las especies existentes de la zona:

Nombre	**Nombre científico**	**Tamaño aproximado**	**Importancia ecológica**
Falsos pimientos	Schinus molle	Altura: 8 a 15 metros Diámetro de copa: 6 a 8 metros	Este árbol tiene follaje colgante que proporciona sombre considerable, siendo ideal para espacios abiertos.
Acacias	Acacia melanoxylon	Altura: 10 a 15 metros Diámetro de copa: 5 a 10 metros	Este árbol de rápido crecimiento y con una copa ancha genera buena sombra ideal para zonas urbanas.
Eugenia	Syzgium paniculatum	Altura: 3 a 17 metros Diámetro de copa: 6 a 8 metros	Este árbol ornamental es compacto y con un follaje denso utilizado para sombra y decoración.

Helechos	Pteridium aquilinum	Altura: 0.5 a 1 metro	Los helechos suelen ser plantados en zonas sombreadas y húmedas que otorgan una textura en el paisaje.
Geranios	Pelarginium spp	Altura: 20 a 60 centímetros	Son plantas de pequeño tamaño que florecen en diversos colores agregando vitalidad y belleza al paisaje.
Lavandas	Lavándula spp	Altura: 30 a 90 centímetros	Son plantas conocidas por sus flores aromáticas y contribuyen al entorno estético y sensorial

Tabla 1. Lista de especies naturales.

Fuente. Elaboración propia.

6.1.1. Datos

En esta investigación se emplearon fotografías aéreas y una nube de puntos en formato LAS, obtenidos mediante un levantamiento topográfico con dron. Para garantizar la precisión, se utilizaron puntos de control y un equipo con receptor GNSS en modo RTK.

6.1.2. Fotografías aéreas

En la recolección de datos a través de fotografías aéreas, el dron se programó para volar a una altura de entre 70 y 80 metros sobre el terreno. Esta altitud fue seleccionada para lograr un equilibrio óptimo entre la resolución de las imágenes y la cobertura del área de estudio. A esta altura, las fotografías capturadas ofrecen un nivel de detalle suficiente para identificar características precisas del paisaje, como la vegetación, las estructuras arquitectónicas y las superficies del terreno, sin comprometer la amplitud de la cobertura.

El vuelo a dicha altitud permitió obtener imágenes con una alta precisión espacial, lo que facilita el procesamiento en la creación de modelos digitales del terreno y ortomosaicos detallados. La combinación de la altitud con los parámetros óptimos de la cámara del dron garantizó una recolección de datos uniforme y coherente, permitiendo un análisis riguroso de la vegetación y la morfología del sitio.

6.1.3. Levantamiento topográfico con vehículo aéreo no tripulado

Para la obtención de la nube de puntos de la zona de estudio, se utilizó un dron equipado con sensores de alta precisión y un receptor GNSS en modo RTK. Este sistema permitió capturar datos tridimensionales con una gran exactitud, generando una nube de puntos que representa detalladamente la topografía y las características físicas del terreno.

La nube de puntos se obtuvo a partir de un barrido aéreo realizado sobre la zona de estudio, durante el cual se capturaron miles de puntos por segundo. Cada punto contiene coordenadas geoespaciales en tres dimensiones (X, Y, Z), lo que permitió reconstruir con precisión la superficie del área,

incluyendo elementos como la vegetación, edificios y otras estructuras del entorno.

Este tipo de datos es fundamental para la creación de modelos digitales del terreno y para realizar análisis más detallados, como la medición de volúmenes, la identificación de cambios en el relieve y el estudio de la distribución de la vegetación en el área de interés. La precisión de la nube de puntos se optimizó mediante la integración de puntos de control en tierra y el uso del modo RTK, asegurando una correcta georreferenciación y exactitud en el levantamiento topográfico. En la ilustración 8 se evidencia la base del levantamiento topográfico en campo con sus respectivas coordenadas, hora y fecha.



Ilustración 8 Datos de la base recolectora.

Fuente. Elaboración propia.

6.2. Métodos

Procedimiento empleado

Para dar claridad a la estructura de la ejecución en las etapas y poder observar los procedimientos realizados, la ilustración 10 que muestra el procedimiento empleado en el proyecto.

La metodología empleada en esta investigación se estructura en tres etapas principales: procesamiento preliminar, procesamiento y análisis. Cada una de estas fases fue diseñada para garantizar la precisión y eficiencia en la clasificación de la cobertura vegetal, como se detalla en la Ilustración 9, "Metodología de la investigación". A continuación, se describen las etapas con mayor detalle:

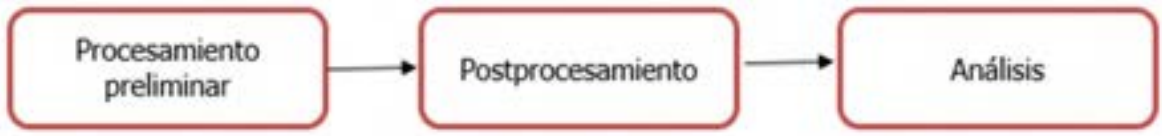


Ilustración 9. Metodología de la investigación.

Fuente. Elaboración propia.

1. **Procesamiento preliminar:** Esta etapa se enfocó en la preparación y limpieza de los datos. Las actividades principales incluyeron la selección adecuada de fotografías aéreas para la creación de un Ortomosaico y la georreferenciación precisa de la información mediante puntos de control. El propósito de esta fase fue asegurar la calidad, fiabilidad y coherencia de los datos como base para las etapas posteriores.

2. **Procesamiento:** Durante esta fase, se implementaron técnicas avanzadas de clasificación aplicadas a los datos procesados. Este paso implicó ajustes iterativos y modificaciones en los algoritmos con el fin de optimizar la clasificación de la cobertura vegetal. Las técnicas empleadas permitieron explorar distintas configuraciones y evaluar la eficiencia de los métodos aplicados.

3. **Análisis:** En esta última etapa, se llevó a cabo un análisis exhaustivo de los resultados obtenidos mediante los modelos de clasificación. La evaluación se centró en medir la exactitud de los datos mediante técnicas estadísticas, asegurando así la validez y fiabilidad de los resultados para la investigación.

6.2.1. Procesamiento preliminar

Durante la fase inicial de preprocesamiento, se llevaron a cabo dos procesos fundamentales: el procesamiento de los datos GNSS recopilados en campo y la generación de un Orto mosaico. A continuación, se describe en detalle cada una de estas fases.

6.2.2. Fase 1 Procesamiento de datos GNSS:

- **Recopilación de datos en campo:** En esta fase se obtuvieron las observaciones GNSS tanto de la estación base como de los puntos de control, empleando receptores GNSS de alta precisión. Estas mediciones fueron esenciales para garantizar que las imágenes capturadas por el dron estuvieran correctamente georreferenciadas, asegurando así un alto grado de precisión y exactitud en los productos derivados.

- **Importación y corrección diferencial de los datos:** Los archivos de observación GNSS de la estación base y los puntos de control fueron importados a software especializado, donde se aplicaron correcciones diferenciales. Este proceso incluyó el cálculo de líneas base entre la estación base y los puntos de control, ajustando las coordenadas relativas para eliminar errores sistemáticos y mejorar la precisión de los datos.

- **Ajuste de Coordenadas al Sistema de Referencia CTM-12:** Se realizó la transformación y ajuste de las coordenadas al sistema de referencia regional CTM-12 (Coordenadas Transversales de Mercator), lo que garantizó la coherencia espacial con el marco geodésico local. Además, los datos fueron sometidos a una verificación para asegurar que los márgenes de error posicional se mantuvieran dentro de los límites aceptables, optimizando así la precisión de la información procesada.

  Finalmente, las coordenadas ajustadas y los resultados procesados fueron exportados para su integración en las etapas posteriores de producción de productos geoespaciales, asegurando que la georreferenciación y precisión posicional cumplieran con los estándares requeridos.

6.2.3. Etapa 2. Creación de un Orto mosaico

Con los datos GNSS procesados, se elaboró un Orto mosaico georreferenciado de alta precisión. Las coordenadas geográficas ajustadas se combinaron con las fotografías aéreas capturadas en campo, asegurando que los parámetros de captura —como la superposición frontal (80%) y lateral (70%)— y la resolución espacial fueran óptimos para el modelo fotogramétrico. La distribución espacial de las imágenes en el software Agisoft Metashape Professional se presenta en la Ilustración 10.

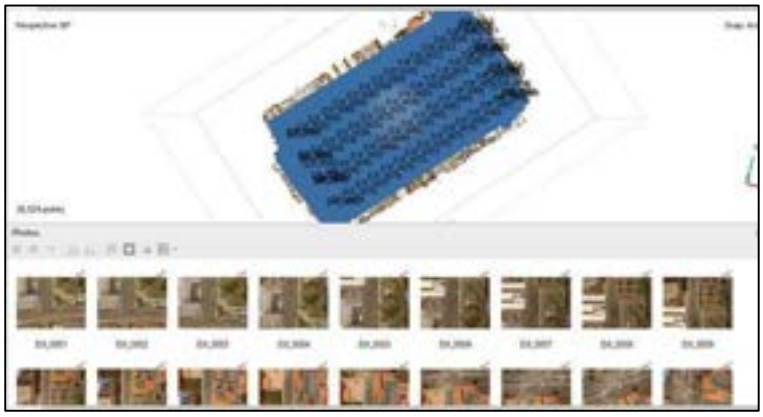


Ilustración 10. Creación de Orto mosaico.

Fuente. Elaboración propia.

Se establecieron parámetros específicos para la alineación de imágenes, como calidad alta, preselección de pares para acelerar el procesamiento y límites de puntos clave y de enlace (10,000 y 4,000 respectivamente). Esto permitió optimizar el rendimiento del software manteniendo la precisión geométrica del modelo. En la ilustración 12 se visualiza la especificación técnica de los parámetros:



Ilustración 11. Parámetros de alineación de fotos.

Fuente. Elaboración propia.

Los puntos de control postprocesados se importaron al proyecto para georreferenciar las imágenes, vinculando las coordenadas GNSS a las cámaras y mejorando la alineación global. Una vez alineadas las imágenes y georreferenciadas con los puntos de control, se creó una nube de puntos densa utilizando un filtro de profundidad moderado, equilibrando detalle y tiempo de procesamiento. A partir de esta nube, se generó un Modelo Digital de Superficie (MDS), aplicando parámetros de interpolación para suavizar irregularidades en la superficie. En la siguiente figura se evidencia los parámetros especificados en la interpolación con el fin de suavizar las irregularidades en la superficie.



Ilustración 12. Parámetros de Modelo digital de superficie.

Fuente. Elaboración propia.

Finalmente, se elaboró el orto mosaico utilizando como base el MDS (Modelo digital de superficie), asegurando la correcta selección de la superficie (DSM) y configurando el modo de combinación de imágenes para evitar discontinuidades. La resolución espacial se ajustó en función del área de estudio, especificada en centímetros por píxel.

El orto mosaico final fue exportado en formato Geo TIFF, asegurándose de que el sistema de referencia fuera WGS84 para mantener la coherencia en la proyección de las coordenadas. Adicionalmente, se verificaron los bordes, la resolución de los píxeles, y se ajustaron los valores de compresión para garantizar que el archivo mantuviera una alta calidad visual sin ocupar un espacio excesivo. Su distribución se muestra en la ilustración 13.



Ilustración 13. Orto Mosaico de la zona de estudio.

Fuente. Elaboración propia.

6.2.4. Procedimiento empleado

Para dar claridad a la estructura de la ejecución en las etapas y poder observar los procedimientos realizados, la ilustración 14 muestra el procedimiento empleado en el proyecto.

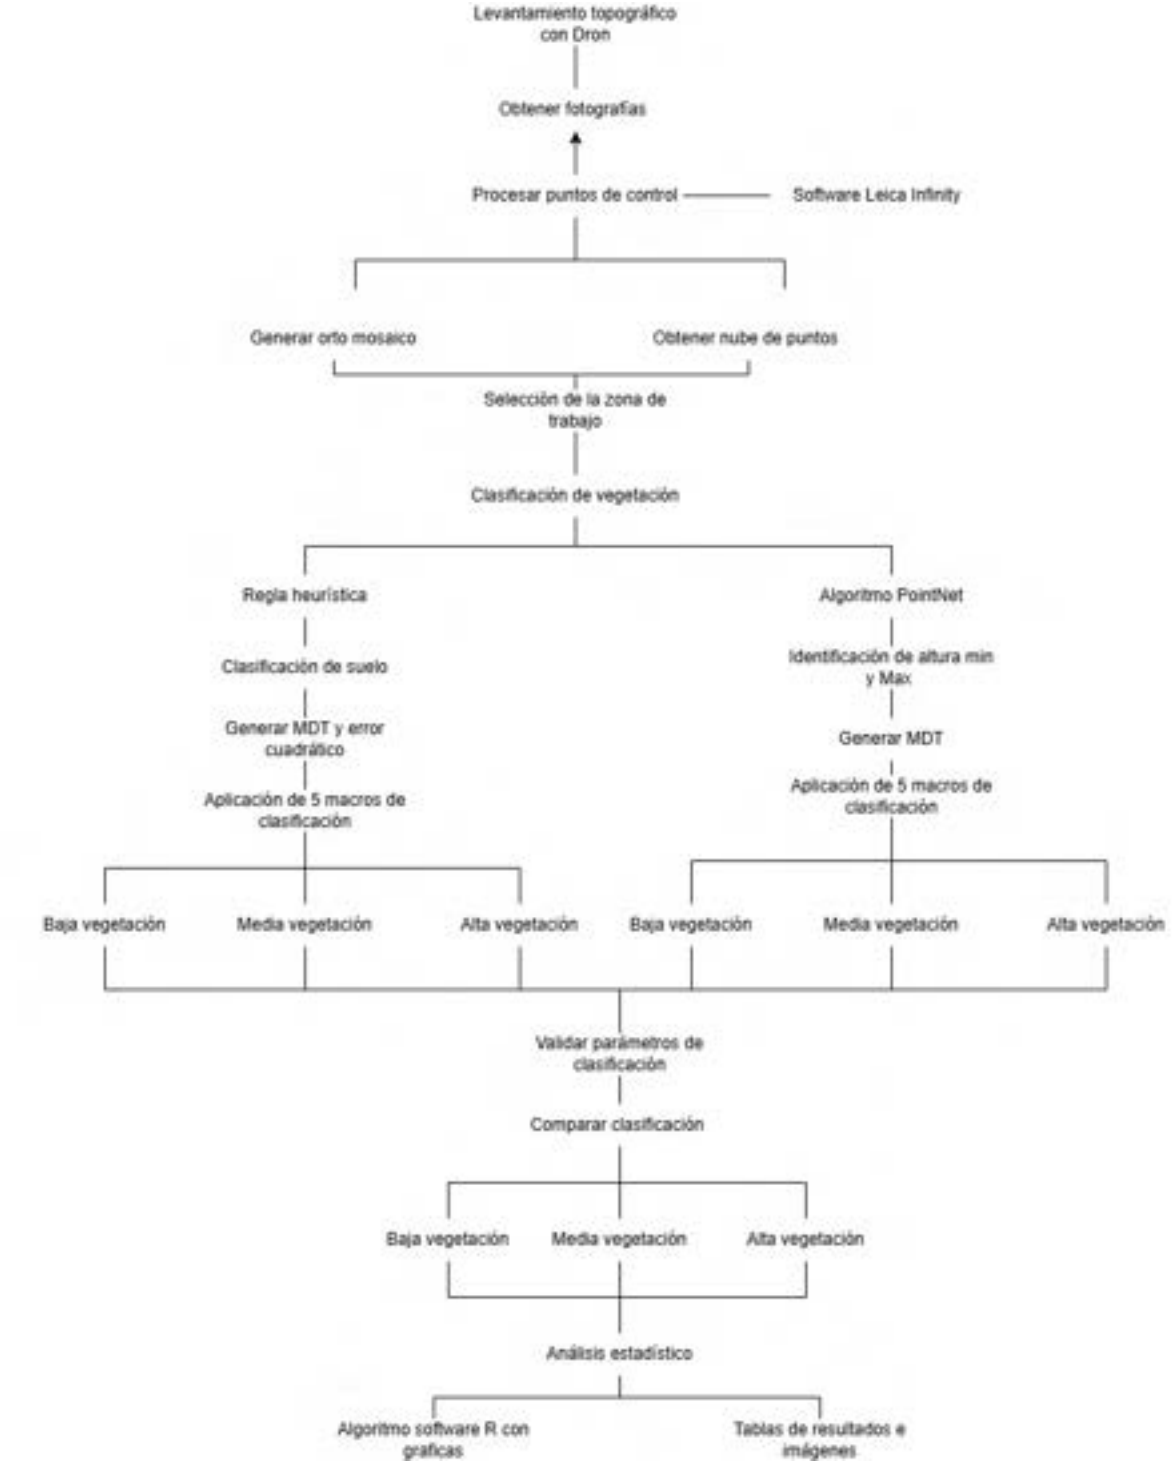


Ilustración 14. Diagrama de metodología empleada.

Fuente. Elaboración propia.

7. Procesamiento

En este ítem, se implementaron métodos avanzados para la clasificación de la cobertura vegetal en la zona de estudio, utilizando como base los datos procesados en la etapa preliminar. El enfoque se estructuró en dos fases principales, diseñadas para garantizar la calidad y precisión de los resultados:

- **Fase 1 Preparación de la información:** Se realizó la integración de los datos provenientes del procesamiento preliminar, como el Ortomosaico georreferenciado y la nube de puntos generada. Estos datos fueron depurados y organizados para su análisis, asegurando que todas las capas de información estuvieran correctamente alineadas y listas para el procesamiento.

- **Fase 2 Aplicación de clasificación:** Se aplicaron algoritmos avanzados para clasificar las diferentes clases de cobertura vegetal presentes en la nube de puntos. Durante esta fase, se ajustaron los parámetros del modelo con el objetivo de mitigar el desbalance entre las clases y optimizar la precisión en la segmentación de las coberturas.

7.1. Fase 1. Preparación de la información

Con el fin de realizar el análisis de clasificación de vegetación, se utilizó como apoyo de la ortofoto de la zona de estudio, en la cual se validaron las áreas con alta y baja densidad de vegetación. El análisis se llevó a cabo de la siguiente manera:

1. **Selección visual de las áreas con alta y baja densidad de vegetación:** Se escogió el área 1 que representa las partes de baja vegetación, donde se evidencia zonas de arbustos, pastizales bajos y helechos. Mientras que el área 2 representa la alta vegetación, como árboles y arbustos altos tal, como se observa en la ilustración 14.



Ilustración 15. Categorización de las zonas con baja y alta densidad de vegetación.

Fuente. Elaboración propia.

2. **Identificación de las zonas en el software Qt Modeler:** En este paso se aplicaron filtros de información, tal como se evidencia en las ilustraciones 15 y 16.



Ilustración 16. Visualización de datos Lidar en el software Qt Modeler de áreas con baja densidad de vegetación.

Fuente. Elaboración propia.



Ilustración 17. Visualización de datos Lidar en el software Qt Modeler de áreas con alta densidad de vegetación.

Fuente. Elaboración propia.

Una vez seleccionada las zonas prioritarias, se efectuó un análisis de la nube de puntos. Este procedimiento se realizó utilizando el software QT Modeler, en el que se aplicaron filtros de densidad de puntos y se eliminaron aquellos puntos considerados como ruido (puntos atípicos, retornos erróneos, etc.). Esta limpieza preliminar optimizó la eficiencia del proceso de clasificación al reducir el volumen de datos a procesar.

Finalmente, se realizó un análisis adicional para validar la pendiente del terreno en el software MicroStation. Se seleccionaron áreas aleatorias y se generaron perfiles de cada una de las zonas para analizar su pendiente, como se observa en la ilustración 17 el resultado es la nube de puntos con bajas pendientes.



Ilustración 18. Visualización de nube de puntos en el software MicroStation y verificación de pendiente.

Fuente. Elaboración propia.

7.2. Fase 2 Aplicación de clasificación.

7.2.1. Algoritmo en Point Net

Inicialmente, se importó la nube de puntos en el software Visión Lidar, donde se observó una disminución en la densidad de puntos, como se muestra en la ilustración 18. Esto se debe a la limpieza realizada previamente, que elimino puntos no útiles y optimizo los recursos computacionales, ajustando la densidad de puntos que el software puede procesar.



Ilustración 19. Visualización de la zona de estudio en el software Visión Lidar.

Fuente. Elaboración propia.

Los datos LiDAR sin procesar se encuentran en la clase 0, que corresponde a información no clasificada. Por esta razón, se implementaron niveles de clasificación para la cobertura de la nube de puntos. En la tabla 2 se presentan los niveles de clasificación empleados en este método, especificando los códigos ID de cada categoría:

Códigos ID	Clase
0	No clasificado
1	Construcciones
2	Suelo
3	Baja vegetación
4	Media vegetación
5	Alta vegetación

Tabla 2: Niveles de clasificación de datos LiDAR.

Fuente. Elaboración propia.

En este proyecto, se implementó el método de clasificación automática utilizando el modelo de aprendizaje profundo PointNet, que aprende de manera directa las representaciones y patrones en datos 3D. Dado que el objetivo del análisis es la categorización de vegetación, se seleccionó el modelo de clasificación correspondiente y se ajustaron los siguientes parámetros para obtener una clasificación precisa:

- **Altura mínima y máxima**: Se definieron los límites de altura para segmentar solo aquellos puntos que representan vegetación, excluyendo otras estructuras no vegetativas.

- **Radio de análisis**: Se estableció un radio de influencia que permite al algoritmo analizar los puntos cercanos y agrupar aquellos que correspondan a la misma clase (vegetación).

El procedimiento de clasificación se basó inicialmente en la identificación de puntos en la zona más baja del área. Este paso fue fundamental para detectar y clasificar correctamente los puntos correspondientes al suelo, mediante la configuración del umbral de altura.

A partir de la identificación obtenida de los puntos más bajos, se generó un modelo de elevación digital (DEM), que represento la topografía del terreno, tal como se muestra en la ilustración 19. Este modelo se creó aplicando un algoritmo de interpolación entre los puntos seleccionados como suelo para obtener una superficie continua que represento correctamente el relieve de la zona de estudio. Posteriormente, se aplicó un filtro TIN (Red irregular triangulada) de clasificación para el suelo, lo cual permitió refinar la selección de los puntos, basándose en variaciones graduales de elevación. En este modelo inicial, los triángulos están principalmente por debajo del nivel de la superficie, y solo los vértices están tocando el suelo.

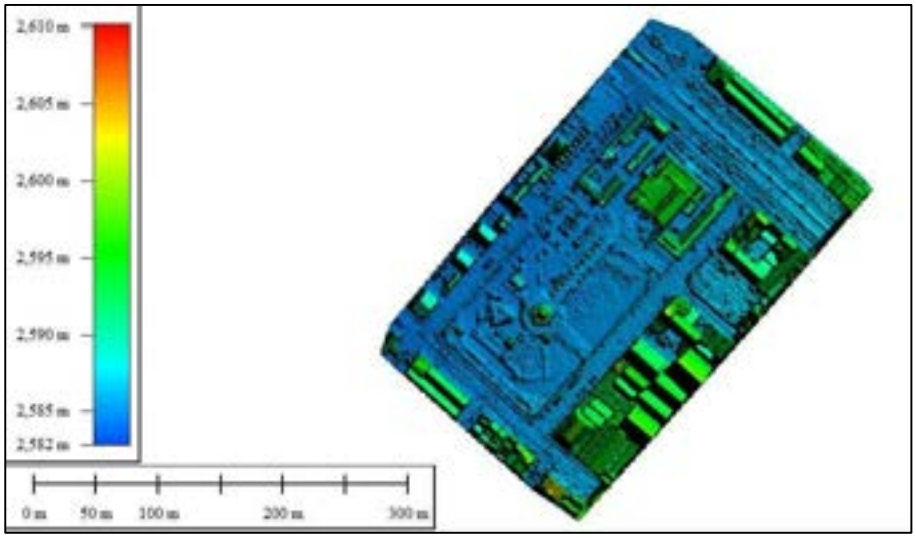


Ilustración 20. Modelo digital de elevación.

Fuente. Elaboración propia.

Una vez categorizada la capa de terreno, se segmentaron los puntos ubicados por encima de la clase de suelo, estableciendo una altura máxima de 6 metros, lo que permitió al algoritmo diferenciar los tipos de vegetación y arborización en la nube de puntos.

El algoritmo empleó filtros de altura y densidad para distinguir las distintas clases de vegetación. Los puntos con menor altura se clasificaron como vegetación baja, mientras que aquellos con mayor altura y densidad se clasificaron como vegetación alta.

La altura relativa de la vegetación se calculó mediante la diferencia entre el modelo digital de elevación (DEM) y Modelo digital de superficie (DSM), obteniendo un modelo de altura normalizado que permitió destacar la vegetación y otras estructuras del terreno, la ecuación 5 representa esta diferencia de DSM y DEM, permitiendo cuantificar la altura de la vegetación y clasificar en la categoría de baja, media y alta.

$$nDSM = DSM - DEM$$

Ecuación 5: Diferencia entre DSM y DEM

Después de aplicar los algoritmos de clasificación automática a la nube de puntos, se obtuvo como resultado la clasificación de suelo y vegetación, tal como se muestra en la ilustración 20.

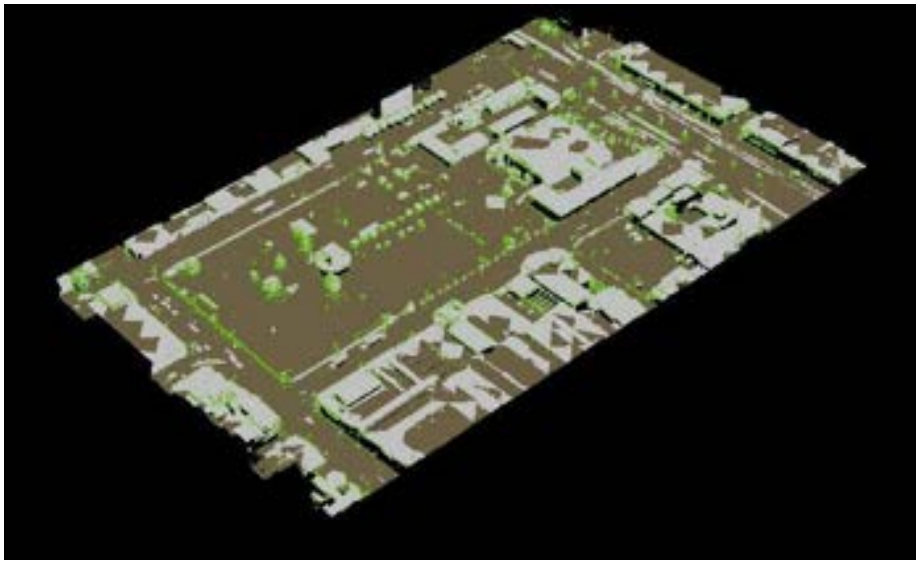


Ilustración 21. Clasificación automática de nube de puntos

Fuente. Elaboración propia.

Las variables de las iteraciones ejecutadas en el algoritmo de clasificación se evidencian en la ilustración 21.

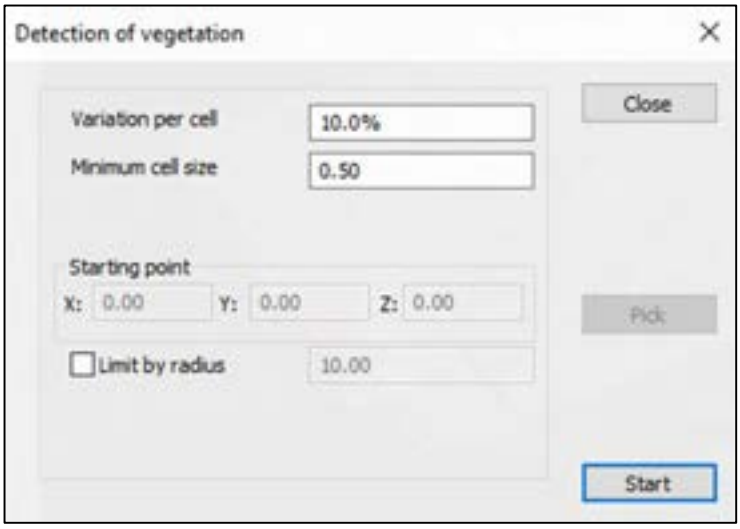


Ilustración 22. Interfaz de parámetros de iteración.

Fuente. Elaboración propia.

Con base en los parámetros descritos anteriormente, la tabla 3 detalla los datos correspondientes a cada iteración del proceso de clasificación de la nube de puntos. Para cada iteración se establecieron cuatro parámetros de clave:

- **Variación de altura en la celda (º):** Define el rango máximo de variación de la altura permitida dentro de cada celda de análisis.
- **Tamaño mínimo de celda:** Especifica el área mínima considerada para segmentar la información en el proceso de clasificación.
- **Pendiente de tolerancia (º):** Indica el Angulo máximo permitido entre celdas adyacentes para determinar cambios significativos en la inclinación.
- **Elevación:** Representa el valor promedio asignado a las celdas analizadas.

Numero de iteraciones	Variación de altura en la celda (º)	Tamaño mínimo de celda	Pendiente de tolerancia (º)	Elevación
1	15 º	0.5	10 º	0.2
2	10 º	0.8	15 º	0.1
3	10 º	0.5	15 º	0.3
4	12 º	0.9	13 º	0.4
5	19 º	0.8	11 º	0.8

Tabla 3. Parámetros de clasificación en las iteraciones.

Fuente. Elaboración propia.

Para lograr una clasificación adecuada de la nube de puntos, se realizó una clasificación manual

con el objetivo de mejorar la representación del terreno. Esta nueva clasificación se utilizó como referencia para comparar el nivel de precisión en cada una de las iteraciones ejecutadas. Como se observa en las ilustraciones siguientes y tabla 4.

Código ID	Categoría	Color
2	Suelo	Café o beige
3	Vegetación baja	Verde claro
4	Vegetación media	Cian
5	Vegetación alta	Verde oscuro
6	Edificación	Naranja o gris

Tabla 4. Parámetros de clasificación manual.

Fuente. Elaboración propia.

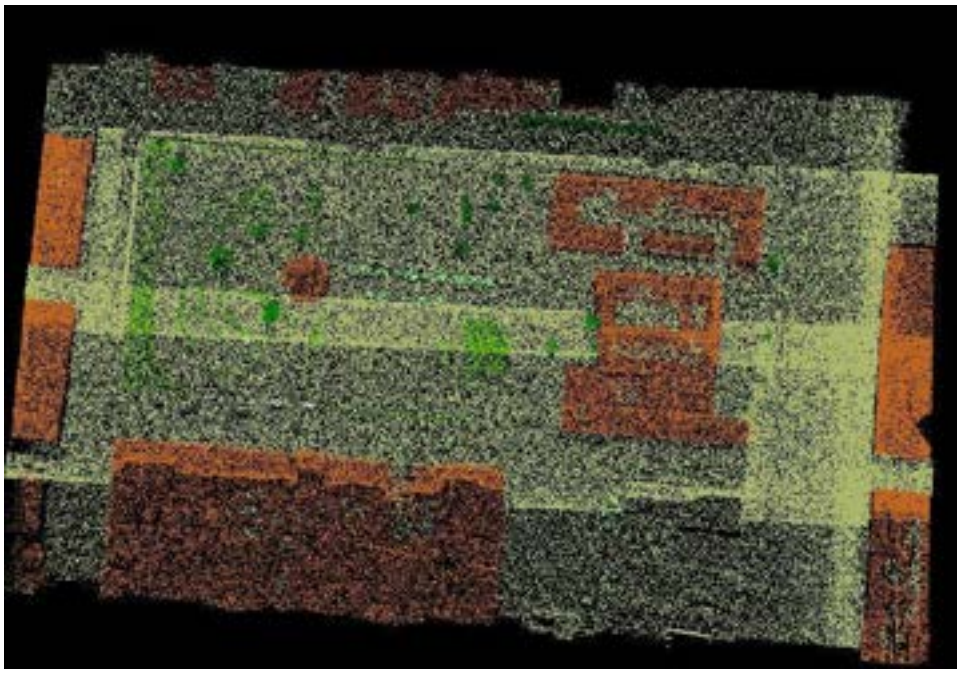


Ilustración 23. Resultado de la primera clasificación manual de la nube de puntos.

Fuente. Elaboración propia.

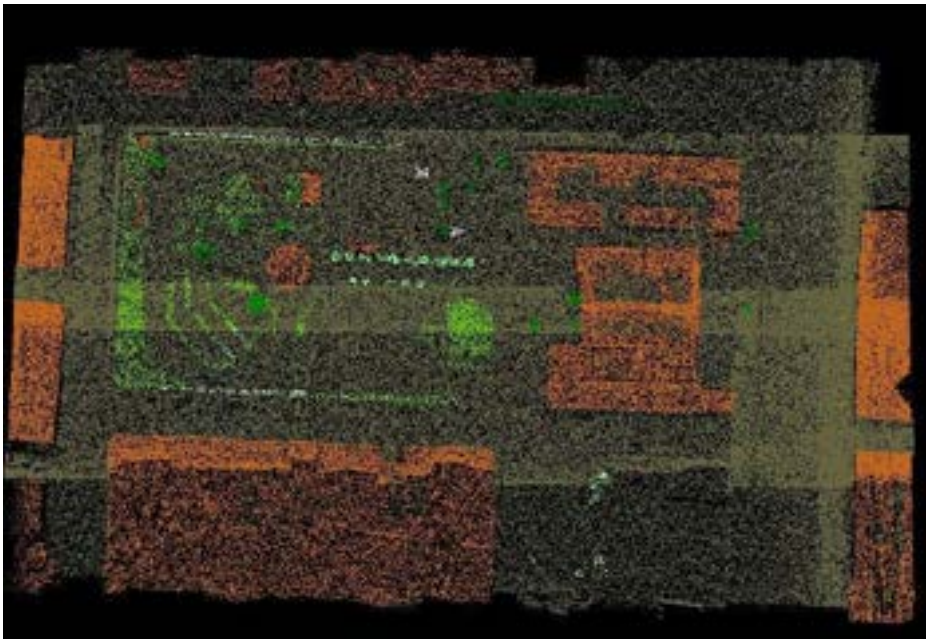


Ilustración 24. Resultado de la segunda clasificación manual de la nube de puntos.

Fuente. Elaboración propia.

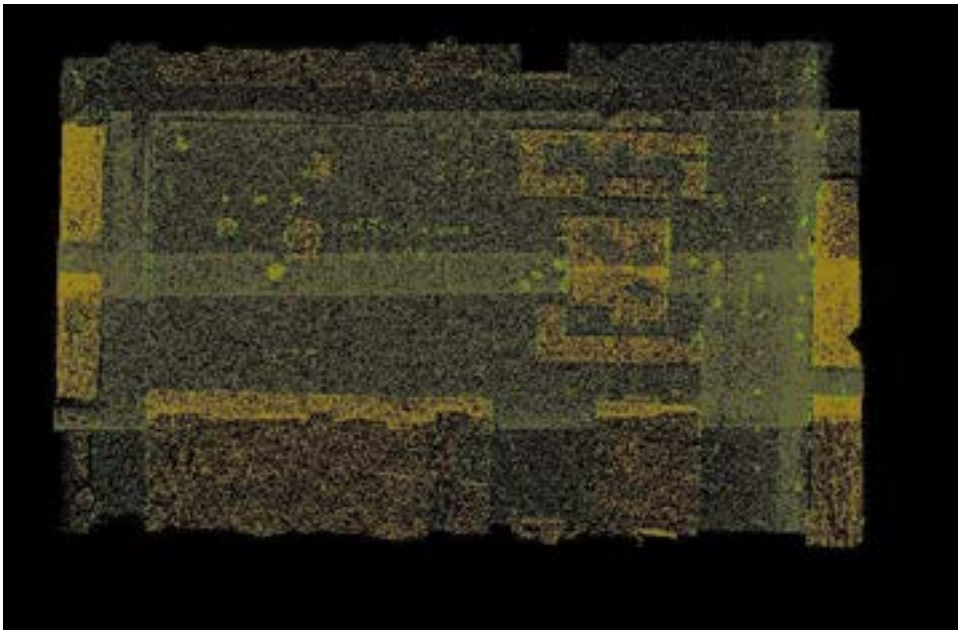


Ilustración 25. Resultado de la tercera clasificación manual de la nube de puntos.

Fuente. Elaboración propia.

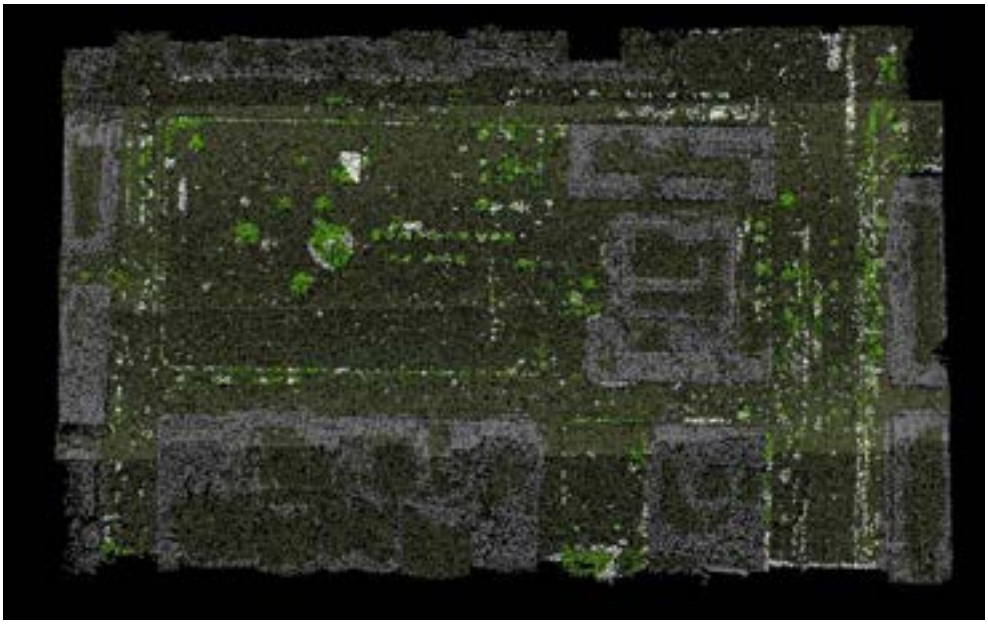


Ilustración 26. Resultado de la cuarta clasificación manual de la nube de puntos.

Fuente. Elaboración propia.

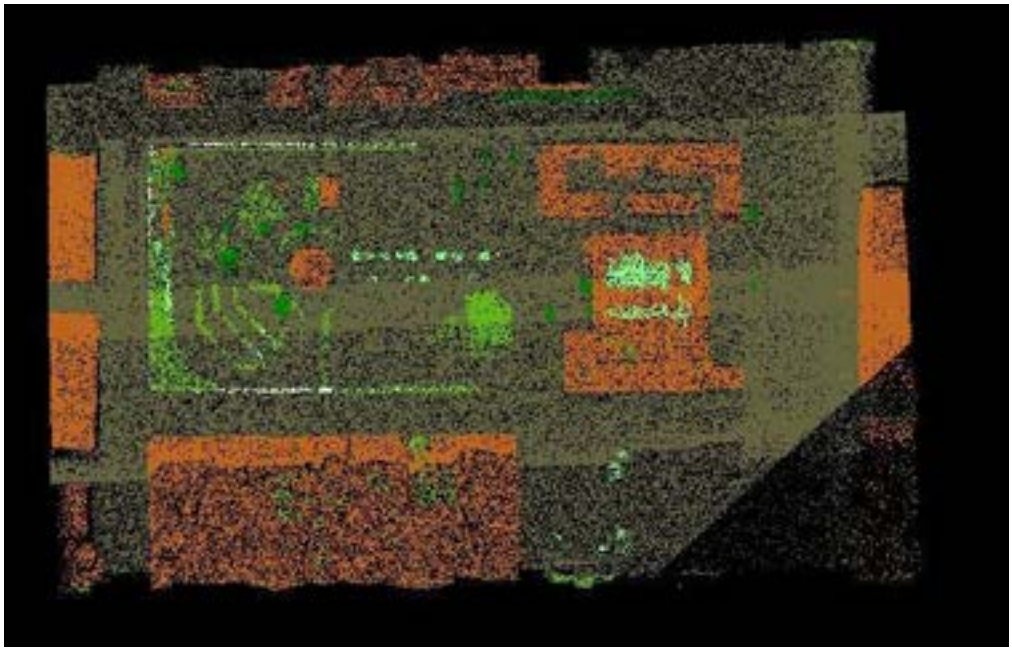


Ilustración 27. Resultado de la quinta clasificación manual de la nube de puntos.

Fuente. Elaboración propia.

Con base en las ilustraciones 22 a 26, se concluye que la clasificación más adecuada para la

categorización de los datos corresponde a la ilustración 23. Esta clasificación permite diferenciar las clases de vegetación en capas de alta, media y baja, representadas en distintos tonos de verde. Así mismo, se valida la categoría de suelo en color café y se resalta la clase de edificación en color naranja, garantizando una adecuada separación entre las diferentes categorías.

7.2.2. Clasificación - Regla heurística

Inicialmente, se cargaron los datos LiDAR en el software Global Mapper, donde se validó la información utilizando las diferentes categorías de visualización disponibles: elevación, intensidad y clasificación. En este caso, los datos LiDAR se encontraban en la clase 0 (sin clasificación). Por lo tanto, se realizó una validación preliminar para identificar y evaluar las clases de clasificación. En la ilustración 27 se presentan las capas de clasificación y código de identificación correspondiente.

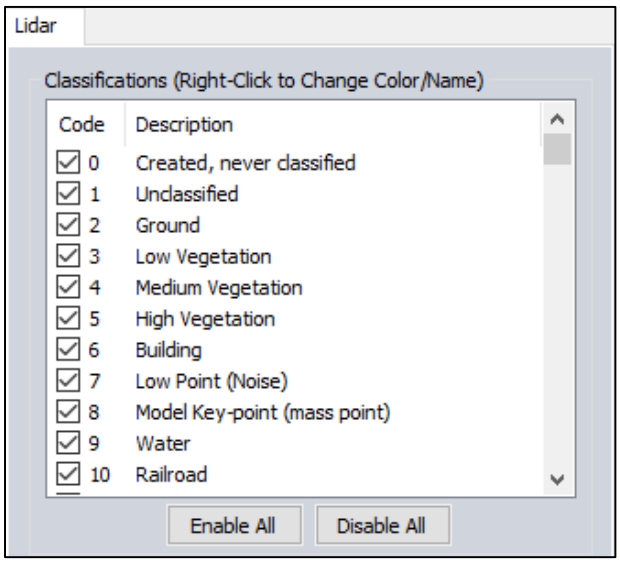


Ilustración 28. Clases de clasificación en el método heurístico.

Fuente. Elaboración propia.

En primera instancia se aplicó la clasificación de suelo con el objetivo de separar los puntos que representan los elementos de vegetación, edificios y estructuras elevadas del terreno propiamente dicho. Esta clasificación se llevó a cabo mediante algoritmos de filtrado, los cuales evalúan:

- Altura relativa.
- Continuidad espacial.
- Densidad de puntos.
- Características geométricas de la superficie de la nube de puntos.

El método de clasificación de suelo se basa en la identificación de altura relativa, la cual debe ser

consistente con la topografía del terreno. El algoritmo utiliza la ecuación 6 para calcular la altura relativa de cada punto con respecto al modelo digital del terreno (MDT).

$$h\,relative: h\,Point - h\,DTM$$

Ecuación 6: Fórmula relativa

Donde:

- H point corresponde a la altura de punto individual
- H DTM es la altura del terreno en la misma posición X, Y obtenida del MDT

Con base en la ecuación anterior un punto se clasifica como suelo si su altura relativa es cercana a cero, es decir h relative< $\in$, en donde $\in$, donde $\in$ es un pequeño umbral de tolerancia, en la ilustración 28 se observa la clasificación de suelo obtenida.

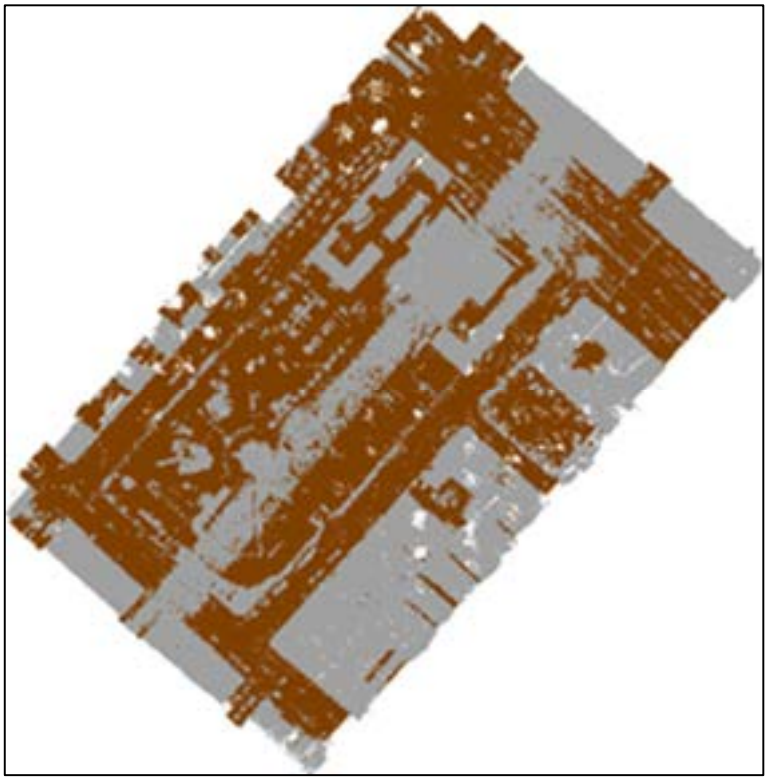


Ilustración 29. Clasificación de suelo.

Fuente. Elaboración propia.

Las variables utilizadas para la identificación del suelo se muestran en la ilustración 29.



Ilustración 30. Parámetros de clasificación de suelo.

Fuente. Elaboración propia.

A continuación, se efectuó una iteración para ajustar la precisión de los puntos clasificados como suelo. Este proceso incluyo:

1. El ajuste progresivo del filtro de clasificación, eliminando puntos fuera de las áreas clasificadas como suelo.
2. Recalculo el Modelo digital de terreno (MDT).

La precisión del ajuste se evaluó utilizando la fórmula del error cuadrático medio (RMSE) entre el MDT y los puntos del suelo clasificado con la finalidad de minimizar el error en cada paso.

$$RMSE = \sqrt{\frac{1}{N}\Sigma_{1=1}^{N}(h, point, i - h\ MDT, i)^2}$$

Ecuación 7: Fórmula de error medio cuadrático.

En donde:

- N corresponde al número total de puntos clasificados como suelo.
- H point, i es la altura del punto i.

- H MDT, i representa la altura del modelo de terreno en el mismo punto.

Este procedimiento iterativo permitió mejorar la precisión del modelo del suelo ajustando los resultados de la clasificación obtenida de la clase de suelo. Con la clase de suelo correctamente ajustada, se procedió a la clasificación de vegetación, utilizando la ecuación de altura relativa para la nube de puntos LiDAR. El algoritmo se basa en la diferencia entre:

- La altura del punto (h point).
- La altura del terreno subyacente (h terreno) en la misma localización horizontal.

La ecuación utilizada es:

$$F(\{X1, X2, \dots Xn\}) \approx g\ (h(X1), \dots h\ (Xn))$$

Ecuación 8: Ecuación de h relativa.

- H punto (X, Y) es la altura del punto Lidar en la posición (X, Y).

- H terreno (X, Y) simboliza la altura del terreno obtenida del modelo digital de terreno (MDT).

La rutina de clasificación de vegetación se fundamentó en calcular la altura relativa de cada punto LiDAR a partir del Modelo Digital de Terreno (MDT), según lo explicado anteriormente. La información de vegetación se clasifico en diferentes categorías basadas en la altura relativa, Estos umbrales fueron establecidos mediante un análisis estadístico de distribución de altura relativa. En la tabla 4 se presenta el análisis estadístico correspondiente a cada categoría de vegetación, incluyendo la clase de suelo.

Categoría	**Análisis estadístico**
Suelo	$\leq \epsilon$
Vegetación baja	ϵ < h relativa ≥ h1
Vegetación media	H1 < h relativa ≤ h2
Vegetación alta	H relativa > h2

Tabla 5. Categorización de vegetación según altura relativa.

Fuente. Elaboración propia.

La variable ϵ representa el umbral de tolerancia para considerar un punto LiDAR como perteneciente a la clase de suelo, mientras que las variables de h1 y h2 simbolizan los umbrales que definen las diferentes categorías de vegetación.

Luego de aplicar los algoritmos de clasificación automática en la nube de puntos se obtuvo como resultado la clasificación de suelo y vegetación, tal como se muestran en la ilustración 31. Los colores representan cada clase, facilitando la identificación visual de la clasificación obtenida.

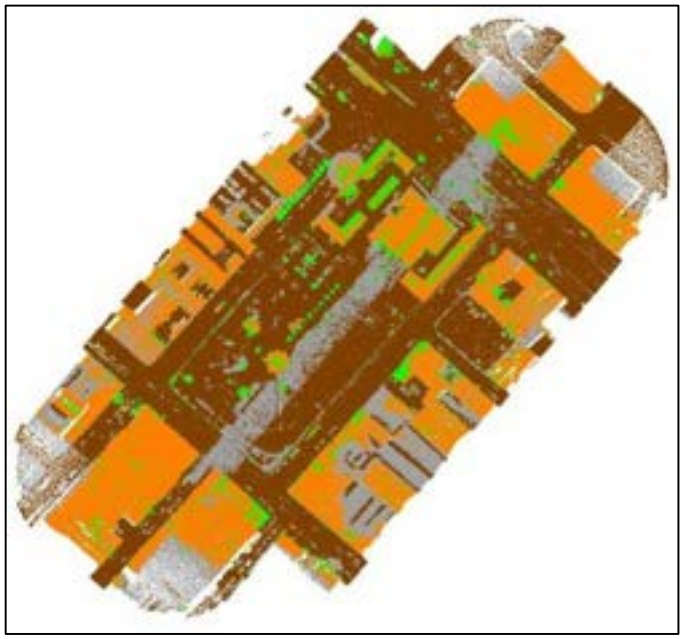


Ilustración 31. Clasificación de la nube de puntos en la categoría suelo y vegetación.

Fuente. Elaboración propia.

En la tabla 5 se presentan las iteraciones realizadas en la nube de puntos utilizando el método de clasificación basada en regla heurística. Se detallan los ajustes aplicados a los parámetros de: altura mínima, distancia mínima, distancia máxima y ángulo de escaneo, para cada iteración correspondiente a la zona de estudio:

Número de iteración	Altura mínima sobre el suelo	Distancia máxima coplanar	Distancia mínima de vegetación	Angulo máxima coplanar	Ángulos de escaneo
1	3	0.10	0.10	5	-35 y 35 º
2	2	0.8	1	15	0
3	0.2	0.3	10	1	-5 y 5 º
4	2	0.9	20	45	-45 y 45 º
5	1	10	12	17	0

Tabla 6. Parámetros de ajuste de la nube de puntos.

Fuente. Elaboración propia.

En cada iteración, los parámetros de clasificación se ajustaron para mejorar la precisión, especialmente en la identificación y distribución de nube de puntos correspondiente a vegetación e infraestructura. Inicialmente, se ajustaron los umbrales de altura relativa empleados para la clasificación de vegetación (Alta, media y baja). Estos ajustes permitieron reducir el error de clasificación.

Cabe mencionar que a medida que se efectuaba cada iteración se modificó el criterio de continuidad espacial evaluando la altura de cada punto radio determinado respecto a puntos vecinos como se define en la ecuación 9 y se ajustó los parámetros de densidad para identificar puntos de vegetación agrupados densamente y con alturas similares.

$$\Sigma i[hi - hj] \leq \delta$$

Ecuación 9: Fórmula de continuidad espacial.

Los puntos que no cumplían con los criterios de continuidad o densidad para clasificarse como suelo fueron recategorizados en la clase de vegetación, con el objetivo de mejorar la clasificación. La Tabla 6 presenta las categorías de clasificación, junto con su código ID y el color de representación correspondiente

Código ID	Categoría	Color
2	Suelo	Gris
3	Vegetación	Verde
5	Edificación	Amarillo

Tabla 7. Criterios de clasificación.

Fuente. Elaboración propia.

A continuación, se muestran las ilustraciones 31 a 35 que representa los resultados de las clasificaciones según los criterios de continuidad.

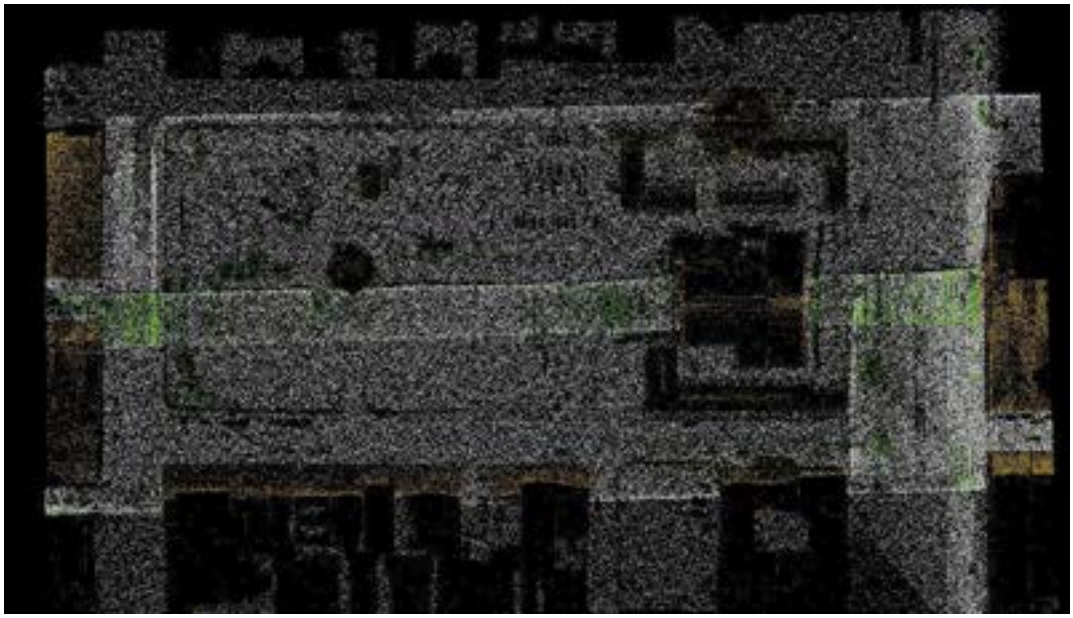


Ilustración 32. Resultado de la primera clasificación según criterio de continuidad.

Fuente. Elaboración propia.

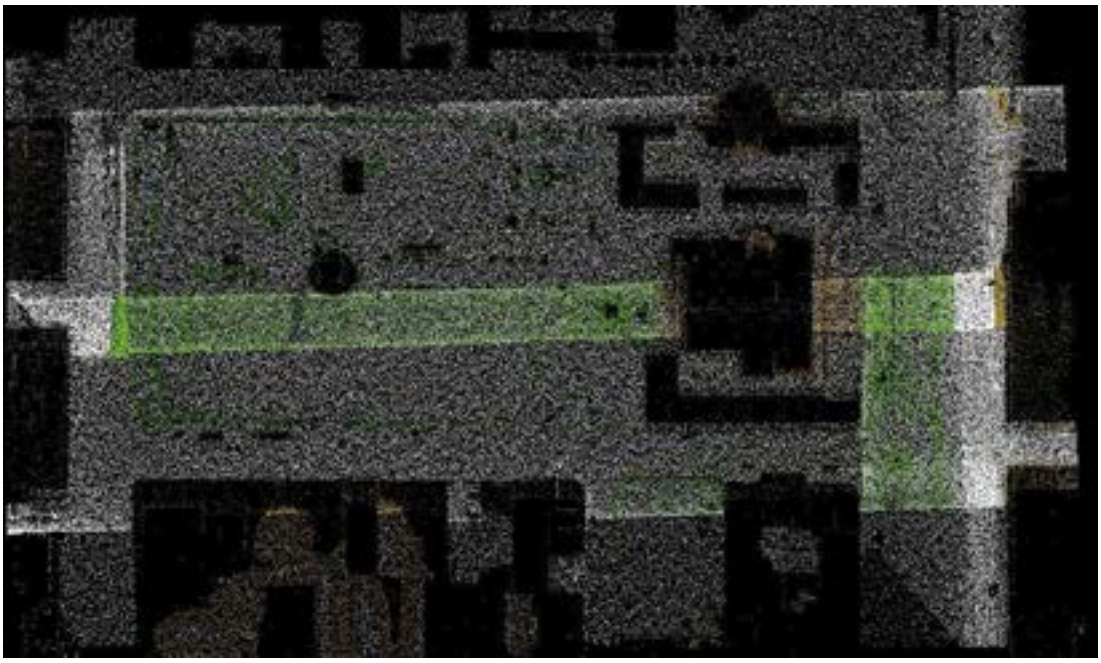


Ilustración 33. Resultado de la segunda clasificación según criterio de continuidad.

Fuente. Elaboración propia.

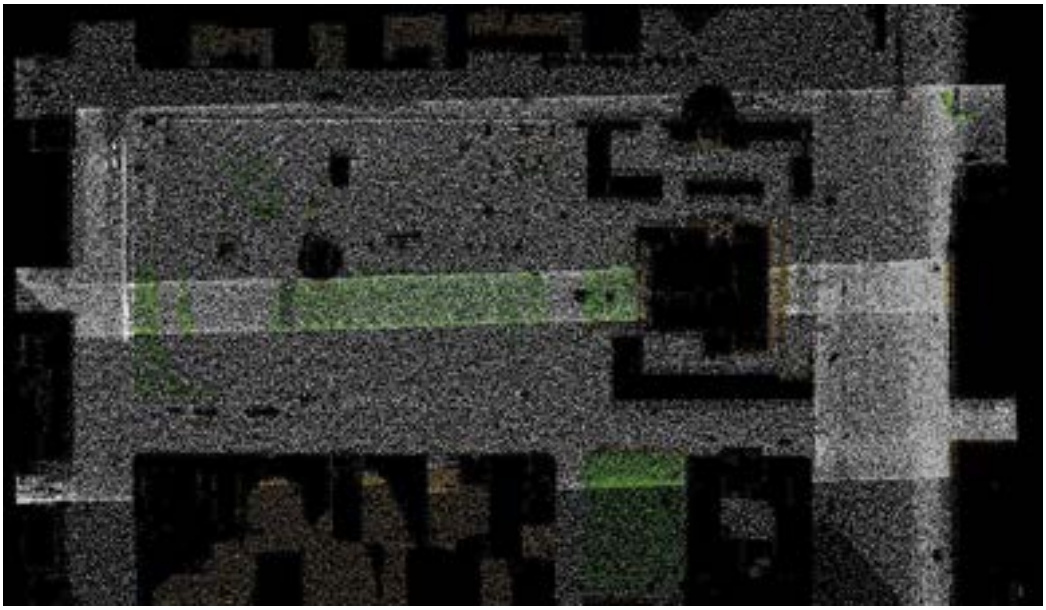


Ilustración 34. Resultado de la tercera clasificación según criterio de continuidad.

Fuente. Elaboración propia.

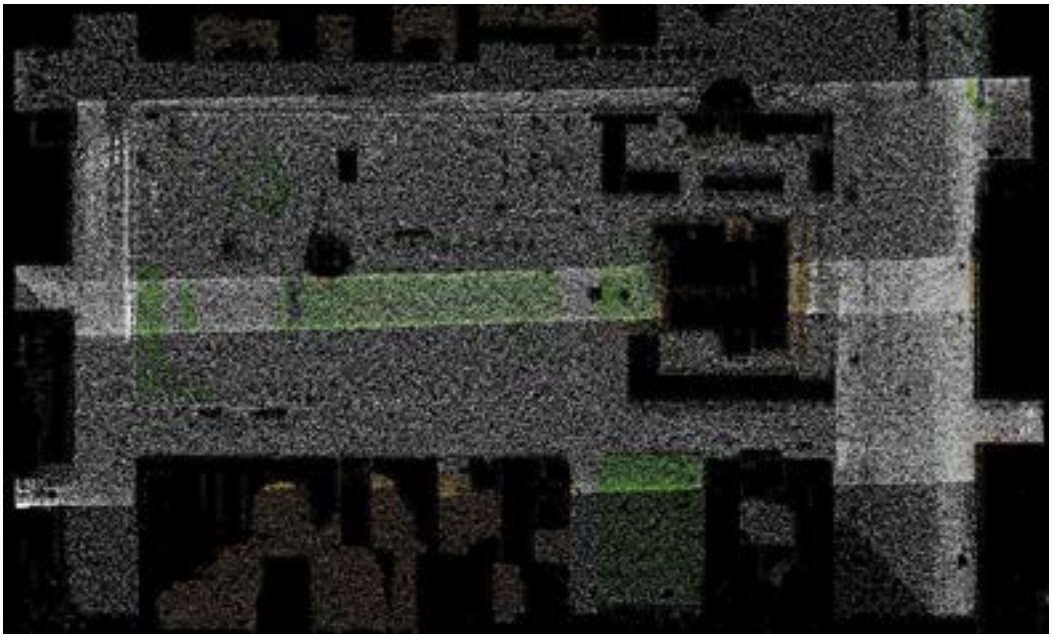


Ilustración 35. Resultado de la cuarta clasificación según criterio de continuidad.

Fuente. Elaboración propia.

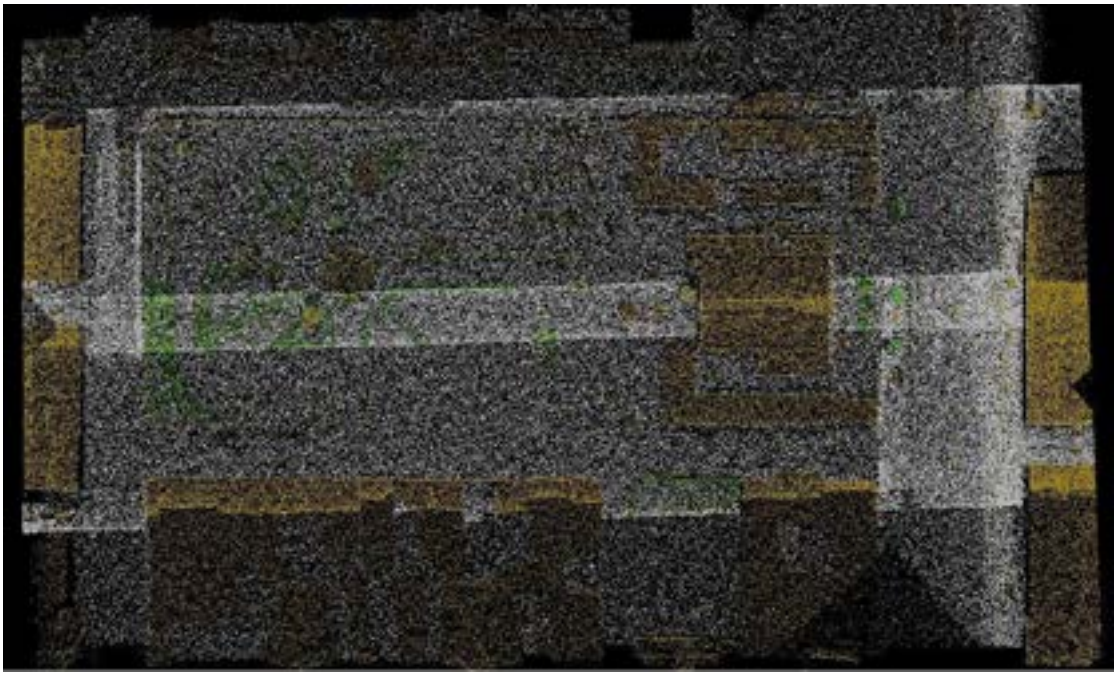


Ilustración 36. Resultado de la quinta clasificación según criterio de continuidad.

Fuente. Elaboración propia.

Con base en los resultados obtenidos anteriormente se concluye que el mejor resultado de clasificación en cada una de las categorías de clasificación corresponde a la ilustración 35, en donde se muestra que la clase de vegetación cubre determinadas zonas de cobertura vegetal y arbustiva sin capturar información adicional o incorrecta de otros objetos, así mismo se evidencia una adecuada clasificación de suelo e infraestructura.

8. Análisis estadístico

En esta sección se presentan los resultados obtenidos tras el procesamiento de clasificación, a partir de los métodos basados en regla heurística y algoritmo PointNet para la identificación de vegetación. A continuación, se expone la validación de los datos correspondientes a las pruebas realizadas, destacando los resultados mediante representaciones gráficas y tablas, con un énfasis particular en las ilustraciones que evidencian la precisión y efectividad de la clasificación de la vegetación.

8.2. Clasificación de nube de puntos

8.2.1. Método regla heurístico

Inicialmente, se presentan los resultados de la clasificación de la nube de puntos correspondientes a cada iteración aplicada, con sus respectivas capas de: Baja vegetación, media vegetación y alta vegetación.

Baja Vegetación

A continuación, se muestran los resultados obtenidos tras aplicar las modificaciones correspondientes en cada iteración de clasificación de la nube de puntos, utilizando esta técnica sobre la información LiDAR recopilada durante el levantamiento topográfico aéreo.

En la ilustración 36 se observa que la clasificación en la categoría de "vegetación baja" incluye información de vegetación con baja pendiente. Sin embargo, también categoriza elementos de la vía, como separadores viales que no pertenece a la información de vegetación

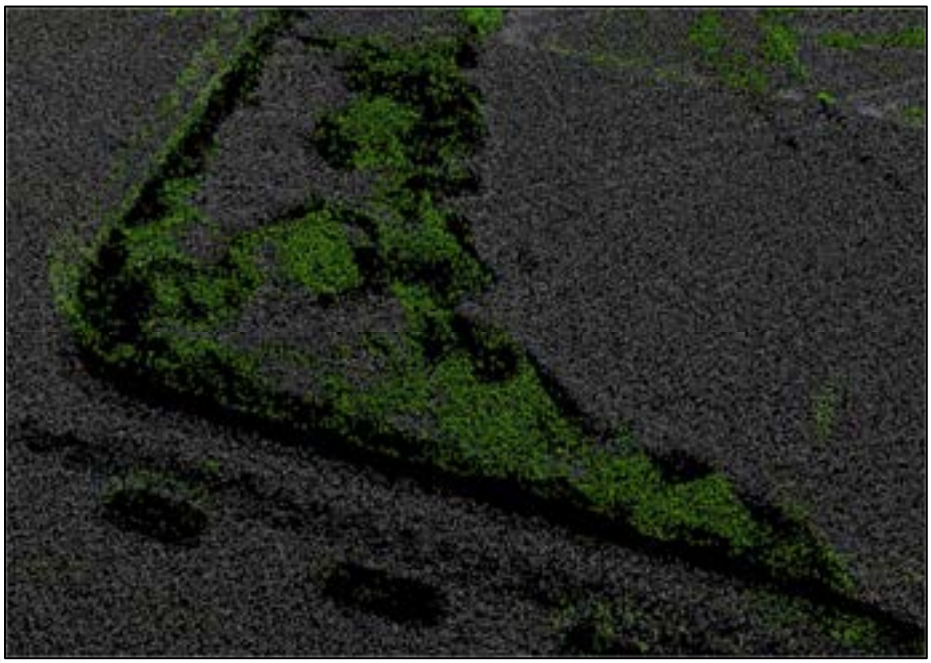


Ilustración 37. Resultado de clasificación primera en categorìa baja vegetaciòn.

Fuente. Elaboración propia.

En la siguiente iteración, representada en la ilustración 37, se muestra que la clasificación abarca un poco más de la cubierta vegetal, pero incluye completamente la nube de puntos que representa el separador vial, además de tomar datos de la vía.



Ilustración 38. Resultado de clasificación segunda en categoría baja vegetación.

Fuente. Elaboración propia.

En la ilustración 38, se evidencia que la clasificación categorizó adecuadamente la información del césped y parte de las hierbas existentes en el suelo, sin incorporar datos que no corresponden a vegetación.

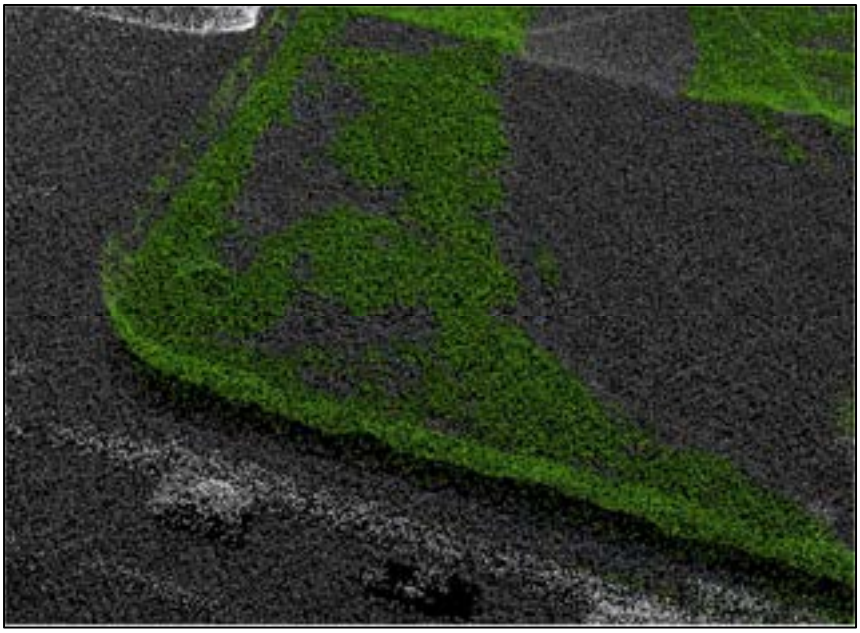


Ilustración 39. Resultado de clasificación tercera en categoría baja vegetación.

Fuente. Elaboración propia.

En la ilustración 39, se aprecia que la clasificación de la clase "vegetación baja" incluye la cobertura vegetal de la zona. Además, se observa que las áreas correspondientes a la vía están clasificadas en la capa de suelo, mientras que los puntos de la nube correspondientes a los separadores viales permanecen en la capa no clasificada. Estas categorizaciones permiten validar mejor la separación de cada una de las capas, destacando que la clase de vegetación es la más relevante en el caso de estudio.

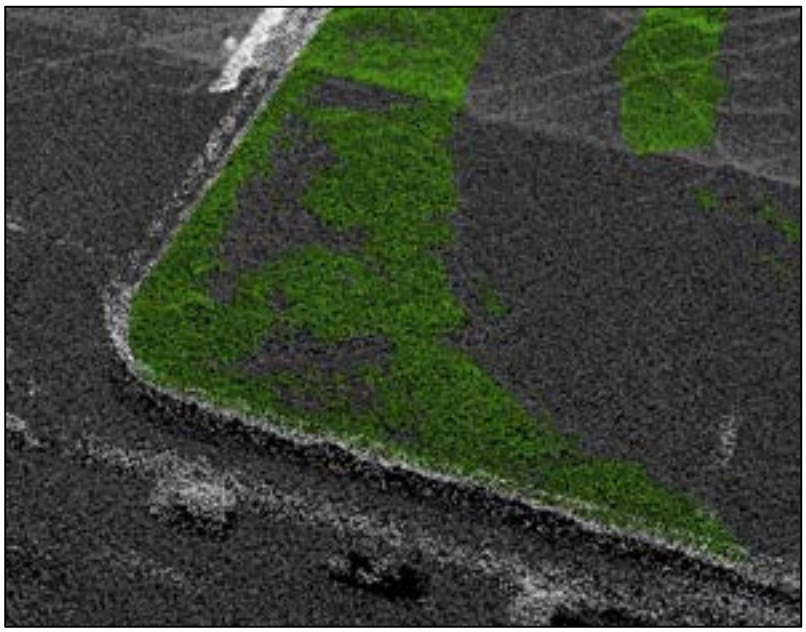


Ilustración 40. Resultado de clasificación cuarta en categoría baja vegetación.

Fuente. Elaboración propia.

Finalmente, en la ilustración 40, se muestra la clasificación de la cobertura vegetal en la zona vegetativa. Sin embargo, se observa que parte de la información correspondiente al borde de los árboles fue categorizada en la clase de "edificación". Así mismo, se analizó que los puntos LiDAR correspondientes a los separadores viales fueron clasificados como "edificación".



Ilustración 41. Resultado de clasificación quinta en categoría baja vegetación.

Fuente. Elaboración propia.

Con base en las ilustraciones 36, 37, 38, 39 y 40 se concluye que cada iteración categorizó la nube de puntos en la clase de "vegetación baja". No obstante, las iteraciones representadas en las ilustraciones 38 y 39 son las que mejor representan la clasificación en la categoría de "vegetación baja".

Media vegetación

A continuación, se presentan los resultados de las áreas clasificadas en la categoría de vegetación media, evaluadas en cada iteración con base en las zonas con condiciones de pendiente media en la nube de puntos. Los resultados se pueden observar en las ilustraciones 41, 42, 43, 44 y 45.

En la ilustración 41, se evidencia que los puntos de la nube clasificaron correctamente los árboles medianos colindantes al sendero peatonal y parqueadero de la zona de estudio. Sin embargo, se identifican errores en la clasificación, ya que parte de la cobertura vegetal ha sido categorizada en la clase "suelo".

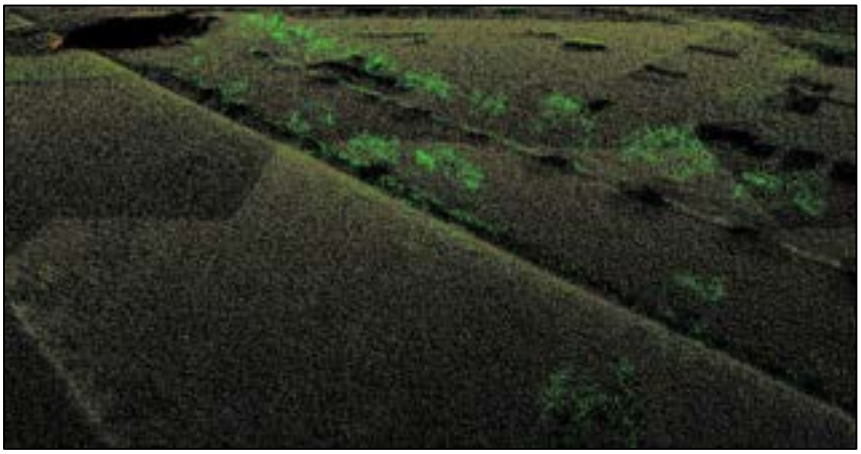


Ilustración 42. Resultado de clasificación primera en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 42, se observa que la clasificación en la capa de "vegetación media" no es precisa, ya que gran parte de los árboles medianos no están correctamente clasificados. Asimismo, se nota que los puntos correspondientes a la cobertura vegetal (césped) han sido categorizados tanto en la clase de "vegetación media" como en la de suelo.

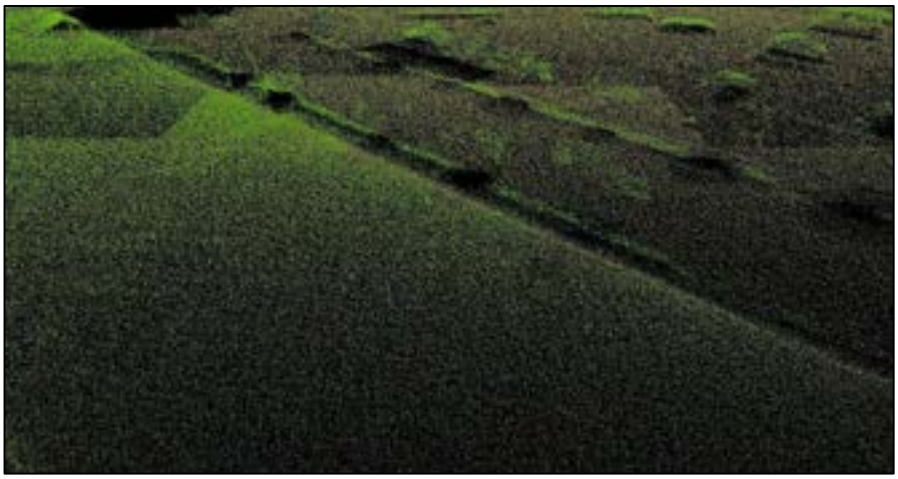


Ilustración 43 Resultado de clasificación segunda en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 43 se muestra que la clasificación asigno una baja densidad de puntos de cobertura vegetal a la clase de suelo. Sin embargo, no todos los árboles de mediana altura fueron clasificados correctamente en la capa de "vegetación media", ya que algunos se encuentran en la clase de "suelo".

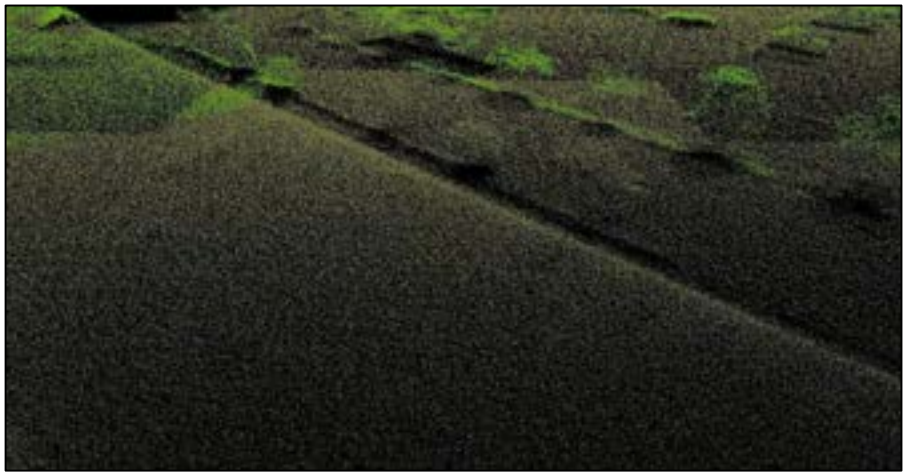


Ilustración 44. Resultado de clasificación tercera en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 44, se evidencia que gran parte de los puntos clasificados en la capa de vegetación media no corresponden a vegetación. En esta clasificación, se categorizaron puntos de suelo, césped y vegetación media dentro de la misma capa, lo que genera inconsistencias en la clasificación.



Ilustración 45. Resultado de clasificación cuarta en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 45**,** se aprecia que menos de la mitad de la vegetación arbustiva mediana ha sido correctamente categorizada como "vegetación media". El resto de los árboles se clasificaron en la capa de "edificación". Además, se observa que parte de la información correspondiente a "baja vegetación" (de color verde) también se incluyó incorrectamente en la clase de "vegetación media".

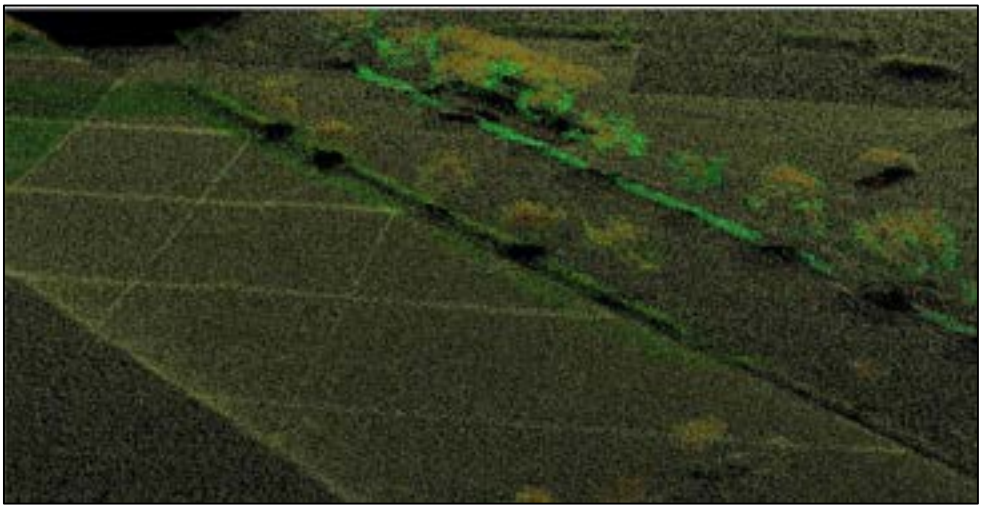


Ilustración 46. Resultado de clasificación quinta en categoría media vegetación.

Fuente. Elaboración propia.

Finalmente, a partir de las ilustraciones 41, 42, 43, 44 y 45, se concluye que todas las iteraciones presentan deficiencias en la clasificación de la clase de "vegetación media". No obstante, es importante destacar que la ilustración 41 representa de mejor manera la categorización de los puntos LiDAR en esta clase.

Alta vegetación

En las ilustraciones 46 a 50 se presentan los resultados obtenidos tras cinco iteraciones utilizando el método de regla heurística de clasificación en la zona de estudio caracterizado por alta pendiente y vegetación densa.

En la ilustración 46, se evidencia una clasificación completa de los árboles en la capa de alta vegetación del caso de estudio. No obstante, parte de la vegetación en una zona verde colindante también fue clasificada erróneamente como alta vegetación.

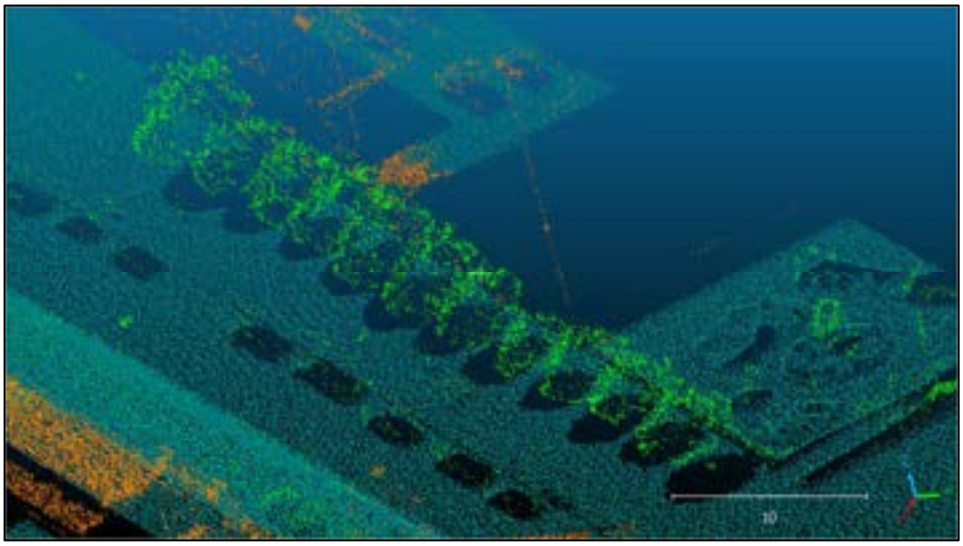


Ilustración 47. Resultado de la primera clasificación en categoría de alta vegetación.

Fuente. Elaboración propia.

En la ilustración 47, se evidencian errores en la clasificación de la vegetación alta en color amarillo, que presenta escasa información. Además, parte de la vegetación arbustiva fue clasificada incorrectamente como "no clasificado" en color azul oscuro.

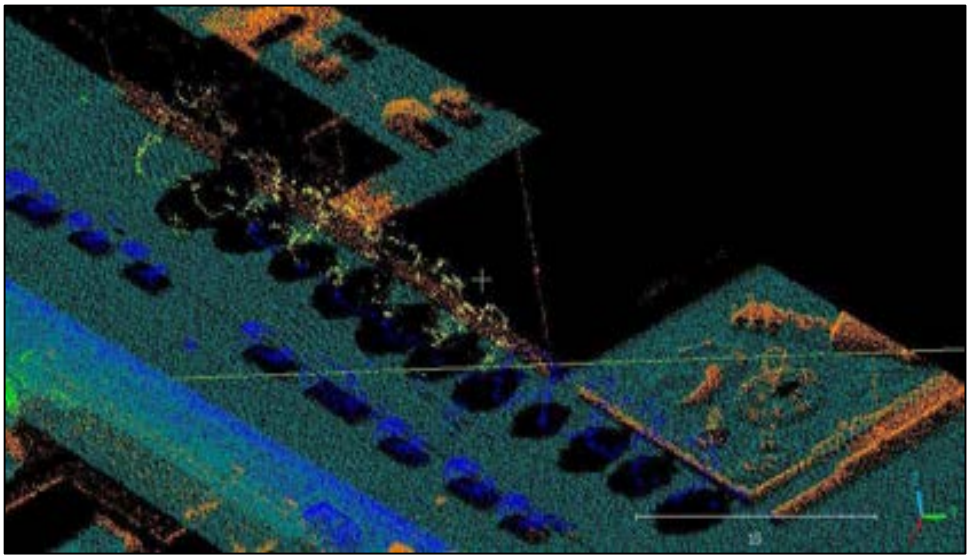


Ilustración 48. Resultado de la segunda clasificación en categoría de alta vegetación.

Fuente. Elaboración propia.

En la ilustración 48, se evidencia que la vegetación arbustiva no aparece clasificada en la capa de “alta vegetación”, y toda la información relevante se encuentra en la capa de "no clasificado" en color azul oscuro.

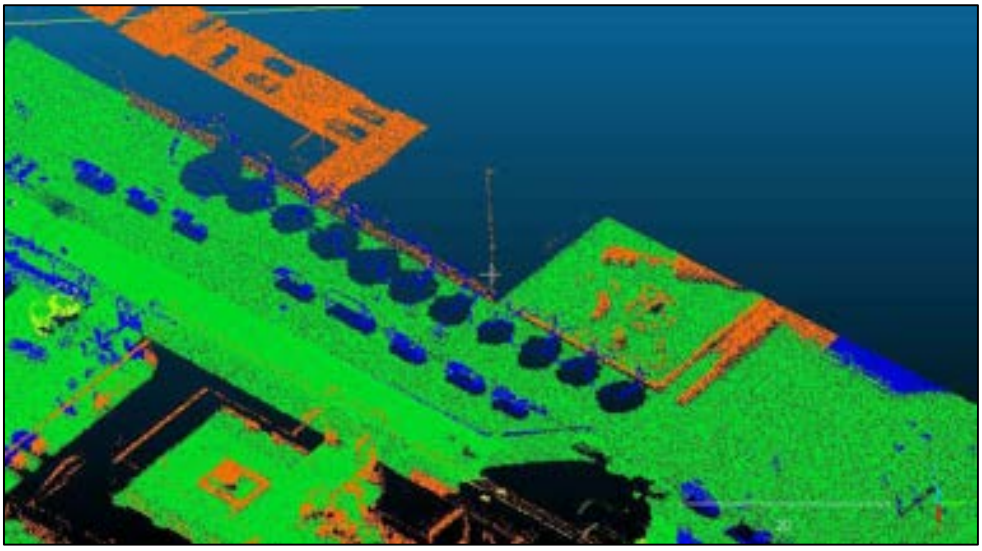


Ilustración 49. Resultado de la tercera clasificación en categoría de alta vegetación.

Fuente. Elaboración propia.

En la ilustración 49, se destaca un índice alto de datos clasificados como "no clasificado" en color rojo. Solo la parte superior de la vegetación arbustiva aparece correctamente clasificada como "alta vegetación” en color morado.

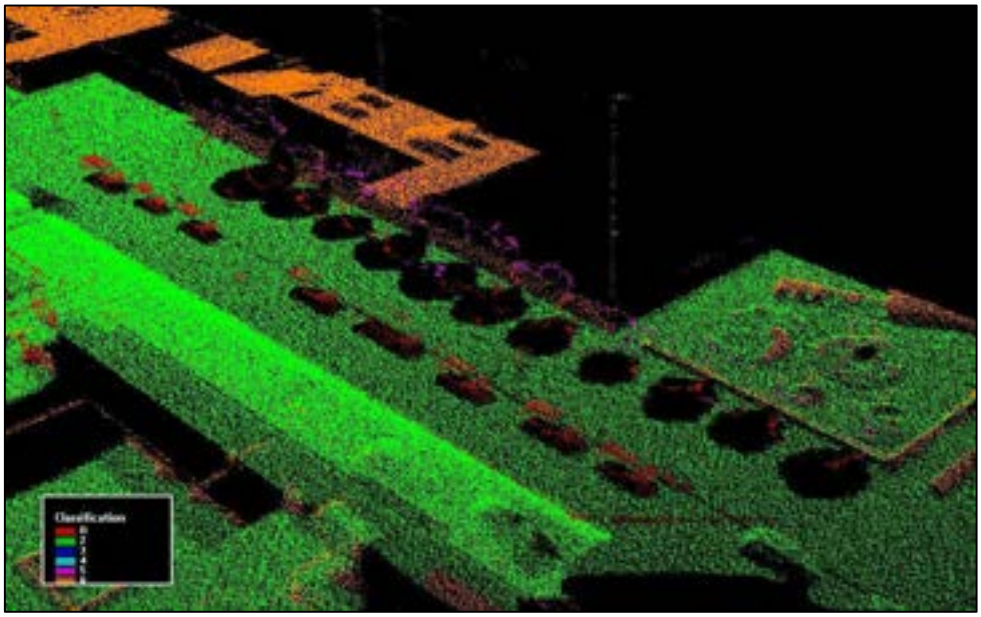


Ilustración 50. Resultado de la cuarta clasificación en categoría de alta vegetación.

Fuente. Elaboración propia.

En la ilustración 50, se visualiza que la clasificación de "alta vegetación" (color verde) incluye gran parte de la vegetación arborizada, pero también incorpora datos correspondientes a edificaciones cercanas y vehículos en vías cercanas.

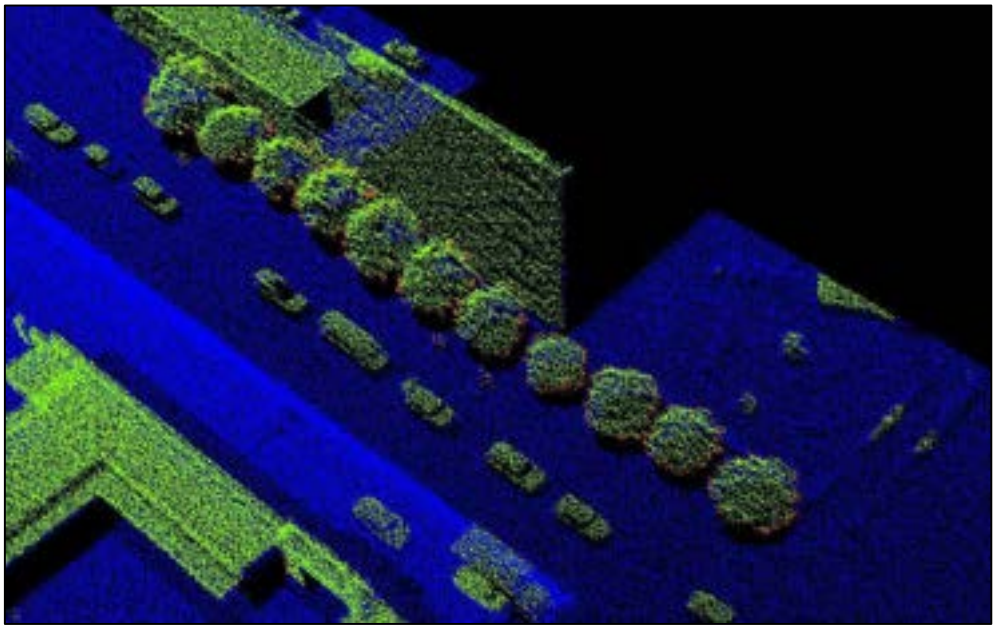


Ilustración 51. Resultado de la quinta clasificación en categoría de alta vegetación.

Fuente. Elaboración propia.

Con base en las ilustraciones anteriores se concluye que, en cada una de las clasificaciones obtenidas por el método de regla heurística, la iteración que permito clasificar debidamente los puntos LiDAR correspondientes a “alta vegetación” fue la ilustración 46.

8.2.2. Método Algoritmo Point Net

Antes de describir los resultados obtenidos, es importante resaltar que se realizaron múltiples iteraciones ajustando los parámetros del algoritmo PointNet. Este análisis considera las capas de baja vegetación, vegetación media y vegetación alta.

Baja vegetación

A continuación, se visualizan las ilustraciones 51, 52, 53, 54 y 55, se presentan los resultados obtenidos tras cada iteración de la clasificación de la nube de puntos, aplicando técnicas de aprendizaje profundo para la clase de “vegetación baja”.

En la ilustración 51 se muestra que la clase de “vegetación baja” de color verde clasificó la cobertura vegetal debidamente. No obstante, con base en la ortofoto obtenida se evidencia que también se clasifico información de infraestructura aledaña y vegetación arbustiva también fueron incluidas en esta capa en color verde oscuro.

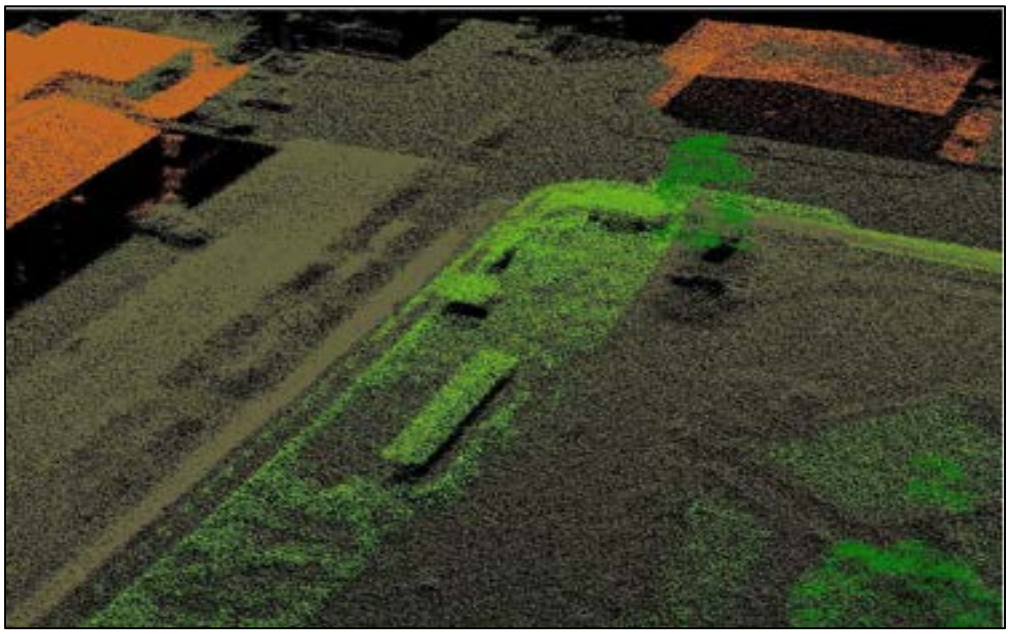


Ilustración 52. Resultado de primera clasificación en categoría baja vegetación.

Fuente. Elaboración propia.

En la ilustración 52 se visualiza una adecuada clasificación de la cobertura vegetal de color verde claro, diferenciando claramente la “vegetación baja” (color verde claro) de otras clases como suelo (gris) y edificación (naranja).

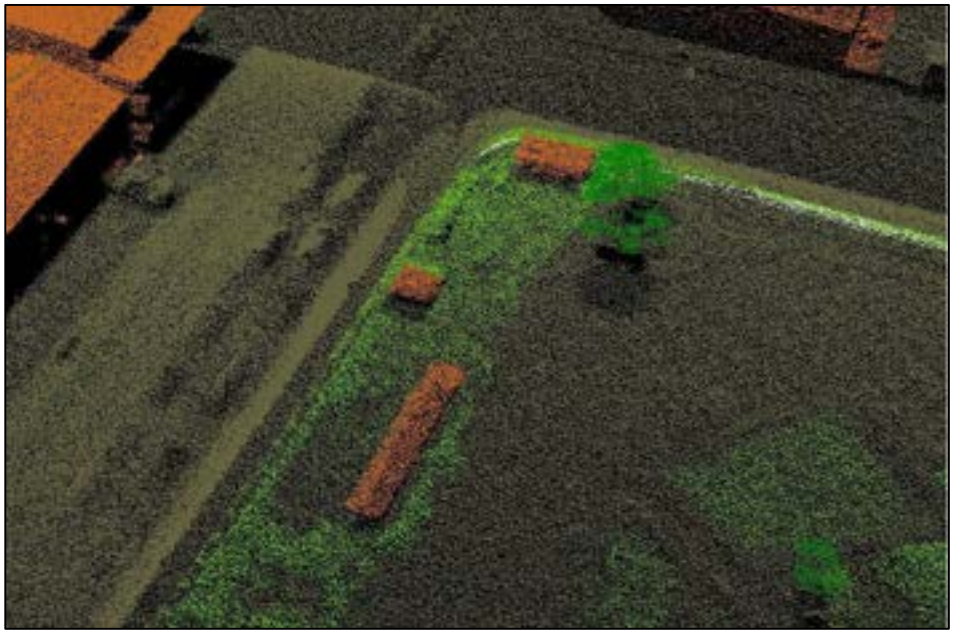


Ilustración 53 Resultado de segunda clasificación en categoría baja vegetación.

Fuente. Elaboración propia.

En la ilustración 53 Presenta un índice bajo de clasificación de “vegetación baja” de color verde claro. Parte de la información se clasificó incorrectamente en la capa de edificación en color amarillo.

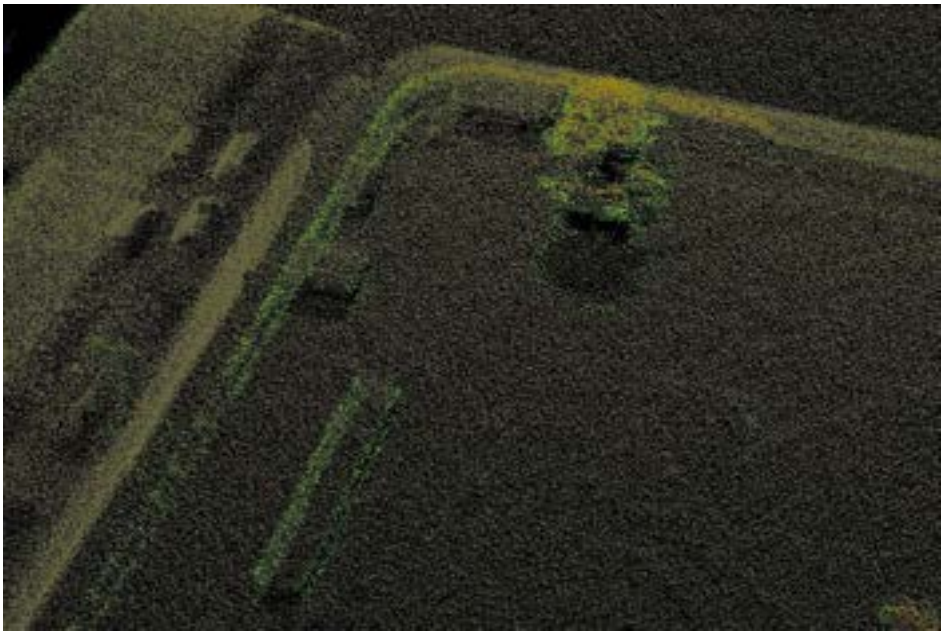


Ilustración 54. Resultado de tercera clasificación en categoría baja vegetación.

Fuente. Elaboración propia.

En la ilustración 54 se evidencia una clasificación de los datos de "vegetación baja". Sin embargo, no se ve en completitud la cobertura vegetal que debería estar clasificada en la capa, así mismo se visualiza que hay clasificación de la nube de puntos en la clase de "no clasificado" en la cobertura vegetal.

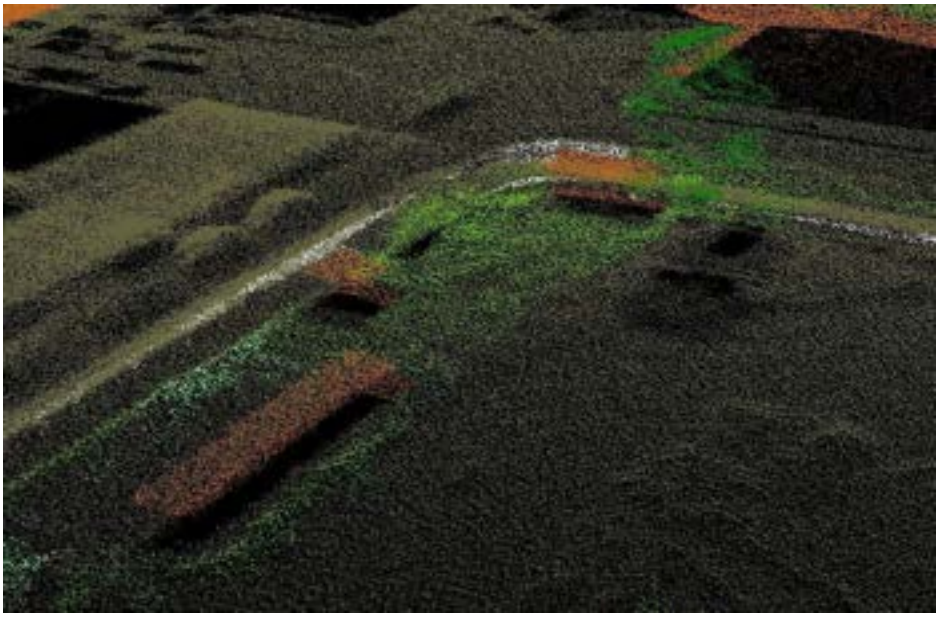


Ilustración 55. Resultado de cuarta clasificación en categoría baja vegetación.

Fuente. Elaboración propia.

En la ilustración 55 se evidencia que la clasificación es deficiente; datos de “vegetación baja” fueron asignados a la capa de edificación, y parte de las edificaciones cercanas aparecen clasificadas como “vegetación baja”.

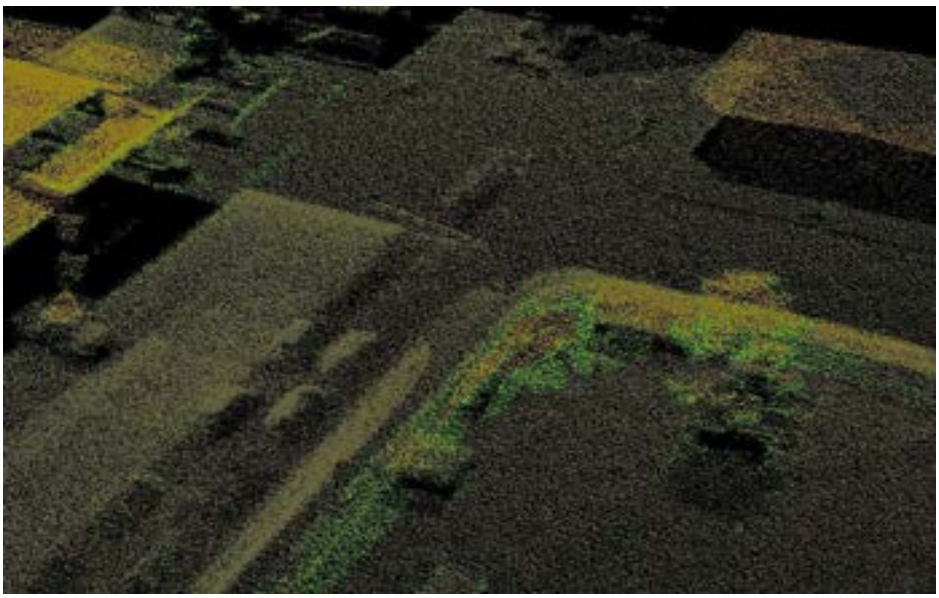


Ilustración 56. Resultado de quinta clasificación en categoría baja vegetación.

Fuente. Elaboración propia.

A partir de las ilustraciones 51 a 55 se concluye que la iteración que mejor clasifico los datos corresponde a la ilustración 52 debido a que fue la única que categorizó correctamente cada una de las entidades existentes.

Media vegetación

A continuación, se evaluaron las áreas clasificadas dentro de la categoría de “vegetación media”, obtenidas en cada iteración, considerando las zonas correspondientes a pendientes moderadas en la nube de puntos.

En la ilustración 56, se visualiza que la clasificación de media vegetación en color cian clasifico incluyo datos de la cobertura vegetal que debería estar clasificada en la clase de baja vegetación

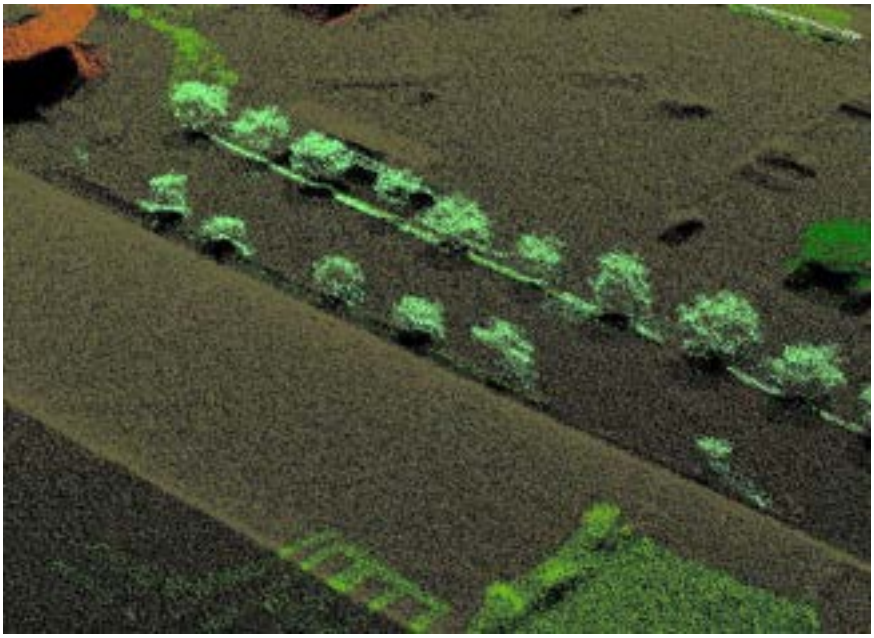


Ilustración 57. Resultado de primera clasificación en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 57, se visualiza que la clasificación no logro categorizar todos los puntos de la nube en la capa de “vegetación media” ya que la mitad de los datos fueron calificados en la capa de “suelo” de color gris mientras que la información correctamente clasificada de la vegetación se encuentra en color cian de la nube de puntos.

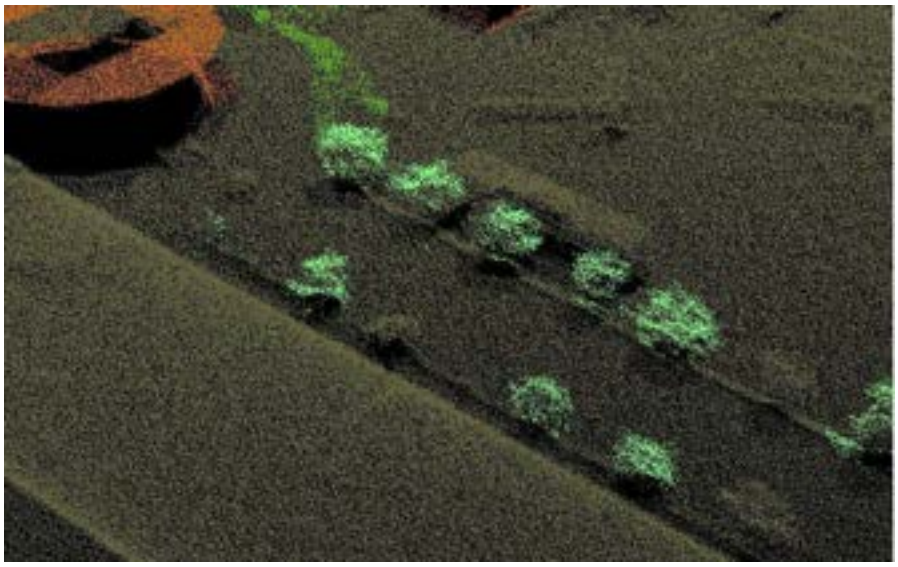


Ilustración 58. Resultado de segunda clasificación en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 58 se evidencia que la clasificación de “vegetación media” de los árboles en color verde solo fue limitada porque solo incluyo los puntos de los datos LiDAR en el contorno de los árboles mientras que en la zona central y superior de los árboles fueron clasificados en la capa de edificación en color amarillo, así mismo se visualiza que parte de la infraestructura aledaña fue clasificada en el borde superior.

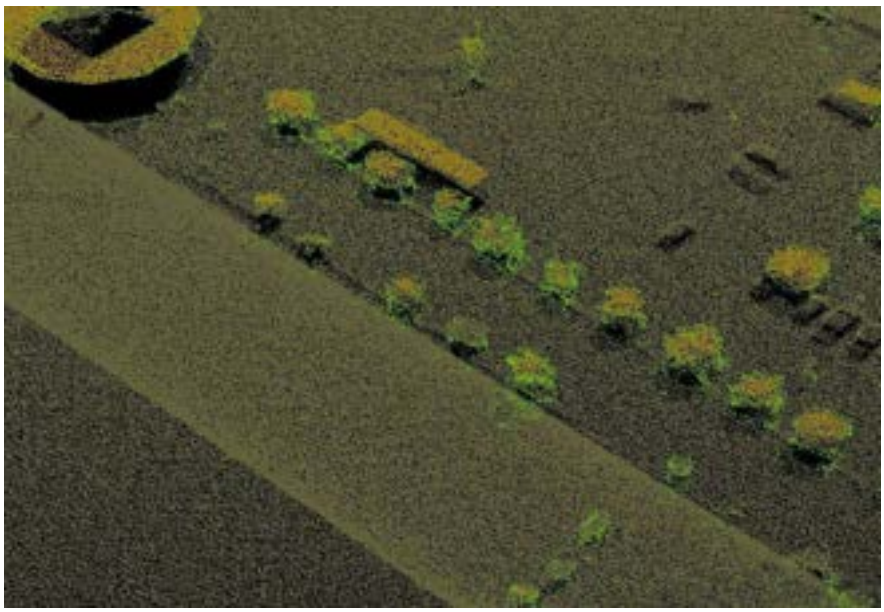


Ilustración 59. Resultado de tercera clasificación en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 59 se demuestra que la clasificación de vegetación categorizó los árboles en color cian. Sin embargo, también incorporó parte de la información los árboles em la clase de “suelo” de color gris adicionalmente se clasifico los puntos de la nube en la capa de “baja vegetación” de color verde claro de uno de los árboles.

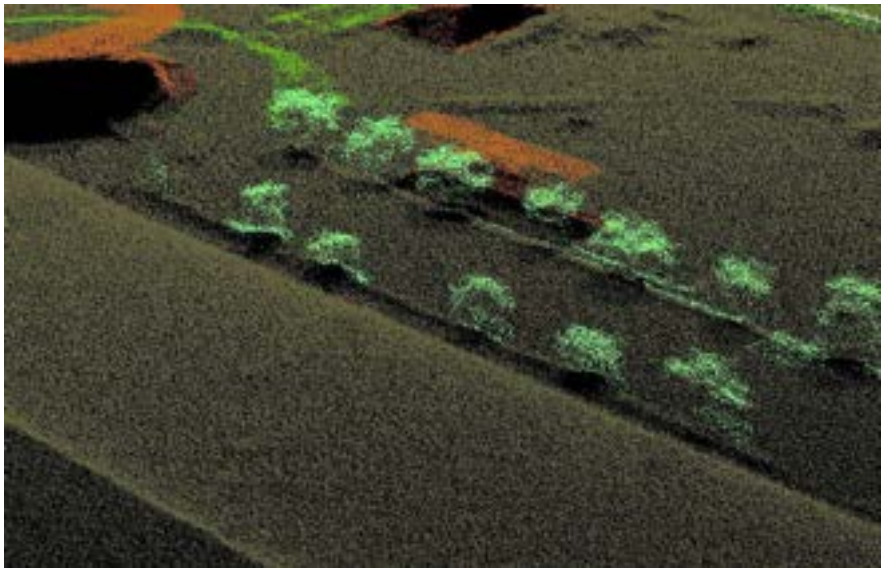


Ilustración 60. Resultado de cuarta clasificación en categoría media vegetación.

Fuente. Elaboración propia.

En la ilustración 60 se evidencia que la información de la categoría de "suelo" en color gris incluye parte de los datos de la nube de puntos correspondiente a los árboles y la capa de edificación incorporo datos de los árboles en color amarillo adicionalmente se visualizó que la capa de "vegetación media" solo clasifica una pequeña parte de los datos en la nube de puntos de color verde.

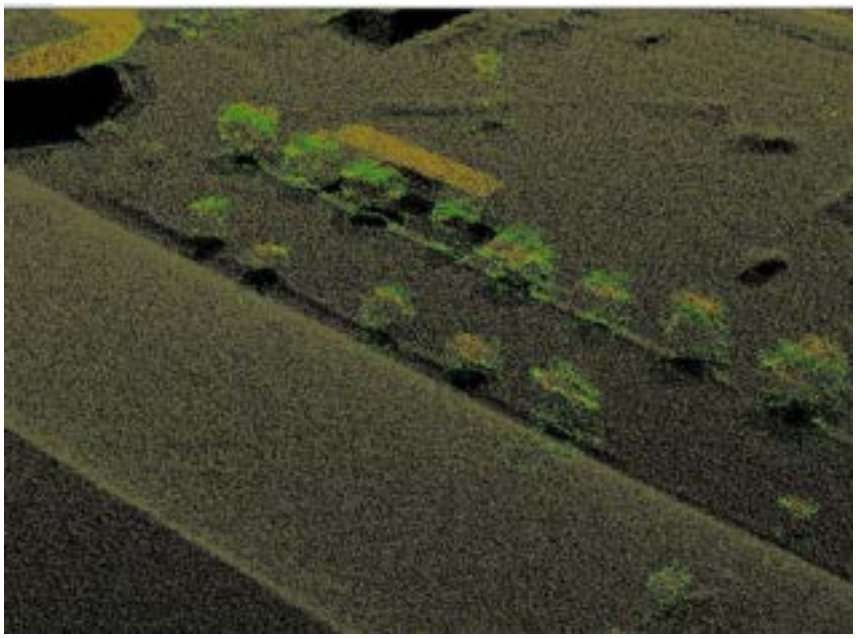


Ilustración 61. Resultado de quinta clasificación en categoría media vegetación.

Fuente. Elaboración propia.

Finalmente, según las ilustraciones anteriormente, se concluye que solo la clasificación de la ilustración 59 proporcionó mejor los resultados de clasificación por el método de aprendizaje profundo Point Net.

Alta vegetación

En las siguientes ilustraciones se presentan los resultados de las cinco iteraciones realizadas con el enfoque de aprendizaje profundo de clasificación, aplicado a las zonas caracterizadas por pendientes pronunciadas y vegetación abundante.

A continuación, se muestra la ilustración 61 en donde se analiza que la clasificación en esta iteración para la clase de vegetación alta en la zona arbustiva categorizó la información en un 90 % mientras que el 10 % restante de puntos LiDAR fue categorizado en la capa de "edificación" así mismo se observa que alcanza a clasificar información de árboles que colindan la zona de estudio.

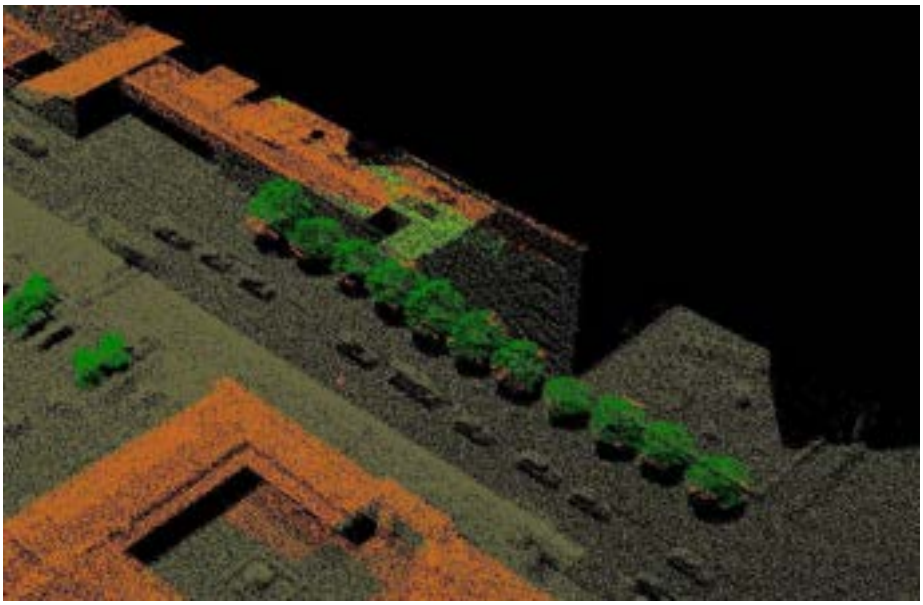


Ilustración 62. Resultado de primera clasificación en categoría alta vegetación.

Fuente. Elaboración propia.

En la ilustración 62, se observa que el resultado obtenido en la segunda iteración categorizó gran parte de la información de vegetación en la categoría "alta vegetación". Sin embargo, cierta información de vegetación arbustiva fue categorizada como "no clasificada" en color, cian. Este error de clasificación se debe a que el algoritmo no entiende correctamente la información debido a la baja densidad de puntos de la zona.

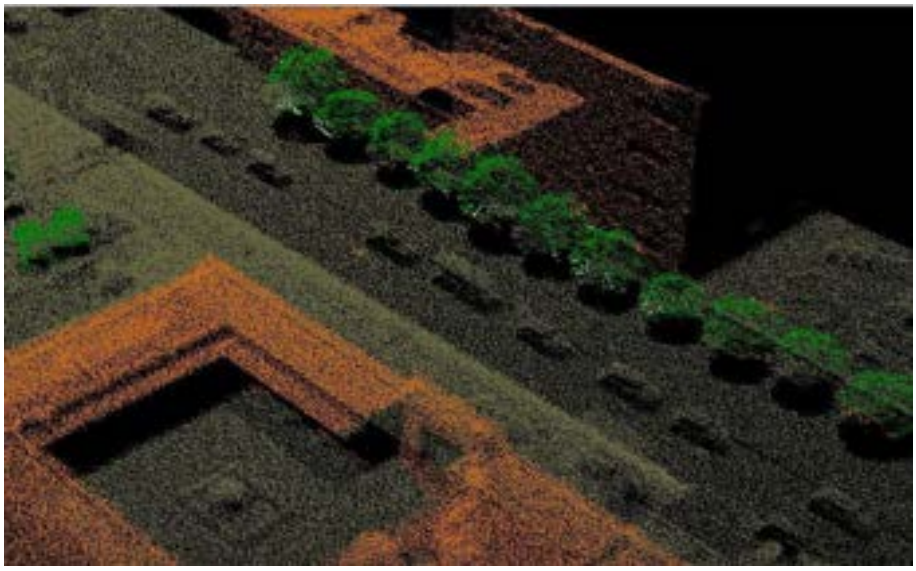


Ilustración 63. Resultado de segunda clasificación en categoría alta vegetación.

Fuente. Elaboración propia.

En la ilustración 63, se analiza una mala clasificación debido a que gran parte de la información que debería estar clasificada en la categoría de “alta vegetación” fue clasificada en la clase de “edificación” mientras que la información clasificada de “vegetación alta” es de color verde y solo categorizó los esquinas de los árboles y bordes de las edificaciones.

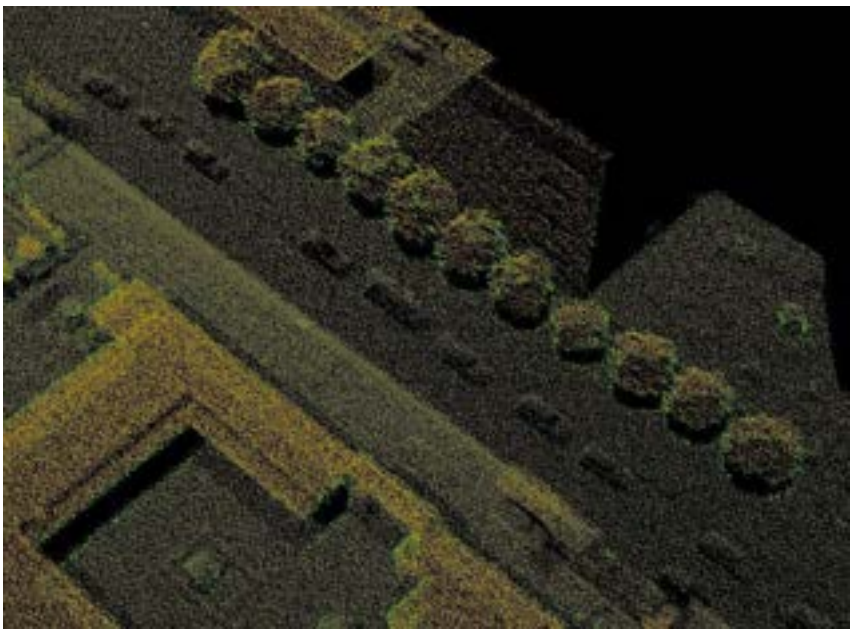


Ilustración 64. Resultado de tercera clasificación en categoría alta vegetación.

Fuente. Elaboración propia.

En la ilustración 64 se evidencia una clasificación de la categoría de “alta vegetación” en color verde oscuro, la información de árboles existentes en la zona de estudio de una manera completa, cabe resaltar que en la infraestructura cercana fue clasificada en la parte superior en la capa de “vegetación media” de color verde claro.

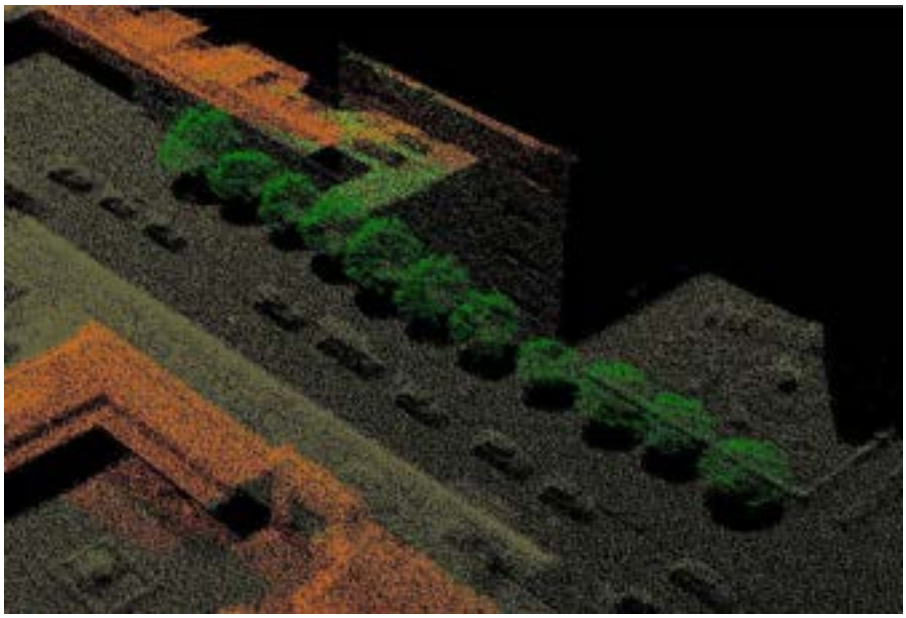


Ilustración 65. Resultado de cuarta clasificación en categoría alta vegetación.

Fuente. Elaboración propia.

En la ilustración 65 se muestra que la clasificación de la “vegetación alta” categorizó la parte central del árbol mientras que la nube restante de información fue categorizada en la capa de edificación, esto se debe a las modificaciones de los parámetros para la última clasificación lo cual impidió una correcta clasificación de la clase de estudio que corresponde a vegetación.

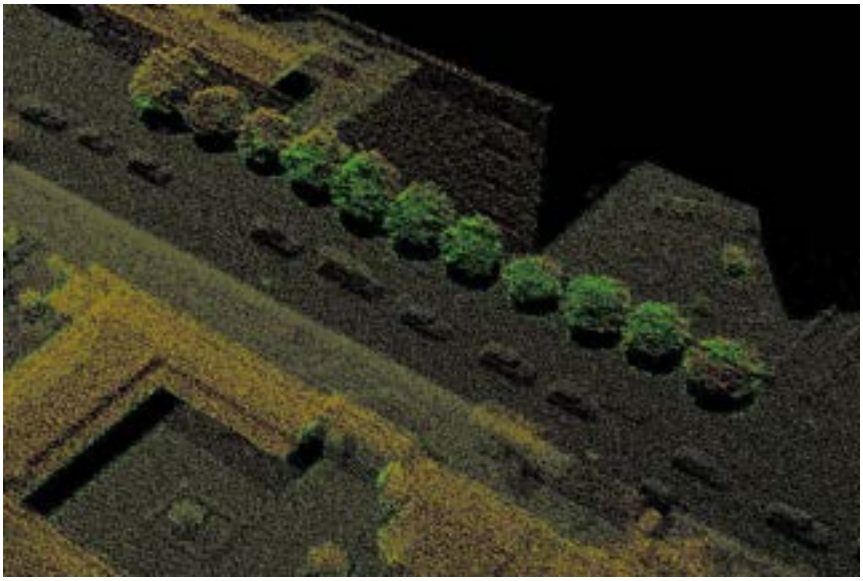


Ilustración 66. Resultado de quinta clasificación en categoría alta vegetación.

Fuente. Elaboración propia.

8.3. Resultados estadísticos

Con el fin de analizar la precisión de clasificación de la nube de puntos en cada iteración, se realizó una comparación de los resultados obtenidos en la zona de estudio según las categorías de clasificación de vegetación (alta, media y baja). En la tabla 6 se presenta la densidad de puntos obtenida en cada procedimiento.

Porcentaje de clasificación en la categoría vegetación						
	Algoritmo PointNet			**Regla heurística**		
	Baja	**Media**	**Alta**	**Baja**	**Media**	**Alta**
Iteración 1	538.443	52.791	4.765.178	675.022	95.506	1.229.863
Iteración 2	515.261	52.791	130.892	1.638.395	181.0	12.293
Iteración 3	1.768.557	182.0	11.754	764.429	103.201	3.832
Iteración 4	564.574	255.711	12.293	538.443	76.896	150.267
Iteración 5	518.462	12.257	10.754	209.555	255.711	95.270

Tabla 8. Densidad de punto en cada módulo de clasificación.

Fuente. Elaboración propia.

Al analizar la tabla anterior, se llevó a cabo una ecuación de distribución de categorías que permitió determinar los porcentajes de dominancia y precisión de la información para cada clase del área de estudio. Esto facilitó la comparación de los resultados obtenidos mediante los diferentes métodos aplicados.

$$\%\ de\ clasificacion = \frac{\rho\ de\ puntos\ de\ categoria\ clasificada}{\rho\ total\ de\ puntos} * 100$$

Ecuación 10. Distribución de categorías

A continuación, se presenta la tabla 7, que muestra los porcentajes de clasificación en la categoría de vegetación para cada una de las clases definidas en los métodos de clasificación aplicados,

Porcentaje de clasificación en la categoría vegetación						
	Algoritmo PointNet			**Regla heurística**		
	Baja	**Media**	**Alta**	**Baja**	**Media**	**Alta**
Iteración 1	3 %	0.29 %	0.75 %	5.75 %	0.81 %	10.48 %
Iteración 2	2.87 %	0.29 %	0.73 %	12.65 %	0 %	0.09 %
Iteración 3	10.05 %	0 %	0.07 %	5.97 %	0.81 %	0.03 %
Iteración 4	3.15 %	1.42 %	0.09 %	3 %	0.43 %	0.84 %
Iteración 5	2.89 %	0.07 %	0.06 %	1.17 %	1.42 %	0.53 %

Tabla 9. Porcentajes de clasificación en la nube de puntos.

Fuente. Elaboración propia.

Al analizar la información de la tabla 6, el dato con menor densidad de puntos clasificados corresponde a la iteración 5 en el método de clasificación de algoritmo PointNet mientras que en el segundo método de regla heurística la iteración 3 resalta por su baja densidad de datos. En la tabla 8 se observa la clasificación de los datos con mayor y menor densidad de puntos aplicado en la nube de puntos según cada clase de vegetación.

Clasificación con mayor y menor densidad de puntos LiDAR						
	Algoritmo PointNet					
	Baja vegetación		**Media vegetación**		**Alta vegetación**	
	Iteración	% clasificado	Iteración	% clasificado	Iteración	% clasificado
Mayor densidad de puntos	Iteración 3	10.05 %	Iteración 4	1.42 %	Iteración 1	0.75%
Menor densidad de puntos	Iteración 5	2.89%	Iteración 5	0 %	Iteración 3	0%
	Regla heurística					
	Baja vegetación		**Media vegetación**		**Alta vegetación**	
	Iteración	% clasificado	Iteración	% clasificado	Iteración	% clasificado
Mayor densidad de puntos	Iteración 3	12.65%	Iteración 4	1.42%	Iteración 1	10.48 %

Menor densidad de puntos	Iteración 5	3 %	Iteración 5	0 %	Iteración 3	0.03%

Tabla 10. Clasificación de nube de puntos según densidad.

Fuente. Elaboración propia.

En el método 1, las iteraciones que lograron el mayor porcentaje de densidad de puntos clasificados correspondieron a las iteraciones 5 y 4, específicamente en las clases de vegetación baja y media. Por otro lado, en el método 2, la iteración con la mayor densidad de puntos fue la iteración 2. No obstante, al realizar la comparación de los resultados, el método 2 demostró una mayor eficacia al lograr una mejor clasificación de la nube de puntos en todas las categorías analizadas.

Adicionalmente con el objetivo de evaluar la precisión en la clasificación de la nube de puntos a nivel general en cada uno de los métodos implementados en el caso de estudio, se llevó a cabo un análisis estadístico de la categoría de vegetación utilizando el software R. Este software fue elegido por su capacidad para integrar herramientas nativas y paquetes adicionales que facilitan la obtención de cálculos estadísticos aplicados a la nube de puntos.

En primer lugar, se desarrolló un código en R para analizar que categoría de vegetación presenta la mayor densidad de puntos, utilizando como referencia el método basado en el algoritmo PointNet. Los resultados obtenidos se presentan en la Tabla 9, donde se detalla la información relativa al número de puntos, altura media, altura mínima y altura máxima

Categoría	**Número de puntos**	**Altura media**	**Altura mínima**	**Altura máxima**
Alta	276991	2590.985	2584.697	2597.879
Media	117839	2587.702	2585.074	2590.675
Baja	2504256	2587.709	2500.258	2612.068

Tabla 11. Análisis estadístico de clasificación.

Fuente. Elaboración propia.

En la ilustración 66 se evidencia el diagrama de barras obtenido del análisis de la tabla anterior.

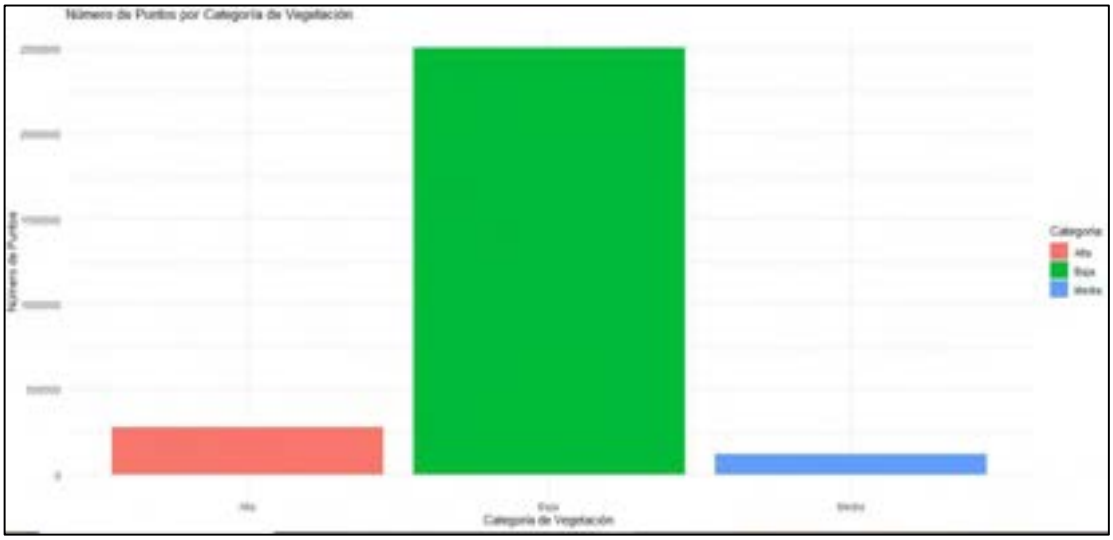


Ilustración 67. Diagrama estadístico de categorías de clasificación.

Fuente. Elaboración propia.

Así mismo del análisis realizado con el algoritmo PointNet se implementó el mismo procedimiento en el segundo método de regla heurística, tal como se evidentica en la tabla 10. con el propósito de comparar los resultados obtenidos en la clasificación de vegetación, este enfoque fue fundamental para identificar patrones específicos en la nube de puntos, destacando las diferencias en la densidad y distribución de puntos de la categoría de vegetación.

Categoría	Número de puntos	Altura media	Altura mínima	Altura máxima
Alta	115227	2589.562	2584.643	2610.041
Media	557800	2587.183	2584.770	2600.618
Baja	4051830	2586.288	2584.298	2610.335

Tabla 12. Análisis estadístico de clasificación.

Fuente. Elaboración propia.

En la Tabla 11 se presenta una comparación entre los métodos de clasificación, destacando que el método basado en el algoritmo PointNet identifica con mayor precisión la información correspondiente a la clase de vegetación, al detectar una mayor cantidad de puntos LIDAR.

Tabla comparativa de clasificación			
Algoritmo PointNet		Regla heurística	
Categoría	Densidad de puntos	Categoría	Densidad de puntos
Alta	2276991	Alta	115227
Media	117839	Media	557800
Baja	2504256	Baja	4051830

Tabla 13. Comparación de métodos de clasificación.

Fuente. Elaboración propia.

En la ilustración 63 se evidencia el diagrama de barras obtenido de la tabla 7 Análisis estadístico de clasificación.

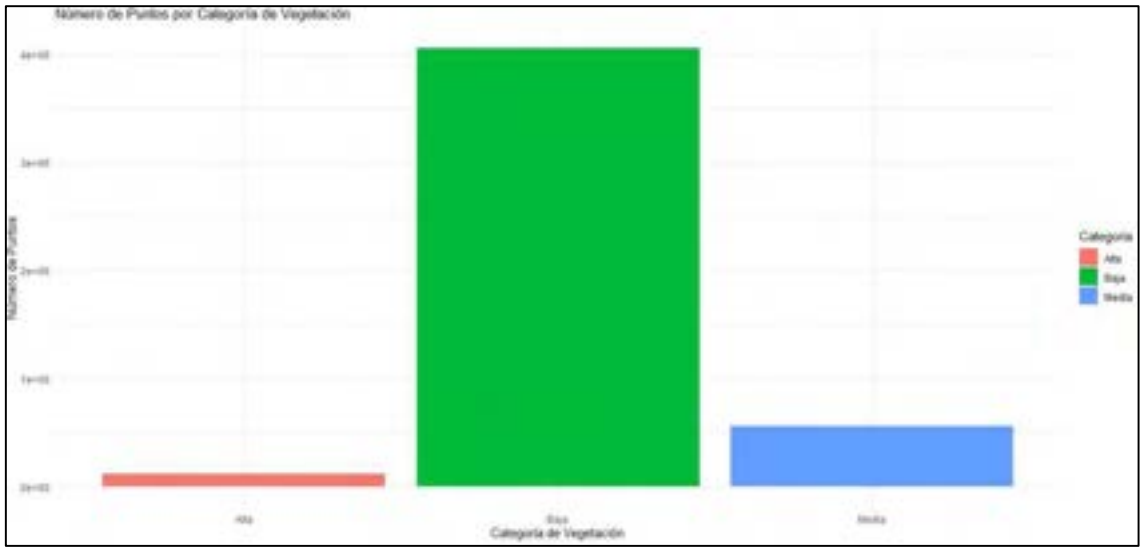


Ilustración 68. Diagrama estadístico de categorías de clasificación.

Fuente. Elaboración propia.

En las ilustraciones 62 y 63 se evidencia que los resultados obtenidos permiten una adecuada comparación en términos de la mayor densidad de puntos. Esto se significa una mejor distribución y clasificación de los datos dentro de la categoría de vegetación y sus respectivas subclases, lograda mediante el uso del algoritmo de clasificación PointNet.

9. Conclusiones

- El uso de tecnologías de detección remota y algoritmos de aprendizaje profundo permitió una clasificación precisa de las diferentes clases de vegetación en la zona de estudio. Este enfoque optimizó la identificación de áreas con baja y alta densidad vegetativa, lo que contribuyó a una comprensión más detallada y precisa de la cobertura vegetal del terreno, evidenciando la efectividad de estas herramientas en el análisis ambiental.

- El ajuste de los parámetros de clasificación en los distintos métodos implementados para la categoría de vegetación (baja, media y alta densidad vegetativa) produjo cambios significativos en los resultados de categorización de la información Lidar. Tras analizar cada método, se concluye que el método correspondiente a la iteración 1 (ver tabla 7) ofreció la mejor segmentación de datos. Esto se evidencia en su mayor índice de porcentajes de clasificación en cada una de las subclases, superando los resultados obtenidos con otros métodos y demostrando ser el más eficaz en este caso de estudio.

- Con base en las pruebas realizadas en los procesos iterativos y comparativos, se concluye que es fundamental implementar las ecuaciones que calculan la diferencia entre el modelo digital de elevación (MDE) y el modelo digital de superficie (MDS) exclusivamente en las categorías de suelo y vegetación. Esto es esencial para estimar de manera precisa las alturas mínima y máxima de la vegetación. La omisión de este procedimiento impide determinar un rango adecuado, lo que puede llevar a la asignación errónea de valores de vegetación en capas como construcción o suelo, afectando la precisión de la clasificación

- El análisis comparativo de los métodos de clasificación de la nube de puntos revela que el método basado en el algoritmo PointNet presenta una mayor eficacia en la clasificación de las categorías de vegetación, destacándose por su capacidad para lograr una mejor distribución y densidad de puntos en comparación con el método de regla heurística. Estos hallazgos subrayan la importancia de seleccionar el método adecuado para optimizar la precisión en la clasificación de datos Lidar.

- El proceso de clasificación de vegetación, complementado con la generación de una ortofoto, permitió una validación visual precisa de los resultados obtenidos, facilitando la identificación de patrones espaciales de baja y alta densidad vegetativa en la zona de estudio. La integración de la ortofoto con los modelos digitales de elevación y superficie demostró ser una herramienta eficaz para mejorar la interpretación de los datos Lidar, optimizando tanto la segmentación como la comprensión de la cobertura vegetal

10. Bibliografía

Alejandro Espacio, S. S. (2021). *Analisis comparativo de segmentacion semantica de nubes de puntos con redes neuronales.* Universidad de Extremadura .

ambiente, M. d. (26 de Julio de 2022). Obtenido de Colombia declara como área protegida el 34 % de su territorio: https://www.minambiente.gov.co/historico-colombia-declara-como-area-protegida-el-34-de-su-territorio/#:~:text=Con%20este%20avance%2C%20el%20pa%C3%ADs,el%20Convenio%20sobre%20Diversidad%20Biol%C3%B3gica.

Cano, M. (2024). *Segmentación de la invasión por vegetación a líneas de transmisión eléctrica usando aprendizaje profundo en imagenes de drone* . Medellin: Universidad Nacional de Colombia.

Charles R, H. S. (10 de Abril de 2017). *Deep Learning on Point Sets for 3D Classification and Segmentation.* Universidad Stanford.

Chris Zhang, W. L. (s.f.). *Efficient Convolutions for Real-Time Semantic Segmentation of 3D Point Clouds.* Toronto: Uber Advanced Tecnologies Group.

Colombia, I. H. (s.f.). Obtenido de Biodiversidad Colombiana: numeros para tener en cuenta: https://www.humboldt.org.co/noticias/biodiversidad-colombiana-numeros-para-tener-en-cuenta

Danysoft. (18 de Noviembre de 2020). *Algortimo de clasificacion de puntos*. Obtenido de https://www.danysoft.com/global-mapper/

Florez, T. G. (2008). *Las Tecnologías de la Información y la Comunicación en la Universidad Autonoma de Queretaro.* Tarragona.

Foody, G. M. (2001). *Estado de evaluacion de la precision de la clasificacion de la cobertura terrestre.* Reino Unido: EL SERVIER .

Henandez, M. (27 de Diciembre de 2017). *¿Cuáles son las especies que componen la flora silvestre urbana de Bogotá?* Obtenido de https://inaturalist.org/posts/13375-cuales-son-las-especies-que-componen-la-flora-silvestre-urbana-de-bogota

Icardo Urvina, E. A. (2023). Localización simultánea y mapeo para control de un robot móvil autónomo usando escaneo de nube de puntos LiDAR y métodos de aprendizaje de máquina. *SCIELO*.

Jardin Botanico de Bogota, U. d. (2020). *Manual de vegetaciòn de Bogota D.C.* Bogota.

Larraga hugo, L. D. (2022). *Segmentacion semantica de cultivos de caña de azucar con imagenes de vehiculos aereos no tripulados* . Mexico: Journal of computational systems and ICTS.

Mapper, G. (2017). *Guia de Iniciacion Rapida.* Blue Marble Geographics.

Maria Alvarez, J. M. (s.f.). *Clasificación Automática de Cubiertas Terrestres en Imagenes Satelitales.* Argentina.

Medina, M. (2019). *Segmentacion inteligente de objetos en nubes de puntos.* Escuela Politecnica superior de Jaen.

Meza, P. A. (2020). *Vegetaciòn urbana como estrategia para reducir la contaminaicon del aire en areas urbanas.* Bogota, Colombia: Universidad del Tolima.

Norte, U. d. (07 de Mayo de 2015). Obtenido de La biodiversidad de Colombia está en riesgo: https://www.uninorte.edu.co/web/grupo-prensa/w/la-biodiversidad-de-colombia-esta-en-riesgo

Oscar Soto, A. C. (2019). *Analisis del desempeño de redes neuronales profundas para segmentacion semantica en hardware limitado.* Mexico: Computacion e informatica.

Quintana, N. M. (2024). *Modelo de segmentacion semantica de imagenes satelitales basado en redes neuronales convolucionales para la clasificacion de cobertura de la tierra en paramos.* Bogota: Universidad Nacional de Colombia.

Rivera, E. C. (2022). *Tecnicas Deep Learning para procesado de nubes de puntos 3D.* Escuela Politecnica Superior.

Sociedad Sostenible. (s.f.). Obtenido de Importancia de la Biodiversidad en Colombia: https://sociedadsostenible.co/la-importancia-de-la-biodiversidad-en-colombia-un-tesoro-natural-por-proteger/#:~:text=La%20biodiversidad%20juega%20un%20papel,y%20medicina%2C%20entre%20otros%20aspectos.

Software, M. (31 de Marzo de 2023). Obtenido de Procesamiento y analisis de nube de puntos: https://www.macronline.cl/procesamiento-y-analisis-de-nubes-de-puntos-lidar/#:~:text=El%20procesamiento%20de%20una%20nube,individuales%20para%20facilitar%20su%20an%C3%A1lisis.

Sostenible, S. (s.f.). *La teledeteccion como herramienta para la conservacion de bosque*. Obtenido de https://sociedadsostenible.co/la-teledeteccion-como-herramienta-para-la-conservacion-de-bosque/#:~:text=La%20teledetecci%C3%B3n%20recopila%20informaci%C3%B3n%20de,relacionada%20con%20las%20diferentes%20cubiertas

Stuart Russell, P. N. (2008). *Inteligencia Artificial un enfoque moderno.* Madrid: Pearson Educacion SA.

William Zaque, L. E. (2017). *Obtención de parámetros óptimos en la clasificación de nube de puntos Lidar, a partir de sensores aerotransportados.* Bogota.

Wilver Salinas, C. P. (2013). *Evaluacion de la exactitud posicional vertical de una nube de puntos topograficos lidar usando topografia convecional como referencia.* Mexico: Investigaciones Geograficas.

Xiaoqing Ye, J. L. (s.f.). *3D Recurrente Neuronal with Context Fusion for Point Cloud Semantic Segmentation.* China: Escuela de ciencia y tecnologia.

Yuan, X. (2020). *Una revision de los metodos de aprendizaje profundo para la segmentacion semantica de imagenes de teledeteccion.* China: EL SEVIER.

Zewen Li, W. Y. (s.f.). *A survey of convolutional Neuronal Networks Analysis Aplications and prospects.* China: Fundacion Natural de ciencia de Jiangsu.