

**DEPARTAMENTO DE POSGRADOS**

**MAESTRÍA EN GEOMÁTICA**

**Título**

DETECCIÓN AUTOMÁTICA DE POSTES DE ALUMBRADO PÚBLICO Y LÍNEAS  
ELÉCTRICAS DE MEDIA Y BAJA TENSION A TRAVÉS DE DATOS LiDAR

**Título a obtener:**

Magister en Geomática

**Estudiante:**

Karla Valeria Durán Mejía

**Director:**

Diego Pacheco Prado

Cuenca, Ecuador

2025

## **DEDICATORIA**

A mi esposo por acompañarme en este camino, su apoyo incondicional y por estar siempre a mi lado.

A mi familia, por ser el pilar sobre el que he construido cada uno de mis sueños. Su apoyo, valores y enseñanzas han sido la base de este logro.

A ustedes dedico cada página de este trabajo con amor y gratitud.

## **AGRADECIMIENTO**

A Dios, fuente infinita de sabiduría, fortaleza y amor, gracias por haber guiado cada paso de este proceso. En los momentos de cansancio, incertidumbre o temor, fuiste mi refugio y mi luz.

Gracias por abrir caminos donde no los veía, por sostenerme en los días difíciles y por bendecirme con las oportunidades, las personas y la capacidad de culminar esta etapa.

Este logro es también tu obra en mí, y a Ti elevo mi gratitud más sincera.

## **DETECCIÓN AUTOMÁTICA DE POSTES DE ALUMBRADO PÚBLICO Y LÍNEAS ELÉCTRICAS DE MEDIA Y BAJA TENSIÓN A TRAVÉS DE DATOS LiDAR**

### **RESUMEN**

El presente estudio desarrolla una metodología semiautomática para la detección de postes de alumbrado público con una precisión del 94,3 %, y la clasificación de líneas eléctricas de baja y media tensión con un 91,2 % y 88,7 % de acierto respectivamente, mediante el uso de datos *LiDAR* obtenidos por escáner láser móvil terrestre (MLS). La zona de estudio corresponde al sector Miraflores, en la ciudad de Quito, donde se procesó una nube de puntos con una densidad promedio de 28,10 pts/m<sup>2</sup>. La metodología incluyó segmentación manual asistida con el algoritmo *Cloth Simulation Filtering* (CSF), detección automática de postes mediante el plugin *RANSAC* en *CloudCompare*, y clasificación altitudinal de líneas eléctricas con scripts en *Python*. Estos resultados evidencian la efectividad del enfoque propuesto, aunque también revelan la necesidad de intervención manual en etapas clave del proceso. Se concluye que la integración de herramientas de software libre con algoritmos geométricos y análisis altitudinal constituye una alternativa viable y de bajo costo para el levantamiento y gestión de infraestructura eléctrica urbana. El estudio plantea también la posibilidad de escalar esta metodología mediante el uso de inteligencia artificial en futuros trabajos.

**Palabras clave:** LiDAR, alumbrado público, líneas eléctricas, clasificación automática, CloudCompare, RANSAC, altura relativa.

**Karla Valeria Durán Mejía**  
Autor

**Diego Francisco Pacheco Prado**  
Director de Tesis

## **AUTOMATIC DETECTION OF PUBLIC LIGHTING POLES AND MEDIUM AND LOW VOLTAGE POWER LINES USING LiDAR DATA**

### **ABSTRACT**

This study develops a semi-automatic methodology for detecting public lighting poles with a precision of 94.3%, and classifying low and medium voltage power lines with accuracies of 91.2% and 88.7%, respectively, using *LiDAR* data acquired through mobile laser scanning (MLS). The study area is located in the Miraflores sector of Quito, Ecuador, where a point cloud with an average density of 28.10 pts/m<sup>2</sup> was processed. The methodology included manual segmentation supported by the *Cloth Simulation Filtering* (CSF) algorithm, automatic pole detection using the *RANSAC* plugin in *CloudCompare*, and height-based classification of power lines using *Python* scripts. These results demonstrate the effectiveness of the proposed approach while also highlighting the need for manual intervention in key processing stages. It is concluded that the integration of open-source tools with geometric and altitude-based analysis represents a cost-effective alternative for surveying and managing urban electrical infrastructure. The study also opens the door to scaling this methodology through the use of artificial intelligence in future work.

**Keywords:** LiDAR, public lighting, power lines, automatic classification, CloudCompare, RANSAC, relative height.

**Karla Valeria Durán Mejía**  
Author

**Diego Francisco Pacheco Prado**  
Thesis Director

## ÍNDICE DE CONTENIDO

DEDICATORIA .....	ii
AGRADECIMIENTO .....	iii
RESUMEN .....	iv
ABSTRACT .....	v
ÍNDICE DE CONTENIDO .....	vi
ÍNDICE DE FIGURAS .....	vii
ÍNDICE DE TABLAS .....	vii
1. INTRODUCCIÓN.....	7
1.1 Objetivo General.....	7
1.2 Objetivos Específicos .....	7
1.3 Estructura de la Tesis .....	8
2. ESTADO DEL ARTE .....	8
3. MATERIALES Y MÉTODOS .....	10
3.1 Área de estudio .....	10
3.2 Metodología.....	10
3.2.1 Características de las nubes de puntos.....	11
3.2.2 Segmentación Manual de nube de puntos .....	13
3.2.3 Clasificación de alumbrado público .....	13
3.2.4 Clasificación de líneas de media y baja tensión .....	14
4. RESULTADOS.....	15
4.1 Detección de postes de alumbrado público con RANSAC .....	15
4.2 3.Clasificación de líneas eléctricas por análisis altitudinal .....	16
5. DISCUSIÓN Y CONCLUSIONES .....	17
5.1 Discusión .....	17
5.2 Conclusiones.....	18

## ÍNDICE DE FIGURAS

<b>Figura 1</b> Zona de estudio .....	10
<b>Figura 2</b> Diagrama de Flujo del Proceso de Clasificación de Infraestructura Eléctrica con LiDAR .....	11
<b>Figura 3</b> Nube de puntos del alimentador 09B .....	12
<b>Figura 4</b> Segmentación preliminar de una sección del alimentador 09B .....	13
<b>Figura 5</b> Clasificación con RANSAC para alumbrado público. ....	16
<b>Figura 6</b> <i>Clasificación de líneas de media y baja tensión, según la altura relativa. ....</i>	17

## ÍNDICE DE TABLAS

<b>Tabla 1</b> Parámetros de evaluación de la aplicación de RANSAC .....	14
<b>Tabla 2</b> Resultados de fiabilidad en la detección de postes (RANSAC) .....	15
<b>Tabla 3</b> Resultados de clasificación de líneas eléctricas por altura relativa .....	16

## 1. INTRODUCCIÓN

La red eléctrica urbana es esencial para la sostenibilidad social, económica y ambiental, al garantizar el acceso confiable a la energía y sostener servicios públicos y privados (Calle, 2024; Ortega et al., 2018). Dentro de esta red, destacan las líneas de media y baja tensión: las primeras distribuyen energía desde subestaciones hasta grandes consumidores como industrias y hospitales, ubicándose entre 8 y 11 metros de altura; las segundas, destinadas al consumo residencial, se disponen entre 6 y 7.5 metros, con una separación de postes de hasta 50 metros. El alumbrado público, conectado a la red de baja tensión, se sitúa entre 4 y 6 metros en vías urbanas (Comisión de Homologación de las Unidades de Propiedad, 2013).

Los métodos tradicionales para la inspección y gestión de la infraestructura eléctrica urbana, basados principalmente en inspecciones visuales manuales y levantamientos topográficos convencionales, presentan múltiples limitaciones. Estas incluyen altos costos operativos, riesgos asociados a trabajos en altura y zonas de tráfico, baja frecuencia de inspección debido al tiempo requerido, y la posibilidad de omisión o error humano en la identificación y registro de elementos (Chasco, 2018). Estas restricciones impactan negativamente en la eficiencia del mantenimiento y en la planificación de mejoras de la red eléctrica.

En respuesta a estas limitaciones, la tecnología *LiDAR* (*Light Detection and Ranging*) se ha consolidado como una herramienta innovadora para la gestión automatizada de infraestructuras eléctricas (Sánchez & Salcines, 2015). Esta técnica de teledetección activa permite generar nubes de puntos 3D con alta precisión, facilitando el análisis geométrico y la clasificación de elementos en distintos contextos mediante escaneos desde plataformas satelitales, aéreas, móviles o terrestres (Cheng et al., 2018; Clode & Rottensteiner, 2005a).

Este trabajo propone una metodología basada en datos *LiDAR* para mejorar la detección y clasificación de infraestructura eléctrica urbana, contribuyendo a la modernización y optimización del sector energético.

### 1.1 Objetivo General

Detectar los postes y líneas eléctricas de media y baja tensión a partir de datos *LIDAR* MLS.

### 1.2 Objetivos Específicos

- Desarrollar una metodología semiautomática que pueda ser extrapolable a otras áreas de estudio.
- Evaluar la detección de líneas eléctrica y postes de alumbrado público en función de las áreas de entrenamiento.
- Caracterizar la topología espacial de las líneas eléctricas para su clasificación.

### 1.3 Estructura de la Tesis

La tesis se divide en cuatro capítulos. El primero presenta el estado del arte; el segundo, los materiales y métodos utilizados; el tercero, los resultados obtenidos y el cuarto, la discusión y conclusiones.

## 2. ESTADO DEL ARTE

*LiDAR* es una tecnología que se presenta como una alternativa avanzada a las técnicas topográficas y fotogramétricas para la generación de modelos digitales del terreno (MDT) de alta precisión y densidad. Un sistema *LiDAR* calcula la distancia entre el emisor de la radiación y el objeto objetivo, basándose en el tiempo que tarda el haz láser pulsado en regresar al emisor (Calle, 2024). En este sentido, la tecnología *LiDAR* se clasifica en función de la plataforma desde la cual se opera el sensor.

Un escáner láser basado en la plataforma de un avión se denomina ALS y se ha utilizado para topografía desde 1994. Hasta ahora, el ALS ha sido un método particularmente importante para el mapeo rápido y de alta precisión de áreas grandes, especialmente para productos DEM. Sin embargo, el ALS ofrece datos de la vista superior, que no es adecuada para el modelado de objetos terrestres y de alta resolución (Laiño, 2022).

El escaneo láser móvil terrestre (MLS) podría proporcionar mediciones complementarias para el ALS. El MLS está integrado con GNSS y unidad de medición inercial (IMU) y contiene uno o varios escáneres láser montados en una plataforma en un automóvil, camioneta o tren. El MLS puede aplicar diferentes densidades de puntos, ángulos de escaneo y rangos a los objetos, con un campo de visión de 360° sin espacios vacíos en comparación con el ALS (Zhu & Hyyppa, 2014).

Numerosos estudios han demostrado el potencial del *LiDAR* para tareas de clasificación automatizada mediante algoritmos como *RANSAC* (*Random Sample Consensus*), *Support Vector Machine* (SVM) y redes neuronales, aplicados tanto a entornos urbanos, forestales y de infraestructuras eléctricas (Laiño, 2022; Varela et al., 2021). En el ámbito eléctrico, se ha logrado detectar postes, líneas y torres con alta precisión, incluso en condiciones complejas, a través del análisis multiescala, voxelización y extracción de descriptores geométricos (Gaha et al., s. f.; Wang, Chen, Li, et al., 2017; Yermo et al., 2019). Por ejemplo, Wang et al. (2017) reportaron una precisión del 96,5% y una exhaustividad del 94,3% en la detección automática de postes eléctricos utilizando datos *LiDAR* urbanos. Asimismo, Yermo et al. (2019) lograron una precisión del 93,2% y una exhaustividad del 91,7% en la identificación de torres de transmisión en entornos rurales mediante análisis multiescala. Por su parte, Gaha et al. (2021) alcanzaron una precisión del 95,0% y una exhaustividad del 92,5% en la detección de líneas eléctricas utilizando técnicas de voxelización y descriptores geométricos en áreas urbanas densas.

Herramientas de software libre como *CloudCompare* han sido empleadas exitosamente en el preprocesamiento, filtrado y segmentación de nubes de puntos, aunque presentan limitaciones en cuanto a automatización y escalabilidad. Pese a ello, permiten desarrollar metodologías viables para clasificar infraestructura eléctrica a bajo costo (Cervero, 2016; Salas, 2021).

Una de las ventajas destacables de los estudios analizados es la capacidad de detectar objetos, como árboles y líneas eléctricas, incluso en nubes de puntos con baja densidad de datos. Si bien la mayoría de los trabajos consultados se centran en el análisis de datos con alta densidad de puntos por metro cuadrado, también se han identificado investigaciones que logran resultados prometedores con densidades considerablemente menores. Por ejemplo, el estudio de (Clode & Rottensteiner, 2005b) demostró la posibilidad de detectar árboles y líneas eléctricas a partir de nubes de puntos con menos de un punto por metro cuadrado en la ciudad de Sídney. Este logro fue alcanzado utilizando únicamente las diferencias entre el primer y el último retorno del sensor. Este enfoque representa una solución eficiente y económica, ya que reduce la necesidad de recolectar grandes cantidades de datos, lo cual es especialmente útil en áreas extensas o en proyectos con recursos limitados.

Otra fortaleza identificada es que contar con un mayor número de áreas de aprendizaje, tanto para el entrenamiento del algoritmo como para su posterior fase de validación, contribuye significativamente a mejorar la precisión y calidad de los resultados de clasificación. Según (Lehtomäki et al., 2019), esta estrategia permite al algoritmo aprender de una variedad más amplia de patrones y contextos, lo que se traduce en una mayor capacidad de generalización y un mejor desempeño en escenarios diversos.

El método propuesto por (Ortega et al., 2018) y (Dihkan & Mustafa, 2021) permiten clasificaciones automáticas y segmentaciones precisas, reduciendo significativamente el tiempo necesario para el procesamiento de grandes volúmenes de datos. (Ortega et al., 2018) reportaron una precisión del 93,5% y una exhaustividad del 91,2% en la clasificación automática de elementos urbanos utilizando modelos de aprendizaje supervisado. Sin embargo, se enfrentan desafíos relacionados con la variabilidad de las condiciones de iluminación y la presencia de objetos parcialmente ocultos, lo que afectó la precisión en ciertas categorías. Por su parte, (Dihkan & Mustafa, 2021) lograron una precisión del 95,0% y una exhaustividad del 92,5% en la segmentación de infraestructuras eléctricas en entornos rurales, aunque señalaron dificultades en la diferenciación de estructuras similares debido a la resolución limitada de las imágenes satelitales utilizadas.

A partir de la revisión bibliográfica realizada, no se han identificado estudios que aborden la clasificación de las líneas de distribución basándose en la disposición específica de las mismas. Esta particularidad fue evidente en la nube de puntos correspondiente a nuestra zona de estudio, lo que la convierte en un aspecto relevante a considerar para futuros trabajos, especialmente al clasificar líneas de media y baja tensión. Además, este estudio contribuye al estado del arte de la aplicación de técnicas geométricas y de análisis altitudinal para la detección automática de postes y la clasificación de líneas de distribución eléctrica.

### 3. MATERIALES Y MÉTODOS

#### 3.1 Área de estudio

El estudio se desarrolló en la zona urbana de Quito, provincia de Pichincha, específicamente en la parroquia Belisario Quevedo, sector Miraflores (Figura 1). Esta área forma parte del alimentador 09B de la red de distribución eléctrica operada por la Empresa Eléctrica Quito, el cual tiene una longitud aproximada de dos kilómetros, cubriendo calles residenciales y vías de tráfico medio.



*Figura 1 Zona de estudio*

#### 3.2 Metodología

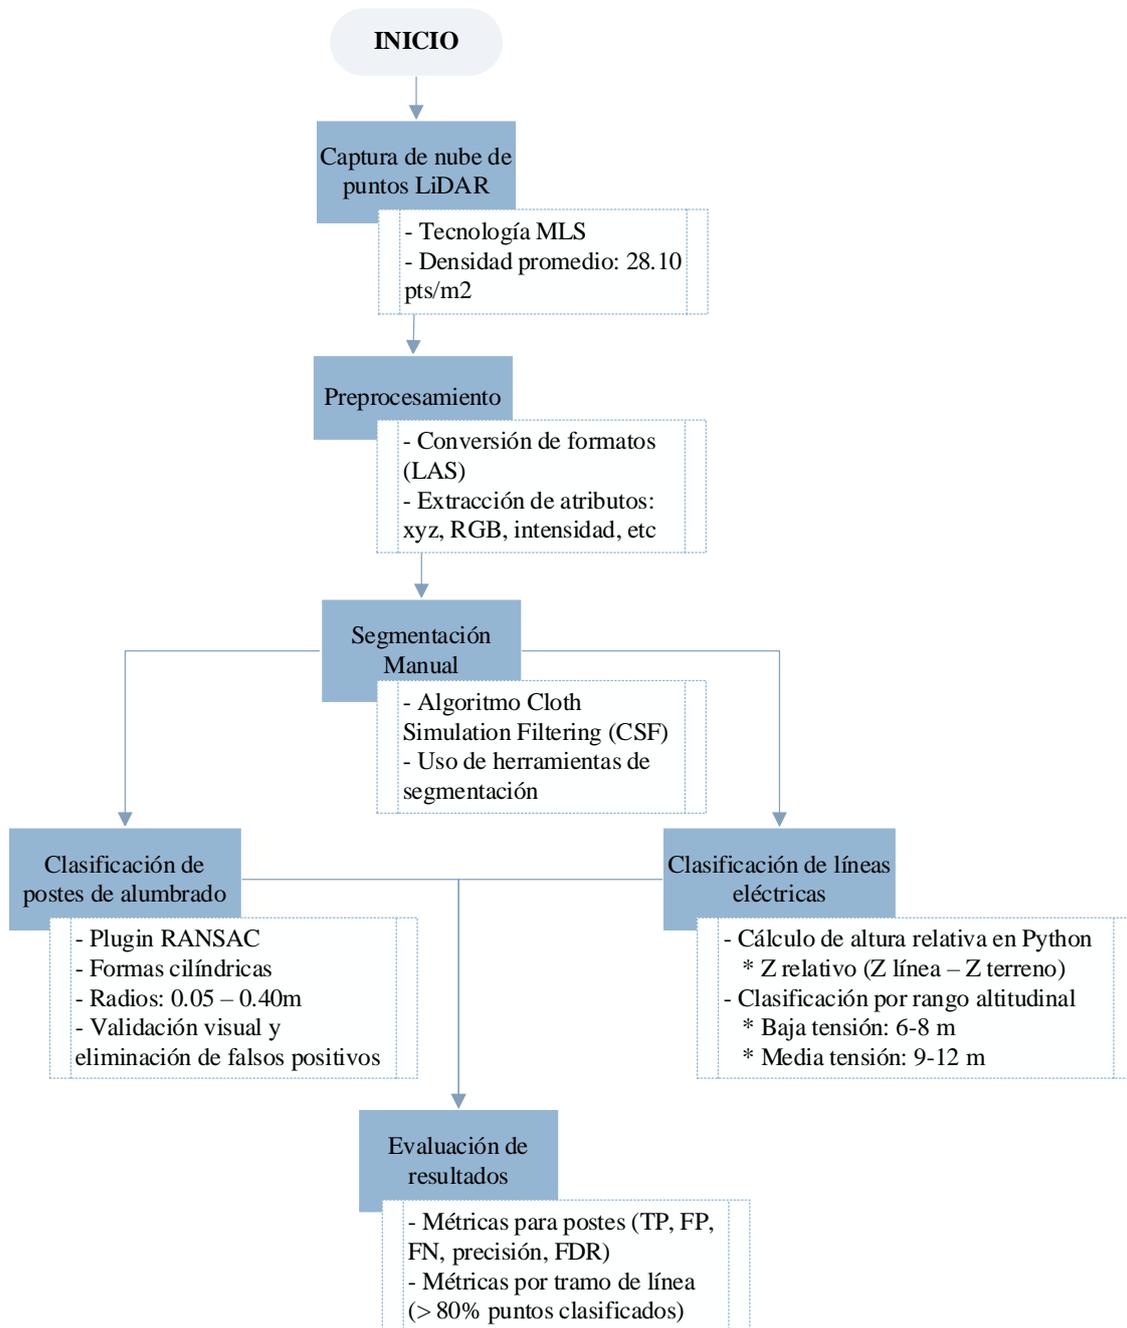
Para la zona de estudio se propone la metodología compuesta de seis etapas (Figura 2). El proceso inicia con la captura de la nube de puntos mediante tecnología *Mobile Laser Scanning* (MLS), alcanzando una densidad promedio de 28,10 puntos por metro cuadrado. A continuación, se realiza el preprocesamiento de los datos, que incluye la conversión al formato LAS y la extracción de atributos clave como coordenadas espaciales (X, Y, Z), color (RGB), e intensidad.

Posteriormente, se lleva a cabo una segmentación manual asistida por el algoritmo *Cloth Simulation Filtering* (CSF) y herramientas de segmentación, lo cual permite separar el terreno de los objetos elevados.

Luego, el flujo metodológico se bifurca en dos procesos de clasificación:

- Por un lado, la clasificación de postes de alumbrado, realizada mediante el plugin *RANSAC*, el cual detecta formas cilíndricas. Esta etapa se complementa con validación visual para eliminar falsos positivos.
- Por otro lado, la clasificación de líneas eléctricas se efectúa mediante el cálculo de altura relativa en *Python*, comparando la elevación de las líneas respecto al terreno. En función de la altura, se clasifican como líneas de baja tensión (6–7,5 m) o media tensión (8–11 m) (Comisión de Homologación de las Unidades de Propiedad, 2013).

Finalmente, se lleva a cabo una evaluación de resultados, en la que se aplican métricas de precisión, recuperación y tasa de falsos descubrimientos para postes; y métricas de clasificación por tramos para las líneas, considerando un umbral de éxito superior al 80% de puntos correctamente identificados por segmento.



**Figura 2** Diagrama de Flujo del Proceso de Clasificación de Infraestructura Eléctrica con LiDAR

### 3.2.1 Características de las nubes de puntos

La nube de puntos utilizada en este estudio fue generada mediante tecnología de escaneo láser móvil (*Mobile Laser Scanning*, MLS) utilizando el sistema *Maverick* fabricado por *Teledyne Optech*. Este equipo integra un sensor *LiDAR* multiuso de alta precisión,

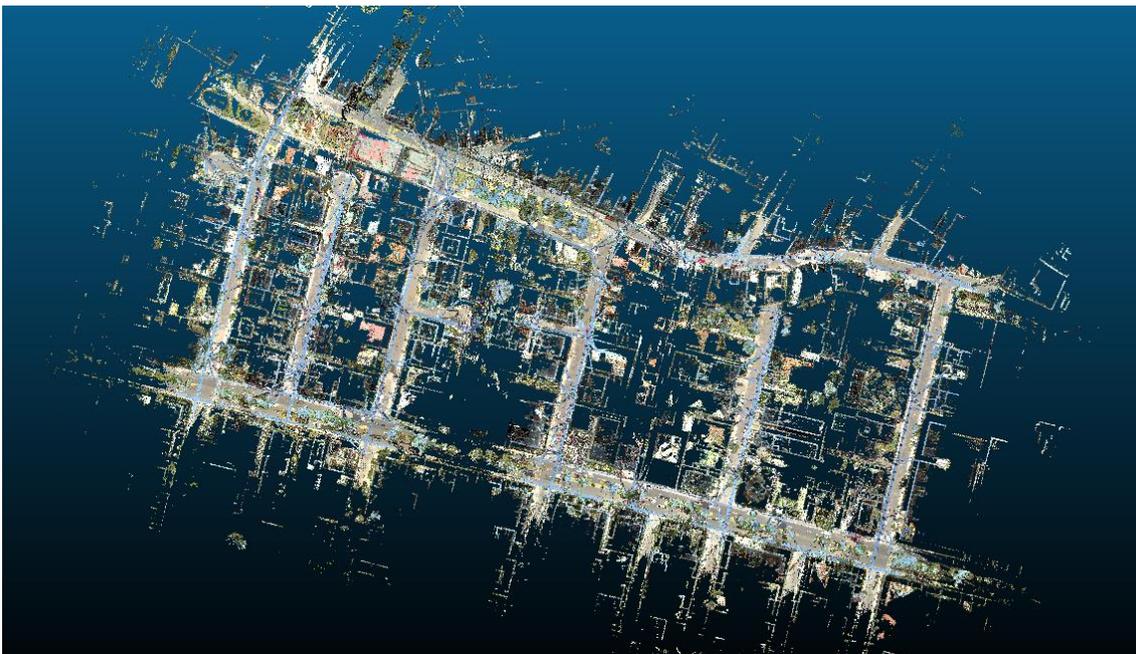
cámaras RGB sincronizadas y una unidad de medición inercial (IMU), permitiendo capturas detalladas desde una plataforma móvil terrestre.

El *Maverick* puede registrar hasta 700.000,00 puntos por segundo, con un rango operativo de hasta 100 metros y precisión centimétrica, incluso en entornos urbanos complejos. Su escáner ofrece un campo de visión de 360°, lo que facilita una cobertura continua del entorno mientras el vehículo se desplaza.

Para la planificación de rutas terrestres, se parte de la localización georreferenciada de los postes asociados a cada alimentador. Con base en esta información, se digitalizan las rutas considerando la orientación y el trazado de las redes eléctricas aéreas, tanto de media como de baja tensión. El levantamiento de datos *LiDAR* se realizó utilizando un vehículo tipo SUV (*Sport Utility Vehicle*) equipado con un sistema de escaneo láser móvil (*Mobile Laser Scanning, MLS*), específicamente el sistema *Maverick* de *Teledyne Optech*, el cual integra un sensor *LiDAR* multieco de alta precisión, cámaras RGB sincronizadas y una unidad de medición inercial (IMU). Esta configuración permitió capturar nubes de puntos detalladas a lo largo de las rutas planificadas.

Como insumos técnicos para el equipo de campo, se entregaron un mapa con las rutas previamente digitalizadas y un archivo *shapefile* (*shp*) con la ubicación precisa de los postes. Estas herramientas optimizan el trabajo en terreno y aseguran que el levantamiento de información se limite exclusivamente a las infraestructuras del alimentador correspondiente, evitando la mezcla de datos entre alimentadores o subestaciones aledañas.

La nube de puntos final del alimentador 09B tuvo una densidad promedio de 28,10 puntos/m<sup>2</sup> (Figura 3). Cada punto incluye atributos como coordenadas espaciales (X, Y, Z), intensidad de retorno, clasificación, ángulo de escaneo, tiempo GPS y, valores de color RGB. Estos atributos son fundamentales para la clasificación y segmentación de los elementos de la red.

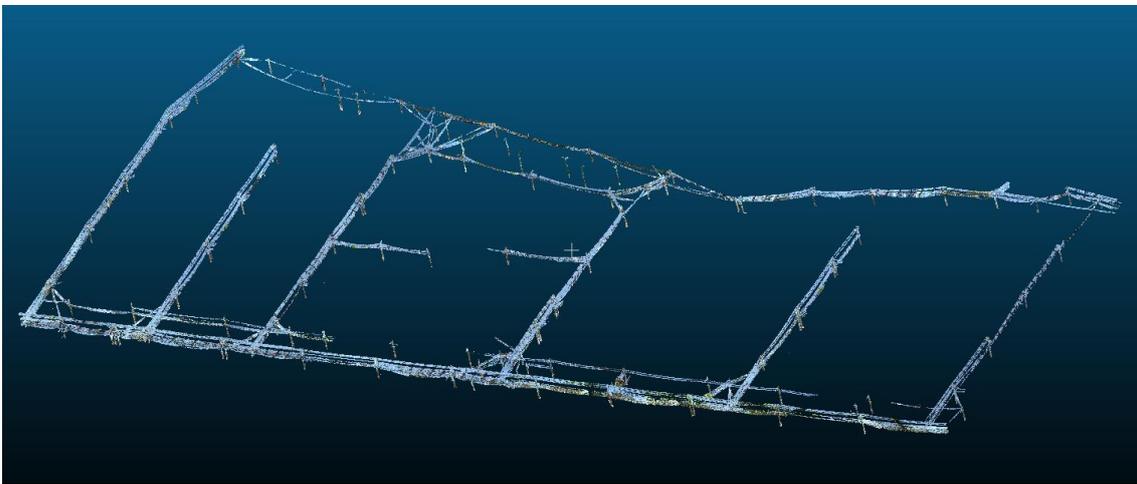


*Figura 3 Nube de puntos del alimentador 09B*

### 3.2.2 Segmentación Manual de nube de puntos

Para separar el terreno de los objetos elevados (vegetación, postes, construcciones), se empleó el algoritmo *Cloth Simulation Filtering* (CSF), que simula una tela cayendo sobre la nube de puntos invertida. Los parámetros de simulación fueron calibrados con un umbral de clasificación de 0,5 y una malla adaptativa. Este umbral corresponde al valor establecido por defecto en el software *CloudCompare* para la herramienta CFS (*Cloth Simulation Filter*), ya que, mediante pruebas realizadas por los desarrolladores del software, se ha determinado que se adapta de forma adecuada a una amplia variedad de escenas (*CloudCompare - Open Source project, s. f.*). Esta etapa permitió generar una superficie continua del terreno como base para el análisis altitudinal.

Posteriormente, se aplicó una clasificación manual complementaria, utilizando herramientas de segmentación en *CloudCompare*, para refinar el conjunto de puntos asociados exclusivamente a infraestructura eléctrica (Figura 4).



*Figura 4 Segmentación preliminar de una sección del alimentador 09B*

### 3.2.3 Clasificación de alumbrado público

Para la detección automática de postes de alumbrado se utilizó el plugin *RANSAC Shape Detection* de *CloudCompare*. Se seleccionó exclusivamente la detección de formas cilíndricas, configurando los siguientes parámetros: 1000 puntos de soporte, y min radius de 0,05m a max radius de 0,40m. Posterior a la ejecución del algoritmo, se llevó a cabo una validación visual para eliminar falsos positivos, como señales de tránsito u otras estructuras tubulares. Estos fueron eliminados manualmente mediante la herramienta *Edit > Segment*.

La fiabilidad del algoritmo fue evaluada mediante una comparación con una base de postes verificada manualmente, a través de las métricas:

**Tabla 1** Parámetros de evaluación de la aplicación de RANSAC

<b>Métrica</b>	<b>Fórmula</b>	<b>Interpretación</b>
Truly Classified (TP)	Postes detectados correctamente	Aciertos en detección
Falsely Classified (FP)	Objetos detectados que no son postes	Falsos positivos
Balanced Accuracy	$(TPR + TNR) / 2$	Precisión considerando clases balanceadas
False Discovery Rate	$FP / (TP + FP)$	Proporción de falsos sobre detectados

### 3.2.4 Clasificación de líneas de media y baja tensión

Para el análisis de las líneas de media y baja tensión, se utilizó la altura relativa como criterio principal. Para ello, se trabajó inicialmente con dos archivos en formato LAS, procesados con la ayuda del lenguaje de programación *Python*. Para el cálculo de la altura relativa se utilizó un script en el lenguaje de programa *Python* versión 3.10 basado en las librerías *numpy* y *scipy.spatial.KDTree*, para implementar el algoritmo de vecino más cercano en el plano XY. Los archivos “.las” fueron manipulados mediante la librería *laspy* 2.5.4.

El primer archivo corresponde a la nube de puntos original, denominada 09B\_TERRENO.las, mientras que el segundo archivo (09B\_LINEAS\_VF.las) fue generado a partir de una segmentación manual, con el objetivo de extraer exclusivamente las líneas eléctricas presentes en la zona de estudio. Sobre las nubes de puntos se aplicó la propiedad geométrica *Verticality* para remover estructuras verticales como paredes que aún permanecían y generaban ruido en el análisis.

Una vez depurado el conjunto de datos, se generó una malla de terreno continua a partir de los puntos, con el objetivo de calcular las alturas relativas de los puntos de 09B\_LINEAS\_VF respecto a esta superficie. Se utilizó el algoritmo de vecino más cercano, que para cada punto de LINEAS\_VF busca el punto más cercano en XY dentro de la malla del terreno, y calcula la diferencia en la coordenada Z:

$$Relative\_Height = Z\_LINEAS\_VF - Z\_TERRAIN$$

Con ayuda del software *CloudCompare*, a través de la herramienta *Scalar Field* con la nube *Relative\_Height* se activa la altura relativa.

En Ecuador, las alturas a las que se instalan los cables de media y baja tensión están reguladas por normas técnicas emitidas por empresas distribuidoras de energía y por el Reglamento de Instalaciones Eléctricas de Baja Tensión (RETIE-ECUADOR), así como por normas técnicas como la NTN-SEDELEC.

La altura de los conductores eléctricos de baja tensión está entre 6 y 7,5 metros, mientras que los conductores eléctricos de media tensión está entre 8 y 11 metros, aunque puede variar según la zona geográfica, urbanización y carga (Comisión de Homologación de las Unidades de Propiedad, 2013).

Dado que cada línea está compuesta por miles de puntos, se evaluó la clasificación a nivel de segmento, considerando el porcentaje de puntos dentro del rango esperado. En función de ello, se definieron criterios de acierto basados en la proporción de puntos correctamente clasificados por línea (>80%).

#### 4. RESULTADOS

Los resultados obtenidos permitieron evaluar la efectividad del enfoque propuesto para la detección automática de postes de alumbrado público y la clasificación de líneas eléctricas de media y baja tensión en entornos urbanos, mediante el análisis de nubes de puntos *LiDAR* obtenidas con escáner móvil terrestre. A continuación, se presentan los principales hallazgos:

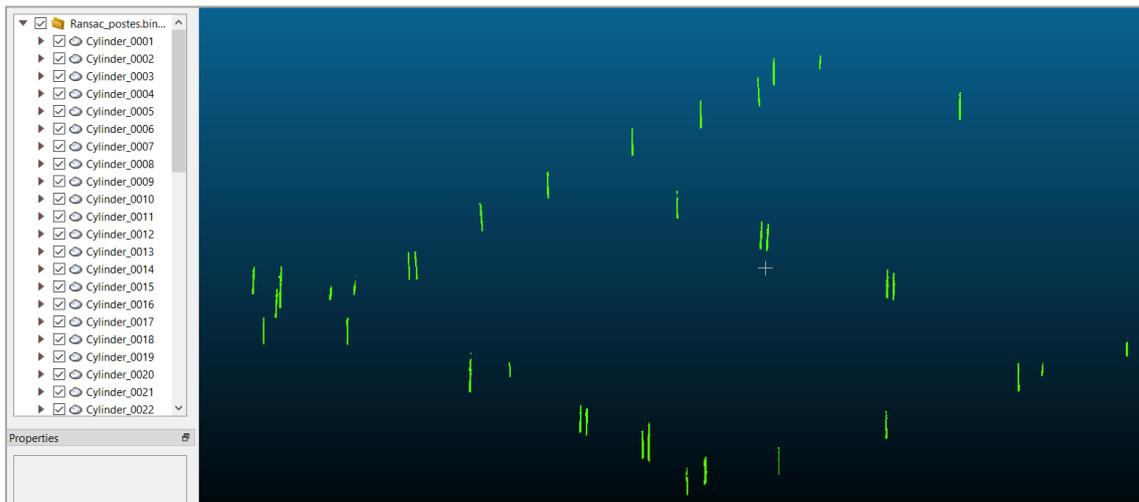
##### 4.1 Detección de postes de alumbrado público con RANSAC

La aplicación del algoritmo *RANSAC Shape Detection* en *CloudCompare*, configurado para identificar estructuras cilíndricas, permitió detectar con alta precisión los postes de alumbrado presentes en el área de estudio. Los parámetros utilizados (1000 puntos de soporte y min radius de 0,05 a max radius 0,40 m) fueron calibrados empíricamente para maximizar los aciertos y minimizar los falsos positivos (Figura 5). Con los mismos se identificaron 134 postes de forma automática, frente a los 142 postes validados manualmente en campo, lo que representa una precisión del 94,3 % (Tabla 2). Adicionalmente se detectaron 8 falsos positivos, asociados principalmente a señales de tránsito y estructuras tubulares similares, y 8 falsos negativos, correspondientes a postes que no fueron reconocidos por el algoritmo debido a interferencias, oclusión o escasa densidad de puntos en esos sectores.

**Tabla 2** Resultados de fiabilidad en la detección de postes (*RANSAC*)

Métrica	Valor	Descripción
Total de postes en campo (TP + FN)	142	Postes reales identificados manualmente
Postes detectados correctamente (TP)	134	Verdaderos positivos
Falsos positivos (FP)	8	Objetos erróneamente identificados como postes
Falsos negativos (FN)	8	Postes reales no detectados automáticamente
Precisión (Precision)	94,3%	$TP / (TP + FP)$
Exhaustividad (Recall)	94,3%	$TP / (TP + FN)$

False Discovery Rate	5,7%	FP / (TP + FP)
----------------------	------	----------------



*Figura 5 Clasificación con RANSAC para alumbrado público.*

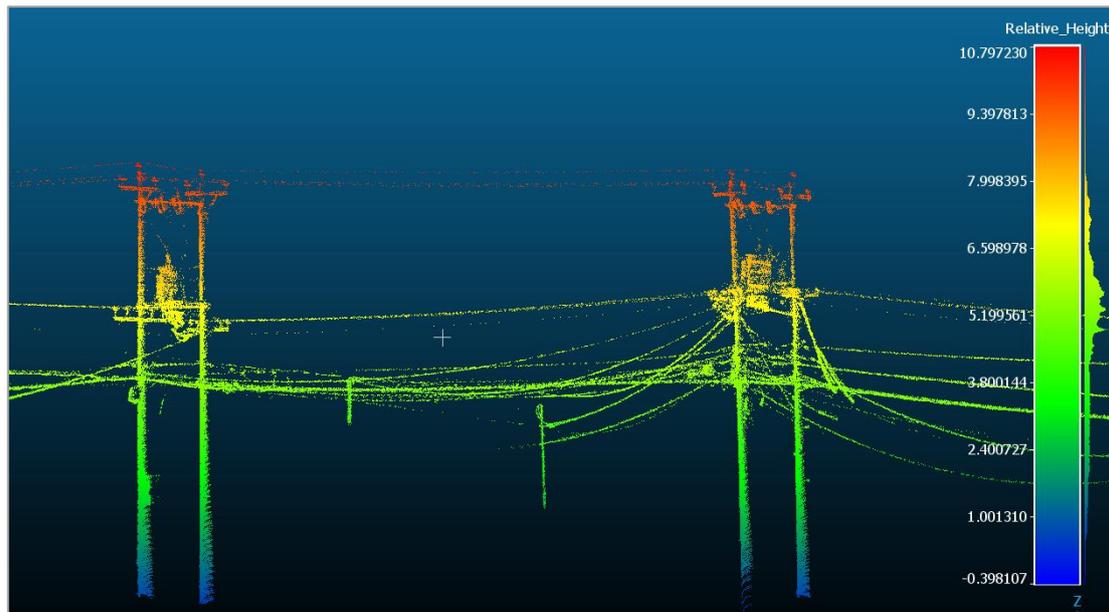
La validación visual posterior y la segmentación manual permitieron depurar los resultados y consolidar una base de datos confiable de postes correctamente identificados.

#### **4.2 3. Clasificación de líneas eléctricas por análisis altitudinal**

Para la clasificación de líneas de media y baja tensión, se utilizó como criterio principal la altura relativa respecto a la superficie del terreno y de acuerdo con la normativa técnica consultada y prácticas locales, de los rangos altitudinales, los resultados indicaron que el 91,2 % de los puntos correspondientes a líneas de baja tensión se ubicaron dentro del rango esperado, mientras que para líneas de media tensión este porcentaje fue del 88,7 % (Tabla 3). Para una evaluación más integral, se analizó el porcentaje de tramos correctamente clasificados, considerando que un tramo es válido si al menos el 80 % de sus puntos se encuentra dentro del rango altitudinal correspondiente (Figura 6).

*Tabla 3 Resultados de clasificación de líneas eléctricas por altura relativa*

<b>Tipo de línea</b>	<b>Rango altitudinal esperado (m)</b>	<b>% de puntos clasificados</b>	<b>Tramos correctamente clasificados</b>
Baja tensión	6 – 7,5	91,2 %	13 de 14
Media tensión	8 – 11	88,7 %	9 de 10



**Figura 6** Clasificación de líneas de media y baja tensión, según la altura relativa.

Los resultados de la clasificación de líneas eléctricas, los aciertos alcanzaron el 91,2 % para baja tensión (IC 95 %: 87,0 % – 94,5 %) y 88,7 % para media tensión (IC 95 %: 84,0 % – 92,5 %). En cuanto a la detección de postes, los resultados presentaron una precisión del 94,3 %, con un intervalo de confianza del 95 % entre 90,5 % y 97,0 %. Se observaron falsos positivos principalmente asociados a objetos cilíndricos similares a postes, como señales de tránsito y estructuras tubulares no eléctricas, los cuales representan un 5,7 % del total de detecciones. Estas confusiones se atribuyen a limitaciones en la resolución espacial y la densidad variable de la nube de puntos, así como a la falta de integración de información contextual adicional. Los falsos negativos, correspondientes a postes no detectados, fueron en su mayoría causados por oclusiones parciales o insuficiente cobertura de puntos en zonas complejas, lo que sugiere la necesidad de mejorar la densidad o calidad de los datos o integrar algoritmos complementarios.

## 5. DISCUSIÓN Y CONCLUSIONES

### 5.1 Discusión

El procesamiento de datos *LiDAR*, particularmente en entornos urbanos complejos, presenta múltiples desafíos derivados del ruido generado por diversas fuentes, entre ellas: errores en la captura, condiciones ambientales, limitaciones del escáner y elementos ajenos a la infraestructura de interés. En este estudio, dichos factores afectaron principalmente la clasificación automática de postes, generando falsos positivos como señales de tránsito o estructuras tubulares que comparten geometría similar. Esta situación impacta directamente en la precisión del análisis y resalta la necesidad de aplicar validaciones visuales o filtros adicionales.

La combinación de filtrado (CSF), detección de formas geométricas (*RANSAC*) y análisis altitudinal demostró ser eficaz para clasificar infraestructura eléctrica urbana utilizando herramientas de software libre. Las métricas alcanzadas son comparables con las reportadas en estudios internacionales similares (Gaha et al., s. f.; Wang, Chen, Liu, et al., 2017), lo que valida la solidez de la metodología propuesta. No obstante, se reconoce que

la intervención manual sigue siendo necesaria en ciertas etapas, lo que limita la automatización total del proceso.

En cuanto a las herramientas utilizadas, *CloudCompare* permitió realizar gran parte del preprocesamiento y la clasificación geométrica, como la detección de postes mediante el algoritmo *RANSAC*. Sin embargo, sus capacidades para una clasificación completamente automatizada son restringidas, especialmente al trabajar con objetos de baja altura o estructuras solapadas. Esto obligó a complementar el flujo de trabajo con scripts en *Python*, especialmente para calcular la altura relativa de los puntos. Esta dependencia de múltiples herramientas expone una limitación operativa importante.

Durante el análisis de la nube de puntos obtenida mediante tecnología *LiDAR*, se identificó una disposición espacial particular de las líneas de distribución eléctrica en la zona de estudio, la cual facilitó su clasificación visual y estructural, en entornos urbanos, sin embargo, a pesar de haber identificado claramente esta disposición estructurada, la clasificación no fue implementada de forma automatizada dentro de la plataforma *CloudCompare*, debido a que esta herramienta no cuenta con módulos nativos para el reconocimiento de estructuras lineales suspendidas o clasificación por trayectorias espaciales.

Por otro lado, la segmentación manual de las líneas eléctricas fue una etapa necesaria para depurar el conjunto de datos y garantizar la calidad de la clasificación. No obstante, este paso resalta la carencia de soluciones plenamente automáticas y sugiere que futuras investigaciones deberían incorporar modelos de aprendizaje automático o redes neuronales para mejorar la eficiencia, reducir la intervención humana y optimizar la adaptabilidad de la metodología a otras zonas.

En comparación con los estudios revisados en el estado del arte, el presente trabajo demuestra una alta fiabilidad en la detección de postes de alumbrado público y la clasificación de líneas eléctricas de media y baja tensión mediante datos *LiDAR*. La precisión alcanzada en la detección de postes (94,3%) y la clasificación de líneas de baja tensión (91,2%) y media tensión (88,7%) se encuentra dentro de los rangos reportados por investigaciones similares, como los trabajos de Wang et al. (2017), Gaha et al. (2021) y Yermo et al. (2019), quienes lograron precisiones superiores al 90% en entornos urbanos y rurales. Sin embargo, a diferencia de estos estudios, que han utilizado métodos como la voxelización y descriptores geométricos para el análisis, el enfoque de esta investigación se distingue por su integración de análisis altitudinal. Aunque la intervención manual sigue siendo necesaria en algunas fases, como en la validación de los resultados de *RANSAC*, el uso de herramientas de software libre como *CloudCompare* y la segmentación asistida demuestra ser una alternativa viable y de bajo costo, especialmente para entornos urbanos con limitaciones presupuestarias. Este estudio también plantea una vía para futuras investigaciones que incorporen inteligencia artificial, lo que podría mejorar la automatización y la fiabilidad en la clasificación de infraestructuras eléctricas.

## 5.2 Conclusiones

El presente estudio demostró la viabilidad del uso de datos *LiDAR* adquiridos mediante escaneo móvil terrestre para la detección automática de postes de alumbrado público y la clasificación de líneas eléctricas de media y baja tensión en entornos urbanos. Se logró

una precisión del 94,3 % en la identificación de postes, y una clasificación correcta superior al 88 % para líneas de distribución, utilizando criterios de altura relativa sobre una malla de terreno generada a partir de la propia nube de puntos.

El uso de herramientas de software libre como *CloudCompare* resultó adecuado para proyectos con restricciones presupuestarias, permitiendo realizar filtrados, segmentaciones y análisis geométricos básicos. No obstante, su aplicabilidad como herramienta única es limitada, ya que requiere ser complementada con otros entornos como *Python* para alcanzar resultados más robustos. Esta limitación evidencia la necesidad de incorporar flujos de trabajo más integrados y, preferiblemente, automatizados.

Una de las principales contribuciones metodológicas de este trabajo fue la clasificación de líneas de distribución eléctrica basándose en su altura relativa respecto al terreno, considerando la disposición estructural observada en campo. A diferencia de la mayoría de los estudios revisados, que se enfocan únicamente en la geometría de los objetos, esta investigación incorpora un enfoque altitudinal adaptado al contexto urbano ecuatoriano.

El presente estudio sienta las bases para futuras investigaciones que puedan ampliar y profundizar el uso de tecnología *LiDAR* en la gestión de infraestructura eléctrica urbana en Ecuador, donde actualmente no se cumple de manera estricta la normativa relacionada con la instalación y mantenimiento de redes. Se vislumbra un gran potencial en el desarrollo de modelos de aprendizaje automático e inteligencia artificial que automaticen completamente la detección y clasificación, reduciendo la intervención manual y aumentando la escalabilidad del método. Además, la integración con datos complementarios como imágenes hiperespectrales o información GIS (*Geographic Information System*) puede mejorar significativamente la precisión y discriminación de objetos similares. Frente a los métodos tradicionales, esta metodología ofrece una solución más rápida, segura, precisa y económicamente eficiente para la gestión y monitoreo continuo de redes eléctricas, contribuyendo a la modernización y optimización del sector energético.

Finalmente, este estudio abre la puerta a futuras investigaciones que integren modelos de inteligencia artificial para automatizar completamente la clasificación, mejorar la precisión y facilitar la replicación del método en otras zonas del país o de la región.

## REFERENCIAS

- Calle, D. (2024). Aplicación de la tecnología LiDAR a la cartografía y modelación de líneas eléctricas de alta tensión. Aplicación práctica a un tramo de 120 kilómetros en Guatemala.
- Cervero, A. (2016). Extracción y Clasificación de Objetos a partir de una Nube de Puntos Registrada con un Escáner Láser Móvil.
- Chasco, D. (2018). DETECCIÓN AUTOMÁTICA DE LINEAS ELÉCTRICAS DE ALTA TENSIÓN EN DATOS LIDAR MEDIANTE MINERÍA DE DATOS.

- Cheng, L., Chen, S., Liu, X., Xu, H., Wu, Y., Li, M., & Chen, Y. (2018). Registration of Laser Scanning Point Clouds: A Review. *Sensors*, 18(5), Article 5.  
<https://doi.org/10.3390/s18051641>
- Clode, S., & Rottensteiner, F. (2005a). Classification of Trees and Powerlines from medium resolution Airborne Laserscanner data in Urban Environments.
- Clode, S., & Rottensteiner, F. (2005b). Classification of Trees and Powerlines from medium resolution Airborne Laserscanner data in Urban Environments.
- CloudCompare—Open Source project. (s. f.). Recuperado 3 de junio de 2025, de <https://www.cloudcompare.org/>
- Comisión de Homologación de las Unidades de Propiedad. (2013). HOMOLOGACIÓN DE LAS UNIDADES DE PROPIEDAD Y UNIDADES DE CONSTRUCCIÓN DEL SISTEMA DE DISTRIBUCIÓN ELÉCTRICA.  
<https://www.unidadespropiedad.com/>
- Dihkan, M., & Mustafa, E. (2021). Automatic detection of power transmission lines and risky object locations using UAV LiDAR data. *Arabian Journal of Geosciences*, 14(7), Article 7. <https://doi.org/10.1007/s12517-021-06947-1>
- Gaha, M., Jaafar, W., Fakhfekh, J., Houle, G., Abderrazak, J. B., & Bourgeois, M. (s. f.). A NEW LIDAR-BASED APPROACH FOR POLES AND DISTRIBUTION LINES DETECTION AND MODELLING. *Computer Science*.
- Laíño, D. (2022). Clasificación de nubes de puntos tridimensionales de parcelas forestales mediante técnicas de aprendizaje profundo. *PARCELAS FORESTALES*.
- Lehtomäki, M., Kukko, A., Matikainen, L., Hyypä, J., Kaartinen, H., & Jaakkola, A. (2019). Power line mapping technique using all-terrain mobile laser scanning.

Automation in Construction, 105, 102802.

<https://doi.org/10.1016/j.autcon.2019.03.023>

- Ortega, S., Trujillo, A., & Pablo, S. (2018). AN IMAGE-BASED METHOD TO CLASSIFY POWER LINES IN LIDAR POINT CLOUDS. *líneas eléctricas*.
- Salas, J. (2021). PROCESAMIENTO AUTOMÁTICO DE NUBES DE PUNTOS MLS PARA LA EXTRACCIÓN DE CARACTERÍSTICAS DE CARRETERAS.
- Sánchez, P. R., & Salcines, I. R. R. (2015). Automatización del sistema de la red de distribución primaria de la ciudad de Cienfuegos.
- Varela, F., Fernández, F., Esmorís, A., Fernández, D., Lopez, D., & Cabaleiro, J. C. (2021). Clasificación y caracterización de elementos de recorrido peatonal en un entorno urbano mediando datos LIDAR.
- Wang, Y., Chen, Q., Li, K., Zheng, D., & Fang, J. (2017). AIRBORNE LIDAR POWER LINE CLASSIFICATION BASED ON SPATIAL TOPOLOGICAL STRUCTURE CHARACTERISTICS. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2/W4, 165-169.  
<https://doi.org/10.5194/isprs-annals-IV-2-W4-165-2017>
- Wang, Y., Chen, Q., Liu, L., Zheng, D., Li, C., & Li, K. (2017). Supervised Classification of Power Lines from Airborne LiDAR Data in Urban Areas. *Remote Sensing*, 9(8), Article 8. <https://doi.org/10.3390/rs9080771>
- Yermo, M., Martínez, J., Lorenzo, O. G., Vilariño, D. L., Cabaleiro, J. C., Pena, T. F., & Rivera, F. F. (2019). AUTOMATIC DETECTION AND CHARACTERISATION OF POWER LINES AND THEIR SURROUNDINGS USING LIDAR DATA. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W13, 1161-1168.  
<https://doi.org/10.5194/isprs-archives-XLII-2-W13-1161-2019>

Zhu, L., & Hyypä, J. (2014). The Use of Airborne and Mobile Laser Scanning for Modeling Railway Environments in 3D. *Remote Sensing*, 6(4), Article 4.

<https://doi.org/10.3390/rs6043075>