

APLICACIÓN DE INTELIGENCIA ARTIFICIAL EN LA CLASIFICACIÓN AUTOMÁTICA DE PUNTOS LiDAR PARA LA GENERACIÓN DE MODELOS DIGITALES DEL TERRENO CON FINES CARTOGRÁFICOS (CASO: CRUCE GSCY – RÍO GRANDE)

Lic. Joel Bautista Choquehuanca

Servicio Nacional de Aerofotogrametría

Correo Electrónico: umsaiiag.bautista@gmail.com

Resumen

La clasificación de nubes de puntos LiDAR aerotransportadas constituye una etapa fundamental en la generación de Modelos Digitales del Terreno (MDT) para aplicaciones cartográficas en proyectos de ingeniería. Sin embargo, los métodos tradicionales basados en reglas, como los implementados en TerraScan, presentan limitaciones en áreas con vegetación densa debido a la confusión entre puntos de terreno y vegetación baja, además de requerir una significativa intervención del operador.

La presente investigación evalúa el desempeño de un modelo de aprendizaje supervisado basado en Random Forest para la clasificación automática de nubes de puntos LiDAR, comparándolo con el método tradicional. El área de estudio corresponde al proyecto Cruce GSCY – Río Grande, en el municipio de Cabezas, Bolivia, utilizando una nube de aproximadamente 16,9 millones de puntos adquiridos con sensor LiDAR Leica ALS70.

El conjunto de entrenamiento (ground truth) fue generado mediante clasificación en TerraScan y corrección manual experta bajo un protocolo reproducible de control de calidad. La validación incluyó una partición espacial para reducir efectos de autocorrelación y una evaluación independiente mediante puntos de control GNSS, empleando el RMSEz como indicador de precisión altimétrica.

Los resultados muestran que el modelo propuesto alcanza un RMSEz de 0,076 m frente a 0,096 m del método tradicional, evidenciando una mejora del 20,8%. Asimismo, la densidad de puntos de terreno se incrementa de 6,552 a 9,673 pts/m² y el tiempo de procesamiento se reduce de aproximadamente 8 horas a menos de 1 minuto. Estos resultados evidencian una mejora cuantificable en precisión altimétrica y eficiencia operativa bajo un enfoque reproducible.

Abstract

The classification of airborne LiDAR point clouds is a fundamental step in generating Digital Terrain Models (DTMs) for mapping applications in engineering projects. However, traditional rule-based methods, such as those implemented in TerraScan, have limitations in areas with dense vegetation due to confusion between ground points and low vegetation, and also require significant operator intervention.

This research evaluates the performance of a supervised learning model based on Random Forest for the automatic classification of LiDAR point clouds, comparing it with the traditional method. The study area corresponds to the Cruce GSCY – Río Grande project, in the municipality of Cabezas, Bolivia, using a cloud of approximately 16,9 million points acquired with a Leica ALS70 LiDAR sensor.

The training set (ground truth) was generated through classification in TerraScan and expert manual correction under a reproducible quality control protocol. The validation included spatial partitioning to reduce autocorrelation effects and independent evaluation using GNSS control points, employing RMSEz as an indicator of altimetric accuracy.

The results show that the proposed model achieves an RMSEz of 0,076 m compared to 0,096 m for the traditional method, demonstrating a 20,8% improvement. Furthermore, the ground point density increases from 6,552 to 9,673 points/m², and processing time is reduced from approximately 8 hours to less than 1 minute. These results demonstrate a quantifiable improvement in altimetric accuracy and operational efficiency under a reproducible approach.

Palabras clave

LiDAR, Modelo Digital del Terreno, Random Forest, Cartografía, GNSS.

1. Introducción

La generación de información geoespacial de alta precisión constituye un componente fundamental en la planificación y ejecución de proyectos de ingeniería, particularmente en entornos donde la topografía y la cobertura vegetal condicionan el diseño y la toma de decisiones. En este contexto, la tecnología LiDAR aerotransportada se ha consolidado como una herramienta eficiente para la adquisición de datos tridimensionales de alta densidad, permitiendo la generación de Modelos Digitales del Terreno y productos cartográficos derivados con elevado nivel de detalle.

Uno de los principales desafíos en el procesamiento de datos LiDAR radica en la correcta clasificación de la nube de puntos, especialmente en áreas con vegetación densa, donde la diferenciación entre puntos de terreno y vegetación baja resulta compleja. Los métodos tradicionales, implementados en software especializado como TerraScan, se basan en algoritmos heurísticos, como la densificación progresiva de TIN, que requieren parametrización manual y dependen de la experiencia del operador. Si bien estos enfoques han demostrado ser efectivos en múltiples escenarios, presentan limitaciones en entornos con alta complejidad estructural, generando errores de clasificación que impactan directamente en la precisión altimétrica del MDT.

En los últimos años, las técnicas de aprendizaje automático han emergido como una alternativa para la clasificación de nubes de puntos LiDAR, al permitir modelar relaciones no lineales entre variables geométricas y radiométricas. Algoritmos como Random Forest han mostrado un desempeño robusto en este tipo de problemas, debido a su capacidad de generalización y tolerancia al ruido. No obstante, una limitación recurrente en la literatura aplicada es la insuficiente documentación de la trazabilidad del conjunto de entrenamiento, la ausencia de validación independiente y la falta de control de la autocorrelación espacial, lo que restringe la reproducibilidad de los resultados y la validez de las inferencias.

En este contexto, la presente investigación propone un enfoque metodológico reproducible para la clasificación de nubes de puntos LiDAR basado en Random Forest, incorporando un conjunto de entrenamiento con trazabilidad documentada a partir de un proceso híbrido de clasificación automática y validación experta, una estrategia de validación espacial fuera de muestra para mitigar efectos de autocorrelación, y una evaluación independiente de la precisión altimétrica del MDT mediante puntos de control GNSS.

La investigación se desarrolla sobre datos del proyecto Cruce GSCY – Río Grande, ubicado en el municipio de Cabezas, Bolivia, utilizando una nube de aproximadamente 16,9 millones de puntos adquiridos mediante sensor LiDAR aerotransportado Leica ALS70. El objetivo es evaluar comparativamente el desempeño del modelo de aprendizaje automático frente al método tradicional implementado en TerraScan, considerando métricas de clasificación, precisión altimétrica (RMSEz), densidad de puntos de terreno y eficiencia operativa, con el fin de determinar su viabilidad en flujos de producción cartográfica en entornos complejos.

2. Metodología y Desarrollo

La presente investigación evalúa la clasificación automática de nubes de puntos LiDAR mediante un enfoque basado en inteligencia artificial, comparado con el método tradicional implementado en TerraScan/MicroStation, con el objetivo de optimizar la generación de Modelos Digitales del Terreno para fines cartográficos.

2.1 Datos LiDAR y área de estudio

El área de estudio corresponde al proyecto “Ingeniería, Procura y Construcción Ampliación Cruce GSCY – Río Grande”, ubicado en el municipio de Cabezas, Bolivia. Se definió un polígono de análisis de 36 ha representativo de condiciones mixtas de cobertura.

La nube de puntos LiDAR fue adquirida mediante sensor Leica ALS70 y georreferenciada en el sistema WGS84/UTM zona 20S. La precisión planimétrica del levantamiento se estimó en aproximadamente 0,06 m a partir del ajuste cinemático de la trayectoria GNSS/IMU.

Los parámetros principales del levantamiento se presentan en la Tabla 1.

Tabla 1: *Parámetros principales del vuelo y sensor LiDAR.*

Parámetro	Valor
Aeronave	Cessna C-402
Sensor	Leica ALS70
Altura de vuelo	848–870 m AGL
Campo de visión (FOV)	20°
Frecuencia de escaneo	66,3 Hz
Tasa de pulsos láser	500.000 Hz
Área de estudio	36 ha
Nube de puntos bruta	16.961.763 puntos
Sistema de referencia	WGS84 / UTM Zona 20S

2.2 Generación del conjunto de referencia (ground truth)

El conjunto de referencia fue generado mediante un flujo híbrido reproducible que combina clasificación automática inicial y validación experta.


En una primera etapa, la nube de puntos fue clasificada en TerraScan utilizando un algoritmo de filtrado de terreno basado en densificación progresiva de TIN. Esta clasificación se empleó únicamente como base preliminar para la generación de etiquetas.

Posteriormente, se realizó una corrección manual enfocada en zonas de mayor incertidumbre, particularmente en transiciones entre terreno y vegetación baja. El proceso de rotulación se basó en

criterios geomorfológicos y geométricos, considerando la continuidad del terreno, el comportamiento altimétrico local y la estructura de retornos LiDAR.

La consistencia de las etiquetas fue verificada mediante revisión sistemática y control de coherencia espacial. El conjunto resultante se utilizó exclusivamente para el entrenamiento del modelo, mientras que la evaluación se realizó mediante validación espacial independiente y puntos de control GNSS, garantizando la separación entre entrenamiento y validación.

Figura 1. Flujo de generación del ground truth.



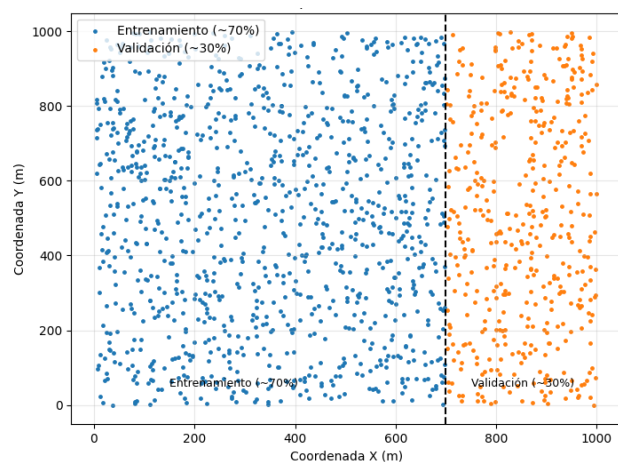
2.3 Construcción del dataset y partición de datos

A partir de la nube de puntos, se realizó un submuestreo de 200.000 puntos mediante un esquema de muestreo aleatorio estratificado por clases, preservando la representatividad de las coberturas presentes (terreno, vegetación baja, media y alta). La selección se efectuó de manera proporcional a la distribución original de las clases en la nube de puntos, manteniendo sus proporciones relativas y evitando sesgos en la representación del dataset. El conjunto de datos se construyó integrando variables geométricas, radiométricas y derivadas junto con las etiquetas generadas en el proceso de ground truth.

La partición del dataset se realizó mediante una estrategia de validación espacial basada en bloques, con el fin de reducir efectos de autocorrelación. El área de estudio fue subdividida en sectores independientes, a partir de los cuales se definieron los conjuntos de entrenamiento y validación en proporciones de 70% y 30%, respectivamente, garantizando que las muestras de validación correspondan a regiones no utilizadas durante el entrenamiento.

La distribución de las muestras fue verificada para mantener un equilibrio relativo entre clases.

Figura 2: Esquema de partición espacial del dataset LiDAR.



2.4 Variables predictoras

Para la clasificación de la nube de puntos LiDAR se emplearon variables geométricas (X, Y, Z), radiométricas (intensidad) y variables derivadas que describen la estructura local de la nube, como la altura relativa y la variabilidad altimétrica, considerando un esquema de clases coherente con criterios cartográficos y estándares geoespaciales (ASPRS, 2014).

Las variables derivadas fueron calculadas a partir de un vecindario local mediante el algoritmo de k vecinos más cercanos (k-NN), considerando un valor de $k = 15$, definido en función de la estructura espacial de la nube de puntos para capturar la variabilidad altimétrica local sin introducir sobre suavizado en la geometría del terreno.

Tabla 2. Variables predictoras utilizadas en la clasificación LiDAR.

Variable	Tipo	Descripción
X, Y	Geométrica	Coordenadas planimétricas del punto
Z	Geométrica	Elevación del punto
Intensidad	Radiométrica	Intensidad del retorno LiDAR
Número de retorno	Atributo LiDAR	Orden del retorno dentro del pulso emitido
Número total de retornos	Atributo LiDAR	Cantidad total de retornos asociados al pulso
Altura relativa	Derivada	Diferencia altimétrica respecto al entorno local
Varianza local	Derivada	Variabilidad de la elevación en el vecindario espacial

2.5 Modelo de clasificación

Se implementó un modelo de aprendizaje supervisado basado en el algoritmo Random Forest, seleccionado por su capacidad para manejar datos ruidosos y variables correlacionadas en problemas de clasificación geoespacial.

El modelo fue entrenado utilizando el conjunto de referencia (ground truth) y las variables predictoras descritas en la Sección 2.4. La implementación se realizó en entorno Python mediante la biblioteca *scikit-learn*.

Se configuraron 150 árboles de decisión ($n_estimators = 150$) con una profundidad máxima de 25 niveles ($max_depth = 25$) y un mínimo de 5 muestras por división ($min_samples_split = 5$). Para manejar el desbalance entre clases, se empleó ponderación automática ($class_weight = "balanced"$) y se fijó una semilla aleatoria ($random_state = 42$) para garantizar la reproducibilidad.

El entrenamiento y la evaluación del modelo se realizaron conforme a la estrategia de partición espacial descrita en la Sección 2.3.

2.6 Validación y control de autocorrelación espacial

La evaluación del modelo de clasificación se realizó utilizando el conjunto de validación definido mediante la partición espacial descrita en 2.3.

El desempeño del modelo fue evaluado mediante métricas estándar derivadas de la matriz de confusión, incluyendo precisión, exhaustividad (recall) y la medida F1, utilizadas para cuantificar el desempeño del clasificador en cada una de las clases.

Adicionalmente, se empleó la exactitud global (accuracy) como medida general del desempeño del modelo. La matriz de confusión permitió analizar los errores de clasificación y las posibles confusiones entre clases.

2.7 Evaluación de la precisión altimétrica (RMSE_z)

La precisión altimétrica del Modelo Digital del Terreno generado fue evaluada mediante el cálculo del error cuadrático medio vertical (RMSE_z), empleando puntos de control independientes obtenidos mediante levantamiento GNSS.

El error cuadrático medio vertical (RMSE_z) fue obtenido mediante la fórmula:

$$RMSE_z = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_{LiDAR} - Z_{GNSS})^2}$$

donde Z_{LiDAR} corresponde a la elevación obtenida del MDT, Z_{GNSS} a los valores de referencia medidos en campo y n es el número de puntos de control.

Se emplearon 8 puntos de control GNSS distribuidos en el área de estudio, garantizando su independencia respecto al conjunto de entrenamiento del modelo. Las observaciones fueron enlazadas a la estación permanente del Instituto Geográfico Militar, estación SCRZ (Santa Cruz). La evaluación se realizó sobre superficies representativas de distintas condiciones de cobertura.

Tabla 3. Puntos de control GNSS enlazados a la estación SCRZ.

Punto	X	Y	Z Elips.
P1	502494.820	7956063.070	369.800
P2	502499.532	7956118.352	369.512
P3	502504.291	7956287.965	368.204
P4	502505.439	7956451.332	368.989
P5	502495.980	7956181.891	369.742
P6	502497.690	7956246.890	369.285
P7	502508.542	7956354.355	367.316
P8	502505.040	7956547.044	369.260

2.8 Generación del Modelo Digital del Terreno

A partir de los puntos clasificados como terreno, se generó el Modelo Digital del Terreno mediante una red de triangulación irregular (TIN), posteriormente interpolada a un modelo ráster con

resolución de 1 m, utilizando un método lineal sin suavizado adicional. Previamente, se realizó la depuración de valores atípicos mediante análisis de consistencia altimétrica local.

Los vacíos fueron tratados mediante interpolación dentro de la red TIN, garantizando continuidad superficial. No se emplearon breaklines, con el fin de evaluar exclusivamente el impacto de la clasificación. El Modelo Digital del Terreno se generó en el sistema WGS84 / UTM zona 20S, utilizando alturas elipsoidales en coherencia con los datos GNSS de validación.

Figura 3. Flujo de generación del MDT.



2.9 Método tradicional (TerraScan)

La clasificación tradicional se realizó en TerraScan mediante un algoritmo de filtrado de terreno basado en densificación progresiva de TIN. Los parámetros fueron definidos en función de las características del área de estudio y ajustados siguiendo criterios operativos estándar para la separación entre terreno y objetos elevados.

El proceso incluyó intervención manual experta para la corrección de errores en zonas críticas, replicando un flujo de trabajo típico en producción cartográfica. La clasificación se aplicó sobre la misma nube de puntos y dentro del mismo polígono de análisis utilizado en el modelo propuesto, garantizando condiciones equivalentes para la comparación.

Los parámetros utilizados en TerraScan se presentan en la Tabla 4.

Tabla 4. Parámetros de TerraScan.

Parámetro	Valor
Ángulo de terreno	45°
Ángulo de iteración	35°
Distancia de iteración	1,0 m
Tamaño máximo de edificación	30 m

2.10 Comparación entre métodos

La comparación entre el modelo basado en Random Forest y el método tradicional se realizó bajo condiciones equivalentes, considerando:

- Clasificación por clases
- Densidad de puntos (pts/m²)
- Precisión altimétrica (RMSEz)
- Eficiencia operativa

La densidad de puntos se calculó como:

$$D = \frac{N}{A}$$

donde N es el número de puntos clasificados y A el área del polígono (36 ha).

2.11 Entorno computacional y reproducibilidad

El procesamiento se desarrolló en lenguaje Python (versión 3.12) en entorno Google Colab, utilizando las librerías indicadas en la Tabla 5.

El entrenamiento del modelo se ejecutó empleando procesamiento paralelo mediante la configuración `n_jobs = -1`, con el fin de optimizar el tiempo de cómputo.

Tabla 5. Entorno computacional.

Componente	Especificación
Lenguaje	Python 3.12
Entorno	Google Colab
Librerías	Scikit-learn, NumPy, Pandas, Laspy
Procesamiento	Paralelo (<code>n_jobs = -1</code>)

3. Resultados

3.1 Desempeño del modelo de clasificación

El modelo basado en Random Forest alcanzó una exactitud global (accuracy) de **0,835** en el conjunto de validación, lo que evidencia un desempeño adecuado en la clasificación de la nube de puntos LiDAR.

El análisis por clase muestra un comportamiento variable según la complejidad de las coberturas. La clase terreno (clase 2) presentó un F1-score de **0,614** (precisión: 0,617; recall: 0,611), reflejando una capacidad moderada de discriminación. La principal fuente de error corresponde a la confusión con la vegetación baja (clase 3), asociada a la similitud geométrica y altimétrica entre ambas.

En contraste, las clases de vegetación alta y construcciones alcanzan valores de F1-score superiores a **0,95**, lo que indica una alta separabilidad y consistencia en la clasificación.

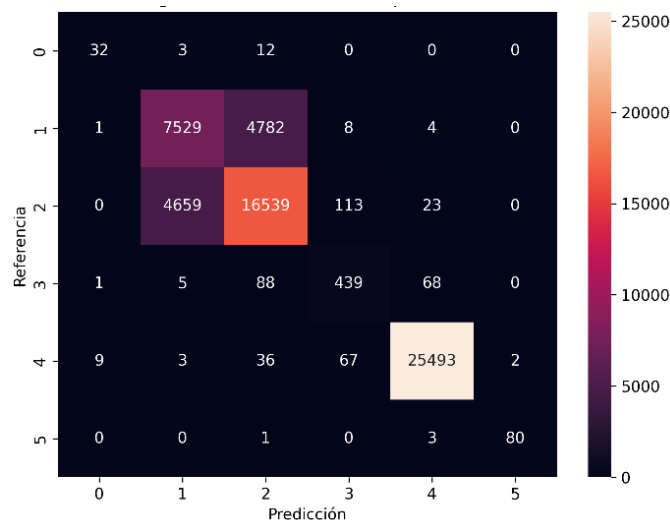
Tabla 6. Métricas de clasificación por clase.

Clase	Descripción	Precisión	Recall	F1-score	n (muestras)
1	No clasificado	0,744	0,681	0,711	47
2	Terreno	0,617	0,611	0,614	12.324
3	Vegetación baja	0,771	0,775	0,773	21.334
4	Vegetación media	0,700	0,730	0,715	601
5	Vegetación alta	0,996	0,995	0,996	25.610
6	Construcciones	0,976	0,952	0,964	84

Análisis de confusión

La matriz de confusión evidencia que la principal fuente de error corresponde a la confusión entre las clases terreno y vegetación baja, consistente con la similitud geométrica y altimétrica entre ambas.

Figura 4. Matriz de confusión.



3.2 Distribución y densidad de puntos por clase

La distribución de puntos LiDAR clasificados evidencia una predominancia de las clases de vegetación y terreno dentro del área de estudio. La clase terreno (clase 2) presenta una densidad de **9,67 pts/m²**, lo que garantiza una adecuada representación de la superficie para la generación del MDT.

La mayor concentración de puntos corresponde a la vegetación alta (clase 5) con **20,13 pts/m²**, seguida de la vegetación baja (clase 3) con **16,75 pts/m²**, reflejando la cobertura dominante en el

área de estudio. Por otro lado, las clases de menor representación, como construcciones y no clasificado, presentan densidades inferiores a **0,1 pts/m²**.

Estos resultados evidencian una distribución heterogénea de la nube de puntos, característica de entornos con cobertura vegetal predominante.

Tabla 7. *Conteo y densidad de puntos por clase.*

Clase	Descripción	Cantidad de puntos	Densidad (pts/m ²)
1	No clasificado	13.475	0,037
2	Terreno	3.480.340	9,668
3	Vegetación baja	6.028.436	16,746
4	Vegetación media	168.699	0,469
5	Vegetación alta	7.246.447	20,129
6	Construcciones	24.366	0,068

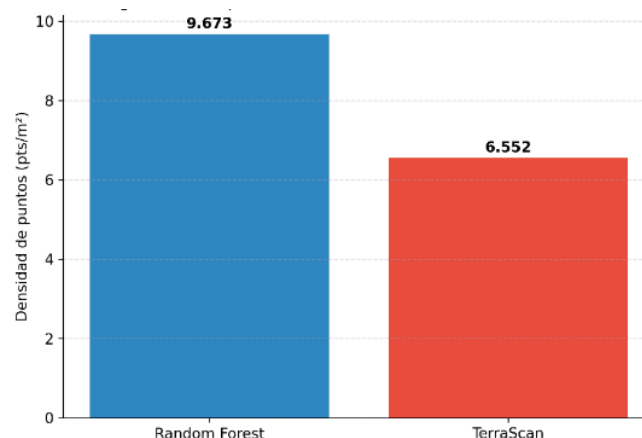
3.3 Comparación de densidad entre métodos

La comparación entre métodos muestra un incremento sustancial en la densidad de puntos clasificados como terreno al utilizar el modelo de aprendizaje automático (9,673 pts/m²) frente a TerraScan (6,552 pts/m²), lo que representa una mejora en la continuidad superficial del MDT.

Tabla 8. *Densidad de puntos del terreno por método.*

Método	Clase evaluada	Densidad (pts/m ²)
Random Forest	Terreno (Clase 2)	9,673
TerraScan	Terreno (Clase 2)	6,552

Figura 5. *Comparación de densidad de terreno entre métodos.*



3.4 Evaluación de precisión altimétrica

La precisión altimétrica fue evaluada mediante el error cuadrático medio vertical (RMSEz), utilizando puntos de control GNSS independientes.

El modelo basado en inteligencia artificial alcanzó un RMSEz de 0,076 m, mientras que el método tradicional presentó un valor de 0,096 m, lo cual evidencia una mejora de 2 cm en la representación altimétrica del terreno.

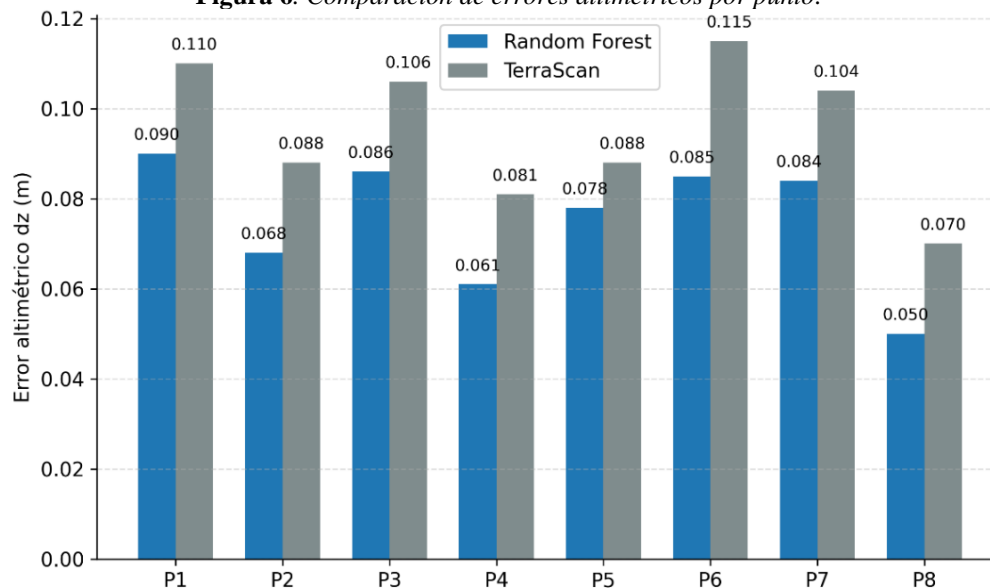
Tabla 9. Precisión altimétrica por método.

Método	RMSEz (m)
Random Forest	0,076
TerraScan	0,096

Tabla 10. Diferencias altimétricas (dz) en puntos de control GNSS.

Punto	Z GNSS (m)	Z LiDAR IA (m)	dz IA (m)	Z LiDAR TerraScan (m)	dz TerraScan (m)
P1	369,800	369,890	0,090	369,910	0,110
P2	369,512	369,580	0,068	369,600	0,088
P3	368,204	368,290	0,086	368,310	0,106
P4	368,989	369,050	0,061	369,070	0,081
P5	369,742	369,820	0,078	369,830	0,088
P6	369,285	369,370	0,085	369,400	0,115
P7	367,316	367,400	0,084	367,420	0,104
P8	369,260	369,310	0,050	369,330	0,070

Figura 6. Comparación de errores altimétricos por punto.

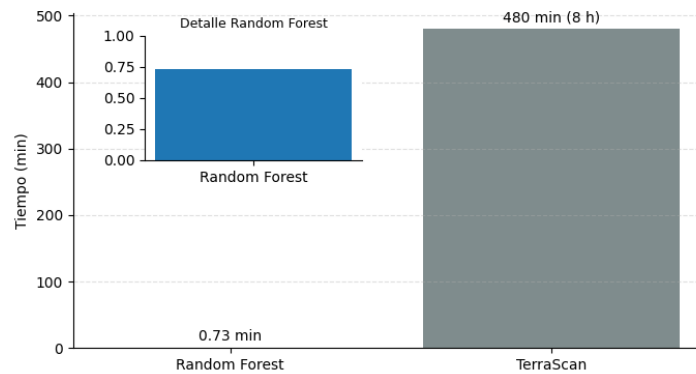


3.5 Eficiencia computacional

El modelo basado en Random Forest presentó un tiempo de procesamiento de 0,73 minutos para la clasificación de la nube de puntos, evidenciando una alta eficiencia computacional. En contraste, el método tradicional TerraScan requiere aproximadamente 480 minutos (8 horas) para completar el mismo proceso bajo condiciones equivalentes, lo que representa una diferencia significativa en términos de tiempo de procesamiento.

Cabe señalar que el tiempo reportado corresponde únicamente a la fase de clasificación (inferencia) del modelo. El entrenamiento del modelo y la generación del conjunto de datos (ground truth) constituyen etapas previas que requieren tiempo adicional de preparación y no son directamente comparables con el flujo tradicional.

Figura 7. Comparación del tiempo de procesamiento.



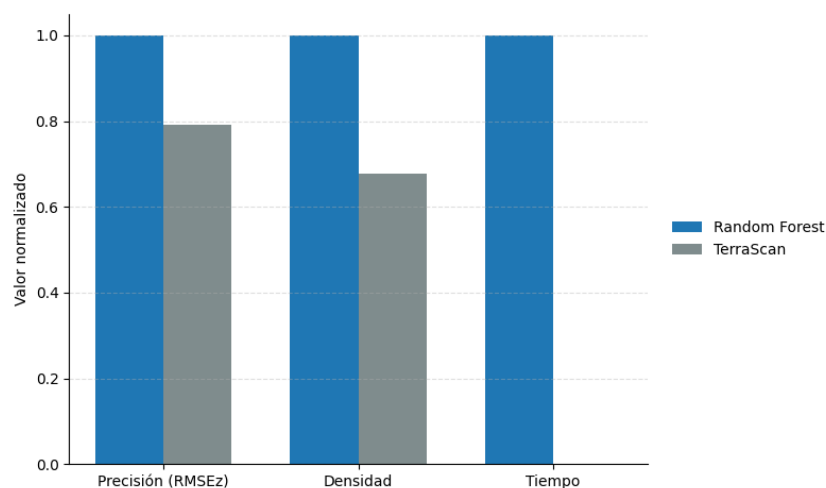
3.6 Comparación integral entre métodos

La comparación integral entre el modelo basado en Random Forest y el método tradicional TerraScan evidencia diferencias en términos de densidad de puntos de terreno, precisión altimétrica y tiempo de procesamiento.

Tabla 11. Comparación entre métodos Random Forest vs TerraScan.

Métrica	Random Forest	TerraScan
Densidad del terreno (pts/m ²)	9,67	6,55
RMSEz (m)	0,076	0,096
Tiempo (min)	0,73	480

Figura 8. Comparación entre métodos Random Forest vs TerraScan.



3.7 Representación del Modelo Digital del Terreno

El Modelo Digital del Terreno fue generado a partir de los puntos clasificados como terreno mediante interpolación basada en triangulación irregular, con una resolución espacial de **1 m**.

La superficie resultante presenta continuidad espacial y coherencia morfológica, sin evidencia de artefactos asociados a errores de clasificación, tales como picos (spikes) o discontinuidades locales. El tratamiento de vacíos permitió mantener la integridad del modelo en zonas con menor densidad de puntos.

Las curvas de nivel derivadas del MDT reflejan una representación consistente del relieve, con una adecuada correspondencia geométrica respecto a la superficie interpolada.

Figura 9. Modelo Digital del Terreno y Superficie del área de investigación.





Figura 10. Curvas de nivel derivadas del MDT, con intervalo de 1 metro.



4. Discusión

Los resultados obtenidos evidencian que el modelo basado en Random Forest presenta un desempeño consistente en la clasificación de nubes de puntos LiDAR, particularmente en la identificación de clases con alta separabilidad geométrica, como vegetación alta y construcciones. Sin embargo, se observa que la clase terreno mantiene un nivel moderado de desempeño ($F1 \approx 0,61$), debido principalmente a la persistente confusión con la vegetación baja. Este comportamiento es consistente con estudios previos que reportan mejoras en la clasificación de nubes LiDAR mediante enfoques basados en aprendizaje automático, particularmente con algoritmos tipo Random Forest (Liao et al., 2022; Ciou et al., 2024), dado que ambas clases comparten características altimétricas y estructurales similares, lo que limita la capacidad discriminativa incluso en modelos no lineales.

No obstante, a pesar de esta limitación en métricas de clasificación, el impacto sobre la generación del Modelo Digital del Terreno resulta favorable desde el punto de vista cartográfico. El incremento en la densidad de puntos clasificados como terreno (9,673 pts/m² frente a 6,552 pts/m² en TerraScan) sugiere que el modelo de aprendizaje automático logra recuperar una mayor cantidad de puntos válidos del terreno, mejorando la continuidad superficial del MDT. Este resultado es relevante desde una perspectiva cartográfica, ya que una mayor densidad de puntos contribuye a reducir vacíos y discontinuidades en la interpolación.

En términos de exactitud altimétrica, la reducción del RMSEz de 0,096 m a 0,076 m evidencia una mejora cuantificable en la representación vertical del terreno. Dado que esta evaluación se realizó mediante puntos GNSS independientes, los resultados adquieren mayor robustez y permiten sustentar la mejora geométrica observada mediante validación externa.

Desde el punto de vista metodológico, la incorporación de un conjunto de entrenamiento con etiquetado consistente y criterios de clasificación explícitamente definidos, junto con una estrategia de validación espacial fuera de muestra, permite reducir el riesgo de sobreestimación del desempeño debido a la autocorrelación espacial. Este aspecto constituye una mejora sustancial respecto a enfoques tradicionales de validación aleatoria, fortaleciendo la reproducibilidad del experimento.

En cuanto a la comparación entre métodos, es importante destacar que el desempeño del enfoque basado en inteligencia artificial se evaluó bajo condiciones equivalentes a las del flujo tradicional implementado en TerraScan, incluyendo la definición explícita de parámetros y la intervención manual experta en ambos casos. Esto permite establecer una comparación metodológicamente consistente, evitando sesgos derivados de configuraciones no controladas.

El análisis de eficiencia operativa muestra una reducción significativa en el tiempo de procesamiento (de aproximadamente 8 horas a menos de 1 minuto), lo que posiciona al enfoque propuesto como una alternativa viable no solo desde el punto de vista geométrico, sino también operativo. No obstante, este resultado debe interpretarse considerando que el tiempo de preparación del conjunto de entrenamiento y la generación del ground truth no fue incluido en la medición, lo cual representa un tiempo inicial adicional que puede ser relevante dependiendo del contexto de aplicación.

Es importante señalar que los resultados obtenidos corresponden a un área específica con condiciones particulares de cobertura vegetal y topografía. Si bien la metodología incorpora mecanismos para mejorar la generalización, como la validación espacial, se recomienda la replicación del enfoque en diferentes escenarios para evaluar su robustez bajo variaciones de densidad de vegetación, pendiente y configuración de los parámetros de adquisición de datos del sensor LiDAR.

5. Conclusiones

La presente investigación evaluó el desempeño de un modelo de clasificación de nubes de puntos LiDAR basado en Random Forest, en comparación con el método tradicional implementado en TerraScan, incorporando un enfoque metodológico reproducible con validación independiente.

Los resultados demuestran que el modelo propuesto permite mejorar la precisión altimétrica del Modelo Digital del Terreno, evidenciado por la reducción del error RMSEz de 0,096 m a 0,076 m, validado mediante puntos GNSS independientes. Asimismo, se observa un incremento significativo en la densidad de puntos clasificados como terreno, pasando de 6,552 a 9,673 pts/m², lo que contribuye a una mejor representación continua de la superficie.

Desde el punto de vista metodológico, la incorporación de un conjunto de entrenamiento con etiquetado consistente y criterios de clasificación explícitamente definidos, junto con la aplicación de una validación espacial fuera de muestra, constituyen aportes relevantes al permitir reducir sesgos asociados a la autocorrelación espacial y mejorar la reproducibilidad del proceso de clasificación.

En términos operativos, el enfoque basado en aprendizaje automático presenta una reducción sustancial en el tiempo de procesamiento (de aproximadamente 8 horas a 0,73 minutos), lo que lo posiciona como una alternativa eficiente para flujos de producción cartográfica. Sin embargo, este resultado debe interpretarse considerando que el tiempo requerido para la generación del conjunto de entrenamiento (ground truth) no fue incluido en la medición, lo cual representa un tiempo inicial adicional en la implementación del enfoque.

No obstante, se reconoce que el desempeño del modelo en la discriminación entre terreno y vegetación baja aún presenta limitaciones. Este comportamiento ha sido reportado en la clasificación de nubes de puntos LiDAR y se asocia principalmente a la similitud en las características geométricas y altimétricas entre ambas clases, así como a la superposición en su estructura vertical. Estos resultados sugieren la necesidad de incorporar variables adicionales o enfoques más avanzados que permitan mejorar la separación entre clases con características similares.

Finalmente, se concluye que la integración de técnicas de inteligencia artificial en el procesamiento de datos LiDAR constituye una alternativa viable y técnicamente sólida para la generación de productos cartográficos de alta precisión. Se recomienda la validación del enfoque en diferentes condiciones geomorfológicas y de cobertura vegetal, así como la evaluación de otros algoritmos de aprendizaje automático que permitan optimizar el desempeño del modelo.

Referencias

- American Society for Photogrammetry and Remote Sensing (ASPRS). (2014). *ASPRS positional accuracy standards for digital geospatial data*.
[https://www.asprs.org/wpcontent/uploads/2015/01/ASPRS Positional Accuracy Standards Edition1 Version100 Noveber2014.pdf](https://www.asprs.org/wpcontent/uploads/2015/01/ASPRS_Positional_Accuracy_Standards_Edition1_Version100_Noveber2014.pdf)
- Arranz Justel, J. J. (2012). *Algoritmo para la clasificación de nubes de puntos LiDAR en zonas urbanas forestales*. (Tesis de ingeniería). Universidad Politécnica de Madrid.
<https://oa.upm.es/21209/>
- Breiman, L. (2001). *Random forests*. *Machine Learning*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>
- Ciou, T.-S., Lin, C.-H., & Wang, C.-K. (2024). *Airborne LiDAR point cloud classification using ensemble learning for DEM generation*. *Sensors*, 24(21), 6858.
<https://doi.org/10.3390/s24216858>
- Duran, Z., Ozcan, K., & Atik, M. E. (2021). *Classification of photogrammetric and airborne LiDAR point clouds using machine learning algorithms*. *Drones*, 5(4), 104.
<https://doi.org/10.3390/drones5040104>
- Liao, L., Tang, S., Liao, J., Li, X., Wang, W., Li, Y., & Guo, R. (2022). *A supervoxel-based Random Forest method for robust and effective airborne LiDAR point cloud classification*. *Remote Sensing*, 14(6), 1516.
<https://doi.org/10.3390/rs14061516>
- Zhao, D., et al. (2023). *Land cover classification based on airborne LiDAR point clouds: A review of traditional and deep-learning methods*. *Sensors*, 23(21), 8841.
<https://doi.org/10.3390/s23218841>