

# Cómo Generar un Modelo Digital del Terreno a partir de Nube de Puntos LiDAR: Flujo de Trabajo Completo

Por [Francisco Navarrete Mandly](#)

La generación de **modelos digitales del terreno (MDT)** a partir de **nubes de puntos LiDAR** es un proceso fundamental en la ingeniería geoespacial, que admite aplicaciones como el modelado de inundaciones, la planificación de infraestructuras, el seguimiento medioambiental y el análisis del terreno. Aunque la tarea puede parecer sencilla a primera vista, abarca una secuencia de fases, cada una con su propia complejidad técnica y puntos de decisión.

Este artículo tiene como objetivo explicar el flujo de trabajo utilizado para producir un MDT de alta calidad a partir de datos LiDAR, detallando cada paso de procesamiento. También exploraremos dos enfoques alternativos para clasificar los puntos del suelo: uno basado en un método tradicional y otro potenciado por Inteligencia Artificial.

Las capturas de pantalla están elaboradas con tcp PointCloud Editor de Aplitop, pero los procedimientos podrían aplicarse en cualquier software de nube de puntos.

## 1. Flujo de trabajo general

El proceso de generación del MDT comienza con la nube de puntos LiDAR original, una densa colección de puntos tridimensionales que normalmente se adquieren a través del escaneo láser aerotransportado. El flujo de trabajo completo se puede resumir de la siguiente manera:

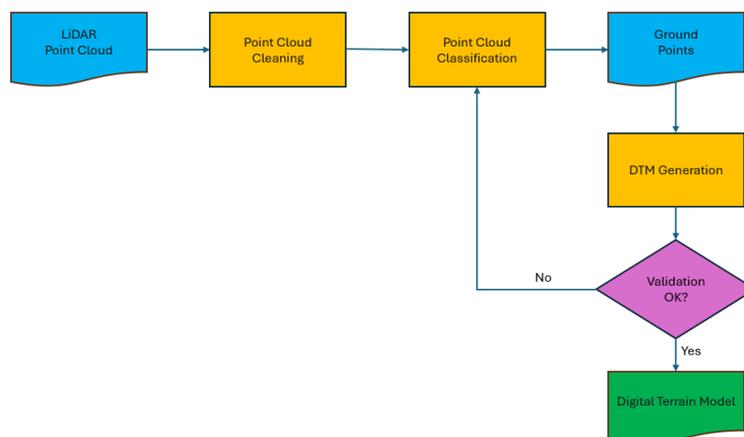


Figura 1. Flujo de trabajo general

## 2. Limpieza de la nube de puntos

Los datos LiDAR sin procesar contienen inevitablemente anomalías e inconsistencias debido a las limitaciones del sensor, las condiciones atmosféricas o la naturaleza del entorno escaneado. Por lo tanto, la limpieza de la nube de puntos es el primer paso esencial. Este proceso puede incluir tareas como las siguientes:

## 2.1 Eliminación de puntos de ruido alto

Los puntos atípicos con valores de elevación extremos o inverosímiles se eliminan mediante filtros estadísticos o geométricos. Estos pueden ser causados por reflejos de pájaros, aviones o señales perdidas.

## 2.2 Eliminación de puntos aislados

Los puntos aislados, aquellos que no tienen vecinos cercanos dentro de un radio definido, a menudo son indicativos de ruido o retornos erróneos. Su eliminación garantiza un conjunto de datos más limpio y denso con un mejor comportamiento de interpolación.

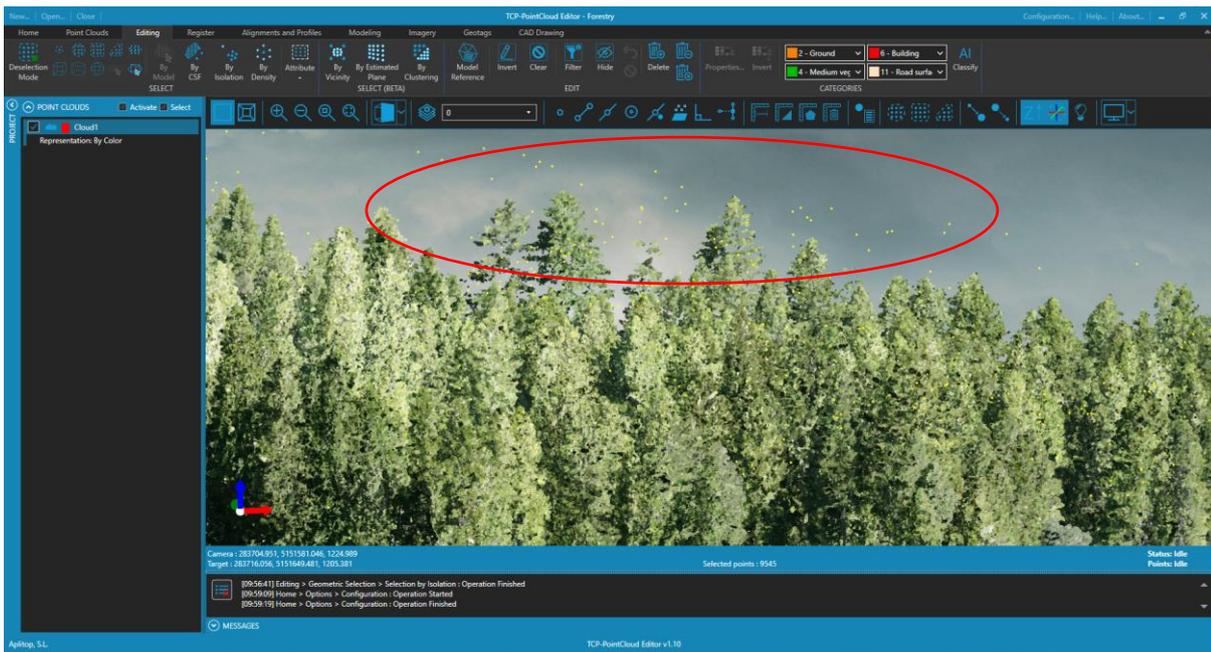


Figura 2. Filtro de puntos aislados

## 2.3 Filtrado por tipos de retorno

Los pulsos LiDAR pueden tener múltiples retornos, que se almacenan como atributos adicionales de la nube de puntos. Si el objetivo principal es extraer el terreno, opcionalmente podemos descartar los puntos que se correspondan con el primero de muchos o intermedios.

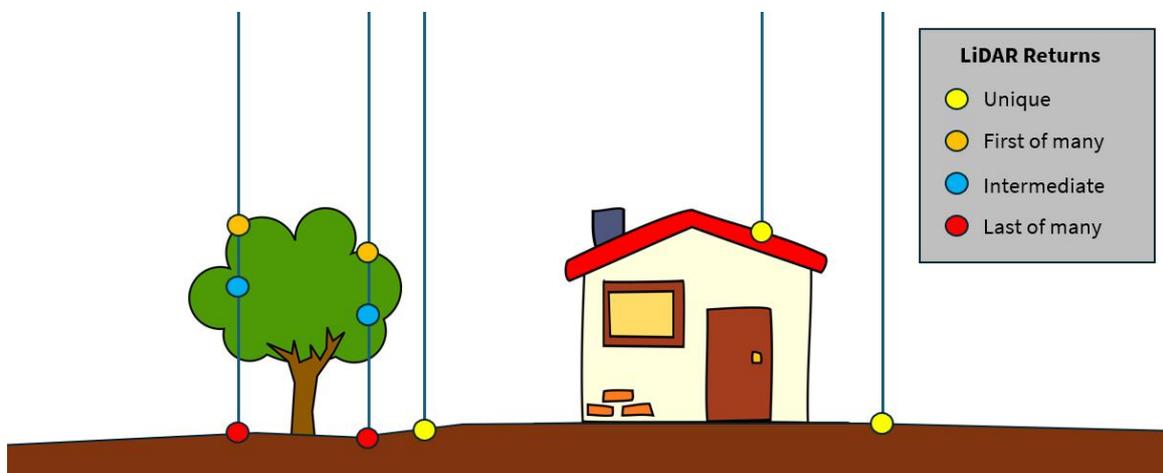


Figura 3. Retornos LiDAR

### 3. Clasificación de puntos

Después de la limpieza, obtenemos la nube de puntos filtrada, lista para la clasificación por categorías.

Existen muchas técnicas y algoritmos para la clasificación, que podemos agrupar en basados en heurísticos, segmentación geométrica, basados en Machine Learning o Deep Learning. A continuación mencionaremos un método tradicional y otro basado en modelos entrenados mediante Inteligencia Artificial.

#### 3.1 Clasificación por método tradicional

El método Cloth Simulation Filter (CSF), introducido por Zhang et al. (2016), consiste en invertir la nube de puntos y simular una tela flexible que la cubre. Los puntos de contacto entre la tela y la "superficie invertida" se consideran el suelo.

Los pasos de este método incluyen la selección de puntos que no definen el terreno, en función de los umbrales de curvatura y pendiente. Si posteriormente invertimos la selección, obtendremos solo los puntos de terreno, a los que asignaremos la categoría correspondiente.

Este algoritmo es eficiente, interpretable y especialmente útil para terrenos con cambios de elevación graduales.

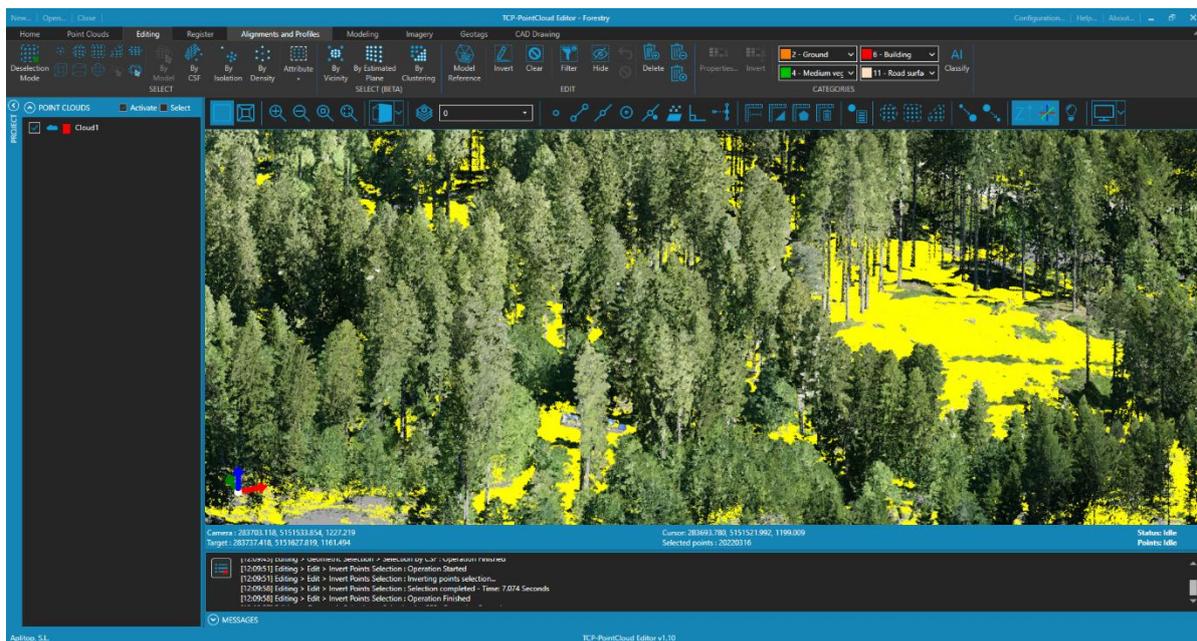


Figura 4. Puntos de terreno obtenidos tras invertir la selección por CSF

#### 3.2 Clasificación potenciada por IA

La Inteligencia Artificial (IA) ofrece poderosas alternativas a la clasificación tradicional basada en reglas. Este método de clasificación utiliza una arquitectura de redes neuronales convolucionales diseñada específicamente para trabajar directamente con nubes de puntos 3D sin necesidad de transformarlas en vóxeles ni en mallas.

En este caso, se ha entrenado previamente un modelo para escenas exteriores, diferenciando entre terreno, edificaciones, vegetación, vehículos, vallas, etc. que se ha aplicado a la nube completa. Los puntos de otras categorías pueden ser ocultados para examinar el resultado en detalle.

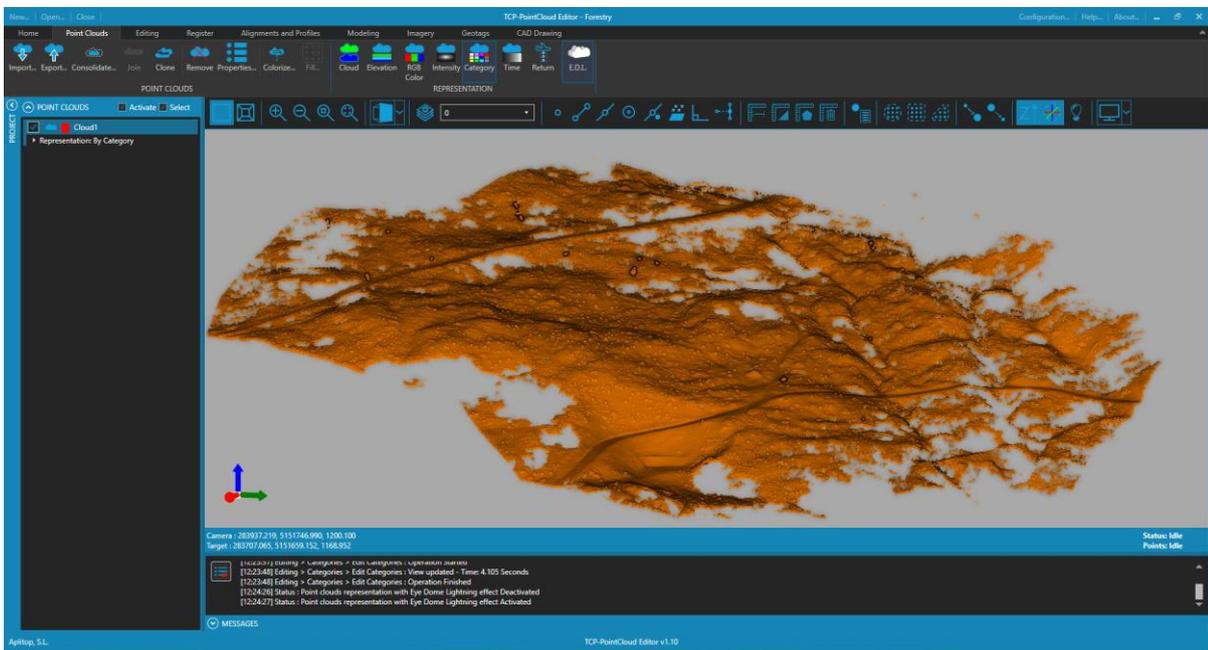


Figura 5. Puntos de la categoría terreno obtenidos mediante clasificación potenciada por IA

Esta técnica ha demostrado ser especialmente eficaz para tareas de segmentación semántica en entornos complejos como escenas urbanas o zonas con vegetación densa, manteniendo una alta precisión con una arquitectura flexible y extensible.

### 3.3 Edición manual

Ambos métodos de clasificación pueden dar lugar a clasificaciones erróneas, especialmente en zonas de transición o áreas ocluidas. Por lo tanto, una etapa de edición manual es conveniente para corregir los errores de clasificación, lo que garantiza un modelado posterior preciso.

Si el software empleado ofrece herramientas de selección avanzada basadas en vecindad o agrupamiento, puede reducirse en gran medida el tiempo de edición.

## 4. Generación del MDT

Una vez aislados los puntos de terreno, a partir de éstos se genera el Modelo Digital del Terreno, representado como una red irregular de triángulos (TIN) o una malla regular.

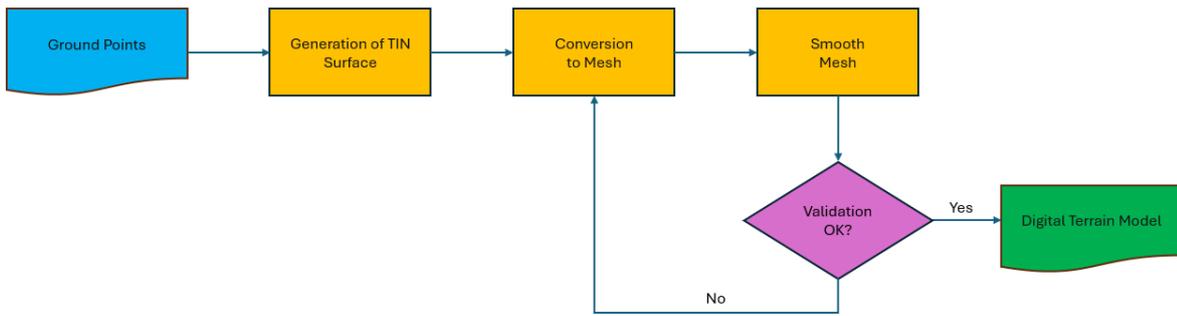


Figura 6. Diagrama de flujo para generación del Modelo Digital del Terreno

#### 4.1 Generación de superficie TIN

Para mejorar la fidelidad del resultado, se recomienda generar inicialmente una superficie TIN a partir de los puntos del terreno, eligiendo bien los valores de longitudes mínima y máxima de triángulos y añadiendo líneas de rotura, si existen.

Si se detectan picos en la superficie, es posible que sea debido a puntos que se han clasificado erróneamente, que se solucionaría con un borrado o reclasificación parcial.

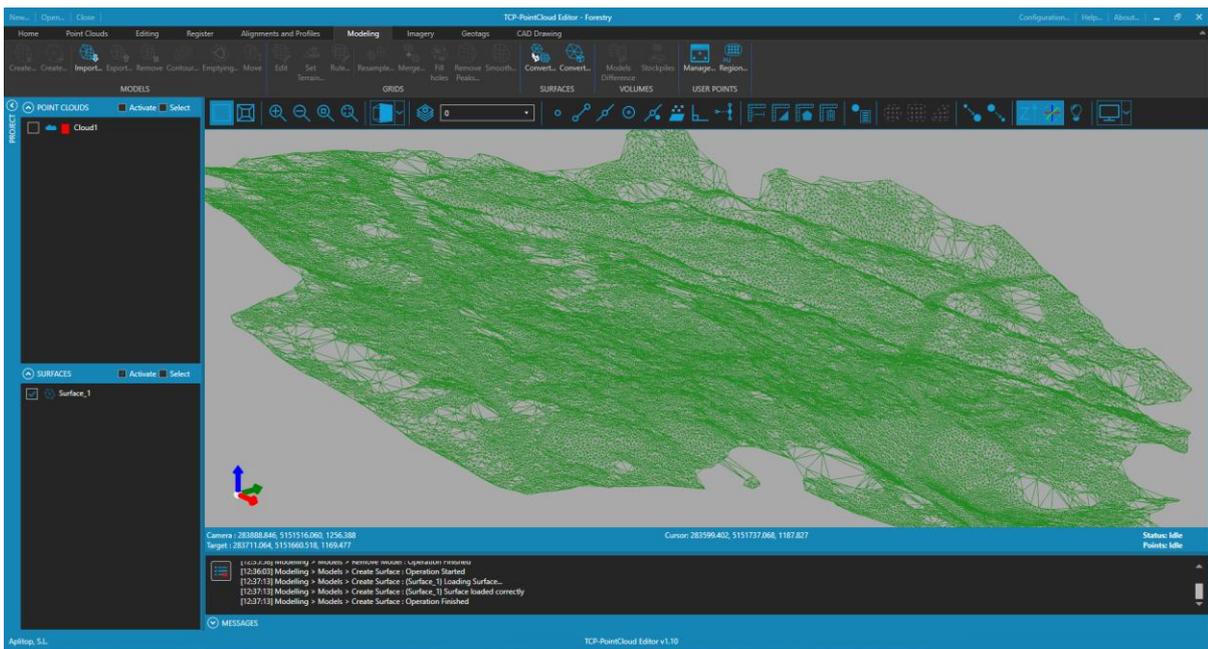


Figura 7. TIN generado a partir de los puntos de terreno

#### 4.2 Conversión a malla

A continuación, el TIN se convierte en una malla regular, con el tamaño idóneo de celda.

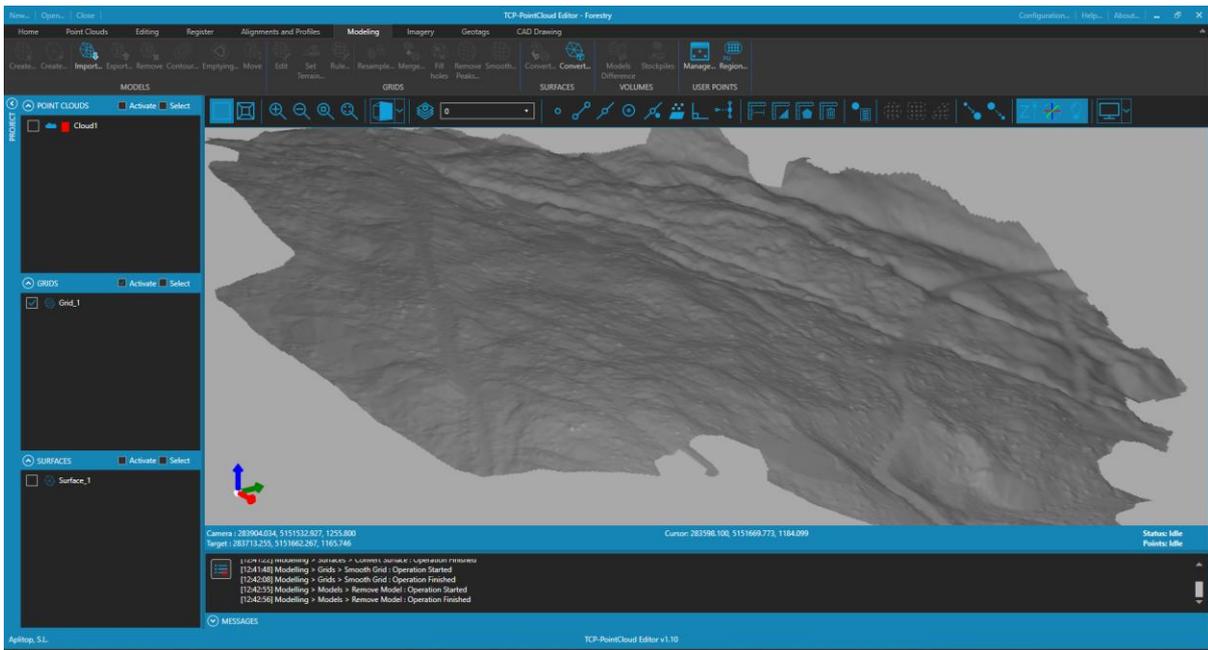


Figura 8. Malla regular generada a partir del TIN

### 4.3 Suavizado de malla

Por último, la malla se suaviza para reducir las transiciones bruscas o el ruido introducido durante la triangulación, lo que da como resultado un modelo visual sin irregularidades y topológicamente continuo.

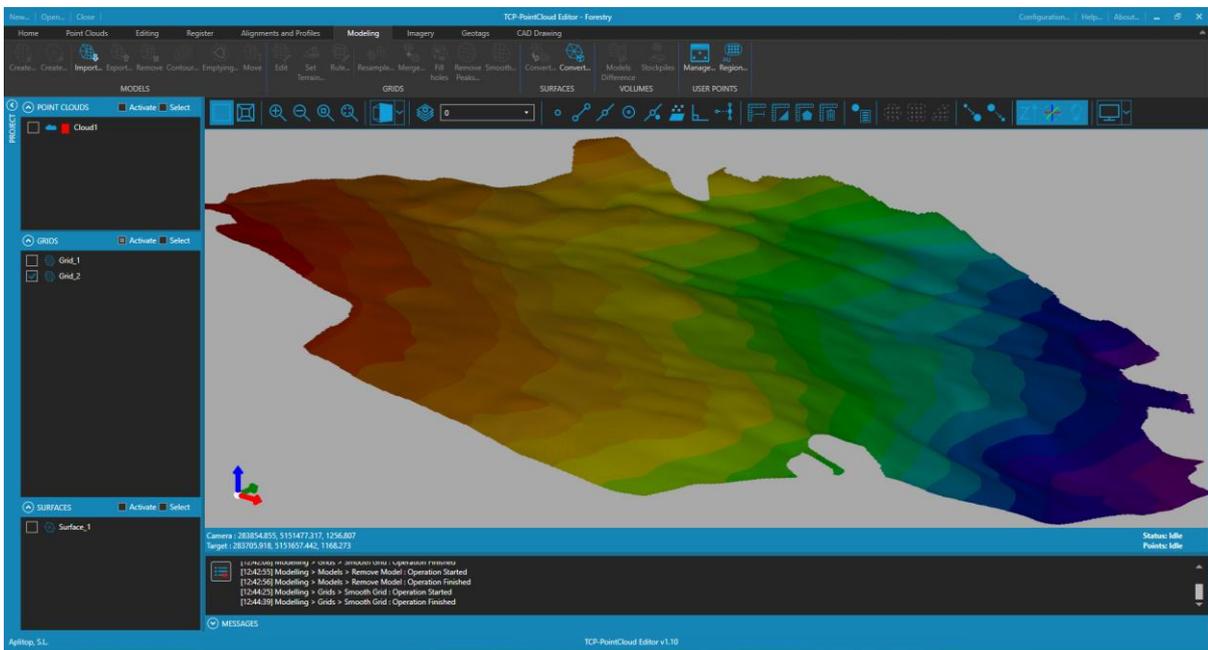


Figura 9. Malla suavizada representada por elevación

## 5. Validación

Antes de dar por finalizado el MDT, es altamente recomendable evaluar su calidad.

Entre las posibles opciones, pueden generarse las curvas de nivel para inspeccionar visualmente anomalías. También puede ser útil realizar perfiles y comparar las cotas de la superficie TIN, malla original y malla suavizada con las de los puntos originales.

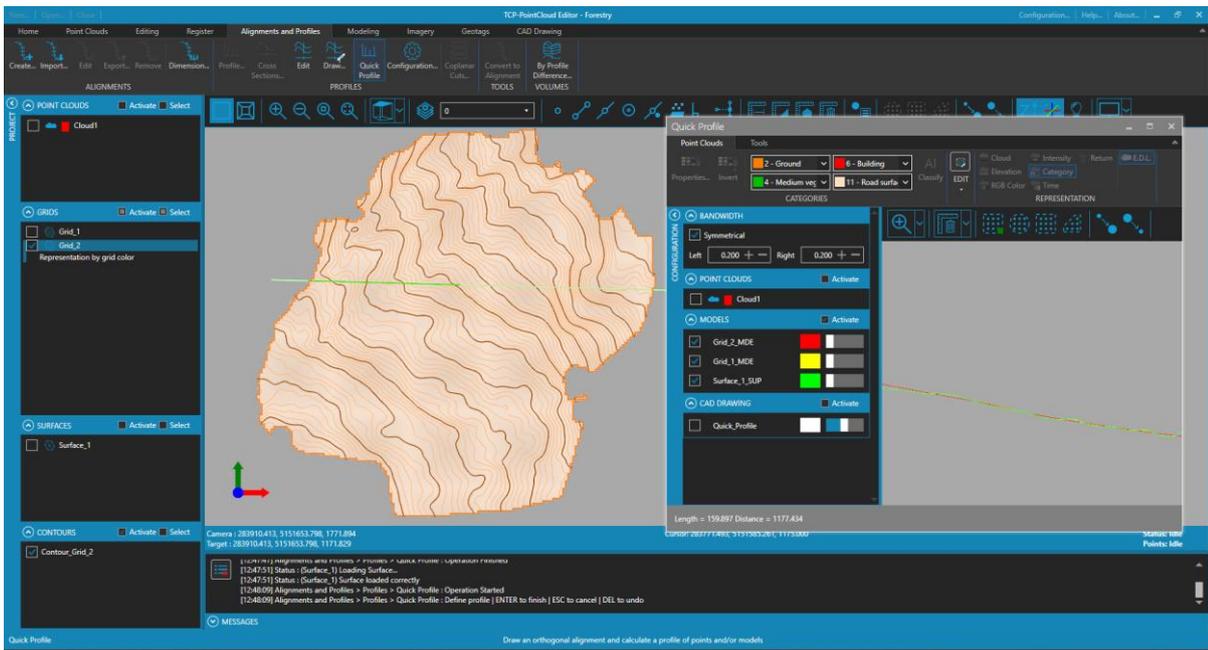


Figura 10. Curvas de nivel y comparación de perfiles

Si el resultado no es satisfactorio, se repetiría la edición manual de la clasificación y volvería a generar el DTM con los datos de entrada corregidos. Este refinamiento iterativo garantiza que el producto final cumpla con los estándares de calidad esperados.

## Conclusión

La transformación de datos LiDAR sin procesar a un modelo digital preciso del terreno es un proceso de varias fases, que requiere una cuidadosa atención a los detalles. Cada etapa (limpieza, clasificación, modelado y validación) contribuye a la fidelidad geométrica y la usabilidad del MDT final.

Comprender este flujo de trabajo es esencial para los profesionales de las ciencias geoespaciales, la ingeniería civil y el análisis ambiental. Ya sea utilizando enfoques basados en reglas o aprovechando los métodos potenciados por la IA, el objetivo sigue siendo el mismo: representar el terreno con la mayor precisión que permitan los datos.