




UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

Redes Neuronales para la Segmentación Inteligente de Nubes de Puntos en la Región Mediterránea del Sureste Peninsular

Alejandro Diéguez López, Pablo Crespo Peremarch, Valery Naranjo Ornedo



ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA

Introducción

El etiquetado manual de **nubes de puntos LiDAR** es un proceso tedioso y exigente debido al gran volumen de datos, lo que evidencia la necesidad de automatizarlo.

Para llevar a cabo esta automatización se pueden emplear técnicas de **aprendizaje profundo** con el fin de conseguir un etiquetado más preciso que con los métodos semiautomáticos actuales.

Metodología

A partir de los datos de la segunda cobertura del **PNOA-LiDAR**, se efectuó una selección de teselas que contuviesen una variabilidad de clases y formasen un número representativo para el entrenamiento y evaluación del modelo. Para el etiquetado de clases, se utilizaron como referencia los datos del **SIOSE**, junto con los propios datos del **PNOA-LiDAR** y un proceso adicional de **fotointerpretación** para mejorar la precisión de ciertas clases. Posteriormente, se llevó a cabo la **división del conjunto de datos y su balanceo** para garantizar una representación adecuada de todas las clases.

Sobre este conjunto de datos se implementaron tres arquitecturas de segmentación de nubes de puntos: **PointNet**, **RandLA-Net** y **KPConv**, con el objetivo de evaluar su rendimiento en la **segmentación de nubes LiDAR** en la zona del sureste peninsular. En el caso de **KPConv**, se aplicó un proceso de **postprocesado** con el fin de refinar los resultados obtenidos. Finalmente, se realizó un **análisis comparativo** entre los diferentes resultados obtenidos para determinar cuál ofreció un mejor desempeño en la tarea propuesta.




Figura 1. Diagrama de flujo metodológico. Fuente: elaboración propia.

Conclusión

Se cumplieron los tres objetivos iniciales. En cuanto al primero, se generó un conjunto de datos 3D propio para la zona sureste peninsular, corrigiendo su etiquetado. Para el segundo, se llevó a cabo una comparación entre las arquitecturas **KPConv**, **PointNet** y **RandLANet**, observándose que la red con mejor rendimiento fue **KPConv**. Por último, para el tercer objetivo, se aplicó un proceso de **postprocesado** que permitió mejorar los resultados de segmentación obtenidos con la red KPConv.

Como posibles mejoras futuras mejoras se destaca, la creación de un conjunto de datos propio, completamente revisado y anotado manualmente, con el objetivo de eliminar errores de etiquetado y reducir los sesgos en los datos de entrada.

Por otra parte, la utilización de datos LiDAR más recientes, como los correspondientes a la tercera cobertura del proyecto PNOA-LiDAR, que presenta una mayor densidad de puntos que la segunda cobertura empleada en este trabajo.

Objetivo

Creación de un **conjunto de datos 3D** propio para la zona sureste peninsular, utilizando datos LiDAR públicos y corrigiendo su etiquetado mediante diferentes métodos.

Comparación entre diferentes algoritmos de segmentación de **nubes de puntos LiDAR** basados en **aprendizaje profundo** como son **PointNet** [1], **RandLA-Net** [2] y **KPConv** [3].

Implementación de **postproceso** basado en la aplicación de un **árbol de decisión** y **reglas manuales**, y su comparación con los resultados del modelo basado en aprendizaje profundo.

Resultados

Las arquitecturas **PointNet** y **RandLA-Net** obtuvieron resultados limitados, por lo que se decidió descartar dichas implementaciones. Por el contrario, la red **KPConv** fue la que mostró un mejor rendimiento. Además, sus resultados mejoraron aún más tras aplicar el proceso de **postprocesado**. En la Figura 2 se presenta un ejemplo correspondiente a la partición de test, y en la Tabla 1 se muestran los resultados del modelo evaluados mediante el índice **IoU**.




Figura 2. Resultado de la red KPConv. Fuente: elaboración propia.

Clase	IoU		Diferencia
	Sin postprocesado	Con postprocesado	
Suelo	0,355	0,355	0,000
Edificio	0,741	0,861	+0,120
Ruido	0,030	0,033	+0,003
Agua	0,343	0,843	+0,500
Aerogenerador	0,415	0,556	+0,141
Torre eléctrica	0,000	0,295	+0,295
Cable eléctrico	0,381	0,404	+0,023
Vías	0,806	0,896	+0,090
Puente	0,000	0,161	+0,161
Placas solares	0,816	0,918	+0,102
Ferrocarril	0,000	0,281	+0,281
Invernadero	0,931	0,921	-0,010
Vegetación	0,434	0,433	-0,001

Tabla 1. Comparativa de los resultados obtenidos aplicando el modelo **KPConv** con y sin aplicar el **postprocesado**.

Observando la Tabla 1, donde se muestra el índice **IoU** por clase, podemos afirmar que la **segmentación** obtenida fue **correcta** para algunas clases como: **invernadero** o **vías**, pero también reveló **limitaciones** en otras como **ruido** o **puentes**.

Referencias

- [1] Charles R. Qi, Hao Su, Kaichun Mo, and Leonidas J. Guibas. Pointnet: Deep learning on point sets for 3d classification and segmentation, 2017. URL <https://arxiv.org/abs/1612.00593>.
- [2] Qingyong Hu, Bo Yang, Linhai Xie, Stefano Rosa, Yulan Guo, Zhihua Wang, Niki Trigoni, and Andrew Markham. Randla-net: Efficient semantic segmentation of large-scale point clouds, 2020. URL <https://arxiv.org/abs/1911.11236>.
- [3] Hugues Thomas, Charles R. Qi, Jean-Emmanuel Deschaud, Beatriz Marcotegui, François Goulette, and Leonidas J. Guibas. Kpconv: Flexible and deformable convolution for point clouds, 2019. URL <https://arxiv.org/abs/1904.08889>.