Tecniche di *deep learning* per la segmentazione semantica di nuvole di punti del patrimonio architettonico

Matrone F. [1[0000-0002-9160-1674]] , Lingua A. [1[0000-0002-5930-2711]]

[1] Dipartimento di Ingegneria dell'Ambiente, del Territorio e delle Infrastrutture (DIATI), Politecnico di Torino, Corso Duca degli Abruzzi 24, 10129 Torino - Italy

Abstract

I recenti sviluppi tecnologici dei *Mobile Mapping System* (MMS) e il crescente utilizzo di Sistemi Aeromobili a Pilotaggio Remoto (SAPR), per il rilievo in ambito urbano o architettonico, contribuiscono alla generazione di notevoli quantità di dati 2D e 3D. La gestione, l'elaborazione e l'interpretazione semantica di tali dati, in particolare le nuvole di punti, sta quindi acquisendo sempre più importanza. La ricerca qui presentata ha come obiettivo principale l'individuazione di una modalità automatica per la gestione di queste nuvole di punti, al fine di velocizzarne la successiva modellazione in ambiente BIM. Per fare ciò, sono state utilizzate tecniche di *deep learning* che consentissero di identificare automaticamente gli elementi architettonici all'interno delle nuvole di punti (segmentazione semantica).

Dapprima è stato quindi creato un dataset *ad hoc* [1], messo a disposizione della comunità scientifica, per l'addestramento delle reti neurali (vedi Fig. 1) e, successivamente, è stata selezionata una specifica rete neurale profonda, la DGCNN – *Dynamic Graph Convolutional Neural Network* [2], da implementare.

Fig. 1. Esempio di nuvole di punti dell'ArCH (*Architectural Cultural Heritage*) dataset.

Le prime fasi della ricerca si sono concentrate sull'individuazione della miglior configurazione di iperparametri per la rete (RGB vs. HSV, metodo di sottocampionamento, dimensioni dei blocchi, numero di punti, ecc). È stata quindi scelta una nuvola di punti simmetrica, suddivisa in due metà. Questo ha permesso di

utilizzarne un lato per l'addestramento/validazione e l'altro per il test. Una volta selezionati i migliori iperparametri, alcune tra le configurazioni che hanno garantito le metriche più alte sono state testate su parte dell'ArCH dataset. In questo caso, più scene hanno costituito il dataset per l'addestramento, mentre una scena mai vista dalla rete è stata utilizzata come test. Questo metodo è stato poi confrontato con un approccio simile di *machine learning* già presente in letteratura [3, 4] ed è stata anche studiata la possibilità di rendere l'intero processo accessibile a utenti non esperti attraverso un approccio di *transfer learning*. Infine, sono stati svolti alcuni test specifici per cercare di capire le modalità di apprendimento della DGCNN, facendo riferimento all'intelligenza artificiale "spiegabile" (*eXplainable AI*) [5, 6].
I risultati del metodo qui proposto hanno consentito di: i) aumentare il livello di dettaglio della segmentazione semantica di nuvole di punti di beni culturali in ambito *deep learning*, ii) passare da un iniziale 56% di *Overall Accuracy* a un finale di 86% (vedi Fig. 2), raggiungendo lo stato dell'arte di approcci più comuni come il Random Forest, iii) ridurre il tempo computazionale per future applicazioni, rendendo disponibile un set di pesi dalla rete già addestrata, iv) definire un nuovo approccio per la velocizzazione del processo *scan-to-BIM*.

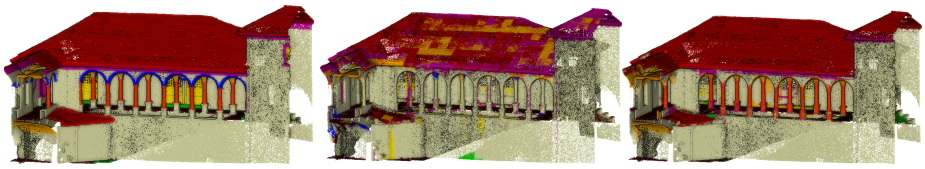

Fig. 2. A sinistra la nuvola di punti di riferimento (*ground truth*), al centro quella predetta nelle prime fasi di test con 0,56% di OA e a destra quella finale con 0,86% di OA.

Riferimenti bibliografici

1. Matrone, F., Lingua, A., Pierdicca, R., Malinverni, E.S., Paolanti, M., Grilli, E., Remondino, F., Murtiyoso, A., Landes, A.: A benchmark for large-sclae heritage point cloud semantic segmentation. Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLIII-B2-2020, 1419–1426 (2020).
2. Wang, Y., Sun, Y., Liu, Z., Sarma, S., Bronstein, M., Solomon, J.: Dynamic Graph CNN for Learning on Point Clouds (2018) arXiv:1801.07829v2.
3. Grilli, E., Remondino, F.: Classification of 3D Digital Heritage. Remote Sensing, *11*(7), 847 (2019). https://doi.org/10.3390/rs11070847
4. Grilli, E., Remondino, F.: Machine learning generalisation across different 3D architectural heritage. ISPRS Int J Geo-Information *9*(6), 379 (2020). https://doi.org/10.3390/ijgi9060379
5. Xie, N., Ras, G., van Gerven, M., Doran, D.: Explainable deep learning: A field guide for the uninitiated (2020). arXiv:2004.14545v1
6. Gilpin, L.H., Bau, D., Yuan, B.Z., Bajwa, A., Specter, M., Kagal, L.: Explaining explanations: An overview of interpretability of machine learning. In: Proc - 2018 IEEE 5th Int Conf Data Sci Adv Anal DSAA 2018 80–89 (2019).