

GeoAI per la Classificazione di Dati SLAM: il Caso Studio della Casetta Gotica di Udine

Antonio Matellon^{1,2,*}, Eleonora Maset¹, Alberto Beinat¹, Domenico Visintini¹

¹ Dipartimento Politecnico di Ingegneria e Architettura (DPIA), Università degli Studi di Udine, 33100 Udine, Italia
matellon.antonio@spes.uniud.it; (eleonora.maset, alberto.beinat, domenico.visintini)@uniud.it

² Dipartimento di Ingegneria e Architettura (DIA), Università degli Studi di Trieste, 34127 Trieste, Italia

Keywords: Classificazione Gerarchica, Machine Learning, SLAM, Nuvole di Punti, Scan-to-BIM

1. Introduzione

I sistemi laser scanner portatili basati su tecnologia SLAM (*Simultaneous Localization and Mapping*) stanno rivoluzionando l'acquisizione dei dati tridimensionali, offrendo, grazie alla loro portabilità, una valida alternativa ai tradizionali laser scanner terrestri (TLS) e consentendo rilievi efficienti, continui e accurati in ambienti complessi o difficilmente accessibili (Matellon et al., 2024). Queste caratteristiche rendono i sistemi SLAM sempre più rilevanti anche nel processo scan-to-BIM, dove la rapidità di acquisizione deve essere accompagnata da una gestione automatizzata ed efficace delle fasi successive. Tra queste, un ruolo chiave è svolto dalla classificazione (segmentazione semantica) delle nuvole di punti, che consente di organizzare le informazioni geometriche in categorie coerenti e funzionali per la modellazione parametrica.

Nonostante i recenti progressi dell'intelligenza artificiale applicata ai dati geospaziali (GeoAI), la maggior parte degli algoritmi di classificazione basati su Machine Learning (ML) e Deep Learning (DL) viene tuttora applicata principalmente a dati TLS o fotogrammetrici (Matrone et al., 2020a; Matrone et al., 2020b), mentre le nuvole di punti SLAM risultano ancora poco investigate in questo ambito. Tuttavia, la crescente diffusione di questi sistemi richiede lo sviluppo di approcci specificamente adattati alle loro peculiarità, quali la maggiore rumorosità e la densità irregolare. Inoltre, in contesti architettonici complessi, la segmentazione simultanea di tutte le classi può generare ambiguità tra categorie morfologicamente simili. Un approccio gerarchico, basato su una classificazione che procede per livelli semantici progressivi, potrebbe superare tali criticità: le macro-categorie vengono identificate per prime, seguite dalle sottoclassi, riducendo così la confusione tra elementi adiacenti e rispecchiando la struttura multi-livello dell'ambiente costruito. Approcci gerarchici sono già stati adottati con successo ai fini della segmentazione semantica di nuvole di punti 3D (Grilli et al., 2020), nel flusso di lavoro scan-to-HBIM (Ceccarelli et al., 2023) e per la classificazione di dati da laser scanning aereo (Macaulay et al., 2024). Il presente lavoro esplora quindi il potenziale della classificazione gerarchica applicata a nuvole di punti SLAM e ne confronta le prestazioni con quelle ottenute su dati TLS di riferimento.

2. Materiali e metodi

La "Casetta Gotica" di Udine (Friuli Venezia Giulia, Italia), edificio trecentesco in stile gotico-veneziano caratterizzato da geometrie complesse e forme irregolari, costituisce un caso studio ideale e impegnativo per la valutazione di approcci di classificazione gerarchica su nuvole di punti. Il rilievo è stato condotto impiegando il sistema SLAM Stonex X120^{GO} (Stonex, 2025), caratterizzato da una testa rotante in grado di acquisire fino a 320,000 pts/s, una portata massima di 120 m e un'accuratezza relativa di circa 6 mm. Ai fini del confronto, è stato eseguito anche un rilievo TLS con lo strumento Leica

BLK360 G1. I due dataset sono stati sottoposti a una fase di pre-elaborazione comprendente la rimozione del rumore e il sottocampionamento, quindi allineati in un sistema di riferimento comune. Per la definizione del *ground truth*, indispensabile per l'addestramento e la valutazione dell'algoritmo di classificazione, i dataset sono stati infine annotati manualmente secondo le classi illustrate in Fig. 1.

La metodologia di classificazione è stata sviluppata all'interno del *framework* 3DMASC (Letard et al., 2024), basato sull'algoritmo *Random Forest* di ML. Per ciascun punto sono state calcolate *features* geometriche multi-scala, derivate dalla matrice di covarianza locale, in grado di descrivere le proprietà morfologiche dell'intorno tridimensionale. In una prima fase, la classificazione è stata eseguita in un'unica iterazione (approccio standard), considerando contemporaneamente tutte le classi definite nel *ground truth*. Successivamente, è stato testato un approccio di classificazione gerarchica, strutturato su due livelli semantici. Nel primo livello, la scena è stata classificata in macro-classi comprendenti *pavimenti, porte/finestre, pareti, scale, tetto, altro*, mentre nel secondo livello alcune macro-classi — in particolare *scale* e *tetto* — sono state ulteriormente scomposte in sottoclassi di dettaglio: rispettivamente *gradini, scala strutturale, parapetto e travi, travetti, tavelle, altro-tetto*. La metodologia proposta è stata inizialmente applicata al dataset SLAM, per poi essere replicata sul dataset TLS. In entrambi i casi, le nuvole di punti etichettate sono state suddivise in set di addestramento e di test (Tab. 1).

3. Risultati e discussioni

I risultati in Tab. 2 mostrano che, in tutti i test, i valori di *Overall Accuracy* superano l'86%. Per entrambi i dataset (SLAM e TLS), le differenze tra approccio standard e gerarchico sono trascurabili, suggerendo che, nel caso studio analizzato — complesso ma di dimensioni contenute — un unico step di classificazione può essere equivalente a una strategia gerarchica. Per scenari più estesi, invece, una classificazione a più livelli potrebbe rivelarsi più efficace. L'accuratezza sul dato SLAM risulta leggermente inferiore rispetto a quella della nuvola di punti da TLS (86.8% vs 89.6% nel caso gerarchico), ma tali valori dimostrano come sia comunque possibile ottenere buoni risultati, nonostante la maggiore rumorosità e la densità meno uniforme. Le matrici di confusione (Fig. 2) confermano che le prestazioni sono coerenti tra dato SLAM e TLS e tra approccio standard e gerarchico, indicando che il maggior rumore del dato SLAM non compromette significativamente la classificazione. Nonostante i risultati positivi, l'approccio adottato rimane ancorato a tecniche di ML tradizionale, mentre l'attuale evoluzione della GeoAI apre numerose prospettive di sviluppo. Questo studio costituisce quindi un primo benchmark su dati SLAM per la classificazione semantica architettonica, che potrà essere ampliato integrando algoritmi GeoAI di nuova generazione, tra cui modelli di Deep Learning 3D, e dataset più estesi e diversificati.

Figure e tabelle




Figura 1. Porzione della nuvola di punti SLAM classificata, utilizzata come *ground truth* e ottenuta da annotazione manuale.

Parapetto	45	476	2024	1	0	0	0	0	1479	1015	41902
Scala strutturale	1869	503	4934	3	109	0	0	0	3183	43684	918
Gradini	6220	181	2348	3	511	0	0	0	59757	740	2787
Altro tetto	1	14	8754	16	1448	439	247	3341	0	0	90
Tavelle	407	204	1466	515	6566	8530	170255	436	1	0	2
Travetti	178	401	3025	79	9582	81051	11609	301	2	0	18
Travi	2529	5543	27872	718	131707	8983	25486	348	1070	6	1447
Altro	5290	12173	21735	12864	2527	180	85	115	1014	68	212
Pareti	15561	56906	1986060	660	3842	223	993	21	2455	732	7844
Porte/Finestre	5831	178566	235217	425	309	76	307	0	124	1	13884
Pavimenti	1143232	5188	18006	219	357	24	156	0	2416	397	243

(a) SLAM – approccio standard.

Parapetto	31	261	1866	1	52	0	0	5	1377	1003	42346
Scala strutturale	1002	105	2414	0	323	1	238	0	4236	45454	1430
Gradini	4342	15	805	0	778	0	1	0	61273	2011	3322
Altro tetto	0	11	7055	0	2558	444	358	3546	0	0	378
Tavelle	107	155	478	93	8904	8859	169323	546	4	0	13
Travetti	46	255	1186	21	12075	80909	11362	328	7	0	57
Travi	428	3801	20412	138	141714	10101	26428	395	202	73	2017
Altro	5085	11547	20031	12073	3791	1	18	217	1673	961	866
Pareti	13786	57743	1965656	566	8612	602	3223	287	8611	3955	12256
Porte/Finestre	5428	182007	230026	399	633	108	488	0	306	83	15262
Pavimenti	1139553	5078	17507	225	1428	3	764	0	4623	476	581

(b) SLAM – approccio gerarchico.

Parapetto	130	19	449	4	0	0	0	0	648	312	15984
Scala strutturale	1286	7	1443	21	0	0	0	0	1194	31986	276
Gradini	2219	2	729	59	1	0	0	0	31452	114	789
Altro tetto	0	0	387	0	34	0	0	0	893	0	0
Tavelle	1110	215	1703	7	2574	6088	88793	70	21	0	1
Travetti	313	883	1856	48	7419	43775	4874	180	155	0	198
Travi	4048	4062	11073	432	55626	4883	17464	68	1022	11	1691
Altro	4918	4339	11796	10979	206	122	429	0	557	7	234
Pareti	10939	15885	1398507	2527	2275	83	248	0	4084	1097	3048
Porte/Finestre	5147	52578	118662	940	270	57	110	0	502	15	4878
Pavimenti	609371	92	10793	153	32	3	30	0	3216	521	320

(c) TLS – approccio standard.

Parapetto	38	33	165	1	25	0	0	0	530	286	16468
Scala strutturale	854	0	631	8	26	0	54	0	913	33272	455
Gradini	1576	0	412	1	4	3	0	0	32175	148	1046
Altro tetto	0	0	29	0	63	0	0	0	1222	0	0
Tavelle	138	95	613	0	6004	5906	87714	86	1	0	25
Travetti	25	622	1009	9	10524	42648	4502	134	7	0	221
Travi	1272	2861	8999	54	64358	4075	17319	92	58	4	1288
Altro	4746	4261	11196	9692	1234	56	409	0	940	134	919
Pareti	10474	13981	1330352	2271	3852	181	557	0	5891	4526	6608
Porte/Finestre	4811	49415	116663	755	520	173	177	0	652	1142	8851
Pavimenti	698288	61	10596	106	337	7	72	0	3864	1517	691

(d) TLS – approccio gerarchico.

Figura 2. Matrici di confusione degli esperimenti eseguiti.

Dataset	n. features calcolate	Set di addestramento n. punti - %	Set di test n. punti - %
SLAM	146	1,776,623 - 28%	4,425,917 - 72%
TLS	149	891,786 - 24%	2,862,071 - 76%

Tabella 1. Nuvole di punti SLAM e TLS: principali caratteristiche.

Prova	OA	Valore medio			Valore medio pesato		
		Prec	Rec	F1	Prec	Rec	F1
SLAM – standard	0.870	0.811	0.693	0.717	0.864	0.870	0.859
SLAM – gerarchico	0.868	0.782	0.702	0.706	0.864	0.868	0.858
TLS – standard	0.898	0.787	0.737	0.741	0.889	0.898	0.886
TLS – gerarchico	0.896	0.766	0.766	0.738	0.890	0.896	0.885

Tabella 2. Metriche di classificazione (Overall Accuracy, Precision, Recall e F1-Score): valori medi e medi pesati sul numero di punti.

Riferimenti bibliografici

Ceccarelli, L., Bevilacqua, M. G., Caroti, G., Castiglia, R. B., Croce, V., 2023. Semantic segmentation through Artificial Intelligence from raw point clouds to H-BIM representation. *Disegnarecon*, 16(30), 17-1.

Grilli, E., Teruggi, S., Fassi, F., Remondino, F., Russo, M. et al., 2020. Approccio gerarchico di machine learning per la segmentazione semantica di nuvole di punti 3D. *Bollettino della società italiana di fotogrammetria e topografia*, 2, 1-9.

Letard, M., Lague, D., Le Guennec, A., Lefèvre, S., Feldmann, B., Leroy, P., Girardeau-Montaut, D., Corpetti, T., 2024. 3DMASC: Accessible, explainable 3D point clouds classification. Application to Bi-spectral Topo-bathymetric lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 207, 175-197.

Macaulay, S. O., Maset, E., Fusiello, A., 2024. Classification of compressed full-waveform airborne lidar data. *Remote Sensing Letters*, 15(7), 729-738.

Matellon, A., Maset, E., Beinat, A., Visintini, D., 2024. Surface reconstruction from SLAM-based point clouds: Results from the datasets of the 2023 SIFET benchmark. *Remote Sensing*, 16(18), 3439.

Matrone, F., Grilli, E., Martini, M., Paolanti, M., Pierdicca, R., Remondino, F., 2020a. Comparing machine and deep learning methods for large 3D heritage semantic segmentation. *ISPRS International Journal of Geo-Information*, 9(9), 535.

Matrone, F., Lingua, A., Pierdicca, R., Malinverni, E. S., Paolanti, M., Grilli, E., Remondino, F., Murtiyoso, A., Landes, T., 2020b. A benchmark for large-scale heritage point cloud semantic segmentation. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 1419-1426.

Stonex, 2025. X120^{GO} SLAM Laser Scanner. Disponibile online: <https://www.stonex.it/project/x120go-slam-laser-scanner/> (accesso in data 2 dicembre 2025).