

APPROCCIO GERARCHICO DI MACHINE LEARNING PER LA SEGMENTAZIONE SEMANTICA DI NUVOLE DI PUNTI 3D

A HIERARCHICAL MACHINE LEARNING APPROACH FOR POINT CLOUD SEGMENTATION

Eleonora Grilli^a, Simone Teruggi^b, Michele Russo^c, Francesco Fassi^b, Fabio Remondino^a

^a 3D Optical Metrology (3DOM) unit, Bruno Kessler Foundation (FBK), Via Sommarive 18, 38121 Trento, Italy; grilli@fbk.eu (E.G.), remondino@fbk.eu (F.R.)

^b 3DSurveyGroup – ABCLab – Politecnico di Milano, via Ponzio 31, 20133 Milano, Italy; simone.teruggi@polimi.it (S.T.), francesco.fassi@polimi.it (F.F.)

^c Department of History, Representation and Restoration of Architecture, Sapienza University of Rome, Rome, Italy Email: m.russo@uniroma1.it (M.R.)

PAROLE CHIAVE: nuvole di punti, classificazione, suddivisione gerarchica, machine learning

KEY WORDS: point cloud, classification, hierarchical segmentation, machine learning

RIASSUNTO

L'uso di dati 3D, nuvole di punti e mesh, per la documentazione, la valorizzazione e la visualizzazione del patrimonio è diventato sempre più diffuso. Ricchi di informazioni metriche, questi dati 3D soffrono la mancanza di informazioni strutturate quali la semantica e la gerarchia tra le parti. In questo contesto, l'introduzione di metodi automatici di classificazione può svolgere un ruolo essenziale per permettere un utilizzo reale di questi dati nelle operazioni di manutenzione e conservazione del bene culturale, agevolando un migliore utilizzo dei dati ai fini informativi e di analisi. In questo articolo viene presentato un innovativo approccio di classificazione multilivello e multi-risoluzione (MLMR). L'approccio MLMR proposto migliora il processo di apprendimento e ottimizza i risultati della classificazione 3D attraverso un concetto gerarchico. La procedura MLMR viene testata e valutata su due diversi datasets, complessi e di grandi dimensioni: l'Abbazia di Pomposa (Italia) e il Duomo di Milano (Italia). I risultati della classificazione mostrano l'affidabilità e la replicabilità del metodo sviluppato, permettendo l'identificazione di svariate classi architettoniche a diversi livelli di risoluzione geometrica.

ABSTRACT

The recent years saw an extensive use of 3D point cloud data for heritage documentation, valorisation, and visualisation. Although rich in metric quality, these 3D data lack structured information such as semantics and hierarchy between parts. In this context, the introduction of point cloud classification methods can play an essential role for better data usage, model definition, analysis, and conservation. The paper aims to extend a machine learning (ML) classification method with a multi-level and multi-resolution (MLMR) approach. The proposed MLMR approach improves the learning process and optimises 3D classification results through a hierarchical concept. The MLMR procedure is tested and evaluated on two large-scale and complex datasets: the Pomposa Abbey (Italy) and the Milan Cathedral (Italy). Classification results show the reliability and replicability of the developed method, allowing the identification of the necessary architectural classes at each geometric resolution.

1. INTRODUZIONE

La segmentazione semantica/classificazione di nuvole di punti è un passaggio cruciale nel trattamento dei dati rilevati. Essa può assumere un ruolo importante nel processo di definizione ed analisi dei dati 3D in forma discreta, usandoli nella pratica quotidiana manutentiva dei Beni Culturali e, più in generale, in tutte quelle operazioni legate alla conoscenza e al restauro della architettura. Il termine segmentazione semantica fa riferimento al raggruppamento in sottoinsiemi di dati simili (detti segmenti), i quali presentano caratteristiche/features, (geometriche, radiometriche, ecc.), attraverso le quali è possibile distinguere e identificare le diverse parti che compongono la nuvola di punti. La suddivisione semantica del dato 3D proveniente dal rilievo, può portare ad una gerarchizzazione del dato geometrico e radiometrico, che permette un uso diretto della nuvola di punti nel processo decisionale e di progetto (ad oggi molto limitato) ed è propedeutica alla fase di ricostruzione di modelli 3D

semplificati (CAD o BIM) e a alle classiche restituzioni 2D. Ciò a sua volta comporta una semplificazione nella lettura e una più semplice gestione dei dati acquisiti, accelerando la fase di interpretazione e di ricostruzione del dato vettoriale. Partendo direttamente dalla nuvola di punti classificata è possibile inoltre avviare un percorso di analisi finalizzato ad un incremento della conoscenza della architettura propedeutico alla progettazione di interventi manutentivi o conservativi, senza bisogno di ulteriori elaborazioni spesso dispendiose e complesse. In tal senso, la possibilità di individuare ed evidenziare a priori le principali componenti architettoniche consente una più facile lettura e comprensione da parte di un pubblico più ampio, incrementando la possibilità di interazione e il coinvolgimento in progetti che riguardano il costruito. Ma la capacità di poter separare, visualizzare e gestire separatamente elementi morfologicamente omogenei permette anche una più rapida analisi spaziale del manufatto, potendo effettuare studi sui singoli elementi, verificarne il dimensionamento e la collocazione nello spazio

secondo regole modulari, analizzando e confrontando gli elementi ricorrenti e le singolarità. Dal punto di vista dell'analisi statica del manufatto, la possibilità di estrarre e classificare separatamente gli elementi della nuvola consente di effettuare uno studio visivo fondato sull'astrazione degli elementi strutturali, preliminare ad una conseguente simulazione con sistemi FEM/FEA. Infine, la possibilità di tradurre questo sistema ordinato di informazioni geometriche in un abaco di modelli poligonali 3D offre l'opportunità di costruire un sistema al quale poter associare informazioni di carattere morfologico e materico, estremamente utile sia in caso di pianificazione conservativa che manutentiva dell'architettura. La possibilità di definire aree, volumi e masse, nel caso di materiali omogenei, permette di quantificare l'intero manufatto, producendo un computo metrico del bene culturale, ampliando la conoscenza di ogni singolo dettaglio e fornendo uno strumento molto utile per il progetto di restauro. Da questo risulta evidente l'utilità nel poter raggiungere in breve tempo la segmentazione semantica del dato 3D rilevato, soprattutto se si tratta di architetture articolate, poiché tale attività semplifica il complesso processo di conoscenza e manutenzione del bene culturale.

1.1 Scopo della ricerca

In questo articolo viene presentato e valutato un metodo di classificazione automatica, basato su un approccio multi-livello e multi-risoluzione (MLMR) combinato con un algoritmo di apprendimento automatico (Machine Learning). Il metodo MLMR classifica gerarchicamente i dati 3D a diverse risoluzioni geometriche per facilitare il processo di apprendimento e ottimizzare i risultati della classificazione. Per testare la metodologia sviluppata sono stati presi in considerazione due dataset complessi e di grande estensione, quali il Duomo di Milano e l'Abbazia di Pomposa. Entrambi i casi studio presentano grande diversità di geometrie e stili, ricchezza di decorazioni e mancanza di regolarità degli elementi architettonici. La scelta di due strutture architettoniche così diverse e complesse è volta a dimostrare l'applicabilità della metodologia a diversi scenari.

2. STATO DELL'ARTE

Nel campo del patrimonio architettonico, la necessità di strutturare e classificare i dati di rilievo 3D è stata sperimentata in diverse applicazioni come strumento di supporto dei processi scan-to-BIM (Rebolj et al., 2017; Son and Kim, 2017; Bassier and Yousefzadeh, 2020), di attività di monitoraggio e di restauro (Apollonio et al., 2018; Croce et al., 2020), pianificazione di opere di manutenzione (Sanchez et al., 2018; Valero et al., 2018; Roussel et al., 2019), o ancora rilevamento dei danni (Mizoguchi et al., 2013; Kashani and Graettinger, 2015).

Tuttavia, nella maggior parte dei casi, la suddivisione manuale dei dataset, oltre ad essere un intervento laborioso e dispendioso, porta con sé un grado elevato di soggettività e di non ripetibilità e di non riproducibilità del processo. Negli ultimi anni sono stati compiuti progressi rilevanti nei processi di classificazione automatica mediante l'utilizzo di metodi di Intelligenza Artificiale, Machine Learning (ML) e Deep Learning (DL), che, al contrario, sono oggettivi, replicabili e ripetibili. Le tecniche standard di ML supervisionato prevedono che gli algoritmi prendano come input alcune parti manualmente annotate della nuvola di punti, assieme alle cosiddette "features", attributi geometrici e/o radiometrici selezionati dall'operatore per facilitare l'apprendimento e la distinzione delle classi ricercate. Dall'altro lato, le strategie di DL prevedono la generazione automatica delle features, che apprendono grazie all'utilizzo di

grandi quantità di dati annotati in input. Per far fronte alla mancanza di dati architettonici utili per l'addestramento degli algoritmi è stata recentemente rilasciata una raccolta (ArCH) di nuvole punti architettoniche annotate (Matrone et al., 2020a). Per facilitare il processo di annotazione, Murtiyoso e Grussenmeyer (2020) hanno sviluppato una serie di funzioni matematiche tramite le quali è possibile isolare alcune specifiche classi architettoniche all'interno della nuvola di punti, come ad esempio colonne e travi. Nell'ambito dei beni culturali, Grilli et al. (2018) hanno proposto un approccio Machine Learning di tipo supervisionato che trasferisce le informazioni di classificazione dalle texture 2D ai modelli 3D. Gli stessi autori hanno poi applicato l'addestramento supervisionato direttamente sulle nuvole di punti formando un classificatore Random Forest (RF) con features geometriche studiate ad hoc per l'architettura (Grilli et al., 2019; Grilli e Remondino, 2020).

In ambito DL, Pierdicca et al., (2020) hanno "addestrato" sul dataset ArCH un Dynamic Graph Convolutional Neural Network (DGCNN) supportato da features significative (colori, normali e HSV). Il modello risultante è stato poi testato in due modi diversi: su un dataset parzialmente etichettato e su una scena non vista, fornendo risultati promettenti.

Recentemente è stato inoltre pubblicato un articolo di confronto sulla classificazione di nuvole di punti architettoniche utilizzando tecniche ML o DL (Matrone et al., 2020b). Dall'articolo è emerso che i risultati ottenuti con ML e DL sono comparabili in termini di accuratezza, sebbene i tempi impiegati nel ML siano ancora di gran lunga inferiori rispetto al DL.

Considerata la complessità e peculiarità dei casi studio trattati in questo articolo, si è scelto di prendere come punto di partenza l'approccio di ML proposto da (Grilli e Remondino, 2020), in quanto risulta facilmente adattabile a nuove classi architettoniche durante la fase di addestramento dell'algoritmo.

3. CASI STUDIO

3.1 Duomo di Milano

A supporto delle attività di manutenzione straordinaria della cattedrale tardo-gotica, negli ultimi dieci anni sono state condotte diverse operazioni di rilievo della Guglia Maggiore, degli altari del transetto e del tiburio, che hanno portato alla produzione di modelli 3D di tipo nurbs e rappresentazioni 2D in scala 1:50 (Fassi et al., 2011). Negli ultimi tre anni inoltre, combinando l'uso di scansioni laser terrestri per gli spazi interni e di fotogrammetria per quelli esterni, è stata generata una nuvola di punti 3D dell'intera Cattedrale ad una risoluzione media uniforme di 5 mm (Achille et al., 2020).

Dati i necessari lavori di manutenzione continua e la grande quantità di dati da gestire, la segmentazione semantica della nuvola di punti del Duomo di Milano può diventare un utile strumento di supporto digitale delle attività di conservazione evitando lunghi processi di modellazione che diventano costosi, complessi, spesso non sostenibili ed inoltre degradano il dato 3D in termini di accuratezza, affidabilità metrica e di risoluzione. L'utilizzo diretto nella pratica decisionale e di progetto della nuvola di punti permetterebbe un'immediata derivazione di misure e rappresentazioni 2D; l'identificazione, conteggio e visualizzazione dei singoli elementi architettonici per una migliore interpretazione delle strutture architettoniche a livello di nuvola di punti. Favorirebbe inoltre la possibilità di tracciamento di ogni attività di restauro, trattando la nuvola di punti come un completo sistema informativo navigabile in 3D dove è possibile consultare informazioni, dati e un catalogo di documenti d'archivio generando una piattaforma informativa web-based di

tipo BIM, utilizzabile direttamente sul campo o all'interno di un sistema a realtà mista.

3.2 Abbazia di Pomposa

Il progetto di rilievo del monastero benedettino dell'Abbazia di Pomposa, risalente al IX secolo, è stato eseguito nel 2015 mediante l'utilizzo di tecnologie di tipo attivo e passivo, terrestri ed aeree, al fine di valutare la possibilità di integrare tecniche di acquisizione fotogrammetrica basate sul processo di Structure from Motion (SfM) con consolidate metodologie di acquisizione 3D da laser scanner, ottenendo in tal senso un modello integrato completo dell'intero complesso abbaziale. La campagna di acquisizione 3D del complesso monastico ha replicato una attività conoscitiva digitale già avviata nel 1998, attraverso un progetto pionieristico per le metodologie di rilevamento adottate. La campagna attuale si è fondata sulla interazione di strumenti attivi e passivi, da terra e da drone (Russo e Manfredini, 2014). Nel caso dell'abbazia l'arricchimento della nuvola di punti con informazioni semantiche può essere utile per differenti finalità. In primis è possibile derivare velocemente da queste informazioni delle misure e relative rappresentazioni 2D. Inoltre, è possibile pianificare un monitoraggio dell'edificio nel tempo, verificando murature, colonne e rotazioni delle coperture: un confronto tra nuvole di punti acquisite nel tempo va considerato come una valida soluzione per l'esatta e completa descrizione dell'intero tessuto. Per quanto riguarda il controllo geometrico sulla qualità dei dati acquisiti, questo può avvenire sui singoli elementi appartenenti alla stessa classe architettonica, evidenziando possibili alterazioni della composizione strutturale dell'edificio. Infine, tale suddivisione può facilitare l'operazione di "quantificazione" dell'edificio dal punto di vista materico e funzionale, raccogliendo alcune informazioni molto importanti sia per la pianificazione di un intervento conservativo che per una eventuale valutazione dei danni (ad esempio dopo un evento distruttivo).

4. METODOLOGIA

La complessità dei casi studio scelti ci pone principalmente davanti a due problemi:

- la dimensione del dato rende il processo di calcolo impegnativo in termini computazionali. Un sottocampionamento della nuvola di punti potrebbe aiutare a gestire l'elevato numero di punti, ma abbasserebbe il livello di dettaglio del dataset originale;
- il numero elevato di classi semantiche da identificare al contempo induce rapidamente ad errori di classificazione: alcuni esperimenti iniziali hanno dimostrato che più alto è il numero di classi, minore è l'accuratezza della classificazione (Teruggi et al., 2020).

Considerando i problemi sopra citati, si è quindi ritenuto opportuno sviluppare la metodologia presentata da Grilli et al. (2020), in cui i dati venivano classificati in un unico passaggio, suddividendo ora il processo su più fasi. Si propone quindi un approccio multi-livello e multi-risoluzione (MLMR), che segue i seguenti passaggi:

1. La nuvola di punti a risoluzione completa viene sottocampionata e classificata tramite apprendimento supervisionato nelle sue parti principali (macro-categorie).
2. I risultati provenienti da questa classificazione vengono interpolati su una versione a più alta risoluzione della nuvola di punti, trasferendo le classi assegnate in prima fase in un determinato intorno di punti.

3. le macrocategorie di interesse vengono a sua volta suddivise nelle loro componenti (ad esempio, le colonne in base, fusto e capitello);
4. i risultati della classificazione vengono nuovamente interpolati su una versione a più alta risoluzione della nuvola di punti fino a raggiungere la piena risoluzione geometrica.

Va detto che ogni elemento può essere classificato in modo sempre più dettagliato, in base alla risoluzione della nuvola di punti usata al livello corrispondente, e poi interpolato su una versione a risoluzione più alta. Il processo è iterativo, e l'ultimo livello di classificazione corrisponderà alla nuvola di punti a piena risoluzione. Inoltre, il sotto campionamento della nuvola di punti dipenderà sia dalla complessità dell'oggetto da classificare che dagli elementi da riconoscere. Le macro-categorie di oggetti, i macro-elementi architettonici, consentono una risoluzione più bassa, mentre la risoluzione più alta viene utilizzata per gli elementi di dettaglio.

4.1 Selezione delle features

Le features geometriche selezionate per addestrare il modello di ML al riconoscimento automatico degli elementi architettonici sono le cosiddette "features di covarianza" (Blomey et al., 2014), le quali consentono di evidenziare le caratteristiche geometriche locali del dato 3D. Vengono, in questo modo, evidenziati i comportamenti locali della nuvola come ad esempio la "linearità", "planarità" e "sfericità" o ancora la "variazione di superficie" e l'"anisotropia". La scelta delle giuste features geometriche ed il raggio di intorno del punto sul quale calcolarle sono fondamentali ai fini dell'individuazione degli elementi architettonici (Figura 1) (Grilli et al., 2019).

La metodologia gerarchica proposta è sintetizzata graficamente nella Figura 5. Il diagramma ha lo scopo di fornire un'indicazione generale in termini di risoluzione geometrica della nuvola di punti e di features geometriche da utilizzare in ogni fase della classificazione. I parametri (risoluzione e raggi delle features), possono variare caso per caso, a seconda delle caratteristiche e delle dimensioni degli oggetti. Tuttavia, si può notare che essi corrispondono al più piccolo dettaglio che può essere rappresentato ad una data scala di rappresentazione e alla sua tolleranza metrica, in una logica di rappresentazione ad un livello di dettaglio crescente.

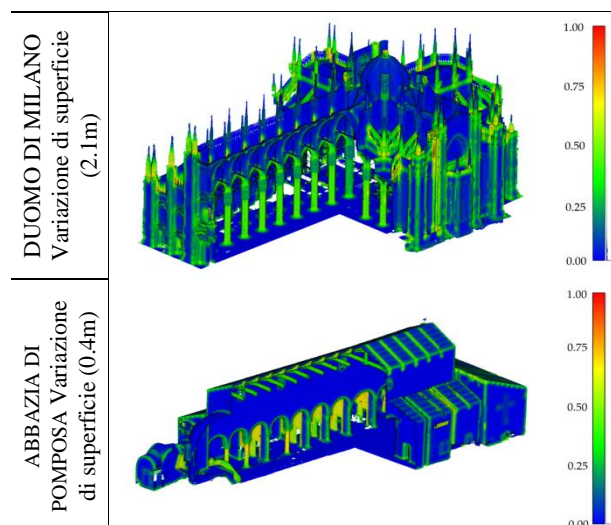


Figura 1. Utilizzo della stessa feature geometrica, calcolata a raggi diversi poiché selezionata in funzione delle dimensioni del caso studio trattato.

4.2 Annotazione del dato

In aggiunta alla selezione delle features geometriche, alcune parti di ogni dataset, ad ogni livello di classificazione, devono essere annotate manualmente per addestrare l'algoritmo Random Forest (Breiman, 2001). La Figura 2 mostra i set di addestramento utilizzati al primo livello di classificazione (risoluzione 5 cm) del Duomo di Milano e dell'Abbazia di Pomposa, rispettivamente. Per il primo caso studio (30 milioni di punti), il campione di addestramento è composto da circa 2,5 milioni di "punti etichettati" per le superfici esterne e circa 2,6 milioni di punti per gli spazi interni. Per l'Abbazia di Pomposa, di 1,1 milione di punti che compongono l'intera nuvola circa 115.444 punti sono stati classificati manualmente.

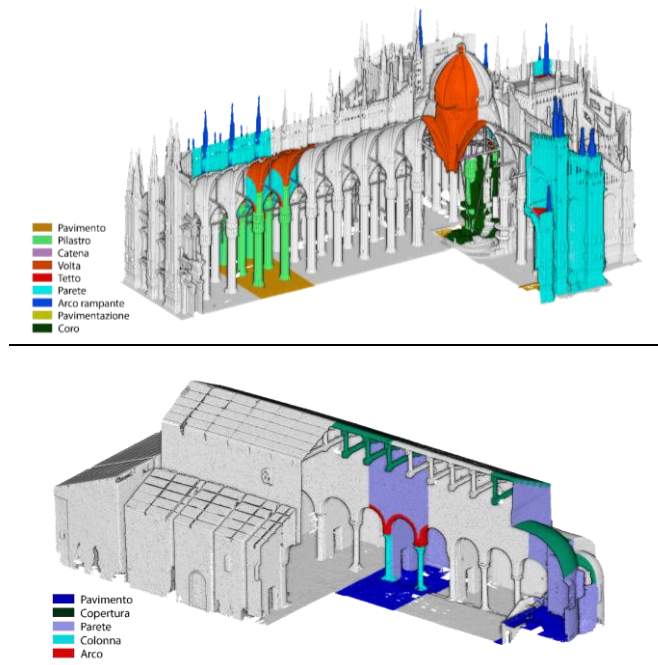


Figura 2. Porzioni di dataset annotate manualmente ai fini di addestramento al livello 1.

4.3 Valutazione dei risultati

Per valutare quantitativamente le prestazioni della classificazione, sono state prese in considerazione le metriche di accuratezza comunemente utilizzate in ambito machine learning, quali "Precision", "Recall" e "F1 score" (Goutte e Gaussier, 2005). Tali metriche vengono ricavate dal confronto diretto tra predizione automatica e annotazione manuale della stessa porzione di nuvola e tengono conto non solo dei valori correttamente predetti ma anche di quelli erronei.

5. RISULTATI

La tabella 1 riassume i tempi di addestramento e di classificazione impiegati per i due casi studi ai tre livelli di classificazione. In aggiunta la Figura 3 indica la percentuale di tempo trascorso in ogni fase di lavoro. È importante sottolineare che il tempo di calcolo per l'estrazione delle features geometriche varia in relazione alla dimensione della nuvola di punti, al numero di features e al loro raggio di ricerca. Per quanto riguarda il primo livello di classificazione, su una workstation con processore a 18 core, la fase di addestramento per il Duomo di Milano ha richiesto circa 5 minuti (2,5 mil. di punti), mentre sono stati necessari 43 secondi per classificare la restante nuvola di

punti (12 mil. di punti). Per quanto riguarda l'Abbazia di Pomposa, il processo di addestramento e di classificazione hanno richiesto rispettivamente 5 e 3 secondi.

		TEMPI (sec)		
		L1	L2	L3
DUOMO	Addestramento	363	17	142
	Classificazione	43	12	174
ABBZIA	Addestramento	5	1	4
	Classificazione	2.7	1	29

Tabella 1. Riepilogo dei tempi impiegati per addestramento e classificazione nei tre livelli di classificazione.

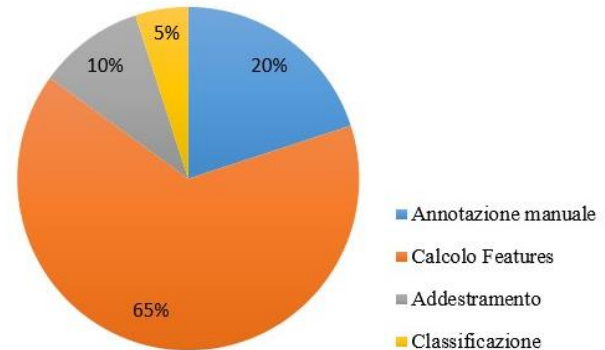


Figura 3. Rappresentazione sintetica dei tempi (normalizzati) necessari per le diverse fasi del processo di classificazione, dall'annotazione manuale alla classificazione finale del dataset.

5.1 Duomo di Milano

Applicando l'approccio gerarchico, la nuvola di punti del Duomo è stata classificata su tre livelli (Fig. 6 -7). Al primo livello la classificazione è stata eseguita su nuvola di punti con risoluzione di 5 cm, calcolando features geometriche di raggio compreso tra 20 cm e 2,5 m, permettendo l'identificazione di macro-elementi architettonici. Al secondo livello di classificazione, dopo aver trasferito la classificazione proveniente dal primo livello su nuvola di punti con risoluzione di 2 cm, gli elementi architettonici precedentemente identificati sono stati suddivisi in sottocomponenti, riducendo a 10 cm e 1 m i raggi min./max di ricerca delle features geometriche.

Infine, il terzo livello di classificazione mira alla suddivisione di ogni componente nei suoi conci di marmo (elementi monolitici quali statue, decorazioni gotiche, ecc.). In questo caso, quindi, è stata utilizzata la nuvola di punti a piena risoluzione, ricercando le features con raggio minimo e massimo di 0,5 e 5 cm rispettivamente. La Tabella 2 riporta i risultati in termine di F1 score ottenuti nei tre livelli, con una precisione sempre superiore al 90%.

	Level 1 (5cm)	Level 2 (2 cm)	Level 3 (0.5 cm)
Precision (%)	94.7	99	92
Recall (%)	95	98	88.5
F1 score (%)	93.78	99.3	91.8

Tabella 2. Metriche di accuratezza ottenute ai tre livelli di classificazione del Duomo di Milano.

6. CONCLUSIONI

In questo articolo è stata presentata una nuova strategia di classificazione gerarchica (MLMR) che permette di assegnare un significato semantico alle nuvole di punti 3D di strutture complesse appartenenti al mondo dei beni culturali, processo classicamente manuale in fase di modellazione 3D.

Gli aspetti innovativi del lavoro presentato sono i seguenti:

- L'uso di tecniche di machine learning per classificare rapidamente grandi e complesse architetture 3D senza la necessità di annotare grandi quantità di dati di training.
- La definizione di regole generali replicabili in vari scenari del patrimonio, in termini di relazioni tra i livelli di classificazione, risoluzione delle nuvole di punti e raggi di ricerca delle features minime/massime.
- La segmentazione gerarchica (fino a singole istanze) dei dati 3D, strumento utile per la modellazione HBIM.
- La velocità del processo: una volta definiti i dataset di formazione e validazione, la previsione dell'intero set di dati si ottiene in pochi minuti.

I risultati di classificazione ottenuti mostrano come le nuvole di punti classificate possano facilitare la comprensione di complesse strutture architettoniche, diventando possibili strumenti di supporto al restauro, la manutenzione e la gestione delle strutture in loco senza il bisogno di sintetizzazioni successive. Sebbene il processo sia automatico il contributo cognitivo di un operatore esperto è fondamentale all'inizio del processo. Proprio perché i Beni Culturali sono variegati non si possono fare generalizzazioni assolute, all'operatore esperto che conosce il Bene in esame, è richiesto lo sforzo della definizione delle classi e la scelta dei set di formazione e di convalida (annotazione dei dati). Queste fasi sono cruciali per adattare il processo ai diversi casi di studio e alle diverse finalità.

Come possibili linee di ricerca future, alcuni aspetti potrebbero meritare ulteriore attenzione e sviluppo:

- una migliore indagine sulla relazione tra i livelli di classificazione, la risoluzione delle nuvole di punti e i raggi di ricerca delle features: è necessario capire se la classificazione automatica con features specifiche può essere generalizzata per quanto riguarda la densità dei dati, o se dipende dal caso;
- verifica dell'utilità del processo di classificazione per il processo scan-to-BIM, verificando se le strutture e le istanze semantiche estratte facilitano il lavoro preparatorio per la costruzione di modelli BIM;
- verifica se le nuvole di punti semanticamente segmentate possono facilitare la generazione di mesh poligonali;
- Creazione di un quadro di classificazione di più facile utilizzo per i non esperti del settore;
- Verifica della possibilità di elaborare automaticamente i dati acquisiti in loco con strumenti scanner mobili per applicazioni di monitoraggio in tempo reale.
- Miglioramento dei dettagli di classificazione integrando le informazioni provenienti da immagini, che in genere hanno una risoluzione più elevata, permettendo così una migliore identificazione/distinzione dei piccoli elementi (es. classificazione di ogni singolo blocco di marmo che compone il Duomo di Milano).




Figura 3. Risultato ottenuto dalla classificazione automatica del Duomo al Livello 1.

5.2 Abbazia di Pomposa

Considerando le esigenze di monitoraggio, la classificazione è stata suddivisa in tre diversi livelli (Figura 8 - 9). Il primo livello fa riferimento al quadro strutturale principale della chiesa, definendo una suddivisione funzionale globale dell'intero dataset: pavimento, facciate, colonne, archi e tetto. Per riconoscere queste macro-categorie, la nuvola di punti è stata elaborata con una risoluzione di 5 cm.

Il secondo livello è dedicato ad un processo di classificazione più approfondito, riconoscendo più sottoclassi all'interno delle categorie provenienti dal primo livello di classificazione. Le facciate sono state suddivise in pareti e finestre, le colonne in basi, fusti e capitelli ed il tetto in cupole, copertura laterale, centrale e frontale. A questo livello, ogni elemento architettonico è stato riconosciuto sulla nuvola di punti con risoluzione di 2 cm. Il terzo livello è stato unicamente focalizzato allo studio delle coperture lignee, le quali presentano strutture complesse e variabili. Per ogni diversa struttura del tetto è stato eseguito un processo di classificazione diversificato, evidenziandone i principali elementi strutturali (ad esempio, travi, travetti, saette, puntoni, tavole, ecc.). Per completare questo studio strutturale, si è deciso di sfruttare nuovamente la nuvola con risoluzione 2 cm. La tabella 3 riporta le metriche di accuratezza ottenute.

	Level 1 (5cm)	Level 2 (2 cm)	Level 3 (0.5 cm)
Precision (%)	95.3	98	95.8
Recall (%)	95.1	97.7	95.7
F1 score (%)	95.1	97.8	94.6

Tabella 3. Metriche di accuratezza ottenute ai tre livelli di classificazione dell'Abbazia di Pomposa.




Figura 4. Risultato ottenuto dalla classificazione automatica dell'Abbazia al Livello 1.

BIBLIOGRAFIA

- Achille, C., Fassi, F., Mandelli, A., Perfetti, L., Rechichi, F. and Teruggi, S., 2020. From a Traditional to a Digital Site: 2008–2019. The History of Milan Cathedral Surveys. In *Digital Transformation of the Design, Construction and Management Processes of the Built Environment* (pp. 331-341). Springer, Cham.
- Apollonio, F.I., Basilissi, V., Callieri, M., Dellepiane, M., Gaiani, M., Ponchio, F., Rizzo, F., Rubino, A.R. and Scopigno, R., 2018. A 3D-centered information system for the documentation of a complex restoration intervention. *Journal of Cultural Heritage*, 29, pp.89-99.
- Bassier, M., Yousefzadeh, M. and Vergauwen, M., 2020. Comparison of 2D and 3D wall reconstruction algorithms from point cloud data for as-built BIM. *Journal of Information Technology in Construction (ITcon)*, 25(11), pp.173-192.
- Blomley, R., Weinmann, M., Leitloff, J. and Jutzi, B., 2014. Shape distribution features for point cloud analysis—a geometric histogram approach on multiple scales. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2(3), 9.
- Breiman, L., 2001. Random forests. *Machine learning*, 45(1), pp. 5-32.
- Croce, V., Caroti, G., De Luca, L., Piemonte, A. and Véron, P., 2020. semantic annotations on heritage models: 2D/3D approaches and future research challenges. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, pp.829-836.
- Fassi, F., Achille, C. and Fregonese, L., 2011. Surveying and modelling the main spire of Milan Cathedral using multiple data sources. *The Photogrammetric Record*, 26(136), pp.462-487.
- Goutte, C. and Gaussier, E., 2005, March. A probabilistic interpretation of precision recall and F-score, with implication for evaluation. In *European conference on information retrieval* (pp. 345-359). Springer, Berlin, Heidelberg.
- Grilli, E. and Remondino, F., 2020. Machine Learning Generalisation across Different 3D Architectural Heritage. *ISPRS International Journal of Geo-Information*, 9(6), 379.
- Grilli, E., Dinunno, D., Marsicano, L., Petrucci, G. and Remondino, F., 2018. Supervised segmentation of 3D cultural heritage. In *2018 3rd Digital Heritage International Congress (DigitalHERITAGE) held jointly with 2018 24th International Conference on Virtual Systems & Multimedia (VSMM 2018)*, pp. 1-8. IEEE.
- Grilli, E., M. Farella, E., Torresani, A. and Remondino, F., 2019. Geometric features analysis for the classification of cultural heritage point clouds. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XLII-2/W15, pp 541-548.
- Kashani, A.G. and Graettinger, A.J., 2015. Cluster-based roof covering damage detection in ground-based lidar data. *Automation in Construction*, 58, pp.19-27.
- Matrone, F., Lingua, A., Pierdicca, R., Malinverni, E.S., Paolanti, M., Grilli, E., Remondino, F., Murtiyoso, A. and Landes, T., 2020a. A benchmark for large-scale heritage point cloud semantic segmentation. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XLIII-B2, pp. 1419-1426.
- Matrone, F., Grilli, E., Martini, M., Paolanti, M., Pierdicca, R. and Remondino, F., 2020b. Comparing Machine and Deep Learning Methods for Large 3D Heritage Semantic Segmentation. *ISPRS International Journal of Geo-Information*, 9(9), 535.
- Mizoguchi, T., Koda, Y., Iwaki, I., Wakabayashi, H., Kobayashi, Y., Shirai, K., Hara, Y. and Lee, H.S., 2013. Quantitative scaling evaluation of concrete structures based on terrestrial laser scanning. *Automation in construction*, 35, pp.263-274.
- Murtiyoso, A. and Grussenmeyer, P., 2020. Virtual Disassembling of Historical Edifices: Experiments and Assessments of an Automatic Approach for Classifying Multi-Scalar Point Clouds into Architectural Elements. *Sensors*, 20(8), 2161.
- Pierdicca, R., Paolanti, M., Matrone, F., Martini, M., Morbidoni, C., Malinverni, E.S., Frontoni, E. and Lingua, A.M., 2020. Point Cloud Semantic Segmentation Using a Deep Learning Framework for Cultural Heritage. *Remote Sensing*, 12(6), 1005.
- Rebolj, D., Pučko, Z., Babič, N.Č., Bizjak, M. and Mongus, D., 2017. Point cloud quality requirements for Scan-vs-BIM based automated construction progress monitoring. *Automation in Construction*, 84, pp.323-334.
- Roussel R., Bagnérís M., De Luca L. and Bomblet P., 2019. A digital diagnosis for the <<autumn>> statue (Marseille, France): photogrammetry, digital cartography and construction of a thesaurus. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XLII-2/W15, pp. 1039–1046.
- Russo, M. and Manferdini, A.M., 2014. Integration of image and range-based techniques for surveying complex architectures. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 2(5).
- Sánchez-Aparicio, L.J., Del Pozo, S., Ramos, L.F., Arce, A. and Fernandes, F.M., 2018. Heritage site preservation with combined radiometric and geometric analysis of TLS data. *Automation in Construction*, 85, pp.24-39.
- Son, H. and Kim, C., 2017. Semantic as-built 3D modeling of structural elements of buildings based on local concavity and convexity. *Advanced Engineering Informatics*, 34, pp.114-124.
- Teruggi, S., Grilli, E., Russo, M., Fassi, F. and Remondino, F., 2020. A Hierarchical Machine Learning Approach for Multi-Level and Multi-Resolution 3D Point Cloud Classification. *Remote Sensing*, 12(16), 2598.
- Valero, E., Bosché, F. and Forster, A., 2018. Automatic segmentation of 3D point clouds of rubble masonry walls, and its application to building surveying, repair and maintenance. *Automation in Construction*, 96, pp.29-39.

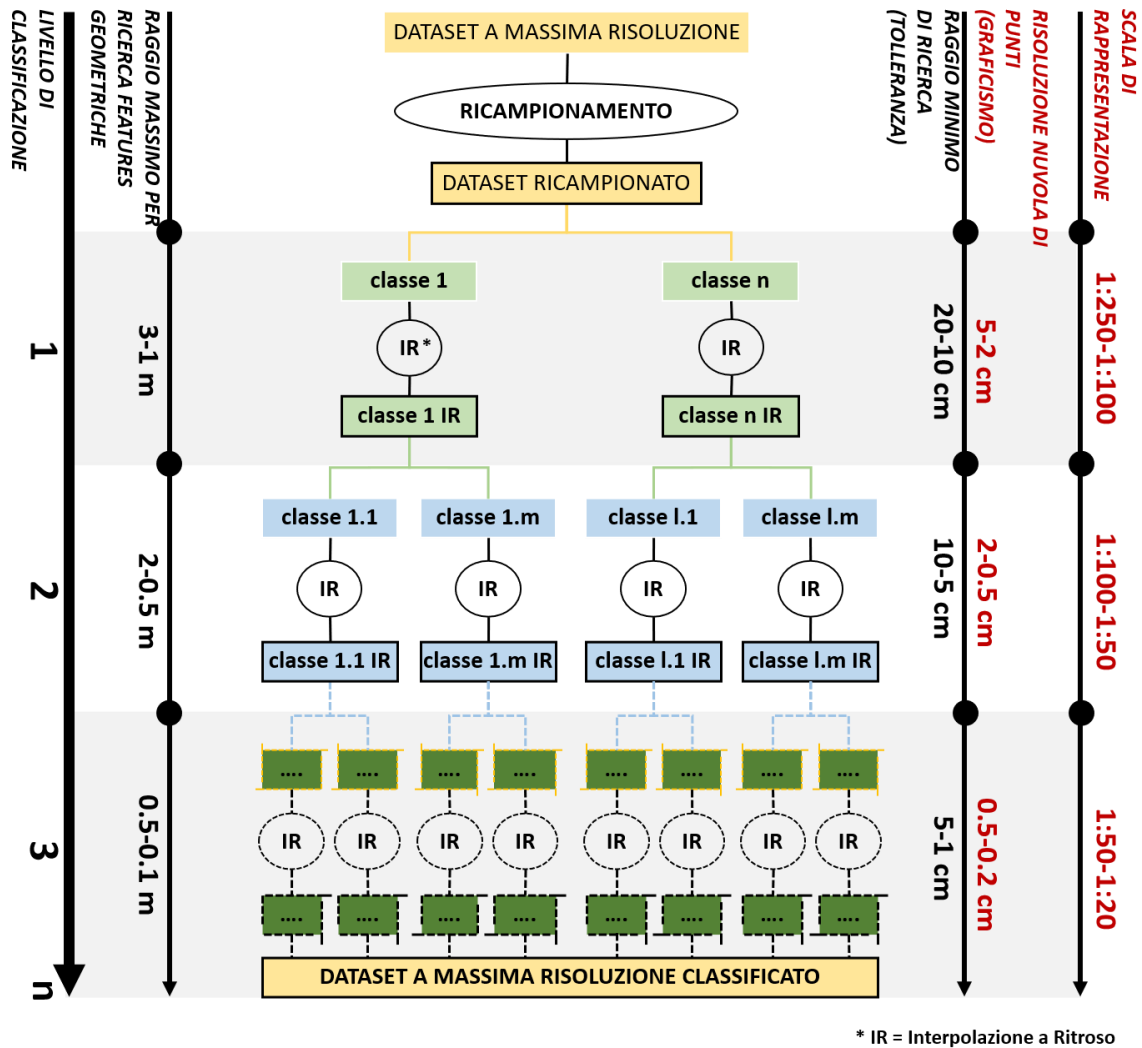


Figura 5. Approccio di classificazione a più livelli e risoluzioni (MLMR). Il diagramma fornisce indicazioni generali in termini di risoluzione delle nuvole di punti e raggio di ricerca minimo/massimo delle features geometriche, che devono essere scelte in ogni fase del processo di classificazione.

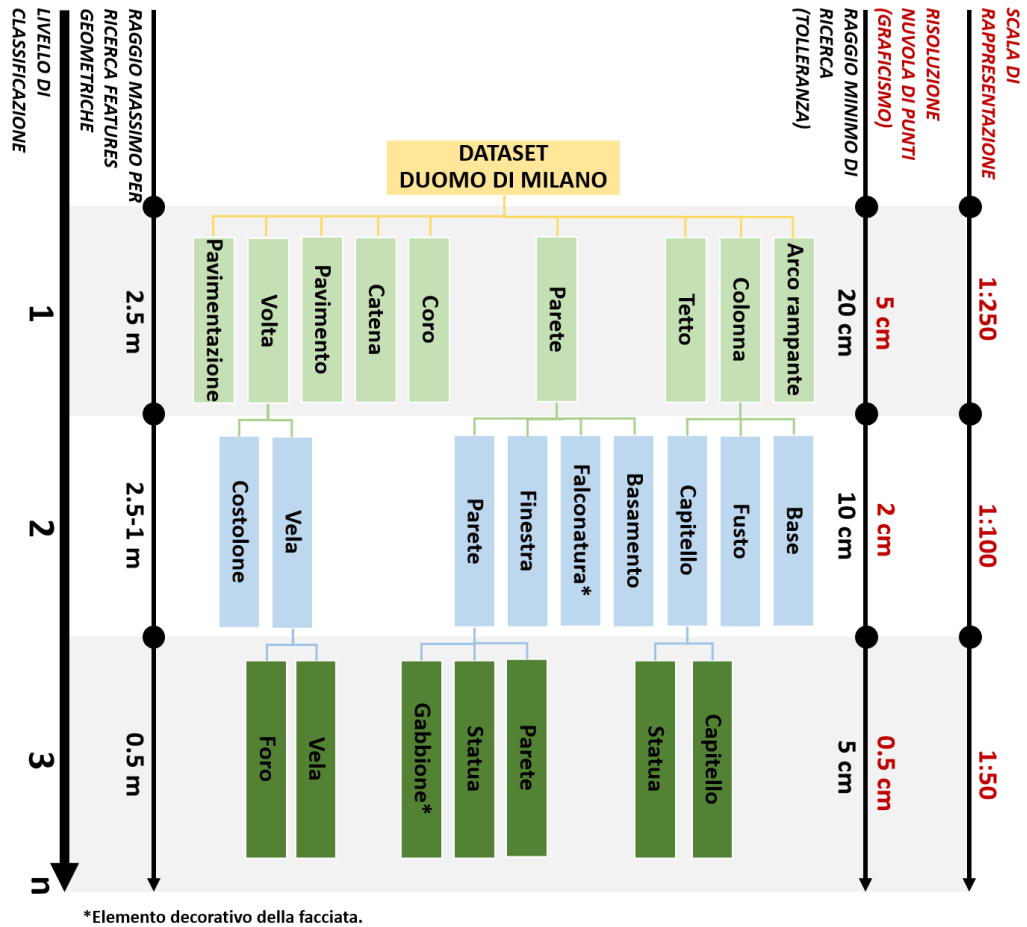


Figura 6. Approccio di classificazione MLMR. Distribuzione delle classi ai diversi livelli di risoluzione per il Duomo di Milano.




Figura 7. Approccio MLMR di classificazione. Risultati ottenuti sul Duomo di Milano.

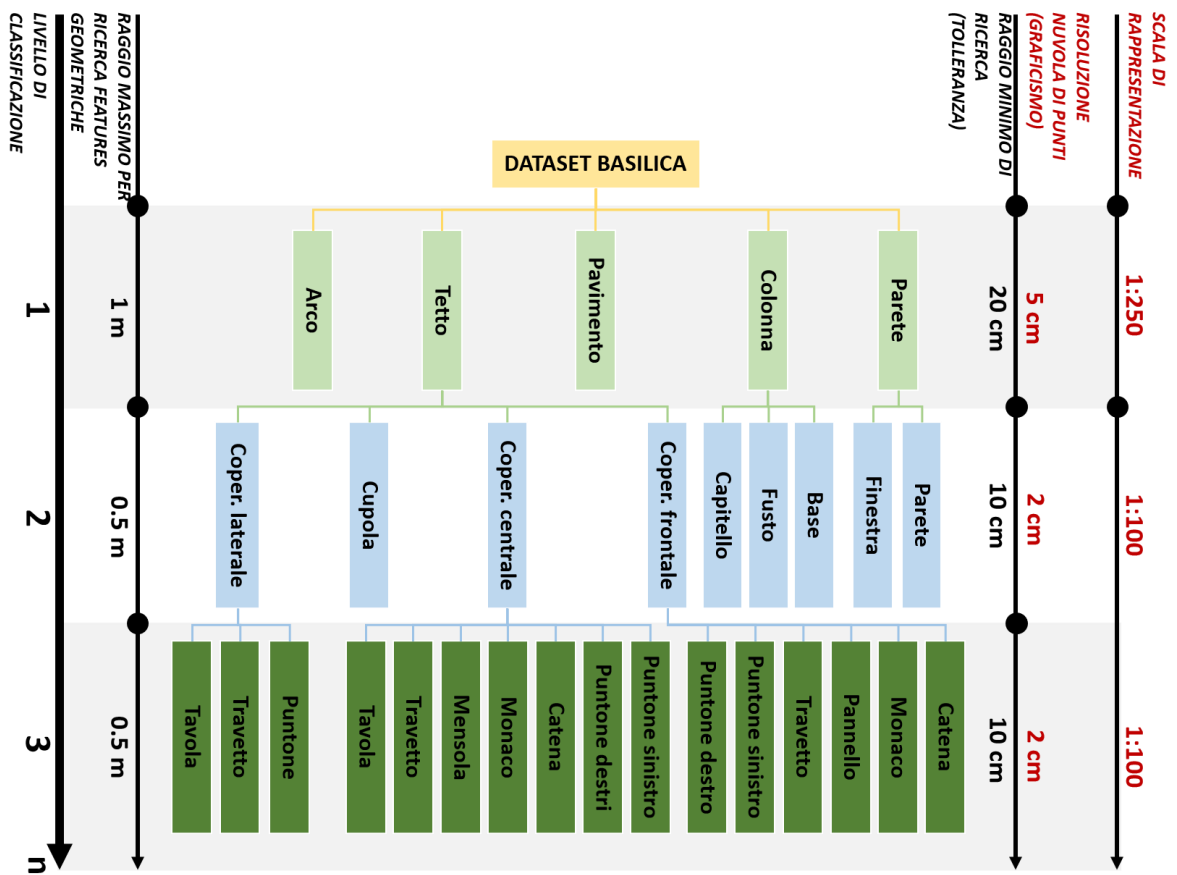


Figura 8. Approccio di classificazione MLMR. Distribuzione delle classi ai diversi livelli di risoluzione per l'Abbazia di Pomposa.




Figura 9. Approccio MLMR di classificazione. Risultati ottenuti sull'Abbazia di Pomposa.