

METODI DI CLASSIFICAZIONE AUTOMATICA TEXTURE- E GEOMETRY-BASED APPLICATI A BENI CULTURALI

TEXTURE- AND GEOMETRY-BASED APPROACHES FOR THE CLASSIFICATION OF 3D HERITAGE

E. Grilli ^{a,b}

^a 3D Optical Metrology (3DOM) unit, Bruno Kessler Foundation (FBK), Trento, Italy

^b Department of Architecture, University of Bologna, Italy

grilli@fbk.eu

PAROLE CHIAVE: Classificazione, Nuvola di punti, Mesh, Machine Learning.

KEY WORDS: Classification, Point Cloud, Mesh, Machine Learning

Questo articolo è stato presentato al Premio Giovani Autori SIFET 2019.

RIASSUNTO

L'applicazione delle nuove metodologie di rilievo e documentazione tridimensionale, attraverso l'utilizzo di sensori attivi e passivi, è ormai una pratica comune nel settore dei beni culturali. Per sfruttare le reali potenzialità di questa significativa quantità di dati e poter estrarre informazioni semantiche da nuvole di punti o modelli poligonali, emerge oggi la necessità di sviluppare metodi affidabili di classificazione. Questo articolo esplora l'uso di metodi di Machine e Deep Learning a supporto della classificazione 3D ai fini di studio, monitoraggio e restauro. In particolare, vengono presentati e confrontati tre diversi approcci di classificazione basati rispettivamente sull'utilizzo di features radiometriche, geometriche o una combinazione di entrambe.

ABSTRACT

The continuous evolution in the last years of remote sensing technologies and methodologies for Cultural Heritage 3D documentation allowed to multiply photogrammetric and laser scanning acquisitions. At the same time, to exploit the real potential of this significant amount of data, the need for reliable and efficient methods to classify (i.e. semantically segment) point clouds or meshes has become a priority. This article explores the use of Machine and Deep Learning methods as support for studies, monitoring, and restoration purposes. More specifically, three different approaches based on texture, geometry, and texture plus geometry features are presented and compared.




Figura 1. Nuvola di punti fotogrammetrica di un edificio rinascimentale a Bologna (85x18 m, 1.2 milioni di punti) (a); corrispondente nuvola di punti classificata automaticamente (b).

1. INTRODUZIONE

Il settore dei beni culturali è stato, negli ultimi decenni, uno dei campi di sperimentazione più interessanti delle nuove tecnologie e metodologie di rilievo digitale tridimensionale. L'evoluzione digitale ha profondamente trasformato le modalità di acquisizione, elaborazione e gestione dei dati in questo settore. Tuttavia, l'associazione di diverse informazioni semantiche ai prodotti del rilievo tridimensionale (nuvole di punti o modelli poligonali), attraverso metodi automatici di segmentazione e classificazione (Grilli et al., 2017), diventa fondamentale per l'interpretazione degli oggetti rilevati.

In generale, con il termine classificazione o segmentazione semantica si fa riferimento al processo di raggruppamento di dati

simili in sottoinsiemi (detti segmenti). Questi ultimi hanno in comune una o più caratteristiche (geometriche, radiometriche, ecc.), attraverso cui è possibile distinguere ed identificare le diverse parti che compongono un'immagine, una nuvola di punti o un modello poligonale. Tra le possibili applicazioni delle metodologie di classificazione 3D applicata al settore dei beni culturali troviamo:

- l'annotazione semantica dei dati 3D per scopi didattici;
- la suddivisione di grandi modelli in parti più piccole che possono essere gestite più facilmente;
- l'identificazione degli elementi architettonici, come fase preliminare per le applicazioni di Building Information Modeling (BIM) (Figura 1);

- l'identificazione e la quantificazione dei materiali da costruzione o stati di conservazione, utili per scopi di monitoraggio o restauro;
- la distinzione tra elementi architettonici strutturali e decorativi.

Tuttavia, lo sviluppo di una procedura automatica per la classificazione 3D è ancora un compito impegnativo, tenendo conto della complessità ed eterogeneità dei dati nel settore dei beni culturali. Nello specifico:

- l'identificazione delle classi non è mai univoca: a seconda dello scopo, più classi potrebbero descrivere lo stesso oggetto;
- gli elementi architettonici sono spesso scomponibili in sottoclassi (ad esempio, per le colonne possono essere individuate basi, fusti e capitelli; per le finestre, le parti decorative e strutturali, ecc.);
- è difficile classificare trasversalmente manufatti architettonici attraverso tecniche di Machine Learning, considerando le diverse peculiarità e caratteristiche dei beni di riconosciuto interesse storico e artistico.

In questo contesto, il lavoro presentato mira ad individuare soluzioni utili, affidabili, replicabili e pratiche per la classificazione sia di nuvole di punti che modelli poligonali di beni architettonici e archeologici, basandosi sull'applicazione di metodi di classificazione Machine Learning supervisionati.

L'articolo discute in primo luogo lo stato dell'arte in materia di classificazione 3D. Vengono, di seguito, valutate tre diverse metodologie di classificazione supervisionata applicate a tre diversi casi di studio: il Sarcofago degli Sposi, la tomba Bartoccini ed il Tempio di Nettuno. Infine, vengono riassunte e discusse le conoscenze acquisite.

2. STATO DELL'ARTE

La comunità geomatica ha mostrato, negli ultimi anni, un crescente interesse nel settore della segmentazione e classificazione dei dati tridimensionali ottenuti da rilievi reality-based. Notevoli progressi, nella ricerca di procedure automatiche di classificazione per l'analisi e la comprensione dei modelli 3D, sono attribuibili all'avvento del Machine Learning (Hackel et al., 2016; Weinmann et al., 2017; Wang et al., 2018). Machine e Deep Learning (ML / DL) sono campi di applicazione dell'Intelligenza Artificiale (AI), basati sullo sviluppo di algoritmi che permettono ai calcolatori/computer di prendere decisioni basate su dati iniziali di training. Deep Learning nello specifico viene considerato una branca del Machine Learning che si basa sull'utilizzo delle reti neurali artificiali (neural network) con due o più strati (hidden layers) per elaborare le informazioni in modo non lineare.

Diversi benchmark, con dati terrestri o aerei annotati, sono stati resi disponibili per testare e convalidare algoritmi. La maggior parte di questi datasets, fanno riferimento a territori rurali o scene urbane, come Semantic3d (Hackel et al., 2017) o The Cityscapes Dataset (Cordts et al., 2016). Mentre in questi scenari le classi di oggetti e le loro etichette sono oramai definite (terreno, strade, alberi, edifici, ecc.), l'identificazione di categorie precise nel settore dei beni culturali è molto più complessa. Ad oggi, le uniche banche dati del patrimonio architettonico annotato sono in 2D, come per le facciate dell'Ecole Centrale Paris (ECP) Facades dataset (Teboul et al., 2010), del eTraining for Interpreting Images of Man-Made Scenes (eTRIMS)(Korc and Forstner, 2009) o del Center for Machine Perception (CMP) Facade Database (Tyleček and Šára, 2013).

Diverse tecniche di Machine Learning sono state, tuttavia, applicate al contesto architettonico. Oses et al. (2014) applicano modelli di Machine Learning per la segmentazione di pareti in

muratura lavorando su immagini. Amato et al. (2015) affrontano il problema del riconoscimento di monumenti nelle immagini utilizzando tecniche di classificazione k-nearest neighbour (kNN). Le Convolutional Neural Networks (CNN) vengono applicate per la prima volta a scenari del patrimonio culturale in Llamas et al. (2016).

Per le applicazioni in ambito 3D, generalmente la classificazione viene eseguita manualmente e le annotazioni trasferite dal 2D al 3D (Campanaro et al., 2016; Grilli et al., 2018). Apollonio et al. (2018), nell'ambito del progetto di restauro della Fontana del Nettuno a Bologna, propongono l'annotazione diretta delle tipologie di degrado sui modelli 3D. Un esempio analogo, è dato dalla piattaforma web Aioli. L'utente, in questo caso, annotando informazioni su immagini utilizzate per la ricostruzione del modello fotogrammetrico, è in grado di trasferire in tempo reale dati semantici sul modello tridimensionale (Roussel et al., 2019). Futuri sviluppi di questa piattaforma prevedono l'utilizzo di metodi semiautomatici per i processi di annotazione.

Diversi metodi, in definitiva, sono stati sviluppati per la classificazione di immagini di edifici o monumenti di riconosciuto interesse architettonico, ma pochi sono i riferimenti a strategie di classificazione automatica di modelli tridimensionali (Poux et al., 2017; Grilli et al., 2019; Malinverni et al., 2019).

3. METODI DI CLASSIFICAZIONE 3D

In questo lavoro, vengono presentate diverse strategie di classificazione applicabili a nuvole di punti o mesh, basate sull'utilizzo di algoritmi di Machine e Deep Learning con apprendimento supervisionato. Con il termine "Machine Learning" ("apprendimento automatico"), si fa riferimento all'abilità delle macchine (computer) di apprendere senza essere state esplicitamente e preventivamente programmate. L'apprendimento supervisionato è una categoria del Machine Learning che prevede l'utilizzo di un set di dati in input e di informazioni relative ai risultati attesi, per l'identificazione di una regola generale che colleghi i dati in ingresso con quelli in uscita.

Per la classificazione di nuvole di punti o modelli poligonali di edifici o elementi architettonici, le categorie semantiche vengono apprese dai dati di input forniti manualmente sotto forma di patch (nel caso vengano annotate le texture) o porzioni annotate di nuvola (nel caso si lavori sul 3D). Oltre alle classi semantiche, ai dati di training sono associate le cosiddette features, particolari caratteristiche radiometriche o geometriche che permettono di distinguere una classe dall'altra. Queste informazioni vengono utilizzate per addestrare un modello predittivo specifico (ad esempio Random Forest) o una rete neurale, in grado di predire con un certo livello di accuratezza la segmentazione semantica dell'intero dataset.

Di seguito vengono presentati tre diversi approcci implementati per facilitare le esigenze di classificazione di scenari eterogenei:

- approccio texture-based, basato sull'utilizzo dei dati radiometrici delle texture dei modelli (sezione 3.1);
- approccio geometry-based, che sfrutta le proprietà geometriche delle nuvole di punti (sezione 3.2);
- approccio combinato texture- e geometry-based (sezione 3.3).

3.1 Classificazione texture-based

Considerando la vasta disponibilità in letteratura di sistemi Machine Learning applicati alla classificazione di immagini, il primo metodo proposto per la classificazione di modelli 3D si basa sull'individuazione delle classi a partire da dati 2D.

In base alla complessità dell'oggetto trattato, questa metodologia è applicabile ad ortofoto (nel caso di oggetti planari quali murature) o mappe UV, ovvero proiezioni su 2D della superficie dei modelli 3D.

Partendo da modelli 3D texturizzati, la pipeline sviluppata si basa su 3 step:

- generazione di ortofoto o mappe UV;
- classificazione supervisionata delle ortofoto o mappe UV;
- ri-proiezione dei risultati della classificazione 2D sui modelli 3D.

Per la classificazione delle texture, è stato utilizzato il plugin Trainable WeKa Segmentation (Witten et al., 2016), disponibile all'interno della distribuzione Fiji di ImageJ (Schindelin et al., 2012). Weka offre la possibilità di annotare manualmente piccole porzioni dell'immagine, estrarre features da informazioni radiometriche ed estendere la classificazione istruendo uno dei diversi modelli predittivi disponibili.

In questo lavoro, viene utilizzato un classificatore Random Forest (Breiman, 2001). Un esempio applicativo è fornito alla Sezione 4.1.

3.2 Classificazione geometry-based

In assenza di particolari caratteristiche colorimetriche e materiche che consentano di evidenziare le classi/componenti sulle texture, la classificazione deve tener conto delle proprietà geometriche del dato tridimensionale.

L'approccio geometry-based viene riassunto alla Figura 2.

In questo caso, le tecniche supervisionate di machine/deep learning vengono applicate alle nuvole di punti. Per la fase di training, questo approccio prevede l'identificazione e la segmentazione manuale delle classi.

L'estrazione delle covarianza features consente l'individuazione delle caratteristiche geometriche locali del dato 3D. Queste features, derivate dalla matrice di covarianza (Cheata et al., 2009), sono in grado di descrivere la distribuzione dei punti della nuvola in un determinato intorno. Vengono, in questo modo, evidenziati i comportamenti locali della nuvola (la linearità, planarità e sfericità o ancora misure quali l'onnivarianza e l'anisotropia (Blomey et al., 2014).

La scelta delle features geometriche ed il raggio di intorno del punto è argomento trattato dall'autore in un precedente articolo

(Grilli et al., 2019). A partire dal dato di training, possono quindi essere istruiti diversi modelli predittivi (machine o deep learning) che hanno il compito di estendere la classificazione al resto del dataset.

In questo lavoro, viene utilizzata un'implementazione Machine Learning Random Forest disponibile nella libreria Python di Scikit-learn (versione 0.21.1) (Pedregosa et al., 2011) ed una rete neurale 2D Convolutional Neural Network (CNN) (Ozdemir and Remondino, 2019a; Ozdemir and Remondino, 2019b).

Come strumento di valutazione dei risultati della classificazione, è valutata la matrice di confusione. Nell'ambito dell'Intelligenza Artificiale, la matrice di confusione restituisce una rappresentazione dell'accuratezza della classificazione statistica. Presa in considerazione una porzione del dataset, per ogni classe segmentata, la colonna della matrice rappresenta i valori predetti ed ogni riga rappresenta i valori reali annotati manualmente. Questa tabella evidenzia le performance del modello predittivo di classificazione, in modo da determinare quanto questo modello sia accurato ed efficace, considerando le seguenti metriche:

$$Accuracy = \frac{Tp + Tn}{Tp + Fp + Tn + Fn} \quad (1)$$

$$Precision = \frac{Tp}{Tp + Fp} \quad (2)$$

$$Recall = \frac{Tp}{Tp + Fn} \quad (3)$$

$$F1\ score = 2 * \frac{Recall * Precision}{Recall + Precision} \quad (4)$$

Tali metriche fanno riferimento non solo ai valori correttamente classificati (TP = true positive e TN = true negative) ma anche a quelli erronei (FP = false positive e FN = false negative).

Alla Sezione 4.2 è possibile trovare un esempio pratico di classificazione Machine e Deep Learning basato sull'uso di sole features geometriche.

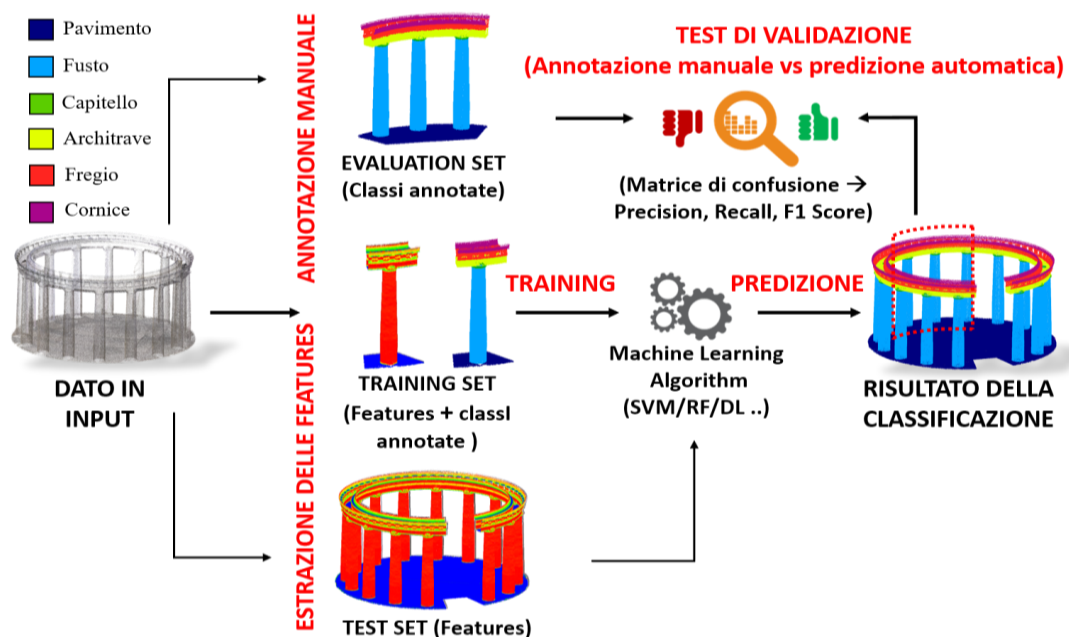


Figura 2. Workflow esemplificativo dell'approccio di classificazione supervisionata geometry-based.

3.3 Classificazione texture- & geometry-based

In alcuni casi, l'utilizzo in input delle sole informazioni radiometriche o geometriche può risultare insufficiente per classificare in maniera soddisfacente il dato 3D. Il tool di classificazione disponibile all'interno della libreria Computational Geometry Algorithms Library (CGAL)(Giraudot and Lafrange, 2019) permette la combinazione di entrambe. Come nell'approccio precedente, le classi di interesse vengono manualmente annotate sulla nuvola di punti. Le features geometriche (distanza dal piano, elevazione, dispersione verticale, verticalità, ecc.) vengono calcolate sulla nuvola a diverse scale di dettaglio, in modo da poter estrapolare ad esempio cambiamenti di direzione dei punti della nuvola sia macro che micro (Brodu and Lague, 2012). Insieme alle features geometriche vengono inoltre considerate quelle colorimetriche, convertendo i valori RGB della nuvola di punti allo spazio colore HSV, meno sensibile ai cambi di illuminazione (Sural et al., 2002). Preparati i dati di training, viene istruito un algoritmo Random Forest (ETH Zurich Random Forest Template, 2015), che estende la classificazione all'intero dataset. Un esempio applicativo di questo tipo di classificazione è riportato nella Sezione 4.3.

4. CASI STUDIO E RISULTATI

La scelta della migliore metodologia di classificazione di modelli archeologici/architettonici è funzione della complessità dell'oggetto e dello scopo della segmentazione. I metodi di classificazione descritti nella Sezione 3 sono stati applicati a tre diversi scenari archeologici:

- Sarcofago degli Sposi (Figura 3), situato nel museo di Villa Giulia a Roma (Italia): si tratta di un sarcofago etrusco di fine VI secolo a.C., alto 1,14 m per 1,9 m di larghezza e 0,8 m di profondità, in terracotta un tempo dipinta con colori vivaci e brillanti. L'approccio texture-based (Sezione 3.1) è stato applicato per identificare le anomalie superficiali (cioè fratture e decadimenti) e quantificare la quantità di cemento mimetico utilizzato per ri-assemblare il manufatto.



Figura 3. Sarcofago degli Sposi, Roma, Italy.

- Tempio di Nettuno (Figura 4) a Paestum (Italia): misura circa 24,5 m x 60 m x 17 m di altezza nel suo punto più alto. Si compone di 6 colonne frontali e 14 colonne laterali, mentre nella zona interna presenta due file di colonne a doppio ordine che dividono il naos in tre parti. L'approccio geometry-based mira ad identificare i principali elementi architettonici che compongono il tempio greco.



Figura 4. Tempio di Nettuno a Paestum, Italy.

- Tomba Bartoccini (Figura 5) a Tarquinia (Italia): la tomba etrusca, risalente al IV secolo a.C., si compone di quattro stanze ancora interamente affrescate - una centrale (circa 5 m per 4 m) e tre ai lati (circa 3 m per 3 m) di altezza non superiore a 3 m. Combinando l'uso di features geometriche e colorimetriche, la classificazione mira all'individuazione e alla quantificazione delle aree che presentano degradi dell'intonaco o hanno subito infiltrazioni.




Figura 5. Tomba Bartoccini a Tarquinia, Italy

4.1 Sarcofago degli Sposi, museo di Villa Giulia, Roma

Il "Sarcofago degli Sposi", di epoca etrusca, è stato ritrovato nel 1881 a Tarquinia (Italia), frammentato in più di 400 pezzi. Gli interventi successivi di restauro, con l'utilizzo di malta cementizia mimetica, hanno consentito la ricomposizione del sarcofago. Diverse metodologie e strumentazioni di rilievo reality-based (fotogrammetria, scansione laser a tempo di volo e a triangolazione), nel 2013, sono state impiegate per la realizzazione del modello tridimensionale (Menna et al., 2013). La mappa UV ad alta risoluzione (4096x4096 pixel), ottenuta dal complesso modello 3D (Figura 6a) (cinque milioni di triangoli), è stata manualmente annotata, identificando tre categorie principali ed una accessoria per la classificazione (Figura 6b). L'annotazione manuale delle patch necessarie al training ha richiesto circa 15 minuti ed è stata assistita da esperti di restauro. Una volta estratte le features radiometriche, il classificatore Random Forest ha esteso la classificazione all'intera mappa UV (Figura 6c). Una volta classificata, la texture è stata ri-proiettata sulla geometria 3D, permettendo di evidenziare i diversi dettagli del manufatto etrusco ricomposto (Figura 7). I piedi di sostegno del sarcofago (le uniche parti del sarcofago con visibili decorazioni a pigmento) sono stati esclusi dalla classificazione. Il modello classificato è stato, infine, analizzato per individuare la distribuzione delle diverse classi individuate. Il dato più interessante emerso è che il 12% della superficie del sarcofago sarebbe composta da malta mimetica. Conoscendo inoltre la superficie complessiva del sarcofago (6.8 m²), misurata a partire dal modello poligonale, si deriva che circa 0.8m² sono occupati da parti ricostruite. Un video rappresentativo della classificazione del Sarcofago è disponibile al seguente link: <https://www.youtube.com/watch?v=ZmjUh3xn6eA>

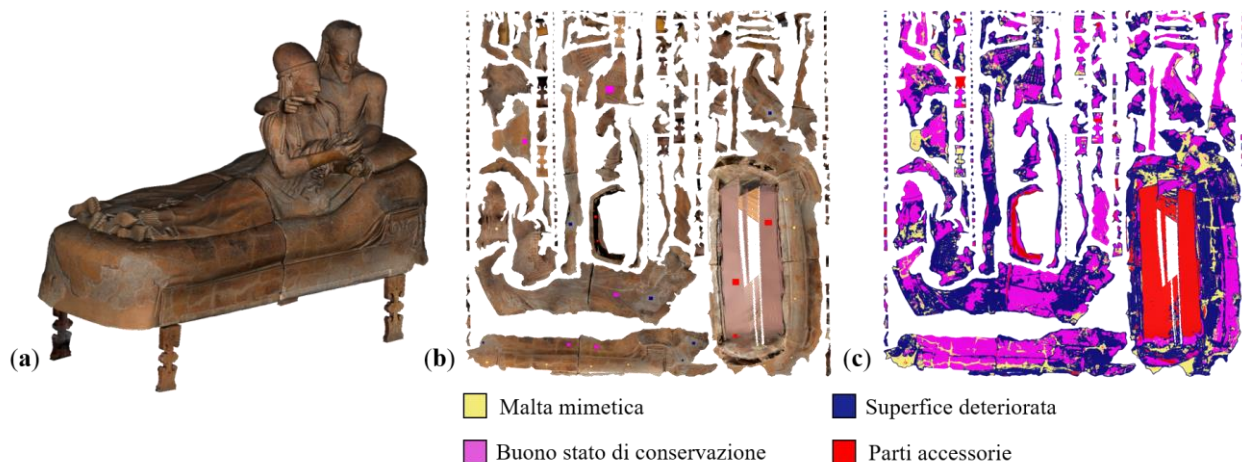


Figura 6. Modello fotogrammetrico ad alta risoluzione del Sarcofago degli sposi (a); classi manualmente annotate sulla mappa UV (b); risultati della classificazione sulla mappa UV (c).



Figura 7. Modello 3D classificato del Sarcofago degli Sposi: evidenziate in giallo le aree occupate da malta mimetica.

4.2 Tempio di Nettuno, parco archeologico di Paestum

Il tempio di Nettuno, costruito nell'antica polis di Paestum intorno alla metà del V secolo a.C., viene considerato tra gli esempi perfetti dell'architettura dorica templare in Italia e in Grecia. La nuvola di punti è il risultato di un rilievo fotogrammetrico con immagini acquisite da piattaforme UAV e terrestri (Fiorillo et al., 2013). La nuvola sotto-campionata, per migliorare le prestazioni computazionali, è costituita da circa 2.2 milioni di punti. Le classi semantiche del tempio sono state individuate e manualmente annotate su piccole porzioni della nuvola di punti (Figura 8). L'operazione di segmentazione manuale ai fini di annotazione ha richiesto all'operatore circa mezz'ora.




Figura 8. Nuvola di punti con classi annotate manualmente.

Le features geometriche significative per la distinzione degli elementi architettonici sono state estratte utilizzando CloudCompare (Hackel et al., 2016) (Figura 9).




Figura 9. Alcune features geometriche estratte sul dataset del Tempio: verticalità (a), onnivarianza (b), sfericità (c), variazione di superficie (d).

Preparato (in un'ora circa) il cosiddetto training set con classi annotate e features estratte, la classificazione è stata estesa all'intero dataset mediante i modelli predittivi Random Forest e CNN 2D.

Classificato il dato 3D, è possibile visualizzare le diverse classi semantiche separatamente. In previsione di un riutilizzo del dato segmentato in ambiente BIM, questa possibilità è particolarmente rilevante (Figura 10). Le tabelle 2 e 3 (situate al

termine dell'articolo) riportano le matrici di confusione e le metriche di precisione estratte rispettivamente con RF e CNN. In termini di precisione, i risultati ottenuti sono comparabili. In riferimento ai tempi di elaborazione, l'approccio Random Forest ha impiegato pochi minuti per classificare l'intero dataset, mentre la CNN ha richiesto circa 1 ora. Per vedere nel dettaglio la nuvola di punti, le features estratte e i risultati della classificazione è disponibile un video al seguente link:

<https://www.youtube.com/watch?v=8-muH633ud8&t=3s>




Figura 10. Risultato della classificazione geometry-based applicata alla nuvola del Tempio di Nettuno a Paestum.

4.3 Tomba Bartoccini

La tomba Bartoccini, risalente al IV secolo a.C., fu scoperta nel 1959 a Tarquinia (Italia). Nel 2013, un modello 3D completo e

texturizzato della tomba (Fernandez Jimenez et al., 2013) è stato ottenuto con tecniche integrate di rilievo reality-based. L'esposizione a diversi agenti atmosferici e fenomeni di umidità di risalita hanno compromesso nei secoli lo stato di conservazione della tomba, che presenta fenomeni di degrado superficiali e profondi sulle murature. La classificazione, in questo caso, ha avuto come obiettivo l'identificazione e la quantificazione delle superfici deteriorate presenti sulle pareti affrescate.

Applicando il metodo descritto alla Sezione 3.2 ed utilizzando features geometriche e radiometriche, sono state annotate in tempi ridotti (circa 10 minuti) piccole porzioni ben distribuite della nuvola di punti (Figura 12a). Il classificatore Random Forest ha, quindi, predetto la classificazione sull'intero dataset (Figura 12b). L'intera elaborazione ha richiesto circa un'ora di tempo. La decisione di combinare features geometriche e radiometriche ha due motivazioni:

- considerando la sola texture, sono emersi alcuni errori di classificazione dovuti alla somiglianza cromatica tra le superfici deteriorate e alcuni dipinti murali;
- utilizzando solo la geometria, è difficile identificare i degradi più superficiali.

Per valutare matematicamente le prestazioni della classificazione, è stata considerata una singola parete della tomba (Figura 11a), annotata manualmente (Figura 11b) e confrontata con i risultati della classificazione automatica (Figura 11c). È stato, dunque, calcolato il rapporto tra il numero di punti correttamente classificati ed il numero totale di punti:

$$Accuracy = \frac{N \text{ of point correctly classified}}{\text{total number of point}} \quad (5)$$




Figura 11. Test di validazione della tomba Bartoccini (a), annotata manualmente (b), classificata automaticamente (c).

Come risultato, è emerso che il 90% della previsione era corretto.




Figura 12. Nuvola di punti della tomba Bartoccini (circa 5 milioni di punti) con evidenziate le parti annotate manualmente (a); risultato della classificazione ottenuto utilizzando features geometriche e radiometriche (b). Dettaglio di un ambiente (c)(d).

Infine, sono state quantificate le superfici erose dell'intera tomba, calcolando la percentuale che ogni classe segmentata occupava rispetto alla superficie totale. La Tabella 1 riporta per ogni classe l'area occupata in termini di numero di punti, percentuale occupata e area in m². Questo tipo di risultato potrebbe significativamente migliorare la pianificazione di interventi di restauro o monitoraggio dello stato di conservazione della tomba. Un video sui risultati della classificazione della tomba di Batoccini è disponibile al seguente link: <https://www.youtube.com/watch?v=omI9xLroSDk&t=4s>

CLASSE	N° punti	% occupata	Area (m ²)
Superficie degradata	3539781	22.62%	42
Intonaco	11014402	70.38%	131
Infiltrazioni	1095229	7.00%	13
TOT	15649412	100.00%	186

Tabella 1. Misura in percentuale e m² delle aree occupate da ciascuna classe.

5. CONCLUSIONI

In questa ricerca sono stati sviluppati e testati diversi metodi di classificazione che permettono di arricchire semanticamente dati 3D appartenenti alla sfera dei beni culturali, lavorando sulla texture, sulla geometria 3D o combinando entrambe le informazioni. Risultati interessanti sono stati raggiunti in tempi di elaborazione ragionevoli rispetto ad un approccio manuale:

- Sarcofago degli sposi: partendo da un modello complesso, utilizzando la texture ad alta risoluzione, è stato possibile distinguere diversi stati di conservazione e stimare la quantità di malta cementizia mimetica utilizzata durante la ricomposizione del sarcofago etrusco. Questi risultati potrebbero aiutare studi sul processo di ricomposizione del manufatto o per monitorarne lo stato di conservazione. L'intero processo di classificazione ha richiesto circa 1 ora, con un input manuale di 10 minuti.
- Tempio di Nettuno: attraverso un'analisi dettagliata delle features geometriche (Grilli et al., 2019) ed un'accurata annotazione manuale di alcune porzioni della nuvola (20 minuti richiesti), è stato possibile ottenere in tempi brevi (RF 12 minuti, CNN circa un'ora) ottimi risultati di segmentazione semantica, sia utilizzando algoritmi machine che deep learning.
- Tomba Bartoccini: dopo aver individuato la migliore strategia per classificare il caso studio, la nuvola di 5 milioni di punti è stata interamente classificata in meno di un'ora, di cui 10 minuti sono stati dedicati all'annotazione manuale. L'accuratezza dei risultati calcolati su un set di prova ha dato come risultato una precisione della previsione del 90%. I risultati della classificazione permettono di calcolare la quantità di superfici deteriorate, fornendo informazioni utili in caso di futuri lavori di restauro.

Considerando i risultati presentati e le precedenti esperienze (Grilli and Remondino, 2019; Grilli et al., 2019), l'autore ritiene che, nel settore dei beni culturali, ogni caso di studio debba essere considerato singolarmente. Per ogni oggetto trattato è essenziale capire quali siano gli scopi della classificazione, le classi ricercate e il livello di dettaglio da raggiungere. La complessità dell'oggetto, dimensioni e caratteristiche materiche e colorimetriche, contribuiscono alla scelta della migliore metodologia da applicare (texture- o geometry-based).

BIBLIOGRAFIA

- Amato, G., Falchi, F. and Gennaro, C., 2015. Fast image classification for monument recognition. *Journal on Computing and Cultural Heritage (JOCCH)*, 8(4), p.18.
- 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.
- 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), p. 9.
- Breiman, L., 2001. Random forests. *Machine learning*, 45(1), pp. 5-32.
- Brodu, N. and Lague, D., 2012. 3D terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68, pp.121-134.
- Campanaro, D. M., Landeschi, G., Dell'Unto, N. and Touati, A.-M. L., 2016. 3D GIS for cultural heritage restoration: A 'white box' workflow. *Journal of Cultural Heritage*, 3, Volume 18, pp. 321-332.
- Chehata, N., Guo, L. and Mallet, C., 2009. Airborne lidar feature selection for urban classification using random forests. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(3/W8).
- Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., Benenson, R., Franke, U., Roth, S. and Schiele, B., 2016. The cityscapes dataset for semantic urban scene understanding. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3213-3223.
- ETH Zurich Random Forest Template, 2015. Available online: www.prs.igp.ethz.ch/research/Source_code_and_datasets.html (accessed on 15 May 2019).
- Fernández-Palacios, B.J., Rizzi, A. and Remondino, F., 2013. Etruscans in 3D-Surveying and 3D modeling for a better access and understanding of heritage. *Virtual Archaeology Review*, 4(8), pp.85-89.
- Fiorillo, F., Fernández-Palacios, B. J., Remondino, F., and Barba, S., 2013. 3D Surveying and modelling of the Archaeological Area of Paestum, Italy. *Virtual Archaeology Review*, Vol. 4(8), pp. 55-60.
- Giraudot, S. and Lafarge, F., 2019. Classification. In *CGAL User and Reference Manual*. CGAL Editorial Board, 4.14 edition.
- Grilli, E., Menna, F. and Remondino, F., 2017. A review of point clouds segmentation and classification algorithms. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, p.339.
- Grilli, E., Dinunno, D., Petrucci, G. and Remondino, F., 2018. From 2D to 3D supervised segmentation and classification for cultural heritage applications. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 42(2), pp. 399-406.
- Grilli, E. and Remondino, F., 2019. Classification of 3D Digital Heritage. *Remote Sensing*, 11(7), p.847.

- 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.
- Hackel, T., Wegner, J.D., Schindler, K., 2016. Fast semantic segmentation of 3D point clouds with strongly varying density. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. III(3), pp. 177-184.
- Hackel, T., Savinov, N., Ladicky, L., Wegner, J.D., Schindler, K. and Pollefeys, M., 2017. Semantic3d. net: A new large-scale point cloud classification benchmark. *arXiv preprint arXiv:1704.03847*.
- Korc, F. and Förstner, W., 2009. eTRIMS Image Database for interpreting images of man-made scenes. *Dept. of Photogrammetry, University of Bonn, Tech. Rep. TR-IGG-P-2009-01*.
- Llamas, J., Leronés, P. M., Zalama, E., and Gómez-García-Bermejo, J., 2016, October: Applying deep learning techniques to cultural heritage images within the INCEPTION project. In *Euro-Mediterranean Conference* (pp. 25-32). Springer, Cham.
- Malinverni, E. S., Pierdicca, R., Paolanti, M., Martini, M., Morbidoni, C., Matrone, F., and Lingua, A., 2019. Deep learning for semantic segmentation of 3D point cloud. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLII-2/W15, pp. 735-742.
- Menna, F., Nocerino, E., Remondino, F., Dellepiane, M., Callieri, M. and Scopigno, R., 2016. 3D digitization of a heritage masterpiece- A critical analysis on quality assessment. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41(B5).
- Oses, N., Dornaika, F., and Moujahid, A., 2014. Image-based delineation and classification of built heritage masonry. *Remote Sensing*, 6(3), pp 1863-1889.
- Ozdemir, E., Remondino, F., 2019a. Classification of aerial point clouds with deep learning. *Int. Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*. Proceedings Geospatial Week 2019, in press.
- Ozdemir, E., Remondino, F., 2019b. Aerial point cloud classification with deep learning and machine learning algorithms. *Int. Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*. Proceedings Geospatial Conference 2019, in press.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. and Vanderplas, J., 2011. Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 12(Oct), pp.2825-2830.
- Poux, F., Hallot, P., Neuville, R. and Billen, R., 2016. Smart Point Cloud: Definition and Remaining Challenges. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, Volume IV-2/W1, pp. 119-127.
- Roussel R., Bagnéris 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.
- Schindelin, J., Arganda-Carreras, I., Frise, E., Kaynig, V., Longair, M., Pietzsch, T., Preibisch, S., Rueden, C., Saalfeld, S., Schmid, B. and Tinevez, J.Y., 2012. Fiji: an open-source platform for biological-image analysis. *Nature methods*, 9(7), p.676.
- Sural, S., Qian, G. and Pramanik, S., 2002. Segmentation and histogram generation using the HSV color space for image retrieval. In *Proceedings. International Conference on Image Processing*, Vol. 2, pp. 589-592. IEEE.
- Teboul, O., Simon, L., Koutsourakis, P. and Paragios, N., 2010, June. Segmentation of building facades using procedural shape priors. In *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 3105-3112.
- Teboul, O., Kokkinos, I., Simon, L., Koutsourakis, P. and Paragios, N., 2013. Parsing facades with shape grammars and reinforcement learning. *IEEE transactions on pattern analysis and machine intelligence*, 35(7), pp.1744-1756.
- Tyleček, R. and Šára, R., 2013, September. Spatial pattern templates for recognition of objects with regular structure. In *German Conference on Pattern Recognition* (pp. 364-374). Springer, Berlin, Heidelberg.
- Wang, Y., Sun, Y., Liu, Z., Sarma, S.E., Bronstein, M.M. and Solomon, J.M., 2018. Dynamic graph CNN for learning on point clouds. *arXiv preprint arXiv:1801.07829*.
- Weinmann, M. and Weinmann, M., 2017. Geospatial Computer Vision Based on Multi-Modal Data - How Valuable Is Shape Information for the Extraction of Semantic Information? *Remote Sensing*, 10(1), p.2.
- Witten, I.H., Frank, E., Hall, M.A. and Pal, C.J., 2016. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann.

CLASS NAME	Erba	Crep.	Pavim.	Fusto	Echino	Abaco	Architr	Fregio	Cornice	Timp.	Prec.	Recall	F1
Erba	56998	1647	0	0	0	0	0	0	0	0	97.19%	99.88%	98.52%
Crepidoma	67	38389	484	497	0	0	0	0	0	0	97.34%	93.43%	95.34%
Pavimento	0	958	62211	993	0	0	0	0	0	0	96.96%	99.03%	97.98%
Fusto	0	54	125	169950	172	56	4	0	268	0	99.60%	98.49%	99.04%
Echino	0	0	0	966	18717	988	4	0	40	0	90.35%	86.62%	88.45%
Abaco	0	0	0	63	2651	23941	3998	0	636	0	76.52%	87.54%	81.66%
Architrave	0	0	0	0	0	2140	50903	2600	1	0	91.48%	90.84%	91.16%
Fregio	0	0	0	0	0	0	1036	34609	334	33	96.10%	79.98%	87.31%
Cornice	0	42	0	90	67	223	90	4569	106415	2071	93.70%	95.41%	94.55%
Timpano	0	0	0	0	0	0	4	1492	3841	21393	80.03%	91.05%	85.19%
AVERAGE											91.93%	92.23%	91.92%

Tabella 2. Matrice di confusione e metriche di precisione ottenute dalla classificazione con Random Forest.

CLASS NAME	Erba	Crep.	Pavim.	Fusto	Echino	Abaco	Architr	Fregio	Cornice	Timp.	Prec.	Recall	F1
Erba	57429	1216	0	0	0	0	0	0	0	0	97.93%	99.77%	98.84%
Crepidoma	133	38380	283	641	0	0	0	0	0	0	97.32%	93.77%	95.51%
Pavimento	0	1256	61923	983	0	0	0	0	0	0	96.51%	99.05%	97.77%
Fusto	0	77	110	169830	233	102	0	0	277	0	99.53%	97.46%	98.48%
Echino	0	0	0	1326	17857	894	0	0	638	0	86.20%	78.97%	82.43%
Abaco	0	0	0	92	3899	24390	2189	0	719	0	77.95%	78.26%	78.11%
Architrave	0	0	0	9	200	5402	49168	752	113	0	88.36%	87.52%	87.94%
Fregio	0	0	0	0	0	14	4724	31047	196	31	86.21%	73.33%	79.25%
Cornice	0	0	197	1378	423	363	98	7222	102117	1769	89.92%	94.85%	92.32%
Timpano	0	0	1	0	0	0	0	3316	3597	19816	74.13%	91.67%	81.98%
AVERAGE											89.41%	89.47%	89.26%

Tabella 3. Matrice di confusione e metriche di precisione ottenute dalla classificazione con CNN 2D.