

# Individuazione automatica di forme di alterazione e degrado da immagini iperspettrali tramite algoritmi di *machine learning*: il caso studio del patrimonio olivettiano

Luca Montemaggi<sup>1</sup>, Francesca Matrone<sup>2</sup> [0000-0002-9160-1674], Andrea Maria Lingua<sup>2</sup> [0000-0002-5930-2711], Sara Fasana<sup>1</sup> [0000-0002-0445-7484]

<sup>1</sup> Dipartimento di Ingegneria Strutturale, Edile e Geotecnica (DISEG), Politecnico di Torino, C.so Duca degli Abruzzi 24, 10129, Torino ([s302043@studenti.polito.it](mailto:s302043@studenti.polito.it), [sara.fasana@polito.it](mailto:sara.fasana@polito.it)).

<sup>2</sup> Dipartimento di Ingegneria dell'Ambiente, del Territorio e delle Infrastrutture (DIATI), Politecnico di Torino, C.so Duca degli Abruzzi 24, 10129, Torino ([francesca.matrone@polito.it](mailto:francesca.matrone@polito.it), [andrea.lingua@polito.it](mailto:andrea.lingua@polito.it))

## 1 Introduzione

Il rilievo dei fenomeni di degrado e delle alterazioni riveste un ruolo chiave per la gestione e la manutenzione del patrimonio costruito. Recentemente, grazie al rapido sviluppo delle tecnologie di Intelligenza Artificiale (IA) e della GeoAI (*Geospatial AI*), il riconoscimento automatico di tali degradi costituisce un task di vitale interesse per la comunità scientifica e per i professionisti del settore del patrimonio architettonico. Ad oggi, la maggior parte di queste sperimentazioni è stata condotta su edifici e infrastrutture preindustriali [1] [2], lasciando parzialmente inesplorata l'applicazione delle stesse tecnologie su opere più recenti, caratterizzate da materiali e patologie diversi. La presente ricerca si propone quindi di affrontare questa tematica, sperimentando l'utilizzo dell'IA su un edificio costruito alla fine degli anni '50 e riconosciuto patrimonio UNESCO nel 2018: la ex Centrale Termica Olivetti, parte del sistema "Ivrea Città Industriale del XX secolo". In particolare, il focus della ricerca è costituito dalle piastrelle in klinker caratterizzanti il rivestimento dell'edificio, il cui rilievo è stato eseguito con una camera iperspettrale.

La metodologia proposta ha testato le prestazioni di diversi algoritmi di *deep learning* per la classificazione supervisionata e apre nuove prospettive per una valutazione critica dei risultati ottenuti dalla segmentazione automatizzata delle piastrelle in klinker.

## 2 Metodologia

Il rilievo ha visto come oggetto di studio la ex – Centrale Termica Olivetti. È stato dapprima condotto un rilievo 3D metrico integrato con tecniche topografiche classiche, UAV (*Unmanned Aerial Vehicles*) come il DJI Mavic3 multispettrale, laser scanner Leica RTC360 e camera iperspettrale Rikola di Senop. Quest'ultima ha un range dai 500 ai 900 nm, 380 canali spettrali, una risoluzione spettrale di 1 nm ed una spaziale di 1010x1010 pixel [3]. Durante la campagna di rilievo sono state scattate 11 immagini

iperspettrali ritraenti il rivestimento esterno all'angolo Nord-Ovest dell'edificio (Fig. 1a). La camera è stata impostata per rilevare 100 bande tra i 506.31 nm e i 902.39 nm, con un passo di circa 3.96 nm, impostando diversi valori ISO per gli scatti "A-B-C" al fine di ottimizzare l'esposizione delle immagini, viste le condizioni di illuminazione diretta date dall'orario pomeridiano.

I dati sono stati quindi elaborati in due fasi: i) elaborazione della nuvola di punti RGB che ha fornito la base per il processo scan-to-BIM, ii) elaborazione delle immagini multispettrali e iperspettrali.

Ai fini della mappatura del degrado e delle alterazioni sono state analizzate le ortofoto estratte dai dati multispettrali per studiare fenomeni di umidità, ossidazione, colatura e agenti biodeteriogeni. In secondo luogo, utilizzando il software ArcGIS Pro di ESRI, sono stati impiegati algoritmi di segmentazione supervisionata (*SVM*, *Maximum Likelihood*, *Random Forest*, *K-Nearest Neighbours*) per il riconoscimento degli elementi in facciata, e non supervisionata, al fine di individuare nel rivestimento in klinker possibili fenomeni in essere non chiaramente identificabili ad occhio nudo (Fig. 1b), indicando specifici elementi da indagare sul campo nelle campagne future.



**Fig. 1a e 1b:** a) *Keymap* delle acquisizioni con la fotocamera iperspettrale "Rikola"; b) angolo Nord-Ovest della ex-Centrale Termica con evidenziate le aree inquadrare.

### 3 Elaborazione

#### 3.1 Classificazione supervisionata: schemi di classificazione e ROI

Il primo step della classificazione supervisionata prevede la creazione degli schemi di classificazione. Sebbene teoricamente sia sufficiente avere due sole classi – “Klinker” e “Contesto” si è preferito dettagliare lo schema di classificazione con tutte le tipologie di materiali ritratti in scena, migliorando l'output di classificazione [5]. Oltre, quindi, alle classi di “Klinker rosso” e “Klinker blu”, sono state individuate ulteriori classi di contesto, come illustrato ad esempio in Fig. 2. I criteri che ha invece

guidato l'individuazione delle ROI (*region of interest*) sono stati due: (I) classificare punti appartenenti alla stessa classe in modo uniforme su tutta l'immagine, (II) ricercare una buona rappresentanza della singola classe termini di pixel classificati sul totale [6]. Sono state riscontrate alcune difficoltà nell'assicurare il secondo criterio per le classi "Malta" e "Mosaico", a causa della loro ridotta estensione abbinata ad una bassa risoluzione dell'immagine.

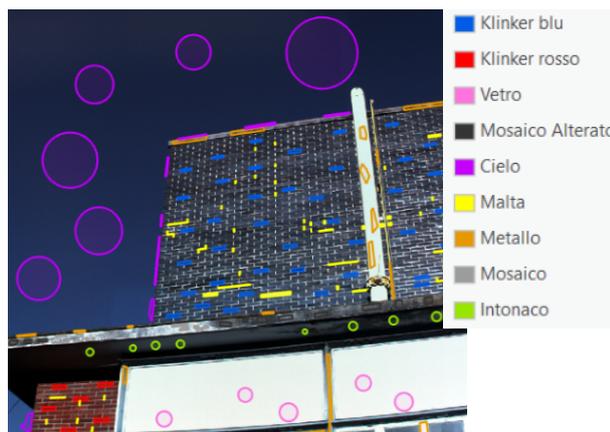


Fig. 2: Schema dei campioni di formazione ed individuazione delle ROI.

### 3.2 Classificazione supervisionata: test degli algoritmi e risultati

Il software ESRI ArcGIS Pro mette a disposizione quattro diversi algoritmi di *deep learning* [7]:

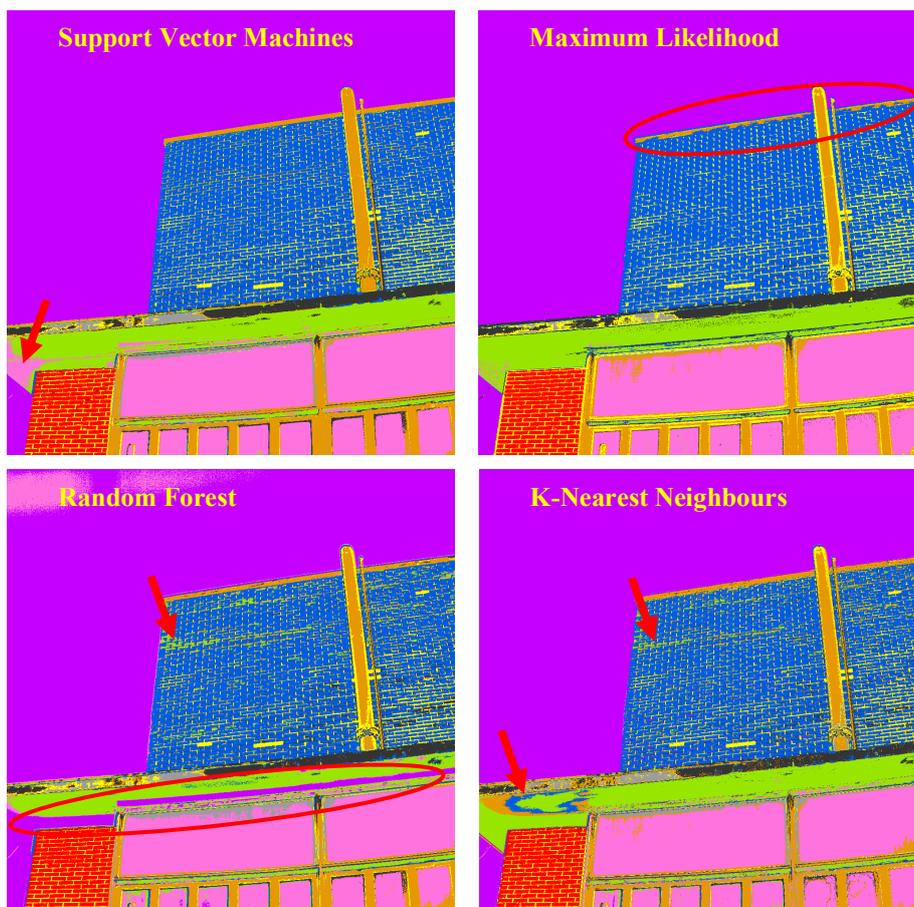
- a. Support Vector Machine – SVM
- b. Maximum Likelihood
- c. Random Forest
- d. K-Nearest Neighbours

È stata quindi valutata la loro efficacia nella segmentazione delle immagini facendo loro eseguire una classificazione dell'immagine "IVREA\_3\_20" e confrontando i risultati di *Accuracy* e "K di Cohen" ottenuti dal calcolo delle matrici di confusione [8]. Tuttavia, non potendo disporre di un dataset di test a causa del limitato numero di acquisizioni effettuate, al fine di ridurre i fenomeni di *overfitting* che possono alterare la validazione dei risultati, si è adottata la seguente metodologia:

- a. Individuazione di nuove ROI costituenti la *groundtruth* e quindi diverse da quelle precedentemente impiegate per il training degli algoritmi
- b. Generazione di 10000 *Accuracy Assessment Points*, ovvero i punti nei quali si registreranno i valori di *groundtruth* (dati dalle nuove ROI) e la classe indicata dalla classificazione
- c. Calcolo e confronto delle matrici di confusione

Osservando i valori di "K di Cohen", è possibile notare come gli algoritmi SVM e Maximum Likelihood offrano delle *performance* superiori (rispettivamente 93.5% e

92%). L'analisi, infine, della *Accuracy* per le classi chiave “C\_1 – Klinker blu” e “C\_2 – Klinker rosso” evidenzia una eccellente classificazione da parte di entrambi gli algoritmi per le piastrelle di color rosso, con valori pari o prossimi al 100%, mentre un leggero divario tra i due nell'individuare le piastrelle in klinker blu, classificate dal metodo SVM con una *Accuracy* di 96.4% e con il 90.4% dal Maximum Likelihood. Per tali ragioni il metodo Support Vector Machines è stato impiegato nella classificazione dell'intero dataset di immagini a disposizione.



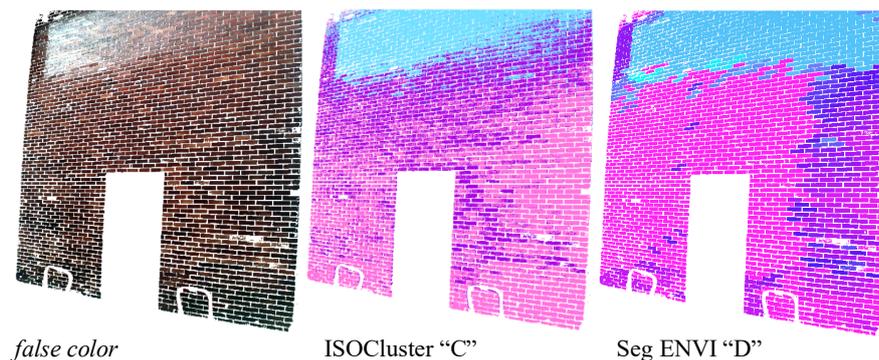
**Fig. 3:** Quattro output di segmentazione ottenuti dai diversi metodi di classificazione supervisionata. Vengono indicati i principali errori di classificazione.

### 3.3 Classificazione non supervisionata

L'ultima fase del lavoro ha visto la classificazione non supervisionata delle piastrelle in Klinker rosso e blu. Anche in questo caso sono stati sperimentati due algoritmi diversi, l'ISOCluster e l'algoritmo di segmentazione proprietario ENVI (di seguito

abbreviato con “Seg ENVI”) su diversi set di immagini. Si riportano qui di seguito due tra i casi più significativi, ossia un’immagine a terra del lato Nord (Fig. 4), ritraente la texture di piastrelle in Klinker rosse attorno a una porta, dove la minore distanza di presa ha permesso una classificazione più accurata delle fughe di malta, e una delle immagini della parte alta dell’edificio (Fig. 5). L’analisi e comparazione delle classificazioni per la prima immagine hanno portato alle seguenti osservazioni:

- entrambi gli algoritmi hanno individuato due classi differenti per le piastrelle soggette a fenomeni di riflessione (colore “azzurro” in Fig. 4) da quelle invece in cui la condizione d’illuminazione non ha influito sulla presa: l’analisi delle firme iperspettrali delle piastrelle soggette a riflessione e quelle non soggette ha infatti evidenziato una diversa distribuzione dei valori radiometrici nel range spettrale 506.31 – 600 nm;
- le piastrelle non interessate dal fenomeno di riflessione sono state classificate dai due algoritmi in modo non omogeneo ed univoco, rendendo difficile individuare un *pattern* comune di segmentazione;
- l’immagine restituita dall’algoritmo ISOCluster non risulta essere particolarmente indicativa ai fini dell’individuazione di potenziale degrado, a causa di una divisione in classi eterogenea, probabilmente influenzata dalla naturale variazione cromatica delle piastrelle, ottenute da un processo di lavorazione semi-artigianale [9];
- facendo riferimento all’output ottenuto dalla Seg ENVI, si nota la creazione di classi omogenee e distinte dalla restante parte del rivestimento in particolare sul lato destro del paramento murario e nel primo metro da terra. In seguito a tale risultato si cercherà di indagare sul campo l’eventuale presenza di forme di degrado quali la formazione di patine biologiche e alterazione cromatica, probabilmente favorite da una maggiore esposizione agli agenti atmosferici e all’umidità di risalita.



**Fig. 4:** Da sinistra verso destra, l’immagine iperspettrale in *false color*, un output ISOCluster con impostazioni “C” (vedi Tab 1) e la Seg ENVI “D” (vedi Tab.2).

Tab. 1: parametri ISOCluster

Tentativo	C
Max n° of Classes	<b>3</b>
Max n°of Iterations	20
Max n° of Cluster	5
Merges x iteration	
Maximum Merge Distance	0.5
Max samples x cluster	20
Skip Factor	1

Tab. 2: parametri Seg ENVI

Tentativo	D
Spectral Detail	5
Spatial detail	1
Minimum segment size in pixel	<b>500</b>

Per quanto riguarda invece i risultati ottenuti dalle classificazioni dell'immagine della parte alta (Fig. 5) si è potuto osservare che:

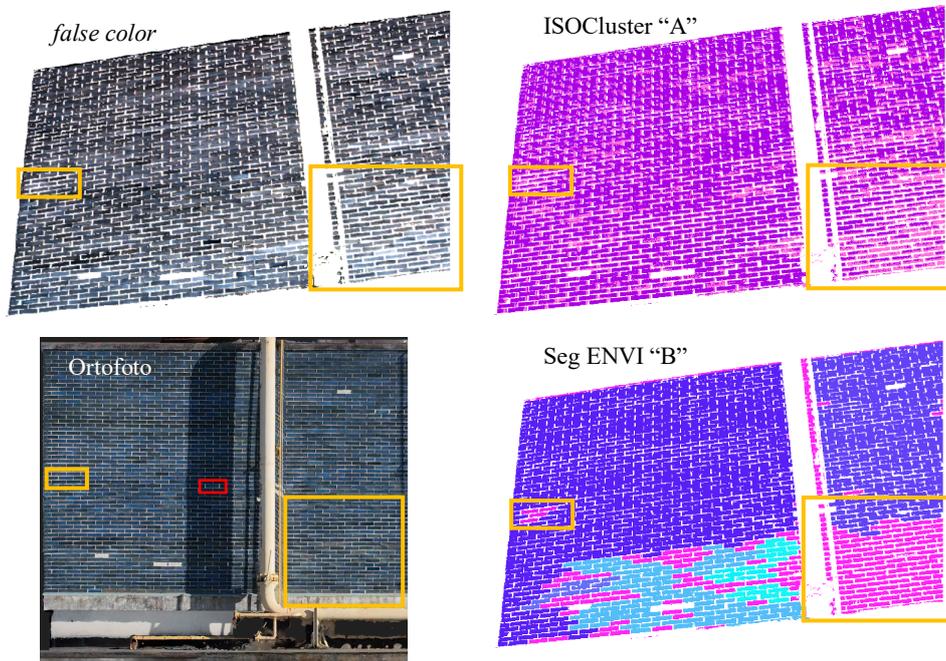
- l'analisi eseguita mediante ISOCluster, sebbene abbia classificato i klinker in modo eterogeneo come nel caso precedente, ha consentito di individuare almeno due aree dove prevale chiaramente una delle due classi;
- la Segmentazione ENVI ha invece nettamente diviso il paramento murario in tre principali aree, operando una chiara separazione tra le piastrelle situate nella parte inferiore da quelle locate nella parte superiore della struttura;
- l'analisi comparata dei due output evidenzia in questo caso almeno due analogie: essi sono concordi nel creare una classe distinta per le piastrelle sul lato destro inferiore dell'immagine e, ancora più interessante, separano nettamente un piccolo agglomerato di piastrelle da quelle a loro contigue sul lato sinistro, suggerendo di indagare sul campo la presenza di patologie in essere e non visibili all'occhio umano;
- non viene invece individuata come differente una piastrella di cui è evidente, per via delle dimensioni diverse, che si tratti di un elemento sostitutivo, probabilmente proveniente da un fondo di riserva di un altro edificio olivettiano: anche tentando di aumentare il peso dello *Spatial detail* nella Segmentazione ENVI non sono stati ottenuti risultati rilevanti.

Tab. 3: parametri ISOCluster

Tentativo	A
Max n° of Classes	2
Max n°of Iterations	20
Max n° of Cluster	5
Merges x iteration	
Maximum Merge Distance	0.5
Max samples x cluster	20
Skip Factor	1
Note	Pattern distinguibile

Tab. 4: parametri Seg ENVI

Tentativo	B
Spectral Detail	5
Spatial detail	1
Minimum segment size in pixel	<b>1000</b>
Note	Leggera riduzione del numero di classi



**Fig. 5:** Confronto tra i diversi set di dati disponibili; si evidenziano con i rettangoli arancioni i pattern di classificazione comuni ai due algoritmi, mentre nell'ortofoto RGB si evidenzia con il rettangolo rosso la piastrella oggetto di sostituzione.

## 4 CONCLUSIONI

Il presente lavoro ha affrontato il tema del riconoscimento automatizzato dei degradi a cui sono soggetti gli edifici del Novecento, con un focus particolare sul klinker, un materiale di rivestimento che ha caratterizzato l'architettura del secondo dopoguerra. La classificazione supervisionata condotta sui quattro set di immagini iperspettrali ha portato, in due casi, a risultati soddisfacenti con gli algoritmi *Support Vector Machine* e *Maximum Likelihood*: mediante calcolo delle matrici di confusione sono emersi valori di "K di Cohen" superiori a 0.9 e *accuratezza* superiori al 95% nel riconoscimento delle classi di "klinker". La classificazione sui ulteriori set di dati ha invece evidenziato alcuni fattori che possono influenzare negativamente la segmentazione, come una eccessiva distanza di presa, angoli di presa troppo ampi rispetto al piano oggetto di studio, le condizioni di illuminazione non omogenee e gli errori nel settaggio dei valori di ISO del sensore.

I tentativi successivi di classificazione non supervisionata delle piastrelle in klinker sono stati condotti sperimentando due algoritmi: l'ISOCluster e la "Segmentazione ENVI". Sebbene non sia stato possibile riconoscere un *pattern* comune di

classificazione nel caso dell'immagine della parte bassa dell'edificio, è stato comunque possibile avanzare ipotesi sulle patologie in essere su alcune piastrelle; nel caso dell'immagine della parte alta si è potuto invece individuare più chiaramente delle aree potenzialmente soggette a fenomeni di degrado e che dovranno essere indagate sul campo grazie agli *output* simili ottenuti con i due algoritmi.

I risultati ottenuti indicano pertanto le aree da indagare ulteriormente in un secondo sopralluogo, il quale permetterà di determinare le eventuali patologie in essere e di procedere con la determinazione delle loro firme iperspettrali. Tali informazioni saranno poi inserite all'interno di un modello HBIM dell'edificio, per poter essere in futuro interrogate, eventualmente confrontate con nuove acquisizioni e contribuire a un piano di manutenzione programmata di questo patrimonio.

## Ringraziamenti

Studio condotto nell'ambito di FAIR - *Future Artificial Intelligence Research* finanziato dall'Unione Europea – Next-GenerationEU (PIANO NAZIONALE DI RIPRESA E RESILIENZA (PNRR) – MISSIONE 4 COMPONENTE 2, INVESTIMENTO 1.3 - D.D. 1555 11/10/2022, PE00000013). I punti di vista e le opinioni espresse sono tuttavia solo quelli degli autori e non riflettono necessariamente quelli dell'Unione europea o della Commissione europea. Né l'Unione Europea né la Commissione Europea possono essere ritenute responsabili per essi.

## Riferimenti bibliografici

1. Chun, Y.G.; Lee, M.S.; Kim, Y.R.; Lee, M.H.; Choi, M.J.; Choi, K.H.: Utilization of hyperspectral image analysis for monitoring of stone cultural heritages. *Journal of Conservation Science* 31 (4), 395-402 (2015).
2. Adamopoulos, E.: Learning-based classification of multispectral images for deterioration mapping of historic structures. *Journal of Building Pathology and Rehabilitation* 6 (41), - (2021).
3. Rikola di Senop, 2024, <https://senop.fi/optics-imaging/hyperspectral-imaging/>
4. Amano, K.; Lou, E.C.W.; Edwards, R.: Integration of point cloud data and hyperspectral imaging as a data gathering methodology for refurbishment projects using building information modelling (BIM). *Journal of Facilities Management* 17 (1), 57-75 (2019).
5. Musci, M.A.; Mazzara, L.; Lingua, A.M.: Ice detection on aircraft surface using machine learning approaches based on hyperspectral and multispectral images. *Drones* 4 (45), - (2020).
6. John A. Richards.: "Supervised Classification Techniques" in *Remote sensing Digital Image Analysis* (6), di John A. Richards, Springer International Publishing, 2022, 340 – 341
7. Alnuaimi, A.F.A.H.; Albaldawi, T.H.K.: An overview of machine learning classification techniques. *BIO Web Conference* 97, - (2024).
8. Russel G. Congalton; Kaas Green: *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, Terza Edizione, New York, CRC Press, 2019
9. Zerbinatti, M.; Giacomelli, E.; Gualtieri, S.: *Color in Modern Architecture of Olivetti's Town*. *Color Research & Application* 49 (1), settembre 2023, 144 – 162 (2023).