



CONVEGNO FABRE
PONTI, VIADOTTI, E GALLERIE ESISTENTI:
RICERCA, INNOVAZIONE E APPLICAZIONI
LUCCA, 2-4 FEBBRAIO 2022



Reti neurali convoluzionali per la classificazione di difetti in galleria

G. Marasco^a, S. Aiello^a, M.M. Rosso^a, B. Chiaia^a, G. Cirrincione^b, G.C. Marano^a

^a Politecnico di Torino, DISEG, Dipartimento di Ingegneria Strutturale, Edile e Geotecnica, Corso Duca Degli Abruzzi, 24, Torino 10129, Italia

^b Università di Picardie Jules Verne, Lab. LTI, Amiens, Francia.

Parole chiave: Gallerie – Trasformata di Fourier – Reti neurali convoluzionali – Monitoraggio strutturale – Georadar

SOMMARIO

L'elaborazione di piani per il controllo e la gestione del patrimonio infrastrutturale è uno dei temi su cui il mondo accademico e ingegneristico sta focalizzando attenzione e risorse e rappresenta una delle sfide più importanti, in questo periodo storico, per la maggior parte dei paesi sviluppati. Questi ultimi, infatti, devono affrontare le problematiche relative all'invecchiamento di infrastrutture ormai prossime alla fine della loro vita utile. In un'ottica di ottimizzazione delle risorse disponibili ai fini manutentivi, il presente studio propone un approccio per automatizzare il processo di classificazione dei difetti in galleria. A partire da una campagna di indagini non distruttive attraverso il georadar (GPR), l'applicazione della trasformata di Fourier 2D ai profili GPR e il successivo impiego di reti neurali convoluzionali ha permesso di classificare, con elevata accuratezza, un'ampia gamma di difetti strutturali (e.g., fratture, vuoti, anomalie, ecc.). La metodologia proposta elimina la necessità dell'interpretazione umana dei profili GPR e dell'utilizzo di indagini integrative (e.g., video-endoscopie, carotaggi, prove con martinetti e di pull-out) ai fini della classificazione della tipologia di problematica strutturale. Di conseguenza, tale approccio è caratterizzato da una significativa velocità e affidabilità che lo rendono efficiente e competitivo per i tempi e i costi associati al suo utilizzo.

1 INTRODUZIONE

Lo sviluppo di sistemi automatizzati per il monitoraggio dello stato strutturale delle infrastrutture è fondamentale per l'implementazione di piani di manutenzione efficienti, economicamente sostenibili ed in grado di garantire un elevato livello di sicurezza [1,2,3,4,5,6,7]. L'estensione del patrimonio infrastrutturale da controllare è tale da rendere necessario lo sviluppo di programmi di monitoraggio della salute strutturale, dall'acronimo inglese *Structural Health Monitoring* (SHM). Questi ultimi devono essere robusti, affidabili e produrre tempestivi allarmi in particolar modo per grandi opere, come ponti [8] e gallerie [9], che hanno una cruciale importanza e un alto impatto nel contesto sociale ed economico odierno. Focalizzando l'attenzione sulle gallerie che si collocano su suolo italiano,

emerge che il numero di esse in prossimità della fine della vita utile definita da progetto, e quindi ad alto rischio, è elevato. Le caratteristiche originali di queste opere possono aver subito variazioni irreversibili, a causa di fenomeni di degrado e/o danni strutturali a cui l'opera è stata soggetta, in grado di provocare l'insorgere di eventi catastrofici. Alla luce di ciò, l'esclusivo utilizzo delle tradizionali tecniche ispettive risulta insufficiente e inefficace [11]. Infatti, tali tecniche richiedono un rilevante investimento di tempo e di denaro dato che si basano sul giudizio umano e sull'impiego di personale altamente specializzato [12].

Ai fini del superamento delle limitazioni fin qui messe in luce, il compito di rilevare la presenza e la natura del potenziale deterioramento delle infrastrutture è spesso affidato ad algoritmi di monitoraggio strutturale incentrati sul riconoscimento delle immagini [13]. In particolare, una delle tecniche che ha mostrato

una notevole efficacia in questo contesto si basa sull'uso di reti convoluzionali, dall'acronimo inglese *Convolutional Neural Networks* (CNNs), che sfruttano processi di *transfer learning*, ossia processi di apprendimento avanzati che permettono il riutilizzo di modelli già addestrati per lo svolgimento di differenti attività [14]. Questa tecnica, se applicata ai risultati dei test di prove non distruttive, dall'acronimo inglese *Non-Destructive testing* (NDT), può fornire un valido supporto nell'identificazione e nella classificazione dei difetti. Il georadar, dall'acronimo inglese *Ground Penetrating Radar* (GPR), è uno tra i metodi non distruttivi più usati in tale ambito dato che permette il superamento delle limitazioni delle procedure di ispezione visiva che sono adatte solo a rilevare difetti superficiali [15]. Tuttavia, l'analisi dei dati GPR è generalmente computazionalmente onerosa in quanto tali dati vengono tipicamente memorizzati e successivamente elaborati *off-line* ed interpretati manualmente da parte di personale tecnico specializzato [16]. Il presente articolo illustra i risultati estratti da una metodologia automatica di classificazione dei difetti a partire dai profili GPR. Inoltre, è stato effettuato un confronto tra i risultati ottenuti considerando come input i dati grezzi e i dati pre-elaborati attraverso l'uso della trasformata di Fourier bidimensionale (2D-TF). I risultati raggiunti appaiono promettenti e incoraggianti nell'ottica di ulteriori ed innovativi sviluppi.

2 MONITORAGGIO DELLE GALLERIE STRADALI CON IL GEORADAR

In letteratura sono molteplici le metodologie sperimentali non distruttive proposte per la caratterizzazione dei difetti nei materiali d'uso ingegneristico [17]. Tra queste, nell'ambito del presente studio, è stata selezionata la tecnica basata sul georadar [18]. Tale strumento risulta essere particolarmente utile per il rilevamento, la localizzazione e la classificazione dei danni grazie alla facilità d'uso, di trasporto e alla capacità di penetrazione che lo caratterizzano [19]. Il georadar è basato su una tecnica di tipo geofisico [20] caratterizzata dalla trasmissione di impulsi di onde elettromagnetiche ad alta frequenza (da 10 a 2600 MHz) nel materiale indagato. La propagazione di tale impulso è influenzata dalle caratteristiche dielettriche del materiale.

La campagna di indagine tramite GPR, oggetto del presente studio, è stata effettuata su gallerie italiane, datate tra il 1890 e il 1992, utilizzando

due tipologie di strumentazione, le cui caratteristiche tecniche sono riportate nelle Tabelle 1 e 2. La prima tipologia è caratterizzata da un'antenna a doppia frequenza, la seconda da una ad alta frequenza.

Tabella 1. Caratteristiche tecniche del GPR con antenna a doppia frequenza.

GPR con antenna a doppia frequenza	valore
Numero minimo di canali	4
Frequenza di ripetizione degli impulsi (kHz)	400
range (nsec)	0-9999
potenza (Volt)	12
antenna primaria a doppia frequenza (MHz)	400-900
antenna secondaria a doppia frequenza (MHz)	200-600

Tabella 2. Caratteristiche tecniche del GPR con antenna a doppia frequenza.

GPR con antenna ad alta frequenza	valore
Numero minimo di canali	4
Frequenza di ripetizione degli impulsi (kHz)	400
range (nsec)	0-9999
min. numero di scans/secondo	400
potenza (Volt)	12
antenna ad alta frequenza	≥ 2

I profili GPR presentano la profondità dello spessore esaminato lungo l'asse verticale e la distanza progressiva dall'inizio della galleria, oggetto di investigazione, lungo l'asse orizzontale. Alla fine dello svolgimento della campagna d'indagine, ogni profilo GPR è stato interpretato manualmente da personale tecnico specializzato al fine di individuare e classificare varie tipologie di difetti che possono essere identificate mediante tale tecnica. Un esempio di profilo GPR con interpretazione dei difetti è riportato nella Figura 1.

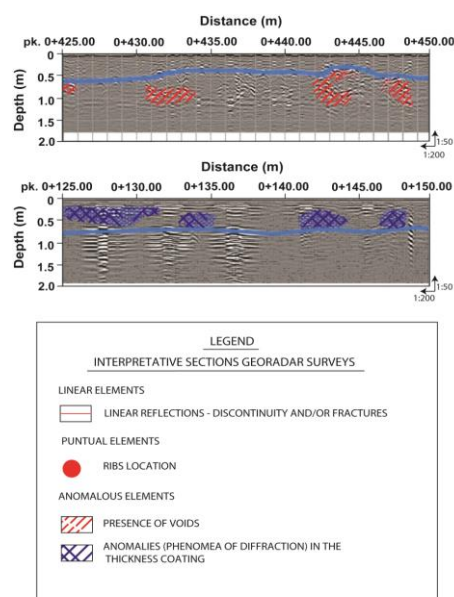


Figura 1. Un esempio di profilo GPR con interpretazione manuale delle tipologie di difetti da parte di personale tecnico specializzato.

3 TRASFORMATA DI FOURIER BIDIMENSIONALE PER L'ELABORAZIONE DELLE IMMAGINI

La trasformata di Fourier (TF) è uno degli strumenti più diffusi per l'elaborazione dei segnali che ne consente la decomposizione nelle componenti armoniche fondamentali. Inoltre, la sua applicazione permette di cambiare il dominio di indagine attraverso una mappatura che implica il passaggio dal dominio in ingresso (spaziale o temporale) al dominio di Fourier o di frequenza in uscita. Quando si analizzano fenomeni di natura continua, attraverso la TF, il segnale può essere espresso come una somma infinita di armoniche a diverse frequenze, ciascuna caratterizzata da un certo peso in base al contenuto di frequenza di quella armonica nella realizzazione del segnale considerato. Tuttavia, nella pratica non è mai possibile considerare fenomeni di natura continua, in quanto anche con la più sofisticata strumentazione, i dati vengono sempre raccolti in maniera discreta attraverso un processo di campionamento. Il teorema del campionamento di Nyquist-Shannon afferma che qualsiasi segnale continuo può essere ricostruito univocamente in modo affidabile a partire dai suoi dati campionati quando la frequenza di campionamento è almeno il doppio della frequenza di Nyquist. Quest'ultima rappresenta quindi la frequenza più alta che è possibile ricostruire a partire da un segnale campionato [21]. Per poter continuare a operare con la TF, anche in presenza di segnali campionati discreti, è stata pertanto sviluppata la versione discreta della stessa (DTF).

Considerando un'immagine digitale, essa è rappresentata da una matrice di pixel, o in generale da un tensore, e ciascun pixel contiene determinati valori interi. Un'immagine in scala di grigi con precisione a 8 bit, appare come una matrice in cui ogni pixel può assumere un valore intero tra 0 e 255. D'altra parte, in un'immagine a colori con codifica RGB (rosso-verde-blu), le informazioni di ogni pixel sono rappresentate da un tensore con profondità pari a 3 dimensioni (uno per ciascun canale di colore RGB). Pertanto, ogni pixel è rappresentato da tre byte dato che ogni canale di colore può assumere valori interi compresi tra 0 e 255 [22]. Senza perdita di generalità, le informazioni contenute in un'immagine possono pertanto essere interpretate come un insieme di segnali bidimensionali [23]. Dunque, la TF può essere adottata per decomporre un segnale 2D discreto (immagine digitale) nelle sue componenti sinusoidali principali. Come conseguenza del teorema del

campionamento, solo un certo numero di armoniche può essere ottenuto. È necessario che tali armoniche siano in numero sufficiente per descrivere le informazioni contenute nell'immagine [24]. Considerando un'immagine digitale nel dominio spaziale A di dimensioni $n \times m$ con componenti r e s , con $0 \leq r \leq n-1$, $0 \leq s \leq m-1$, la 2D-DTF risulta essere una matrice F nel dominio di Fourier di dimensioni $n \times m$ con componenti [24] $f(k,l)$ espresse come segue:

$$f(k,l) = \sum_{r=0}^{n-1} \sum_{s=0}^{m-1} a(r,s) e^{-2\pi i \left(\frac{kr}{m} + \frac{ls}{n} \right)} \quad (1)$$

dove $0 \leq k \leq n-1$, $0 \leq l \leq m-1$.

La 2D-DTF, in pratica, esegue una somma dei prodotti dell'input dell'immagine spaziale con le funzioni base sinusoidali, espresse in forma esponenziale complessa. Il termine $f(0,0)$ denota la componente di corrente continua DC che rappresenta la luminosità media dell'immagine in ingresso. L'ultima realizzazione è associata alla $f(n-1, m-1)$ che corrisponde a quella con componente di frequenza più alta [24]. L'equazione inversa per la 2D-DTF è definita mediante la seguente formula:

$$a(r,s) = \frac{1}{n \cdot m} \sum_{k=0}^{n-1} \sum_{l=0}^{m-1} f(k,l) e^{2\pi i \left(\frac{kr}{m} + \frac{ls}{n} \right)} \quad (2)$$

Per ridurre lo sforzo computazionale è possibile dimostrare che la 2D-DTF può essere analizzata come una serie di $2n$ TF unidimensionali [24]; questo processo comporta, tuttavia, una complessità computazionale pari a $O(n^2)$. Lo sviluppo della *Fast Fourier Transform* (2D-FTF) ha permesso di ridurre questa complessità a $O(n \log_2(n))$.

La trasformata di Fourier fornisce una matrice complessa che può essere analizzata sia attraverso le componenti reali e immaginarie, sia in termini di ampiezza e fase. Quest'ultima non viene utilizzata spesso dato che la maggior parte delle informazioni è contenuta nell'ampiezza. Tuttavia, con la trasformata inversa risulta fondamentale considerare anche la fase onde evitare una ricostruzione corrotta dell'immagine [24]. Inoltre, la maggior parte delle informazioni sono contenute all'interno delle componenti a bassa frequenza. A causa della forte dispersione dei valori dell'ampiezza su diversi ordini di grandezza, viene spesso applicata una trasformazione logaritmica per migliorare la risoluzione delle informazioni:

$$\tilde{f}(k,l) = c \log(1 + |M_{k,l}|) \quad (3)$$

dove c è un fattore di scala impostato all'unità nel presente studio, e

$$M_{k,l} = \sqrt{\operatorname{Re}(f(k,l))^2 + \operatorname{Im}(f(k,l))^2} \quad (4)$$

rappresenta il modulo di $f(k,l)$ per ogni pixel nel dominio della frequenza. Nell'ambito del nostro studio, la proprietà di convoluzione risulta essere la più importante dato che l'operazione di convoluzione nel dominio di ingresso diventa una semplice moltiplicazione nel dominio di Fourier. Il processo di elaborazione delle immagini è caratterizzato dall'applicazione di filtri digitali con lo scopo di eliminare le alte frequenze o rilevare i bordi rimuovendo le basse frequenze [24]. Queste operazioni sono svolte attraverso una funzione kernel (o filtro) $h(r,s)$ che scorre sull'immagine e ne calcola una correlazione tra il campo recettivo del filtro stesso e l'immagine di ingresso:

$$g(r,s) = h(r,s) * a(r,s) \quad (5)$$

In particolare, la convoluzione è un'operazione di correlazione che agisce con un kernel $h(-r,-s)$. Questa operazione matematica rappresenta la base delle reti neurali convoluzionali e risulta essere notevolmente più efficiente nel dominio di Fourier perché si riduce ad un semplice prodotto. Nel presente studio, i profili GPR dei rivestimenti delle gallerie analizzate sono stati pre-elaborati attraverso l'applicazione della 2D-FTF. L'applicazione della convoluzione permette di comprimere i dati, mantenendo la struttura geometrica dell'immagine digitale di partenza. La 2D-FTF identifica gli schemi notevoli in direzione verticale e orizzontale nell'immagine di ingresso, conservando le informazioni di tali allineamenti nelle componenti in frequenza dominanti, ossia più importanti. Inoltre, come evidenziato nella Figura 2, la 2D-FTF permette di rimuovere le componenti orizzontali periodiche, tipiche dei profili georadar, lungo la direzione della profondità del substrato analizzato. La Figura 2 mostra due esempi illustrativi che mettono in luce gli effetti della pre-elaborazione tramite 2D-FTF sui profili georadar delle gallerie stradali.




Figura 2. Due esempi di pre-elaborazione 2D-FTF di profili GPR di gallerie stradali. (a) e (c): campioni i-esimi estratti dall'intero profilo GPR; (b) e (d) ampiezze dei campioni i-esimi pre-elaborati.

4 METODOLOGIA

I profili georadar adoperati nel presente studio sono stati estratti da molteplici gallerie italiane.

Il database adottato per la validazione della metodologia proposta è stato realizzato ottenendo elementi i-esimi dei profili GPR attraverso una suddivisione, con passo costante pari a 5.00 m, dei medesimi profili lungo il loro asse longitudinale.

Le immagini i-esime così ottenute sono state successivamente etichettate da tecnici specializzati che hanno associato ad ognuna di esse la tipologia di difetto identificato.

4.1 Classificazione multilivello del difetto

La classificazione delle immagini oggetto di investigazione è stata condotta adoperando una procedura gerarchica articolata in numerosi livelli mostranti un grado di dettaglio crescente nella definizione del difetto strutturale.

Nel presente studio sono stati addestrati quattro modelli di reti neurali convoluzionali, ciascuno effettuante una classificazione binaria, relativi ai livelli mostrati in Figura 3.

Si sottolinea che, per evitare problemi legati a fenomeni di non bilanciamento delle classi, la classificazione binaria avviene adoperando un numero di campioni pari a quelli presenti nella classe meno numerosa per il livello considerato.

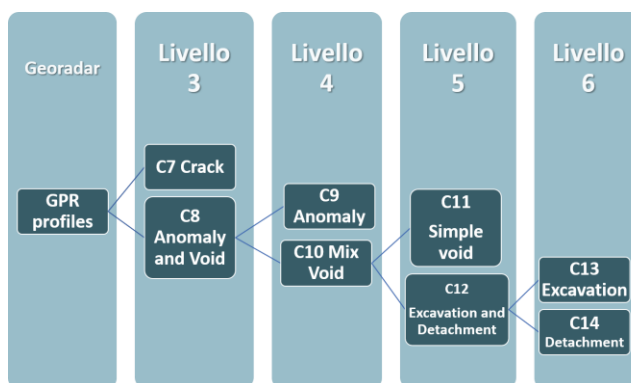


Figura 3. Diagramma di flusso dell'albero gerarchico della classificazione.

4.2 Reti Neurali Convoluzionali: ResNet-50

Le reti neurali convoluzionali sono tra gli algoritmi di *deep learning* maggiormente usati per affrontare problemi di classificazione basati sul riconoscimento delle immagini. Per risolvere i problemi di classificazione per lo studio in oggetto è stata addestrata la rete ResNet-50, sfruttando i vantaggi derivanti dalla tecnica del *transfer learning*.

Infatti, tale rete è già pre-addestrata sul dataset ImageNet Large Scale Visual Recognition Challenge (ILSVRC) composto da 1281167 immagini usate per l'addestramento, 50000 per la validazione e 100000 per il test [25,26]. La CNN scelta è stata adoperata all'interno dell'ambiente di programmazione MATLAB2020b. Essa è stata progettata nel 2015 da He K et al. [27] e presenta un'architettura composta da 177 *layers* di cui 49 convoluzionali e 1 *fully-connected*. È una rete neurale *feed-forward* caratterizzata dalla presenza di connessioni residue (*skip connection*), adopera le funzioni di attivazione ReLu e *softmax* e sfrutta 25 milioni di parametri. Tra i *layers* della rete è possibile riconoscere quattro differenti tipologie: i *layer* di attivazione, di *pooling*, di convoluzione e i *fully connected* [28]. Il *layer* convoluzionale contiene neuroni che interagiscono con quelli del *layer* successivo attraverso kernel convoluzionali, mentre le caratteristiche non lineari vengono estratte usando i *layer* di attivazione. Il *pooling layer* ha lo scopo di ridurre le caratteristiche convoluzionali per migliorare le prestazioni dell'algoritmo diminuendo il costo computazione. Il *fully connected layer* è quello che interpreta le caratteristiche estratte e crea un vettore contenente le probabilità di appartenenza ad ogni classe [29]. Come mostrato in diversi studi in letteratura [30,31], è intuibile supporre che le reti neurali più profonde presentino prestazioni migliori di quelle meno profonde, specialmente durante la fase di addestramento. L'aumento di accuratezza, però, non è sempre legato ad un aumento della profondità della rete, in quanto una maggiore profondità genera spesso un aumento di problematiche che influenzano negativamente le performance della rete. L'elemento innovativo e caratterizzante della rete convoluzionale ResNet è la presenza di connessioni residue. Queste ultime permettono l'apprendimento delle differenze tra i *layers* di input e di output limitando, in questo modo, problemi derivanti dall'eccessiva profondità. La scelta di adottare ResNet per affrontare il problema in questione è perciò giustificata sia dalla profondità della rete che da un livello computazionale relativamente ridotto. Nel dettaglio, ResNet-50 è stata sfruttata come rete pre-addestrata per eseguire una classificazione binaria sia sui profili GPR grezzi che su quelli pre-processati tramite la procedura FTF, precedentemente descritta. Gli iperparametri utilizzati sono riportati nella Tabella 3.

Tabella 3. Iperparametri della rete ResNet-50 adottata.

Parametri	valore
Tasso di apprendimento	0.001
Dimensione dei batch	32

5 RISULTATI E DISCUSSIONE

La classificazione dei difetti è stata effettuata su dati estratti in gallerie attraverso la procedura descritta nelle sezioni precedenti. I risultati ottenuti dall'addestramento delle reti con i profili GPR grezzi, sono stati confrontati con i risultati ricavati addestrando le stesse reti con le TF dei profili GPR. L'accuratezza ottenuta seguendo il primo approccio ha mostrato valori pari in media al 95.3% [29]. D'altra parte, i risultati ottenuti con il secondo approccio hanno mostrato un'accuratezza pari in media a 89.9%. Le tabelle seguenti mostrano le matrici di confusione per i livelli analizzati con il secondo approccio.

5.1 Matrici di confusione per ogni livello

Tra i numerosi metodi utili per definire le prestazioni di un algoritmo classificatore, il più noto è la matrice di confusione. Per ogni livello, oltre alle matrici di confusione sono stati riportati i valori di accuratezza e RMSE ottenuti. Le matrici di confusione sono composte da righe che mostrano le classi reali e colonne che rappresentano le etichette predette. Il valore di accuratezza è determinato dal rapporto tra la traccia della matrice e la somma totale dei suoi termini.

I valori riportati sono relativi ai risultati ottenuti attraverso l'applicazione della tecnica *K-fold cross validation*. Il dataset per ogni classificazione è stato diviso in *k* gruppi (*folds*) dove un "*fold*" è usato per il test, uno per la validazione e (*k-2*) *fold* per l'addestramento della rete [32,33]. Il valore di *k* utilizzato è pari a 10. Empiricamente si è dimostrato che un valore di *k* uguale a 10 produce stime del tasso di errore del test che non hanno una distorsione eccessiva o una grande varianza [34].

Tabella 4. Matrice di confusione – Livello 3.

Classe reale	C7: predetta	C8: predetta	Metriche di prestazione
C7	97.8%	0.22%	Accuratezza: 94.4%
C8	9.0%	91.0%	RMSE: 20.6%

Tabella 5. Matrice di confusione – Livello 4.

Classe reale	C9: predetta	C10: predetta	Metriche di prestazione
C9	83.9%	16.1%	Accuratezza: 85.1%

C10	13.6%	86.4%	RMSE: 38.3%
-----	-------	-------	----------------

Tabella 6. Matrice di confusione – Livello 5.

Classe reale	C11: predetta	C12: predetta	Metriche di prestazione
C11	85.7%	14.3%	Accuratezza: 89.9%
C12	5.9%	94.1%	RMSE: 28.6%

Tabella 7. Matrice di confusione – Livello 6.

Classe reale	C13: predetta	C14: predetta	Metriche di prestazione
C13	92.4%	7.6%	Accuratezza: 90.5%
C14	11.3%	88.7%	RMSE: 25.8%

5.2 Confronto con lavori precedenti [29]

La strategia proposta in questo lavoro è legata alla possibilità di utilizzare come dati di input di una CNN non solo immagini di profili GPR grezzi (primo approccio) ma anche le TF degli stessi (secondo approccio). I risultati ottenuti con il secondo approccio hanno mostrato una diminuzione dell'accuratezza per tutti i livelli (mantenendo comunque una precisione superiore a circa il 90% per i livelli 3, 5 e 6) rispetto ai risultati raggiunti con il primo approccio [29]. In dettaglio, si nota che l'accuratezza nel livello 3 (C7/C8) presenta un valore molto simile (95.9% e 94.4% rispettivamente per il primo e per il secondo approccio). Il livello 4 (C9/C10) mostra il più basso valore di accuratezza per entrambe le metodologie. Essa è pari a 91.8% per il primo approccio e 85.1% per il secondo. Negli ultimi due livelli, il secondo approccio ha mostrato valori di accuratezza abbastanza elevati, pari rispettivamente a 89.9% e 90.5% per i livelli 5 e 6. Essi risultano comunque inferiori ai valori ricavati dalla stessa CNN con il primo approccio (98,2% e 95,3%).

6 CONCLUSIONI

Nel presente studio viene presentato e discusso un approccio gerarchico di classificazione multilivello basato su prove georadar, ai fini della classificazione automatica dei difetti del calcestruzzo del rivestimento delle gallerie stradali. La tecnica 2D-FTF —ha permesso di comprimere i profili GPR rendendo la convoluzione più efficiente. Quattro differenti modelli (CNN) sono stati addestrati a partire dalla

rete pre-addestrata ResNet-50 e sfruttando l'approccio del *transfer learning*. Un confronto con i modelli addestrati con le immagini non pre-elaborate ha evidenziato l'affidabilità della metodologia generale. Tuttavia, i risultati fanno emergere che nello specifico caso la fase di pre-elaborazione produce probabilmente un'eccessiva compressione dei dati, fornendo livelli di accuratezza inferiori rispetto al modello basato sui profili grezzi.

Futuri sviluppi del presente lavoro potrebbero comportare ulteriori pre-elaborazioni dei dati e cambiamenti dell'architettura neurale ai fini di un miglioramento dell'accuratezza ottenuta nella classificazione.

BIBLIOGRAFIA

1. Chiaia, B., Marasco, G., Ventura, G., Zannini Quirini, C.: Customised active monitoring system for structural control and maintenance optimisation. *Journal of Civil Structural Health Monitoring* 10(2), 267–282 (2020)
2. Aloisio, A., Pasca, D.P., Battista, L., Rosso, M.M., Cucuzza, R., Marano, G., Alaggio, R.: Indirect assessment of concrete resistance from fe model updating and young's modulus estimation of a multi-span psc viaduct: Experimental tests and validation. *Elsevier Structures* 37, 686–697 (2022)
3. Rosso, M.M., Cucuzza, R., Aloisio, A., Marano, G.C.: Enhanced multi-strategy particle swarm optimization for constrained problems with an evolutionary-strategies-based unfeasible local search operator. *Applied Sciences* 12(5) (2022)
4. Asso, R., Cucuzza, R., Rosso, M.M., Maserà, D., Marano, G.C.: Bridges monitoring: an application of ai with gaussian processes. In: 14th International Conference on Evolutionary and Deterministic Methods for Design, Optimization and Control. Institute of Structural Analysis and Antiseismic Research National Technical University of Athens (2021)
5. Rosso, M.M., Cucuzza, R., Di Trapani, F., Marano, G.C.: Nonpenalty machine learning constraint handling using pso-svm for structural optimization. *Advances in Civil Engineering* 2021 (2021)
6. Cucuzza, R., Costi, C., Rosso, M.M., Domaneschi, M., Marano, G., Maserà, D.: Optimal strengthening by steel truss arches in prestressed girder bridges. *Proceedings of the Institution of Civil Engineers - Bridge Engineering* pp. 1–51 (01 2022)
7. Marasco, G., Chiaia, B., Ventura, G.: Ai based bridge health assessment. 9th International Workshop on Reliable Engineering Computing (REC2021) is "Risk and Uncertainty in Engineering Computations" (2021), <http://ww2new.unime.it/REC2021/papers/REC2021-39.pdf>
8. Chiaia, B., Ventura, G., Quirini, C.Z., Marasco, G.: Bridge active monitoring for maintenance and structural safety. In: International Conference on Arch Bridges. pp. 866–873. Springer (2019)

9. Bhalla, S., Yang, Y., Zhao, J., Soh, C.: Structural health monitoring of underground facilities –technological issues and challenges. *Tunnelling and Underground Space Technology* 20(5), 487–500 (2005)
10. Di Trapani, F., Tomaselli, G., Sberna, A.P., Rosso, M.M., Marano, G.C., Cavaleri, L., Bertagnoli, G.: Dynamic response of infilled frames subject to accidental column losses. In: Pellegrino, C., Faleschini, F., Zanini, M.A., Matos, J.C., Casas, J.R., Strauss, A. (eds.) *Proceedings of the 1st Conference of the European Association on Quality Control of Bridges and Structures*. pp. 1100–1107. Springer International Publishing, Cham (2022)
11. Jiang, Y., Zhang, X., Taniguchi, T.: Quantitative condition inspection and assessment of tunnel lining. *Automation in Construction* 102, 258–269 (2019)
12. Attard, L., Debono, C.J., Valentino, G., Di Castro, M.: Tunnel inspection using photogrammetric techniques and image processing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 144, 180–188 (2018)
13. Lei, M., Liu, L., Shi, C., Tan, Y., Lin, Y., Wang, W.: A novel tunnel-lining crack recognition system based on digital image technology. *Tunnelling and Underground Space Technology* 108, 103724 (2021)
14. Feng, C., Zhang, H., Wang, S., Li, Y., Wang, H., Yan, F.: Structural damage detection using deep convolutional neural network and transfer learning. *KSCE Journal of Civil Engineering* 23(10), 4493–4502 (2019)
15. Dawood, T., Zhu, Z., Zayed, T.: Deterioration mapping in subway infrastructure using sensory data of gpr. *Tunnelling and Underground Space Technology* 103, 103487 (2020)
16. Al-Nuaimy, W., Huang, Y., Nakhkash, M., Fang, M., Nguyen, V., Eriksen, A.: Automatic detection of buried utilities and solid objects with gpr using neural networks and pattern recognition. *Journal of Applied Geophysics* 43(2), 157–165 (2000)
17. Dwivedi, S.K., Vishwakarma, M., Soni, P.: Advances and researches on non destructive testing: A review. *Materials Today: Proceedings* 5(2, Part 1), 3690–3698 (2018), 7th International Conference of Materials Processing and Characterization, March 17-19, (2017)
18. Tosti, F., Ferrante, C.: Using ground penetrating radar methods to investigate reinforced concrete structures. *Surveys in Geophysics* 41(3), 485–530 (2020)
19. Davis, A.G., Lim, M.K., Petersen, C.G.: Rapid and economical evaluation of concrete tunnel linings with impulse response and impulse radar non-destructive methods. *NDT & E International* 38(3), 181–186 (2005), structural Faults and Repair
20. Cardarelli, E., Marrone, C., Orlando, L.: Evaluation of tunnel stability using integrated geophysical methods. *Journal of Applied Geophysics* 52(2), 93–102 (2003)
21. Farrar, C.R., Worden, K.: *Structural health monitoring: a machine learning perspective*. JohnWiley & Sons (2012)
22. Broughton, S.A., Bryan, K.: *Discrete Fourier analysis and wavelets: applications to signal and image processing*. John Wiley & Sons (2018)
23. Lim, J.S.: *Two-dimensional signal and image processing*. Englewood Cliffs (1990)
24. Fisher, R., Perkins, S., Walker, A., Wolfart, E.: *Hypermedia image processing reference*. England: John Wiley & Sons Ltd pp. 118–130 (1996)
25. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., et al.: Imagenet large scale visual recognition challenge. *International journal of computer vision* 115(3), 211–252 (2015)
26. Markoff, J.: For web images, creating new technology to seek and find. *New York Times* (2012)
27. He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. pp. 770–778 (2016)
28. Rawat, W., Wang, Z.: Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation* 29(9), 2352–2449 (09 2017)
29. Chiaia, B., Marasco, G., Aiello, S.: Deep convolutional neural network for multi-level non-invasive tunnel lining assessment. *Frontiers Of Structural And Civil Engineering* (2022)
30. Anitescu, C., Atroshchenko, E., Alajlan, N., Rabczuk, T.: Artificial neural network methods for the solution of second order boundary value problems. *Computers, Materials & Continua* 59(1), 345–359 (2019)
31. Guo, H., Zhuang, X., Rabczuk, T.: A deep collocation method for the bending analysis of Kirchhoff plate. *Computers, Materials & Continua* 59(2), 433–456 (2019)
32. Rodriguez, J.D., Perez, A., Lozano, J.A.: Sensitivity analysis of k-fold cross validation in prediction error estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 32(3), 569–575 (2010)
33. Refaeilzadeh, P., Tang, L., Liu, H.: *Cross-Validation*, pp. 1–7. Springer New York, New York, NY (2016)
34. Gareth, J., Daniela, W., Trevor, H., Robert, T.: *An introduction to statistical learning: with applications in R*. Springer (2013)