

CLASSIFICAZIONE DEL LIVELLO DI DANNO NEGLI EDIFICI A SEGUITO DI TERREMOTI

Michele Scarpiniti, Wangyi Pu, Aurelio Uncini

Dipartimento di Ingegneria dell'Informazione, Elettronica e Telecomunicazioni (DIET)
"Sapienza" Università di Roma
Via Eudossiana 18, 00184 Roma

Nel campo della visione artificiale e dell'ingegneria civile, la valutazione dei danni post-disastro gioca un ruolo fondamentale, in particolare a seguito di eventi naturali come i terremoti, dove edifici e strutture possono subire danni di varia gravità [1]. Una classificazione efficace del livello di danno, che va da lieve a moderato a grave, è essenziale per valutare l'integrità strutturale, al fine di ricalibrare i coefficienti di resistenza degli elementi strutturali e guidare le decisioni di riparazione e ricostruzione [2]. Negli ultimi anni, le reti neurali convoluzionali (CNN), grazie alla loro capacità di apprendere automaticamente dalle immagini, sono emerse come un potente strumento per l'analisi e la classificazione delle immagini, aprendo nuove possibilità nella valutazione dei danni post-terremoto [2, 3].

La motivazione alla base dell'utilizzo delle CNN per la classificazione dei danni strutturali post-terremoto risiede nell'urgente necessità di una valutazione rapida e automatizzata dei danni immediatamente dopo i disastri naturali. Tradizionalmente, tali valutazioni si basavano in gran parte sull'ispezione visiva umana, che, sebbene preziosa, è limitata dalla soggettività e dall'esperienza [1-3]. Il monitoraggio della salute strutturale (SHM) degli edifici, basato su CNN, mira ad aumentare o sostituire l'ispezione manuale con sistemi di riconoscimento automatizzati.

Lo studio seguente, si focalizza sul confronto di diverse architetture CNN, come VGG16, VGG-19, ResNet-50, MobileNet, EfficientNet, ecc. [7, 8], e sull'utilizzo della fusione dati di diverse rappresentazioni dell'immagine [9], al fine di individuare la migliore strategia di classificazione automatica del livello di danno degli edifici. Il set di dati utilizzato in questo studio deriva dal task 7 della PHI Net Challenge, organizzata dalla Pacific Earthquake Engineering Research (PEER) Hub ImageNet Challenge, e dal database INGV DFM [6, 7]. Ogni immagine nel set di dati è stata etichettata manualmente da esperti strutturisti con il corrispondente livello di danno in quattro classi: "Grave", "Moderato", "Minore" e "Integro" [7]. Questo set di dati comprende una raccolta di 5000 immagini RGB, espanso ad oltre 20.000 tramite l'utilizzo di tecniche di *data augmentation*.

Gli esperimenti, sintetizzati in Tabella 1, hanno coinvolto dodici diverse architetture CNN, i cui iper-parametri sono state opportunamente selezionati tramite validazione. Le prove sperimentali hanno mostrato quale migliore architettura la VGG-16 che ha raggiunto un'accuratezza di picco sul test set del 89,33% [7, 8]. Tali performance sono confermate anche da altri indicatori, quali la precisione, il richiamo e l'F1-score. Tuttavia, è fondamentale sottolineare i limiti degli approcci analizzati di discernere efficacemente tra le classi di danno lieve e moderato. Queste sfide sottolineano l'imperativo di aumentare e perfezionare i set di dati, affrontando sia i vincoli di quantità che di qualità delle immagini.

In sintesi, questo studio illustra il potenziale delle CNN nella valutazione dei danni post-sisma e fornisce una base per ulteriori ricerche nel campo dell'ingegneria civile, contribuendo a migliorare la resilienza delle comunità colpite da eventi sismici.

Tabella 1 Risultati comparativi delle diverse architetture CNN analizzate nello studio.

Architettura	Accuratezza	Precisione	Richiamo	F1-score
Baseline CNN	82.33	83.80	82.30	83.10
AlexNet	82.75	83.96	82.75	82.35
MobileNet-V2	83.25	84.80	83.30	84.00
EfficientNet-B0	84.42	86.80	84.40	84.60
DenseNet201	84.66	86.20	84.70	85.50
GoogLeNet	85.50	86.50	85.50	85.40
ResNet50	87.50	89.14	87.50	87.69
ResNet101	87.67	89.40	87.67	87.79
XceptionNet	87.50	88.82	87.50	87.58
InceptionV3	87.83	88.61	87.83	87.89
VGG19	88.75	89.57	88.75	88.90
VGG16	89.33	89.53	89.33	89.37

BIBLIOGRAFIA

1. Azimi, M., Eslamlou, A., Pekcan, G.: Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review. *Sensors* 20, 2778 (2020). DOI: 10.3390/s20102778.
2. Hong, Z., Zhong, H., Pan, H., Liu, J., Zhou, R., Zhang, Y., Han, Y., Wang, J., Yang, S., Zhong, C.: Classification of building damage using a novel convolutional neural network based on post-disaster aerial images. *Sensors* 22(15), 5920 (2022). DOI: 10.3390/s22155920.
3. Ogunjinmi, P.D., Park, S.S., Kim, B., Lee, D.E.: Rapid post-earthquake structural damage assessment using convolutional neural networks and transfer learning. *Sensors* 22, 3471 (2022). DOI: 10.3390/s22093471
4. Gao, Y., Mosalam, K.M.: Deep transfer learning for image-based structural damage recognition. *Computer-Aided Civil and Infrastructure Engineering* 33, 748–768 (2018). DOI: 10.1111/mice. 12363
5. Saquella, S., Scarpiniti, M., Pedone, L., Angelucci, G., Francioli, M., Matteoni, M., Pampanin, S.: Building damage level classification using deep learning: A CNN-based approach for post-earthquake structural assessment. In: *10th International Conference on Computational Methods in Structural Dynamics and Earthquake Engineering (COMPDYN 2025)* (2025).
6. Saquella, S., Scarpiniti, M., Laneve, G., Uncini, A.: Benchmarking of CNN architectures for post-earthquake damage assessment. In: A. Esposito, M. Faundez Zanuy, F.C. Morabito, E. Pasero, G. Cordasco (eds.) *Neural Networks: Overview of Current Theories and Applications*, Smart Innovation, Systems and Technologies. Springer (2025).
7. Saquella, S., Scarpiniti, M., Pu, W., Pedone, L., Angelucci, G., Matteoni, M., Francioli, M., Pampanin, S.: Post-earthquake Damage Assessment of Buildings Exploiting Data Fusion. In: *2025 International Conference on Neural Networks (IJCNN 2025)* (2025).