




Journal of Mining and Earth Sciences

Website: <https://jmes.humg.edu.vn>



Flood inundation detection using multi-temporal dual-polarization Sentinel-1 SAR imagery and Convolutional Neural Networks: A case study in Hue City, Vietnam



Hang Minh Le, Hai Hong Vu Le*, Hien Vinh Tran Nguyen

Institute of Construction Technology, Le Quy Don Technical University, Hanoi, Vietnam

ARTICLE INFO

Article history:

Received 01st Apr. 2026

Revised 27th June 2026

Accepted 17th July 2026

Keywords:

Convolutional Neural Network (CNN),
Flood detection,
Multi-temporal,
Sentinel-1.

ABSTRACT

Flooding is one of the most destructive natural hazards, causing substantial impacts on socio-economic systems and the environment. Rapid and accurate delineation of flood extent plays a crucial role in disaster monitoring and decision-making processes. This study presents a deep learning framework based on Convolutional Neural Network (CNN) for flood inundation mapping in Hue City, Vietnam, using multi-temporal dual-polarization Sentinel-1 Synthetic Aperture Radar (SAR) imagery. The input dataset was constructed from pre-flood and post-flood Sentinel-1 acquisitions, including the VV and VH polarization bands. In addition, two change-detection bands (ΔVV and ΔVH) were generated to capture temporal variations in surface backscatter intensity between the two observation periods. These six bands were integrated and used as input features for the CNN model. The proposed CNN architecture was designed to exploit both spatial contextual information and radar backscatter characteristics through 5×5 pixel image patches, enabling effective discrimination between flooded and non-flooded areas. A total of 16,000 labeled samples representing flooded and non-flooded areas were used for model training and evaluation. The experimental results demonstrate that the CNN achieves a classification accuracy of 95.13% on the test dataset with a loss value of 0.1918. Independent validation using 1000 random reference points yielded an overall accuracy of 96.4% and a Kappa coefficient of 0.928. The results confirm the effectiveness and applicability of integrating multi-temporal Sentinel-1 SAR data with a CNN-based deep learning framework for flood inundation mapping. The proposed approach improves flood boundary delineation and provides an effective tool for rapid flood mapping, disaster response, and flood risk management.

Copyright © 2026 Hanoi University of Mining and Geology. All rights reserved.

*Corresponding author


E - mail: lhvh108@lqdtu.edu.vn

DOI: 10.46326/JMES.2026.67(5).05



Tạp chí Khoa học Kỹ thuật Mỏ - Địa chất

Trang điện tử: <https://tapchi.humg.edu.vn>



Ứng dụng mô hình Convolutional Neural Networks để xác định vùng ngập lụt từ ảnh đa thời gian và phân cực đôi Sentinel-1: Khu vực thử nghiệm tại thành phố Huế, Việt Nam

Lê Minh Hằng, Lê Vũ Hồng Hải*, Nguyễn Trần Vinh Hiễn

Viện Kỹ thuật công trình đặc biệt, Trường Đại học Kỹ thuật Lê Quý Đôn, Hà Nội, Việt Nam

THÔNG TIN BÀI BÁO

Quá trình:

Nhận bài 01/4/2026

Sửa xong 27/6/2026

Chấp nhận đăng 17/7/2026

Từ khóa:

Ảnh Sentinel-1,
Đa thời gian,
Mạng tích chập CNN,
Xác định vùng ngập.

TÓM TẮT

Ngập lụt là một trong những loại hình thiên tai gây thiệt hại nghiêm trọng đến kinh tế - xã hội và môi trường. Việc xác định nhanh và chính xác phạm vi ngập lụt đóng vai trò quan trọng trong công tác giám sát thiên tai, hỗ trợ ra quyết định. Trong nghiên cứu này, các tác giả đề xuất sử dụng mô hình học sâu Convolutional Neural Network (CNN) xác định vùng ngập lụt tại thành phố Huế bằng cách kết hợp dữ liệu ảnh SAR Sentinel-1 phân cực đôi đa thời gian. Bộ dữ liệu đầu vào được xây dựng từ các ảnh Sentinel-1 thu nhận trước và sau sự kiện lũ với hai kênh phân cực VV và VH. Bên cạnh đó, hai kênh tương ứng ΔVV và ΔVH thể hiện sự thay đổi cường độ tán xạ ngược của bề mặt giữa hai thời điểm quan sát. Các lớp dữ liệu này được tích hợp và được sử dụng làm đầu vào cho mô hình CNN. Mô hình CNN được thiết kế thông qua các ô cửa sổ dữ liệu kích thước 5×5 pixel nhằm khai thác đồng thời đặc trưng tán xạ ngược và cấu trúc không gian của bề mặt trên ảnh Sentinel-1 đa thời gian. Quá trình huấn luyện và đánh giá mô hình sử dụng 16.000 mẫu dữ liệu bao gồm vùng ngập và không ngập. Kết quả cho thấy mô hình CNN đạt độ chính xác phân loại 95,13% trên tập kiểm tra với giá trị hàm mất mát 0,1918. Độ chính xác thực tế của phương pháp được xác định trên 1000 điểm kiểm tra ngẫu nhiên cho độ chính xác tổng thể là 96,4% và hệ số Kappa đạt 0,928. Kết quả nghiên cứu khẳng định tính hiệu quả của việc ứng dụng mô hình CNN và dữ liệu Sentinel-1 đa thời gian trong thành lập bản đồ ngập lụt, góp phần nâng cao độ chính xác trong xác định ranh giới vùng ngập và hỗ trợ hiệu quả cho công tác giám sát và quản lý thiên tai.

© 2026 Trường Đại học Mỏ - Địa chất. Tất cả các quyền được bảo đảm.

*Tác giả liên hệ

E - mail: lhvh108@lqdtu.edu.vn

DOI: 10.46326/JMES.2026.67(5).05

1. Mở đầu

Ngập lụt là một trong những loại hình thiên tai gây thiệt hại nghiêm trọng đến kinh tế - xã hội và môi trường, đặc biệt tại các khu vực đô thị, vùng nông nghiệp, đồng bằng ven sông và ven biển. Trong những năm gần đây, viễn thám đã trở thành công cụ quan trọng trong giám sát và xác định phạm vi ngập lụt nhờ khả năng quan sát diện rộng và lặp lại theo chu kỳ. Các phương pháp xác định vùng ngập được xây dựng dựa trên đặc tính phản xạ hoặc tán xạ của sóng điện từ ở các dải phổ khác nhau.

Đối với dữ liệu quang học, các chỉ số nước như NDWI (Normalized Difference Water Index) và MNDWI (Modified NDWI) được sử dụng phổ biến để phân tách nước và đất. Tuy nhiên, phương pháp này bị hạn chế đáng kể do ảnh hưởng của mây che phủ và điều kiện thời tiết bất lợi trong thời gian xảy ra ngập lụt. Ngược lại, dữ liệu radar khẩu độ tổng hợp (SAR- Synthetic Aperture Radar), như ảnh Sentinel-1, cho phép quan sát bề mặt Trái đất trong mọi điều kiện thời tiết, ngày và đêm nhờ khả năng xuyên mây. Đặc tính năng lượng tán xạ ngược thấp của bề mặt nước trên ảnh SAR là cơ sở khoa học cho nhiều phương pháp xác định vùng ngập lụt hiệu quả.

Trên thế giới, nhiều nghiên cứu đã phát triển các phương pháp xác định vùng ngập lụt dựa trên dữ liệu ảnh SAR. Nhóm phương pháp phân ngưỡng đơn giản (ví dụ: Otsu, Kittler-Illingworth) thường cho kết quả tốt đối với các vùng ngập diện rộng có độ tương phản rõ rệt so với khu vực xung quanh (Tiwari và nnk., 2020). Tuy nhiên, do đặc trưng nhiễu hạt của ảnh SAR nên một số nghiên cứu đã đề xuất phương pháp ngưỡng thích nghi theo không gian nhằm nâng cao tính ổn định của ngưỡng phân loại (Cao và nnk., 2019). Để khai thác dữ liệu đa thời gian, phương pháp phát hiện thay đổi dựa trên sự khác biệt tán xạ ngược trước và sau lũ, hoặc tỷ lệ kênh phân cực, đã được áp dụng nhằm phân biệt nước thường xuyên và vùng ngập mới (Alexandre và nnk., 2020). Tuy nhiên, độ chính xác của phương pháp này phụ thuộc mạnh vào điều kiện thu nhận ảnh và mức độ lọc nhiễu. Một số nghiên cứu đã đề xuất khai thác đặc trưng chuỗi thời gian để giảm nhiễu lẫn giữa nước và các bề mặt có tán xạ thấp (như cát khô, bê tông). Tác giả Martinis và cộng sự (Martinis và nnk., 2018) đã xây dựng một lớp loại trừ cát (Sand Exclusion

Layer-SEL), là mặt nạ loại trừ dựa trên dữ liệu Sentinel-1 nhằm nhận diện các bề mặt cát có đặc tính tán xạ ngược thấp xuất hiện thường xuyên và z-score bất thường từ chuỗi ảnh Sentinel-1. Kết quả cho thấy phương pháp SEL đạt độ chính xác tổng thể 98,5% (UA 95,1%; PA 94,3%) trong môi trường khô hạn. Khi so sánh với bản đồ Copernicus EMS tại Hy Lạp, tỷ lệ trùng khớp tổng thể đạt 98,5% (Martinis và nnk., 2018). Trên nền tảng Google Earth Engine (GEE), phương pháp z-score đa thời gian kết hợp xác suất vị trí nước trong quá khứ từ dữ liệu Landsat đạt độ chính xác chuẩn hóa theo diện tích là 89,8% (DeVries và cộng sự, 2020).

Trong những năm gần đây, các phương pháp học sâu đã và đang được nghiên cứu trong xác định và lập bản đồ ngập lụt từ dữ liệu ảnh SAR Sentinel-1. Bằng cách kết hợp thông tin trước và sau ngập, các mô hình học sâu có khả năng học được các đặc trưng thay đổi của tín hiệu tán xạ ngược trên ảnh SAR, từ đó giảm nhiễu lẫn giữa vùng ngập và các đối tượng có đặc tính tán xạ tương tự như đất ẩm hoặc nước thường xuyên (Zhao và cộng sự, 2023).

Bên cạnh các mô hình học sâu truyền thống như Random Forest (RF), Support Vector Machine (SVM) hay Convolutional Neural Network (CNN), nhiều nghiên cứu trong năm 2024 đã phát triển các mô hình dựa trên U-Net nhằm nâng cao hiệu quả phân đoạn ảnh ngập lụt. Tác giả Ghosh và cộng sự (2024) đã đề xuất mô hình Unet++ kết hợp bộ mã hóa EfficientNet-B7 cho dữ liệu Sentinel-1 và chứng minh việc khai thác đồng thời thông tin đa tỉ lệ và ngữ cảnh không gian sẽ giúp cải thiện đáng kể độ chính xác phân đoạn vùng ngập trên nhiều khu vực địa lý khác nhau. Ngoài ra, các mô hình học sâu thể hệ mới cũng được ứng dụng rộng rãi trong xác định vùng ngập trên ảnh Sentinel-1. Tác giả Saleh và cộng sự (2024) đã phát triển mô hình DAM-Net nhằm khai thác hiệu quả các đặc trưng không gian và thời gian của ảnh Sentinel-1 đa thời gian. Kết quả thực nghiệm cho thấy việc sử dụng cơ chế tự động lựa chọn thông tin quan trọng trên ảnh của mô hình DAM-Net giúp cải thiện khả năng nhận dạng vùng ngập trong các khu vực có cấu trúc bề mặt phức tạp, đồng thời nâng cao khả năng chống nhiễu của mô hình. Trong các mô hình học sâu thì bộ dữ liệu chuẩn phục vụ huấn luyện đóng vai trò quan trọng, quyết định độ chính xác của mô hình. Năm 2024, tác giả Zhao và cộng sự (Zhao và

cộng sự, 2024) đã công bố bộ dữ liệu UrbanSARFloods chuyên biệt cho bài toán xác định ngập lụt trong môi trường đô thị từ dữ liệu ảnh SAR Sentinel-1. Kết quả nghiên cứu cũng chỉ ra rằng việc lập bản đồ ngập lụt cho khu vực đô thị vẫn là thách thức lớn do ảnh hưởng của hiện tượng tán xạ nhiều lần từ các công trình xây dựng và sự không đồng nhất của lớp phủ bề mặt.

Tại Việt Nam, các nghiên cứu sử dụng Sentinel-1 chủ yếu sử dụng phương pháp phân ngưỡng tự động trên nền tảng GEE. Tác giả Võ Quốc Tuấn và cộng sự (Tuan và nnk., 2018) sử dụng phân tích ngưỡng trên 20 ảnh Sentinel-1 để xác định hiện trạng ngập lũ tại Đồng bằng sông Cửu Long từ tháng 6 đến tháng 12 tại các năm 2015, 2016 và 2017. Kết quả cho thấy số liệu thủy văn tại trạm Tân Châu và Châu Đốc có giá trị tương quan cao với diện tích ngập. Tác giả Trinh và cộng sự (Trinh và nnk., 2021) áp dụng thuật toán SNIC kết hợp Otsu đạt độ chính xác trên 86%. Tác giả Lê Ngọc Hành và cộng sự (Le Ngoc và nnk., 2024) xây dựng bản đồ ngập lụt huyện Hòa Vang (Đà Nẵng) bằng phương pháp Otsu trên GEE với độ chính xác toàn cục 89% và hệ số Kappa 0,79.


Nhìn chung, các nghiên cứu trong nước vẫn chủ yếu dựa trên phương pháp phân ngưỡng và chưa khai thác khả năng học hiệu quả về không gian-ngữ cảnh và các đặc trưng phi tuyến của dữ liệu ảnh SAR trên các mô hình học sâu. Ngoài ra,

chưa có nhiều nghiên cứu đánh giá khả năng kết hợp thông tin phân cực và các biến động tán xạ ngược giữa thời điểm trước và sau ngập nhằm nâng cao hiệu quả xác định vùng ngập trong điều kiện địa hình phức tạp của khu vực miền Trung Việt Nam, đặc biệt là khu vực thành phố Huế. Do đó, bài báo đề xuất phương pháp xác định vùng ngập lụt trên ảnh Sentinel-1 dựa trên mô hình mạng nơ-ron tích chập (CNN). Dữ liệu đầu vào bao gồm dữ liệu ảnh Sentinel-1 trước và sau khi ngập, sự thay đổi của giá trị tán xạ ngược giữa hai thời điểm. Phương pháp nhằm khai thác đồng thời đặc trưng tán xạ ngược, biến động theo thời gian và cấu trúc không gian của đối tượng, qua đó nâng cao độ chính xác phân đoạn và giảm nhầm lẫn với các bề mặt có tán xạ thấp tương tự nước, những vùng nước thường xuyên.

2. Khu vực nghiên cứu và dữ liệu thử nghiệm

2.1. Khu vực nghiên cứu

Khu vực nghiên cứu là thành phố Huế, trong khoảng từ 15°59' đến 16°48' vĩ độ Bắc và 107°00' đến 108°12' kinh độ Đông (Hình 1b), thuộc khu vực duyên hải miền Trung Việt Nam. Ngày 01/01/2025, Quốc hội Việt Nam đã ban hành Nghị quyết số 175/2024/QH15 (Quốc hội, 2024) về việc thành lập thành phố Huế trên cơ sở toàn bộ diện tích và dân số của tỉnh Thừa Thiên Huế.



Hình 1. Vị trí khu vực nghiên cứu. (a) Vị trí nghiên cứu trên bản đồ Việt Nam; (b) Bản đồ đơn vị hành chính Thành phố Huế; (c) Ảnh Sentinel-1 (GRD) chụp năm 2025.

Địa hình thành phố Huế phân hóa rõ rệt theo hướng tây-đông, bao gồm ba dạng chính: vùng núi và trung du ở phía tây (chiếm khoảng 70% diện tích), vùng đồng bằng ven biển ở trung tâm và hệ đầm phá-cồn cát ven biển ở phía đông (Phan và nnk., 2021). Dải ven biển có hệ thống đầm phá Tam Giang-Cầu Hai dài khoảng 68 km với diện tích khoảng 22.000 ha, là hệ đầm phá nước lợ lớn nhất Đông Nam Á (Disperati và Virdis, 2015).

Hệ thống sông ngòi tương đối dày đặc, chủ yếu bắt nguồn từ vùng núi phía tây và chảy theo hướng tây bắc - đông nam ra biển. Các con sông chính gồm sông Hương, sông Bồ và sông Ô Lâu, có lưu vực ngắn, độ dốc lớn ở thượng nguồn và đổ ra vùng đồng bằng thấp trũng (Phan và nnk., 2021). Khí hậu thành phố Huế thuộc kiểu nhiệt đới gió mùa, chịu tác động mạnh của gió mùa Đông Bắc và bão từ Biển Đông. Nhiệt độ trung bình năm khoảng 24-25°C; lượng mưa trung bình năm dao động từ 2.500-3.500 mm, tập trung chủ yếu từ tháng 9 đến tháng 12 (Weather and Climate, 2026).

Với đặc điểm địa hình thấp, mạng lưới sông ngòi dày đặc và cơ chế ngập tổng hợp do mưa lớn, lũ sông và triều cường đã tạo ra cho thành phố Huế có sự biến động về không gian và thời gian phức tạp của các vùng ngập. Ngoài ra, sự tồn tại của các bề mặt có tán xạ phản hồi tương tự nước như đất ẩm, ruộng lúa, mặt bê tông phẳng cũng là những yếu tố gây nhiễu cho các phương pháp phân tích trên ảnh SAR Sentinel-1.

2.2. Dữ liệu thử nghiệm

Dữ liệu thử nghiệm bao gồm tư liệu ảnh Sentinel-1 đa thời gian được khai thác từ nguồn dữ liệu trên GEE (GEE, 2026). Các thông tin về dữ liệu ảnh thử nghiệm được thể hiện trong Bảng 1.

Bảng 1. Thông số của dữ liệu thử nghiệm.

Thông số	Dữ liệu vệ tinh
	Sentinel-1
Trước ngập	05/05/2025-18/05/2025
Sau ngập	20/10/2025-05/11/2025
Chế độ chụp	IW/Kênh C
Mức xử lý	GRD
Hướng chụp	Descending
Phân cực	VV và VH
Độ phân giải	10 m

Dữ liệu trước ngập được chọn vào tháng 05/2025 để đảm bảo thời điểm chụp không vào thời tiết xấu. Dữ liệu sau ngập được chọn vào cuối tháng 10/2025 là thời điểm khu vực nghiên cứu ngập nặng nhất. Dữ liệu Sentinel-1 ở mức xử lý GRD được khai thác từ nguồn GEE đã được thực hiện các bước tiền xử lý gồm khử nhiễu nhiệt, hiệu chuẩn đo bức xạ, hiệu chỉnh địa hình bằng dữ liệu SRTM 30 hoặc ASTER DEM. Dữ liệu được chuyển về giá trị dB (decibel) (GEE, 2026).

3. Phương pháp nghiên cứu

3.1. Mạng tích chập CNN

Mạng nơ-ron tích chập (Convolutional Neural Network - CNN) là một kiến trúc học sâu chuyên biệt được thiết kế để trích xuất đặc trưng từ dữ liệu có cấu trúc lưới như hình ảnh kỹ thuật số. Khác với mạng nơ-ron kết nối đầy đủ (Fully Connected Network), CNN sử dụng các phép tích chập cục bộ kết hợp cơ chế chia sẻ trọng số (weight sharing), cho phép mô hình học các biểu diễn không gian từ đặc trưng mức thấp đến các đặc trưng ngữ nghĩa phức tạp, đồng thời duy trì tính bất biến đối với các dịch chuyển nhỏ. Trong nghiên cứu này, mô hình CNN thực hiện phân loại nhị phân trên các ô cửa sổ dữ liệu (patches) kích thước 5x5 pixel nhằm xác định mỗi điểm trung tâm thuộc vùng ngập hoặc không ngập.

Đặc tính này đặc biệt phù hợp với dữ liệu viễn thám, nhất là ảnh SAR Sentinel-1. Nhờ khả năng khai thác ngữ cảnh không gian và nhận diện các mẫu tán xạ đặc trưng, CNN giúp phân biệt hiệu quả các vùng ngập lụt so với các phương pháp phân ngưỡng truyền thống vốn nhạy cảm với nhiễu hạt (speckle noise) trên ảnh SAR và điều kiện bề mặt phức tạp.

Thành phần cốt lõi của CNN là lớp tích chập (convolutional layer). Với ảnh đầu vào $X \in \mathbb{R}^{H \times W \times C}$, trong đó $C=6$ và một bộ lọc (kernel) $K \in \mathbb{R}^{m \times n \times C}$. Khi đó phép tích chập được thực hiện để tạo ra bản đồ đặc trưng Y theo công thức:

$$Y(i, j) = \sum_{c=1}^C \sum_{u=0}^{m-1} \sum_{v=0}^{n-1} K(u, v, c) \cdot X(i + u, j + v, c) \quad (1)$$

Trong đó: X - tensor ảnh đầu vào kích thước $H \times W \times C$ với $C=6$ tương ứng với 6 kênh ảnh; K

- tensor trọng số của bộ lọc tích chập; Y - bản đồ đặc trưng (feature map) tạo ra sau phép tích chập.

Mỗi kernel hoạt động như một bộ phát hiện đặc trưng (feature detector) để nhận diện các cấu trúc như cạnh, đường thẳng, kết cấu hoặc hình thái không gian phức tạp. Một lớp tích chập thường sử dụng nhiều kernel để tạo ra nhiều bản đồ đặc trưng song song.

Sau phép tích chập, dữ liệu được đưa qua hàm kích hoạt phi tuyến, phổ biến nhất là ReLU (Rectified Linear Unit):

$$f(x) = \max(0, x) \quad (2)$$

Hàm ReLU giúp giảm hiện tượng triệt tiêu gradient và tăng tốc độ hội tụ khi huấn luyện. Sau mỗi lớp tích chập, đầu ra được chuẩn hóa bằng Batch Normalization nhằm ổn định phân bố đặc trưng trong quá trình huấn luyện, giảm hiện tượng Internal Covariate Shift và tăng tốc hội tụ của mô hình (Ioffe và Szegedy, 2015).

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}}; y_i = \gamma \hat{x}_i + \beta \quad (3)$$

Trong đó: μ_B và σ_B^2 lần lượt là trung bình và phương sai của mỗi lớp tích chập, ε - hằng số nhỏ nhằm tránh chia cho 0; γ và β - các tham số được học trong quá trình huấn luyện

Tiếp theo, lớp gộp Max Pooling được sử dụng để giảm kích thước không gian của bản đồ đặc trưng, phổ biến nhất là:

$$y = \max_{i,j \in R} (x_{i,j}) \quad (4)$$

Trong đó: R - cửa sổ pooling. Cơ chế giúp giảm số lượng tham số cần học, tăng tính bất biến với dịch chuyển nhỏ và giảm thiểu nguy cơ quá khớp (overfitting).

Để giảm hiện tượng quá khớp, mô hình sử dụng lớp Dropout, trong đó một tỷ lệ nơ-ron được loại bỏ ngẫu nhiên trong quá trình huấn luyện (Srivastava và cộng sự, 2014). Sau khối tích chập cuối cùng, Global Average Pooling (Lin và cộng sự, 2013) được sử dụng thay cho lớp Flatten truyền thống nhằm giảm số lượng tham số và cải thiện khả năng tổng quát hóa. Với bản đồ đặc trưng thứ k , đầu ra của Global Average Pooling được tính theo công thức sau:

$$G_k = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_k(i, j) \quad (5)$$

Trong đó: $F_k(i, j)$ - giá trị tại vị trí (i, j) của bản đồ đặc trưng thứ k , còn H và W lần lượt là chiều cao và chiều rộng của bản đồ đặc trưng.

Trong quá trình huấn luyện, mục tiêu của CNN là tối thiểu hóa hàm mất mát (loss function) giữa nhãn dự đoán $\hat{y}$ và nhãn thực tế y . Với bài toán phân loại nhị phân, hàm mất mát Entropi chéo (Binary Cross-Entropy - BCE) thường được sử dụng:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (6)$$

Trong đó: y_i - nhãn thực tế; $\hat{y}_i$ - xác suất dự báo của mô hình và N là số lượng mẫu.

Nhờ cấu trúc phân tầng và khả năng học đặc trưng tự động, CNN mang lại nhiều ưu thế trong xử lý ảnh Sentinel-1. Mô hình có thể học trực tiếp các đặc trưng tán xạ bề mặt từ dữ liệu thô mà không cần thiết lập ngưỡng thủ công. Đồng thời, việc khai thác ngữ cảnh không gian giúp nhận diện chính xác cấu trúc hình thái của vùng nước và mạng lưới sông ngòi, từ đó phân biệt hiệu quả các vùng ngập với các bề mặt có đặc tính tán xạ tương tự.

3.2. Quy trình nghiên cứu

Quy trình nghiên cứu đề xuất trong bài báo được thực hiện dựa nền tảng GEE và Google Colab. Dữ liệu ảnh Sentinel-1 đa thời gian được khai thác trên kho dữ liệu GEE, sau đó được lấy mẫu để thực hiện huấn luyện cho mô hình CNN, từ đó xác định khu vực ngập lụt. Quy trình của phương pháp đề xuất bao gồm bốn bước chính:

Bước 1 (Khởi tạo vùng nghiên cứu và tiền xử lý dữ liệu): Xác định phạm vi nghiên cứu và truy xuất ảnh Sentinel-1 GRD tại hai thời điểm trước ngập (Pre) và sau ngập (Post). Xác định 06 kênh ảnh đặc trưng gồm VV_{pre} , VH_{pre} , VV_{post} , VH_{post} , ΔVV , ΔVH .

Bước 2 (Xây dựng và chuẩn hóa bộ dữ liệu huấn luyện): Xác định các mẫu "Ngập" và "Không ngập" trên dữ liệu ảnh Sentinel-1 đa thời gian trước và sau ngập. Quá trình xây dựng mẫu được thực hiện trên GEE. Dữ liệu sau đó được xuất sang định dạng TFRecord lưu trữ trên Google Drive và thực hiện chuẩn hóa Z-score (Mean, Std) trong môi trường Google Colab.

Bước 3 (Xây dựng và huấn luyện mô hình CNN): Thiết kế mô hình CNN cải tiến được xây dựng từ các khối Conv2D-Batch Normalization-ReLU-MaxPooling kết hợp với Dropout nhằm tăng khả năng học đặc trưng không gian và giảm hiện tượng quá khớp. Đặc trưng cuối cùng được tổng hợp bằng hàm Global Average Pooling và phân loại bằng lớp Dense sử dụng hàm kích hoạt Sigmoid để phân loại nhị phân vùng ngập và không ngập.


Bước 4 (Xác định vùng ngập và đánh giá độ chính xác): Do quá trình học máy CNN chiếm nhiều tài nguyên nên các tác giả đề xuất chia khu vực nghiên cứu thành các mảng nhỏ (tiles). Áp dụng mô hình CNN trên từng tiles. Bản đồ ngập được ghép từ kết quả phân tích của các mảng và chuyển về hệ tọa độ UTM 48N. Sau đó, đánh giá độ chính xác kết quả.

4. Kết quả thử nghiệm và thảo luận

Vào cuối tháng 10/2025 và đầu tháng 11/2025, thành phố Huế xuất hiện mưa lớn kéo dài và gây lụt lội nghiêm trọng trên diện rộng. Dựa



trên quy trình tại Hình 2 và dữ liệu thử nghiệm tại Bảng 1, các tác giả thử nghiệm xác định vùng ngập tại khu vực nghiên cứu sử dụng mô hình CNN. Dữ liệu ảnh Sentinel-1 sẽ được thực hiện các bước tiền xử lý ảnh và xác định 06 kênh ảnh đầu vào bao gồm VVpre, VHpre (ảnh trước ngập), VVpost, VHpost (ảnh sau ngập), $\Delta VV = VV_{post} - VV_{pre}$ (ảnh khác biệt giữa trước và sau ngập). Quá trình xây dựng và chuẩn hóa bộ dữ liệu huấn luyện được thực hiện trên nền tảng GEE. Bộ dữ liệu huấn luyện được xây dựng dựa trên các đặc tính tán xạ ngược của ảnh trước và sau ngập. Đặc điểm vùng mẫu của đối tượng ngập và không ngập được thể hiện trong Bảng 2. Đối tượng ngập là những đối tượng trước ngập không có nước và sau ngập bị bao phủ bởi nước (vùng tối trên ảnh SAR). Đối tượng không ngập là những đối tượng còn lại có đặc điểm tán xạ ngược không đổi trên cả ảnh trước và sau ngập.

Số lượng điểm mẫu bao gồm 8000 điểm ngập và 8000 điểm không ngập, trong đó số lượng điểm tham gia huấn luyện là 12799 điểm (chiếm 80%) và số lượng điểm kiểm tra là 3201 điểm (chiếm 20%). Việc xây dựng tập mẫu được hoàn tất trên nền tảng GEE.



Hình 2. Sơ đồ quy trình phương pháp nghiên cứu.

Bảng 2. Đặc điểm mẫu huấn luyện mô hình CNN trên ảnh tổ hợp màu VV: VH: VV.

Đối tượng	Hình ảnh trên ảnh		Đặc điểm của đối tượng
	Trước ngập	Sau ngập	
Vùng ngập			Vị trí ngập
Vùng không ngập			-Nước thường xuyên (hồ, đầm, sông) -Khu dân cư -Rừng

Quá trình xây dựng và huấn luyện mô hình CNN được thực hiện trên nền tảng Google Colab. Mô hình CNN được huấn luyện trên 12799 mẫu với Batch size=32 và Epoch=10. Trong quá trình huấn luyện, mô hình sử dụng bộ tối ưu Adam và hàm mất mát BCE. Thuật toán CNN sẽ tự động trích xuất các đặc trưng hình học và ngữ cảnh không gian từ các ô cửa sổ dữ liệu với kích thước 5x5 pixel. Kích thước ô cửa sổ dữ liệu được lựa chọn phù hợp với độ phân giải của ảnh Sentinel-1 là 10 m và đảm bảo nhận diện được hình thái vùng ngập mà vẫn hạn chế được việc pha trộn thông tin giữa các lớp phủ bề mặt khác nhau. Kết quả độ chính xác mô hình là 95,13% với hàm mất mát đạt 0,1918. Hình 3 thể hiện quá trình học của mô hình CNN. Kết quả huấn luyện mô hình CNN qua 10 Epoch cho thấy khả năng hội tụ nhanh và ổn định. Độ chính xác trên tập huấn luyện tăng từ khoảng 80,8% ở epoch 1 lên khoảng 94% ở epoch 2 và đạt xấp xỉ 95% ở epoch 3. Sau đó, độ chính xác duy trì ổn định đến hết quá trình huấn luyện. Đối với tập kiểm tra, độ chính xác đạt khoảng 95% ngay ở epoch đầu tiên và gần như không thay đổi ở các epoch tiếp theo. Khoảng cách giữa huấn luyện và kiểm tra rất nhỏ, chứng tỏ mô hình có khả năng tổng quát hóa tốt trên dữ liệu chưa được sử dụng trong quá trình huấn luyện. Biểu đồ mất mát phản ánh rõ hơn quá trình học của mô hình. Hàm mất mát trên tập huấn luyện giảm liên tục từ khoảng 0,51 ở epoch 1 xuống khoảng 0,10 ở epoch 10. Trong khi đó, hàm mất mát trên tập kiểm tra giảm từ khoảng 0,34-0,18, mặc dù có dao động tại các epoch 6, 8, 10 nhưng không có xu hướng tăng liên tục. Điều này cho thấy mô hình duy trì khả năng tổng quát tốt.

Để đánh giá hiệu quả của phương pháp CNN trong xác định vùng ngập trên ảnh Sentinel-1 đa thời gian phân cực đôi, các tác giả tiến hành so sánh mô hình CNN với mô hình học máy RF và


SVM với cùng số lượng điểm huấn luyện và kiểm tra. Độ chính xác của các mô hình thử nghiệm được thể hiện qua các tham số Accuracy, Precision, Recall, F1-Score, IoU và Kappa (Hình 4). Phân tích kết quả trên Hình 4 thì cả ba mô hình đều cho hiệu suất phân loại cao với độ chính xác tổng thể (Accuracy) vượt 94%. Trong các chỉ số đánh giá độ chính xác như Accuracy, Precision, F1-Score, IoU và Kappa thì mô hình CNN cho giá trị cao hơn mô hình RF và SVM. Riêng chỉ số Recall thì mô hình CNN và SVM cho giá trị 1, chứng minh mô hình CNN và SVM nhận dạng được tất cả các vùng ngập.

Trên Bảng 3 thể hiện ma trận nhầm lẫn của kết quả phân loại vùng ngập/không ngập dựa trên tổng số 3201 điểm trong tập kiểm tra của mô hình. Kết quả của ma trận nhầm lẫn cũng cho thấy mô hình CNN và SVM cho độ chính xác phân loại cao hơn mô hình RF. Mô hình CNN và SVM cho giá trị FN=0 và TP=1591, chứng tỏ hai mô hình không bỏ sót điểm ngập nào trong tập kiểm tra, trong khi đó mô hình RF bỏ sót 13 điểm ngập. Tuy nhiên, mô hình CNN có số FP thấp hơn SVM. Điều đó cho thấy mô hình CNN khả năng phân biệt giữa vùng ngập và không ngập tốt hơn một chút so với mô hình SVM.


Bảng 3. Ma trận nhầm lẫn của mô hình CNN, RF và SVM.

Mô hình	TN	FP	FN	TP	Tổng điểm
CNN	1454	156	0	1591	3201
RF	1455	155	13	1578	3201
SVM	1453	157	0	1591	3201

Ngoài ra, để chứng minh kết quả so sánh mô hình CNN và SVM có ý nghĩa trong kiểm định thống kê, các tác giả đã thử nghiệm 10 lần chạy huấn luyện độc lập với giá trị khởi tạo khác nhau



Hình 3. Đường cong quá trình học của mô hình CNN. (Bên trái) Đường cong về độ chính xác; (Bên phải) Đường cong của hàm mất mát.



Hình 4. So sánh độ chính xác của mô hình CNN, RF và SVM trong xác định vùng ngập trên ảnh Sentinel-1.


nhưng vẫn giữ nguyên cùng một tập kiểm tra độc lập (Hình 5). Kết quả cho thấy cả mô hình CNN và SVM đều đạt độ chính xác cao và ổn định. Tuy nhiên, CNN đạt giá trị trung bình cao hơn ở tất cả các chỉ số ngoại trừ Recall. Chỉ số Recall của cả hai mô hình đều bằng 1,000 với độ lệch bằng 0, chứng tỏ trong 10 lần thử nghiệm thì cả CNN và SVM đều phát hiện được toàn bộ các điểm ngập trong tập kiểm tra.

Ngoài ra, các thông số kiểm định thống kê cho thấy sự khác biệt về Accuracy, Precision, F1-Score, IoU và Kappa của mô hình CNN và SVM đều có ý nghĩa thống kê ($p < 0,05$). Kiểm định Wilcoxon cũng cho kết quả tương tự ($p < 0,05$) đối với các chỉ số, ngoại trừ Recall. Đồng thời, kết quả vị trí của các điểm trung bình trên Hình 5 cũng cho thấy mô hình CNN có khả năng tổng quát hóa tốt và duy trì hiệu năng ổn định khi thay đổi bộ huấn luyện độc


lập, trong khi SVM gần như không chịu ảnh hưởng bởi bộ huấn luyện nhưng vẫn đạt hiệu suất thấp hơn một chút so với CNN.

Nhìn chung, kết quả nghiên cứu đã chứng minh mô hình CNN là phương pháp phân loại tốt vùng ngập/không ngập trên dữ liệu Sentinel-1 đa thời gian và phân cực đôi. Mô hình CNN đạt hiệu suất tương đương SVM về chỉ số Recall nhưng có các chỉ số khác cao hơn một chút, đồng thời giảm số lượng FP trong ma trận đánh giá độ chính xác. Ngoài ra, mô hình CNN có khả năng hội tụ nhanh, tính ổn định cao và hiệu quả tổng quát hóa tốt. Đây là những yếu tố quan trọng khẳng định tính khả thi của CNN đối với các ứng dụng phân loại ảnh viễn thám trong thực tế.

Kết quả phân loại vùng ngập trên ảnh Sentinel-1 phân cực đôi đa thời gian tại thành phố Huế bằng mô hình CNN được thể hiện trên Hình 6.



Hình 5. So sánh kiểm định thống kê CNN và SVM qua 10 lần huấn luyện độc lập.




Hình 6. Vùng ngập khu vực Thành phố Huế tháng 10/2025 sử dụng thuật toán CNN.

Để đánh giá độ chính xác thực tế của kết quả phân loại, các tác giả sử dụng 1000 điểm kiểm tra ngẫu nhiên với vị trí phân bố như ở Hình 7. Các điểm kiểm tra độ chính xác thực tế được xây dựng độc lập, ngẫu nhiên và không sử dụng trong quá trình huấn luyện mô hình. Kết quả kiểm tra thực địa được xây dựng dựa trên thông tin ngập tại thành phố Huế năm 2025 và giải đoán trên ảnh

Sentinel-1 tại thời điểm ngập. Độ chính xác tổng thể đạt 96,4% với hệ số Kappa đạt 0,928 (Bảng 4).

Tóm lại, kết quả đánh giá độ chính xác về mô hình và độ chính xác thực tế đã chứng minh mô hình CNN cho phép phân loại tốt các đối tượng điểm ngập trên ảnh vệ tinh Sentinel-1 phân cực đôi đa thời gian.



Hình 7. Vị trí điểm kiểm tra ngẫu nhiên trên khu vực nghiên cứu.

Bảng 4. Ma trận nhầm lẫn của đánh giá thực tế.

Đối tượng	Không ngập	Ngập	UA (%)
Không ngập	483	17	96,6
Ngập	19	481	96,2
PA (%)	96,2	96,6	1000
Độ chính xác tổng thể = 96,4%			
Chỉ số Kappa = 0,928			

Việc lựa chọn các mẫu học đóng vai trò quan trọng trong quá trình xây dựng mô hình và kết quả phân tích điểm ngập. Các vị trí ngập được xác định là những vùng ngập mới, không trùng với các vùng nước thường xuyên như hồ, đầm, sông và ruộng đang có nước. Tuy nhiên, các vị trí gây nhầm lẫn thường tại các khu vực đất ẩm, chỗ ven các đầm, hồ hoặc ruộng có nước do đặc trưng trước và sau ngập trên ảnh Sentinel-1 không có nhiều sự khác biệt.

5. Kết luận

Nghiên cứu đã đề xuất phương pháp tự động xác định vùng ngập lụt tại thành phố Huế bằng

cách kết hợp dữ liệu ảnh Sentinel-1 SAR đa thời gian với mô hình học sâu CNN. Việc sử dụng dữ liệu ảnh Sentinel-1 SAR cho phép khắc phục hạn chế của ảnh vệ tinh quang học trong điều kiện mây che phủ và thời tiết bất lợi khi xảy ra lũ, góp phần nâng cao khả năng giám sát ngập lụt trong tình huống thiên tai thực tế.

Kết quả thực nghiệm cho thấy mô hình CNN có khả năng khai thác hiệu quả các đặc trưng tán xạ ngược trên ảnh đa thời gian của các kênh ảnh VV, VH và lớp biến động ΔVV và ΔVH , đồng thời tận dụng được đặc trưng không gian-ngữ cảnh thông qua cửa sổ dữ liệu 5x5 pixel. Độ chính xác của mô hình trên tập kiểm tra là 95,13% và độ chính xác thực tế trên điểm kiểm tra ngẫu nhiên

đạt 96,4% với hệ số Kappa là 0,928. Điều này cho thấy mô hình CNN có khả năng nhận dạng tốt các khu vực ngập mới và hạn chế nhầm lẫn với các đối tượng có đặc trưng tán xạ tương tự như đất ẩm, ruộng nước hoặc nước thường xuyên. Độ chính xác của mô hình CNN đã được so sánh với mô hình RF và SVM. Kết quả so sánh cho thấy mô hình CNN tốt hơn mô hình RF về các chỉ số đánh giá và ưu thế trong việc học đặc trưng không gian và cao hơn một chút so với SVM. Điều đó cho thấy các phương pháp học sâu có tiềm năng ứng dụng trong lĩnh vực viễn thám radar phục vụ giám sát và quản lý thiên tai.

Trong tương lai, nghiên cứu có thể được phát triển theo hướng mở rộng bộ dữ liệu huấn luyện, tích hợp thêm các nguồn dữ liệu phụ trợ như mô hình số độ cao (DEM), độ cao so với dòng chảy gần nhất hoặc chuỗi dữ liệu dài hạn có thể tiếp tục nâng cao độ chính xác và ứng dụng trong công tác cảnh báo sớm và quản lý rủi ro ngập lụt.

Lời cảm ơn

Nghiên cứu khai thác dữ liệu ảnh vệ tinh Sentinel-1 trên nền tảng Google Earth Engine, kết hợp với môi trường Google Colab để triển khai các thuật toán học sâu và xử lý dữ liệu quy mô lớn.

Đóng góp của các tác giả

Lê Minh Hằng - phương pháp luận, viết bản thảo bài báo, đánh giá và chỉnh sửa; Lê Vũ Hồng Hải - phương pháp luận, viết bản thảo bài báo, biên tập kết quả nghiên cứu; Nguyễn Trần Vinh Hiển - xử lý, phân tích dữ liệu, đánh giá độ chính xác.

Tài liệu tham khảo

Alexandre, C., Johary, R., Catry, T., Mouquet, P., Révillion, C., Rakotondraompiana, S., Pennober, G. (2020). A sentinel-1 based processing chain for detection of cyclonic flood impacts. *Remote sensing*, 12(2), 252.

Cao, H., Zhang, H., Wang, C., Zhang, B. (2019). Operational flood detection using Sentinel-1 SAR data over large areas. *Water*, 11(4), 786.

DeVries, B., Huang, C., Armston, J., Huang, W., Jones, J. W., Lang, M. W. (2020). Rapid and robust monitoring of flood events using Sentinel-1 and Landsat data on the Google

Earth Engine. *Remote sensing of Environment*, 240, 111664.

- Disperati, L., Virdis, S. G. P. (2015). Assessment of land-use and land-cover changes from 1965 to 2014 in Tam Giang-Cau Hai Lagoon, central Vietnam. *Applied Geography*, 58, 48-64.
- Ghosh, B., Garg, S., Motagh, M., Martinis, S. (2024). Automatic flood detection from Sentinel-1 data using a nested UNet model and a NASA benchmark dataset. *PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 92(1), 1-18.
- Google Earth Engine (GEE). (2026). *Copernicus Sentinel-1 GRD*. https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S1_GRD?hl=vi
- Ioffe, S., Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning*, PMLR 37 (pp. 448-456).
- Le Ngoc, H., Nguyen, H. S., Le Phuc, C. L., Nguyen, V. A., Tran, T. A. (2024). Flood mapping and impact assessment in agricultural land in Hoa Vang, Da Nang using remote sensing and Google Earth Engine. *VNU Journal of Science: Earth and Environmental Sciences*, 40(2), 77-92 (in Vietnamese).
- Lin, M., Chen, Q., Yan, S. (2013). Network in network. *arXiv preprint arXiv:1312.4400*.
- Martinis, S., Plank, S., Ćwik, K. (2018). The use of Sentinel-1 time-series data to improve flood monitoring in arid areas. *Remote Sensing*, 10(4), 583.
- Phan, H. A., Van Le, T., Tran, T. A., & Nguyen, S. H. (2021). An environmental zoning for sustainable development in Thua Thien Hue Province, Vietnam. In *Global Changes and Sustainable Development in Asian Emerging Market Economies Vol. 2: Proceedings of EDESUS 2019*, 817-841.
- Quốc hội. (2024). *Nghị quyết về việc thành lập thành phố Huế trực thuộc trung ương* (Nghị quyết số 175/2024/QH15).
- Saleh, T., Weng, X., Holail, S., Hao, C., Xia, G. S. (2024). DAM-Net: Flood detection from SAR

- imagery using differential attention metric-based vision transformers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 212, 440-453.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Tiwari, V., Kumar, V., Matin, M. A., Thapa, A., Ellenburg, W. L., Gupta, N., Thapa, S. (2020). Flood inundation mapping-Kerala 2018; Harnessing the power of SAR, automatic threshold detection method and Google Earth Engine. *Plos one*, 15(8), e0237324.
- Trinh, L.H., Mai, D.S., Nguyen, N.H., Le, V.P., (2021). Automatic flood detection using Sentinel-1 images in Google Earth Engine. *Journal of Science and Technique: Section on Special Construction Engineering*, 4(2), 29-43.
- Tuan, V. Q., Khai, D. H., Nhan, H. T. K., & Hoa, N. T. (2018). Developing a flood monitoring algorithm for the Mekong Delta region based on Google Earth Engine. *Can Tho University Journal of Science*, 54(9A), 29-36. (in Vietnamese).
- Weather and Climate. (2026). *Average monthly precipitation (rainfall) in Hue, Vietnam*. <https://weather-and-climate.com/average-monthly-precipitation-Rainfall,Hue,Vietnam>
- Zhao, J., Xiong, Z., Zhu, X. X. (2024). UrbanSARFloods: Sentinel-1 SLC-based benchmark dataset for urban and open-area flood mapping. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 419-429).
- Zhao, Z., Zhang, B., Wu, F., Yang, J. (2023, September). Deep Learning-Based Flood Detection Using Multi-Temporal Sentinel-1 SAR Data: A Case Study in Beijing Area, 2023. In *2023 SAR in Big Data Era (BIGSAR DATA)* (pp. 1-4). IEEE.