



IMPROVING GROUND PENETRATING RADAR IMAGE CLASSIFICATION USING DEEP LEARNING WITH WHITE NOISE DATA AUGMENTATION

Ngoc Quy Hoang¹, Seonghun Kang¹, Jong Sub Lee¹, Quang Hung Truong^{2*}

¹School of Civil, Environmental and Architectural Engineering, Korea University, 145, Anam-ro, Seongbuk-gu, Seoul, 02841, Republic of Korea

²Faculty of Civil Engineering, Van Lang School of Technology, Van Lang University, No 69/68 Dang Thuy Tram Street, Ho Chi Minh City, Viet Nam.

ARTICLE INFO

TYPE: Research Article

Received: 12/12/2024

Revised: 12/08/2025

Accepted: 13/08/2025

Published online: 15/08/2025

<https://doi.org/10.47869/tcsj.76.6.8>

* *Corresponding author*

Email: hung.tq@vlu.edu.vn

Abstract. Ground Penetrating Radar (GPR) technology is increasingly utilized in underground structure surveys in Vietnam to enhance construction safety, optimize costs, and minimize environmental impact, particularly in urban infrastructure, transportation, water resource management, and archaeological studies. However, to maximize its potential, advancements in data processing and analytical techniques are required to improve the accuracy of subsurface investigations and geological assessments. This study investigates the enhancement of GPR image classification performance through the integration of deep learning techniques (DNN) and data augmentation utilizing white noise. The dataset used in the research was collected from construction sites in South Korea and comprises three primary categories: background noise, hyperbolic reflections from buried objects, and reflections from manholes. To increase the diversity of the dataset and mitigate the effects of environmental noise, a data augmentation method incorporating white noise with a coefficient of variation (cov) is employed. A DNN model based on the VGG19 architecture is implemented for feature extraction and classification of GPR images. Experimental results demonstrate that the augmented data significantly enhance classification performance, reduce overfitting, and improve the generalization capability of the model. This research highlights the potential of using white noise-based data augmentation to enhance GPR image classification performance.

Keywords: classification, white noise, DNN, GPR, NDT

@ 2025 University of Transport and Communications



TĂNG CƯỜNG PHÂN LOẠI VÀ XỬ LÝ ẢNH GPR BẰNG PHƯƠNG PHÁP HỌC SÂU KẾT HỢP VỚI GIA TĂNG NHIỀU TRẮNG

Hoàng Ngọc Quý¹, Kang Seonghun¹, Lee Jong Sub¹, Trương Quang Hùng^{2*}

¹Khoa Môi trường, Kiến trúc và Xây dựng, Korea University, 145, Anam-ro, Seongbuk-gu, Seoul, 02841, Hàn Quốc

²Khoa Xây dựng, Trường công nghệ Văn Lang, Trường Đại học Văn Lang, Số 69/68 Đặng Thùy Trâm, Hồ Chí Minh, Việt Nam.

THÔNG TIN BÀI BÁO

CHUYÊN MỤC: Công trình khoa học

Ngày nhận bài: 12/12/2024

Ngày nhận bài sửa: 12/08/2025

Ngày chấp nhận đăng: 13/08/2025

Ngày xuất bản Online: 15/08/2025

<https://doi.org/10.47869/tcsj.76.6.8>

* Tác giả liên hệ

Email: hung.tq@vlu.edu.vn


Tóm tắt. Công nghệ Ground Penetrating Radar (GPR) hiện đang được ứng dụng trong khảo sát công trình ngầm tại Việt Nam nhằm giảm rủi ro thi công, tiết kiệm chi phí và bảo vệ môi trường, đặc biệt trong lĩnh vực hạ tầng đô thị, giao thông, thủy lợi và khảo cổ. Tuy nhiên, để phát huy tối đa hiệu quả, cần cải thiện khả năng xử lý và phân tích dữ liệu GPR nhằm tăng độ chính xác trong khảo sát và đánh giá hiện trạng địa chất. Bài báo nghiên cứu việc cải thiện hiệu suất phân loại ảnh radar xuyên mặt đất (GPR) bằng cách kết hợp phương pháp học sâu (DNN) với tăng cường dữ liệu sử dụng nhiễu trắng. Dữ liệu nghiên cứu được thu thập từ các công trường xây dựng tại Hàn Quốc và bao gồm ba nhóm chính: nhiễu nền, phản xạ hyperbol từ vật thể chôn vùi, và phản xạ từ hố ga. Để tăng tính đa dạng của dữ liệu và giảm thiểu tác động của nhiễu môi trường, phương pháp tăng cường dữ liệu bằng cách thêm nhiễu trắng với hệ số biến thiên (cov) được áp dụng. Mô hình DNN dựa trên cấu trúc VGG19 được triển khai để trích xuất đặc trưng và phân loại các ảnh GPR. Kết quả thực nghiệm cho thấy dữ liệu tăng cường giúp cải thiện đáng kể hiệu suất phân loại, giảm hiện tượng overfitting và tăng cường tính tổng quát của mô hình. Nghiên cứu này chứng minh tiềm năng của việc áp dụng nhiễu trắng trong xử lý ảnh GPR kết hợp với phương pháp học sâu.

Từ khóa: Phân loại, nhiễu trắng, DNN, GPR, NDT

@ 2025 Trường Đại học Giao thông vận tải

1. GIỚI THIỆU

Yêu cầu cấp thiết về phát triển đô thị hiện đại tại các thành phố lớn ở Việt Nam như Hà Nội và Hồ Chí Minh và áp lực gia tăng dân số ở các đô thị làm gia tăng nhu cầu phát triển nhiều các công trình ngầm, như hệ thống cống thoát nước, không gian ngầm, hệ thống tàu điện ngầm MRT. Một trong những vấn đề phổ biến và lớn nhất trong xây dựng ngầm là sự hình thành các hốc và lỗ rỗng trong nền đất, ảnh hưởng nghiêm trọng đến các công trình và có thể dẫn đến phá hủy. Xói mòn do dòng chảy ngầm hoặc nứt vỡ đường ống cấp thoát nước là nguyên nhân phổ biến nhất gây ra các hốc rỗng và hố sụt ở dưới nền đường và công trình [1, 2, 3], thể hiện trong Hình 1. Bên cạnh đó, rung động do vận hành đường sắt đô thị hoặc thi công đóng cọc cũng là những nguyên nhân phổ biến hình thành các hốc rỗng trong nền đất [4, 5]. Các lỗ rỗng có thể dẫn đến sự phân bố lại áp lực đất lên các công trình, sụt lún, sụt hố và giảm khả năng chịu lực, có thể dẫn đến hư hỏng và phá hủy các công trình. Các lỗ rỗng có thể phát triển nhanh chóng nhưng có thể không được phát hiện sớm nếu không có kiểm tra kỹ thuật. Do đó, áp dụng các phương pháp khảo sát không phá hủy (non-destructive testing - NDT) là 1 nhu cầu bắt buộc trước khi tiến hành các công trình. Radar xuyên mặt đất, ground radar penetrating radar, GPR, là 1 trong các phương pháp phổ biến nhất được sử dụng để khảo sát công trình không phá hủy [3, 6]. GPR hoạt động bằng cách sử dụng sóng điện từ để khảo sát các vật thể, lớp đất hoặc cấu trúc nằm dưới bề mặt đất [7, 8, 9, 10]. Các tín hiệu sóng điện từ phản xạ từ các vật thể hoặc lớp đất sẽ được ghi lại dưới dạng tín hiệu điện từ. Tín hiệu điện từ có thể được thể hiện dưới dạng ảnh nhưng không phải là ảnh quang học mà cần phân tích chuyên sâu để phát hiện và xác định vị trí dị biệt.



Hình 1. Cơ chế hình thành lỗ rỗng trong nền đất [3].

Việc xử lý các dữ liệu tín hiệu từ GPR không đơn giản và còn chịu nhiều ảnh hưởng chủ quan của người xử lý vì ảnh GPR không phải là ảnh quang học thông thường mà là các tín hiệu số GPR được xử lý để thể hiện dưới dạng ảnh 2 chiều. Việc xử lý ảnh không phải ảnh quang học có nhiều điểm phức tạp. Do đó, việc áp dụng các phương pháp dựa trên máy học (machine learning) và học sâu (deep learning) để phân tích và phân loại ảnh GPR đã trở thành một xu hướng nghiên cứu quan trọng nhằm tăng cường độ chính xác.

Mục tiêu chính của nghiên cứu này là đánh giá hiệu suất của mô hình học sâu trong việc phân loại ảnh GPR, cải thiện độ chính xác phân loại thông qua việc thêm nhiễu trắng (white noise) vào ảnh GPR và đề xuất thay đổi hàm chi phí thông qua đánh giá tổn thất tái tạo nhằm cải thiện hiệu quả của việc phân loại ảnh. Kết quả từ nghiên cứu này sẽ là nền tảng cho việc phát triển các ứng dụng sử dụng tín hiệu GPR trong thời gian thực trên các công trường xây dựng, nhằm tăng năng suất và độ hiệu quả của công tác khảo sát bằng GPR.


2. DỮ LIỆU & PHƯƠNG PHÁP

2.1. Ảnh GPR

Hình ảnh quét GPR-B là hình ảnh GPR đen trắng chuyển đổi từ tín hiệu điện từ sang dạng ảnh 2D và không phải là ảnh quang học của đối tượng được khảo sát. Trục dọc của hình ảnh GPR thường biểu thị thời gian di chuyển của sóng điện từ (hoặc độ sâu) và trục ngang biểu thị khoảng cách của thiết bị GPR đang di chuyển. Độ phân giải của khảo sát GPR bị giới hạn ở một nửa bước sóng điện từ và tốc độ khảo sát. Khảo sát tần số cao tạo ra độ phân giải cao nhưng dẫn đến độ sâu điều tra nông [11]. Nghiên cứu này sử dụng tần số trung tâm là 400 MHz với ăng-ten được ghép nối với bộ điều khiển, cho kết quả khảo sát đến độ sâu trung bình 2m. Dữ liệu GPR được thu thập từ các khảo sát thực tế tại các công trường xây dựng ở Hàn Quốc trong giai đoạn từ năm 2018 đến 2020. Các ảnh GPR được ghi lại với độ phân giải 400×400 pixel, tương ứng với kích thước thực tế của mỗi pixel là $106 \text{ mm} \times 106 \text{ mm}$, xem Hình 2. Trong quá trình khảo sát, các ảnh GPR thu được được phân loại vào ba nhóm chính dựa trên loại phản xạ từ các vật thể dưới lòng đất, bao gồm:

- Nhiễu nền (NN): Các tín hiệu nhiễu ngẫu nhiên không mang thông tin về các vật thể dưới lòng đất, thường xuất hiện do các yếu tố môi trường như thiết bị điện tử, phương tiện giao thông hoặc trạm phát sóng vô tuyến.
- Lỗ rỗng (LR): Các phản xạ điển hình của các vật thể chôn vùi, lỗ rỗng có hình dạng hyperbol, chẳng hạn như các đường ống hoặc cáp ngầm.
- Hố ga (HG): phản xạ mạnh của sóng điện từ ở các nắp hố ga kim loại, do vật liệu kim loại không cho sóng điện từ đi xuyên qua.

Các ảnh GPR thu được đã được phân loại thủ công bởi các chuyên gia để xác định các nhóm trên và tạo thành bộ dữ liệu đầu vào cho quá trình huấn luyện mô hình học sâu.



Hình 2. Ảnh đặc trưng của 3 nhóm: (a) nhóm 1 NN; (b) Nhóm 2 LR; (c) Nhóm 3 HG.

2.2. Tăng cường dữ liệu với nhiễu trắng

Để tăng tính biến thiên của ảnh GPR, nhiễu trắng được đưa vào ảnh GPR thô bằng công thức (1). Nhiễu trắng, tức là nhiễu Gauss, được tạo ra ngẫu nhiên với hệ số biến thiên (cov) bằng 0,1 và được thêm vào ảnh GPR ban đầu để tạo ra các ảnh mới, từ đó giúp mô hình học được những đặc trưng mạnh mẽ hơn và cải thiện khả năng phân loại. Việc sử dụng nhiễu trắng nhằm mục đích làm tăng tính đa dạng của bộ dữ liệu, giúp mô hình học sâu trở nên tự động hơn trước các tác động nhiễu từ môi trường. Nhiễu được hạn chế ở mức thấp bằng hệ số biến thiên $cov=0,1$ để không làm ảnh hưởng huấn luyện biến dạng quá mức và vẫn giữ được các đặc trưng cơ bản [12]. Hệ số kết hợp Λ của nhiễu và ảnh thô được rút ra từ phân phối beta $B(\alpha, \alpha)$ với $\alpha = 0,2$ [13, 14]. Trong nghiên cứu này, để loại bỏ việc dán nhãn sai và trùng lặp, Λ được giới hạn ở $\Lambda \in (0,5 \cdot 1,0)$ và độ tin cậy của nhãn thực tế vẫn bằng với nhãn gốc:

$$\begin{cases} \hat{X} = \Lambda X_i + (1 - \Lambda) X_j \\ \hat{Y} = Y_i \end{cases} \quad (1)$$


Trong đó, $\hat{X}$ và $\hat{Y}$ là vector hình ảnh tổng hợp và nhãn của vector; X_i và Y_i là vector hình ảnh gốc và nhãn; $X_j = \mathcal{N}(0,5; 0,05^2)$ là vector nhiễu trắng.

2.3. Mạng học sâu DNN và cấu hình mô hình

Để phân loại các ảnh GPR, một mạng nơ-ron tích chập (DNN) được sử dụng. Mạng DNN bao gồm một bộ trích xuất đặc trưng sâu (deep feature extractor) và một bộ phân loại (classifier). Cấu hình của mạng DNN trong nghiên cứu này được thiết kế dựa trên mô hình VGG19, một mạng DNN nổi tiếng với khoảng 138 triệu trọng số phân bố trên 9 lớp [15]. Mạng VGG19 được sử dụng để trích xuất các đặc trưng từ các ảnh GPR, sau đó các đặc trưng này sẽ được đưa vào bộ phân loại để phân loại ảnh thành các nhóm NN, LR và HG.

Nghiên cứu này đề xuất sử dụng hàm chi phí (loss) được tạo ra bởi một mạng lưới tái tạo dựa trên một mạng siêu phân giải [16] tái tạo các hình ảnh đầu vào từ các tính năng được trích xuất bởi các mạng phân loại như thể hiện trong Hình 3. Ý tưởng là mạng lưới tái tạo điều khiển các tính năng của các mạng phân loại để bảo toàn thông tin của các hình ảnh đầu vào. Mạng lưới tái tạo được huấn luyện đồng thời với các mạng phân loại. Trong quá trình huấn luyện, các hình ảnh đầu vào ($X \in \mathbb{R}(w \times h \times c)$) được đưa vào mạng phân loại và các đặc trưng sâu ($F \in \mathbb{R}(w' \times h' \times c')$) từ lớp tích chập cuối cùng được sử dụng để huấn luyện trình tái tạo cho các hình ảnh được tái tạo ($XRC \in \mathbb{R}(w \times h \times c)$). Mạng tái tạo R bao gồm B khối HRB, là các chồng lớp tích chập $\text{Conv}(\cdot)$, chuẩn hoá $\text{BN}(\cdot)$ và hàm kích hoạt tuyến tính chỉnh lưu $\text{ReLU}(\cdot)$, và b khối tái tạo H_{UP} , là một chồng lớp $\text{Conv}(\cdot)$, xáo trộn điểm ảnh $\text{PixelShuffle}(\cdot)$ và $\text{ReLU}(\cdot)$. Hàm chi phí tổng L là sự kết hợp tuyến tính của tổn thất tái tạo $L_{RC}(X^{RC}, X)$ giữa các ảnh tái tạo XRC và ảnh đầu vào X và tổn thất entropy chéo $L_{CE}(Y', Y)$ giữa các nhãn dự đoán Y' và nhãn chính xác, được thể hiện ở công thức (2). Độ chính xác của mô hình sau quá trình huấn luyện được đánh giá bằng hệ số giữa số các kết quả dự đoán chính xác trên tổng số mẫu kiểm tra. Do đó, độ chính xác sẽ nằm trong khoảng từ 0,0 (không có dự đoán chính xác) đến 1,0 (tất cả các dự đoán đều chính xác).

$$L = L_{CE}(Y', Y) + L_{RC}(X^{RC}, X) \quad (2)$$



Hình 3. Mạng DNN áp dụng mô hình VGG19.

2.4. Phương pháp huấn luyện và phân loại

Quá trình huấn luyện mô hình được thực hiện với tổng số 3000 mẫu ảnh GPR thô với tỉ lệ đồng đều giữa 3 nhóm (1000 ảnh/ nhóm), với tỷ lệ dữ liệu huấn luyện và kiểm tra là 6:4, sử dụng cả ảnh GPR thô và ảnh GPR đã được tăng cường bằng nhiễu trắng. Nếu số lượng dữ liệu dùng cho quá trình huấn luyện giảm đi thì tính tổng quát của mẫu dữ liệu sẽ bị giảm, từ đó mô hình DNN sẽ có tính cục bộ và gặp khó khăn khi dự đoán các dữ liệu có sự khác biệt với mẫu huấn luyện. Nghiên cứu của tác giả trong [17] chỉ sử dụng 1000 ảnh GPR cho huấn luyện và 384 ảnh để kiểm tra. Các mô hình được huấn luyện trên loại dữ liệu:

- Dữ liệu GPR thô: Đây là dữ liệu gốc thu thập từ các công trường xây dựng, chưa qua xử lý.
- Dữ liệu tổng hợp: Đây là dữ liệu GPR đã được tăng cường với nhiễu trắng theo phương pháp tạo nhiễu trắng.

Quá trình huấn luyện được thực hiện trong nhiều vòng lặp (epoch) và sử dụng kỹ thuật dừng sớm (early stopping) để tránh quá khớp (overfitting). Mô hình học sâu sẽ được huấn luyện cho đến khi đạt được mức độ chính xác tối ưu trên dữ liệu kiểm tra.

Cuối cùng, các kết quả thu được từ mô hình học sâu sẽ được phân tích và so sánh giữa các ảnh GPR thô và ảnh GPR đã được tăng cường. Các chỉ số hiệu suất như độ chính xác, loss trong huấn luyện và xác nhận sẽ được tính toán và so sánh.


3. KẾT QUẢ THÍ NGHIỆM

Hiệu suất phân loại trên ảnh GPR đã được tăng cường với nhiễu trắng

Sau khi thử nghiệm trên ảnh GPR thô, chúng tôi tiến hành huấn luyện mô hình với dữ liệu đã được tăng cường bằng nhiễu trắng với hệ số biến thiên (cov) = 0,1. Kết quả huấn luyện trên dữ liệu tăng cường được trình bày trong Hình 4. Các quan sát chính bao gồm:

- Loss: Loss trong quá trình huấn luyện trên dữ liệu tăng cường giảm nhanh chóng trong vài vòng lặp đầu tiên, tương tự như với dữ liệu thô. Tuy nhiên, khác với ảnh GPR thô, loss trong xác nhận đạt đến mức thấp nhất tại điểm dừng sớm và sau đó có sự tăng nhẹ, nhưng không đáng kể. Điều này cho thấy dữ liệu tăng cường với nhiễu trắng giúp mô hình học tốt hơn và ít bị overfitting hơn.
- Độ chính xác (Accuracy): Độ chính xác trong huấn luyện đạt giá trị tối đa 1,0, chứng tỏ rằng mô hình học rất tốt trên bộ dữ liệu tăng cường. Tuy nhiên, độ chính xác trong xác nhận ở mức 0,941 tại điểm dừng sớm, thấp hơn một chút so với độ chính xác trong huấn luyện nhưng vẫn rất cao. Điều này cho thấy rằng ảnh GPR tăng cường với nhiễu trắng đã giúp mô hình học được các đặc trưng mạnh mẽ hơn, cải thiện khả năng phân loại.

Nhìn chung, việc tăng cường dữ liệu với nhiễu trắng đã giúp cải thiện hiệu suất phân loại, thể hiện qua sự cải thiện nhẹ nhưng rõ rệt trong độ chính xác của mô hình.



Hình 4. Kết quả huấn luyện trên hình ảnh tăng cường: (a) Loss; (b) Độ chính xác.

Mạng phân loại VGG với hàm chi phí được đề xuất được sử dụng để huấn luyện và thử nghiệm trên dữ liệu mới tạo bằng cách sử dụng dữ liệu gốc và dữ liệu thêm nhiễu trắng. Kết quả thử nghiệm được tóm tắt và hiển thị trong Bảng 1. Bảng 1 cho thấy nhiễu nền cải thiện đáng kể độ chính xác từ 87,9% lên 94,1%.

Bảng 1. Kết quả thí nghiệm.

Dữ liệu	Độ chính xác phân loại (%)
Dữ liệu gốc	87,9
Dữ liệu thêm nhiễu ($cov=0,1$)	94,1

4. PHÂN TÍCH & THẢO LUẬN

Hiệu quả của việc tăng cường dữ liệu với nhiễu trắng

Từ kết quả thí nghiệm, bảng nhầm lẫn (confusion matrix) khi kiểm tra trên mẫu thêm nhiễu được thể hiện ở Bảng 2, và so sánh hiệu quả khi kiểm tra trên dữ liệu thô và dữ liệu thêm nhiễu được tổng hợp ở Bảng 3.

Bảng 2. Bảng nhầm lẫn (confusion matrix) kiểm tra trên dữ liệu thêm nhiễu.


Giá trị thực	Dự đoán		
	Nhóm 1	Nhóm 2	Nhóm 3
Nhóm 1	363	17	20
Nhóm 2	5	389	6
Nhóm 3	10	14	376

Bảng 3. So sánh hiệu quả (coi nhóm 2 là dương tính và nhóm 1 và 3 là âm tính).

	Dữ liệu gốc	Dữ liệu thêm nhiễu
Độ chính xác dương tính (precision)	0,890	0,926
Tỉ lệ phát hiện dương tính (recall)	0,779	0,905
Độ chính xác F1	0,831	0,915

Độ chính xác dương tính xác định dựa trên tỉ lệ dương tính thật và tổng dương tính thật và dương tính giả, độ phát hiện dương tính được tính dựa trên tỉ lệ dương tính thật và tổng dương tính thật và âm tính giả. Từ độ chính xác dương tính và tỉ lệ phát hiện dương tính, hệ số chính xác F1 được xác định. F1 càng gần giá trị 1,0 thể hiện việc giảm quá khớp (overfitting). Kết quả từ các thí nghiệm cho thấy rằng việc tăng cường dữ liệu GPR với nhiễu trắng đã mang lại những cải thiện rõ rệt trong việc phân loại các ảnh GPR. Nhóm 2 là nhóm thể hiện phản xạ lỗ rỗng, đối tượng quan trọng cần được khảo sát nên được coi là nhóm dương tính, trong khi nhóm 1 và 3 là các phản xạ nhiễu nền và hố ga là các phản xạ không phải là mục tiêu khảo sát nên được coi là nhóm âm tính. Độ chính xác dương tính, tỉ lệ phát hiện dương tính và độ chính xác F1 được tính toán cho nhóm dương tính và thể hiện ở Bảng 3 đều tăng nhiều sau khi thêm nhiễu vào dữ liệu thô. So với việc sử dụng dữ liệu GPR thô, mô hình học sâu huấn luyện trên dữ liệu tăng cường cho thấy độ chính xác cao hơn và ít bị overfitting hơn. Điều này có thể lý giải bởi việc nhiễu trắng đã giúp làm tăng sự đa dạng trong bộ dữ liệu huấn luyện, giúp mô hình học được các đặc trưng mạnh mẽ hơn và trở nên linh hoạt hơn trong việc nhận diện các đối tượng trong ảnh.

Để thấy được hiệu quả phân loại sau khi thêm nhiễu, 2 ảnh thuộc nhóm 2 bị phân loại nhầm thành nhóm 1 trước khi thêm nhiễu, và đã được phân loại chính xác sau khi thêm nhiễu được thể hiện ở Hình 5. Quan sát cho thấy các ảnh này thể hiện đặc trưng nhóm 2 rất mờ nhạt và có thể bị nhầm lẫn thành nhóm 1. Việc ảnh phân loại nhầm được hiệu chỉnh cho thấy nhiễu nền đã giúp mạng chú ý hơn vào các đặc trưng riêng của nhóm, và không bị nhầm lẫn với các đặc trưng không liên quan.



Hình 5. Ảnh nhóm 2 bị phân loại nhầm trước khi thêm nhiễu và được phân loại đúng sau khi thêm nhiễu.


Bảng 4. Biến đổi Fourier và lọc tần số cao cho hình ảnh LR tổng hợp.

	Ảnh đầu vào	Biến đổi Fourier		Bộ lọc	
		3D	2D	Lọc tần số thấp	Ảnh sau lọc
Nhiều trắng (cov = 0,1)					
Ảnh LR gốc					
Ảnh LR được thêm nhiễu					

Sử dụng nhiễu trắng tạo ra các biến thể mới của ảnh GPR ban đầu nhưng vẫn giữ lại các đặc trưng chính của các đối tượng của các nhóm, xem Bảng 4. Bảng 4 thể hiện biến đổi Fourier cho nhiễu trắng, ảnh gốc LR, và ảnh sau khi thêm nhiễu trắng. Thêm nhiễu trắng không làm thay đổi quá nhiều thông tin ở tần số thấp, và chủ yếu biến đổi thông tin lưu trữ ở tần số cao hơn. Nhờ vậy ảnh mới được tạo ra khác với ảnh ban đầu nhưng vẫn giữ nguyên các đặc trưng cơ bản của đối tượng vốn được mã hoá ở tần số thấp. Nhờ vậy mô hình không chỉ học được các đặc trưng cơ bản tốt hơn và có khả năng phân loại tốt hơn đối với các nhiễu môi trường thực tế, như tín hiệu từ các thiết bị điện tử, phương tiện giao thông, hay các yếu tố khác có thể gây nhiễu trong quá trình thu thập dữ liệu. Như vậy, dữ liệu tăng cường bằng nhiễu trắng không chỉ giúp tăng tính chính xác của phân loại mà còn giúp mô hình trở nên ổn định hơn khi đối diện với

những yếu tố không thể kiểm soát trong môi trường thực.

Để phân tích sự thay đổi mức độ chú ý của mạng vào vùng khác biệt của nhóm 2 và 3, kỹ thuật tái tạo ngược từ đặc trưng cơ bản, Grad-cam, [18] được sử dụng vào ảnh trước và sau khi thêm nhiễu trắng của nhóm 2 và 3, thể hiện ở Hình 6. Trước khi thêm nhiễu, mức độ chú ý bị phân tán bởi các chi tiết nhiễu, không thể hiện đặc trưng của nhóm. Sau khi thêm nhiễu, mức độ chú ý vào các đặc trưng của nhóm được cải thiện rất nhiều và không bị phân tán bởi các chi tiết không đặc trưng.



Hình 6. Mức độ chú ý của mạng vào ảnh nhóm 2 tái tạo bằng Grad-cam [18]: (a) ảnh gốc nhóm 2; (b) Grad-cam nhóm 2 trước khi thêm nhiễu; (c) Grad-cam nhóm 2 sau khi thêm nhiễu; (d) ảnh gốc lớp 3; (e) Grad-cam nhóm 3 trước khi thêm nhiễu; (f) Grad-cam nhóm 3 sau khi thêm nhiễu.

Tăng cường hiệu suất phân loại và giảm quá khớp (overfitting)

Một trong những vấn đề phổ biến trong học sâu là overfitting, khi mô hình học quá chi tiết vào dữ liệu huấn luyện và không thể tổng quát tốt cho dữ liệu mới. Trong nghiên cứu này, mặc dù mô hình được huấn luyện trên một bộ dữ liệu GPR có kích thước trung bình (3000 ảnh), nhưng việc sử dụng nhiễu trắng để tăng cường dữ liệu đã giúp giảm thiểu hiện tượng overfitting.

Trong quá trình huấn luyện, mô hình sử dụng dữ liệu thô đã đạt đến điểm dừng sớm tại vòng lặp thứ 157, và từ đó độ mất mát trong xác nhận bắt đầu tăng lên, chỉ ra rằng mô hình đã học quá nhiều về dữ liệu huấn luyện và không thể áp dụng tốt cho dữ liệu xác nhận. Tuy nhiên, khi sử dụng ảnh tăng cường với nhiễu trắng, mô hình không gặp phải vấn đề này. Thay vì hiện tượng overfitting, độ chính xác trên dữ liệu xác nhận vẫn giữ được mức cao, chỉ có sự chênh lệch nhỏ giữa độ chính xác huấn luyện và xác nhận. Điều này cho thấy rằng việc tăng cường dữ liệu với nhiễu trắng giúp mô hình trở nên tổng quát hơn, có khả năng xử lý tốt hơn các tình

huống nhiều thực tế và cải thiện độ ổn định của mô hình.

5. KẾT LUẬN

Nghiên cứu này đã chứng minh rằng việc sử dụng mạng học sâu (DNN) để phân loại ảnh GPR là một phương pháp hiệu quả trong việc nhận diện và phân loại các vật thể dưới lòng đất, đặc biệt khi kết hợp với phương pháp tăng cường dữ liệu bằng nhiễu trắng. Các kết quả thực nghiệm cho thấy rằng mô hình học sâu huấn luyện trên ảnh GPR thô đạt hiệu suất cao, nhưng khi sử dụng ảnh tăng cường với nhiễu trắng, mô hình không chỉ cải thiện độ chính xác phân loại mà còn tăng cường khả năng xác định chính xác vị trí của các vật thể trong ảnh.

Cụ thể, dữ liệu tăng cường với nhiễu trắng giúp mô hình học sâu hiệu quả hơn với các nhiễu từ môi trường, giảm thiểu hiện tượng overfitting và cải thiện khả năng tổng quát khi phân tích các dữ liệu GPR thực tế.

Nghiên cứu này giúp gia tăng hiệu quả cho việc xử lý ảnh GPR ứng dụng rộng rãi trong các lĩnh vực như khảo sát địa chất, xây dựng cơ sở hạ tầng, và bảo trì các công trình ngầm. Tuy nhiên, để nâng cao độ chính xác và khả năng ứng dụng trong môi trường thực tế, cần tiếp tục nghiên cứu và cải thiện các phương pháp tăng cường dữ liệu, đặc biệt là với các loại dữ liệu có nhiễu cao hoặc môi trường không đồng nhất.

LỜI CẢM ƠN

Nghiên cứu này được hỗ trợ bởi Chương trình Nghiên cứu Khoa học Cơ bản thông qua Quỹ Nghiên cứu Quốc gia Hàn Quốc (NRF), được tài trợ bởi Bộ Khoa học, Công nghệ thông tin và Kế hoạch Tương lai, Hàn Quốc. (Số NRF-2021R1A5A1032433).

TÀI LIỆU THAM KHẢO

- [1]. A. P. Jaganathan, E. Allouche, N. Simicevic, Numerical modeling and experimental evaluation of a time domain UWB technique for soil void detection, *Tunn. Undergr. Space Technol.*, 25 (2010) 652-659. <https://doi.org/10.1016/j.tust.2009.08.006>
- [2]. D. Feng, X. Wang, B. Zhang, Specific evaluation of tunnel lining multi-defects by all-refined GPR simulation method using hybrid algorithm of FETD and FDTD, *Constr. Build. Mater.*, 185 (2018) 220–229. <https://doi.org/10.1016/j.conbuildmat.2018.07.039>
- [3]. W.-T. Hong, S. Kang, S. J. Lee, J.-S. Lee, Analyses of GPR signals for characterization of ground conditions in urban areas, *J. Appl. Geophys.*, 152 (2018) 65–76. <https://doi.org/10.1016/j.jappgeo.2018.03.005>
- [4]. S. Jones, H. Hunt, Voids at the tunnel–soil interface for calculation of ground vibration from underground railways, *J. Sound. Vib.*, 330 (2011) 245-270. <https://doi.org/10.1016/j.jsv.2010.08.015>
- [5]. R. D. Woods, *Dynamic effects of pile installations on adjacent structures*, National Academy Press, Washington, D.C., 1997.
- [6]. K. H. Ko, G. Jang, K. Park, K. Kim, GPR-Based landmine detection and identification using multiple features, *Int. J. Antennas Propag.*, 2012. <https://doi.org/10.1155/2012/826404>
- [7]. T. Saarenketo, Minnesota GPR 1998 Project, Report: TH28, Burtrum, District 3, (1998), Minnesota Department of Transportation, Office of Minnesota Road Research.
- [8]. F. Gutierrez, J. P. Galve, P. Lucha, C. Castaneda, J. Bonachea, J. Guerrero, Integrating geomorphological mapping, trenching, InSAR and GPR for the identification and characterization of sinkholes: A review and application in the mantled evaporite karst of the Ebro Valley (NE Spain), *Geomorphology*, 134 (2011) 144-156. <https://doi.org/10.1016/j.geomorph.2011.01.018>

- [9]. Trần Viết Tuấn, Ứng dụng Radar xuyên đất (GPR) để dò tìm và đo vẽ bản đồ công trình ngầm đô thị, Tạp chí khoa học đo đạc và bản đồ, 8 (2011), 12-15. <https://doi.org/10.54491/jgac.2011.8.449>
- [10]. Trần Anh Dũng, Nghiên cứu xác định hạ tầng kỹ thuật công trình ngầm dưới đường giao thông bằng công nghệ GPR, Đề tài Khoa học Công nghệ, Bộ Giao Thông Vận Tải, 2023.
- [11]. J. H. Bradford, Frequency-dependent attenuation analysis of ground-penetrating radar data, Geophysics, 72 (2007) J7–J16. <https://doi.org/10.1190/1.2710183>
- [12]. D. Cook, M. Julias, E. Nauman, Biological variability in biomechanical engineering research: Significance and meta-analysis of current modeling practices, Journal of Biomechanics, 47 (2014) 1241–1250. <https://doi.org/10.1016/j.jbiomech.2014.01.040>
- [13]. H. Zhang, M. Cisse, Y. N. Dauphin, D. Lopez-Paz, mixup: Beyond empirical risk minimization, in ICLR 2018 Conference Blind Submission, Vancouver, BC, Canada, 2017. <https://doi.org/10.48550/arXiv.1710.09412>
- [14]. D. Hendrycks, N. Mu, E. D. Cubuk, B. Zoph, J. Gilmer, B. Lakshminarayanan, AugMix: A simple data processing method to improve robustness and uncertainty, in ICLR 2020 · The Eighth International Conference on Learning Representations, 2020. <https://doi.org/10.48550/arXiv.1912.02781>
- [15]. K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, in 3rd International Conference on Learning Representations, (2015) 1–14. <https://doi.org/10.48550/arXiv.1409.1556>
- [16]. C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, W. S. Twitter, Photo-realistic single image super-resolution using a generative adversarial network, in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, Honolulu, HI, USA, IEEE, 105-114, <https://doi.org/10.1109/CVPR.2017.19>
- [17]. M. Elsaadouny, J. Barowski, I. Rolfes, ConvNet Transfer Learning for GPR Images Classification, in 2020 German Microwave Conference (GeMiC), Cottbus, Germany, (2020) 21-24.
- [18]. R. R. Selvaraju et al., Visual Explanations from Deep Networks via Gradient-Based Localization, in 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, (2017) 618-626. <https://doi.org/10.1109/ICCV.2017.74>