

**NGHIÊN CỨU XÁC ĐỊNH KHOANG RỔNG TRONG THÂN ĐÊ, ĐẬP BẰNG  
CÔNG NGHỆ RADAR XUYỀN ĐẤT KẾT HỢP THUẬT TOÁN HỌC SÂU**  
DETECTION OF CAVITIES WITHIN LEVEES AND EARTH DAMS USING GROUND  
PENETRATING RADAR INTEGRATED WITH DEEP LEARNING ALGORITHMS

**ĐOÀN XUÂN HƯNG<sup>a,\*</sup>, PHẠM THỊ THANH VÂN<sup>a</sup>, VŨ ĐỨC TRƯỜNG<sup>a</sup>**

<sup>a</sup>Viện Thiết kế/Tổng cục Hậu cần - Kỹ thuật/Bộ Quốc phòng

\*Tác giả đại diện: Email: xuanhungdhhbk@gmail.com

Ngày nhận 17/7/2026, Ngày sửa 12/8/2026, Chấp nhận 14/8/2026

<https://doi.org/10.59382/j-ibst.2026.vi.vol3-9>

**Tóm tắt:** *Khoang rỗng trong thân đê, đập hình thành chủ yếu do hiện tượng xói ngầm hoặc hoạt động đào hang của một số loài động vật là một trong những nguyên nhân chính làm suy giảm ổn định kết cấu và tiềm ẩn nguy cơ mất an toàn công trình. Nghiên cứu này đề xuất quy trình tự động phát hiện khoang rỗng đến độ sâu 3,5m bằng công nghệ radar xuyên đất sử dụng ăng-ten tần số kép 200–600 MHz kết hợp với mô hình học sâu YOLOv11. Dữ liệu GPR được thu nhận trên các tuyến khảo sát, tiền xử lý và sau đó chuyển định dạng ảnh B-scan. Bộ dữ liệu được gán nhãn trên nền tảng Roboflow và sử dụng để huấn luyện mô hình YOLOv11n, YOLOv11s và YOLOv11m nhận dạng tự động các vùng phản xạ đặc trưng của khoang rỗng. Hiệu quả của mô hình được đánh giá thông qua bốn chỉ số phổ biến trong bài toán phát hiện đối tượng, bao gồm Precision, Recall, mAP@50 và mAP@50–95. Kết quả nghiên cứu cho thấy phương pháp đề xuất có khả năng phát hiện nhanh và chính xác các khoang rỗng tùy thuộc vào môi trường khảo sát, góp phần nâng cao hiệu quả kiểm tra không phá hủy và hỗ trợ đánh giá an toàn đê, đập.*

**Từ khóa:** *Radar xuyên đất; kiểm định đê; thân đập; deep learning, YOLOv11.*

**Abstract:** *Internal voids within embankments and dams, primarily formed by internal erosion (piping) or burrowing activities of animals, are among the major factors contributing to structural instability and increasing the risk of infrastructure failure. This study proposes an automated approach for detecting internal voids at depths of up to 3,5 m using Ground Penetrating Radar (GPR) equipped with a dual-frequency 200–600 MHz antenna in combination with the YOLOv11 deep learning model. GPR data were collected along survey profiles, preprocessed, and subsequently converted into B-scan images. The dataset was annotated using the Roboflow platform and employed to train the YOLOv11n, YOLOv11s, and YOLOv11m models for the automatic detection of characteristic*

*reflection patterns associated with internal voids. Model performance was evaluated using four widely adopted object detection metrics, including Precision, Recall, mAP@50, and mAP@50–95. The results demonstrate that the proposed method is capable of rapidly and accurately detecting internal voids, with its detection performance depending on the survey environment. The proposed approach enhances the efficiency of non-destructive inspection and provides effective support for the safety assessment of embankments and dams.*

**Keywords:** *Ground penetrating radar; embankment inspection; dam embankment; deep learning; YOLOv11.*

## 1. Mở đầu

Việt Nam có 6648 hồ chứa thủy lợi chủ yếu quy mô vừa và nhỏ, phần lớn trong số đó có đập tạo hồ là đập đất [1-3]. Đê, đập là những công trình thủy lợi quan trọng, đóng vai trò bảo vệ dân cư, cơ sở hạ tầng và khu vực sản xuất trước các nguy cơ ngập lụt, đồng thời góp phần điều tiết nguồn nước phục vụ phát triển kinh tế - xã hội nói chung và nông nghiệp nói riêng. Việc bảo đảm an toàn đê, đập có ý nghĩa đặc biệt quan trọng trong bối cảnh biến đổi khí hậu và các hiện tượng thời tiết cực đoan ngày càng gia tăng [3].

Trong quá trình khai thác, thân đê và đập đất có thể xuất hiện các khoang rỗng do nhiều nguyên nhân khác nhau. Ngoài hiện tượng xói ngầm, khoang rỗng trong thân đê, đập còn có thể hình thành do nhiều nguyên nhân khác như rửa trôi vật liệu, nứt thân đê, lún không đều hoặc hoạt động đào hang của các loài động vật như mối, chuột và các sinh vật sống trong đất. Đặc biệt, mối là loài côn trùng có tập tính xây dựng hệ thống đường ngầm và tổ với cấu trúc phức tạp, có thể kéo dài trong thân đê. Các khoang rỗng này làm thay đổi ít nhiều cấu trúc thân đê đập, tạo điều kiện cho dòng thấm phát triển. Khi dòng thấm cuốn theo các hạt đất mịn, tạo thành các đường dẫn

thấm và dần hình thành các khoang rỗng trong thân hoặc nền công trình. Nếu không được phát hiện và xử lý kịp thời, các khoang rỗng này sẽ phát triển theo

thời gian, làm giảm khả năng chịu lực và có thể dẫn đến mất ổn định tổng thể của công trình từ đó làm gia tăng nguy cơ sự cố [4].



**Hình 1.** Vỡ đê sông Lô tại Tuyên Quang (Việt Nam) ngày 10 tháng 9 năm 2024 [5]. Hai đoạn thân đập của hồ chứa Liulan tại Hoàng Châu (Trung Quốc) bị vỡ ngày 6 tháng 7 năm 2026 [6]



**Hình 2.** Cấu trúc một tổ mối được tìm thấy trong thân đê [7]

Hiện nay, việc phát hiện khoang rỗng trong thân đê, đập chủ yếu dựa vào các phương pháp khảo sát trực tiếp như khoan thăm dò, đào kiểm tra hoặc quan sát hiện trường. Mặc dù cho độ tin cậy cao tại vị trí khảo sát, các phương pháp này thường tốn nhiều thời gian, chi phí lớn, không cơ động và chỉ cung cấp thông tin cục bộ, đồng thời có thể làm ảnh hưởng đến kết cấu công trình [8]. Đối với các tuyến đê có chiều dài hàng chục đến hàng trăm kilômét, việc áp dụng các phương pháp này trên diện rộng là rất khó khăn và khó đáp ứng được yêu cầu kiểm tra định kỳ. Do đó, các phương pháp khảo sát không phá hủy đang ngày càng được quan tâm trong công tác đánh giá hiện trạng và giám sát an toàn đê, đập.

Radar xuyên đất (Ground Penetrating Radar - GPR) là một trong những công nghệ địa vật lý

không phá hủy được ứng dụng rộng rãi trong khảo sát công trình ngầm, đánh giá kết cấu hạ tầng và khảo sát địa vật lý dưới bề mặt [9]. Phương pháp khảo sát này có thể xác định vị trí các vùng có sự thay đổi về hằng số điện môi như bề mặt các lớp vật liệu khác nhau, khoang rỗng, hang động hoặc các khu vực vật liệu bị suy yếu [10, 11]. Nhiều nghiên cứu đã chứng minh hiệu quả của GPR trong phát hiện tổ mối, hang động vật và các khoang rỗng bên trong thân đê, đập với ưu điểm nổi bật là khảo sát nhanh, không phá hủy và cho kết quả theo thời gian thực. GPR đã được áp dụng thành công trong khảo sát hồ xói quanh trụ cầu dưới nước, phát hiện hiện tượng xói mòn trong lõi đất sét của đập, kiểm tra đê điều, khảo sát đặc điểm các đứt gãy gần mặt đất, cũng như phát hiện các công trình ngầm dưới nước [12-14].

Mặc dù vậy, việc giải đoán dữ liệu GPR hiện nay vẫn phụ thuộc nhiều vào kinh nghiệm của chuyên gia [9]. Các phản xạ của sóng điện từ được thể hiện dưới dạng ảnh B-scan và có thể bị ảnh hưởng bởi nhiều môi trường, điều kiện địa chất hoặc độ ẩm của vật liệu phía dưới, làm cho quá trình nhận dạng thủ công trở nên khó khăn và mang tính chủ quan [15]. Trong những năm gần đây, cùng với sự phát triển mạnh mẽ của trí tuệ nhân tạo (Artificial Intelligence - AI), các mô hình học sâu (Deep Learning) đã được ứng dụng ngày càng rộng rãi trong xử lý ảnh và nhận dạng mẫu. Nhiều nghiên cứu đã chứng minh rằng các mô hình học sâu như CNN, Faster R-CNN, U-Net và đặc biệt là họ mô hình YOLO có khả năng phát hiện đối tượng trên ảnh GPR với độ chính xác cao tùy thuộc vào mô hình huấn luyện và giảm thời gian xử lý, góp phần giảm sự phụ thuộc vào chuyên gia giải đoán [9, 16-18]. Tuy nhiên, phần lớn các nghiên cứu hiện nay tập trung vào phát hiện cốt thép, đường ống hoặc khuyết tật trong mặt đường, trong khi các nghiên cứu về phát hiện khoang rỗng trong thân đê, đập bằng dữ liệu GPR thực địa vẫn còn tương đối hạn chế.

Xuất phát từ những vấn đề trên, nghiên cứu này đề xuất quy trình phát hiện tự động khoang rỗng trong thân đê, đập bằng công nghệ radar xuyên đất sử dụng ăng-ten tần số kép 200–600 MHz kết hợp với mô hình học sâu YOLOv11. Dữ liệu GPR được thu nhận trên các tuyến khảo sát thực địa, xử lý và chuyển đổi thành ảnh B-scan để xây dựng cơ sở dữ liệu huấn luyện trên nền tảng Roboflow. Mục tiêu của nghiên cứu là đánh giá khả năng ứng dụng của mô hình YOLOv11 trong nhận dạng tự động các khoang rỗng trong thân đê từ bề mặt khảo sát đến độ sâu khoảng 6m, qua đó góp phần nâng cao hiệu quả kiểm tra không phá hủy và hỗ trợ công tác đánh giá an toàn đê, đập.

## **2. Cơ sở lý thuyết và nguyên lý hoạt động của radar xuyên đất**

### **2.1 Cơ sở lý thuyết**

Hệ thống radar xuyên đất hoạt động dựa trên nguyên lý lan truyền và phản xạ sóng điện từ trong môi trường đất. Khi sóng điện từ được phát từ ăng-ten, chúng truyền xuống lớp đất và bị phản xạ tại các ranh giới có sự thay đổi hằng số điện môi. Tín hiệu phản xạ được ăng-ten thu nhận, số hóa và xử lý để suy ra vị trí và đặc tính của công trình ngầm [19].

Sự lan truyền sóng trong môi trường điện môi được mô tả bởi hệ phương trình Maxwell:

$$\nabla \times \mathbf{E} = -\mu \frac{\partial \mathbf{H}}{\partial t}, \nabla \times \mathbf{H} = \sigma \mathbf{E} + \varepsilon \frac{\partial \mathbf{E}}{\partial t} \quad (1)$$

trong đó,  $\mathbf{E}$  và  $\mathbf{H}$  lần lượt là cường độ điện trường và từ trường;  $\varepsilon$  là độ điện thẩm;  $\mu$  là độ từ thẩm;  $\sigma$  là độ dẫn điện của môi trường. Vận tốc lan truyền sóng điện từ được xác định:

$$v = \frac{c}{\sqrt{\varepsilon_r \mu_r}} \quad (2)$$

Đối với các môi trường không có từ tính như không khí, đất, cát hay bê tông...,  $\mu \approx \mu_0$  nên  $\mu_r = 1$ , do đó vận tốc lan truyền sóng  $v$  phụ thuộc chủ yếu vào độ điện thẩm tương đối  $\varepsilon_r$ :

$$v = \frac{c}{\sqrt{\varepsilon_r \mu_r}} \quad (3)$$


Với  $c$  là tốc độ ánh sáng trong môi trường chân không ( $v \sim 3 \times 10^8$  m/s). Khi tín hiệu được phản xạ lại ăng-ten, độ sâu đối tượng  $d$  được tính từ thời gian lan truyền hai chiều  $t$  theo công thức (3):

$$d = \frac{c \times t}{2\sqrt{\varepsilon_r}} \quad (4)$$

trong đó,  $d$  là độ sâu công trình ngầm. Hằng số điện thẩm  $\varepsilon_r$  nằm trong khoảng 1-40 tùy loại đất và 80 đối với nước mặn và nước ngọt. Ngoài ra, cường độ phản xạ tại ranh giới môi trường phụ thuộc vào sự khác biệt độ điện thẩm được xác định bởi hệ số phản xạ theo (5):

$$R = \frac{\sqrt{\varepsilon_{r_{i+1}}} - \sqrt{\varepsilon_{r_i}}}{\sqrt{\varepsilon_{r_{i+1}}} + \sqrt{\varepsilon_{r_i}}} \quad (5)$$

Với  $\varepsilon_{r_{i+1}}$  và  $\varepsilon_{r_i}$  lần lượt là độ điện thẩm của hai môi trường liền kề. Nếu  $\varepsilon_{r_{i+1}} > \varepsilon_{r_i}$ , sóng phản xạ sẽ đảo pha, nếu  $\varepsilon_{r_{i+1}} < \varepsilon_{r_i}$ , sóng phản xạ sẽ cùng pha.



Hình 3. Sự phản xạ sóng điện từ qua môi trường các lớp đất đá khác nhau [20]

## 2.2 Cấu tạo và nguyên lý hoạt động của hệ thống

Một hệ thống GPR điển hình gồm các bộ phận chính: ăng-ten phát, ăng-ten thu, khối điều khiển, thiết bị hiển thị và nguồn điện. Trong quá trình khảo sát, khối điều khiển phát xung điện từ tới ăng-ten phát, sau đó các xung này được truyền vào môi trường khảo sát. Khi sóng điện từ gặp mặt phân cách giữa hai môi trường có sự khác biệt về tính chất điện hoặc gặp các đối tượng có hằng số điện môi khác biệt so với môi trường xung quanh, một phần năng lượng sẽ phản xạ trở lại và được ăng-ten thu tiếp nhận, phần còn lại tiếp tục được truyền xuống dưới và lặp lại quy trình cho đến khi hết năng lượng truyền sóng. Tín hiệu phản xạ sau đó được khuếch đại, số hóa và truyền đến khối điều khiển để xử lý, đồng thời hiển thị dưới dạng các mặt cắt radar (A-scan, B-scan hoặc C-scan) phục vụ phân tích.

Thời gian lan truyền của sóng điện từ từ khi phát đến khi thu nhận tín hiệu phản xạ thường nằm trong khoảng từ vài chục đến vài nghìn nano giây, tùy thuộc vào độ sâu khảo sát và đặc tính của môi trường. Dựa trên thời gian lan truyền hai chiều của sóng điện từ và vận tốc truyền sóng trong môi trường, có thể xác định vị trí và độ sâu của đối tượng phản xạ được đề cập ở công thức (3).

Hiệu quả khảo sát của hệ thống GPR phụ thuộc vào nhiều yếu tố, trong đó quan trọng nhất là tần số của ăng-ten, năng lượng phát và đặc tính điện môi của môi trường khảo sát. Ăng-ten có tần số cao cho


độ phân giải lớn, giúp nhận biết các đối tượng có kích thước nhỏ nhưng khả năng xuyên sâu hạn chế. Ngược lại, ăng-ten tần số thấp có khả năng khảo sát ở độ sâu lớn hơn nhưng độ phân giải giảm. Ngoài ra, hằng số điện môi và độ dẫn điện của đất ảnh hưởng trực tiếp đến vận tốc lan truyền cũng như mức độ suy giảm tín hiệu, từ đó quyết định độ sâu khảo sát và chất lượng ảnh radar thu được.

Trong khảo sát đê, đập, các khoang rỗng thường có hằng số điện môi rất khác so với đất đắp xung quanh, tạo nên các phản xạ mạnh trên tín hiệu GPR. Khi biểu diễn dưới dạng ảnh B-scan, các khoang rỗng thường xuất hiện dưới dạng các đường cong hyperbol đặc trưng, là cơ sở để áp dụng các thuật toán học sâu, như YOLOv11, nhằm tự động phát hiện và nhận dạng các vị trí bất thường trong thân đê, đập.

## 3. Mô hình YOLOv11 và xây dựng bộ dữ liệu huấn luyện tự động nhận dạng khoang rỗng

### 3.1 Cấu trúc mạng Yolov11

YOLO11 là phiên bản cải tiến trong họ mô hình You Only Look Once (YOLO) do Ultralytics phát triển, hướng đến việc nâng cao hiệu quả phát hiện đối tượng trong khi vẫn duy trì tốc độ suy luận theo thời gian thực. So với các phiên bản trước, YOLO11 được cải tiến về khả năng trích xuất đặc trưng, hợp nhất thông tin đa tỷ lệ và tối ưu hóa quá trình dự đoán, giúp mô hình đạt độ chính xác cao hơn đối với các đối tượng có kích thước và hình dạng khác nhau.



Hình 4. Kiến trúc tổng quát của YOLOv11 [21]

Như minh họa trong Hình 4, kiến trúc của YOLO11 gồm ba thành phần chính là Backbone (mạng trích xuất đặc trưng), Neck (mạng hợp nhất đặc trưng) và Head (đầu phát hiện đối tượng). Ba thành phần này phối hợp với nhau để thực hiện quá trình trích xuất đặc trưng, hợp nhất thông tin và dự đoán đối tượng trong ảnh đầu vào.

Backbone là thành phần chịu trách nhiệm trích xuất đặc trưng từ ảnh đầu vào. Mạng sử dụng các lớp tích chập (Convolution) kết hợp với các khối C3k2 nhằm tăng khả năng học đặc trưng và cải thiện hiệu quả lan truyền gradient. Sau quá trình trích xuất, mô-đun Spatial Pyramid Pooling Fast (SPPF) được sử dụng để mở rộng vùng cảm nhận (receptive field), giúp mô hình khai thác thông tin ngữ cảnh ở nhiều tỷ lệ khác nhau. Tiếp theo, mô-đun Cross-Stage Partial with Spatial Attention (C2PSA) được tích hợp nhằm tăng cường khả năng chú ý không gian, giúp mô hình tập trung vào các vùng chứa thông tin quan trọng và nâng cao chất lượng biểu diễn đặc trưng.

Đầu ra của Backbone được truyền đến Neck, nơi thực hiện quá trình hợp nhất đặc trưng đa tỷ lệ. Thành phần này sử dụng các phép Upsample (nội

suy), Concat (nối) và các khối C3k2 để kết hợp các đặc trưng từ nhiều mức độ phân giải khác nhau. Việc kết hợp này cho phép mô hình đồng thời khai thác thông tin ngữ nghĩa từ các tầng sâu và thông tin chi tiết từ các tầng nông, qua đó cải thiện khả năng phát hiện các đối tượng có kích thước nhỏ, trung bình và lớn.

Cuối cùng, Head thực hiện nhiệm vụ phát hiện đối tượng trên ba mức đặc trưng P3, P4 và P5. Tại mỗi mức đặc trưng, mô hình đồng thời dự đoán vị trí hộp giới hạn (bounding box), xác suất tồn tại của đối tượng (objectness score) và nhãn phân loại (class probability). Cơ chế dự đoán đa tỷ lệ giúp YOLO11 tăng độ chính xác đối với các đối tượng có kích thước khác nhau trong cùng một ảnh, đồng thời vẫn duy trì tốc độ xử lý đáp ứng yêu cầu của các ứng dụng thời gian thực.


Bên cạnh những cải tiến về kiến trúc, YOLO11 còn áp dụng cơ chế phát hiện đối tượng không sử dụng hộp neo (anchor-free), trong đó mô hình dự đoán trực tiếp vị trí và kích thước của đối tượng mà không cần sử dụng các hộp neo (anchor boxes) được xác định trước. Cách tiếp cận này giúp giảm số lượng siêu tham số cần thiết, đơn giản hóa quá

trình huấn luyện và cải thiện khả năng tổng quát hóa trên nhiều tập dữ liệu khác nhau.


Nhờ sự kết hợp giữa các khối C3k2, mô-đun SPPF, C2PSA, cơ chế hợp nhất đặc trưng đa tỷ lệ và chiến lược phát hiện anchor-free, YOLO11 đạt được sự cân bằng giữa độ chính xác, tốc độ suy luận và hiệu quả tính toán. Vì vậy, mô hình được lựa chọn trong nghiên cứu này để thực hiện bài toán phát hiện đối tượng trên dữ liệu radar xuyên đất.

### 3.2 Xây dựng bộ dữ liệu huấn luyện mô hình phát hiện khoang rỗng

Trong nghiên cứu này, bộ dữ liệu được xây dựng nhằm huấn luyện và đánh giá trên mô hình YOLOv11 cho bài toán tự động phát hiện các khoang rỗng thân đê, đập. Quá trình khảo sát hiện trường, tín hiệu thu được từ radar xuyên đất được tiền xử lý, sau đó định dạng ảnh B-scan sử dụng làm dữ liệu đầu vào cho quá trình huấn luyện. Do đó, việc xây dựng một bộ dữ liệu được gán nhãn chính xác trên Roboflow đóng vai trò quan trọng trong quá trình huấn luyện mô hình, giúp YOLOv11 học được các đặc trưng của đối tượng mục tiêu và nâng cao khả năng phát hiện, định vị khoang rỗng trên các dữ liệu GPR.



a)



b)

**Hình 5.** Kết quả gán nhãn trên nền Roboflow; a) Hiển thị nhãn dán, b) Tính chất bộ dữ liệu nghiên cứu

Hình 5 trình bày thống kê phân bố các nhãn của tập dữ liệu huấn luyện sau khi gán nhãn. Tập dữ liệu chỉ bao gồm một lớp đối tượng là “khoảng”, 458 ảnh với 585 đối tượng được gán nhãn sử dụng trong quá trình huấn luyện, trong đó có một số ảnh không có đối tượng nhằm tăng khả năng phân biệt (Hình 5a). Quá trình gán nhãn được thực hiện trên nền tảng Roboflow, trong đó mỗi khoang rỗng được xác định bằng một hộp giới hạn (*bounding box*) và gán vào một lớp đối tượng duy nhất. Sau khi hoàn tất gán nhãn, bộ dữ liệu được xuất theo định dạng YOLO, bao gồm các tệp ảnh và tệp nhãn chứa thông tin về chỉ số lớp cùng tọa độ chuẩn hóa của hộp giới hạn.

Hình 5b cho thấy phân bố tâm của các hộp giới hạn tập trung chủ yếu ở vùng trung tâm của ảnh B-scan, phản ánh sự phân bố của các đối tượng trong

vùng khảo sát. Đồng thời, phân bố chiều rộng (*width*) và chiều cao (*height*) của các hộp giới hạn cho thấy kích thước đối tượng tương đối đồng đều, với phần lớn các giá trị chuẩn hóa nằm trong khoảng 0,10–0,30. Sự phân bố này cho thấy bộ dữ liệu có tính nhất quán về vị trí và kích thước của đối tượng, góp phần tạo điều kiện thuận lợi cho quá trình huấn luyện và nâng cao khả năng học đặc trưng của mô hình.

Để đánh giá khả năng tổng quát hóa của mô hình, bộ dữ liệu được chia thành ba tập gồm tập huấn luyện (Training), tập xác thực (Validation) và tập kiểm tra (Testing) theo tỷ lệ 80% : 10% : 10% với số ảnh lần lượt là 387, 48 và 49 ảnh. Trong đó, tập huấn luyện được sử dụng để học đặc trưng của đối tượng, tối ưu các tham số của mô hình. Tập xác thực phục vụ theo dõi quá trình hội tụ trong huấn luyện và lựa chọn mô hình có hiệu suất tốt nhất.

Tập kiểm tra được sử dụng để đánh giá khả năng phát hiện đối tượng trên các dữ liệu chưa xuất hiện trong quá trình huấn luyện.

Sau khi hoàn tất quá trình xây dựng bộ dữ liệu, ba phiên bản của YOLOv11 gồm YOLOv11n, YOLOv11s và YOLOv11m được huấn luyện trên nền tảng Ultralytics sử dụng bộ dữ liệu đã gán nhãn và xuất từ Roboflow theo định dạng YOLO. Việc sử dụng cùng một bộ dữ liệu và quy trình huấn luyện cho cả ba phiên bản giúp đảm bảo tính nhất quán trong quá trình đánh giá, cho phép so sánh khách quan hiệu quả phát hiện khoảng rỗng giữa các mô hình. Kết quả thực nghiệm được sử dụng để lựa chọn phiên bản YOLOv11 có hiệu suất tối ưu, đáp ứng yêu cầu về độ chính xác và khả năng triển khai trong thực tế.

#### 4. Kết quả và thực nghiệm kiểm chứng mô hình huấn luyện

##### 4.1 Kết quả huấn luyện mô hình

Sau khi hoàn thành quá trình huấn luyện, hiệu quả của các phiên bản YOLOv11n, YOLOv11s và

YOLOv11m được đánh giá thông qua bốn chỉ số phổ biến trong bài toán phát hiện đối tượng, bao gồm Precision, Recall, mAP@50 và mAP@50-95. Trong đó, Precision phản ánh tỷ lệ dự đoán đúng trên tổng số đối tượng mà mô hình phát hiện, thể hiện mức độ chính xác của các kết quả dự đoán. Recall biểu thị tỷ lệ đối tượng thực tế được mô hình phát hiện thành công, phản ánh khả năng phát hiện đầy đủ các đối tượng trong ảnh. mAP@50 (mean Average Precision tại ngưỡng IoU = 0,5) đánh giá đồng thời khả năng phát hiện và định vị đối tượng khi hộp dự đoán có độ chồng lấp với hộp thực tế từ 50% trở lên. Trong khi đó, mAP@50-95 là giá trị trung bình của mAP tại các ngưỡng IoU từ 0,50 đến 0,95 với bước 0,05, do đó là chỉ số đánh giá nghiêm ngặt hơn, phản ánh toàn diện chất lượng định vị của mô hình.

Trong nghiên cứu này, tiêu chí ưu tiên là giảm nguy cơ bỏ sót khoảng rỗng. Do đó, ngoài mAP, chỉ số Recall được sử dụng làm tiêu chí chính để lựa chọn mô hình, trong khi Precision được xem là tiêu chí nhằm kiểm soát tỷ lệ cảnh báo nhầm.

**Bảng 1.** Kết quả huấn luyện trên mô hình YOLOv11

| Mô hình | Precision (%) | Recall (%) | mAP@50 (%) | mAP@50-95 (%) | Tham số (Triệu) | GFLOPs |
|---------|---------------|------------|------------|---------------|-----------------|--------|
| YOLO11n | 87,1          | 65,7       | 82,5       | 43,7          | 2,58            | 6,3    |
| YOLO11s | 71,6          | 75,3       | 80,8       | 42,3          | 9,41            | 21,3   |
| YOLO11m | 84,3          | 70,1       | 81,3       | 42,5          | 20,03           | 67,7   |

Kết quả huấn luyện của ba mô hình YOLO11 được trình bày trong Bảng 1 cho thấy cả ba đều đạt hiệu quả tốt trong bài toán phát hiện khoảng rỗng trên ảnh radar xuyên đất. Giá trị mAP@50 dao động từ 80,8% đến 82,5%, trong khi mAP@50-95 đạt từ 42,3% đến 43,7%, chứng tỏ các mô hình đều có khả năng nhận diện đối tượng với độ chính xác tương đối cao.

Trong ba mô hình, YOLO11n đạt Precision cao nhất (87,1%), đồng thời có mAP@50 (82,5%) và mAP@50-95 (43,7%) cao nhất. Điều này cho thấy mô hình có khả năng đưa ra dự đoán chính xác và hạn chế các cảnh báo giả. Tuy nhiên, Recall chỉ đạt 65,7%, thấp nhất trong ba mô hình, phản ánh việc vẫn còn một số lượng đáng kể khoảng rỗng chưa được phát hiện.

Ngược lại, YOLO11s đạt Recall cao nhất (75,3%), chứng tỏ mô hình có khả năng phát hiện

được nhiều khoảng rỗng hơn. Tuy nhiên, Precision chỉ đạt 71,6%, thấp hơn đáng kể so với hai mô hình còn lại, đồng nghĩa với việc số lượng dự đoán nhầm tăng lên. Đồng thời, mAP@50 và mAP@50-95 của YOLO11s cũng thấp nhất trong ba mô hình.

Đối với YOLO11m, các chỉ số đạt được khá cân bằng với Precision = 84,3%, Recall = 70,1%, mAP@50 = 81,3% và mAP@50-95 = 42,5%. So với YOLO11n, Precision chỉ giảm 2,8% cho thấy có sự giảm nhỏ về độ chính xác của các dự đoán, trong khi Recall tăng 4,4%, cho thấy mô hình phát hiện được nhiều khoảng rỗng hơn, nghĩa là giảm số lượng khoảng rỗng bị bỏ sót.


Bên cạnh sự khác biệt về các chỉ số đánh giá, ba mô hình còn khác nhau về quy mô kiến trúc. YOLO11n chỉ gồm 2,58 triệu tham số và 6,3 GFLOPs, trong khi YOLO11s tăng lên 9,41 triệu tham số và 21,3 GFLOPs, còn YOLO11m đạt 20,03 triệu tham số với 67,7 GFLOPs. Số lượng tham số

và khối lượng tính toán lớn hơn giúp YOLO11m có khả năng học được các đặc trưng phức tạp của ảnh radar xuyên đất tốt hơn, đặc biệt đối với các tín hiệu phản xạ yếu, hình dạng không đồng nhất hoặc chịu ảnh hưởng của nhiễu. Đổi lại, mô hình yêu cầu nhiều tài nguyên tính toán hơn và thời gian huấn luyện cũng dài hơn.

Kết quả thử nghiệm cũng cho thấy thời gian suy luận của ba mô hình vẫn ở mức rất nhanh trên GPU Tesla T4, lần lượt khoảng 3,0 ms/ảnh đối với YOLO11n, 4,0 ms/ảnh đối với YOLO11s và 10,5 ms/ảnh đối với YOLO11m. Mặc dù YOLO11m có thời gian suy luận lớn hơn khoảng 3,5 lần so với YOLO11n, tốc độ này vẫn hoàn toàn đáp ứng yêu

cầu xử lý gần thời gian thực trong các ứng dụng kiểm định công trình.

Tổng hợp các kết quả trên cho thấy YOLO11n phù hợp khi ưu tiên tốc độ và độ chính xác của các dự đoán, YOLO11s phù hợp khi mục tiêu là phát hiện tối đa các đối tượng nhưng chấp nhận nhiều cảnh báo giả hơn, trong khi YOLO11m đạt được sự cân bằng tốt nhất giữa Precision và Recall. Với đặc thù của bài toán phát hiện khoang rỗng trong thân bê đập, nơi việc bỏ sót khuyết tật có thể dẫn đến những hậu quả nghiêm trọng hơn so với việc phát sinh một số cảnh báo giả, YOLO11m được lựa chọn là mô hình phù hợp nhất để triển khai trong nghiên cứu.




**Hình 6.** Diễn biến các hàm mất mát và các chỉ số đánh giá của mô hình YOLOv11m trong quá trình huấn luyện

Hình 6 trình bày diễn biến các hàm mất mát (loss) và các chỉ số đánh giá của mô hình YOLOv11n trong suốt quá trình huấn luyện. Kết quả cho thấy các hàm mất mát trên tập huấn luyện, bao gồm box\_loss, classification loss (cls\_loss) và distribution focal loss (df\_l\_loss), đều giảm dần theo số vòng lặp (epoch), chứng tỏ mô hình đã học được các đặc trưng của đối tượng và quá trình tối ưu diễn ra ổn định. Trên tập xác thực, các giá trị val/box\_loss, val/cls\_loss và val/df\_l\_loss dao động trong phạm vi hẹp và có xu hướng ổn định ở các epoch cuối, cho thấy mô hình không xuất hiện hiện tượng mất ổn định hoặc quá khớp rõ rệt.

Bên cạnh đó, các chỉ số đánh giá Precision, Recall, mAP@50 và mAP@50–95 đều tăng nhanh trong giai đoạn đầu của quá trình huấn luyện và dần hội tụ sau khoảng 20–30 epoch. Đến cuối quá trình

huấn luyện, mô hình đạt Precision  $\approx 0,84$ , Recall  $\approx 0,70$ , mAP@50  $\approx 0,81$  và mAP@50–95  $\approx 0,43$ , phù hợp với các giá trị được tổng hợp trong Bảng 1. Kết quả này cho thấy mô hình YOLOv11n có khả năng hội tụ tốt và đạt hiệu quả phát hiện khoang rỗng ổn định trên bộ dữ liệu nghiên cứu.

Hình 7 trình bày các đường cong đánh giá hiệu năng của mô hình YOLOv11m trên tập kiểm tra. Đường cong Precision–Confidence cho thấy độ chính xác của mô hình tăng dần theo ngưỡng độ tin cậy và đạt giá trị gần 1,0 khi ngưỡng confidence khoảng 0,791, chứng tỏ các dự đoán có độ tin cậy cao hầu hết đều chính xác. Ngược lại, đường cong Recall–Confidence có xu hướng giảm khi tăng ngưỡng confidence, phản ánh sự đánh đổi giữa khả năng phát hiện đầy đủ đối tượng và độ chính xác của mô hình huấn luyện.



Hình 7. Nhóm đường cong đánh giá của mô hình YOLOv11m sau khi huấn luyện

Đường cong Precision–Recall (PR Curve) đạt  $mAP@50 = 0,813$ , cho thấy mô hình duy trì được độ chính xác cao trên phần lớn phạm vi Recall và có khả năng phát hiện khoảng trống tốt trên bộ dữ liệu nghiên cứu. Bên cạnh đó, đường cong F1–Confidence đạt giá trị cực đại khoảng 0,77 tại ngưỡng confidence  $\approx 0,53$ , thể hiện sự cân bằng tối ưu giữa Precision và Recall. Do đó, ngưỡng confidence khoảng 0,45–0,50 được xem là phù hợp khi triển khai mô hình trong thực tế nhằm đảm bảo đồng thời độ chính xác và khả năng phát hiện đối tượng.

#### 4.2 Thực nghiệm kiểm chứng mô hình huấn luyện

Khu vực khảo sát được lựa chọn là tuyến đê Hà Châu, thuộc phường Vạn Xuân, tỉnh Thái Nguyên. Tuyến đê được lựa chọn làm đối tượng nghiên cứu nhằm đánh giá khả năng ứng dụng của mô hình YOLOv11 trong phát hiện tự động các khoảng trống từ dữ liệu radar xuyên đất (GPR) dưới điều kiện thực tế. Dữ liệu được thu thập trên tuyến đê bằng thiết bị radar xuyên đất IDS tần số kép F200–600 MHz, với mục tiêu phát hiện các khoảng trống trong thân đê đến độ sâu khoảng 3,5 m, phục vụ công tác kiểm tra và đánh giá định kỳ.



Hình 8. Vị trí tuyến đê khảo sát

Trước khi khảo sát, khu vực hiện trường được khảo sát sơ bộ nhằm ghi nhận điều kiện địa hình,

địa vật và các dấu hiệu bất thường như vết nứt, hố sụt hoặc hoạt động của động vật đào hang. Các

thông tin này được sử dụng làm cơ sở hỗ trợ quá


trình phân tích và giải đoán dữ liệu GPR.



**Hình 9.** Khảo sát radar xuyên đất tại hiện trường

Dữ liệu được thu thập bằng phần mềm K2 FastWave theo phương pháp quét dạng lưới với kích thước ô  $1,0 \times 1,0$  m hoặc lớn hơn tùy điều kiện thực tế. Trong mỗi ô khảo sát, các tuyến quét được thực hiện theo hai phương vuông góc gồm phương

dọc (Longitudinal – L) và phương ngang (Transversal – T) nhằm bảo đảm bao phủ toàn bộ khu vực khảo sát. Sau khi hoàn thành, dữ liệu GPR được lưu dưới dạng các ảnh B-scan để phục vụ quá trình kiểm chứng mô hình YOLOv11.



**Hình 10.** Kết quả nhận dạng khoang rỗng trên mô hình YOLOv11 tại KM2+125; a) Tín hiệu radar định dạng ảnh B-Scan, b) Kết quả nhận dạng khoang rỗng

Kết quả trên Hình 10 cho thấy mô hình YOLOv11 đã phát hiện các tín hiệu đặc trưng của khoang rỗng trên ảnh B-Scan tại hai mặt cắt thuộc KM2+125. Đối với ảnh thứ nhất, mô hình nhận diện được 02 khoang rỗng, nằm ở độ sâu khoảng 1,4 m và 1,6 m, tương ứng với vị trí cách gốc tọa độ khoảng 0,5 m và 1,0 m với độ tin cậy từ 0,59 đến 0,80. Các hộp bao bám sát vùng phản xạ dạng hyperbol, phù hợp với đặc trưng tín hiệu của khoang rỗng trên ảnh GPR. Đối với ảnh thứ hai, mô


hình phát hiện được một cụm gồm 06 khoang rỗng, phân bố ở độ sâu từ 1,3–2,1 m và cách gốc tọa độ từ 1,2–3,1 m. Các khoang được nhận dạng với mức độ tin cậy đến 0,68, phản ánh khả năng phát hiện đồng thời nhiều mục tiêu có kích thước và vị trí khác nhau. Qua phân tích cho thấy mô hình có khả năng xác định chính xác vị trí và phạm vi phân bố của các khoang rỗng trên mặt cắt radar, đáp ứng tốt yêu cầu hỗ trợ phân tích và đánh giá hiện trạng khoang rỗng trong thân đê, đập.



Hình 11. Khoan khảo sát khoang rỗng

Để kiểm chứng kết quả nhận dạng của mô hình YOLO11m, nhóm nghiên cứu đã tiến hành khoan khảo sát xác minh tại hiện trường ở vị trí KM2+125 (Hình 11), tương ứng với vị trí mô hình dự đoán có xuất hiện khoang rỗng trên ảnh radar xuyên đất (GPR). Vị trí khoan được lựa chọn tại tâm vùng có xác suất nhận dạng cao nhằm đánh giá độ tin cậy của mô hình. Kết quả khoan khảo sát cho thấy tại

khu vực này thực tế tồn tại khoang rỗng với vị trí và độ sâu phù hợp với tín hiệu dị thường được phát hiện trên ảnh B-Scan. Kết quả đối chứng giữa mô hình YOLO11m và khoan kiểm chứng hiện trường cho thấy sự tương đồng tốt về vị trí và phạm vi phân bố của khoang rỗng, qua đó khẳng định khả năng nhận dạng chính xác của mô hình trong việc phát hiện các vùng rỗng bên dưới công trình (Hình 12).



Hình 12. Kết quả xác định vị trí khoang rỗng tại KM2+125

## 5. Kết luận

Nghiên cứu đã xây dựng quy trình phát hiện tự động khoang rỗng trong thân đê, dựa trên dữ liệu radar xuyên đất (GPR) dựa trên mô hình học sâu YOLOv11. Bộ dữ liệu gồm các ảnh B-scan được thu thập từ khảo sát thực địa, gán nhãn trên nền tảng Roboflow và huấn luyện bằng thư viện Ultralytics. Ba phiên bản YOLOv11n, YOLOv11s và YOLOv11m được đánh giá nhằm lựa chọn mô hình phù hợp cho bài toán phát hiện khoang rỗng.

Kết quả thực nghiệm cho thấy mô hình YOLOv11m phù hợp nhiệm vụ khảo sát với Precision = 84,3%, Recall = 70,1%, mAP@50 = 81,3% và mAP@50-95 = 42,5%. Các đường cong hội tụ, đường cong Precision-Recall và các chỉ tiêu cho thấy mô hình có khả năng học ổn định, nhận dạng chính xác phần lớn các khoang rỗng trên ảnh GPR và duy trì hiệu suất tốt trên tập dữ liệu kiểm tra. Việc kiểm chứng trên dữ liệu khảo sát thực tế

tại tuyến đê Hà Châu, tỉnh Thái Nguyên cũng chứng minh tính khả thi của phương pháp trong việc hỗ trợ phát hiện nhanh các vị trí nghi ngờ xuất hiện khoang rỗng, góp phần nâng cao hiệu quả phân tích dữ liệu GPR và giảm sự phụ thuộc vào quá trình giải đoán thủ công.

Mặc dù đạt được kết quả khả quan, nghiên cứu vẫn còn một số hạn chế do quy mô bộ dữ liệu chưa lớn và chỉ bao gồm một lớp đối tượng, dẫn đến khả năng tổng quát hóa của mô hình chưa được đánh giá trên nhiều điều kiện địa chất và loại công trình khác nhau. Để mức độ chính xác đạt đến tối đa cần thêm số lượng lớn dữ liệu đầu vào với đa dạng các môi trường địa chất phản ánh thực tế của khoang rỗng ngoài tự nhiên cần được dán nhãn đầy đủ.

## TÀI LIỆU THAM KHẢO

- [1] Tổng cục Thủy lợi (2014). *Công tác quản lý an toàn hồ chứa nước thủy lợi – Hội thảo Đảm bảo an toàn*

- hồ đập – Thực trạng, thách thức và giải pháp.* Tổng cục Thủy lợi, Hà Nội.
- [2] *Báo cáo nghiên cứu khả thi dự án Sửa chữa, nâng cao an toàn đập (DaRSIP/WB8).* Viện Khoa học Thủy lợi Việt Nam, Hà Nội, 2015.
- [3] PennWell Corporation (2010). *Review of geophysical methods to detect seepage and internal erosion in embankment dams.* Hydro Review, 29(2).
- [4] Chlaib, F. H. K., Mahdi, H., Al-Shukri, H., Su, M. M., Catakli, A., Abd, N. (2014). *Using ground penetrating radar in levee assessment to detect small scale animal burrows.* Journal of Applied Geophysics, 103:121-131.
- [5] Hà, M., Huy, Đ. (2024). *Cận cảnh đoạn đê vỡ 22 m trên sông Lô.* Báo Thanh Niên. <https://thanhnien.vn/can-canhh-doan-de-vo-22-m-tren-song-lo-185240911233042681.htm>.
- [6] Zhang, P. (2026). *China dam collapse: Hundreds evacuated after typhoon rains breach Guangxi reservoir.* South China Morning Post. <https://www.scmp.com/news/china/politics/article/3359586/china-dam-collapse-hundreds-evacuated-after-typhoon-rains-breach-guangxi-reservoir>.
- [7] Trần Liên (2025). *PGS Vũ Văn Tuyển... người đột phá trong bảo vệ đê điều.* Tạp chí điện tử Tri thức và Cuộc sống.
- [8] Hassani, S., Dackermann, U. (2023). *A systematic review of advanced sensor technologies for non-destructive testing and structural health monitoring.* Sensors, 23(4):2204.
- [9] Đoàn Xuân Hưng, Phạm Thị Thanh Vân, Vũ Đức Trường (2025). *Nghiên cứu cấu tạo và ứng dụng công nghệ radar xuyên đất IDS kết hợp phương pháp học sâu trong khảo sát công trình ngầm.* Kỷ yếu Hội nghị khoa học quốc tế Kỷ niệm 60 năm thành lập Viện KHCN Xây dựng:487-495.
- [10] Daniels, D. J. (2004). *Ground Penetrating Radar (2nd ed.).* Institution of Engineering and Technology (IET), London.
- [11] Van, N. T., Cuong, L. V. A., Trung, D. H., Triet, V. M., Tuan, H. K. (2012). *Kirchhoff migration for specifying velocity model in ground penetrating radar method.* Proceedings of the International Conference on Ground Penetrating Radar, Shanghai, China:419-424.
- [12] Chang, W., Lai, J., Yen, C. (2004). *Evolution of scour depth at circular bridge piers.* Journal of Hydraulic Engineering, 130(9):905-913.
- [13] Cai, J., McMechan, G. A., Fisher, M. A. (1996). *Application of ground-penetrating radar to investigation of near-surface fault properties in the San Francisco Bay region.* Bulletin of the Seismological Society of America, 86(5):1459-1470.
- [14] Xu, X. X., Wu, J., Shen, J. Y., He, Z. C. (2006). *Case study: Application of GPR to detection of hidden dangers to underwater hydraulic structures.* Journal of Hydraulic Engineering, 132(1):12-20.
- [15] Tao, Y., Zeng, S., Zhou, K., Sun, H. (2025). *Cross-domain feature-enhanced YOLOv8 model for underground defect detection.* Reliability Engineering & System Safety, 264(Part B):111400.
- [16] Fang, Y., Tong, Z., Hei, T., Wang, S., Ma, T. (2026). *Deep learning applications in ground-penetrating radar inversion: A review.* Measurement, 258(Part D):119399.
- [17] Dai, Q., Lee, Y. H., Sun, H. H., Ow, G., Yusof, M. L. M., Yucel, A. C. (2023). *3DInvNet: A deep learning-based 3D ground-penetrating radar data inversion.* IEEE Transactions on Geoscience and Remote Sensing, 61:5105018.
- [18] Hoang, N. Q., Kang, S., Lee, J. S., Truong, Q. H. (2025). *Improving ground penetrating radar image classification using deep learning with white noise data augmentation.* Transport and Communications Science Journal, 76(6):916-927.
- [19] Zhou, D., Zhu, H. (2021). *Application of ground penetrating radar in detecting deeply embedded reinforcing bars in pile foundation.* Advances in Civil Engineering.
- [20] United States Environmental Protection Agency. *Ground-Penetrating Radar (GPR).* <https://www.epa.gov/environmental-geophysics/ground-penetrating-radar-gpr>, truy cập ngày 01/07/2026.
- [21] LearnOpenCV (2024). *YOLO11 Explained: Architecture, Applications and Custom Training.* <https://learnopencv.com/yolo11/>, truy cập ngày 01/07/2026.