



PHÁT HIỆN VÀ CẢNH BÁO SỚM HIỆN TƯỢNG SẠT LỞ ĐẤT CÁC TỈNH MIỀN NÚI PHÍA BẮC DỰA TRÊN KỸ THUẬT HỌC SÂU VÀ TRÍ TUỆ NHÂN TẠO ỨNG DỤNG THỰC TIỄN CHO TỈNH CAO BẰNG

EARLY DETECTION AND WARNING OF LANDSLIDE RISKS IN NORTHERN MOUNTAINOUS PROVINCES BASED ON DEEP LEARNING AND ARTIFICIAL INTELLIGENCE APPLIED IN PRACTICAL USE FOR CAO BANG PROVINCE

TS. Nguyễn Kim Cường¹, TS. Nguyễn Công Đức²,
TS. Nguyễn Quốc Huy³, TS. Kei Kawamura⁴

Tóm tắt: Địa hình Việt Nam có nhiều đồi núi, thường xảy ra hiện tượng sạt lở đất đá gây hậu quả nghiêm trọng về tính mạng và tài sản, đặc biệt tại khu vực miền núi trung du phía Bắc, trong đó có tỉnh Cao Bằng. Do đó, việc phát hiện và cảnh báo sớm nguy cơ sạt lở đất là cần thiết để kịp thời cảnh báo người dân sinh sống tại khu vực xung quanh vùng có nguy cơ sạt lở, nhanh chóng di dời tài sản và con người đến vị trí an toàn.

Trong bài báo này, nhóm tác giả sử dụng các hình ảnh thu thập từ vệ tinh tại tỉnh miền núi Yamaguchi (Nhật Bản), có địa hình tương tự khu vực miền núi trung du Việt Nam, làm cơ sở dữ liệu huấn luyện cho mô hình học sâu nhằm phát hiện sớm vết sạt lở đất thông qua kỹ thuật phân tích ảnh. Sau khi xây dựng được mô hình tối ưu, hệ thống được tích hợp API với công cụ hỗ trợ AI để triển khai cảnh báo sớm sạt lở đất cho các tỉnh miền núi phía Bắc, ứng dụng nghiên cứu thực tiễn cho tỉnh Cao Bằng.

Từ khóa: Ảnh vệ tinh, cảnh báo sớm, Cao Bằng, học sâu, sạt lở đất, UNet.

Abstract: Vietnam's mountainous terrain frequently leads to landslides, causing serious consequences for lives and property, especially in the northern mountainous and midland regions, including Cao Bang province. Therefore, early detection and warning of landslide risks are essential to promptly alert residents living in areas at risk, enabling them to quickly relocate property and people to safe locations.

In this article, the authors use satellite imagery from Yamaguchi province (Japan), a mountainous region with terrain similar to Vietnam's midland mountainous region, as the training database for a deep learning model to detect landslides early through image analysis techniques. After developing an optimized model, the system is integrated with an API and AI-powered tools to implement early landslide warning for the northern mountainous provinces, applying the research to Cao Bang province.

Keywords: Satellite imagery, early warning, Cao Bang, deep learning, landslides, UNet.

Nhận bài ngày 22/01/2026, chỉnh sửa ngày 20/02/2026, chấp nhận đăng ngày 25/3/2026.

I. ĐẶT VẤN ĐỀ

Việt Nam có khí hậu nhiệt đới, lượng mưa lớn và độ ẩm cao. Địa hình đồi núi, sườn dốc tại một số tỉnh miền núi chưa được gia cố và tăng cường ổn định đầy đủ. Do đó, vào mùa mưa (thường bắt đầu từ tháng 9 kéo dài đến tháng 12), các hiện tượng sạt lở đất đá, bong tróc và lăn xuống sườn đồi thường xảy ra, gây nguy hiểm cho giao thông và thiệt hại về tính mạng, tài sản của người dân cũng như các khu dân cư sinh sống xung quanh khu vực đó.

Diễn hình, cơn bão số 11 năm 2025 tại Cao Bằng đã cho thấy những hạn chế của phương pháp phòng chống thiên tai truyền thống vốn mang tính thụ động. Việc cứu hộ và cứu trợ sau sự cố chỉ có thể giảm nhẹ hậu quả tức thời, chưa phải là giải pháp chủ động


^{1,2,3} Nhóm nghiên cứu ATMD, Trường ĐH Xây dựng Miền Trung

⁴ Trường sau ĐH đổi mới khoa học công nghệ, Đại học Yamaguchi - Nhật Bản

Email liên hệ: ¹nguyenkimcuong@muce.edu.vn

nhằm phòng ngừa từ sớm, đặc biệt tại các khu vực có cấu trúc địa chất phức tạp như Nguyên Bình hoặc Bảo Lạc – Cao Bằng.

Vì vậy, việc xây dựng hệ thống cảnh báo sớm rủi ro sạt lở đất đá tại các xã miền núi tỉnh Cao Bằng nói riêng và khu vực phía Bắc nói chung là nhiệm vụ cấp thiết. Đây là giải pháp quan trọng nhằm giảm thiểu thiệt hại do thiên tai, đồng thời đảm bảo an sinh xã hội và an toàn cho hệ thống giao thông huyết mạch.



Hình 1. Vị trí nghiên cứu, bản đồ nhiệt về độ dốc, chấm đen vị trí nguy cơ sạt lở [1]

Trên thế giới và tại Việt Nam hiện nay đã có nhiều nghiên cứu phân tích ảnh vệ tinh để đánh giá nguy cơ sạt lở đất. Nguyen Trung Kien và các cộng sự [1] (2021) nghiên cứu lập bản đồ khả năng sạt lở đất dựa trên phương pháp thống kê hai biến và phương pháp phân tích thứ bậc có sửa đổi. Phương pháp này cho phép tính toán xác suất sạt lở dựa trên dữ liệu lịch sử. Tuy nhiên, phương pháp còn hạn chế do phụ thuộc nhiều vào dữ liệu quá khứ, trong khi biến đổi khí hậu có thể làm thay đổi điều kiện nền, đồng thời khả năng thích ứng với điểm dữ liệu mới còn hạn chế nếu thiếu dữ liệu quan trắc.

Mohan và các cộng sự [2], Li và các cộng sự [3] sử dụng phương pháp phân tích ảnh vệ tinh và kỹ thuật học sâu để trích xuất vết sạt lở dựa trên kỹ thuật viễn thám (remote sensing). Phương pháp này có thể kết hợp với phương pháp kiểm tra trực quan dựa trên sự thay đổi của từng pixel. Độ chính xác của phương pháp tương đối cao, tuy nhiên yêu cầu nhiều thời gian, tài nguyên tính toán và chi phí nhân công.

Funakoshi và các cộng sự [4] so sánh kỹ thuật học sâu kết hợp pix2pix [5] để trích xuất sự dịch chuyển của trầm tích thông qua so sánh ảnh trước và sau sự kiện. Kết quả cho thấy mức độ nhận dạng lỗi được cải thiện từ 12,9% đến 32,5%.

Chen và các cộng sự đề xuất DeepLabv3+ cho phân đoạn ảnh dựa trên cơ chế mã hóa – giải mã và so sánh với ResNet-38, PSPNet và DeepLabv3, cho thấy hiệu suất cao hơn. Mabu [6] sử dụng kiến trúc UNet với convolution autoencoder (CAE) để tăng cường khả năng giữ thông tin chi tiết khi đánh giá vùng phá hoại trầm tích. Ishii và các cộng sự [7] áp dụng mạng UNet để phát triển hệ thống tự động nhận dạng và cảnh báo sạt lở.

Trong nghiên cứu này, chúng tôi áp dụng cấu trúc mạng UNet để nhận dạng sạt lở dựa trên các hình ảnh thu thập từ ảnh vệ tinh.

II. VẬT LIỆU NGHIÊN CỨU

2.1. Cấu trúc mạng Unet

Hình 2 trình bày cấu trúc mạng UNet.

Trong tiến trình học của UNet, Encoder ($E^{1,1}$) học các đặc trưng cục bộ và tạo ra bản đồ đặc trưng (feature map) bằng cách thực hiện phép tích chập (convolution) trên hình ảnh đầu vào có kích thước 224×224 pixel với lớp tích chập tương ứng.

Tiến trình này bao gồm hai giai đoạn:

- Giai đoạn (a): Kết nối nút $D^{2,2}$ với nút $E^{2,1}$ trở thành đầu vào của nút $D^{1,2}$ (skip connection).

- Giai đoạn (b): Thực hiện phép MaxPooling để nén một nửa kích thước theo phương dọc và phương ngang của bản đồ đặc trưng, tạo thành đầu vào của nút $E^{2,1}$ ở tầng mã hóa tiếp theo.

Quá trình này giúp mô hình học có khả năng nắm bắt các đặc trưng của hình ảnh đầu vào, đồng thời xử lý sự dịch chuyển và biến dạng của các điểm đặc trưng.

Trong đó:

- Input: Hình ảnh vệ tinh đầu vào chứa các thông tin địa vật lý như độ ẩm, độ dốc, biến dạng bề mặt, chỉ số thực vật, mặt nước, công trình xây dựng.


- E_i : Tiến trình mã hóa lớp i của biến đầu vào thứ j .

Mỗi nút mã hóa bao gồm:

- Hai lớp tích chập Convolution ($32, 3 \times 3$);
- Hàm kích hoạt ReLU;
- MaxPooling (2×2);
- Padding = 1

Trong bước kết nối giữa Encoder và Decoder bao gồm:

- Một phép khuếch đại (upsampling);
- Hai phép tích chập với bộ lọc ($32, 3 \times 3$);
- Một phép tích chập (1×1);
- Hàm kích hoạt Sigmoid tại lớp đầu ra.



Hình 2. Cấu trúc mạng UNet

2.2. Cấu trúc mạng UNet cải tiến

Hình 3 thể hiện cấu trúc học sâu của mạng UNet cải tiến. Phần màu đỏ trong sơ đồ là phần bổ sung so với mạng UNet truyền thống.

Trong mạng UNet cải tiến, nhiều lớp mã hóa trực tiếp được thêm vào cho bốn nhánh. Mỗi nhánh trước khi kết nối với đầu ra đều thông qua một hàm mất mát để tính toán sai số tương ứng từ L1 đến L4.

Hình 4 thể hiện chi tiết quá trình phân cụm của từng giai đoạn trong mô hình UNet cải tiến. Trong từng nhánh, mô hình trích xuất các dịch chuyển vết sạt lở từ D^1 đến D^6 tương ứng với mỗi cấp độ đặc trưng.

Trong suốt quá trình huấn luyện:


- Bốn nhánh đều tính toán sai số so với hình ảnh nhân (ground truth);

- Sau đó lấy giá trị trung bình của sai số tại nút D1,6;


Sử dụng giá trị lỗi trung bình này để cập nhật và cải tiến các tham số của nút mã hóa (E) trong quá trình lan truyền ngược (backpropagation).

Hơn nữa, các bước kết nối giữa nút mã hóa (E) và giải mã (D) trong các lớp trở thành đường dẫn trong lan truyền ngược, từ đó tiến trình cập nhật sai số được cải tiến hiệu quả hơn.

Trong quá trình huấn luyện, bản đồ đặc trưng của mỗi giai đoạn trong tiến trình giảm mẫu (down-sampling) cũng được sử dụng để phát hiện sạt lở. Điều này giúp duy trì các thông tin chi tiết của vết sạt lở, hạn chế mất mát thông tin như trong mô hình UNet truyền thống.



Hình 3. Cấu trúc mạng UNet cải tiến



Hình 4. Trình tự cải tiến mạng UNet

III. KẾT QUẢ VÀ THẢO LUẬN

Bảng 1. Thể hiện các tham số thí nghiệm. Các hình ảnh được chụp địa hình tại khu vực Hiroshima, Nhật Bản theo hướng Bắc – Nam. Các hình ảnh này được chụp từ ngày 9 đến ngày 11 tháng 7


năm 2018, là thời điểm xảy ra mưa lớn ở phía Tây Nhật Bản. Những hình ảnh này thuộc bản quyền của Cơ quan Thông tin Địa lý Nhật Bản. Những hình ảnh này được sử dụng làm thí nghiệm với độ phân giải cao. Diện tích vùng ảnh vệ tinh là 36 km × 22,4 km theo hướng Đông – Tây, được sử dụng như các mẫu ảnh thẩm tra..

Bảng 1. Các thông số thí nghiệm 1

Cấu trúc Mạng	UNet		UNet cải tiến	
Kích thước ảnh huấn luyện	224*224 (pixels)			
Phép đo hiệu suất	F _{0.5}	F ₁	F ₂	F ₃
Số dữ liệu huấn luyện	7408 cặp			
Số dữ liệu kiểm tra	1856			
Số lần huấn luyện (Epoch)	100 vòng		300 vòng	
Kích thước Batch	16			
Phương pháp tối ưu	Adam (tỷ lệ học=0,00001)			

Những hình ảnh nhân dùng để training (Teaching images) được xử lý từ ảnh vệ tinh với độ phân giải cao nó cũng được cung cấp từ viện thông tin địa lý của Nhật Bản.

Hơn nữa, nhóm tác giả sử dụng kết quả phân tích sự dịch chuyển của sạt lở trong nghiên cứu trước, làm bộ dữ liệu để huấn luyện, thẩm định và kiểm tra kết quả của mô hình thí nghiệm. Bộ dữ liệu này được trích xuất xuống một cách trực quan ngay sau khi thảm họa ở Hiroshimazaka (từ ngày 9 đến ngày 11 tháng 7 năm 2018) do quá trình sạt trước ở độ dốc lớn. Bộ dữ liệu bao gồm nhiều hình ảnh khách quan khác nhau như vùng bồi lắng, vùng có dòng chảy, vùng trầm tích thảm thực vật, vùng có công trình xây dựng, giao thông, vùng bìa rừng...



Hình 5. ..


3.1. Phương pháp thí nghiệm

Để tạo dữ liệu huấn luyện, chúng tôi đã chọn 12 cặp hình ảnh kết quả giải thích tương ứng (sau đây gọi là hình ảnh chính xác) từ các khu vực được hiển thị trong Hình 6 (kích thước 12.560 × 6.087 pixel) với một lượng lớn trầm tích. Các hình ảnh này được chia thành các ảnh có kích thước 224 × 224 pixel. Ngoài ra, các vùng còn lại sau khi chia cũng được sử dụng cho việc huấn luyện mô hình.

Độ phân giải hình ảnh là khoảng 0,59 m/pixel. Trong vùng của hình ảnh được chia, một hình ảnh có 5% đất và cát trở lên

trong hình ảnh chính xác được xác định là hình ảnh có đất và cát; ngược lại, ảnh có 5% đất và cát trở xuống được xác định là ảnh không có đất và cát.

Hình ảnh được sử dụng làm dữ liệu huấn luyện. Cụ thể, có 2.316 cặp đã được chọn làm dữ liệu huấn luyện trong thí nghiệm này.



Hình 6. Ảnh phát hiện vết sạt lở trong hình Test 1

Hình 6 cho thấy các ví dụ về dữ liệu có đất và cát; không có đất và cát. Hình 5(b) là một ví dụ về dữ liệu với đất và cát. Nhìn vào hình ảnh chồng lên của bức ảnh chụp từ trên không và hình ảnh chính xác, người phiên dịch tạo ra hình ảnh chính xác cho thấy ngay cả những nơi đất và cát không lộ ra ngoài cũng được trích xuất thành. Điều này là do người phiên dịch xem xét tính liên tục của chuyển động trầm tích từ thông tin địa hình như thung lũng và sông, đồng thời giải thích các khu vực nơi trầm tích bị cây che khuất là trầm tích. Hơn nữa, để tăng lượng dữ liệu cho việc huấn luyện, chúng tôi đã xoay dữ liệu bộ ảnh gốc có chứa các yếu tố gây ra sạt lở và hình ảnh chính xác tương ứng ba lần sang phải theo góc 90°, 180° và 270° Epoch, đồng thời tăng dịch chuyển làm dữ liệu tăng lên đáng kể.

Tổng số tập dữ liệu huấn luyện cuối cùng thu được từ công việc trên là 9.264 cặp. Trong số này, khoảng 80% (7.408 cặp) được sử dụng làm dữ liệu huấn luyện và 20% còn lại (1.856 cặp) được sử dụng làm dữ liệu xác thực. Ở đây, dữ liệu huấn luyện là tập dữ liệu dùng cho mục đích học tính toán sai số giữa dữ liệu đầu vào và dữ liệu chính xác với mục đích cập nhật các trọng số, còn dữ liệu xác thực là đánh giá tình huống học tập không dùng để cập nhật các tham số của mô hình. Tập dữ liệu này được sử dụng để xác định các trọng số được sử dụng trong bộ phân loại nhằm mục đích nhập tập dữ liệu được tạo ở trên vào mạng học sâu và thực hiện việc huấn luyện. Việc hoàn thành một lần huấn luyện toàn bộ tập dữ liệu được gọi là một chu kỳ (Epoch). Vào cuối mỗi chu kỳ,

chúng tôi lưu các trọng số đã học và tính toán hàm lỗi với bộ dữ liệu huấn luyện và xác thực để tìm ra độ chính xác xác thực sau khi học, trọng số của số chu kỳ có độ chính xác của việc xác thực cao nhất sẽ được sử dụng cho bộ phân loại từ tập dữ liệu xác minh.

Bảng 2. Kết quả phép đo thí nghiệm

F	Mô hình	Test 1			Test 2		
		Recall	Precision	F-score	Recall	Precision	F-score
F _{0.5}	UNet++	0.65	0.40	0.50	0.76	0.36	0.49
	UNet	0.81	0.16	0.28	0.90	0.16	0.27

3.2. Phép đo hiệu suất mô hình

$$F_{\beta} = (1 + \beta^2) \frac{recall \cdot precision}{\beta^2 \cdot recall + precision}$$
 (1)

$$(Recall) = \frac{TP}{TP + FN}$$
 (2)

$$(Precision) = \frac{TP}{TP + FP}$$
 (3)

$$F_1 = 2 \frac{recall \cdot precision}{recall + precision}$$
 (4)

Bảng 3. Định nghĩa các tham số TP, TN, FN, FP

Hình ảnh dự đoán	Hình ảnh Thật	
	Có sạt lở	Không sạt lở
Có sạt lở	TP	FP
Không sạt lở	FN	TN


3.3. Kết quả thí nghiệm

Bảng 2 trình bày kết quả thí nghiệm, so sánh giữa 2 mô hình UNet ++ cho kết quả chính xác hơn mô hình UNet truyền thống. Dựa trên 2 phép đo precision và F-score được xác định trong phương trình (3) và (4), đo độ chính xác trên từng pixel ảnh. Trong khi đó giá trị Recall của phương pháp Unet truyền thống tốt hơn do có dự đoán về FN (false negative - không phát hiện được dấu vết gây sạt lở) nhỏ hơn. Kết quả thí nghiệm cho thấy rằng có thể sử dụng mô hình học sâu Unet ++ cải tiến được dùng để cảnh báo sớm nguy cơ sạt lở đất.

3.4. Hệ thống cảnh báo sớm

3.4.1 Hình ảnh đầu vào (Input data): Ảnh có độ phân giải cao, kết hợp từ nhiều nguồn dữ liệu mở toàn cầu như ảnh vệ tinh (Sentinel-1, Sentinel-2, NASA, ESA) có chứa 6 kênh thông tin như Hình 7 biểu thị thông tin về độ ẩm (SMI), thảm phủ (NDVI), độ dốc (slope), độ cao (DEM), chỉ số xây dựng (NDBI), chỉ số mặt nước (NDWI).

Hệ sinh thái Dữ liệu Đa nguồn



Hình 7. Ảnh kết hợp đa kênh được trích xuất từ nguồn mở vệ tinh

3.4.2. Mô hình AI: Công nghệ lõi là cấu trúc học sâu, UNet cải tiến giúp lọc các thông tin nhiễu, lưu giữ 6 đặc trưng thông tin của ảnh đầu vào, thông qua việc huấn luyện, cho ngay kết quả phán đoán đầu ra là có sạt lở hay không sạt lở. Ngưỡng tin cậy của UNet cải tiến là 66.7% được xem là mô hình có độ chính xác cao hơn các mô hình học sâu khác như DeepLabv3+.

3.4.3. Tối ưu hóa ảnh (video) thời gian thực: Hệ thống camera xử lý với tốc độ 21,66 khung hình/ giây. Với tốc độ này cho phép phát tin cảnh báo tức thời khi ngưỡng mưa, độ bão hòa đất vượt ngưỡng an toàn.

Qua kết quả phân tích cho thấy đến 94% yếu tố gây sạt lở là do độ dốc, tiếp theo do địa chất, hướng dốc và lượng mưa tích lũy. Thường sạt lở xảy ra khi lượng mưa lớn rơi vào vùng đất đã đạt trạng thái bão hòa [8].

3.4.4 Đánh giá hiệu suất thông qua chỉ số KPIs:

KPI cho mô hình LSI (Phân loại rủi ro): Đạt ngưỡng AUC 0.968. Đây là chỉ số chứng minh khả năng phân biệt cực tốt giữa vùng an toàn và vùng nguy hiểm tiềm tàng.

Chỉ số LSI (Landslide Risk Index) được tính công thức sau:

$$LSI = \sigma(\omega_1 Slope + \omega_2 DEM + \omega_3 NDVI + \dots) R_m$$

$$R_m = \alpha P + \beta D$$

Trong đó: ω_i là trọng số của các yếu tố tác động tĩnh thứ i (độ dốc, độ cao, độ ẩm, thảm thực vật...), R_m : Hệ số nhân mưa tác động động tính đến cường độ mưa (P) và thời gian mưa (D), α, β : Hệ số điều chỉnh.

Có thể cho rằng chỉ số LSI hoạt động như một lớp kiến thức chuyên gia "expert knowledge" hỗ trợ, định hướng thêm cho mô hình AI.

Tốc độ xử lý: Duy trì trên 21 FPS để đảm bảo tính thời gian thực cho hệ thống cảnh báo sớm.

Việc đạt được các chỉ số này giúp giảm thiểu tối đa "sai số cảnh báo giả" – nguyên nhân chính gây ra tâm lý chủ quan trong nhân dân. Khi AI đạt độ tin cậy cao, sự phối hợp giữa các đơn vị cứu hộ sẽ hiệu quả hơn, kịp thời sơ tán tài sản và nhân mạng trước khi sạt lở xảy ra.

IV. KẾT LUẬN

Bài báo này nhóm tác giả tập trung phát triển mô hình học sâu UNet cải tiến để lọc nhiễu và trích xuất các đặc trưng của hình ảnh đầu vào chứa đựng thông tin như về độ ẩm, độ dốc, hướng dốc, thảm thực vật, chỉ số xây dựng, mặt nước, đất... cho ra kết quả đầu ra là có hay không sạt lở.

Tác giả đề xuất bộ KPIs để tính chỉ số LSI như là một định hướng hỗ trợ ra quyết định thêm cho mô hình cảnh báo thời gian thực. Lộ trình kỹ thuật này sẽ tiếp tục được hoàn thiện bằng cách tích hợp dữ liệu từ các cảm biến IoT thực địa và hiệu chỉnh trọng số LSI theo đặc thù địa chất đá vôi Karst của từng huyện, đưa Cao Bằng trở thành một trong tỉnh đi đầu trong ứng dụng mô hình AI và phân tích ảnh không gian vào quản trị rủi ro thiên tai bền vững trong điều kiện khí hậu cực đoan.

Trần Công (BT)

Tài liệu tham khảo:

- [1] Nguyen, T. K., Tran, T. V., Lien, V. T. H., Linh, P. L. H., & Thanh, N. Q. (2021). *Landslide susceptibility mapping based on the combination of bivariate statistics and modified analytic hierarchy process methods: A case study of Tinh Tuc town, Nguyen Binh district, Cao Bang province, Vietnam*. Journal of Disaster Research, 16(4).
- [2] Mohan, A., & Singh, A. K. (2021). *Review on remote sensing methods for landslide detection using machine and deep learning*. Transactions on Emerging Telecommunications Technologies, 32.
- [3] Li, H., & He, Y. (2022). *Detection and segmentation of loess landslides via satellite images: A two-phase framework*. Landslides, 19(3), 673–686.
- [4] Funakoshi, K., & Kakuta, S. (2020). *A study on a method for detecting landslide areas automatically using constellation satellite optical images*. Journal of the Japan Society of Erosion Control Engineering, 73(2), 34–41.
- [5] Isola, P., Zhu, J.-Y., Zhou, T., & Efros, A. A. (2017). *Image-to-image translation with conditional adversarial networks*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [6] Mabu, S. (2021). *Landslide area detection from synthetic aperture radar (SAR) images using convolutional neural networks*. Systems, Control and Information, 65(2), 39–46.
- [7] Ishii, M., Hirokane, M. (2020). *Considering social factors in setting of sediment disaster warning area using deep learning*. Journal of Japan Society of Civil Engineers, Series F6 (Safety Problem), 74(2), I_193–I_199.
- [8] Trần, M. C., Trần, A. P., Nguyễn, A. Đ., Trần, V. T., & Trần, B. C. (2025). *Application of the random forest machine learning model in developing landslide susceptibility maps in Lao Cai province*. Tạp chí Môi trường, Số chuyên đề khoa học (20/9/2025).