

Xây dựng chỉ số thực vật kết hợp giữa ảnh vệ tinh quang học và radar (CORVI) phục vụ phân loại lớp phủ ven biển tại miền Bắc Việt Nam

Nguyễn Văn Thị¹, Nguyễn Hải Hòa^{2*}, Lê Sỹ Doanh²

¹Công ty Cổ phần Thương mại Công nghệ Xuân Mai Green

²Trường Đại học Lâm nghiệp

Developing a combined optical and radar vegetation index (CORVI) for coastal land cover classification in Northern Vietnam

Nguyen Van Thi¹, Nguyen Hai Hoa^{2*}, Le Sy Doanh²

¹Xuan Mai Green Technology Trading Joint Stock Company

²Vietnam National University of Forestry

*Corresponding author: hoanhh@vnuf.edu.vn

<https://doi.org/10.55250/jo.vnuf.15.7.2026.092-101>

Thông tin chung:

Ngày nhận bài: 30/05/2026

Ngày phản biện: 02/07/2026

Ngày quyết định đăng: 31/07/2026

Từ khóa:

CORVI, Random Forest, rừng ngập mặn, Sentinel-1, Sentinel-2, tích hợp quang học và Radar.

Keywords:

CORVI, Combined Optical and Radar, mangrove forests, Random Forests, Sentinel-1, Sentinel-2.

TÓM TẮT

Nghiên cứu xây dựng chỉ số thực vật kết hợp giữa ảnh quang học Sentinel-2 và Radar Sentinel-1, gọi là CORVI (Combined Optical and Radar Vegetation Index), nhằm đánh giá khả năng phân loại lớp phủ ven biển miền Bắc Việt Nam. CORVI được xây dựng từ chỉ số RVI (Radar Vegetation Index) của Sentinel-1 và hai kênh SWIR B11, B12 của Sentinel-2. Năm lớp phủ được phân loại gồm rừng ngập mặn, cây nông nghiệp, công trình xây dựng, đất trống và mặt nước. Các chỉ số NDVI (Normalized Different Vegetation Index), RVI và CORVI được tính từ ảnh tổ hợp Quý 4 năm 2025 và đưa vào mô hình Random Forest (RF) theo sáu kịch bản đầu vào. Độ chính xác được đánh giá bằng kiểm định chéo 5-fold và báo cáo dưới dạng trung bình $\pm$ độ lệch chuẩn. Kết quả cho thấy các chỉ số đơn lẻ chưa đủ để phân biệt hiệu quả toàn bộ lớp phủ ven biển; trong đó NDVI đạt độ chính xác cao nhất trong nhóm đơn biến với OA = $60,71 \pm 0,71\%$. Khi kết hợp NDVI với CORVI, OA tăng lên $70,98 \pm 0,77\%$. Kịch bản tích hợp đầy đủ NDVI, RVI và CORVI đạt kết quả tốt nhất với OA = $82,93 \pm 0,32\%$, Kappa = $0,7792 \pm 0,0042$ và Macro-F1 = $80,25 \pm 0,52\%$. Đối với lớp RNM, kịch bản này đạt PA = $95,21 \pm 1,75\%$, UA = $89,14 \pm 1,56\%$ và F1-score = $92,05 \pm 0,67\%$. Kết quả cho thấy CORVI là biến tích hợp hữu ích trong mô hình đa biến, có tiềm năng hỗ trợ lập bản đồ RNM và giám sát lớp phủ ven biển từ dữ liệu Sentinel-1/Sentinel-2.

ABSTRACT

This study developed a vegetation index integrating Sentinel-2 optical imagery and Sentinel-1 Radar data, named CORVI (Combined Optical and Radar Vegetation Index), to assess coastal land cover classification in northern Vietnam. CORVI was constructed from the Sentinel-1 RVI (Radar Vegetation Index) and the two Sentinel-2 SWIR bands, B11 and B12. Five land cover classes were classified, including mangrove forests, agricultural land, built-up areas, bare land, and water bodies. NDVI (Normalized Difference Vegetation Index), RVI, and CORVI were derived from the fourth-quarter 2025 composite imagery and used as input variables in a Random Forest (RF) model under six scenarios. Classification accuracy was evaluated using 5-fold cross-validation and reported as mean $\pm$ standard deviation. The results show that single indices were insufficient to effectively distinguish all coastal land cover classes; among the single-index scenarios, NDVI achieved the highest accuracy, with an OA of $60.71 \pm 0.71\%$. When NDVI was combined with CORVI, OA increased to $70.98 \pm 0.77\%$. The full integration scenario using NDVI, RVI, and CORVI achieved the best performance, with an OA of $82.93 \pm 0.32\%$, Kappa of 0.7792 ± 0.0042 , and Macro-F1 of $80.25 \pm 0.52\%$. For the mangrove forest class, this scenario achieved a PA of $95.21 \pm 1.75\%$, UA of $89.14 \pm 1.56\%$, and F1-score of $92.05 \pm 0.67\%$. These findings indicate that CORVI is a useful integrated variable in multivariate models, with potential to support mangrove mapping and coastal land cover monitoring using Sentinel-1/Sentinel-2 data.

1. ĐẶT VẤN ĐỀ

Rừng ngập mặn (RNM) là một trong những thảm thực vật ven biển có giá trị sinh thái, môi trường và kinh tế đặc biệt, phân bố chủ yếu ở vùng nhiệt đới và cận nhiệt đới, nơi đất liền, sông và biển tương tác mạnh dưới tác động của thủy triều [1-3]. Hệ sinh thái này không chỉ góp phần bảo vệ bờ biển, giảm xói lở, duy trì đa dạng sinh học và hỗ trợ sinh kế cộng đồng, mà còn giữ vai trò quan trọng trong chu trình các-bon xanh [1, 2, 4]. Nhiều nghiên cứu đã chỉ ra rằng RNM có khả năng tích lũy các-bon lớn trong sinh khối và trầm tích, qua đó đóng góp đáng kể vào điều hòa khí hậu và giảm thiểu phát thải khí nhà kính [1, 4, 5].

Trong nghiên cứu và quản lý RNM, việc xác định chính xác phân bố không gian của rừng là bước nền tảng trước khi đánh giá biến động diện tích, cấu trúc rừng, sinh khối và trữ lượng các-bon. Giri đã sử dụng dữ liệu vệ tinh để lập bản đồ hiện trạng và phân bố RNM toàn cầu [6], trong khi Bunting cung cấp chuỗi dữ liệu Global Mangrove Watch giai đoạn 1996–2020 nhằm hỗ trợ giám sát biến động RNM ở quy mô toàn cầu [7]. Các nghiên cứu tổng quan gần đây cũng cho thấy viễn thám đã trở thành công cụ quan trọng trong lập bản đồ, theo dõi biến động và đánh giá các thuộc tính sinh thái của RNM [8-10]. Tuy nhiên, phân biệt RNM với các lớp phủ ven biển khác bằng viễn thám vẫn là một thách thức đáng kể [8, 9, 11]. Do đó, phân loại chính xác lớp phủ ven biển không chỉ có ý nghĩa trong lập bản đồ hiện trạng mà còn là bước tiền đề để xây dựng mô hình ước tính sinh khối và trữ lượng các-bon RNM ở các giai đoạn tiếp theo [6, 8, 9].

Dữ liệu quang học, đặc biệt là Sentinel-2 MSI, có ưu thế trong phản ánh đặc điểm phổ của thảm thực vật nhờ các kênh nhìn thấy, cận hồng ngoại, red-edge và SWIR. Sentinel-2 thu nhận 13 kênh phổ, trong đó B11 và B12 là hai kênh SWIR có độ phân giải không gian 20 m, thường được sử dụng để phản ánh độ ẩm của thảm thực vật, đất và nền bề mặt [12]. Trong nhóm chỉ số quang học, NDVI là chỉ số được sử dụng rộng rãi để mô tả độ xanh và hoạt động sinh trưởng của thảm thực vật [13]. Đối với RNM, các chỉ số phổ như NDVI, EVI (Enhanced

Vegetation Index), NDWI (Normalized Difference Water Index), NDMI (Normalized Difference Moisture Index) và các chỉ số chuyên biệt khác đã được sử dụng phổ biến trong phân loại, giám sát và đánh giá trạng thái rừng; trong đó NDVI là một trong những chỉ số được ứng dụng nhiều nhất [11]. Tuy nhiên, trong môi trường ven biển, các chỉ số quang học có thể bị ảnh hưởng bởi mây, bóng mây, nền nước, bùn ẩm, sự pha trộn pixel và sự tương đồng phổ giữa RNM với các kiểu thảm thực vật khác.

Khác với dữ liệu quang học, Sentinel-1 SAR là nguồn dữ liệu radar chủ động, có khả năng thu nhận ảnh trong điều kiện mây che phủ và hoạt động cả ngày lẫn đêm. Tín hiệu SAR, thông qua các phân cực như VV và VH, phản ánh độ nhám, cấu trúc và độ ẩm bề mặt, do đó bổ sung thông tin quan trọng cho phân loại lớp phủ ven biển và giám sát RNM [9, 10]. Trong các chỉ số RVI được sử dụng để mô tả trạng thái thảm thực vật dựa trên đặc điểm tán xạ radar. Với dữ liệu Sentinel-1 hai phân cực, RVI thường được biểu diễn dưới dạng $RVI = 4VH/(VV+VH)$, trong đó VH và VV được sử dụng ở dạng tán xạ tuyến tính [14]. Các nghiên cứu gần đây cho thấy RVI và các biến thể radar hai phân cực có tiềm năng phản ánh cấu trúc và trạng thái sinh trưởng của thảm thực vật, đặc biệt khi dữ liệu quang học bị hạn chế bởi mây hoặc điều kiện khí quyển [15]. Mặc dù dữ liệu radar có ưu thế trong điều kiện mây và có khả năng phản ánh cấu trúc bề mặt, tín hiệu SAR cũng chịu ảnh hưởng của độ ẩm nền, điều kiện ngập nước, nhiễu speckle và hình học quan sát. Vì vậy, xu hướng kết hợp dữ liệu quang học và radar ngày càng được quan tâm trong nghiên cứu RNM, do mỗi nguồn dữ liệu phản ánh một khía cạnh khác nhau của lớp phủ: dữ liệu quang học nhạy với trạng thái sinh trưởng, trong khi dữ liệu radar nhạy với cấu trúc, độ nhám và độ ẩm bề mặt [8-10].

Trên cơ sở tích hợp ưu thế của dữ liệu quang học và Radar, nhiều nghiên cứu trên thế giới đã sử dụng kết hợp các chỉ số phổ từ ảnh quang học như NDVI, EVI, NDWI, NDMI, các kênh red-edge/SWIR với các biến Radar như hệ số tán xạ VV, VH, tỷ số VH/VV, VV/VH, RVI hoặc các đặc trưng texture để phân loại lớp phủ, giám sát RNM và đánh giá cấu trúc rừng [8-11, 16]. Các

nghiên cứu tổng quan cho thấy dữ liệu quang học có ưu thế trong phản ánh độ xanh, trạng thái sinh trưởng và đặc điểm phổ của thảm thực vật, trong khi dữ liệu Radar bổ sung thông tin về cấu trúc, độ nhám, độ ẩm bề mặt và có khả năng quan sát trong điều kiện mây che phủ [8-10, 16]. Tuy nhiên, phần lớn các nghiên cứu thường đưa các biến quang học và Radar vào mô hình dưới dạng các biến độc lập, thay vì xây dựng một chỉ số tích hợp trực tiếp giữa hai nguồn dữ liệu. Trong bối cảnh đó, nghiên cứu này đề xuất chỉ số CORVI, được xây dựng bằng cách cải tiến RVI từ Sentinel-1 thông qua thông tin SWIR của Sentinel-2. Ý tưởng của CORVI là kết hợp khả năng phản ánh cấu trúc và tán xạ Radar của RVI với thông tin độ ẩm và nền bề mặt từ B11, B12, qua đó tạo ra một chỉ số tích hợp có khả năng bổ sung thông tin cho NDVI và RVI trong phân biệt RNM với các lớp phủ ven biển như cây nông nghiệp, công trình xây dựng, đất trống/bãi bùn và mặt nước [11, 12, 14, 15]. Cách tiếp cận này là điểm khác biệt chính của nghiên cứu, vì CORVI không chỉ sử dụng đồng thời dữ liệu Sentinel-1 và Sentinel-2 trong mô hình phân loại, mà còn tổng hợp chúng thành một chỉ số có ý nghĩa vật lý gắn với điều kiện bề mặt ven biển. Để kiểm định vai trò của CORVI, nghiên cứu sử dụng mô hình RF, một thuật toán học máy tổ hợp dựa trên nhiều cây quyết định, có khả năng xử lý quan hệ phi tuyến và đánh giá tầm quan trọng của biến đầu vào [17]. Trong nghiên cứu viễn thám lớp phủ, RF thường được sử dụng nhờ tính ổn định, khả năng làm việc với dữ liệu đa nguồn và ít yêu cầu giả định phân phối dữ liệu so với các mô hình thống kê truyền thống [18].

Từ góc độ đóng góp khoa học, nghiên cứu này không nhằm thay thế các chỉ số truyền thống như NDVI hoặc RVI, mà kiểm định một cách có hệ thống khả năng bổ sung thông tin của CORVI trong bối cảnh lớp phủ ven biển phức tạp. Nếu CORVI cải thiện độ chính xác phân loại, đặc biệt thông qua F1-score, Producer's Accuracy và User's Accuracy của lớp RNM, chỉ số này có thể được xem là một biến đầu vào tiềm năng cho các nghiên cứu tiếp theo về lập bản đồ RNM, giám sát biến động và ước tính sinh khối trên mặt đất bằng dữ liệu

Sentinel-1/Sentinel-2.

2. PHƯƠNG PHÁP NGHIÊN CỨU

2.1. Khu vực nghiên cứu

Khu vực nghiên cứu là dải ven biển miền Bắc Việt Nam, bao gồm các khu vực RNM và lớp phủ ven biển thuộc Quảng Ninh, Hải Phòng, Hưng Yên và Ninh Bình.

2.2. Dữ liệu mẫu lớp phủ

Dữ liệu mẫu lớp phủ gồm 6.561 mẫu thu thập dựa trên ảnh vệ tinh độ phân giải cao, bản đồ hiện trạng rừng và điều tra thực địa, phân bố tương đối đều theo 4 tỉnh và theo lớp phủ và được xây dựng dưới dạng tập mẫu không gian có gắn nhãn lớp phủ và được đưa vào Google Earth Engine (GEE) để trích xuất giá trị chỉ số viễn thám. Năm lớp phủ được mã hóa và sử dụng trong nghiên cứu gồm: RNM (0) với 1981 mẫu, cây nông nghiệp (1) với 1075 mẫu, công trình xây dựng (2) với 1166 mẫu, đất trống (3) với 1165 mẫu và mặt nước (4) với 1174 mẫu. Trong đó, RNM là lớp mục tiêu chính, còn các lớp còn lại là những đối tượng phổ biến ở vùng ven biển và có khả năng gây nhầm lẫn trong phân loại ảnh.

2.3. Dữ liệu Sentinel-1 và Sentinel-2

Nghiên cứu lựa chọn dữ liệu viễn thám từ 01/10/2025 đến 31/12/2025 (Quý 4/2025) nhằm bảo đảm sự phù hợp giữa điều kiện ảnh vệ tinh và mục tiêu phân biệt lớp phủ ven biển. Đây là giai đoạn sau mùa mưa chính ở miền Bắc Việt Nam, khi điều kiện mây mưa thường giảm so với các tháng mùa hè, nhờ đó thuận lợi hơn cho việc lựa chọn và tổng hợp ảnh Sentinel-2 có chất lượng phù hợp [19]. Đồng thời, Sentinel-2 cung cấp các kênh phổ ở vùng nhìn thấy, cận hồng ngoại và SWIR, trong đó B11 và B12 có ý nghĩa quan trọng trong phản ánh độ ẩm và trạng thái nền bề mặt; Sentinel-1 cung cấp dữ liệu radar có khả năng thu nhận trong điều kiện mây che phủ, bổ sung thông tin về độ nhám, cấu trúc và tán xạ bề mặt [12, 20]. Do vậy, sử dụng ảnh Sentinel-1 (41 phiên ảnh) và Sentinel-2 (130 phiên ảnh) trong Quý 4/2025 cho phép tạo bộ dữ liệu tương đối đồng bộ giữa thông tin quang học và radar, phù hợp để kiểm định khả năng phân biệt các lớp phủ như RNM, cây nông nghiệp, mặt nước, đất trống và công trình xây dựng. Sentinel-2 Surface Reflectance

Harmonized được sử dụng để tính NDVI và trích xuất hai kênh SWIR là B11 và B12. Dữ liệu Sentinel-1 GRD Ascending được sử dụng để trích xuất hai phân cực VV và VH.

2.4. Tiền xử lý ảnh Sentinel-1 và Sentinel-2

Quy trình xử lý ảnh được thực hiện trên nền tảng GEE. Đối với Sentinel-2, dữ liệu được lọc theo khu vực nghiên cứu và tỷ lệ mây nhỏ hơn 80%. Các pixel bị ảnh hưởng bởi mây, bóng mây được loại bỏ dựa trên lớp phân loại cảnh SCL. Sau đó, các ảnh hợp lệ được tổng hợp bằng giá trị trung vị để tạo ảnh đại diện cho giai đoạn nghiên cứu. Các giá trị phản xạ bề mặt được chia cho 10.000 để đưa về thang 0–1 trước khi tính toán chỉ số [21-23]. Đối với Sentinel-1, dữ liệu GRD thu ở chế độ IW được lọc theo khu vực nghiên cứu. Giá trị trung vị được sử dụng thay cho giá trị trung bình nhằm giảm ảnh hưởng của các giá trị bất thường trong chuỗi ảnh, nhiễu cục bộ hoặc các pixel có phản xạ quá cao/thấp trong một số thời điểm. Trong GEE, phép tổng hợp trung vị trên ImageCollection được tính theo từng pixel, trong đó mỗi pixel đầu ra là giá trị trung vị của các pixel tương ứng trong toàn bộ tập ảnh đầu vào [23]. Do dữ liệu Sentinel-1 được chia sẻ thông qua GEE thường ở đơn vị dB, VV và VH được chuyển sang dạng tuyến tính trước khi tính RVI và CORVI theo công thức:

$$\sigma_{linear}^0 = 10^{\frac{\sigma_{dB}^0}{10}}$$

Trong đó:

σ_{linear}^0 : giá trị tán xạ ở dạng tuyến tính;
và σ_{dB}^0 : giá trị tán xạ ở dạng decibel (dB).

2.5. Xây dựng chỉ số CORVI

Chỉ số CORVI được xây dựng nhằm tích hợp thông tin radar từ Sentinel-1 và thông tin SWIR từ Sentinel-2. Trước hết, chỉ số RVI được tính từ hai phân cực VV và VH theo công thức [14]:

$$RVI = \frac{4VH}{VV + VH}$$

Trong đó:

VV và VH là hệ số tán xạ Radar ở dạng tuyến tính.

Trên cơ sở RVI, chỉ số CORVI được xác định như sau:

$$CORVI = \frac{RVI}{RVI^{B11+B12}} = RVI^{1-(B11+B12)}$$

hay:

$$CORVI = \left(\frac{4VH}{VV + VH} \right)^{1-(B11+B12)}$$

Trong đó: thành phần RVI phản ánh đặc điểm tán xạ radar của bề mặt và trạng thái thảm thực vật thông qua quan hệ giữa hai phân cực VV và VH của Sentinel-1, trong khi B11 và B12 của Sentinel-2 thuộc vùng SWIR, có khả năng bổ sung thông tin về độ ẩm của đất, thảm thực vật và trạng thái nền bề mặt [12, 15, 24].

2.6. Xây dựng các kịch bản phân loại

Để đánh giá vai trò của CORVI trong phân biệt lớp phủ ven biển, nghiên cứu thiết kế sáu kịch bản phân loại dựa trên các tổ hợp biến đầu vào khác nhau. Kịch bản **S1** chỉ sử dụng NDVI nhằm kiểm định khả năng phân biệt của chỉ số quang học truyền thống; kịch bản **S2** chỉ sử dụng RVI nhằm đánh giá riêng vai trò của thông tin Radar; kịch bản **S3** chỉ sử dụng CORVI để kiểm tra khả năng phân biệt độc lập của chỉ số đề xuất. Bên cạnh các kịch bản đơn biến, nghiên cứu xây dựng ba kịch bản kết hợp gồm **S4** với NDVI và CORVI được dùng để đánh giá khả năng bổ sung thông tin của CORVI cho NDVI, **S5** với NDVI và RVI đại diện cho tổ hợp quang học–Radar truyền thống, **S6** với đầy đủ NDVI, RVI và CORVI nhằm kiểm định hiệu quả của mô hình tích hợp đầy đủ khi đồng thời sử dụng thông tin quang học, Radar và chỉ số CORVI đề xuất.

2.7. Huấn luyện và kiểm định mô hình Random Forest

Mô hình RF được sử dụng để phân loại lớp phủ ven biển trong từng kịch bản biến đầu vào dựa trên 200 cây quyết định, trong đó mỗi cây được xây dựng từ một mẫu *bootstrap* của tập huấn luyện và tại mỗi nút phân chia chỉ sử dụng một tập con ngẫu nhiên của các biến đầu vào. Cách tiếp cận này giúp mô hình giảm phương sai, hạn chế quá khớp và xử lý tốt các quan hệ phi tuyến giữa biến viễn thám và lớp phủ bề mặt [17, 18]. Tập mẫu lớp phủ ban đầu sau khi loại bỏ các điểm không hợp lệ (6558 điểm) có trường nhãn dạng văn bản, gồm RNM (1981 điểm), cây nông nghiệp (1072 điểm), công trình xây dựng (1166 điểm), đất trống (1165 điểm) và mặt nước (1174 điểm). Trước khi huấn luyện mô hình, các nhãn này được mã hóa sang dạng

số để phù hợp với yêu cầu của thuật toán phân loại trong GEE. Trong nghiên cứu này, mã lớp được quy định như sau: RNM = 0, cây nông nghiệp = 1, công trình xây dựng = 2, đất trống = 3 và mặt nước = 4. Tập mẫu hợp lệ được đánh giá theo phương pháp kiểm định chéo k-fold với k = 5. Theo cách tiếp cận này, toàn bộ tập mẫu được chia ngẫu nhiên thành 5 phần có quy mô tương đối tương đương; tại mỗi lần lặp, 4 phần được sử dụng để huấn luyện mô hình RF và phần còn lại được sử dụng để kiểm định. Kết quả đánh giá cuối cùng được tổng hợp từ toàn bộ các lần kiểm định.

2.8. Đánh giá độ chính xác và tầm quan trọng biến

Độ chính xác phân loại được đánh giá bằng ma trận sai số giữa nhãn thực tế và nhãn dự báo trên tập kiểm định. Trong nghiên cứu này, các chỉ tiêu sử dụng gồm Overall Accuracy (OA), Kappa, Producer's Accuracy (PA), User's Accuracy (UA), F1-score và Macro-F1. OA và Kappa phản ánh độ chính xác tổng thể của mô hình, trong khi PA và UA cho phép đánh giá sai số bỏ sót và sai số gán nhầm theo từng lớp; F1-score kết hợp Precision và Recall nên phù hợp để đánh giá cân bằng hiệu quả phân loại của từng lớp, đặc biệt trong trường hợp số lượng mẫu giữa các lớp không hoàn toàn đồng đều [25-27].

OA phản ánh tỷ lệ mẫu được phân loại đúng trên tổng số mẫu kiểm định:

$$OA = \frac{\sum_{i=1}^k n_{ii}}{N}$$

PA phản ánh tỷ lệ mẫu thực tế của một lớp

được mô hình phân loại đúng và tương đương với Recall:

$$PA_i = Recall_i = \frac{TP_i}{TP_i + FN_i}$$

UA phản ánh độ tin cậy của các mẫu được gán vào một lớp và tương đương với Precision:

$$UA_i = Precision_i = \frac{TP_i}{TP_i + FP_i}$$

F1-score được tính từ Precision và Recall:

$$F1_i = \frac{2 \times Precision_i \times Recall_i}{Precision_i + Recall_i}$$

Macro-F1 được tính bằng trung bình F1-score của tất cả các lớp:

$$MacroF1 = \frac{1}{k} \sum_{i=1}^k F1_i$$

Ngoài các chỉ tiêu tổng thể, F1-score của lớp RNM được xem là chỉ tiêu trọng tâm vì đây là lớp mục tiêu chính của bài báo. Bên cạnh đó, tầm quan trọng biến trong mô hình RF được phân tích để đánh giá mức đóng góp tương đối của NDVI, RVI và CORVI trong từng kịch bản, qua đó làm rõ vai trò bổ sung của CORVI trong phân loại lớp phủ ven biển.

3. KẾT QUẢ VÀ THẢO LUẬN

3.1. Đặc điểm phân bố giá trị NDVI, RVI và CORVI

Từ tập mẫu đã trích xuất, gồm năm lớp phủ: RNM, cây nông nghiệp, công trình xây dựng, đất trống và mặt nước. Các giá trị NDVI, RVI và CORVI được thống kê theo từng lớp nhằm đánh giá sơ bộ khả năng phân biệt lớp phủ của từng chỉ số trước khi đưa vào mô hình phân loại (Bảng 1).

Bảng 1. Tổng hợp giá trị thống kê chỉ số NDVI, RVI và CORVI theo lớp phủ

Lớp phủ	Số mẫu	NDVI		RVI		CORVI	
		Mean	Median	Mean	Median	Mean	Median
Rừng ngập mặn	1.981	0,767	0,806	0,909	0,909	0,917	0,919
Cây nông nghiệp	1.072	0,488	0,655	0,722	0,716	0,772	0,779
Công trình xây dựng	1.166	0,244	0,228	0,624	0,542	0,746	0,728
Đất trống	1.165	0,326	0,338	0,634	0,634	0,742	0,757
Mặt nước	1.174	-0,461	-0,471	0,321	0,260	0,328	0,269

Kết quả cho thấy lớp RNM có giá trị trung bình và trung vị cao nhất ở cả ba chỉ số. NDVI của RNM đạt trung bình 0,767 và trung vị 0,806, phản ánh đặc điểm thảm thực vật xanh và có độ che phủ cao. Tuy nhiên, lớp cây nông nghiệp


cũng có NDVI tương đối cao, đặc biệt giá trị trung vị đạt 0,655, cho thấy có khả năng chồng lấn với RNM nếu chỉ sử dụng thông tin quang học. Ngược lại, lớp mặt nước có NDVI trung bình -0,461, thấp hơn rõ rệt so với các lớp còn

lại, thể hiện khả năng phân biệt tốt của NDVI đối với đối tượng nước.

Kết quả tại Hình 2 cho thấy đối với RVI, RNM cũng có giá trị cao nhất với trung bình 0,909, cao hơn cây nông nghiệp (0,722), đất trống (0,634), công trình xây dựng (0,624) và mặt nước (0,321). Kết quả này cho thấy thông tin Radar có khả năng phản ánh sự khác biệt về cấu trúc, độ nhám và trạng thái bề mặt giữa RNM với các lớp phủ khác. Tuy nhiên, khoảng cách giữa cây nông nghiệp, đất trống và công trình xây dựng không quá lớn, cho thấy RVI đơn lẻ có thể gặp hạn chế trong phân biệt các lớp phủ ven biển có cấu trúc và độ ẩm nền phức tạp. CORVI thể hiện xu hướng tương tự RVI nhưng

có giá trị được điều chỉnh bởi thông tin SWIR từ B11 và B12. RNM đạt giá trị CORVI trung bình 0,917, cao nhất trong các lớp phủ. Cây nông nghiệp, công trình xây dựng và đất trống có giá trị trung bình lần lượt là 0,772, 0,746 và 0,742, trong khi mặt nước thấp nhất với 0,328. Như vậy, CORVI duy trì sự khác biệt rõ giữa RNM và mặt nước, đồng thời phản ánh thêm ảnh hưởng của độ ẩm và nền bề mặt thông qua thành phần SWIR.

Nhìn chung, phân bố giá trị của ba chỉ số cho thấy RNM có đặc trưng khác biệt so với các lớp phủ ven biển còn lại, nhưng mức độ tách biệt thay đổi theo từng chỉ số.



Hình 2. Biểu đồ phân bố giá trị NDVI, RVI, CORVI theo lớp phủ

3.2. Đánh giá độ chính xác phân loại theo các kịch bản

Kết quả đánh giá sáu kịch bản theo kiểm định chéo 5-fold cho thấy độ chính xác phân loại thay đổi rõ rệt theo tổ hợp biến đầu vào (Bảng 2). Nhìn chung, các kịch bản sử dụng một

chỉ số đơn lẻ cho kết quả thấp hơn so với các kịch bản kết hợp nhiều chỉ số. Trong đó, kịch bản S6 sử dụng đồng thời NDVI, RVI và CORVI đạt kết quả cao nhất với $OA = 82,93 \pm 0,32\%$, $Kappa = 0,7792 \pm 0,0042$ và $Macro-F1 = 80,25 \pm 0,52\%$.

Bảng 2. Độ chính xác phân loại theo sáu kịch bản từ kiểm định chéo 5-fold

Kịch bản	OA TB $\pm$ SD (%)	Kappa TB $\pm$ SD	Macro-F1 TB $\pm$ SD (%)	95% CI của OA (%)
S1	60,71 $\pm$ 0,71	0,4931 $\pm$ 0,0095	57,09 $\pm$ 0,79	59,83–61,59
S2	42,10 $\pm$ 0,99	0,2528 $\pm$ 0,0126	37,05 $\pm$ 1,16	40,86–43,33
S3	42,74 $\pm$ 1,14	0,2606 $\pm$ 0,0129	38,12 $\pm$ 0,61	41,32–44,16
S4	70,98 $\pm$ 0,77	0,6244 $\pm$ 0,0113	67,50 $\pm$ 1,24	70,03–71,93
S5	71,87 $\pm$ 1,25	0,6359 $\pm$ 0,0179	68,61 $\pm$ 1,77	70,32–73,42
S6	82,93 $\pm$ 0,32	0,7792 $\pm$ 0,0042	80,25 $\pm$ 0,52	82,53–83,33

Trong nhóm kịch bản đơn biến, NDVI cho kết quả tốt nhất với $OA = 60,71 \pm 0,71\%$ và $Macro-F1 = 57,09 \pm 0,79\%$. Điều này cho thấy thông tin quang học về độ xanh thực vật vẫn có vai trò

quan trọng trong phân biệt lớp phủ ven biển. Tuy nhiên, mức độ chính xác này chưa cao, phản ánh hạn chế của NDVI khi phải phân biệt các lớp có khả năng chồng lấn phổ, đặc biệt

giữa RNM và cây nông nghiệp. Hai kịch bản chỉ sử dụng RVI và CORVI đạt OA lần lượt $42,10 \pm 0,99\%$ và $42,74 \pm 1,14\%$, cho thấy thông tin radar hoặc chỉ số tích hợp nếu sử dụng riêng lẻ chưa đủ để phân biệt ổn định toàn bộ năm lớp phủ. Khi kết hợp các chỉ số, độ chính xác được cải thiện rõ rệt. Kịch bản S4 đạt OA = $70,98 \pm 0,77\%$, tăng trung bình 10,27 điểm phần trăm so với S1; kịch bản S5 đạt OA = $71,87 \pm 1,25\%$, cao hơn S4 nhưng mức chênh lệch không lớn. Đáng chú ý, S6 đạt kết quả tốt nhất ở tất cả các chỉ tiêu tổng thể. So với S5, việc bổ sung CORVI vào tổ hợp NDVI + RVI làm tăng OA trung bình 11,07 điểm phần trăm và Macro-F1 trung bình 11,64 điểm phần trăm. Kiểm định Wilcoxon

theo cặp trên 5 fold cho thấy chênh lệch giữa S6 và S5 có ý nghĩa thống kê đối với OA, Macro-F1 và F1-score của lớp RNM ($p = 0,031$). Điều này cho thấy mức cải thiện của S6 không chỉ là dao động ngẫu nhiên giữa các fold, mà phản ánh đóng góp bổ sung của CORVI trong mô hình phân loại.

3.3. Đánh giá khả năng phân loại lớp phủ RNM từ các chỉ số

Do RNM là lớp mục tiêu chính của nghiên cứu, khả năng nhận diện lớp này được đánh giá riêng thông qua PA, UA và F1-score. Các giá trị trong Bảng 3 được tổng hợp dưới dạng trung bình $\pm$ độ lệch chuẩn từ 5 fold kiểm định.

Bảng 3. Độ chính xác phân loại lớp RNM theo các kịch bản từ kiểm định chéo 5-fold

Kịch bản	PA RNM TB $\pm$ SD (%)	UA RNM TB $\pm$ SD (%)	F1 RNM TB $\pm$ SD (%)
S1	$72,47 \pm 2,23$	$70,76 \pm 1,31$	$71,58 \pm 1,13$
S2	$60,73 \pm 0,87$	$59,62 \pm 2,58$	$60,15 \pm 1,54$
S3	$55,95 \pm 2,53$	$54,33 \pm 2,82$	$55,11 \pm 2,55$
S4	$83,07 \pm 2,09$	$76,45 \pm 1,11$	$79,62 \pm 1,24$
S5	$83,65 \pm 1,24$	$77,34 \pm 1,53$	$80,37 \pm 1,28$
S6	$95,21 \pm 1,75$	$89,14 \pm 1,56$	$92,05 \pm 0,67$

Kết quả tại Bảng 3 cho thấy kịch bản S6 có khả năng nhận diện RNM tốt nhất, với PA = $95,21 \pm 1,75\%$, UA = $89,14 \pm 1,56\%$ và F1-score = $92,05 \pm 0,67\%$. Điều này cho thấy phần lớn mẫu RNM thực tế đã được mô hình phát hiện đúng, đồng thời các mẫu được dự báo là RNM cũng có độ tin cậy cao. Trong nhóm kịch bản đơn biến, NDVI tiếp tục cho kết quả tốt nhất với F1-score = $71,58 \pm 1,13\%$, cao hơn RVI và CORVI. Kết quả này khẳng định vai trò của thông tin quang học về độ xanh thực vật trong nhận diện RNM, nhưng cũng cho thấy NDVI đơn biến còn hạn chế do khả năng nhầm lẫn với các lớp thực vật khác. Khi kết hợp thêm CORVI hoặc RVI với NDVI, khả năng nhận diện RNM được cải thiện. Kịch bản S4 đạt F1-score = $79,62 \pm 1,24\%$, tăng trung bình 8,03 điểm phần trăm so với S1; kịch bản S5 đạt F1-score = $80,37 \pm 1,28\%$, cao hơn S4 nhưng mức chênh lệch nhỏ. Đáng chú ý, khi bổ sung CORVI vào tổ hợp NDVI + RVI, F1-score của RNM tăng từ $80,37 \pm 1,28\%$ ở S5 lên $92,05 \pm 0,67\%$ ở S6, tương ứng tăng

trung bình 11,68 điểm phần trăm. PA cũng tăng từ $83,65 \pm 1,24\%$ lên $95,21 \pm 1,75\%$, trong khi UA tăng từ $77,34 \pm 1,53\%$ lên $89,14 \pm 1,56\%$. Kiểm định Wilcoxon theo cặp cho thấy mức tăng F1-score của S6 so với S5 có ý nghĩa thống kê ($p = 0,031$). Kết quả này cũng khá tương đồng với các nghiên cứu đã công bố. Ghorbanian và cộng sự (2021) [28] sử dụng tích hợp Sentinel-1, Sentinel-2 và RF để lập bản đồ hệ sinh thái RNM Hara tại Iran, đạt OA trung bình 93,23% và Kappa = 0,92. Ở quy mô quốc gia tại Trung Quốc, Hu và cộng sự (2020) [29] cho thấy tổ hợp Sentinel-1 và Sentinel-2 đạt F1-score = 0,94, cao hơn so với chỉ dùng Sentinel-1 (0,88) hoặc Sentinel-2 (0,895). Vì vậy, trong điều kiện nghiên cứu này phân loại đồng thời năm lớp phủ ven biển có tín hiệu chồng lấn, kết quả S6 với OA = $82,93 \pm 0,32\%$ và F1-score RNM = $92,05 \pm 0,67\%$ là phù hợp, đồng thời cho thấy CORVI có giá trị bổ sung trong mô hình đa biến.

3.4. Kết quả xác định diện tích RNM theo kịch bản S6

Kết quả xác định diện tích RNM theo kịch bản S6 cho thấy tổng diện tích RNM tại khu vực nghiên cứu đạt khoảng 31.182,95 ha. Trong đó, Quảng Ninh có diện tích lớn nhất với 20.140,53 ha, chiếm khoảng 64,58% tổng diện tích; tiếp theo là Ninh Bình với 3.968,71 ha (12,73%), Hưng Yên với 3.797,64 ha (12,18%) và thành phố Hải Phòng với 3.276,07 ha (10,51%). So sánh với số liệu theo dõi diễn biến rừng năm 2025 [30] của các địa phương cho thấy diện tích RNM xác định theo kịch bản S6 cao hơn hiện trạng quản lý 3.408,84 ha, tương ứng 12,27%. Mức chênh lệch chủ yếu đến từ Quảng Ninh, nơi diện tích theo S6 cao hơn số liệu quản lý 2.856,42 ha (16,53%) và thành phố Hải Phòng cao hơn 580,68 ha (21,54%). Ninh Bình có mức chênh lệch nhỏ hơn, cao hơn 150,39 ha (3,94%), trong khi Hưng Yên là địa phương duy nhất có diện tích theo S6 thấp hơn hiện trạng quản lý, chênh -178,64 ha (-4,49%). Kết quả này không thay thế trực tiếp số liệu hiện trạng quản lý, mà cho thấy dữ liệu viễn thám có khả năng

cung cấp một lớp thông tin độc lập để rà soát, đối chiếu và phát hiện các khu vực có nguy cơ bị bỏ sót trong quá trình cập nhật hiện trạng rừng. Những khu vực được mô hình S6 nhận diện là RNM nhưng chưa có trong số liệu quản lý cần được ưu tiên kiểm tra bằng ảnh độ phân giải cao, hồ sơ khoanh vẽ địa phương và điều tra thực địa, qua đó hỗ trợ cập nhật dữ liệu RNM đầy đủ và nhất quán hơn.

3.5. Tầm quan trọng của CORVI trong mô hình RF

Phân tích tầm quan trọng biến trong mô hình RF được tổng hợp từ 5-fold cho thấy mức đóng góp của NDVI, RVI và CORVI thay đổi theo từng kịch bản. Trong các kịch bản đơn biến, toàn bộ tầm quan trọng tập trung vào biến duy nhất được sử dụng, vì vậy giá trị *importance* tuyệt đối ở các kịch bản này chủ yếu phản ánh cấu trúc mô hình hơn là khả năng so sánh trực tiếp giữa các chỉ số. Ý nghĩa của CORVI thể hiện rõ hơn trong các kịch bản kết hợp, đặc biệt khi đặt cạnh NDVI và RVI.

Bảng 4. Tầm quan trọng của các biến trong mô hình RF theo kịch bản từ kiểm định chéo 5-fold

Kịch bản	Importance NDVI TB ± SD	Importance RVI TB ± SD	Importance CORVI TB ± SD	Tỷ trọng CORVI (%)
S1	31.767,62 ± 245,27	0,00 ± 0,00	0,00 ± 0,00	0,00
S2	0,00 ± 0,00	55.271,04 ± 455,95	0,00 ± 0,00	0,00
S3	0,00 ± 0,00	0,00 ± 0,00	56.705,16 ± 329,34	100,00
S4	14.535,13 ± 85,62	0,00 ± 0,00	14.033,18 ± 83,31	49,12
S5	13.951,91 ± 74,71	13.445,74 ± 74,64	0,00 ± 0,00	0,00
S6	7.250,26 ± 81,56	7.320,47 ± 77,91	7.322,39 ± 53,89	33,45

Kết quả tổng hợp tại Bảng 5 cho thấy ở kịch bản S4, CORVI có *importance* trung bình 14.033,18 ± 83,31, chiếm 49,12% tổng *importance* của kịch bản, gần tương đương với NDVI. Điều này cho thấy CORVI có đóng góp một lượng thông tin bổ sung đáng kể cho mô hình. Kết quả này phù hợp với việc kịch bản S4 có độ chính xác cao hơn kịch bản chỉ sử dụng NDVI, chứng tỏ CORVI giúp tăng khả năng phân biệt lớp phủ khi kết hợp với chỉ số quang học truyền thống. Trong kịch bản S6, ba biến có mức đóng góp khá cân bằng. CORVI đạt *importance* trung bình 7.322,39 ± 53,89, chiếm 33,45% tổng *importance*, cao hơn không đáng

kể so với RVI (7.320,47 ± 77,91) và NDVI (7.250,26 ± 81,56). Mặc dù chênh lệch giữa ba biến không lớn, việc CORVI vẫn duy trì tỷ trọng xấp xỉ một phần ba trong kịch bản đầy đủ cho thấy chỉ số này không hoàn toàn trùng lặp với NDVI hoặc RVI. Kết quả tầm quan trọng biến thống nhất với kết quả độ chính xác phân loại, khi S6 vừa đạt OA, Kappa, Macro-F1 và F1-score của lớp RNM cao nhất, vừa duy trì vai trò đáng kể của CORVI trong mô hình. Kết quả này cũng gợi ý rằng CORVI có thể được sử dụng như một biến bổ sung trong phân loại lớp phủ ven biển, nhưng cần bảo đảm tính đồng bộ tương đối giữa dữ liệu Sentinel-1 và Sentinel-2. Chỉ số này

phù hợp nhất khi hai nguồn dữ liệu được tổng hợp trong cùng một khoảng thời gian quan sát, chẳng hạn theo tháng hoặc theo mùa, để giảm ảnh hưởng của sai khác ngày chụp và biến động thủy triều. CORVI cũng có thể được mở rộng cho các vùng rừng ngập mặn khác, đặc biệt ở nơi mây che phủ nhiều và lớp phủ ven biển phức tạp, nhưng cần kiểm định lại bằng mẫu địa phương do tín hiệu quang học-radar chịu ảnh hưởng bởi loài cây, cấu trúc tán, nền bùn nước, độ mặn, thủy triều và mùa vụ.

Nghiên cứu vẫn có một số hạn chế. Thứ nhất, dữ liệu mới được kiểm định cho ảnh Quý 4, chưa phản ánh đầy đủ biến động mùa vụ, thủy triều và điều kiện khí tượng khác nhau. Thứ hai, hệ lớp phủ gồm năm lớp chính, chưa tách riêng các đối tượng dễ nhầm lẫn như ao đầm nuôi trồng thủy sản, bãi bùn ướt hoặc RNM thưa. Thứ ba, mặc dù kiểm định chéo 5-fold đã giúp định lượng độ dao động của kết quả giữa các fold, nghiên cứu vẫn cần kiểm định thêm theo không gian và bằng tập mẫu độc lập ở các khu vực khác để đánh giá khả năng chuyển giao của mô hình. Thứ tư, vấn đề tương quan giữa CORVI và RVI ảnh hưởng đến diễn giải tầm quan trọng của biến đầu vào. Trong các nghiên cứu tiếp theo, CORVI nên được kiểm định với dữ liệu đa thời gian, hệ lớp phủ chi tiết hơn và các mô hình học máy khác nhau để đánh giá độ ổn định và khả năng ứng dụng trong giám sát RNM và các-bon xanh.

4. KẾT LUẬN

Nghiên cứu đã xây dựng và kiểm định chỉ số CORVI bằng việc kết hợp thông tin tán xạ ngược từ dữ liệu Sentinel-1 và thông tin SWIR từ Sentinel-2 phục vụ phân loại lớp phủ ven biển tại miền Bắc Việt Nam. Kết quả kiểm định 5-fold cho thấy các chỉ số đơn lẻ chưa đủ để phân biệt hiệu quả toàn bộ lớp phủ. Kịch bản tích hợp NDVI + RVI + CORVI đạt kết quả tốt nhất với OA = $82,93 \pm 0,32\%$, Kappa = $0,7792 \pm 0,0042$ và Macro-F1 = $80,25 \pm 0,52\%$; riêng lớp RNM đạt F1-score = $92,05 \pm 0,67\%$. Kết quả này cho thấy CORVI mặc dù không thể thay thế NDVI hay RVI nhưng có giá trị như một biến tích hợp bổ sung trong mô hình đa biến. Từ kịch bản S6, diện tích

RNM tại khu vực nghiên cứu được xác định khoảng 31.182,95 ha, cao hơn số liệu theo dõi diễn biến rừng năm 2025 là 12,27%. Kết quả này cho thấy dữ liệu viễn thám có thể hỗ trợ rà soát, đối chiếu và phát hiện các khu vực RNM có nguy cơ bị bỏ sót trong số liệu quản lý. Trong các nghiên cứu tiếp theo, CORVI cần được kiểm định ở nhiều thời điểm, vùng địa lý và điều kiện thủy triều khác nhau, đồng thời so sánh trực tiếp với các biến thành phần như RVI, B11, B12 để làm rõ giá trị gia tăng trong lập bản đồ RNM và ước tính sinh khối, trữ lượng các-bon.

Lời cảm ơn

Đây là kết quả nghiên cứu thuộc luận án tiến sĩ “Nghiên cứu cơ sở khoa học và xây dựng mô hình ước tính trữ lượng các-bon rừng ngập mặn từ dữ liệu viễn thám tại phía Bắc Việt Nam” của nghiên cứu sinh Nguyễn Văn Thị. Nhóm tác giả trân trọng cảm ơn tập thể lãnh đạo và cán bộ, nhân viên Viện Sinh thái rừng và Môi trường đã tạo điều kiện để nghiên cứu sinh tham gia điều tra, thu thập số liệu thực địa và hỗ trợ thực hiện, hoàn thành nghiên cứu này.

TÀI LIỆU THAM KHẢO

- [1]. Daniel M. Alongi (2022). Present state and future of the world's mangrove forests. *Environmental Conservation*. 29(3): 331-349. DOI: 10.1017/S0376892902000231.
- [2]. N. C. Duke, J.-O. Meynecke, S. Dittmann, A. M. Ellison, K. Anger, U. Berger, S. Cannicci, K. Diele, K. C. Ewel, C. D. Field, N. Koedam, S. Y. Lee, C. Marchand, I. Nordhaus & F. Dahdouh-Guebas (2007). A world without mangroves. *Science*. 317(5834): 41-42. DOI: 10.1126/science.317.5834.41b.
- [3]. M. Spalding, M. Kainuma & L. Collins (2010). *World Atlas of Mangroves*. Earthscan/Routledge. DOI: 10.4324/9781849776608.
- [4]. Donato D. C., Kauffman J. B., Murdiyarso D., Kurnianto S., Stidham M. & Kanninen M. (2011). Mangroves among the most carbon-rich forests in the tropics. *Nature Geoscience*. 45(5): 293–297. DOI: 10.1038/ngeo1123
- [5]. Rovai A. S., Twilley R. R., Castañeda-Moya E., Midway S. R., Bouillon S., Rivera-Monroy V. H. & Simard M. (2018). Global controls on carbon storage in mangrove forests. *Nature Climate Change*. 8(6): 534-538. DOI: 10.1038/s41558-018-0162-5.
- [6]. Giri C., Ochieng E., Tieszen L. L., Zhu Z., Singh A., T. Loveland & Duke N. (2011). Status and distribution of mangrove forests of the world using earth observation

- satellite data. *Global Ecology and Biogeography*. 20(1): 154-159. DOI: 10.1111/j.1466-8238.2010.00584.x.
- [7]. P. Bunting, A. Rosenqvist, L. Hilarides, R. M. Lucas, N. Thomas, T. Tadono, T. A. Worthington, M. Spalding, N. J. Murray & L.-M. Rebelo (2022). Global Mangrove Extent Change 1996–2020: Global Mangrove Watch Version 3.0. *Remote Sensing*. 14(15): 3657. DOI: 10.3390/rs14153657.
- [8]. Claudia Kuenzer, Andrea Bluemel, Steffen Gebhardt, Tuan Vo Quoc & Stefan Dech (2011). Remote sensing of mangrove ecosystems: A review. *Remote Sensing*. 3(4): 878–928. DOI: 10.3390/rs3050878.
- [9]. Le Wang, Mingming Jia, Dameng Yin & Jinyan Tian (2019). A review of remote sensing for mangrove forests: 1956–2018. *Remote Sensing of Environment*. 231. DOI: 10.1016/j.rse.2019.111223.
- [10]. T. D. Pham, N. Yokoya, D. T. Bui, K. Yoshino & D. A. Friess (2019). Remote sensing approaches for monitoring mangrove species, structure, and biomass: Opportunities and challenges. *Remote Sensing*. 11(3): 230. DOI: 10.3390/rs11030230.
- [11]. Thuong V. Tran, Ruth Reef & Xuan Zhu (2022). A Review of Spectral Indices for Mangrove Remote Sensing. *Remote Sensing*. 14(19): 4868. DOI: 10.3390/rs14194868.
- [12]. European Space Agency. (2015). Sentinel-2 User Handbook. ESA Standard Document.
- [13]. Compton J. Tucker (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*. 8(2): 127-150. DOI: 10.1016/0034-4257(79)90013-0.
- [14]. Rouhollah Nasirzadehdizaji, Fusun Balik Sanli, Saygin Abdikan, Ziyadin Cakir, Alihsan Sekertekin & Mustafa Ustuner (2019). Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. *Applied Sciences*. 9(4): 655. DOI: 10.3390/app9040655.
- [15]. D. Mandal, V. Kumar, D. Ratha, S. Dey, A. Bhattacharya, J. M. Lopez-Sanchez, H. McNairn & Y. S. Rao (2020). Dual polarimetric radar vegetation index for crop growth monitoring using Sentinel-1 SAR data. *Remote Sensing of Environment*. 247: 111954. DOI: 10.1016/j.rse.2020.111954.
- [16]. D. Phiri, M. Simwanda, S. Salekin, V. R. Nyirenda, Y. Murayama & M. Ranagalage (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*. 12(14): 2291. DOI: 10.3390/rs12142291.
- [17]. Breiman, L. (2001). Random forests. *Machine Learning*. 45(1): 5–32. DOI: 10.1023/A:1010933404324
- [18]. M. Belgiu & L. Drăguț (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*. 114: 24-31. DOI: 10.1016/j.isprsjprs.2016.01.011.
- [19]. Encyclopaedia Britannica. (2024). Vietnam - Climate. Encyclopaedia Britannica.
- [20]. European Space Agency (2024). Sentinel-1. European Space Agency.
- [21]. Google Earth Engine (2024a). Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A. Google Developers. Truy cập từ: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED.
- [22]. Google Earth Engine (2024b). Sentinel-2 MSI: MultiSpectral Instrument, Level-2A Data. Google Developers. Truy cập từ: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR.
- [23]. Google Earth Engine (2024c). ImageCollection reductions. Google Developers. Truy cập từ: https://developers.google.com/earth-engine/guides/reducers_image_collection.
- [24]. Sentinel Hub (2024). Sentinel-2 Bands. Sentinel Hub Custom Scripts. Truy cập từ: <https://custom-scripts.sentinel-hub.com/custom-scripts/sentinel-2/bands/>.
- [25]. G. M. Foody (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*. 80(1): 185-201. DOI: 10.1016/S0034-4257(01)00295-4.
- [26]. R. G. Congalton & K. Green (2019). Assessing the Accuracy of Remotely Sensed Data: Principles and Practices (3rd ed.). CRC Press. DOI: 10.1201/9780429052729.
- [27]. M. Sokolova & G. Lapalme (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*. 45(4): 427-437. DOI: 10.1016/j.ipm.2009.03.002.
- [28]. A. Ghorbanian, A. Mohammadzadeh, S. Jamali, C. A. Silva & M. R. Sahebi (2021). Mangrove ecosystem mapping using Sentinel-1 and Sentinel-2 satellite images and Random Forest algorithm in Google Earth Engine. *Remote Sensing*. 13(13): 2565. DOI: 10.3390/rs13132565.
- [29]. L. Hu, N. Xu, J. Liang, Z. Li, L. Chen & F. Zhao (2020). Advancing the mapping of mangrove forests at national-scale using Sentinel-1 and Sentinel-2 time-series data with Google Earth Engine: A case study in China. *Remote Sensing*. 12(19): 3120. DOI: 10.3390/rs12193120.
- [30]. Bộ Nông nghiệp và Môi trường (2026). Công bố hiện trạng rừng toàn quốc năm 2025. Quyết định số 1106/QĐ-BNNMT ngày 31 tháng 3 năm 2026.