

BỘ GIÁO DỤC VÀ ĐÀO TẠO
TRƯỜNG ĐẠI HỌC MỎ - ĐỊA CHẤT

BÁO CÁO HỌC THUẬT HỌC KỲ 2
NĂM HỌC 2025 – 2026

**XÂY DỰNG MÔ HÌNH DEEP LEARNING PHÂN ĐOẠN
TRANG TRẠI ĐIỆN MẶT TRỜI TỪ DỮ LIỆU ẢNH VỆ TINH**

Người báo cáo: Ths. Nguyễn Văn Thắng

Đơn vị: Bộ môn Tin học Trắc địa

Khoa Công nghệ Thông tin

Hà Nội, 2026

BỘ GIÁO DỤC VÀ ĐÀO TẠO
TRƯỜNG ĐẠI HỌC MỎ - ĐỊA CHẤT

BÁO CÁO HỌC THUẬT HỌC KỲ 2
NĂM HỌC 2025 – 2026

**XÂY DỰNG MÔ HÌNH DEEP LEARNING PHÂN ĐOẠN TRANG
TRẠI ĐIỆN MẶT TRỜI TỪ DỮ LIỆU ẢNH VỆ TINH**

Phòng KHCN

Bộ môn Tin học Trắc địa

Người báo cáo

Ths. Nguyễn Văn Thắng

Hà Nội - 2026

Mục lục

TÓM TẮT	3
1. GIỚI THIỆU	4
1.1. Bối cảnh nghiên cứu	4
1.2. Vai trò của ảnh Sentinel-2 trong giám sát điện mặt trời	4
1.3. Vai trò của học sâu trong phân đoạn ảnh viễn thám	5
1.4. Mục tiêu và phạm vi nghiên cứu.....	5
1.5. Cấu trúc báo cáo.....	5
2. TỔNG QUAN NGHIÊN CỨU LIÊN QUAN	7
2.1. Viễn thám đối với hạ tầng điện mặt trời	7
2.2. Giám sát đa thời gian biến động lớp phủ và hạ tầng.....	7
2.3. Năng lượng mặt trời và viễn thám tại Việt Nam	8
2.4. Nhận xét và khoảng trống nghiên cứu	9
2.5. Vai trò của các chỉ số phổ chuyên biệt trong viễn thám điện mặt trời.....	9
2.6. So sánh các kiến trúc mã hóa – giải mã trong phân đoạn ảnh viễn thám	10
3. KHU VỰC NGHIÊN CỨU VÀ DỮ LIỆU	11
3.1. Khu vực nghiên cứu.....	11
3.2. Dữ liệu ảnh vệ tinh Sentinel-2	11
3.2.1. Các kênh phổ và chỉ số sử dụng.....	12
3.2.2. Khung thời gian thu thập dữ liệu	12
4. PHƯƠNG PHÁP LUẬN	14
4.1. Khung nghiên cứu tổng thể.....	14
4.2. Chuẩn bị dữ liệu Sentinel-2	15
4.2.1. Phân chia lưới khu vực nghiên cứu và thu thập ảnh hằng năm	15
4.2.2. Che mây và tổ hợp ảnh hằng năm.....	16
4.2.3. Lựa chọn kênh phổ và xây dựng PVSÍ	16
4.3. Phân đoạn trang trại điện mặt trời.....	16
4.3.1. Chuẩn bị dữ liệu huấn luyện	16
4.3.2. Tăng cường và tiền xử lý dữ liệu	17
4.3.3. Các kiến trúc mô hình phân đoạn	17
U-Net.....	17
LinkNet	17
DeepLabV3+.....	18
4.3.4. Cấu hình đầu vào – đầu ra chung.....	18
4.4. Bản đồ hóa hằng năm và hậu xử lý.....	18
4.5. Quy trình huấn luyện và đánh giá mô hình.....	19
5. THIẾT LẬP THỰC NGHIỆM	21

5.1. Các chỉ số đánh giá hiệu năng.....	21
6. KẾT QUẢ VÀ PHÂN TÍCH	23
6.1. Hiệu năng phân đoạn của các mô hình	23
6.2. Thí nghiệm loại bỏ thành phần PVSI.....	23
6.3. Phân tích trực quan kết quả phân đoạn	24
6.4. Tổng hợp kết quả chính	24
7. THẢO LUẬN	26
7.1. Giá trị của ảnh Sentinel-2 đối với giám sát điện mặt trời cấp vùng.....	26
7.2. So sánh hiệu năng giữa các kiến trúc phân đoạn	26
7.3. Hàm ý đối với công tác quản lý và quy hoạch năng lượng tại địa phương	27
7.4. Hạn chế và hướng phát triển trong tương lai	27
8. KẾT LUẬN.....	29
TÀI LIỆU THAM KHẢO	30

TÓM TẮT

Báo cáo này trình bày một khung nghiên cứu ứng dụng học sâu (deep learning) để phân đoạn ngữ nghĩa (semantic segmentation) và giám sát biến động không gian – thời gian của các trang trại điện mặt trời tại tỉnh Bà Rịa – Vũng Tàu (BRVT), Việt Nam, dựa trên ảnh vệ tinh đa thời gian Sentinel-2 trong giai đoạn 2020–2025. Dữ liệu ảnh được xử lý thành các ảnh tổ hợp theo mùa, ít mây, sử dụng bảy kênh phổ (B2, B3, B4, B6, B8, B11, B12) kết hợp với một chỉ số phổ quang điện (Photovoltaic Spectral Index – PVSI) nhằm tăng cường khả năng phân biệt bề mặt tấm pin mặt trời với các loại hình bề mặt khác. Dữ liệu thu thập trong giai đoạn 2020–2022 được sử dụng để gán nhãn và huấn luyện mô hình, trong khi dữ liệu 2023–2025 được dành riêng cho việc suy luận trên toàn tỉnh và phân tích biến động liên năm. Ba kiến trúc mạng nơ-ron học sâu phổ biến cho bài toán phân đoạn ảnh viễn thám, gồm U-Net, LinkNet và DeepLabV3+, được triển khai và đánh giá trên cùng một tập dữ liệu kiểm tra. Kết quả cho thấy LinkNet đạt hiệu năng tổng thể tốt nhất với chỉ số IoU đạt 90,74% và F1-score đạt 93,32%, nhỉnh hơn so với U-Net (IoU = 90,60%, F1 = 93,31%) và vượt trội so với DeepLabV3+ (IoU = 87,62%, F1 = 90,93%). Một thí nghiệm loại bỏ thành phần (ablation study) cũng được thực hiện để đánh giá đóng góp của kênh PVSI, cho thấy việc bổ sung chỉ số này giúp cải thiện nhất quán các chỉ số recall, F1-score, IoU và độ chính xác tổng thể (OA), dù mức cải thiện ở mức vừa phải. Báo cáo cũng thảo luận về giá trị của ảnh Sentinel-2 trong giám sát hạ tầng năng lượng tái tạo ở quy mô cấp tỉnh, so sánh hiệu năng giữa các kiến trúc phân đoạn, đồng thời chỉ ra các hạn chế và hướng phát triển trong tương lai, bao gồm việc tích hợp dữ liệu radar khẩu độ tổng hợp (SAR), ảnh độ phân giải cao hơn, và các phương pháp học sâu nhận biết chuỗi thời gian.

Từ khóa: Giám sát trang trại điện mặt trời; Sentinel-2; Phân đoạn ngữ nghĩa; Bà Rịa – Vũng Tàu; Học sâu; LinkNet; U-Net; DeepLabV3+; Chỉ số phổ quang điện (PVSI).

1. GIỚI THIỆU

1.1. Bối cảnh nghiên cứu

Trong thập kỷ vừa qua, Việt Nam đã trải qua một quá trình chuyển dịch năng lượng mạnh mẽ, với công suất điện mặt trời (photovoltaic – PV) tăng trưởng từ mức gần như không đáng kể lên đến hàng gigawatt chỉ trong một khoảng thời gian ngắn nhờ các chính sách khuyến khích phát triển năng lượng tái tạo. Sự bùng nổ này diễn ra đồng thời ở cả phân khúc điện mặt trời quy mô lớn (utility-scale) và điện mặt trời mái nhà (rooftop), với mức độ tập trung đặc biệt cao tại các tỉnh ven biển phía Nam – nơi có điều kiện bức xạ mặt trời thuận lợi quanh năm và quỹ đất công nghiệp, đất trống tương đối dồi dào.

Tỉnh Bà Rịa – Vũng Tàu (BRVT), nằm ở vùng duyên hải Đông Nam Bộ, là một trong những địa phương nổi bật về phát triển năng lượng mặt trời, bên cạnh vai trò truyền thống là trung tâm khai thác dầu khí, cảng biển và logistics, cũng như các khu công nghiệp sản xuất quy mô lớn. Sự kết hợp giữa điều kiện bức xạ cao, địa hình tương đối bằng phẳng và hạ tầng lưới điện sẵn có đã thúc đẩy việc triển khai các trang trại điện mặt trời quy mô công nghiệp tại tỉnh này kể từ năm 2019.

Mặc dù hạ tầng năng lượng mặt trời phát triển nhanh chóng, công tác giám sát không gian một cách hệ thống đối với sự phân bố và biến động của các trang trại điện mặt trời tại BRVT vẫn còn rất hạn chế. Các nhà quản lý và quy hoạch hiện vẫn chủ yếu dựa vào hồ sơ hành chính hoặc các đợt khảo sát thực địa định kỳ, vốn thiếu độ chi tiết không gian và tính nhất quán theo thời gian cần thiết cho công tác quản lý sử dụng đất một cách hiệu quả. Trong bối cảnh đó, viễn thám (remote sensing) nổi lên như một giải pháp thay thế có khả năng mở rộng, cho phép thực hiện các quan trắc lặp lại, có tham chiếu địa lý đối với biến động hạ tầng theo chu kỳ năm hoặc dưới năm mà không bị giới hạn bởi khả năng tiếp cận thực địa.

1.2. Vai trò của ảnh Sentinel-2 trong giám sát điện mặt trời

Sentinel-2, do Cơ quan Vũ trụ Châu Âu (ESA) vận hành trong khuôn khổ chương trình Copernicus, cung cấp ảnh đa phổ với độ phân giải không gian từ 10 đến 20 mét và chu kỳ chụp lặp lại khoảng 5 ngày. Những đặc điểm này khiến Sentinel-2 trở thành nguồn dữ liệu phù hợp để giám sát các công trình điện mặt trời có quy mô từ trung bình đến lớn ở cấp độ tỉnh. Tuy nhiên, để tạo ra các bản đồ biến động đáng tin cậy từ chuỗi ảnh đa thời gian, cần có quy trình xử lý mạnh mẽ nhằm khắc phục các vấn đề về nhiễu mây, sự thay đổi bức xạ giữa các năm, cũng như hiện tượng nhầm lẫn phổ giữa trang trại điện mặt trời với các loại hình bề mặt có đặc trưng phổ tương tự (ví dụ như mái nhà công nghiệp, mặt nước tĩnh, hoặc đất trống).

1.3. Vai trò của học sâu trong phân đoạn ảnh viễn thám

Phân đoạn ngữ nghĩa dựa trên học sâu đã trở thành một phương pháp hiệu quả để trích xuất các lớp phủ bề mặt từ ảnh viễn thám. Các kiến trúc mạng nơ-ron dạng mã hóa – giải mã (encoder–decoder), điển hình như U-Net và các biến thể liên quan, đã chứng tỏ hiệu năng vượt trội trong các bài toán bản đồ hóa hạ tầng và lớp phủ mặt đất. Tuy nhiên, phần lớn các nghiên cứu hiện có tập trung chủ yếu vào việc phát hiện tại một thời điểm đơn lẻ (single-date detection), trong khi vấn đề giám sát biến động theo từng năm của trang trại điện mặt trời – bao gồm tính bền vững (persistence), sự mở rộng (expansion) và các công trình mới xuất hiện (newly emerged) – vẫn chưa nhận được sự quan tâm tương xứng. Bên cạnh đó, hiệu quả của dữ liệu Sentinel-2 độ phân giải trung bình khi được tăng cường bằng các đặc trưng phổ chuyên biệt cho điện mặt trời cũng chưa được khai thác đầy đủ.

1.4. Mục tiêu và phạm vi nghiên cứu

Để giải quyết khoảng trống nêu trên, báo cáo này trình bày một khung giám sát tích hợp kết hợp: (i) ảnh Sentinel-2 đa thời gian; (ii) xây dựng đặc trưng định hướng quang điện thông qua chỉ số phổ PVSI; (iii) phân đoạn ngữ nghĩa bằng học sâu; (iv) tạo bản đồ nhị phân hằng năm; và (v) phân tích biến động liên năm cho tỉnh Bà Rịa – Vũng Tàu. Khung nghiên cứu sử dụng bảy kênh phổ Sentinel-2 cùng với một chỉ số phổ quang điện, đồng thời so sánh các kiến trúc phân đoạn trước khi triển khai suy luận trên toàn tỉnh.

Các đóng góp chính của báo cáo bao gồm:

1. Xây dựng một quy trình thực tiễn và có khả năng tái lập cho việc bản đồ hóa hằng năm trang trại điện mặt trời tại BRVT, sử dụng các ảnh tổ hợp theo mùa của Sentinel-2, đầu vào đa phổ và phân đoạn ngữ nghĩa bằng học sâu. Các ảnh tổ hợp Sentinel-2 thu thập trong giai đoạn 2020–2025 được gán nhãn thủ công và sử dụng riêng cho việc huấn luyện và kiểm định mô hình.
2. Thực hiện đánh giá so sánh ba kiến trúc phân đoạn: U-Net, LinkNet và DeepLabV3+, kết hợp với một thí nghiệm loại bỏ thành phần nhằm đánh giá đóng góp của kênh PVSI đối với bài toán bản đồ hóa điện mặt trời từ ảnh độ phân giải trung bình.

1.5. Cấu trúc báo cáo

Phần còn lại của báo cáo được tổ chức như sau. Mục 2 trình bày tổng quan các nghiên cứu liên quan về bản đồ hóa điện mặt trời và viễn thám đa thời gian. Mục 3 mô tả khu vực nghiên cứu và bộ dữ liệu Sentinel-2. Mục 4 trình bày phương pháp luận đề xuất, bao gồm tiền xử lý dữ liệu, phân

đoạn và giám sát. Mục 5 mô tả thiết lập thực nghiệm. Mục 6 trình bày kết quả và phân tích. Mục 7 thảo luận về ý nghĩa và hạn chế của khung nghiên cứu. Mục 8 trình bày kết luận và hướng phát triển trong tương lai.

2. TỔNG QUAN NGHIÊN CỨU LIÊN QUAN

2.1. Viễn thám đối với hạ tầng điện mặt trời

Lĩnh vực viễn thám phục vụ giám sát hạ tầng điện mặt trời (PV) đã phát triển nhanh chóng cùng với sự gia tăng khả năng tiếp cận ảnh độ phân giải cao và những tiến bộ trong phân đoạn ngữ nghĩa dựa trên học sâu. Các nghiên cứu ban đầu chủ yếu dựa vào các chỉ số phổ, phân tích ảnh hưởng đối tượng (object-based image analysis) và các đặc trưng kết cấu được thiết kế thủ công, áp dụng cho ảnh có độ phân giải rất cao. Tuy nhiên, các phương pháp này thường đòi hỏi quá trình hiệu chỉnh thủ công đáng kể và cho thấy khả năng mở rộng hạn chế khi áp dụng ở quy mô lớn.

Trong những năm gần đây, hướng tiếp cận chủ đạo đã chuyển dịch sang sử dụng mạng nơ-ron tích chập (CNN) để tự động phát hiện và phân định các công trình điện mặt trời từ kho dữ liệu ảnh vệ tinh quy mô lớn, cho phép thực hiện bản đồ hóa ở quy mô từ vùng đến toàn cầu. Các kiến trúc phân đoạn ngữ nghĩa như U-Net và DeepLabV3+ đã được áp dụng rộng rãi để trích xuất trang trại điện mặt trời từ ảnh quang học có độ phân giải trung bình và cao. Các mô hình CNN đã được áp dụng thành công cho bài toán bản đồ hóa trang trại điện mặt trời quy mô lớn sử dụng dữ liệu PlanetScope và Sentinel-2.

Một số nghiên cứu khác cho thấy các mạng CNN dạng mã hóa – giải mã vẫn duy trì tính cạnh tranh cao, thậm chí vượt trội so với các mô hình Transformer thị giác (Vision Transformers) đối với ảnh viễn thám đa phổ độ phân giải trung bình trong điều kiện thực tế bị giới hạn về dữ liệu huấn luyện và tài nguyên tính toán. Các kết quả tương tự cũng được ghi nhận trong các nghiên cứu bản đồ hóa lớp phủ mặt đất sử dụng Sentinel-2 ở phạm vi rộng hơn. Các nghiên cứu gần đây còn khai thác hướng phân đoạn nhận biết chuỗi thời gian (time-series-aware segmentation) và kỹ thuật xây dựng đặc trưng theo thời gian nhằm nắm bắt tốt hơn sự biến động của các trang trại điện mặt trời theo thời gian.

Mặc dù các kiến trúc Transformer và mô hình lai (hybrid) đã thể hiện hiệu năng mạnh mẽ trong các môi trường phức tạp, các mô hình CNN dạng mã hóa – giải mã vẫn là lựa chọn thực tiễn cho công tác giám sát điện mặt trời ở quy mô cấp tỉnh, do chúng mang lại sự cân bằng thuận lợi giữa độ chính xác, chi phí tính toán và hiệu quả triển khai. Dựa trên cơ sở bằng chứng đó, báo cáo này đánh giá ba kiến trúc phân đoạn dựa trên CNN có tính đại diện cao, gồm U-Net, LinkNet và DeepLabV3+, cho bài toán bản đồ hóa hằng năm trang trại điện mặt trời từ các ảnh tổ hợp theo mùa của Sentinel-2 tại BRVT.

2.2. Giám sát đa thời gian biến động lớp phủ và hạ tầng

Giám sát lớp phủ mặt đất đa thời gian và phát hiện biến động là những chủ đề đã được nghiên cứu khá đầy đủ trong lĩnh vực viễn thám, được ứng dụng rộng rãi trong các bài toán đô thị hóa, biến động nông nghiệp và mất rừng. Các nghiên cứu gần đây ngày càng sử dụng chuỗi ảnh quang học dày đặc, chẳng hạn như Sentinel-1/2 và Landsat-8/9, kết hợp với các phương pháp học máy hoặc học sâu để tạo ra các bản đồ nhất quán theo thời gian và định lượng các quá trình chuyển đổi lớp phủ mặt đất. Kỹ thuật tổ hợp ảnh theo thời gian (temporal compositing) và trích xuất đặc trưng chuỗi thời gian đặc biệt hiệu quả ở các khu vực nhiệt đới, nơi mà tình trạng mây che phủ kéo dài thường gây hạn chế cho các phân tích dựa trên ảnh đơn lẻ tại một thời điểm.

Đối với hạ tầng năng lượng mặt trời, các nghiên cứu ban đầu chủ yếu xây dựng các bộ dữ liệu kiểm kê tĩnh hoặc bản đồ đơn năm. Các nghiên cứu gần đây hơn đã phát triển các bộ dữ liệu điện mặt trời mang tính thời gian rõ ràng, thông qua việc áp dụng phân đoạn học sâu trên ảnh đa năm, từ đó cho phép phát hiện các công trình điện mặt trời mới xây dựng, được mở rộng hoặc bị ngừng hoạt động ở quy mô lớn. Các khung nghiên cứu liên quan cũng cho thấy giá trị của việc sử dụng các chồng ảnh đa năm hoặc các chỉ số phổ để nắm bắt quỹ đạo biến động thay vì chỉ bản đồ hóa từng năm một cách độc lập. Theo định hướng đó, nghiên cứu trong báo cáo này sử dụng các ảnh tổ hợp Sentinel-2 hằng năm và phương pháp sai khác sau phân đoạn (post-segmentation differencing) để bản đồ hóa các vùng trang trại điện mặt trời mới, ổn định và mở rộng ở quy mô cấp tỉnh.

2.3. Năng lượng mặt trời và viễn thám tại Việt Nam

Tại Việt Nam, việc ứng dụng viễn thám và trí tuệ nhân tạo cho các mục đích năng lượng và môi trường đã phát triển nhanh chóng trong những năm gần đây, mặc dù các nghiên cứu chuyên biệt về giám sát trang trại điện mặt trời vẫn còn hạn chế. Chuỗi ảnh Sentinel-2 và các phương pháp dựa trên CNN ngày càng được áp dụng rộng rãi để tạo ra các bản đồ sử dụng đất và lớp phủ mặt đất có độ phân giải cao, bao gồm các sản phẩm được thiết kế riêng cho Việt Nam và được tối ưu hóa cho các điều kiện thường xuyên có mây thông qua kỹ thuật tổ hợp ảnh đa năm. Các phương pháp viễn thám và học máy tương tự cũng đã được sử dụng cho giám sát rừng, mở rộng đô thị, phân tích nhiệt độ bề mặt và đánh giá chất lượng nước biển, qua đó cho thấy giá trị thực tiễn của các phương pháp này đối với công tác quản lý môi trường tại Việt Nam.

Mặc dù Việt Nam đã trải qua sự tăng trưởng nhanh chóng ở cả phân khúc điện mặt trời quy mô lớn và điện mặt trời mái nhà, việc giám sát hạ tầng điện mặt trời dựa trên học sâu ở quy mô cấp tỉnh vẫn còn rất hạn chế. Các nghiên cứu ứng dụng hiện có chủ yếu tập trung vào bản đồ hóa điện mặt trời mái nhà tại một số tỉnh và năm cụ thể, với sự quan tâm hạn chế đối với việc giám sát hằng

năm một cách nhất quán đối với các trang trại điện mặt trời lắp đặt trên mặt đất. Báo cáo này hướng tới việc lấp đầy khoảng trống đó cho tỉnh BRVT, đồng thời chứng minh tiềm năng của ảnh độ phân giải trung bình kết hợp với phân đoạn dựa trên CNN cho việc giám sát năm-quá-năm có thể tái lập đối với sự mở rộng của điện mặt trời tại Việt Nam.

2.4. Nhận xét và khoảng trống nghiên cứu

Từ tổng quan trên, có thể rút ra ba nhận xét chính. Thứ nhất, mặc dù các kiến trúc CNN dạng mã hóa – giải mã đã được chứng minh hiệu quả trong bài toán phân đoạn trang trại điện mặt trời, phần lớn các nghiên cứu vẫn tập trung vào phân tích đơn thời điểm thay vì giám sát biến động liên năm một cách hệ thống. Thứ hai, việc kết hợp các chỉ số phổ chuyên biệt cho điện mặt trời (như PVSI) với ảnh đa phổ Sentinel-2 độ phân giải trung bình vẫn chưa được khai thác đầy đủ, đặc biệt trong bối cảnh các điều kiện khí hậu nhiệt đới với mây che phủ thường xuyên. Thứ ba, đối với Việt Nam nói chung và BRVT nói riêng, vẫn thiếu vắng các nghiên cứu cung cấp một quy trình hoàn chỉnh, có khả năng tái lập, từ thu thập dữ liệu, gán nhãn, huấn luyện mô hình đến giám sát biến động hàng năm ở quy mô cấp tỉnh.

Báo cáo này được xây dựng nhằm đáp ứng các khoảng trống nêu trên, thông qua việc xây dựng một khung giám sát tích hợp, kết hợp dữ liệu Sentinel-2 đa thời gian, đặc trưng phổ định hướng quang điện (PVSI), và so sánh có hệ thống giữa ba kiến trúc phân đoạn phổ biến, áp dụng cho bài toán giám sát trang trại điện mặt trời tại tỉnh BRVT trong giai đoạn 2020–2025.

2.5. Vai trò của các chỉ số phổ chuyên biệt trong viễn thám điện mặt trời

Bên cạnh việc sử dụng trực tiếp các kênh phổ thô làm đầu vào cho mô hình học sâu, nhiều nghiên cứu đã chứng minh rằng việc bổ sung các chỉ số phổ được thiết kế chuyên biệt có thể cải thiện đáng kể khả năng phân biệt giữa đối tượng quan tâm và nền xung quanh, đặc biệt trong các bài toán có sự nhập nhằng phổ cao. Trong lĩnh vực giám sát thực vật, các chỉ số như NDVI (Normalized Difference Vegetation Index) hay NDWI (Normalized Difference Water Index) từ lâu đã được sử dụng như các kênh đầu vào bổ sung cho mô hình phân loại và phân đoạn, giúp mô hình hội tụ nhanh hơn và đạt độ chính xác cao hơn so với khi chỉ sử dụng các kênh phổ gốc.

Đối với bài toán phát hiện bề mặt tấm pin quang điện, các tấm pin silicon tinh thể có đặc trưng phổ phản xạ khá đặc biệt: phản xạ thấp ở vùng ánh sáng nhìn thấy do lớp phủ chống phản xạ, đồng thời có sự khác biệt rõ rệt trong vùng hồng ngoại sóng ngắn (SWIR) so với các bề mặt nhân tạo khác như mái tôn, bê tông hay đường nhựa. Chỉ số PVSI được sử dụng trong nghiên cứu này được xây dựng dựa trên sự kết hợp có trọng số giữa các kênh SWIR (B11, B12), kênh cận hồng ngoại

(B8) và các kênh vùng nhìn thấy (B2, B4), cùng với một thành phần liên quan đến tỷ lệ giữa kênh red-edge (B6) và NIR nhằm loại trừ các pixel có đặc trưng thực vật. Cách tiếp cận tổ hợp đa thành phần này cho phép PVSI nắm bắt đồng thời nhiều khía cạnh của tín hiệu phổ đặc trưng cho bề mặt quang điện, thay vì chỉ dựa vào một cặp kênh phổ đơn lẻ như các chỉ số truyền thống.

Việc đưa PVSI vào như một kênh đầu vào bổ sung, thay vì chỉ sử dụng nó như một bước tiền lọc (pre-filtering) hoặc hậu xử lý, cho phép mô hình học sâu tự học cách kết hợp thông tin từ PVSI với các đặc trưng không gian và phổ khác trong quá trình huấn luyện end-to-end. Đây là một trong những điểm khác biệt của khung nghiên cứu được trình bày trong báo cáo này so với các phương pháp dựa trên ngưỡng chỉ số phổ đơn thuần.

2.6. So sánh các kiến trúc mã hóa – giải mã trong phân đoạn ảnh viễn thám

Việc lựa chọn kiến trúc mạng nơ-ron phù hợp là một yếu tố quan trọng quyết định hiệu năng và khả năng triển khai thực tế của một hệ thống giám sát dựa trên học sâu. U-Net, kể từ khi được giới thiệu cho bài toán phân đoạn ảnh y sinh, đã được áp dụng rộng rãi sang lĩnh vực viễn thám nhờ khả năng khôi phục chi tiết không gian thông qua các kết nối tắt giữa các lớp tương ứng của nhánh mã hóa và giải mã. Tuy nhiên, số lượng tham số của U-Net thường lớn hơn so với các kiến trúc gọn nhẹ hơn như LinkNet, dẫn đến chi phí tính toán và bộ nhớ cao hơn khi triển khai trên các tập dữ liệu lớn.

LinkNet, với chiến lược cộng trực tiếp đặc trưng từ nhánh mã hóa vào nhánh giải mã thay vì nối (concatenation), giúp giảm đáng kể số lượng tham số mà không làm giảm nhiều chất lượng phân đoạn, đặc biệt khi kết hợp với một bộ mã hóa nền mạnh như EfficientNet. Điều này khiến LinkNet trở thành một lựa chọn hấp dẫn cho các ứng dụng cần xử lý khối lượng dữ liệu lớn, chẳng hạn như suy luận trên toàn bộ phạm vi một tỉnh với nhiều ô lưới ảnh.


DeepLabV3+, với mô-đun ASPP, được thiết kế ban đầu cho các bài toán phân đoạn cảnh đô thị phức tạp với nhiều đối tượng có kích thước và hình dạng đa dạng. Trong bối cảnh phân đoạn trang trại điện mặt trời – vốn là các đối tượng có hình dạng tương đối đồng nhất, ranh giới rõ ràng và kích thước lớn so với kích thước pixel – lợi thế của ASPP trong việc nắm bắt ngữ cảnh đa tỷ lệ có thể không được phát huy đầy đủ, trong khi cấu trúc phức tạp hơn của mô hình có thể dẫn đến xu hướng dự đoán thận trọng hơn ở vùng biên, như đã được quan sát trong kết quả thực nghiệm tại Mục 6.

3. KHU VỰC NGHIÊN CỨU VÀ DỮ LIỆU

3.1. Khu vực nghiên cứu

Tỉnh Bà Rịa – Vũng Tàu, với diện tích khoảng 1.980 km², nằm ở vùng duyên hải Đông Nam Bộ Việt Nam, là một khu vực có vị trí chiến lược quan trọng, được đặc trưng bởi một cảnh quan đa dạng bao gồm các khu công nghiệp và vùng đất thấp ven biển. Nhờ khí hậu nhiệt đới gió mùa, tỉnh được hưởng lợi từ mức bức xạ mặt trời cao quanh năm. Lợi thế tài nguyên này, kết hợp với địa hình tương đối bằng phẳng gần các cơ sở hạ tầng lưới điện hiện có, đã thúc đẩy quá trình triển khai các trang trại điện mặt trời quy mô công nghiệp kể từ năm 2019.

Phạm vi địa lý của khu vực nghiên cứu cùng với sự phân bố không gian của các cụm trang trại điện mặt trời được thể hiện trong bản đồ khu vực nghiên cứu. Bản đồ nền cho thấy ranh giới hành chính cấp tỉnh và vị trí của các cụm trang trại điện mặt trời đã được biết đến, phân bố tương đối tập trung ở một số khu vực có địa hình thuận lợi và gần hạ tầng lưới điện.



Hình 3.1. Khu vực nghiên cứu: tỉnh Bà Rịa – Vũng Tàu, Việt Nam, với ranh giới hành chính và vị trí các cụm trang trại điện mặt trời đã được xác định.

3.2. Dữ liệu ảnh vệ tinh Sentinel-2

Sentinel-2 cung cấp ảnh quang học đa phổ trong các dải sóng nhìn thấy, cận hồng ngoại (NIR) và hồng ngoại sóng ngắn (SWIR) với độ phân giải không gian từ 10 đến 20 mét, cùng tần suất chụp lặp lại phù hợp cho việc tổ hợp ảnh hằng năm trong điều kiện môi trường nhiệt đới. Những đặc điểm này khiến Sentinel-2 trở thành nguồn dữ liệu phù hợp cho công tác bản đồ hóa và giám sát trang trại điện mặt trời ở quy mô cấp tỉnh.

Trong nghiên cứu này, dữ liệu phản xạ bề mặt Sentinel-2 mức xử lý Level-2A đã được thu thập cho tỉnh BRVT trong giai đoạn 2020–2025, sử dụng nền tảng Google Earth Engine (GEE) và bộ dữ liệu COPERNICUS/S2_SR_HARMONIZED. Dữ liệu giai đoạn 2020–2022 được sử dụng để hỗ trợ công tác gán nhãn và phát triển mô hình, trong khi ảnh từ giai đoạn 2023–2025 được sử dụng cho bản đồ hóa hằng năm và phân tích biến động liên năm. Việc phân tách thời gian này giúp đảm bảo rằng giai đoạn giám sát được thực hiện trên dữ liệu ảnh khác biệt với dữ liệu được sử dụng để chuẩn bị nhãn, qua đó cung cấp một hình thức kiểm chứng tiến cứu (prospective validation) cho mô hình.

3.2.1. Các kênh phổ và chỉ số sử dụng

Bảng 3.1 tóm tắt các kênh phổ Sentinel-2 và chỉ số phổ quang điện (PVSI) được sử dụng trong nghiên cứu này. Mỗi kênh phổ được lựa chọn dựa trên vai trò cụ thể của nó trong việc phân biệt bề mặt trang trại điện mặt trời với các loại hình bề mặt khác.

Kênh / Chỉ số	Tên gọi	Mô tả	Vai trò trong phân tích
B2	Lam (Blue)	Kênh phổ vùng ánh sáng lam	Tổ hợp RGB / trực quan hóa
B3	Lục (Green)	Kênh phổ vùng ánh sáng lục	Tổ hợp RGB / trực quan hóa
B4	Đỏ (Red)	Kênh phổ vùng ánh sáng đỏ	Tương phản thực vật
B6	Red Edge 1	Kênh phổ rìa đỏ thứ nhất	Phát hiện thực vật / tấm pin
B8	NIR	Kênh cận hồng ngoại	Thực vật / đất trống
B11	SWIR-1	Hồng ngoại sóng ngắn 1	Phân biệt tấm pin / khu xây dựng
B12	SWIR-2	Hồng ngoại sóng ngắn 2	Tương phản vật liệu bề mặt
PVSI	Chỉ số phổ quang điện	Chỉ số tổ hợp dùng để làm nổi bật bề mặt tấm pin mặt trời	Làm nổi bật tấm pin mặt trời

Bảng 3.1. Các kênh phổ Sentinel-2 và chỉ số PVSI sử dụng cho bản đồ hóa trang trại điện mặt trời.

3.2.2. Khung thời gian thu thập dữ liệu

Dữ liệu ảnh được thu thập trong khung thời gian cố định từ ngày 1 tháng 1 đến ngày 1 tháng 7 hằng năm, nhằm đảm bảo tính nhất quán về điều kiện chiếu sáng và giảm thiểu ảnh hưởng của biến động theo mùa. Đối với mỗi năm trong giai đoạn 2020–2025, một ảnh tổ hợp duy nhất, ít mây, được tạo ra từ tất cả các quan trắc hợp lệ trong khung thời gian nêu trên. Bảng 3.2 tóm tắt việc phân chia vai trò của dữ liệu theo từng năm.

Giai đoạn	Vai trò	Ghi chú
2020 – 2022	Gán nhãn thủ công và phát triển mô hình (huấn luyện, kiểm định, kiểm tra)	Không sử dụng cho suy luận trên toàn tỉnh
2023 – 2025	Suy luận trên toàn tỉnh và phân tích biến động liên năm	Không tham gia quá trình huấn luyện mô hình

Bảng 3.2. Phân chia vai trò dữ liệu Sentinel-2 theo giai đoạn thời gian.


4. PHƯƠNG PHÁP LUẬN

4.1. Khung nghiên cứu tổng thể

Khung nghiên cứu đề xuất bao gồm bốn giai đoạn tuần tự, được thiết kế nhằm đảm bảo tính nhất quán giữa giai đoạn xây dựng mô hình và giai đoạn triển khai giám sát thực tế:

3. Thu thập và tiền xử lý dữ liệu: bao gồm việc truy xuất ảnh Sentinel-2 thông qua Google Earth Engine, che mây, tổ hợp ảnh hằng năm, xây dựng đặc trưng phổ và gán nhãn thủ công.
4. Phát triển mô hình học sâu: triển khai và huấn luyện các kiến trúc phân đoạn U-Net, LinkNet và DeepLabV3+.
5. Đánh giá và lựa chọn mô hình: sử dụng các chỉ số đánh giá phân đoạn tiêu chuẩn để so sánh hiệu năng các mô hình và xác định kiến trúc phù hợp nhất.
6. Bản đồ hóa điện mặt trời hằng năm và giám sát biến động: tạo các bản đồ dấu vết trang trại điện mặt trời theo từng năm và phân tích các mô hình mở rộng không gian – thời gian.

Sơ đồ tổng thể của quy trình xử lý được trình bày trong Hình 4.1, cho thấy luồng xử lý đi từ thu thập và tiền xử lý dữ liệu, qua huấn luyện và so sánh mô hình, đến tạo bản đồ nhị phân hằng năm và phân tích biến động liên năm.



Hình 4.1. Khung tổng thể cho giám sát hằng năm trang trại điện mặt trời sử dụng ảnh Sentinel-2 đa thời gian và phân đoạn ngữ nghĩa bằng học sâu. Quy trình tiến hành từ thu thập và tiền xử lý dữ liệu, qua huấn luyện và so sánh mô hình, tạo bản đồ nhị phân hằng năm, đến phân tích biến động liên năm.

4.2. Chuẩn bị dữ liệu Sentinel-2

4.2.1. Phân chia lưới khu vực nghiên cứu và thu thập ảnh hằng năm

Để hỗ trợ quá trình xử lý trên toàn tỉnh, khu vực BRVT được chia thành các ô lưới đều với kích thước xấp xỉ $0,25^\circ \times 0,25^\circ$, và chỉ những ô lưới giao cắt với ranh giới hành chính cấp tỉnh mới được giữ lại để xử lý. Chiến lược dựa trên lưới này cho phép trích xuất ảnh một cách có hệ thống và giảm thiểu gánh nặng tính toán khi xử lý dữ liệu trên diện rộng trong môi trường Google Earth Engine.

Ảnh phản xạ bề mặt Sentinel-2 mức Level-2A được thu thập cho tất cả các năm từ 2020 đến 2025, trong khung thời gian cố định từ ngày 1 tháng 1 đến ngày 1 tháng 7. Các ảnh tổ hợp hằng năm thuộc giai đoạn 2020–2022 được sử dụng cho công tác gán nhãn và phát triển mô hình, trong khi các ảnh tổ hợp thuộc giai đoạn 2023–2025 được dành riêng cho suy luận trên toàn tỉnh và giám sát biến động. Thiết kế này đảm bảo sự phân tách rõ ràng giữa giai đoạn chuẩn bị dữ liệu huấn luyện và giai đoạn triển khai vận hành.

4.2.2. Che mây và tổ hợp ảnh hằng năm

Để giảm thiểu nhiễu do mây che phủ, mỗi ảnh Sentinel-2 được ghép cặp với sản phẩm xác suất mây tương ứng và được che bằng ngưỡng xác suất mây 50%. Tất cả các quan trắc hợp lệ trong mỗi năm sau đó được tổng hợp bằng phương pháp tổ hợp trung vị (median compositing) để tạo ra một ảnh tổ hợp hằng năm duy nhất, đã được giảm nhiễu mây. Phương pháp này giúp loại bỏ các tạp chất còn sót lại do mây gây ra và tạo ra các biểu diễn ảnh hằng năm ổn định về mặt phổ, phù hợp cho việc so sánh giữa các năm.

4.2.3. Lựa chọn kênh phổ và xây dựng PVSI

Mỗi ảnh tổ hợp hằng năm được giữ lại bảy kênh Sentinel-2: B2, B3, B4, B6, B8, B11 và B12. Bên cạnh đó, một chỉ số phổ quang điện được tính toán như một đặc trưng bổ sung nhằm tăng cường khả năng phân biệt bề mặt tấm pin mặt trời với các loại hình lớp phủ xung quanh. Theo công thức được đề xuất trong tài liệu tham khảo về chỉ số PVSI, công thức tính như sau:

$$PVSI = (2,3 \cdot B11 - 1,1 \cdot B12 - B8) / (2,3 \cdot B11 + 1,1 \cdot B12 + B8) + 0,5 \cdot (B2 - B4 - B8) + \text{sign}(1,3 - B6/B8) - 1$$

trong đó các kênh phổ đầu vào trước tiên được chuyển đổi sang giá trị phản xạ bề mặt bằng cách chia giá trị số nguyên (digital number) cho 10.000. Lớp PVSI thu được sau đó được ghép thêm vào chồng ảnh đa phổ, tạo thành một tensor đầu vào tám kênh. Để đánh giá đóng góp của thành phần này, một thí nghiệm loại bỏ thành phần (ablation experiment) cũng được tiến hành sử dụng cùng một kiến trúc mô hình nhưng không bao gồm kênh PVSI.

Về mặt trực quan, PVSI được thiết kế để khai thác sự khác biệt phổ đặc trưng của bề mặt tấm pin quang điện trong các kênh hồng ngoại sóng ngắn (B11, B12) so với cận hồng ngoại (B8), kết hợp với thành phần liên quan đến vùng ánh sáng nhìn thấy (B2, B4) và tỷ lệ giữa kênh red-edge (B6) và NIR (B8) nhằm phân biệt bề mặt tấm pin với thực vật và đất trồng. Việc tích hợp các thành phần này vào một chỉ số tổng hợp duy nhất cho phép mô hình học sâu khai thác thông tin phổ chuyên biệt mà không cần tăng đáng kể số lượng kênh đầu vào.

4.3. Phân đoạn trang trại điện mặt trời

4.3.1. Chuẩn bị dữ liệu huấn luyện

Nhãn huấn luyện được tạo ra thông qua quá trình giải đoán trực quan thủ công trên các ảnh tổ hợp Sentinel-2 hằng năm thuộc giai đoạn 2020–2022. Các đa giác trang trại điện mặt trời được khoanh vẽ dựa trên các đặc trưng không gian và đặc trưng phổ riêng biệt của chúng, kết hợp với việc đối chiếu chéo giữa các năm liên tiếp nhằm giảm thiểu sự không nhất quán trong gán nhãn. Chỉ những công trình quang điện có thể nhận diện rõ ràng mới được giữ lại trong tập dữ liệu huấn luyện có giám sát.

Các ảnh đã được gán nhãn sau đó được chuyển đổi thành các mặt nạ phân đoạn nhị phân (binary segmentation masks). Các mảnh ảnh đầu vào (patches) có kích thước 256×256 pixel được trích xuất, mỗi mảnh chứa tám kênh: bảy kênh phổ Sentinel-2 (B2, B3, B4, B6, B8, B11, B12) và một lớp PVI dẫn xuất. Tổng cộng 5.000 mảnh ảnh đã gán nhãn được chia thành các tập huấn luyện, kiểm định và kiểm tra theo tỷ lệ 8:1:1, tương ứng với 4.000 / 500 / 500 mảnh. Điều quan trọng là không có mảnh ảnh nào từ giai đoạn giám sát 2023–2025 được đưa vào tập dữ liệu huấn luyện, nhằm đảm bảo khả năng tổng quát hóa theo thời gian của mô hình.

4.3.2. Tăng cường và tiền xử lý dữ liệu

Tăng cường dữ liệu (data augmentation) được áp dụng trong quá trình huấn luyện thông qua thư viện Albumentations nhằm nâng cao khả năng tổng quát hóa và giảm hiện tượng quá khớp (overfitting). Quy trình tăng cường bao gồm: lật ngang (horizontal flipping) với xác suất $p = 0,8$; lật dọc (vertical flipping) với xác suất $p = 0,8$; và cắt ngẫu nhiên có thay đổi tỷ lệ (random resized cropping) với khoảng tỷ lệ 0,5–1,0 và xác suất $p = 0,5$, trong khi vẫn duy trì kích thước mảnh ảnh đầu ra cuối cùng là 256×256 pixel.

Đối với các mảnh ảnh thuộc tập kiểm định, phép đệm (padding) được áp dụng khi cần thiết để đảm bảo kích thước đầu vào nhất quán. Tất cả các tensor ảnh được chuyển đổi từ định dạng channel-last sang channel-first trước khi đưa vào huấn luyện, nhằm tuân thủ quy ước của PyTorch.

4.3.3. Các kiến trúc mô hình phân đoạn

Quá trình phân đoạn ngữ nghĩa được thực hiện sử dụng ba kiến trúc mã hóa – giải mã (encoder-decoder) từ thư viện segmentation_models_pytorch: U-Net, LinkNet và DeepLabV3+. Mỗi kiến trúc có những đặc điểm thiết kế riêng biệt, phù hợp để so sánh trong bối cảnh bài toán phân đoạn trang trại điện mặt trời từ ảnh đa phổ độ phân giải trung bình.

U-Net

U-Net áp dụng một cấu trúc mã hóa – giải mã đối xứng với các kết nối tắt (skip connections), cho phép truyền các đặc trưng không gian chi tiết từ nhánh mã hóa sang nhánh giải mã. Cấu trúc này giúp mô hình khôi phục lại các chi tiết biên dạng (boundary) một cách chính xác, đặc biệt hữu ích đối với các đối tượng có hình dạng hình học rõ ràng như các tấm pin mặt trời được sắp xếp theo dãy.

LinkNet

LinkNet áp dụng một thiết kế gọn nhẹ hơn, trong đó các bản đồ đặc trưng từ nhánh mã hóa được cộng trực tiếp (thay vì nối – concatenation) vào đầu ra của nhánh giải mã tương ứng. Cách tiếp

cận này giúp giảm đáng kể số lượng tham số của mô hình trong khi vẫn bảo toàn được các chi tiết không gian quan trọng, qua đó mang lại hiệu quả tính toán cao hơn so với U-Net mà không làm giảm đáng kể chất lượng phân đoạn.

DeepLabV3+

DeepLabV3+ mở rộng mô hình mã hóa – giải mã bằng cách bổ sung mô-đun gộp không gian kim tự tháp giãn nở (Atrous Spatial Pyramid Pooling – ASPP) tại lớp nút thắt cổ chai (bottleneck) của nhánh mã hóa. Mô-đun ASPP được thiết kế để nắm bắt thông tin ngữ cảnh đa tỷ lệ thông qua các phép tích chập giãn nở (atrous/dilated convolutions) song song với nhiều tỷ lệ giãn nở khác nhau, cho phép mô hình bao quát các đối tượng có kích thước khác nhau trong cùng một ảnh.

4.3.4. Cấu hình đầu vào – đầu ra chung

Cả ba kiến trúc đều được cấu hình để nhận đầu vào là tensor tám kênh (bảy kênh phổ Sentinel-2 và lớp PVSII dẫn xuất) và tạo ra một kênh đầu ra nhị phân duy nhất, tương ứng với sự hiện diện của trang trại điện mặt trời. Đối với tất cả các kiến trúc, một bộ mã hóa (encoder) EfficientNet-B7 đã được huấn luyện trước trên bộ dữ liệu ImageNet được sử dụng để đảm bảo một cơ sở trích xuất đặc trưng nhất quán giữa các mô hình so sánh. Một hàm kích hoạt sigmoid được áp dụng tại lớp đầu ra để tạo ra xác suất xuất hiện trang trại điện mặt trời cho từng pixel.

4.4. Bản đồ hóa hằng năm và hậu xử lý

Dựa trên kết quả đánh giá so sánh được trình bày tại Mục 6.1, LinkNet đạt được sự cân bằng tổng thể tốt nhất trong số các kiến trúc được đánh giá, đạt được chỉ số IoU, F1-score và độ chính xác tổng thể cao nhất, đồng thời duy trì tính nhất quán không gian mạnh mẽ trong việc khoanh vẽ trang trại điện mặt trời. Bên cạnh đó, thiết kế mã hóa – giải mã gọn nhẹ của LinkNet mang lại lợi thế thực tiễn cho việc suy luận trên diện rộng đối với ảnh Sentinel-2 đa thời gian. Do đó, LinkNet được lựa chọn cho bản đồ hóa toàn tỉnh hằng năm và giám sát biến động.

Mô hình LinkNet được lựa chọn, đã được huấn luyện trên ảnh giai đoạn 2020–2022, sau đó được áp dụng cho các ảnh tổ hợp hằng năm thuộc giai đoạn 2023–2025. Vì dữ liệu ảnh thuộc giai đoạn giám sát không được sử dụng trong quá trình huấn luyện, thiết lập này cung cấp một hình thức kiểm chứng tiến cứu (prospective validation) và phản ánh khả năng tổng quát hóa vận hành của mô hình. Các bản đồ xác suất dự đoán được áp dụng ngưỡng 0,5 để tạo ra các mặt nạ nhị phân trang trại điện mặt trời, sau đó được ghép (mosaicked) thành phạm vi toàn tỉnh cho mỗi năm.

Để cải thiện chất lượng bản đồ, quy trình hậu xử lý bao gồm ba bước:

7. Loại bỏ các thành phần liên thông (connected components) có diện tích nhỏ hơn 0,5 ha, phù hợp với giới hạn phát hiện thực tế đối với các công trình điện mặt trời quy mô công nghiệp ở độ phân giải Sentinel-2.
8. Áp dụng phép toán hình thái học mở (morphological opening) để loại bỏ các cụm nhiễu bị cô lập.
9. Áp dụng phép toán hình thái học đóng (morphological closing) để làm mượt các bất thường nhỏ ở biên và cải thiện tính nhất quán không gian giữa các năm.

Kết quả đầu ra cuối cùng bao gồm ba bản đồ raster nhị phân có tham chiếu địa lý (M2023 đến M2025), thể hiện dấu vết ước tính của trang trại điện mặt trời cho từng năm tương ứng.

4.5. Quy trình huấn luyện và đánh giá mô hình

Quá trình huấn luyện được thực hiện theo hướng tiếp cận học có giám sát (supervised learning) tiêu chuẩn cho bài toán phân đoạn nhị phân. Đối với mỗi kiến trúc (U-Net, LinkNet, DeepLabV3+), mô hình được khởi tạo với trọng số bộ mã hóa EfficientNet-B7 đã được huấn luyện trước trên ImageNet, trong khi các trọng số của nhánh giải mã và lớp đầu ra được khởi tạo ngẫu nhiên. Việc sử dụng trọng số huấn luyện trước giúp mô hình tận dụng được các đặc trưng thị giác cấp thấp và cấp trung đã được học từ một tập dữ liệu ảnh tự nhiên quy mô lớn, từ đó tăng tốc độ hội tụ và cải thiện hiệu năng tổng quát hóa, đặc biệt trong điều kiện tập dữ liệu huấn luyện viễn thám có quy mô tương đối hạn chế.

Hàm mất mát binary focal loss được lựa chọn nhằm giải quyết vấn đề mất cân bằng lớp (class imbalance) vốn rất phổ biến trong bài toán phân đoạn trang trại điện mặt trời, khi diện tích pixel thuộc lớp nền (background) chiếm ưu thế áp đảo so với lớp đối tượng (trang trại điện mặt trời). So với hàm mất mát binary cross-entropy tiêu chuẩn, focal loss bổ sung một hệ số điều chỉnh (modulating factor) làm giảm trọng số đóng góp của các mẫu dễ phân loại (easy examples), qua đó tập trung quá trình học vào các mẫu khó – thường là các pixel nằm gần biên đối tượng hoặc thuộc các mảng pin có kích thước nhỏ, phân tán.

Bộ tối ưu hóa Adam được sử dụng với tốc độ học ban đầu 5×10^{-4} , là một lựa chọn phổ biến cho các bài toán phân đoạn ảnh do khả năng thích ứng tốc độ học theo từng tham số, giúp ổn định quá trình huấn luyện trong giai đoạn đầu. Kích thước batch được thiết lập là 16, là một sự cân bằng hợp lý giữa hiệu quả sử dụng bộ nhớ GPU và tính ổn định của gradient ước lượng, đặc biệt khi xử lý các tensor đầu vào tám kênh có kích thước không gian 256×256 .

Trong suốt quá trình huấn luyện, hiệu năng mô hình trên tập kiểm định (validation set) được theo dõi định kỳ nhằm phát hiện dấu hiệu quá khớp và lựa chọn điểm dừng (checkpoint) phù hợp. Sau khi hoàn tất huấn luyện, mô hình tốt nhất theo tiêu chí trên tập kiểm định được đánh giá lần cuối trên tập kiểm tra độc lập (held-out test set) để tạo ra các kết quả định lượng được trình bày tại Mục 6. Việc phân chia rõ ràng giữa ba tập huấn luyện, kiểm định và kiểm tra theo tỷ lệ 8:1:1, cùng với việc loại trừ hoàn toàn dữ liệu giai đoạn 2023–2025 khỏi quá trình huấn luyện và kiểm định, đảm bảo rằng các đánh giá hiệu năng phản ánh trung thực khả năng tổng quát hóa của mô hình, cả về không gian (đối với các khu vực chưa từng xuất hiện trong tập huấn luyện) lẫn về thời gian (đối với các năm chưa từng được sử dụng để huấn luyện).

5. THIẾT LẬP THỰC NGHIỆM

Quá trình thu thập dữ liệu, che mây và tổ hợp ảnh hàng năm được thực hiện trên nền tảng Google Earth Engine. Các ảnh tổ hợp GeoTIFF sau khi xuất ra được phân mảnh (tiled) trên hạ tầng tính toán cục bộ và được sử dụng cho huấn luyện, đánh giá và suy luận mô hình. Bảng 5.1 tóm tắt các tham số chính của cấu hình thực nghiệm.

Tham số	Giá trị
Mô hình phân đoạn	U-Net, LinkNet, DeepLabV3+ (triển khai trên PyTorch)
Số kênh đầu vào	8 kênh (B2, B3, B4, B6, B8, B11, B12, PVSI)
Kích thước mảnh ảnh (tile/patch)	256×256 pixel, độ phân giải 10 m
Tỷ lệ Huấn luyện / Kiểm định / Kiểm tra	80% / 10% / 10%
Bộ mã hóa nền (encoder backbone)	EfficientNet-B7 (huấn luyện trước trên ImageNet)
Hàm mất mát (loss function)	Binary focal loss
Bộ tối ưu hóa (optimizer)	Adam
Tốc độ học ban đầu (learning rate)	5×10^{-4}
Kích thước batch (batch size)	16
Khoảng thời gian tổ hợp ảnh	Tháng 1 đến tháng 6 hàng năm
Ảnh tổ hợp dùng để gán nhãn	2020, 2021, 2022
Ảnh tổ hợp dùng để giám sát	2023, 2024, 2025
Hàm kích hoạt đầu ra	Sigmoid
Ngưỡng phân ngưỡng nhị phân	0,5

Bảng 5.1. Cấu hình thực nghiệm cho huấn luyện và suy luận mô hình phân đoạn.

5.1. Các chỉ số đánh giá hiệu năng

Hiệu năng mô hình được đánh giá trên tập kiểm tra (held-out test set) sử dụng các chỉ số đánh giá phân đoạn tiêu chuẩn, bao gồm Precision (độ chính xác), Recall (độ bao phủ), F1-score, Intersection over Union (IoU – chỉ số giao trên hợp) và Overall Accuracy (OA – độ chính xác tổng thể).

- Precision (Độ chính xác): đo tỷ lệ các pixel được dự đoán là trạng thái điện mặt trời mà thực sự đúng, trên tổng số pixel được dự đoán dương tính.
- Recall (Độ bao phủ): định lượng tỷ lệ các pixel trạng thái điện mặt trời trong dữ liệu tham chiếu được mô hình phát hiện thành công.
- F1-score: tóm tắt sự cân bằng giữa Precision và Recall thông qua trung bình điều hòa của hai chỉ số này.

- IoU (Intersection over Union): đánh giá mức độ chồng lấp không gian giữa vùng dự đoán và vùng tham chiếu của trang trại điện mặt trời.
- OA (Overall Accuracy): biểu thị tỷ lệ pixel được phân loại đúng trên toàn bộ các lớp (gồm cả lớp trang trại điện mặt trời và lớp nền).

Việc sử dụng đồng thời nhiều chỉ số đánh giá cho phép phân tích toàn diện hiệu năng mô hình từ các góc độ khác nhau: trong khi Precision và Recall phản ánh xu hướng dự đoán quá mức (over-prediction) hoặc dưới mức (under-prediction) của mô hình, IoU và F1-score cung cấp cái nhìn tổng hợp về chất lượng phân đoạn không gian, còn OA phản ánh hiệu năng tổng thể trên toàn bộ ảnh, bao gồm cả vùng nền chiếm phần lớn diện tích.

6. KẾT QUẢ VÀ PHÂN TÍCH

6.1. Hiệu năng phân đoạn của các mô hình

Bảng 6.1 tóm tắt hiệu năng phân đoạn của các mô hình được đánh giá trên tập kiểm tra (held-out test set). Ba kiến trúc được đánh giá sử dụng cùng một cấu hình đầu vào tám kênh (bảy kênh phổ Sentinel-2 và PVSI): U-Net, LinkNet và DeepLabV3+.

Mô hình	Precision (%)	Recall (%)	F1 (%)	IoU (%)	OA (%)
U-Net (8-band + PVSI)	97,00	93,07	93,31	90,60	99,27
LinkNet (8-band + PVSI)	97,77	92,50	93,32	90,74	99,31
DeepLabV3+ (8-band + PVSI)	98,75	88,25	90,93	87,62	98,78

Bảng 6.1. Hiệu năng phân đoạn của các kiến trúc được đánh giá trên tập kiểm tra, sử dụng cấu hình đầu vào đầy đủ tám kênh.

Cả U-Net và LinkNet đều đạt hiệu năng mạnh mẽ ($\text{IoU} > 90\%$, $\text{F1} > 93\%$), khẳng định hiệu quả của cấu hình đầu vào đa phổ được đề xuất. LinkNet mang lại sự cân bằng tổng thể tốt nhất, với IoU cao nhất (90,74%), F1-score cao nhất (93,32%) và OA cao nhất (99,31%), trong khi U-Net đạt được Recall nhỉnh hơn một chút (93,07%). Ngược lại, DeepLabV3+ đạt Precision cao nhất (98,75%) nhưng Recall, IoU và F1-score thấp hơn, cho thấy xu hướng dự đoán thận trọng hơn và bỏ sót nhiều hơn ở các pixel biên và các mảng pin thưa, điều này kém phù hợp hơn cho bài toán ước tính diện tích hàng năm và giám sát biến động.

Nhìn chung, kết quả cho thấy các kiến trúc mã hóa – giải mã gọn nhẹ phù hợp hơn cho bài toán bản đồ hóa trang trại điện mặt trời ở quy mô cấp tỉnh từ ảnh Sentinel-2. Để đánh giá sâu hơn đóng góp của PVSI, một thí nghiệm loại bỏ thành phần đã được tiến hành sử dụng kiến trúc LinkNet (Bảng 6.2).

6.2. Thí nghiệm loại bỏ thành phần PVSI

Cấu hình đầu vào	Precision (%)	Recall (%)	F1 (%)	IoU (%)	OA (%)
LinkNet (7-band, không PVSI)	98,12	91,77	93,19	90,32	99,23
LinkNet (8-band, có PVSI)	97,77	92,50	93,32	90,74	99,31


Bảng 6.2. Thí nghiệm loại bỏ thành phần đánh giá đóng góp của PVSI, sử dụng kiến trúc LinkNet.

Việc bổ sung PVSI giúp cải thiện nhất quán các chỉ số Recall, F1-score, IoU và OA, chỉ với mức giảm nhẹ về Precision. Cụ thể, Recall tăng thêm 0,73 điểm phần trăm và IoU tăng thêm 0,42 điểm phần trăm, cho thấy PVSI giúp giảm các lỗi bỏ sót (omission errors) và cải thiện độ hoàn thiện

trong phát hiện. Mặc dù mức cải thiện ở mức vừa phải, điều này vẫn có ý nghĩa quan trọng đối với giám sát đa năm, nơi mà những cải thiện nhỏ ở cấp độ pixel có thể đóng góp vào việc ước tính diện tích hằng năm và quỹ đạo biến động đáng tin cậy hơn.

6.3. Phân tích trực quan kết quả phân đoạn

Việc kiểm tra trực quan tiếp tục khẳng định rằng U-Net và LinkNet khoanh vẽ một cách đáng tin cậy phạm vi chính của các công trình điện mặt trời lớn và có cấu trúc liên khối, chỉ với một số bất định nhỏ ở phần biên đối với các mảng pin có hình dạng phân tán hoặc bất quy tắc. DeepLabV3+ nhìn chung tạo ra các dự đoán sạch hơn nhưng mang tính bảo thủ hơn về mặt không gian, thường dưới-phân-đoạn (under-segment) các pixel ở vùng ngoại vi. Hình 6.1 trình bày các ví dụ minh họa đại diện.



Hình 6.1. Các ví dụ minh họa kết quả phân đoạn đại diện. Mỗi hàng thể hiện (từ trái sang phải): ảnh gốc Sentinel-2, nhãn tham chiếu, kết quả dự đoán của LinkNet, kết quả dự đoán của U-Net và kết quả dự đoán của DeepLabV3+.

6.4. Tổng hợp kết quả chính

Có thể tổng hợp các phát hiện chính từ các thí nghiệm như sau:

- LinkNet đạt được sự cân bằng tổng thể tốt nhất giữa các chỉ số đánh giá, với $\text{IoU} = 90,74\%$ và $\text{F1-score} = 93,32\%$, và được lựa chọn cho bản đồ hóa và giám sát toàn tỉnh.

- U-Net đạt hiệu năng tương đương LinkNet, với Recall nhỉnh hơn một chút (93,07% so với 92,50%), nhưng có chi phí tính toán cao hơn do số lượng tham số lớn hơn.
- DeepLabV3+ có Precision cao nhất (98,75%) nhưng Recall, IoU và F1-score thấp hơn đáng kể, phản ánh xu hướng dự đoán bảo thủ và bỏ sót các pixel biên.
- Việc bổ sung kênh PVSI mang lại cải thiện nhất quán cho Recall (+0,73 điểm phần trăm) và IoU (+0,42 điểm phần trăm) khi sử dụng kiến trúc LinkNet.

7. THẢO LUẬN

7.1. Giá trị của ảnh Sentinel-2 đối với giám sát điện mặt trời cấp vùng

Các kết quả đạt được khẳng định rằng Sentinel-2 cung cấp một cơ sở thực tiễn cho công tác giám sát trang trại điện mặt trời ở quy mô cấp tỉnh tại BRVT. Mặc dù độ phân giải không gian của Sentinel-2 chỉ ở mức trung bình, các công trình điện mặt trời quy mô từ trung bình đến lớn vẫn có thể được bản đồ hóa một cách nhất quán khi áp dụng kỹ thuật tổ hợp ảnh hằng năm và các đặc trưng phổ phù hợp. Đặc biệt, sự kết hợp giữa các kênh phổ đa phổ Sentinel-2 và chỉ số PVSI đã cải thiện khả năng phân tách bề mặt trang trại điện mặt trời khỏi các loại hình lớp phủ mặt đất xung quanh.

Một ưu điểm khác của Sentinel-2 là chu kỳ chụp lặp lại thường xuyên, hỗ trợ việc tổ hợp ảnh hằng năm với khả năng giảm nhiễu mây trong điều kiện khí hậu nhiệt đới. Với tính sẵn có miễn phí và tính liên tục về mặt vận hành, Sentinel-2 phù hợp cho công tác giám sát dài hạn có thể lặp lại và hiệu quả về chi phí, đặc biệt phù hợp với điều kiện ngân sách của các cơ quan quản lý cấp tỉnh tại Việt Nam.

7.2. So sánh hiệu năng giữa các kiến trúc phân đoạn

Các thí nghiệm so sánh cho thấy U-Net và LinkNet đều rất hiệu quả cho bài toán phân đoạn trang trại điện mặt trời từ ảnh độ phân giải trung bình, với chỉ số IoU vượt trên 90% và F1-score vượt trên 93%. Cấu trúc mã hóa – giải mã với các kết nối tắt của hai kiến trúc này tỏ ra phù hợp với tính quy tắc về mặt không gian của các trang trại điện mặt trời quy mô công nghiệp – vốn thường có hình dạng hình học đều đặn (hình chữ nhật hoặc các dãy song song). LinkNet đạt được sự cân bằng tổng thể tốt nhất, trong khi U-Net thể hiện độ nhạy cao hơn một chút trong việc khôi phục các pixel thuộc trang trại điện mặt trời.

Ngược lại, DeepLabV3+ đạt được Precision cao nhất nhưng Recall và mức độ tương đồng không gian tổng thể thấp hơn. Hành vi dự đoán mang tính bảo thủ này kém phù hợp hơn cho các ứng dụng giám sát, nơi mà các lỗi bỏ sót (omission errors) có thể dẫn đến việc đánh giá thấp diện tích hằng năm và mức độ mở rộng. Có thể lý giải hiện tượng này là do mô-đun ASPP của DeepLabV3+, vốn được tối ưu cho việc nắm bắt ngữ cảnh đa tỷ lệ trong các cảnh phức tạp, có thể không phát huy được lợi thế đầy đủ đối với các đối tượng có hình dạng đồng nhất và kích thước tương đối lớn như trang trại điện mặt trời ở độ phân giải Sentinel-2, trong khi lại làm tăng xu hướng dự đoán thận trọng ở vùng biên.

Thí nghiệm loại bỏ thành phần PVSI tiếp tục khẳng định rằng PVSI đóng góp thông tin phổ hữu ích, đặc biệt thông qua việc cải thiện Recall và độ hoàn thiện phát hiện tổng thể. Mặc dù mức cải thiện về các chỉ số định lượng là vừa phải, kết quả này có ý nghĩa thực tiễn quan trọng đối với các ứng dụng giám sát đa năm, nơi sự tích lũy của những cải thiện nhỏ ở cấp độ pixel theo thời gian có thể tạo ra sự khác biệt đáng kể trong việc ước tính diện tích và xác định xu hướng biến động.

7.3. Hàm ý đối với công tác quản lý và quy hoạch năng lượng tại địa phương

Từ góc độ quản lý nhà nước, kết quả của khung nghiên cứu này có thể được khai thác theo nhiều hướng. Trước hết, các bản đồ dấu vết trang trại điện mặt trời hằng năm cung cấp một nguồn dữ liệu không gian độc lập, có thể được đối chiếu với hồ sơ cấp phép đầu tư và quy hoạch sử dụng đất hiện hành, từ đó hỗ trợ phát hiện các trường hợp xây dựng không đúng quy hoạch hoặc chưa hoàn thiện thủ tục pháp lý. Thứ hai, chuỗi số liệu diện tích hằng năm (Bảng 6.3) có thể được sử dụng như một chỉ số giám sát tiến độ thực hiện các mục tiêu phát triển năng lượng tái tạo trong các quy hoạch phát triển điện lực của tỉnh, cho phép so sánh giữa tốc độ phát triển thực tế và các kịch bản quy hoạch đã đề ra.

Thứ ba, việc xác định các khu vực có xu hướng mở rộng tập trung (như các cụm lõi được mô tả tại Mục 6.4) có thể cung cấp thông tin đầu vào hữu ích cho công tác quy hoạch hạ tầng lưới điện đi kèm, ví dụ như xác định các vị trí cần ưu tiên nâng cấp trạm biến áp hoặc đường dây truyền tải nhằm đáp ứng công suất phát tăng thêm từ các khu vực này. Cuối cùng, do khung nghiên cứu được xây dựng hoàn toàn dựa trên dữ liệu vệ tinh miễn phí và các công cụ mã nguồn mở, chi phí vận hành định kỳ là tương đối thấp, tạo điều kiện thuận lợi để các cơ quan quản lý cấp tỉnh có thể duy trì một quy trình giám sát thường niên mà không phụ thuộc vào các đợt khảo sát thực địa tốn kém.

Tuy nhiên, để các kết quả này có thể được sử dụng trực tiếp trong quy trình ra quyết định hành chính, cần có thêm các bước kiểm chứng thực địa (ground-truthing) định kỳ nhằm đánh giá độ tin cậy của bản đồ trong điều kiện vận hành thực tế, cũng như xây dựng cơ chế phối hợp giữa đơn vị thực hiện phân tích viễn thám và các cơ quan quản lý chuyên ngành về điện lực và tài nguyên – môi trường tại địa phương.

7.4. Hạn chế và hướng phát triển trong tương lai

Một số hạn chế cần được ghi nhận. Thứ nhất, ảnh Sentinel-2 với độ phân giải 10–20 mét phù hợp cho các trang trại điện mặt trời quy mô công nghiệp nhưng không phù hợp cho việc phát hiện đáng tin cậy các công trình điện mặt trời mái nhà hoặc các hệ thống phân tán có quy mô rất nhỏ. Thứ hai, vẫn có khả năng tồn tại sự nhập nhằng phổ trong các khu vực xây dựng phức tạp, mặc dù đã

sử dụng các kênh SWIR và PVSII. Thứ ba, kỹ thuật tổ hợp ảnh hằng năm cải thiện khả năng chống nhiễu mây nhưng có thể tạo ra độ trễ thời gian nhỏ đối với các công trình được xây dựng gần cuối khung thời gian tổ hợp.

Bên cạnh đó, các nhân huấn luyện được chuẩn bị thủ công và do đó vẫn phụ thuộc vào sự giải đoán của chuyên gia. Các nghiên cứu trong tương lai có thể cải thiện độ chi tiết không gian thông qua việc sử dụng ảnh quang học có độ phân giải cao hơn, tăng cường tính ổn định thông qua việc tích hợp dữ liệu radar khẩu độ tổng hợp Sentinel-1 (SAR), và nâng cao hơn nữa khả năng phân tích theo thời gian thông qua các phương pháp học sâu nhận biết không gian – thời gian (spatiotemporal deep learning) hoặc phân đoạn có nhận biết độ bất định (uncertainty-aware segmentation).

Ngoài ra, việc mở rộng khung nghiên cứu sang các tỉnh lân cận có điều kiện địa lý và khí hậu tương tự, hoặc tích hợp với các nguồn dữ liệu hành chính (ví dụ: hồ sơ cấp phép đầu tư dự án năng lượng tái tạo), cũng là những hướng đi tiềm năng nhằm nâng cao giá trị ứng dụng thực tiễn của khung nghiên cứu trong công tác quản lý nhà nước về năng lượng và sử dụng đất.

8. KẾT LUẬN

Báo cáo này đã trình bày một khung nghiên cứu thực tiễn dựa trên học sâu cho bài toán bản đồ hóa hằng năm và giám sát biến động không gian – thời gian trong ngắn hạn đối với các trang trại điện mặt trời tại tỉnh Bà Rịa – Vũng Tàu, Việt Nam, sử dụng ảnh Sentinel-2 đa thời gian. Các ảnh tổ hợp hằng năm đã được giảm nhiễu mây được tạo ra và sử dụng làm đầu vào cho các mô hình phân đoạn ngữ nghĩa được huấn luyện trên dữ liệu tham chiếu được giải đoán thủ công. U-Net và LinkNet được đánh giá sử dụng đầu vào tám kênh, bao gồm các kênh phổ Sentinel-2 được lựa chọn và chỉ số phổ quang điện.

Cả hai mô hình đều đạt hiệu năng phân đoạn mạnh mẽ, với chỉ số IoU vượt trên 90% và F1-score vượt trên 93% trên tập kiểm tra, khẳng định hiệu quả của cấu hình đầu vào và chiến lược mô hình hóa được đề xuất đối với bài toán bản đồ hóa trang trại điện mặt trời ở quy mô cấp tỉnh. Trong số các mô hình được đánh giá, LinkNet mang lại sự cân bằng tổng thể tốt nhất giữa độ chính xác và tính nhất quán không gian, do đó được lựa chọn cho bản đồ hóa hằng năm và phân tích biến động.

Các bản đồ hằng năm cho giai đoạn 2023–2025 cho thấy sự tăng trưởng dần dần của trang trại điện mặt trời tại khu vực nghiên cứu, chủ yếu được thúc đẩy bởi sự mở rộng cục bộ và làm dày đặc các cụm hiện hữu, hơn là sự xuất hiện rộng rãi của các địa điểm quy mô lớn mới. Những kết quả này chứng minh rằng ảnh quang học độ phân giải trung bình, kết hợp với phân đoạn ngữ nghĩa bằng học sâu và tổ hợp ảnh hằng năm, có thể cung cấp một cơ sở đáng tin cậy và có khả năng tái lập cho công tác giám sát hạ tầng năng lượng mặt trời ở quy mô vận hành.

Nhìn chung, khung nghiên cứu được đề xuất có chi phí hợp lý, có khả năng lặp lại và có thể chuyển giao sang các tỉnh khác của Việt Nam hoặc các khu vực nhiệt đới có điều kiện tương tự. Các nghiên cứu trong tương lai sẽ tập trung vào việc mở rộng giai đoạn giám sát, tích hợp dữ liệu SAR và ảnh có độ phân giải cao hơn, cũng như khám phá các phương pháp học sâu nhận biết không gian – thời gian nhằm cải thiện hơn nữa độ tin cậy trong phát hiện và đặc trưng hóa biến động.

TÀI LIỆU THAM KHẢO

- [1] International Renewable Energy Agency: Renewable power generation costs in 2024 (2025). https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2025/Jul/IRENA_TEC_RPGC_in_2024_2025.pdf
- [2] Anh, P., Ngan, N.T.K., Huong, N.T.T.: Vietnam's national energy development strategy to 2030 and outlook to 2045. *International Journal of Economics & Business Administration (IJEBA)* 8(4), 1023–1032 (2020). <https://ideas.repec.org/a/ers/ijebaa/vviii2020i4p1023-1032.html>
- [3] Zhu, X.X., Tuia, D., Mou, L., Xia, G.S., Zhang, L., Xu, F., Fraundorfer, F.: Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine* 5(4), 8–36 (Dec 2017). <http://dx.doi.org/10.1109/MGRS.2017.2762307>
- [4] Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., Gao, J., Zhang, L.: Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sensing of Environment* (2020). <https://api.semanticscholar.org/CorpusID:213463573>
- [5] Ronneberger, O., Fischer, P., Brox, T.: U-net: Convolutional networks for biomedical image segmentation (2015). <https://arxiv.org/abs/1505.04597>
- [6] Kruitwagen, L., Story, K.T., Friedrich, J., Byers, L., Skillman, S., Hepburn, C.: A global inventory of photovoltaic solar energy generating units. *Nature* 598(7882), 604–610 (2021). <https://doi.org/10.1038/s41586-021-03957-7>
- [7] Robinson, C., Ortiz, A., Kim, A., Dodhia, R., Zolli, A., Nagaraju, S.K., Oakleaf, J., Kiesecker, J., Ferres, J.M.L.: Global renewables watch: A temporal dataset of solar and wind energy derived from satellite imagery (2025). <https://arxiv.org/abs/2503.14860>
- [8] Li, A., Liu, L., Li, S., et al.: Global photovoltaic solar panel dataset from 2019 to 2022. *Scientific Data* 12, 637 (2025). <https://doi.org/10.1038/s41597-025-04985-y>
- [9] Viennois, G., Tulet, H., Tresson, P., Ploton, P., Coueron, P., Barbier, N.: Sentinel-2 forest typology mapping in central africa: assessing deep learning and image preprocessing effects. *Frontiers in Remote Sensing Volume 6 - 2025* (2025). <https://www.frontiersin.org/journals/remote-sensing/articles/10.3389/frsen.2025.1682132>
- [10] Truong, V.T., Hirayama, S., Phan, D.C., et al.: Jaxa's new high-resolution land use land cover map for vietnam using a time-feature convolutional neural network. *Scientific Reports* 14, 3926 (2024). <https://doi.org/10.1038/s41598-024-54308-1>
- [11] Cullerton, M., Zhu, Z., Qiu, S., Rittenhouse, C.D., Suh, J.W.: Back in time: A novel time series and deep learning framework for mapping solar installations. *Science of Remote Sensing* 12, 100322 (2025). <https://www.sciencedirect.com/science/article/pii/S2666017225001282>
- [12] Deep learning and remote sensing for agricultural land use monitoring: A spatio-multitemporal analysis of rice field conversion using optical satellite images. *International Journal of Advances in Data and Information Systems* 6(2), 290–307 (Jun 2025). <https://ijadis.org/index.php/ijadis/article/view/1385>
- [13] Hang, P.T.: Evaluating the performance of sentinel 2a and planetscope satellite imaging systems in forest cover classification at ta dung national park, dak nong, vietnam. *Vietnam Journal of Forest Science* (2) (Jun 2024). <https://vjfs.vafs.gov.vn/js/article/view/888>

- [14] Ngan, C.T.: Smart monitoring of water quality in ha long bay using remote sensing and artificial intelligence. VAST (2025), accessed 2026
- [15] Van, T.: Application of remote sensing GIS to estimate the changes of surface temperature in ninh thuan. VNUHCM Journal of Environment and Earth Sciences (2024)
- [16] TransitionZero: Mapping vietnam's rooftop solar landscape with machine learning and sentinel-2. Technical report (2025), accessed 2026
- [17] European Space Agency: Copernicus Sentinel-2 (processed by ESA), MSI Level-2A BOA Reflectance Product, Collection 1. European Space Agency. https://doi.org/10.5270/S2_-znk9xsj, accessed: 2026-04-09
- [18] Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R.: Google earth engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* 202, 18–27 (2017). <https://www.sciencedirect.com/science/article/pii/S0034425717302900>
- [19] Shimada, S., Takeuchi, W.: A new spectral index to characterize solar photovoltaic panels for sentinel-2 data. In: *Proceedings of the Asian Conference on Remote Sensing (ACRS 2022)*. Mongolia (2022)