

Bài báo khoa học

Ứng dụng mô hình học máy trên dữ liệu vệ tinh địa tĩnh cho bài toán nhận dạng và cảnh báo sớm bão nhiệt đới trên khu vực Tây Bắc Thái Bình Dương và Biển Đông

Chu Thị Huyền Trang¹, Lê Quang Đạo², Trần Huy Hoàng^{2,3}, Lưu Việt Hưng², Bùi Quang Hưng², Mai Khánh Hưng¹, Nguyễn Thu Hằng¹, Đỗ Thuỳ Trang¹ và Dư Đức Tiến^{1*}, Đặng Đình Quân¹, Hoàng Gia Nam¹

¹ Trung tâm Dự báo khí tượng thủy văn quốc gia, Tổng cục Khí tượng Thủy văn; chutrang.2406@gmail.com; maikhanhhung18988@gmail.com; nthang0676@gmail.com; dotrang111@gmail.com; duductien@gmail.com; quandangdinh.92@gmail.com; namhoangkt95@gmail.com

² Trung tâm Công nghệ tích hợp liên ngành Giám sát hiện trường (FIMO), Trường Đại học Công nghệ, Đại học Quốc gia Hà Nội; daolq@fimo.edu.vn; huyhoang.tran6669@gmail.com; hunglv@piv.asia; hungbq@fimo.edu.vn

³ Trung tâm Không gian mạng Viettel (VTCC), Tập Đoàn Công Nghiệp - Viễn Thông Quân Đội (Viettel); huyhoang.tran6669@gmail.com

*Tác giả liên hệ: duductien@gmail.com; Tel.: +84-936067015

Ban Biên tập nhận bài: 8/3/2024; Ngày phản biện xong: 12/4/2024; Ngày đăng bài: 25/8/2024

Tóm tắt: Bài báo trình bày ứng dụng phương pháp học sâu để xác định vị trí và phân loại xoáy thuận nhiệt đới (XTNĐ) một cách tự động. Phương pháp học sâu trong bài báo là ứng dụng mạng nơ-ron tích chập hai luồng (CNN) cùng các đặc điểm theo không gian và thời gian của dữ liệu vệ tinh địa tĩnh. Bộ dữ liệu vệ tinh địa tĩnh Himawari-8/9 cho các XTNĐ trên Tây Bắc Thái Bình Dương và Biển Đông từ năm 2015 đến năm 2019 đã được thu thập và sử dụng trong nghiên cứu. Đầu vào bổ sung cho phương pháp học sâu là vectơ chuyển động khí quyển (AMV) được tính toán từ dữ liệu vệ tinh liên tiếp theo thời gian. Kết quả cho thấy khả năng ứng dụng cao của phương pháp học máy trong bài toán nhận dạng XTNĐ. Ngoài ra, một thử nghiệm cụ thể cho cơn bão Doksuri vào năm 2017 cho thấy khả năng cảnh báo sớm trước so với phát báo của Cơ quan khí tượng Nhật Bản (JMA).

Từ khóa: Nhận dạng bão; Mạng nơ-ron tích chập hai luồng.

1. Mở đầu

Xoáy thuận nhiệt đới (XTNĐ) có đặc trưng chính là vùng gió xoáy với đường kính có thể tới hàng trăm km, gió thổi xoáy vào trung tâm theo hướng ngược chiều kim đồng hồ (khu vực Bắc Bán Cầu), áp suất khí quyển (khí áp) trong XTNĐ thấp hơn xung quanh, hình thành trên các vùng biển nhiệt đới và khi quan sát trên dữ liệu vệ tinh (Himawari) thường là một dạng cấu trúc xoắn từ các hệ thống mây đối lưu phát triển. Theo Tổ chức khí tượng thế giới (World Meteorological Organization-WMO), XTNĐ thuộc vào nhóm loại hình thiên tai đứng đầu gồm bão, lũ lụt, hạn hán, cháy rừng, lở đất và động đất, sóng thần gây thiệt hại lớn về người và của trên thế giới. Để giảm thiểu tác hại của XTNĐ, trong nghiệp vụ dự báo XTNĐ, một trong những yêu cầu chính đặt ra là giám sát được XTNĐ trong điều kiện thực tế, gồm vị trí tâm của XTNĐ, cường độ của XTNĐ, vùng ảnh hưởng (xác định theo các cấp gió mạnh, ví dụ bán kính vùng gió mạnh > 10,8 m/s ứng với cấp 6 trong thang sức gió Beaufort, hoặc theo vùng mưa lớn do hoàn lưu XTNĐ). Thông tin này cho phép triển khai công tác cảnh báo

những tác động do XTNĐ gây ra như gió mạnh gây đổ cây, tóc mái nhà..., mưa lớn gây lũ lụt, ngập úng, gián đoạn giao thông ... và qua đó xây dựng các kịch bản ứng phó để đảm bảo an toàn về tính mạng của con người, giảm thiểu thiệt hại vật chất và ổn định hoạt động sản xuất kinh tế (trên đất liền và trên biển) cho vùng chịu ảnh hưởng bởi XTNĐ.

Để xác định vị trí, cường độ bão thời gian thực, phương pháp chủ yếu được sử dụng là phương pháp Dvorak (DT) và những năm gần đây, cùng với sự phát triển của thể hệ cảm biến trên các vệ tinh khí tượng thế hệ mới và khả năng tính toán của máy tính, kết hợp với sự tích lũy lâu năm kinh nghiệm của dự báo viên và những thành tựu mới của công nghệ tự động hóa, việc tự động phân tích và ước lượng cường độ bão nhiệt đới bằng các hệ thống máy tính đã trở nên khả thi hơn rất nhiều, tạo tiền đề để phương pháp Dvorak cải tiến (*Advanced Objective Dvorak Technique - ADT*) ra đời. Mặc dù vậy, các phương pháp DT, ADT vẫn còn nhiều sai số và mang tính chủ quan khá nhiều, chi tiết đánh giá trên khu vực Biển Đông được trích dẫn trong tài liệu [1, 2].

Việc ứng dụng trí tuệ nhân tạo (*Artificial Intelligence- AI*) trong bài toán giám sát vị trí, cường độ XTNĐ từ quan trắc vệ tinh, radar được xem là những thế mạnh thực sự của công nghệ AI thông qua ứng dụng công nghệ nhận dạng với các mẫu tìm kiếm là các mẫu dạng mây bão khác nhau [3]. Ngoài dữ liệu vệ tinh thuần túy, các dữ liệu gián tiếp từ vệ tinh gồm thông tin trường gió khí quyển AMV (*Atmospheric Motion Vector -* xác định từ dữ liệu vệ tinh đo đặc liên tục theo thời gian), thông tin trạng thái biển từ các dữ liệu vệ tinh cực cũng đóng góp trong việc cải thiện chất lượng giám sát XTNĐ bằng AI [4–6]. Một số công trình liên quan đến xác định cường độ XTNĐ như sử dụng kiến trúc mạng nơ-ron tích chập (*Convolution Neural Network - CNN*) và dữ liệu ảnh vệ tinh kênh phổ hồng ngoại (IR) để xác định cường độ của XTNĐ [7]. Kết quả của nghiên cứu cho sai số trung bình quân phương (RMSE) xấp xỉ ~ 5 m/s. Phương pháp phân loại hình ảnh dựa trên mô hình Visual Geometry Group (VGG) với biến thể 19 lớp để ước tính cường độ XTNĐ từ dữ liệu vệ tinh đa phổ giai đoạn từ năm 1996 đến năm 2016 trên khu vực Tây Bắc Thái Bình Dương [8] cho các kết quả cho sai số RMSE $\sim 6,5$ m/s. Sử dụng dữ liệu kênh phổ vi sóng (microwave, các kênh vi sóng 37, 85-92 Ghz) của vệ tinh quỹ đạo cực để ước tính cường độ XTNĐ thông qua kiến trúc CNN sử dụng 2 toán tử tích chập (2D-CNN) [9]. Các kết quả đạt được với sai số RMSE ~ 7.2 m/s. Các sai số của các công trình này đều khá tương đương với sai số của phương pháp thống kê và mô hình số (NWP).

Trong vấn đề dự báo sự hình thành XTNĐ sử dụng dữ liệu vệ tinh, các công trình chủ yếu sử dụng các phương pháp phân cụm dữ liệu. Điển hình gồm nghiên cứu sử dụng phương pháp cây quyết định (Decision Tree-DT) để khảo sát các nguyên nhân hình thành XTNĐ [10], Sử dụng thuật toán tổng hợp phân loại AdaBoost trong việc dự đoán sự phát triển của hệ thống đối lưu có tổ chức (*Mesoscale Convective System-MCS*) trên biển và đánh giá khả năng MCS sẽ phát triển thành XTNĐ [11].

Hoạt động của XTNĐ có tính chất lặp đi lặp lại, ví dụ xu thế đi lên phía Bắc vào đầu mùa bão ở Tây Bắc Thái Bình Dương. Do đó các thông tin về những XTNĐ có có đặc điểm tương tự trong quá khứ (quỹ đạo và cường độ) cho phép bổ sung các thông tin trong những bản tin dự báo, đặc biệt là các hệ quả mà các XTNĐ tương tự đã gây ra [12–14]. Đây là tiền đề của việc ứng dụng trí tuệ nhân tạo AI trong bài toán tìm kiếm XTNĐ có đặc điểm tương tự trong quá khứ.

AI trong dự báo XTNĐ có thể chia làm 5 khía cạnh: Dự báo sự hình thành, dự báo quỹ đạo, dự báo cường độ, dự báo thời tiết XTNĐ và tác động cực đoan của nó, giúp cải thiện kết quả dự báo từ mô hình số. Mỗi một khía cạnh sử dụng những thuật toán khác nhau sao cho phù hợp nhất. Cụ thể:

Đối với dự báo sự hình thành, mục tiêu cuối cùng của AI là tạo ra các dự báo xác suất về một khu vực cố định trong thời gian thực và dự báo định lượng về thời gian và địa điểm hình thành XTNĐ. Ở giai đoạn này, AI có khả năng dự đoán liệu các tiền thân có phát triển thành XTNĐ hay không và tần suất theo mùa của sự hình thành XTNĐ trong mỗi khu vực.

Các thuật toán điển hình được sử dụng như cây quyết định (DT), hồi quy logistic (LR), Máy vectơ hỗ trợ (SVM), CNN, Hệ thống tiếp cận lai (Hybrid) [15].

Đối với dự báo quỹ đạo XTNĐ, các mô hình AI thường bắt nguồn từ phương pháp thống kê, tức là sử dụng các đặc điểm của chính XTNĐ, các biến khí tượng và đại dương liên quan để dự đoán vị trí của XTNĐ và đây được coi là ánh xạ phi tuyến. Các thuật toán được sử dụng như DT, CNN, Mạng nơ-ron hồi quy RNN, ConvLSTM (*Convolutional Long-Short Term Memory*), phân cụm Clustering, mạng nơ-ron truyền thẳng nhiều lớp MLP (*Multilayer perceptron*) [16].

Đối với dự báo cường độ, do thiếu các thám sát tại chỗ nên dữ liệu vệ tinh là nguồn dữ liệu rất quan trọng. Phương pháp điển hình để dự báo trực tiếp cường độ là lấy toàn bộ đường đi của XTNĐ làm thành một chuỗi và sử dụng MLP hoặc RNN để dự đoán cường độ ở các thời điểm tiếp theo dựa trên cường độ của thời điểm hiện tại. Các thuật toán học máy có thể kể tới như: DT, SVM, rừng ngẫu nhiên (RF), MLP, CNN, RNN, Hybrid, thuật toán phân cụm (K-means), Transfer learning (Học chuyển giao) [17].

Trong phần tiếp theo của bài báo sẽ trình bày chi tiết về dữ liệu sử dụng và phương pháp học máy ứng dụng từ bài toán nhận dạng vật thể đến chuyển đổi sang bài toán phân loại và xác định vị trí XTNĐ một cách tự động. Phần 3 trình bày một số kết quả đánh giá kết quả thử nghiệm cho các XTNĐ trên Tây Bắc Thái Bình Dương và Biển Đông từ năm 2015 đến năm 2019. Một số kết luận chính được đưa ra trong phần 4 của bài báo.

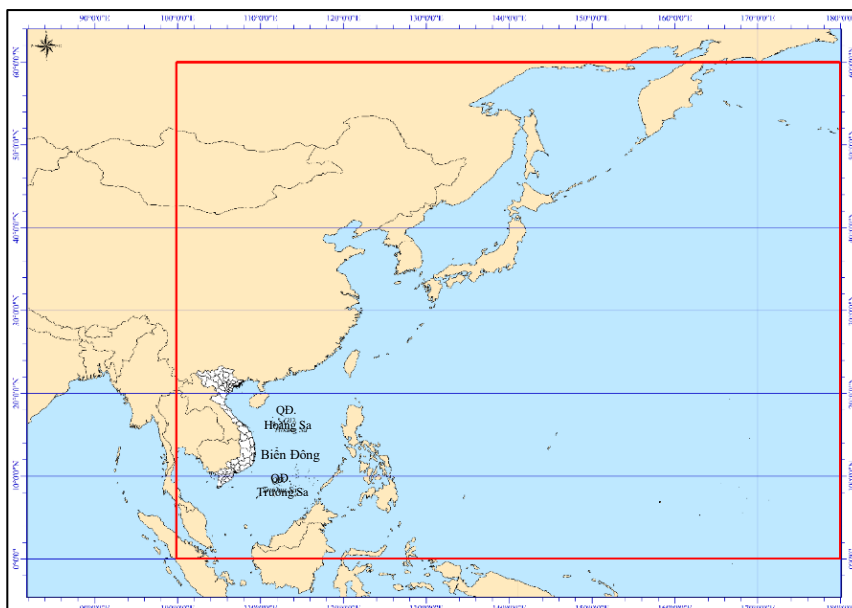
2. Dữ liệu và phương pháp nghiên cứu

2.1. Dữ liệu nghiên cứu

AI phụ thuộc vào dữ liệu và quá trình xây dựng và triển khai hệ thống AI đòi hỏi bộ dữ liệu lớn và đa dạng. Trong nghiên cứu, dữ liệu AI gồm dữ liệu vệ tinh địa tĩnh chứa các thông tin bức xạ khí quyển thể hiện hình thái bão và dữ liệu quỹ đạo bão chuẩn (best-track) dùng để thiết lập định danh thông tin trên dữ liệu học, bao gồm vị trí XTNĐ ở đâu trên dữ liệu vệ tinh và được phân loại ở cấp độ nào.

2.1.1. Dữ liệu quỹ đạo bão chuẩn (Best-track)

Best-track của RSMC Tokyo (JMA-Nhật Bản) được dùng cho việc huấn luyện mô hình AI. Best-track được lấy từ trang web chính thức của JMA, thời đoạn từ năm 2015 tới 2019, định dạng file text. Phạm vi thu thập dữ liệu XTNĐ của best-track, JMA nằm trong miền xác định 0° - 60° N, 100° E- 180° E (Hình 1).



Hình 1. Mô phỏng miền thống kê của best track.

Best-track bao gồm thông tin về vị trí và cường độ của XTNĐ từ khi hình thành tới khi ra ngoài phạm vi quan trắc. Bảng 1 đưa ra thống kê số lượng cấp độ XTNĐ được xác định trên best-track gồm áp thấp nhiệt đới (TD), thành bão (TS), bão mạnh (STS), siêu bão (TY), tan rã hoặc di chuyển ra khu vực ngoại nhiệt đới (L).

Bảng 1. Thống kê số mẫu thử được sử dụng cho học máy giai đoạn 2015-2019.

Năm/Phân loại XTNĐ	TD	TS	STS	TY	L
2015	209	272	140	447	149
2016	216	174	110	216	85
2017	256	216	142	169	84
2018	321	260	124	311	108
2019	315	226	137	249	119

2.1.2. Dữ liệu vệ tinh Himawari

Himawari-8/9 là vệ tinh địa tĩnh do cơ quan khí tượng Nhật Bản vận hành và được phóng và đưa vào vận hành vào lúc 2:00 UTC ngày 7 tháng 7 năm 2015. Trên Himawari-8/9 chứa AHI (*Advanced Himawari Imager*) là cảm biến đo đặc 16 kênh phổ (3 kênh thị phổ, 3 kênh cận hồng ngoại và 10 kênh hồng ngoại) với độ phân giải không gian từ 500 m đến 2 km. Cụ thể, độ phân giải không gian của Himawari-8/9 là 0,5-1km đối với dải thị phổ và 1-2km đối với dải hồng ngoại và cận hồng ngoại.

2.1.3. Dữ liệu trích xuất vector chuyển động khí quyển

AMV là dữ liệu quan trắc về vector chuyển động của khí quyển được thu thập từ các hình ảnh vệ tinh. AMV đo lường sự di chuyển của đám mây và các thành phần khác của khí quyển, thông qua việc theo dõi sự thay đổi vị trí của các đối tượng khí tượng trên các hình ảnh vệ tinh liên tục. Như vậy, AMV có thể cung cấp thông tin về hướng và tốc độ gió ở các tầng khác nhau của khí quyển, giúp cho việc nhận dạng dễ dàng hơn. Bên cạnh đó, AMV rất hữu ích khi theo dõi XTNĐ vì trên đại dương các quan trắc có rất thưa thớt. AMV cũng thể hiện tính “thời gian-temporal” trong dữ liệu đầu vào cho mô hình AI. Trên thực tế, trong quá trình phân tích ảnh mây vệ tinh, các dự báo viên cũng sử dụng kỹ thuật looping để theo dõi hoàn lưu xoắn của XTNĐ. Trong nghiên cứu ứng dụng phương pháp tương quan cực đại (maximum correclation) giữa ô lưới mục tiêu (target) trong một miền tìm kiếm giới hạn (search domain). Nghiên cứu này sử dụng lưới dữ liệu target có độ phân giải 7x7 pixels cho các kênh ảnh độ phân giải 500m và 28x28 pixels cho các kênh ảnh có độ phân giải 2km. Mỗi một trích xuất AMV tại thời điểm t sẽ được tạo ra bằng cách so sánh sự dịch chuyển của khí quyển tại thời điểm t-10phút, t, t+10phút. Ví dụ, để có AMV lúc 15h00, phương pháp sẽ so sánh sự tương quan giữa ảnh vệ tinh lúc 15h00 với ảnh vệ tinh lúc 14h50 và 15h10. Với mỗi ô lưới, thuật toán sẽ tính toán, so sánh sự tương đồng giữa ảnh vệ tinh tại thời điểm t với t-10phút và t+10phút. Vị trí có hệ số tương đồng cao nhất thể hiện sự tương ứng của từng ô lưới trong từng ảnh. Từ đó sẽ tính được sự dịch chuyển bằng thuật toán tương quan mẫu với hàm mục tiêu là sự tương đồng lớn nhất. Chi tiết tham khảo tại tài liệu kỹ thuật của JMA theo đường dẫn <https://www.data.jma.go.jp/mscweb/technotes/msctechrep62-4.pdf> do Shimoji Kazuki thiết lập năm 2017.

2.1.4. Dữ liệu được gán nhãn

Gán nhãn hình ảnh là quá trình gán nhãn cho các đối tượng trong ảnh, giúp cho các thuật toán của mô hình có thể nhận diện được các đối tượng đó. Một bộ dữ liệu có 2 phần chính: hình ảnh và chú thích của chúng.

- Các ảnh Himawari-8/9 được sắp xếp thành một hệ thống phân cấp các thư mục, với thư mục cấp cao nhất chứa các thư mục con cho các tập huấn luyện, đánh giá và kiểm tra.

- Mỗi chú thích trong tập dữ liệu bao gồm các thông tin sau: Tên tệp hình ảnh; miền xác định vị trí XTNĐ theo Quỹ đạo bão chuẩn (bao gồm toạ độ lat, lon của tâm bão, chiều rộng và chiều cao của miền), phân loại XTNĐ (Áp thấp nhiệt đới, Bão, Bão mạnh, Siêu bão, Bão ngoại nhiệt đới).

Tập dữ liệu sử dụng định dạng csv cung cấp thông tin về tất cả hình ảnh, minh họa dưới đây là cấu trúc của tập dữ liệu:

```
[
  {
    "image_file": "IR2020091500.jpg",
    "x1": 14.8,
    "y1": 119.8,
    "x2": 10.8,
    "y2": 123.8,
    "class_name": "Tropical Depression"
  },
  {
    "image_file": "IR2020091506.jpg",
    "x1": 14.6,
    "y1": 118.4,
    "x2": 10.6,
    "y2": 122.4,
    "class_name": "Tropical Depression"
  },
  {
    "image_file": "IR2020091512.jpg",
    "x1": 14.7,
    "y1": 117.1,
    "x2": 10.7,
    "y2": 121.1,
    "class_name": "Tropical Depression"
  },
]
```

Hình 2. Mô phỏng file dữ liệu csv, ví dụ với tên file dữ liệu (image_file) ứng với kênh phổ hồng ngoại là IR2020091500.jpg, vùng XTNĐ được xác định qua các toạ độ x_1, y_1, x_2, y_2 và phân loại với thông tin trường class_name.

2.2. Phương pháp AI cho bài toán nhận dạng và xác định vị trí XTNĐ tự động

AI có thể hiểu đơn giản là các chương trình máy tính (thể hiện cụ thể của các kiến trúc *Machine Learning/Deep Learning*) và nhiệm vụ cốt lõi là xây dựng các mô hình toán học sử dụng số liệu với mẫu đủ lớn để đưa ra suy luận từ tập mẫu (đối tượng cần hướng tới có được kết quả phân tích và dự báo) [18].

2.2.1. Phương pháp nhận dạng đối tượng bằng mô hình AI

Thuật ngữ “Nhận dạng đối tượng” là sử dụng thị giác máy tính để xác định các đối tượng trong ảnh. Có 3 nhiệm vụ thị giác máy tính cơ bản giúp nhận dạng đối tượng:

- Phân loại hình ảnh: Dự đoán nhãn của một đối tượng trong ảnh.
- Định vị đối tượng: Xác định vị trí của các đối tượng trong ảnh dưới dạng miền định vị đối tượng (các ô chữ nhật được vẽ bao quanh đối tượng - bounding box)
- Phát hiện đối tượng: Xác định vị trí của đối tượng trong miền định vị và nhãn của đối tượng đó.

Hiện nay trên thế giới nhận dạng đối tượng bằng thị giác máy tính được ứng dụng rất nhiều, ví dụ như nhận dạng biển số xe, nhận dạng khuôn mặt, xe tự lái, ... Một số hệ thống ứng dụng AI điển hình vào nhận dạng đối tượng gồm:

- Hệ thống YOLO (*You Only Look Once*) là một mô hình nhận dạng đối tượng thời gian thực cho phép nhận dạng nhiều đối tượng trong một hình ảnh một cách nhanh chóng và chính xác [19]. Bộ dữ liệu (Dataset) được sử dụng cho việc huấn luyện mô hình là COCO (*Common Objects in Context*), một bộ dữ liệu lớn chứa hơn 1,5 triệu hình ảnh với hơn 80 loại đối tượng khác nhau.

- Faster R-CNN (*Region-based Convolutional Neural Networks*) là một kiến trúc mạng học sâu được sử dụng phổ biến trong nhận dạng đối tượng [20]. Dataset phổ biến là Pascal VOC (*Visual Object Classes*), bộ dữ liệu gồm nhiều hình ảnh chứa các đối tượng khác nhau

được gán nhãn. Faster R-CNN có thể được sử dụng để đếm và theo dõi hành khách trong sân bay.

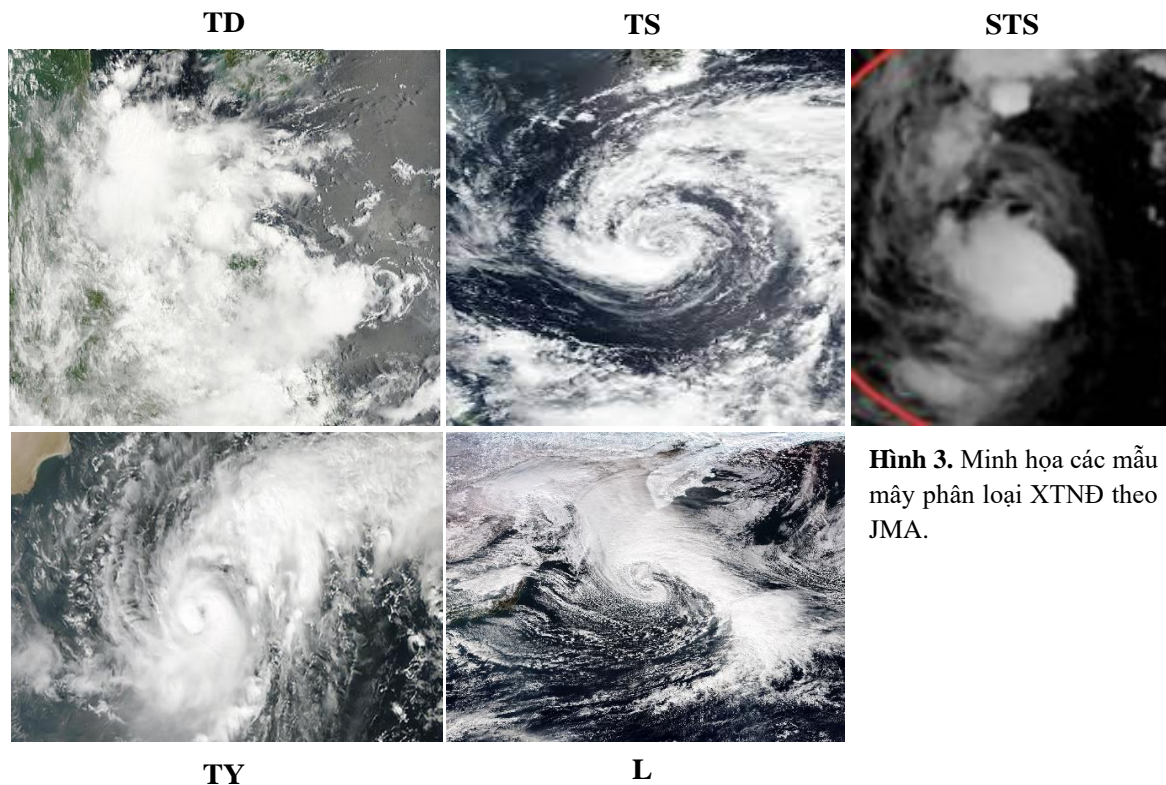
- SSD (*Single Shot MultiBox Detector*) là một mô hình nhận dạng đối tượng thời gian thực có khả năng nhận dạng nhanh chóng và hiệu quả [21]. Dataset phổ biến được dùng để huấn luyện mạng là MS COCO (*Microsoft Common Objects in Context*) gồm hàng ngàn hình ảnh được gán nhãn các đối tượng khác nhau.

- RetinaNet là mô hình nhận dạng đối tượng được phát triển bởi nhóm nghiên cứu tại Facebook AI Research (FAIR). Đặc điểm nổi bật của RetinaNet là khả năng nhận dạng đối tượng với độ chính xác cao ở nhiều tỷ lệ khác nhau, ngay cả khi tập dataset chứa dữ liệu bị mất cân bằng giữa các lớp (các đối tượng này có thể xuất hiện nhiều hơn đối tượng khác). RetinaNet đã được chứng minh là có hiệu suất cao trong nhận dạng đối tượng trên nhiều bộ dữ liệu khác nhau như COCO và Pascal VOC. RetinaNet được sử dụng trong giám sát an ninh, xe tự lái, nhận dạng đối tượng trong hình ảnh y khoa, ... [22].

Nghiên cứu sẽ ứng dụng lớp bài toán nhận dạng nhưng đối tượng là XTNĐ, những vật thể phân loại khác nhau ứng với cấp độ XTNĐ và vị trí XTNĐ trên dữ liệu ảnh-vệ tinh ứng với vị trí “vật thể” XTNĐ được xác định trên dữ liệu ảnh-vệ tinh. Chi tiết sẽ được trình bày trong phần tiếp theo.

2.2.2. Ứng dụng cho bài toán nhận dạng XTNĐ

Theo trung tâm JMA-RMSC Typhoon Center thì XTNĐ sẽ chia thành 6 dạng trong đó có 5 dạng chính, minh họa tại hình 3.



Hình 3. Minh họa các mẫu mây phân loại XTNĐ theo JMA.

Mô hình AI được xây dựng nhằm nhận dạng XTNĐ trên ảnh vệ tinh địa tĩnh, cụ thể:

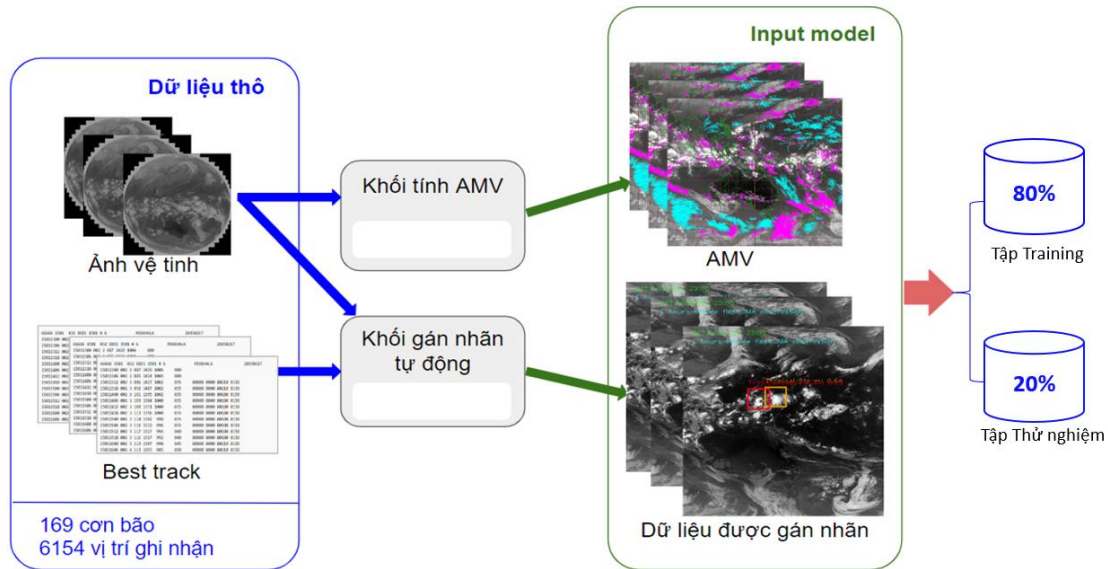
- Phân loại đối tượng: Dự đoán nhãn của XTNĐ trong ảnh, phân loại XTNĐ là Áp thấp nhiệt đới, Bão, Bão mạnh, Siêu bão hay Bão ngoại nhiệt đới. Đây cũng chính là nhận dạng cường độ XTNĐ.

- Định vị đối tượng: Vẽ các miền định vị xung quanh đối tượng, với tâm miền chính là tâm XTNĐ.

- Phát hiện đối tượng: Vẽ các miền định vị đối tượng kèm theo nhãn của chúng.

2.2.3. Thiết lập tập dữ liệu dataset cho bài toán nhận dạng XTNĐ từ dữ liệu Himawari

Mô hình AI nhận dạng XTNĐ là một mạng không gian - thời gian. Ảnh Himawari-8/9 ở dạng riêng lẻ sẽ cung cấp thông tin về vị trí XTNĐ, đặc điểm về mẫu mây - tính chất về không gian. Về phần thời gian, ảnh Himawari dưới dạng liên tục 10 phút một thể hiện các chuyển động của khí quyển chính là trích xuất AMV. Từ dữ liệu thô là ảnh Himawari-8/9 và số liệu best-track, tạo ra cơ sở dữ liệu bao gồm ảnh AMV và Ảnh được gắn nhãn làm đầu vào cho việc huấn luyện mô hình AI.



Hình 4. Sơ đồ thiết lập dữ liệu cho bài toán ứng dụng học sâu nhận dạng XTNĐ.


2.2.4. Mô hình AI ResNet ứng dụng cho bài toán nhận dạng XTNĐ

ResNet, hay Residual Networks là một loại kiến trúc mạng nơ-ron sâu (*deep neural network*) với vai trò học tập phân loại hình ảnh. Mục tiêu chính của giai đoạn này là gắn nhãn lớp cho hình ảnh XTNĐ theo từng cấp độ. Kết quả học tập của Resnet là tạo ra bộ tham số chứa các tính năng đặc trưng cho việc nhận dạng XTNĐ, làm đầu vào cho mô hình Retinanet nhận dạng ở bước tiếp theo. Điểm mạnh của ResNet là có thể giải quyết vấn đề độ sâu trong mạng nơ-ron, cụ thể là vấn đề về biến mất đạo hàm (*vanishing gradient*) trong quá trình đào tạo các mô hình học sâu.

Về cấu trúc, ResNet thể hiện cấu trúc của mạng CNN (Hình 5). Mạng CNN là một kiến trúc học sâu được áp dụng rộng rãi như một mô hình rất hiệu quả trong việc phân tích hình ảnh hoặc dữ liệu giống hình ảnh để nhận dạng mẫu. CNN được cấu trúc theo các lớp: một lớp đầu vào kết nối với dữ liệu, một lớp đầu ra kết nối với các đại lượng để ước tính và nhiều lớp ẩn ở giữa. Các lớp ẩn của CNN thường bao gồm các lớp tích chập (*convolutional layers*), các lớp tổng hợp (*pooling layers*), các lớp được kết nối đầy đủ (*fully connected layers*) và các lớp chuẩn hóa (*normalization layers*). Các lớp phức hợp trích xuất các đặc trưng của hình ảnh. Các lớp tổng hợp lọc giá trị tối đa của các đặc trưng này để giảm số lượng các đặc trưng. Các lớp được kết nối đầy đủ thường nằm ở cuối của mạng CNN, sẽ đóng vai trò kết nối mọi nơ-ron trong một lớp với mọi nơ-ron trong lớp khác. Một mạng CNN có thể bao gồm nhiều lớp tích chập và nhiều lớp tổng hợp. Ưu điểm của CNN là có thể học cách nhận dạng các mẫu không gian bằng cách khai thác tất cả các phần của hình ảnh được xử lý theo cách tương tự, và do đó có thể trích xuất các tính năng tự động trong khi giảm đáng kể số lượng tham số.

Một trong những thách thức lớn khi đào tạo mạng nơ-ron sâu là việc truyền ngược đạo hàm qua nhiều lớp. Khi bắt đầu huấn luyện, các trọng số của một mô hình học sâu được khởi tạo ngẫu nhiên. Sử dụng dữ liệu đầu vào, mô hình sẽ dự đoán nhãn đầu ra dựa trên các trọng số ban đầu. Sự khác biệt giữa nhãn thực và nhãn dự đoán được đo bằng một hàm mất mát (*loss function*). Sau đó, các gradient (đạo hàm) của các hàm mất mát được sử dụng trong quá

trình tính toán các thông số mô hình mới để giảm thiểu tối đa sự chênh lệch giữa nhãn thực và nhãn được dự đoán. Toàn bộ quá trình này được gọi là lan truyền ngược (Back Propagation). Sau khi lan truyền ngược, trình tối ưu hóa (optimizer) sẽ cập nhật các trọng số mô hình và tất cả các bước này được lặp lại cho đến khi hàm mất mát được đánh giá trên dữ liệu thử nghiệm hoặc huấn luyện giảm xuống mức chấp nhận được (mô hình lúc này được xem là hội tụ).



Hình 5. Kiến trúc mạng RetinaNet.


Trong quá trình này, gradient có thể giảm đáng kể khi đi qua nhiều lớp, dẫn đến hiện tượng biến mất đạo hàm. Điều này làm giảm khả năng học của mô hình và làm tăng khó khăn trong việc đào tạo các mạng nơ-ron sâu. Khi mạng học càng sâu (càng nhiều lớp), giá trị gradient giảm xuống 0, khiến các trọng số không cập nhật và kết quả là không có quá trình học nào được thực hiện.

ResNet giải quyết vấn đề này bằng cách sử dụng các “khối phần dư” (*residual blocks*) để xây dựng kiến trúc của mạng. Thay vì chỉ học biểu diễn của dữ liệu đầu vào, ResNet học sự chênh lệch giữa dữ liệu đầu vào và đầu ra (đoạn dư). Mục đích của mạng Resnet là cho phép tạo ra mạng nơ-ron với độ sâu lớn.

Cụ thể, một đoạn dư trong ResNet được biểu diễn như sau:

$$\text{Output} = \text{ReLU}(\text{Weight} \times \text{input} + \text{Shortcut})$$

Trong đó input là đầu vào của đoạn dư; Weight là trọng số của lớp convolution; Shortcut là đường ngắn (shortcut connection), thường được thêm vào để làm cho kích thước của đầu ra bằng với đầu vào.




Hình 6. Minh họa tính hiệu quả của việc sử dụng mạng Resnet trong nhận dạng ảnh so với các kiến trúc mạng khác (GoogleNet, VGG,...) trong đó chỉ số trên các biểu đồ cột ứng với xác suất lỗi xảy ra khi nhận dạng (link gốc ảnh minh họa: https://www.researchgate.net/publication/321896881_Iris_Recognition_with_Off-the-Shelf_CNN_Features_A_Deep_Learning_Perspective).

Nhờ vào cơ chế khối phần dư, mô hình ResNet có khả năng học các biểu diễn phức tạp mà không gặp vấn đề vanishing gradient. ResNet đã chứng minh sự hiệu quả của mình trong nhiều nhiệm vụ thị giác máy tính, như nhận diện hình ảnh và phân loại (Hình 6).

Mạng học sâu được sử dụng cho bài toán nhận dạng XTNĐ ứng dụng cụ thể trong nghiên cứu là Retinanet (Hình 5), về bản chất RetinaNet là một mạng tổng hợp bao gồm:

- Một mạng xương sống có tên là Mạng kim tự tháp đặc trưng (*Feature Pyramid Net*), được xây dựng dựa trên mạng ResNet và chịu trách nhiệm tính toán các bản đồ đặc trưng tích chập của toàn bộ hình ảnh.
- Một mạng con chịu trách nhiệm phân loại đối tượng (class subnet), cụ thể ở đây là nhận dạng cường độ XTNĐ.
- Một mạng con chịu trách nhiệm thực hiện hồi quy tìm ra miền định vị đối tượng thể hiện vị trí của XTNĐ (*box subnet*).


Minh họa tổng thể thiết kế mạng Resnet cho bài toán nhận dạng XTNĐ cụ thể như sau (Hình 7): Chuỗi thời gian của ảnh vệ tinh có thể được phân tách thành các thành phần không gian và thời gian. Đối với phần không gian, ở dạng hình ảnh riêng lẻ sẽ mang thông tin về XTNĐ được mô tả trong hình ảnh. Đối với phần thời gian, ở dạng chuyển động của khí quyển qua các hình ảnh liên tục (thể hiện bởi trích xuất AMV), sẽ thể hiện cường độ và hướng gió. Về cơ bản, phần thứ nhất là sử dụng mạng Resnet học đồng thời các đặc điểm không gian và thời gian, sau đó kết hợp với nhau bằng thuật toán chuẩn hoá L2 xếp chồng. Sau đó, các đặc trưng sẽ được sử dụng làm đầu vào cho mô hình Retinanet học tập nhận dạng vị trí và cường độ XTNĐ.



Hình 7. Cấu trúc mạng không - thời gian để nhận dạng XTNĐ.

2.2.5. Phương pháp đánh giá

Liên quan đến bài toán đánh giá độ tin cậy trong nhận dạng, hiện nay đa số sử dụng chỉ số Intersection over Union (IoU) trong hình 8a.



Hình 8. Minh họa tính toán chỉ số độ tin cậy trong nhận dạng (a): trong đó Area of Overlap là diện tích vùng giao nhau giữa vùng dự báo và vùng tồn tại thực của XTNĐ, Area of Union bao gồm diện tích phần hợp của vùng dự báo và vùng tồn tại thực của XTNĐ và (b): Mô tả về chỉ số IoU, đường bao trắng: đường bao thực vị trí bão. Đường bao cam, xanh: đường bao dự đoán vị trí bão.


IoU đặc trưng cho tỉ lệ đo lường giữa mức độ giao nhau của hai đường bao (đường bao dự đoán và đường bao thực), ví dụ về đường bao được mô tả trong Hình 8b. Giá trị IoU thường nằm trong khoảng từ 0 đến 1, với 0 thể hiện giữa dự báo và thực tế không có sự giống nhau và 1 thể hiện dự báo hoàn toàn khớp với thực tế. Một ngưỡng IoU sẽ được xác định trước để quyết định xem một dự báo có được coi là chính xác hay không. Thông thường, ngưỡng IoU được chọn là 0,5, với: dự báo được cho là chính xác ($IoU \geq 0,5$), dự báo không chính xác ($IoU < 0,5$) và không nhận dạng được.

Ngoài ra, từ chỉ số IoU sẽ xác định tỉ lệ phát hiện đúng (*True Positive - TP*), sai (*False Positive -FP*), không nhận dạng được (*False Negative - FN*) để tính ra chỉ số mAP. TP thể hiện mô hình dự báo đúng sự tồn tại của XTNĐ, FP thể hiện mô hình dự báo được XTNĐ nhưng không chính xác so với thực tế, FN thể hiện mô hình không dự báo được XTNĐ trong khi thực tế có XTNĐ.

mAP hay còn gọi là đường cong Precision-Recall. Precision (Độ chính xác) là thang đo đặc trưng cho độ chính xác của dự báo, là tỷ lệ giữa số trường hợp dự báo đúng trên tổng số các trường hợp dự báo. Recall (Độ bao phủ) là thang đo đặc trưng cho độ tốt của khả năng tìm thấy vùng dự báo chính xác (hay còn gọi là độ nhạy của phương pháp), là tỷ lệ giữa số trường hợp dự báo đúng trên tổng số các trường hợp có tồn tại XTNĐ, xác định theo các công thức (1).

$$\text{Precision} = \frac{TP}{TP+FP}; \text{Recall} = \frac{TP}{TP+FN} \tag{1}$$

Giả sử có N ngưỡng để tính Precision và Recall, với mỗi ngưỡng cho một cặp giá trị Precision, Recall là P_n, R_n , với $n=1,2, \dots, N$. Precision-Recall Curve được vẽ bằng cách nối từng điểm tọa độ (P_n, R_n) , minh họa tại Hình 10.



Hình 9. Ví dụ về đường cong Precision-Recall.

Khi đó AP được xác định bằng:

$$AP = \sum_n \frac{R_n - R_{n-1}}{P_n} \tag{2}$$

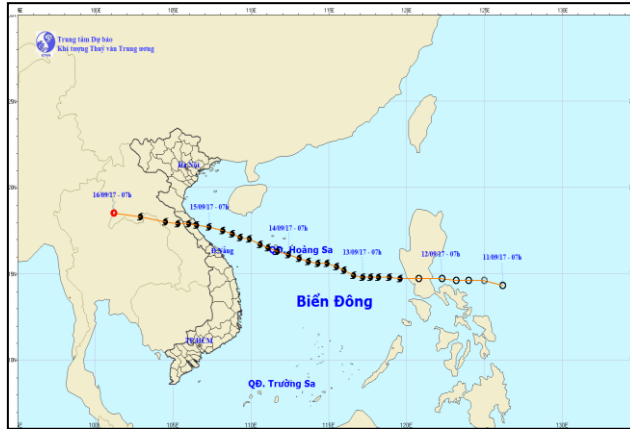
mAP là trung bình AP của tất cả các lớp. mAP là chỉ số tin cậy trung bình của phương pháp, đây sẽ là chỉ số định lượng để đánh giá tỉ lệ nhận dạng thành công của phương pháp nhận dạng sử dụng AI.

Về số liệu sử dụng để đánh giá, các giá trị tọa độ được nhận dạng bởi phương pháp AI sẽ được so sánh với quỹ đạo Best track của Nhật Bản tại cùng thời điểm tương ứng.


3. Kết quả và thảo luận

3.1. Trường hợp thử nghiệm cụ thể cho cơn bão Doksuri năm 2017 trên Biển Đông

Để minh họa cụ thể khả năng nhận dạng của hệ thống đối với cơn bão Doksuri năm 2017 hoạt động trên Biển Đông và đổ bộ và miền Trung (Hình 10), khi bão Doksuri hoạt động trên khu vực Biển Đông đã đạt cấp độ mạnh nhất (TY) với gió mạnh cấp 13, giật cấp 15 và khi đổ bộ vào đất liền đạt cấp 11-12, giật cấp 14. Kết quả nhận dạng xác định cường độ được đưa ra tương ứng tại hình 11 cho thấy độ đo tổng hợp mAP đạt 93,1% và đánh giá thêm cho thấy hệ thống đã cho phép cảnh báo khả năng phát hiện sự hình thành của bão trước 24h so với thời điểm đầu tiên được JMA phát báo.



Hình 10. Quỹ đạo di chuyển của bão Doksuri (Nguồn: Trung tâm Dự báo khí tượng thủy văn quốc gia).



Hình 11. Kết quả nhận dạng cho cơn bão Doksuri năm 2017 tại một số thời điểm cụ thể. Khung định vị màu trắng ứng với dữ liệu từ best-track của JMA, các khung hình màu đỏ (TD), màu xanh (STS) và màu da cam (TS) ứng với khung hình phân loại nhận dạng tự động của hệ thống.

3.2. Kết quả nhận dạng cho giai đoạn 2015-2019

Trong bảng 2 đưa ra kết quả thử nghiệm với 427 mẫu thử với 3 lựa chọn đầu vào khác nhau cho mô hình nhận dạng RetinaNet bao gồm chỉ sử dụng ảnh vệ tinh, chỉ sử dụng dữ liệu AMV và đồng thời sử dụng cả hai đầu vào dữ liệu ảnh kết hợp AMV. Kết quả cho thấy khi sử dụng riêng biệt ảnh mây vệ tinh, mô hình có thể nhận ra Typhoon tốt nhất với tỷ lệ lên tới 88,18%. Điều này đồng nhất với phương pháp AMVs khi nhận diện được 60,67% số lượng mẫu thử Typhoon. Khi sử dụng đồng thời cả hai phương pháp này, khả năng phát hiện Typhoon của AI được cải thiện lên 89,13%.

Ở tất cả 5 loại mẫu thử, việc kết hợp cả ảnh vệ tinh và AMVs đều cho thấy AI nhận diện tốt hơn khi sử dụng riêng biệt từng phương pháp. Cải thiện tốt nhất có thể thấy được ở 94 mẫu thử Tropical Depression khi khả năng phát hiện tăng lên tới 60.78% so với sử dụng riêng ảnh vệ tinh (34,51%) hay AMVs (10,69). Đối với việc cải thiện nhận dạng Tropical Depression cho thấy tiềm năng trong vấn đề cảnh báo và dự báo trước sự hình thành của bão.

Bảng 2. Kết quả so sánh mAP độ nhận diện 6 dạng XTNĐ ứng với đầu vào ảnh, AMV và kết hợp ảnh và AMV.

Phân loại	Mẫu đánh giá	Image	AMVs	Image + AMVs
		RetinaNet mAP	RetinaNet mAP	RetinaNet mAP
Tropical Depression	94	34,51	10,69	60,78
Tropical Storm	109	52,44	12,87	66,95
Severe Tropical Storm	45	33,28	19,35	42,30
Typhoon	103	88,18	60,67	89,13
Extra-tropical Cyclone	76	38,93	7,71	57,24
Trung bình	427	52,69	23,69	66,62

4. Kết luận

Nghiên cứu đã trình bày chi tiết việc ứng dụng phương pháp học sâu để xác định vị trí và phân loại XTNĐ một cách tự động. Mạng học sâu được sử dụng cho bài toán nhận dạng XTNĐ là Retinanet trong đó mạng xương sống có tên là Mạng kim tự tháp đặc trưng chịu trách nhiệm tính toán các bản đồ đặc trưng tích chập của toàn bộ hình ảnh, một mạng con chịu trách nhiệm phân loại đối tượng ứng với nhận dạng cường độ XTNĐ và một mạng con chịu trách nhiệm thực hiện hồi quy tìm ra miền định vị đối tượng thể hiện vị trí của XTNĐ.

Với bộ dữ liệu Himawari cho các XTNĐ trên Tây Bắc Thái Bình Dương và Biển Đông từ năm 2015 đến năm 2019 đã được thu thập, mô hình đã được thử nghiệm và kết hợp với dữ liệu bổ sung thông qua dữ liệu vectơ chuyển động khí quyển. Kết quả tính toán đã cho thấy khả năng ứng dụng cao của phương pháp AI trong bài toán nhận dạng XTNĐ và với tỉ lệ tin cậy cao trong xác định phân lớp TĐ cũng cho thấy khả năng cảnh báo sớm cả sự hình thành của XTNĐ.

Đóng góp của tác giả: Xây dựng ý tưởng nghiên cứu: L.V.H., D.D.T., B.Q.H.; Lựa chọn phương pháp nghiên cứu: L.V.H., L.Q.D.; Xử lý số liệu: T.H.H., L.Q.D., L.V.H.; Phân tích mẫu: T.H.H., C.T., N.T.H., M.K.H.; Lấy mẫu: D.T.T., C.T., L.Q.D.; Viết bản thảo bài báo: D.D.T., C.T.; Chỉnh sửa bài báo: C.T., D.D.T.

Lời cam đoan: Tập thể tác giả cam đoan bài báo này là công trình nghiên cứu của tập thể tác giả, chưa được công bố ở đâu, không được sao chép từ những nghiên cứu trước đây; không có sự tranh chấp lợi ích trong nhóm tác giả.

Lời cảm ơn: Nghiên cứu được hoàn thành dựa trên sự hỗ trợ của Đề tài nghiên cứu khoa học “Nghiên cứu xây dựng hệ thống trí tuệ nhân tạo ứng dụng trong dự báo xoáy thuận nhiệt đới (XTNĐ) ở Biển Đông và ảnh hưởng đến Việt Nam hạn đến 3 ngày”, Mã số: KC-4.0-46/19-

25, thuộc Chương trình “Hỗ trợ nghiên cứu, phát triển và ứng dụng công nghệ của công nghiệp 4.0”, Bộ Khoa học và Công nghệ.

Tài liệu tham khảo

1. Thành, N.H.; Năng, T.Q.; Tiên, D.Đ.; Dung, P.P.; Ngà, P.T.T. Đánh giá kết quả áp dụng kỹ thuật Dvorak cải tiến (ADT) phân tích cường độ bão trên biển Đông. *Tạp chí Khí tượng Thủy văn* **2017**, 680, 14–24.
2. Năng, T.Q.; Dung, P.P.; Huyền, L.K.; Thành, N.H.; Tiên, D.Đ. So sánh kỹ thuật phân tích cường độ bão Dvorak cải tiến (ADT) và phương pháp phân tích Dvorak (DT) trong nghiệp vụ dự báo bão trên khu vực biển Đông. *Tạp chí Khí tượng Thủy văn* **2018**, 686, 12–20.
3. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. ImageNet classification with deep convolutional neural networks. Proceedings of the 25th International Conference on Neural Information Processing Systems (Lake Tahoe, NV), 2012, 1097–1105.
4. Liu, Y.; Racah, E.; Prabhat, Correa J.; Khosrowshahi, A.; Lavers, D.; Kunkel, K.; Wehner, M.; Collins, W. Application of deep convolutional neural networks for detecting extreme weather in climate datasets. 2016. <https://doi.org/10.48550/arXiv.1605.01156>.
5. Kim, S.K.; Ames, S.; Lee, J.; Zhang, C.; Wilson, A.C.; Williams, D. Massive scale deep learning for detecting extreme climate events. Proceedings of the 7th International Workshop on Climate Informatics, Boulder, 2017.
6. Matsuoka, D.; Nakano, M.; Sugiyama, D.; Uchida, S. Deep learning approach for detecting tropical cyclones and their precursors in the simulation by a cloud-resolving global nonhydrostatic atmospheric model. *Prog. Earth Planet. Sci.* **2018**, 5, 80.
7. Pradhan, R.; Aygun, R.S.; Maskey, M. Ramachandran, R., Cecil, D.J. Tropical cyclone intensity estimation using a deep convolutional neural network. *IEEE Trans. Image Process.* **2018**, 27, 692–702.
8. Combinido, J.S.; Mendoza, J.R.; Aborot, J.A. Convolutional neural network approach for estimating tropical cyclone intensity using satellite-based infrared images. Proceedings of the 2018 24th ICPR, Beijing, China, 2018.
9. Wimmers, A.; Velden, C.; Cossuth, J.H. Using Deep Learning to Estimate Tropical Cyclone Intensity from Satellite Passive Microwave Imagery. *Mon. Weather Rev.* **2019**, 147, 2261–2282.
10. Park, M.S.; Kim, M.; Lee, M.I.; Im, J.; Park, S. Detection of tropical cyclone genesis via quantitative satellite ocean surface wind pattern and intensity analyses using decision trees. *Remote Sens. Environ.* **2016**, 183, 205–214.
11. Zhang, T.; Lin, W.; Lin, Y.; Zhang, M.; Yu, H.; Cao, K.; Xue, W. Prediction of Tropical Cyclone Genesis from Mesoscale Convective Systems Using Machine Learning. *Weather Forecast.* **2019**, 34, 1035–1049.
12. Yu, J.H., Zheng, Y.Q., Wu, Q.S., Lin, J.G., Gong, Z.B. K-Means clustering for classification of the northwestern pacific tropical cyclone tracks. *J. Trop. Meteorol.* **2016**, 22, 127–135.
13. Kim, H.S.; Kim, J.H.; Ho, C.H.; Chu, P.S. Pattern classification of typhoon tracks using the fuzzy c-means clustering method. *J. Clim.* **2011**, 24, 488–508.
14. Kim, S.W.; et al. A time-dependent surrogate model for storm surge prediction based on an artificial neural network using high-fidelity synthetic hurricane modeling. *Nat. Hazards* **2016b**, 76(1), 565–585.
15. Yunsoo, C.; Ebrahim, E. Hybrid AI hurricane forecasting system: deep learning ensemble approach and Kalman filter. 1st Workshop on Leveraging Artificial Intelligence (AI) in the Exploitation of Satellite Earth Observations & Numerical

- Weather Prediction (NWP), NOAA Center for Weather and Climate Prediction, Maryland 20740, USA, 2019.
16. Rui, C.; Zhang, W.; Wang, X. Machine learning in tropical cyclone forecast modeling: A review. *Atmosphere* **2020**, *11*(7), 676.
 17. Xu, W.; Balaguru, K.; August, A.; Lalo, N.; Hodas, N.; DeMaria, M.; Judi, D. Deep learning experiments for tropical cyclone intensity forecasts. *Weather Forecasting* **2021**, *36*(4), 1453–1470.
 18. Tiến, D.Đ. Nghiên cứu xây dựng hệ thống trí tuệ nhân tạo ứng dụng trong dự báo xoáy thuận nhiệt đới (XTNĐ) ở Biển Đông và ảnh hưởng đến Việt Nam hạn đến 3 ngày. Thuyết minh đề tài nghiên cứu ứng dụng và phát triển công nghệ cấp quốc gia, 2021.
 19. Wei, F.; Wang, L.; Ren, P. Tinier-YOLO: A real-time object detection method for constrained environments. *IEEE Access* **2019**, *8*, 1935–1944.
 20. Cao, Changqing, et al. An improved faster R-CNN for small object detection. *IEEE Access* **2019**, *7*, 106838–106846.
 21. Cao, G.; Xie, X.; Yang, W.; Liao, Q.; Shi, G.; Wu, J. Feature-fused SSD: Fast detection for small objects. Proceeding of the 9th International Conference on Graphic and Image Processing (ICGIP 2017). SPIE, 2018, 10615.
 22. Afif, M.; Ayachi, R.; Said, Y.; Pissaloux, E.; Atri, M. An evaluation of retinanet on indoor object detection for blind and visually impaired persons assistance navigation. *Neural Process. Lett.* **2020**, *51*, 2265–2279.

Application of deep learning for identifying and early warning of tropical cyclones in the Northwest Pacific basin and East Sea

Chu Thi Huyen Trang¹, Le Quang Dao², Tran Huy Hoang^{2,3}, Luu Viet Hung², Bui Quang Hung², Mai Khanh Hung¹, Nguyen Thu Hang¹, Do Thuy Trang¹, Du Duc Tien^{1*}, Dang Dinh Quan¹, Hoang Gia Nam¹

¹ National Center for Hydro-Meteorological Forecasting (NCHMF), Vietnam Meteorological and Hydrological Administration; chutrang.2406@gmail.com; maikhanhhung18988@gmail.com; nthang0676@gmail.com; dotrang111@gmail.com; duductien@gmail.com; quandangdinh.92@gmail.com; namhoangkt95@gmail.com

² Center of Multidisciplinary Integrated Technologies for Field Monitoring (FIMO), University of Engineering and Technology, Vietnam National University; daolq@fimo.edu.vn; huyhoang.tran6669@gmail.com; hunglv@piv.asia; hungbq@fimo.edu.vn

³ Viettel Cyberspace Center (VTCC), Viettel Group; huyhoang.tran6669@gmail.com

Abstract: In this study presents a deep learning (DL) application to detect tropical cyclones (TCs). A two-stream Convolution Neural Network (CNN) which captures both spatial and temporal features of time-series of geostationary satellite cloud images (SCIs) is proposed. A dataset of Himawari-8 SCIs of TCs over Western North Pacific and East Sea from 2015 to 2019 are processed. Additional inputs for DL relating to tropical cyclone circulation features are atmospheric motion vector (AMV). Results show that our model can significantly improve the performance of TC detection. Moreover, our case study for the detection of TC Doksuri in 2017 yielded promising results as our proposed model is capable of detecting and early warning TC formation 24 hours prior to the first time reported by the (Japan Meteorological Agency) JMA.

Keywords: Tropical Cyclones detection; Two-stream Convolution Neural Network.