

APPLYING ARTIFICIAL INTELLIGENCE IN IDENTIFYING TROPICAL CYCLONE REGIONS FROM NUMERICAL METEOROLOGICAL AND CLIMATE DATA TO MINIMIZE RISKS AND SUPPORT SUSTAINABLE DEVELOPMENT IN THE BIEN DONG SEA AND VIETNAM

Du Duc Thang ¹, Bui Quang Hung ², Du Duc Tien ^{3*}

Received: April 12, 2025

Revised: May 12, 2025; Accepted:

ABSTRACT

This study proposes a fully automated method for identifying tropical cyclone areas from numerical weather prediction (NWP) model data using the RetinaNet model combined with the ResNet152 backbone. Atmospheric variables such as pressure, wind, and temperature from NWPs are processed into multi-channel spectral images to train an object detection model, with labels derived from best-track typhoon data provided by the Japan Meteorological Agency (JMA). Experimental results on reanalysis data show that the model achieves high accuracy, with a detection rate above 90% when combining both surface and upper-level data. This enables effective identification of storm-related regions without requiring initial conditions, unlike traditional cyclone center-finding methods. Several experiments using actual forecast data over the Bien Dong Sea demonstrate realistic detection capability, highlighting the great potential of deep learning in automating storm detection from NWP data. The system can be applied to climate forecast and projection datasets to assess the impact of climate change on tropical cyclone activity, particularly in the Bien Dong Sea and Vietnam.

Keywords: *Tropical cyclone; Bien Dong Sea; numerical weather/climate data; tropical cyclone detection.*

¹ School of Interdisciplinary Sciences and Arts, Vietnam National University, Hanoi.

² University of Engineering and Technology, Vietnam National University, Hanoi.

³ National Center for Hydro-Meteorological forecasting, Ministry of Agriculture and Environment.

* Corresponding author

Email: duductionien@gmail.com

ỨNG DỤNG TRÍ TUỆ NHÂN TẠO TRONG NHẬN DẠNG VÙNG ẢNH HƯỞNG BÃO TỪ DỮ LIỆU MÔ PHỎNG KHÍ TƯỢNG - KHÍ HẬU NHẪM GIẢM THIỂU RỦI RO VÀ HỖ TRỢ PHÁT TRIỂN BỀN VỮNG TẠI KHU VỰC BIỂN ĐÔNG VÀ VIỆT NAM

Dur Đức Thắng¹, Bùi Quang Hưng², Dur Đức Tiến^{3*}

Ngày nhận bài: 12 tháng 4 năm 2025

Ngày nhận bài sửa: 20 tháng 5 năm 2025; Ngày duyệt đăng: 25 tháng 5 năm 2025

TÓM TẮT

Nghiên cứu đề xuất phương pháp hoàn toàn tự động để nhận dạng vùng bão từ dữ liệu mô hình dự báo thời tiết (NWP) bằng cách sử dụng mô hình RetinaNet kết hợp với mạng cơ sở (backbone) ResNet152. Các trường khí quyển như áp suất, gió và nhiệt độ từ dữ liệu tái phân tích được xử lý thành ảnh đa kênh phổ để huấn luyện mô hình phát hiện đối tượng trong đó nhãn dữ liệu được xác định từ dữ liệu quỹ đạo bão chuẩn (best-track) của Cơ quan Khí tượng Nhật Bản (JMA). Kết quả thử nghiệm cho thấy mô hình đạt độ chính xác cao, tỉ lệ phát hiện trên 90% khi kết hợp các dữ liệu bề mặt và trên cao, qua đó xác định được tốt các vùng thông tin liên quan đến hoạt động của bão mà không cần thông tin khởi tạo ban đầu như phương pháp do tìm tâm bão truyền thống. Một số thử nghiệm với dữ liệu dự báo thực tế trên khu vực Biển Đông cho thấy khả năng phát hiện sát thực tế. Qua đó hoàn toàn có thể áp dụng vào các dữ liệu dự báo khí hậu, dự tính khí hậu để đánh giá những biến đổi khí hậu ảnh hưởng liên quan đến hoạt động của bão cũng như ảnh hưởng của nó trên Biển Đông và đối với Việt Nam.

Từ khóa: Bão nhiệt đới; Biển Đông; dữ liệu mô hình số; nhận dạng vùng bão.

¹ Trường Khoa học liên ngành và Nghệ thuật, Đại học Quốc gia Hà Nội.

² Trường Đại học Công nghệ, Đại học Quốc gia Hà Nội.

³ Trung tâm Dự báo khí tượng thủy văn quốc gia, Bộ Nông nghiệp và Môi trường.

*Tác giả liên hệ. Địa chỉ email: duductien@gmail.com

1. ĐẶT VẤN ĐỀ

1.1. Bão



Bão là một hiện tượng khí tượng nguy hiểm, thường xảy ra ở các vùng nhiệt đới với đặc trưng là một xoáy thuận mạnh mẽ, kèm theo hệ quả về gió mạnh, mưa lớn và nguy cơ lũ lụt. Bão có thể gây thiệt hại nghiêm trọng đến người, tài sản và môi trường, đặc biệt tại các khu vực ven biển như Biển Đông và Việt Nam (Phan Văn Tân và cộng sự 2014). Việc dự báo số lượng bão và cường độ của chúng từ dữ liệu mô phỏng khí tượng, khí hậu và dự tính khí hậu trong tương lai là cực kỳ quan trọng để giảm thiểu rủi ro thiên tai và bảo vệ sự phát triển bền vững (Phan Văn Tân và cộng sự 2015, 2016, 2019). Dự báo chính xác giúp cộng đồng và cơ quan chức năng chủ động chuẩn bị các biện pháp phòng chống, giảm thiểu thiệt hại và đảm bảo an toàn cho người dân. Hơn nữa, dữ liệu mô phỏng còn giúp xây dựng các chiến lược phát triển kinh tế phù hợp, tránh những tổn thất nặng nề trong các hoạt động sản xuất và đầu tư, qua đó đảm bảo sự ổn định và phát triển bền vững.

1.2. Mô hình dự báo thời tiết số

Mô hình dự báo thời tiết số (Numerical Weather Prediction, NWP), là một công cụ quan trọng trong dự báo thời tiết và nghiên cứu khí hậu (Phan Văn Tân và cộng sự 2015), (Duy và cộng sự 2019). NWP sử dụng các phương trình động học, nhiệt động lực học và các phương trình bảo toàn năng lượng-khối lượng để mô phỏng và dự đoán các hiện tượng khí quyển trong tương lai. NWP sử dụng các quan trắc khí tượng (từ vệ tinh, trạm mặt đất, radar) và kỹ thuật đồng hóa số liệu (data assimilation) để xây dựng trạng thái khí quyển ban đầu.

NWP đóng một vai trò quan trọng trong việc dự báo bão. NWP cung cấp thông tin về các yếu tố như vị trí và đường đi và cường độ của bão.

Hình 1 minh họa về thông tin dự báo của NWP phản ánh trong các bản tin dự báo chính thức tại Việt Nam. Tùy thuộc vào hạn dự báo, các NWP có thể ứng dụng trong dự báo khí hậu (hạn từ vài tháng đến năm) đến ứng dụng trong dự báo biến đổi, dự tính khí hậu (từ vài chục năm đến hàng trăm năm).



Hình 1: Bản đồ dự báo vị trí của cơn bão Trà My vào tháng 10/2024 của Trung tâm Dự báo khí tượng thủy văn quốc gia (trên) và thông tin dự báo vị trí từ mô hình số của Trung tâm dự báo thời tiết hạn vừa châu Âu (dưới).

1.3. Về cách thức xác định tâm bão trên các sản phẩm mô hình số và hạn chế chung

Tâm bão thường được xác định dựa trên các trường khí quyển được mô phỏng từ NWP (chẳng hạn như áp suất trung bình mực biển, gió, nhiệt độ, hoặc độ ẩm) trong đó khu vực có bão thường thể hiện đặc trưng riêng biệt, như áp suất thấp nhất tại tâm bão (Võ Văn Hòa và cộng sự 2024). Thông thường thuật toán tìm kiếm vị trí cực trị như “downhill” sẽ được áp dụng. Đây là một phương pháp tối ưu hóa, trong đó hệ thống tìm kiếm điểm thấp nhất của một “dãy núi” - trong trường hợp này là các trường áp suất, nơi các điểm có giá trị áp suất thấp nhất thường chính là tâm bão. Quá trình này được thực hiện qua các bước tính toán sự thay đổi của các trường khí quyển để tìm ra vị trí chính xác của tâm bão.

Một số vấn đề chính là trong quá trình sử dụng thuật toán downhill, cần có một first guess (dự đoán ban đầu) để chỉ ra vùng có thể có bão. First guess có thể được xác định dựa trên các yếu tố như hình dạng và xu hướng của các trường khí quyển (gió, áp suất). Đây là bước khởi tạo, nơi các thuật toán sẽ sử dụng thông tin về vùng khả dĩ có bão (vùng áp suất thấp) để bắt đầu quá trình tìm kiếm tâm bão. Nếu không có first guess chính xác, quá trình tìm kiếm có thể tốn nhiều thời gian hơn hoặc dẫn đến kết quả không chính xác. Ví dụ việc tìm kiếm các vùng first guess có thể dựa trên trường áp suất mực biển có thể dẫn tới tồn tại nhiều vùng áp suất thấp có tiềm năng, hay còn gọi là “ứng cử viên” tốt (Bùi Hoàng Hải và Phan Văn Tân 2009), khi đó cần thực hiện thêm các kiểm tra chéo ở các mực khác

nhau, các yếu tố khí tượng khác nhau để xác nhận thực tế đây là ứng cử viên tốt cho việc dò tìm chính xác tâm bão cuối cùng. Do đó, khi áp dụng tìm kiếm thông tin bão trên một tập dữ liệu lớn dự báo về khí hậu, các dự tính khí hậu trong tương lai với độ phân giải theo không gian có thể tới 1-6 giờ, việc xác định thủ công các vùng first guess này gần như là không thể và cần có những cải tiến để tự động hóa vấn đề này. Đây cũng chính là mục đích của nghiên cứu đề xuất một phương pháp hoàn toàn tự động để nhận dạng vùng bão từ dữ liệu NWP bằng cách sử dụng công nghệ trí tuệ nhân tạo trong bài toán nhận dạng vật thể (object detection).

2. MÔ HÌNH TRÍ TUỆ NHÂN TẠO VÀ ỨNG DỤNG CHO BÀI TOÁN NHẬN DẠNG BÃO

2.1. Bài toán nhận dạng vật thể

Bài toán nhận dạng vật thể (object detection) là một trong những thách thức quan trọng trong lĩnh vực thị giác máy tính (computer vision), với mục tiêu xác định và phân loại các đối tượng xuất hiện trong ảnh hoặc video, đồng thời xác định vị trí của chúng thông qua các hộp giới hạn (bounding boxes) (Lin và cộng sự 2020). Trong thập kỷ qua, sự phát triển mạnh mẽ của các mô hình học sâu (deep learning) đã giúp nâng cao đáng kể độ chính xác và tốc độ của các hệ thống nhận dạng vật thể. Các mô hình nền tảng như VGGNet đã đặt nền móng cho việc trích xuất đặc trưng hiệu quả trong ảnh. Sau đó, các kiến trúc hiện đại như RetinaNet (với hàm focal loss để xử lý mất cân bằng mẫu), Faster R-CNN (dựa trên hai giai đoạn phát hiện), và YOLO (You

Only Look Once - phát hiện một giai đoạn) đã được phát triển, kết hợp độ chính xác cao và thời gian xử lý nhanh. Gần đây hơn, các mô hình tiên tiến như DETR và RT-DETR, với sự kết hợp của các cơ chế “attention” trong các kiến trúc Transformer, đang mở ra hướng đi mới cho bài toán này, cho phép phát hiện đối tượng trong các tình huống phức tạp hơn và ít cần tinh chỉnh thủ công/chủ quan hơn.

2.2. Mô hình trí tuệ nhân tạo RetinaNet

RetinaNet là mô hình nhận dạng đối tượng được phát triển bởi nhóm nghiên cứu tại Facebook AI Research (FAIR) và được chi tiết hóa trong công trình của Lin và cộng sự công bố năm 2020. 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 hay nhận dạng đối tượng trong hình ảnh y khoa,... (Afif và cộng sự 2020).

Để triển khai cho bài toán nhận dạng vùng “chứa bão” trên các dữ liệu “ảnh” đưa vào, mô hình RetinaNet là một mạng tổng hợp bao gồm:

- Mạng xương sống có tên là Mạng kim tự tháp đặc trưng (Feature Pyramid Net), được xây dựng dựa trên mạng cơ sở (ví dụ như ResNet, MobileNet, VGG) 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 đối tượng có là loại hình bão được đưa bổ sung vào lớp huấn luyện.

- Một mạng con chịu trách nhiệm thực hiện hồi quy tìm ra miền định vị đối tượng thể hiện vị trí của bão (box subnet).



Hình 2: Minh họa kiến trúc mạng RetinaNet trong đó sử dụng mạng cơ sở là ResNet (Nguồn hình vẽ: <https://doi.org/10.48550/arXiv.1708.02002>, truy cập ngày 20/3/2025)

Liên quan đến mạng cơ sở trong kiến trúc RetinaNet, trong nghiên cứu này sử dụng ResNet hay Residual Networks. Đây là một loại kiến trúc mạng nơ-ron sâu (deep neural network) với vai trò học tập phân

loại hình ảnh. Về cấu trúc, ResNet ứng dụng các lớp mạng tích chập (Convolutional Neural Networks - CNN). CNN là một loại mạng nơ-ron sâu được thiết kế đặc biệt để xử lý dữ liệu có cấu trúc lưới, ví dụ như ảnh, và


được áp dụng rộng rãi trong các bài toán nhận dạng hình ảnh, phân loại, và phát hiện đối tượng. CNN đã chứng minh được khả năng vượt trội trong việc học và nhận dạng các đặc trưng trong ảnh mà không cần phải thực hiện các thao tác tiền xử lý phức tạp.

Về bản chất, 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).

Mạng ResNet152 là một biến thể sâu của kiến trúc mạng nơ-ron tích chập (CNN) ResNet, được thiết kế nhằm giải quyết hiện tượng mất mát thông tin và gradient trong các mạng rất sâu thông qua cơ chế residual learning. Hình 3 minh họa cụ thể kiến trúc sử dụng trong nghiên cứu. Kiến trúc này bắt đầu với một lớp tích chập đầu vào (7×7 , stride 2) giúp trích xuất đặc trưng ban đầu, tiếp theo là một lớp pooling (3×3 , stride 2) để giảm kích thước không gian của ảnh. Sau đó, mạng được chia thành bốn khối chính: Conv2_x, Conv3_x, Conv4_x và Conv5_x, lần lượt chứa 3, 8, 36 và 3 khối residual. Mỗi khối residual gồm ba lớp tích chập liên tiếp với các kích thước 1×1 , 3×3 và 1×1 , giúp tăng chiều sâu nhưng vẫn giữ được khả năng học hiệu quả. Các tầng này có số lượng kênh tăng dần từ 256 đến 2048. Đầu ra cuối cùng của mạng được đưa qua lớp global average pooling, sau đó là lớp fully connected với hàm softmax để phân loại đầu ra thành 1000 lớp, phù hợp với bài toán phân loại ảnh ImageNet. Với tổng cộng 152 lớp sâu, ResNet152 có khả năng trích xuất đặc trưng mạnh mẽ, phù hợp cho các bài toán thị giác máy tính như phát hiện và nhận dạng đối tượng, kể cả trong điều kiện phức tạp.



Hình 3: Kiến trúc của mạng ResNet152

(Nguồn hình vẽ: <https://doi.org/10.1080/02664763.2020.1849057>, truy cập ngày 10/05/2025)

2.3. Cách thức triển khai chung

2.3.1. Xây dựng dữ liệu gán nhãn

Để xây dựng bộ dữ liệu huấn luyện cho mô hình RetinaNet trong bài toán nhận dạng vùng bão, các trường vật lý từ dữ liệu mô hình số NWP như áp suất trung bình mực biển, thành phần gió u/v ở các mức áp suất khác nhau (gió tầng thấp, tầng trung, tầng cao), và nhiệt độ khí quyển được xử lý và chuyển đổi thành các ảnh 2D dạng raster. Mỗi trường vật lý tương ứng với một kênh ảnh (channel), từ đó tạo nên các ảnh đa kênh (multi-channel image) làm đầu vào cho mô hình học sâu. Việc chuyển đổi này thường được thực hiện bằng cách nội suy dữ liệu lưới (grid) lên không gian ảnh cố định (ví dụ 256x256 hoặc 512x512 pixel), chuẩn hóa giá trị vật lý về cùng khoảng (min-max

hoặc z-score), và lưu dưới dạng tensor phù hợp với mô hình.

Để gán nhãn (label), vị trí bão tại từng thời điểm được xác định từ dữ liệu best-track (ví dụ từ Cơ quan Khí tượng Nhật Bản - JMA). Với mỗi thời điểm tương ứng với một ảnh đầu vào, tọa độ tâm bão và bán kính vùng ảnh hưởng được dùng để tạo hộp giới hạn (bounding box) đánh dấu vùng bão. Quá trình này tạo nên tập huấn luyện gồm các ảnh đầu vào đa kênh và các hộp giới hạn có nhãn, phù hợp với định dạng đầu vào yêu cầu của RetinaNet. Nhờ đó, mô hình học sâu có thể học được mối liên hệ giữa các cấu trúc vật lý khí quyển và sự hiện diện của một hệ thống xoáy thuận nhiệt đới, mà không cần thông tin khởi tạo chủ quan như các phương pháp tìm tâm truyền thống.

2.3.2. Ứng dụng kỹ thuật học chuyển tiếp

Trên thực tế nếu xây dựng một tập dữ liệu chuyên biệt về bão, sẽ cần rất nhiều dữ liệu để có thể huấn luyện cho một mô hình học sâu từ đầu. Trong nghiên cứu này, chúng tôi ứng dụng mô hình RetinaNet với mạng cơ sở ResNet152 được huấn luyện sẵn (pre-trained model) trên tập dữ liệu ImageNet nhằm tận dụng các đặc trưng hình học - không gian đã học từ ảnh tự nhiên. ImageNet là một trong những tập dữ liệu hình ảnh lớn và có ảnh hưởng nhất trong lĩnh vực thị giác máy tính (computer vision), được sử dụng rộng rãi để huấn luyện và đánh giá các mô hình học sâu (Deng và cộng sự 2009). Tập dữ liệu này bao gồm hơn 14 triệu hình ảnh được gán nhãn theo hệ thống phân loại của WordNet, với hơn 20.000 danh mục đối tượng khác nhau. Các mô hình học sâu được huấn luyện sẵn trên ImageNet có khả năng trích xuất đặc trưng mạnh mẽ từ hình ảnh và thường được sử dụng trong transfer learning, đặc biệt hiệu quả khi áp dụng cho các bài toán thị giác máy tính với dữ liệu ít hoặc không gán nhãn đầy đủ.

Kỹ thuật học chuyển tiếp (transfer learning) được triển khai bằng cách giữ nguyên các lớp đầu của ResNet152 để bảo toàn khả năng trích xuất đặc trưng tổng quát, trong khi các lớp phía sau của mạng phát hiện đối tượng được thay thế và huấn luyện lại để thích ứng với tập nhãn mới đặc trưng cho các vùng bão. Dữ liệu đầu vào là các ảnh đa kênh được xây dựng từ các trường vật lý (áp suất, gió, nhiệt độ...) của mô hình số, được ánh xạ thành định dạng phù hợp với đầu vào của mạng học sâu. Nhờ phương pháp này, mô hình có thể nhanh chóng học được các đặc trưng đặc thù của hiện tượng bão mà không cần huấn luyện toàn bộ từ đầu, đồng thời đạt

hiệu quả cao ngay cả khi dữ liệu huấn luyện không quá lớn.

Trong quá trình huấn luyện mô hình RetinaNet nhận dạng vùng bão từ ảnh dữ liệu khí tượng, toàn bộ các lớp trong backbone của ResNet152 - bao gồm conv1, bn1, các khối residual từ layer1 đến layer4 - được giữ nguyên trọng số (freeze), tức là không tham gia cập nhật trong quá trình huấn luyện nhằm bảo toàn khả năng trích xuất đặc trưng tổng quát đã học từ ảnh tự nhiên. Trong khi đó, các lớp phát hiện đối tượng (detection heads) của RetinaNet - bao gồm subnet phân loại và subnet hồi quy hộp giới hạn - được huấn luyện lại hoàn toàn với dữ liệu ảnh khí tượng đầu vào. Trong trường hợp ảnh đầu vào có số kênh khác ảnh RGB thông thường (ví dụ ảnh khí tượng có nhiều kênh vật lý như gió, áp suất, nhiệt độ...), lớp conv1 có thể được tùy chỉnh để tiếp nhận đầu vào mới và được huấn luyện lại. Sau khi các lớp mới ổn định, có thể tiếp tục tinh chỉnh (fine-tune) một phần các lớp sâu trong backbone như layer4 để cải thiện độ phù hợp của mô hình với dữ liệu chuyên ngành. Phương pháp này giúp rút ngắn thời gian huấn luyện, giảm yêu cầu dữ liệu lớn và tận dụng hiệu quả kiến thức học sẵn từ mô hình ResNet152.

3. SỐ LIỆU VÀ CÁC PHƯƠNG ÁN THỬ NGHIỆM

3.1. Số liệu thông tin về bão

Dữ liệu best-track (quỹ đạo bão chuẩn) từ JMA cung cấp thông tin chi tiết về quỹ đạo và cường độ của các cơn bão nhiệt đới trong suốt quá trình phát triển (Muroi và cộng sự 2018). Mỗi cơn bão được theo dõi qua các mốc thời gian, thường là mỗi 6 giờ, với các thông số quan


trọng như tọa độ (vĩ độ, kinh độ), vận tốc gió cực đại, áp suất trung tâm, và loại bão (Tropical Depression, Tropical Storm, Typhoon...). Dữ liệu này rất quan trọng cho việc đánh giá sự thay đổi và di chuyển của bão trong không gian và thời gian. Các thông tin từ dữ liệu best-track giúp xác định vị trí và cường độ của bão, phục vụ cho các nghiên cứu dự báo bão, cũng như giúp các mô hình học máy, như RetinaNet, nhận dạng và phân tích các vùng ảnh hưởng bão từ dữ liệu mô phỏng khí tượng. Bằng cách sử dụng dữ liệu best-track từ JMA, các mô hình có thể tự động phát hiện và theo dõi các cơn bão, từ đó hỗ trợ các quyết định ứng phó kịp thời, giảm thiểu thiệt hại do thiên tai, và đảm bảo an toàn cho các khu vực dễ bị ảnh hưởng, đặc biệt là khu vực Biển Đông. Số liệu best-track được thu thập tại địa chỉ: <https://www.jma.go.jp/jma/jma-eng/jma-center/rsmc-hp-pub-eg/besttrack.html>

3.2. Số liệu mô hình số tái phân tích

Mô hình số tái phân tích là quá trình sử dụng các mô hình dự báo thời tiết kết hợp với quan trắc thực tế để tái tạo lại trạng thái khí quyển trong quá khứ một cách đồng nhất và nhất quán theo thời gian. Dữ liệu tái phân tích cung cấp thông tin chi tiết về các trường khí tượng như nhiệt độ, gió, áp suất ở nhiều tầng khí quyển. ERA5, do Trung tâm dự báo thời tiết hạn vừa châu Âu (European Centre for Medium-Range Weather Forecasts, ECMWF) phát triển, là một trong những bộ dữ liệu tái phân tích hiện đại và phổ biến nhất hiện nay, cung cấp dữ liệu toàn cầu với độ phân giải cao theo từng giờ, rất hữu ích cho nghiên cứu khí hậu và thời tiết (Dullaart và cộng sự. 2020), (Hersbach và cộng sự. 2020). Trước khi áp

dụng thực tế việc xác định vùng bão trên dữ liệu mô hình NWP dự báo khí tượng, khí hậu và dự tính khí hậu, việc huấn luyện mô hình sẽ được thực hiện trên số liệu ERA5. Số liệu ERA5 được thu thập tại địa chỉ: <https://cds.climate.copernicus.eu/datasets/reanalysis-era5-pressure-levels>

3.3. Các phương án thử nghiệm



Hình 4: Minh họa dữ liệu áp suất bề mặt biển (trên) từ số liệu tái phân tích cho cơn bão Yagi từ lúc bắt đầu đi sát Biển Đông ngày 01 tháng 9 năm 2024 và dữ liệu gió kinh hướng mực 10m (dưới) đã được chuyển về dạng ảnh cho mô hình học sâu, vùng bão (ô vuông màu đen) sẽ được lấy thông tin từ dữ liệu best-track để đưa vào huấn luyện

Phương án thử nghiệm gồm: i) sử dụng trường áp suất mực biển MSLP hoặc trường độ cao địa thế vị (geopotential) tại các mực độ cao mực 925hPa (dưới 1km), 850hPa (~ 2km), 500hPa (~ 5km), ii) các trường gió kinh hướng bề mặt (10m), iii) trường gió vĩ hướng bề mặt (10m), iv) kết hợp trường áp suất và trường các trường gió.

4. KẾT QUẢ THỬ NGHIỆM


4.1. Kết quả huấn luyện trên dữ liệu mô hình số tái phân tích

Để thực hiện huấn luyện mô hình, dữ liệu số ERA5 đã được thu thập và xử lý về dạng số cho từng biến dữ liệu ứng với từng kênh ảnh đưa vào mô hình học sâu. Dữ liệu thử nghiệm sử dụng dữ liệu 5 năm về bão trên khu vực Tây Bắc Thái Bình Dương và Biển Đông giai đoạn từ 2014-2018 bao gồm 133 cơn bão và tổng số lượng ảnh liên quan là 4837. Sau khi có được kết quả huấn luyện sẽ thử nghiệm trong giai đoạn 2019-2023 với số liệu của 110 cơn bão. Chúng tôi thử nghiệm dữ liệu ngay cả khi bão đang ở trạng thái ban đầu (dạng áp thấp nhiệt đới), khi đó thông tin của các trường như MSLP hay các phân bố gió của bão sẽ chưa thực sự rõ ràng, khi đó mô hình sẽ được tăng khả năng nắm bắt các thông tin khi bão yếu, bão suy yếu - các trường hợp mà các phương pháp dò tìm truyền thống rất khó nhận biết do các tiêu chuẩn về động lực đã quá yếu. Để đánh giá kết quả, trước hết chúng ta định nghĩa IoU là tỉ lệ giữa diện tích phần vùng bão nhận dạng được và vùng bão thực tế giao nhau / diện tích phần hợp lại. Chỉ số mAP50 đo độ chính xác trung bình của mô hình nhận dạng khi $\text{IoU} \geq 0.5$,

có nghĩa là vùng dự đoán trùng với vùng thực ít nhất 50%. Chỉ số này phản ánh chất lượng phát hiện đối tượng của các mô hình học máy, học sâu nói chung (Chu Thị Huyền Trang và cộng sự 2024). Về bản chất, chỉ cần nắm bắt được vùng có bão, các bước thực hiện tiếp sau đó như tìm vị trí có áp suất cực tiểu trong phạm vi ô nhận dạng (anchor box) hoặc giá trị tốc độ gió bề mặt lớn nhất sẽ đưa ra được chính xác thông tin của bão nhận dạng được. Do đó, việc sử dụng chỉ số mAP50 là đủ mức để đánh giá kết quả đạt được.

Khi sử dụng một kênh dữ liệu áp suất trung bình mực biển hoặc độ cao địa thế vị tại các mực độ cao khác nhau, mAP50 trung bình từ 0.75-0.85, đặc biệt khi bão yếu hoặc đổ bộ, áp suất bề mặt thường loãng nên khi kết hợp với các kênh bề mặt và trên cao (mực 500hPa) cho mAP50 cao hơn rõ rệt, từ 0.85-0.95. Việc sử dụng riêng kênh dữ liệu từ một trong các thành phần gió cho kết quả thấp hơn so với dùng riêng kênh dữ liệu liên quan đến áp suất do có những giai đoạn không thể hiện được cấu trúc gió bão (ví dụ Hình 4, dưới), với mAP50 trung bình từ 0.70-0.80. Sự kết hợp giữa 3 kênh dữ liệu áp suất trung bình mực biển, thành phần gió kinh hướng sát bề mặt và độ cao địa thế vị mực 500hPa cho kết quả nhận dạng tốt nhất, với mAP50 trung bình từ 0.90-0.95.

Hình 5 minh họa kết quả dò tìm tại thời điểm bắt đầu xuất hiện của các cơn bão ảnh hưởng đến Biển Đông giai đoạn 2019-2023 trong đó bao gồm vị trí thực tế của cơn bão (dấu sao) và ô vuông nhận dạng được bằng AI, tên cơn bão và mã quốc tế của cơn bão được kí hiệu phía góc phải-trên của từng ô nhận dạng được.



Hình 5: Minh họa kết quả dò tìm vị trí xuất hiện của các cơn bão ảnh hưởng đến Biển Đông giai đoạn 2019-2023, dấu sao là vị trí thực tế của cơn bão, ô vuông là vùng bão nhận dạng được bằng AI


Trong tổng số 110 cơn bão giai đoạn 2019-2023 dùng để thử nghiệm, tỉ lệ phát hiện đạt 90-95% đối với các trường hợp có cấp độ là bão (tốc độ gió sát bề mặt đạt trên 17m/s). đối với cấp độ áp thấp nhiệt đới (tốc độ gió sát bề mặt đạt ~ 8.5-17m/s) tỉ lệ phát hiện đạt 85-90% liên quan đến giai đoạn ban đầu và suy yếu của bão, khi đó thông tin các trường thể hiện về cấu trúc thường không rõ ràng và cần có những thông tin bổ sung như gió quan trắc thực tế từ các trạm quan trắc khí tượng bề mặt hoặc các thám sát từ radar.

4.2. Thử nghiệm thực tế trên dữ liệu dự báo


Để minh họa một cách cụ thể nhất khả năng ứng dụng của mô hình đã thiết lập nhưng với dữ liệu dự báo (forecast data), trong Hình 5 đưa ra trường dự báo của mô hình số IFS của ECMWF tại thời điểm ngày

24/11/2018 trên khu vực Biển Đông. Áp dụng mô hình học sâu đã phát triển với trường đầu vào là áp suất mực biển, các kết quả đã nhận dạng được 2 vị trí của bão với độ tin cậy ~ 75%, minh họa trong Hình 5. So sánh với dữ liệu vệ tinh thực tế là cơn bão Usagi với vị trí sát khu vực ven biển Nam Bộ và cơn bão Man-Ti nằm ở vùng biển ngoài Philippine, có thể thấy tính phù hợp của kết quả nhận dạng được.


Một đánh giá chi tiết hơn giữa kết quả dò tìm bão của mô hình IFS và mô hình học sâu cũng được đưa ra trong Hình 6 thể hiện các thông tin xác định vùng tâm bão bám sát hơn so với thực tế của mô hình châu Âu cho thấy quá trình huấn luyện ngoài việc phát hiện vùng chứa bão còn cho phép hiệu chỉnh thông tin xác định khi học trên tập dữ liệu quỹ đạo bão chuẩn.



(a)




(b)




(c)

Hình 6: Các trường khí tượng bề mặt từ mô hình Châu Âu (a) và kết quả nhận dạng với đầu vào là trường áp suất mực biển từ mô hình số (b) và thông tin thực tế về 2 cơn bão nhận dạng được trên ảnh vệ tinh vào ngày 24/11/2018



(a)



(b)

Hình 7: Vị trí các thời điểm dự báo cho cơn bão Usagi (hình a) từ các mô hình dự báo số khác nhau được xác định theo các thuật toán truyền thống tại hệ thống hỗ trợ nghiệp vụ của Trung tâm Dự báo khí tượng thủy văn quốc gia và so sánh giữa quỹ đạo của mô hình IFS với quỹ đạo thực tế (hình b) kết quả ứng dụng mô hình trí tuệ nhân tạo (IFS-RetinaNet)

5. KẾT LUẬN

Nghiên cứu đã bước đầu thử nghiệm và cho thấy tính hiệu quả của mô hình trí tuệ nhân tạo (ở đây là kiến trúc RetinaNet kết hợp với mạng cơ sở ResNet152) trong việc tự động hoàn toàn nhận dạng vùng ảnh hưởng của bão từ dữ liệu mô phỏng và dự báo khí tượng - khí hậu. Một số thử nghiệm ban đầu cho thấy việc áp dụng phương pháp này cho khu vực Biển Đông cho phép phát hiện sát với thực tế các hệ thống bão, bao gồm cả những trường hợp yếu mà các phương pháp truyền thống dễ bỏ sót. Không phụ thuộc vào điều kiện khởi tạo ban đầu, mô hình đạt tỉ lệ phát hiện trên 90% đối với dữ liệu tái phân tích, cho thấy độ chính xác và khả năng tổng quát hóa cao. Sai số lớn liên quan đến giai đoạn đầu bắt đầu và giai đoạn suy yếu, đổ bộ của bão. Điều này khẳng định tiềm năng của học sâu trong việc tự động hóa quy trình nhận dạng bão, góp phần nâng cao khả năng giám sát, cảnh báo sớm và đánh giá rủi ro khí hậu tại Việt Nam nói chung và khu vực Biển Đông nói riêng.

Trong phần nghiên cứu tiếp theo, chúng tôi sẽ áp dụng thuật toán cho các bộ dữ liệu dự tính khí hậu để đánh giá hoạt động trong tương lai của bão trên Biển Đông, qua đó, bước đầu mở ra hướng tiếp cận mới trong ứng dụng trí tuệ nhân tạo cho lĩnh vực khí tượng - khí hậu, phục vụ hiệu quả cho công tác phòng chống thiên tai và phát triển bền vững trong bối cảnh biến đổi khí hậu ngày càng gia tăng.

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 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 ứng dụng công nghệ của công nghiệp 4.0, Bộ Khoa học và Công nghệ.

TÀI LIỆU THAM KHẢO

- Afif, M., Ayachi, R., Said, Y., Pissaloux, E., & Atri, M. (2020). An evaluation of RetinaNet on indoor object detection for blind and visually impaired persons assistance navigation. *Neural Processing Letters*, 51, pp. 2265 - 2279.
- Bùi Hoàng Hải, Phan Văn Tân (2009), Xây dựng sơ đồ dò tìm xoáy bão cho mô hình REGCM3 để mô phỏng sự hoạt động của bão trên khu vực Tây Bắc Thái Bình Dương và Biển Đông. *Tạp chí Khí tượng Thủy văn*, 585, pp. 1 - 8.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/CVPR.2009.5206848>.
- Dullaart, J., van Oldenborgh, G. J., Vos, S., & Hersbach, H. (2020). Improved representation of tropical cyclones in

- ERA5. *Geophysical Research Letters*, 47(19), e2020GL087416. <https://doi.org/10.1029/2020GL087416>.
- Duy, D. B., Thanh, N. D., Duc, T. Q., & Phan, V.-T. (2019). Seasonal edictions of the number of tropical cyclones in the Vietnam East Sea using statistical models. *VNU Journal of Science: Earth and Environmental Sciences*, 35(2), pp. 45 -57. <https://doi.org/10.25073/2588-1094/VNUEES.4379>.
- Hersbach, H., Bell, B., Berrisford, P., et al. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), pp. 1999 - 2049.
- Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2020). Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), pp. 318 - 327.
- Muroi, C. (2018). Brief history and recent activities of RSMC Tokyo-Typhoon Centre. *Tropical Cyclone Research and Review*, 7(1), pp. 57 - 64. <https://doi.org/10.6057/2018TCRR01.09>.
- Phan Văn Tân và Nguyễn Xuân Thành (2016). Về khả năng ứng dụng mô hình RegCM3 trong dự báo hạn mùa khu vực Tây Nguyên. *Tạp chí Khoa học ĐHQGHN: Các Khoa học Trái đất và Môi trường*, 32(3S), tr. 1 - 18.
- Phan Văn Tân, Đinh Bá Duy, Ngô Đức Thành, Trần Quang Đức (2019). Thử nghiệm dự báo hạn mùa số lượng xoáy thuận nhiệt đới hoạt động trên khu vực Biển Đông bằng phương pháp thống kê. *Tạp chí Khoa học ĐHQGHN: Các Khoa học Trái đất và Môi trường*, 35(2), tr. 45-57.
- Phan, V.-T., Long, T. T., Hai, B. H., & Kieu, C. (2015). Seasonal forecasting of tropical cyclone activity in the coastal region of Vietnam using RegCM4.2. *Climate Research*, 62, pp. 115 - 129. <https://doi.org/10.3354/cr01267>
- Phan Văn Tân, Bùi Minh Tăng, Võ Văn Hòa (2014). Nghiên cứu ứng dụng các phương pháp tính toán trung bình có trọng số để nâng cao chất lượng dự báo trung bình tổ hợp cho hệ thống dự báo tổ hợp thời tiết hạn ngắn. *Tạp chí Khí tượng Thủy văn*, 640, tr. 25-32.
- Chu Thị Huyền Trang, Lê Quang Đạo, Trần Huy Hoàng, Lưu Việt Hưng, Bùi Quang Hưng, Mai Khánh Hưng, Nguyễn Thu Hằng, Đỗ Thùy Trang, Dư Đức Tiến, Đặng Đình Quân, Hoàng Gia Nam (2024). 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. *Tạp chí Khí tượng Thủy văn*, 764, tr. 1-14. [https://doi.org/10.36335/VNJHM.2024\(764\)](https://doi.org/10.36335/VNJHM.2024(764)).
- Vo Van Hoa, H., Mai Khanh, T., Du Duc, L., Hole, R., Dang Dinh, Q., Tran Anh, D., Pham Thi, H., & Hoang Gia, N. (2024). Performance of international global models and official tropical cyclone forecasts over the Bien Dong Sea for the period 2012-2019. *Advances in Meteorology*, 2024 (1), 7244738. <https://doi.org/10.1155/2024/7244738>