



Original Article

A CNN-ConvLSTM Deep Learning Model with Axial Attention for Radar Reflectivity-based Precipitation Nowcasting in Southern Vietnam

Tran Van Hoai^{1,2}, Nguyen Van Gia Thinh^{1,2}, Le Dinh Quyet³, Phan Thanh An^{1,2,*}

Ho Chi Minh City University of Technology (HCMUT),

268 Ly Thuong Kiet, Dien Hong, Ho Chi Minh City, Vietnam

²Vietnam National University Ho Chi Minh City, Linh Xuan, Ho Chi Minh City, Vietnam

³Southern Regional Hydrometeorological Center, 8 Mac Dinh Chi, Sai Gon, Ho Chi Minh City, Vietnam

Received 14th April 2026

Revised 29th May 2026; Accepted 01st October 2026

Abstract: Precipitation nowcasting plays a critical role in early hazard warning, especially for rapidly evolving convective systems. This study proposes a radar-based deep learning model that combines convolutional neural networks (CNN) for spatial feature extraction, a recurrent spatiotemporal module (ConvLSTM) for image sequences, and axial attention to capture spatiotemporal context. The experiments use reflectivity fields derived from the CAPPI radar product during the 2022 rainy season (April–October) at the Nha Be radar station. Training samples are constructed from six consecutive radar frames at 10-minute intervals (i.e., the preceding 60 minutes) to predict the target frame 10 minutes ahead. To support an operational 60-minute warning window, we additionally apply a recursive rollout scheme to generate forecasts at lead times of 10, 20, 30, 40, 50, and 60 minutes, and report lead-dependent skill. On the October 2022 test set, the model achieves high structural similarity at 10 minutes ($SSIM \approx 0.79$) with strong threshold-based classification skill ($CSI \approx 0.70$ at 0.5 mm/h and ≈ 0.42 at 10 mm/h). At 60 minutes, $SSIM$ remains around 0.71 and CSI at 0.5 mm/h remains around 0.36, indicating the model still captures the large-scale evolution of rainfall despite degradation at heavy-rain thresholds. When independently tested on June 2023 data, performance remains stable at 10 minutes ($SSIM \approx 0.79$; $CSI \approx 0.69$ at 0.5 mm/h and ≈ 0.44 at 10 mm/h), and at 60 minutes $SSIM$ remains around 0.68 with CSI at 0.5 mm/h around 0.35. Compared with baseline models trained and evaluated under the same data processing protocol and the same loss function, the proposed model consistently performs better, particularly at moderate-to-heavy rainfall thresholds. These results suggest the model can serve as a complementary module for operational precipitation nowcasting workflows.

Keywords: Extreme weather, nowcasting, precipitation forecasting, artificial intelligence, deep learning.

* Corresponding author.

E-mail address: thanhan@hcmut.edu.vn

<https://doi.org/10.25073/2588-1094/vnuees.5363>

Mô hình học sâu CNN–ConvLSTM kết hợp cơ chế chú ý theo trục cho dự báo mưa hạn cực ngắn từ phản hồi ra-đa ở Nam Bộ

Trần Văn Hoài^{1,2}, Nguyễn Văn Gia Thịnh^{1,2}, Lê Đình Quyết³, Phan Thành An^{1,2,*}

¹Trường Đại học Bách khoa, Đại học Quốc gia Thành phố Hồ Chí Minh,

268 Lý Thường Kiệt, Diên Hồng, Thành phố Hồ Chí Minh, Việt Nam

²Đại học Quốc gia Thành phố Hồ Chí Minh, Linh Xuân, Thành phố Hồ Chí Minh, Việt Nam

³Đài Khí tượng Thủy văn Nam Bộ, 8 Mạc Đĩnh Chi, Sài Gòn, Thành phố Hồ Chí Minh, Việt Nam

Nhận ngày 14 tháng 4 năm 2026

Chỉnh sửa ngày 29 tháng 5 năm 2026; Chấp nhận đăng ngày 01 tháng 10 năm 2026

Tóm tắt: Dự báo mưa hạn cực ngắn (nowcasting) có vai trò quan trọng trong cảnh báo sớm thiên tai, đặc biệt đối với các hệ mưa đối lưu phát triển nhanh. Nghiên cứu này đề xuất một mô hình học sâu dự báo mưa từ dữ liệu ra-đa thời tiết, kết hợp mạng nơ-ron tích chập (CNN) để trích xuất đặc trưng không gian, mô-đun hồi tiếp không gian–thời gian (ConvLSTM) cho chuỗi ảnh, và cơ chế chú ý theo trục (Axial Attention) nhằm khai thác ngữ cảnh không gian–thời gian hiệu quả. Dữ liệu thí nghiệm là trường phản hồi ra-đa (CAPPI) trong mùa mưa năm 2022 (tháng 4–10) tại trạm ra-đa Nhà Bè; các mẫu huấn luyện được tạo từ chuỗi 6 ảnh liên tiếp theo bước 10 phút (tương ứng 60 phút quá khứ) để dự báo ảnh mục tiêu ở thời điểm 10 phút kế tiếp. Kết quả đánh giá trên tập kiểm thử 10/2022 cho thấy mô hình đạt độ tương đồng cấu trúc cao (SSIM xấp xỉ 0,79) và chất lượng phân loại tốt theo ngưỡng mưa (chỉ số CSI khoảng 0,70 ở ngưỡng 0,5 mm/h và khoảng 0,42 ở ngưỡng 10 mm/h). Khi kiểm thử độc lập trên dữ liệu 6/2023, chất lượng duy trì ổn định (SSIM xấp xỉ 0,79; CSI khoảng 0,69 ở 0,5 mm/h và khoảng 0,44 ở 10 mm/h), cho thấy khả năng tổng quát theo thời gian tốt. Để đáp ứng yêu cầu nghiệp vụ cảnh báo trước 60 phút, nghiên cứu bổ sung thiết lập dự báo đa bước bằng suy diễn lặp (recursive rollout) để sinh dự báo tại các mốc 10–60 phút; tại mốc 60 phút, SSIM duy trì khoảng 0,68–0,71 và CSI ở ngưỡng 0,5 mm/h duy trì khoảng 0,35–0,36, cho thấy mô hình vẫn hữu ích trong việc theo dõi xu thế và phạm vi vùng mưa ở cửa sổ cảnh báo 20–60 phút (trong khi chất lượng ở ngưỡng mưa rất lớn suy giảm nhanh). So sánh với các mô hình đối chứng trên cùng dữ liệu và cùng hàm mất mát, mô hình đề xuất cho kết quả tốt hơn, đặc biệt ở các ngưỡng mưa vừa và to. Các kết quả này gợi ý mô hình có tiềm năng tích hợp như một mô-đun hỗ trợ cho quy trình dự báo hạn cực ngắn hiện hành.

Từ khóa: Thời tiết cực đoan, dự báo hạn cực ngắn, ước lượng mưa, trí tuệ nhân tạo, mạng thần kinh học sâu.

1. Giới thiệu

Các hiện tượng thời tiết cực đoan như dông sét, mưa đá, lũ, ngập lụt, lốc có thể gây ảnh hưởng nghiêm trọng đến nhiều mặt của đời sống

như tính mạng con người, sản lượng mùa vụ, cơ sở hạ tầng, ô nhiễm môi trường,... Vì lý do này, công tác dự báo chính xác và kịp thời các hiện tượng thời tiết nêu trên nhằm đề ra các phương

* Tác giả liên hệ.

Địa chỉ email: thanhan@hcmut.edu.vn

<https://doi.org/10.25073/2588-1094/vnuees.5363>

án phòng ngừa và giảm thiểu các thiệt hại ngày càng trở nên cấp thiết.

Một phương án tiếp cận truyền thống của dự báo thời tiết đó là sử dụng các mô hình số trị. Để thực hiện phương án này ta thiết lập các phương trình vật lý mô phỏng các tính chất vật lý và động học của khí quyển. Điều kiện ban đầu của các phương trình này được xác định bởi quá trình đồng hóa dữ liệu thu thập từ các nguồn khác nhau như vệ tinh, phao, bóng thám không,... Các phương trình này sau đó được rời rạc hóa trên một miền tính toán hữu hạn và được giải trên máy tính dựa trên các phương pháp số. Xem [1] để biết các nội dung dẫn nhập về chủ đề này. Tại Việt Nam, một số nghiên cứu đã khai thác sản phẩm kết hợp ra-đa và mô hình số cho cảnh báo mưa hạn cực ngắn (nowcasting), ví dụ nghiên cứu trường hợp áp dụng sản phẩm blending radar-NWP trong nowcasting [2] và đánh giá ứng dụng sản phẩm blended radar-NWP trong hệ thống SWIRLS cho cảnh báo mưa lớn cục bộ khi bão nhiệt đới đổ bộ [3]. Mặc dù lĩnh vực dự báo thời tiết bằng mô hình số trị đã có nhiều tiến bộ vượt bậc trong nhiều thập kỉ qua (chẳng hạn xem [4]), phương pháp này vẫn tồn tại những hạn chế cố hữu của nó: lượng tài nguyên tính toán đòi hỏi không lồ, thời gian tính toán dài - không thích hợp cho công tác dự báo ngắn hạn, nghiệm của các phương trình vật lý khá nhạy cảm với các điều kiện ban đầu do đó dễ bị ảnh hưởng bởi sai số trong nguồn dữ liệu,...

Một hướng tiếp cận khác đó là sử dụng các công cụ về trí tuệ nhân tạo, đặc biệt là các mạng thần kinh học sâu để đưa ra dự báo thời tiết. Hướng tiếp cận này trở nên ngày càng phổ biến trong những năm gần đây. Có hai lý do chính dẫn đến sự tiếp nhận rộng rãi của phương pháp này trong ngành dự báo: thứ nhất đó là tính khả dụng của các bộ dữ liệu thời tiết đa nguồn (ví dụ như dữ liệu từ vệ tinh địa tĩnh GOES-16 (<https://www.goes-r.gov/>), dữ liệu ra-đa từ hệ thống đa cảm biến MRMS (<https://www.nssl.noaa.gov/projects/mrms/>) và thứ hai là những đột phá trong các kiến trúc mạng thần kinh học sâu, điển hình nhất là các mạng tích chập (Convolutional Neural Network), mạng hồi quy (Recurrent Neural

Network), mạng đối nghịch tạo sinh (Generative Adversarial Networks). Các kiến trúc này ban đầu được đề xuất nhằm giải quyết các vấn đề của ngành trí tuệ nhân tạo như nhận dạng, phân loại các đối tượng ảnh,...; tuy nhiên chúng cũng đã được ứng dụng thành công trong các lĩnh vực khác, trong đó có ngành Khí tượng Thủy văn. Một số nghiên cứu đáng chú ý trong hướng này có thể kể đến chuỗi bài báo của Leinonen cùng cộng sự về dự báo sấm chớp [5] và dông sét [6] bằng các mô hình dựa trên CNN và RNN hay công trình của Ravuri cùng cộng sự [7] về dự báo mưa bằng mạng học sâu GAN. Mặc dù có những lợi thế như đã nêu, hướng tiếp cận dự báo ngắn hạn bằng các mô hình học sâu vẫn còn một số hạn chế như khả năng diễn giải, khả năng khái quát hoá của các mạng này.

Ở Việt Nam các công nghệ liên quan đến trí tuệ nhân tạo đã được sử dụng rộng rãi trong công tác dự báo thời tiết. Chu Thị Huyền Trang và cộng sự trong công trình [8] đã ứng dụng kiến trúc mạng tích chập RetinaNet [9] vào nhận dạng xoáy thuận nhiệt đới ở biển Đông. Nguyễn Vinh Thư và cộng sự [10] đã sử dụng dữ liệu vệ tinh Himawari-8 để dự báo lượng mưa bề mặt ở các tỉnh miền Bắc bằng mô hình học máy Random Forest. Trong một hướng nghiên cứu tương tự, nhóm nghiên cứu của Đỗ Hồng Hoat [11] đã ước tính lượng mưa tại Thủ Đức, thành phố Hồ Chí Minh từ độ phản hồi ra-đa bằng mạng RainNet [12]. Các kiến trúc dựa trên CNN và LSTM cũng đã được áp dụng thành công trong việc phân tích dữ liệu GNSS [13] và dự đoán lưu lượng dòng chảy [14].

Các nghiên cứu trước đây về dự báo mưa hạn cực ngắn ở Việt Nam chủ yếu khai thác các kiến trúc học sâu cơ bản có sẵn và/hoặc các mô hình đã được huấn luyện từ trước. Trong khi đó, ở góc độ nghiệp vụ, công tác nowcasting tại Cục Khí tượng Thủy văn đã và đang được triển khai trên cơ sở tích hợp dữ liệu quan trắc thời gian thực (radar thời tiết, vệ tinh, định vị sét, mạng đo mưa tự động) và được cung cấp qua các hệ thống/sản phẩm vận hành thường xuyên của Trung tâm kĩ thuật quan trắc Khí tượng Thủy văn (ví dụ hệ thống iWeather), phục vụ giám sát – cảnh báo sớm dông, sét và mưa dông với tần suất cập nhật

ngắn (mức vài phút), qua đó hỗ trợ đáng kể cho dự báo cực ngắn trong 1–2 giờ đầu [15]. Từ thực tiễn đó, một câu hỏi đặt ra là liệu có thể thiết kế và huấn luyện mô hình học sâu chuyên biệt cho đặc trưng dữ liệu radar và chế độ mưa đối lưu tại Việt Nam (thay vì chỉ tinh chỉnh mô hình phổ dụng) nhằm cải thiện khả năng tổng quát khi điều kiện quan trắc và phân bố mưa thay đổi theo thời gian hay không. Chúng tôi trả lời câu hỏi này bằng cách đề xuất một mô hình học sâu mới cho bài toán dự báo mưa hạn cực ngắn, sử dụng trực tiếp dữ liệu phản hồi vô tuyến từ trạm radar Nhà Bè làm đầu vào.

2. Đặt vấn đề

Mục tiêu của bài toán dự báo thời tiết đó là sử dụng các giá trị quan trắc thu thập được (nhiệt độ, độ ẩm, hướng gió, ảnh vệ tinh,...) để đưa ra các dự đoán về các trạng thái thời tiết trong tương lai. Trong vấn đề cụ thể về dự báo mưa hạn cực ngắn, một hướng tiếp cận phổ biến đó là sử dụng các ảnh ra-đa về độ phản hồi vô tuyến (reflectivity). Có hai lợi thế cho hướng tiếp cận này. Thứ nhất, dựa trên quan hệ Marshall - Palmer (quan hệ $Z - R$)

$$Z = aR^b \quad (1)$$

trong đó a, b là các hằng số thực nghiệm ta có thể ước lượng được lượng mưa từ giá trị phản hồi vô tuyến. Lợi thế thứ hai đó là bằng cách sử dụng các dữ liệu dạng ảnh, ta có thể chuyển một câu hỏi về khí tượng thành một vấn đề trong xử lý ảnh, nơi mà ta có thể sử dụng rất nhiều công cụ mạnh mẽ được phát triển trong những năm qua. Các nghiên cứu nổi bật về xử lý ảnh ra-đa bằng các mạng học sâu có thể kể đến các kiến trúc ConvLSTM [16], TrajGRU [17], PredRNN [18], SimVP [19], TSGAN [20] hay gần đây là kiến trúc NowcastNet [21].

Trong dự báo hạn cực ngắn, ra-đa thời tiết là nguồn quan trắc then chốt vì cung cấp trường phản hồi với độ phân giải thời gian cao và thông tin không gian chi tiết trong vùng giám sát, cho phép theo dõi sự hình thành, phát triển và dịch chuyển của hệ mây-mưa theo thời gian thực. Trạm ra-đa Nhà Bè cung cấp chuỗi dữ liệu quan

trắc phục vụ trực tiếp cho bài toán này, đồng thời dữ liệu của trạm đã được sử dụng trong nhiều nghiên cứu trong nước về dự báo hiện tượng thời tiết cực đoan, chẳng hạn các công trình về dự báo dông sét [22, 23], ước lượng mưa từ ra-đa [24] và ứng dụng dữ liệu mưa ra-đa trong dự báo ngập đô thị [25]. Vì vậy, để khai thác hiệu quả các đặc trưng không gian-thời gian mà ra-đa cung cấp cho dự báo hạn cực ngắn, chúng tôi lựa chọn huấn luyện mô hình học sâu trên dữ liệu ra-đa Nhà Bè.

Bài toán dự báo mưa bằng ảnh ra-đa được phát biểu cụ thể như sau: giả sử ta đã biết các ảnh ra-đa (biểu diễn toán học bằng các tensor với cỡ $C \times H \times W$) ở các thời điểm trong quá khứ $t_{-p}, \dots, t_{-1}, t_0$ dự đoán các ảnh ra-đa ở các thời điểm $t_1, \dots, t_f$ trong tương lai.

3. Số liệu sử dụng và phương pháp nghiên cứu

3.1. Khu vực nghiên cứu

Ra-đa thời tiết Nhà Bè nằm ở xã Nhà Bè, thành phố Hồ Chí Minh tại tọa độ $10^\circ 31' 39''$ vĩ độ Bắc và $106^\circ 43' 42''$ kinh độ Đông. Đài Khí tượng Thủy văn Nam Bộ là đơn vị quản lý hiện tại. Ra-đa thời tiết Nhà Bè được lắp đặt bởi các chuyên gia của công ty EEC Hoa Kỳ năm 2004, sau đó được nâng cấp một số bộ phận phần cứng và thay thế bằng phần mềm IRIS Focus phiên bản 2.0 của Công ty thiết bị đo lường Vaisala vào năm 2019. Ra-đa có tần số hoạt động từ 5500-5700MHz (băng C). Bán kính quan trắc tối đa của ra-đa là 480km và có khả năng tự động điều chỉnh góc nâng từ $0^\circ - 90^\circ$, cho phép thăm dò một cách toàn diện các khối mây theo bề rộng và chiều cao.


3.2. Số liệu sử dụng và phương pháp xử lý

Nghiên cứu sử dụng dữ liệu ra-đa cung cấp bởi trạm ra-đa thời tiết Nhà Bè trong các tháng mùa mưa (từ tháng 4 đến tháng 10) của hai năm 2022 và 2023. Mô hình học sâu sẽ được huấn luyện trên dữ liệu của năm 2022 và sẽ được kiểm thử trên dữ liệu của năm 2023. Dữ liệu ra-đa được thu thập mỗi 10 phút. Trong thời gian này


ra-đa tuần tự hoàn thành các vòng quay ở các góc nghiêng từ $0,5^\circ$ đến $5,0^\circ$ và thực hiện đo ở hai khoảng cách 120 km và 300 km. Dữ liệu ra-đa thô được lưu trữ ở định dạng SIGMET RAW, bao gồm các trường giá trị về tổng công suất (total power), độ phản hồi vô tuyến (dBz-reflectivity), vận tốc gió Doppler (V-velocity) và độ rộng phổ (spectrum width). Trong khuôn khổ của bài báo chúng tôi chỉ sử dụng giá trị về cường độ phản hồi vô tuyến.

Kiểm soát tính liên tục của chuỗi thời gian. Do đặc thù vận hành, dữ liệu ra-đa tại trạm Nhà Bè có thể xuất hiện các khoảng gián đoạn (vì lý do bảo trì, sự cố thu ghi,...), dẫn đến việc các tệp dữ liệu không luôn nối tiếp nhau đúng theo bước


thời gian 10 phút. Để đảm bảo mô hình có thể học đúng quan hệ không gian–thời gian của trường mưa tương ứng với bước lấy mẫu 10 phút, các khung hình không liên tiếp nhau không được xuất hiện trong cùng một mẫu chuỗi. Việc vi phạm điều kiện này sẽ làm sai lệch động học tiến triển mà mô hình cần học và làm giảm khả năng tổng quát hóa theo thời gian. Vì vậy, trước khi tạo mẫu chuỗi chúng tôi thực hiện bước kiểm soát chất lượng theo thời gian bằng cách chỉ giữ các dãy dữ liệu thật sự liên tiếp theo chu kỳ 10 phút (cho phép dung sai 120 giây để bù sai lệch về mốc thời gian nếu có). Mọi chuỗi có mốc thời gian liên tiếp vượt ngưỡng dung sai sẽ bị loại khỏi tập dữ liệu. Quy trình xử lý dữ liệu được tóm tắt trong Hình 1.



Hình 1. Quy trình xử lý dữ liệu ra-đa bằng thư viện Py-ART và khu vực nghiên cứu trong phạm vi 120 km xung quanh trạm ra-đa Nhà Bè.



Hình 2. Ảnh CAPPI trích xuất từ sản phẩm SIGMET ngày 22/07/2022.



Hình 3. Ảnh CAPPI trích xuất từ sản phẩm SIGMET ngày 25/10/2022.

Phần mềm Py-ART [26] được sử dụng để thực hiện bước tiền xử lý dữ liệu từ định dạng SIGMET sang các định dạng mà mô hình học sâu có thể thao tác được, cụ thể là các dữ liệu dạng tensor. Chúng tôi trích xuất sản phẩm CAPPI bằng tính năng nội suy lưới vuông từ các giá trị công ra-đa (radar gate), trong đó các mắt lưới bị khuyết về dữ liệu phản hồi vô tuyến được thay bằng giá trị 0. Tập dữ liệu sau khi xử lý bao gồm các ảnh phản hồi vô tuyến trên một diện tích $240 \text{ km} \times 240 \text{ km}$ ở 20 độ cao cách đều nhau từ 1 km đến 5 km. Dữ liệu CAPPI ở độ cao 3 km được chọn trích xuất cho quá trình huấn luyện vì độ cao này chứa nhiều nhất số điểm dữ liệu phản hồi vô tuyến. Một số ảnh CAPPI sau khi trích xuất được thể hiện trong Hình 2 và Hình 3.

Lưu ý về cách chọn các hằng số a và b ở hệ thức (1). Trong nghiên cứu này, trường cường độ mưa R (mm/h) được suy ra từ hệ số phản hồi ra-đa Z dựa theo hệ thức (1). Do trạm ra-đa Nhà Bè hiện chưa có bộ hệ số $Z - R$ được hiệu chỉnh theo số liệu đo mưa mặt đất địa phương, chúng tôi sử dụng bộ hệ số mặc định $a = 200$ và $b = 1,6$, vốn thường được dùng như cấu hình khởi tạo trong các hệ thống ra-đa. Ở phạm vi bài báo, lựa chọn hệ số $Z - R$ được giữ tương đồng cho toàn bộ các tập huấn luyện/xác thực/kiểm thử nhằm đảm bảo tính nhất quán của dữ liệu đầu vào – đầu ra và tính công bằng khi so sánh các mô hình khác nhau.

Trong bước tiền xử lý, các ảnh phản hồi vô tuyến được chuẩn hóa các ảnh kích cỡ 240×240 với giá trị trung bình mỗi pixel nằm trong đoạn $[0, 1]$ bằng công thức

$$pixel = \frac{dBZ + 10}{70} \quad (2)$$

Ma trận lượng mưa có thể thu được thông qua hệ thức

$$Z = 200R^{1,6} \Rightarrow R = \left(\frac{10^{dBZ/10}}{200} \right)^{5/8} \quad (3)$$

Sau khi qua bước chuẩn hóa, các ảnh phản hồi vô tuyến của các tháng mùa mưa năm 2022 (từ tháng 4 đến tháng 10) được sử dụng làm dữ liệu xây dựng mô hình và được chia làm ba tập: tập huấn luyện gồm dữ liệu tháng 4 đến tháng 8 dùng để huấn luyện mô hình (train set); tập xác

thực (validation set) gồm dữ liệu tháng 9 dùng để tinh chỉnh siêu tham số; và tập kiểm thử (test set) gồm dữ liệu tháng 10. Các ảnh phản hồi của tháng 6/2023 cũng được sử dụng với vai trò là một tập kiểm thử độc lập nhằm đánh giá khả năng tổng quát hóa của mô hình trên dữ liệu mới. Số lượng ảnh trong mỗi tập dữ liệu được tổng hợp ở Bảng 1.

Bảng 1. Thống kê số lượng ảnh phản hồi vô tuyến trong các tập dữ liệu

Train	Validation	Test 2022	Test 2023
21695	3523	4450	4086

Thống kê phân bố điểm mưa theo ngưỡng. Do đặc thù trường mưa từ ra-đa, dữ liệu có mức mắt cân bằng lớn giữa vùng không mưa/mưa rất nhỏ và vùng mưa vừa/mưa to. Để định lượng mức cân bằng này, tỉ lệ pixel theo các khoảng cường độ mưa R (mm/h) được thống kê trên các tập huấn luyện, xác thực và kiểm thử, với các ngưỡng 0,0; 0,5; 1,0; 2,0; 5,0; 10,0; 30,0 mm/h. Kết quả được thống kê ở Bảng 2.

Bảng 2. Tỉ lệ phần trăm số pixel thuộc các khoảng $[0; 0,5)$, $[0,5; 1)$, $[1; 2)$, $[2; 5)$, $[5; 10)$, $[10; 30)$, $[30; \infty)$ (mm/h) trên các tập dữ liệu đã phân chia

Tập dữ liệu Ngưỡng mưa (mm/h)	Train	Validati on	Test 2022	Test 2023
$[0; 0,5)$	96,55%	94,82%	94,7%	94,63%
$[0,5; 1)$	1,18%	1,59%	1,41%	1,67%
$[1; 2)$	0,91%	1,34%	1,26%	1,44%
$[2; 5)$	0,80%	1,28%	1,42%	1,33%
$[5; 10)$	0,31%	0,50%	0,64%	0,48%
$[10; 30)$	0,19%	0,35%	0,38%	0,34%
$[30; \infty)$	0,06%	0,11%	0,10%	0,11%

Từ Bảng 2 có thể thấy phần lớn pixel nằm trong khoảng $[0; 0,5)$ mm/h (xấp xỉ 94,6-96,6% tùy theo tập) trong khi các mức mưa lớn chiếm tỉ lệ rất nhỏ (chẳng hạn $R \geq 10$ mm/h chỉ chiếm khoảng 0,25-0,48%).

3.3. Thiết lập dự báo đa bước và quy trình cảnh báo 60 phút

Mô hình được huấn luyện cho bài toán dự báo một bước: từ chuỗi 6 ảnh ra-đa liên tiếp theo

chu kỳ 10 phút (tương ứng 60 phút quá khứ), mô hình dự báo ảnh mục tiêu tại thời điểm 10 phút kế tiếp. Để thực hiện dự báo đến 60 phút, phương pháp suy diễn lặp (recursive rollout) được sử dụng: dự báo tại bước trước được đưa trở lại làm một phần đầu vào để dự báo bước tiếp theo. Kí hiệu $\mathbf{X}_t$ là trường mưa tại thời điểm t , mô hình một bước $f(\cdot)$ được cho bởi

$$\hat{X}_{t+10} = f(X_{t-50}, \dots, X_{t-10}, X_t) \quad (4)$$

Với $k = 2, \dots, 6$, dự báo $\hat{X}_{t+10k}$ được sinh bằng cách trượt cửa sổ đầu vào và ghép thêm vào dự báo gần nhất:

$$\hat{X}_{t+10k} = f(\hat{X}_{t-50+10(k-1)}, \dots, X_t, \hat{X}_{t+10}, \dots, \hat{X}_{t+10(k-1)}) \quad (5)$$

Như vậy, tại mỗi thời điểm cập nhật dữ liệu ra-đa, hệ thống có thể thực hiện một chuỗi dự báo 6 mốc tương ứng 10, 20, 30, 40, 50 và 60 phút trong tương lai.

3.4. Phương pháp xây dựng mô hình học sâu dự đoán ảnh ra-đa

3.4.1. Mô tả kiến trúc sử dụng

Mô hình đề xuất bởi nhóm tác giả trong [27] được thiết kế với mục tiêu thu thập và trích xuất các đặc trưng phức tạp về không gian-thời gian hiện hữu trong dữ liệu ảnh ra-đa. Mô hình được xây dựng từ các thành phần cơ bản: kiến trúc mạng tích chập CNN [28], kiến trúc ConvLSTM [16], cơ chế Axial Attention [29]. Các kiến trúc cơ bản này đã được sử dụng rất thành công trong các bài toán xử lý chuỗi hình ảnh.

- Mạng Convolutional LSTM (gọi tắt là ConvLSTM) là một kiến trúc kết hợp giữa các mạng thần kinh tích chập (Convolutional Neural Networks - CNNs) và các mạng bộ nhớ ngắn hạn - dài hạn (Long-Short Term Memory - LSTM). ConvLSTM được thiết kế để giải quyết các bài toán dự báo các dữ liệu liên quan đến không gian-thời gian như chuỗi video. Trong thực tế kiến trúc này cho thấy khả năng dự đoán khá tốt nhờ tận dụng được khả năng trích xuất các phụ thuộc về thời gian của LSTM và khả năng trích xuất các tương quan về không gian của kiến trúc tích chập.

- Cơ chế axial attention, đề xuất bởi Ho và cộng sự [29] là một mở rộng của cơ chế attention [30] dùng trong các kiến trúc Transformer. Cơ chế này hoạt động bằng cách phân tích một attention hai chiều thành hai attention một chiều theo chiều rộng và chiều cao. Hướng tiếp cận này cho phép tối ưu hóa khối lượng tính toán đồng thời vẫn bảo toàn được trường thị giác toàn cục.

Kiến trúc học sâu được chúng tôi đề xuất [27] tuân theo lược đồ mã hóa - giải mã (encoder - decoder) điển hình. Trong giai đoạn mã hóa, dãy các ảnh đầu vào được truyền qua một cụm gồm ba lớp ConvLSTM và cụm hai lớp tích chập 3 chiều nhằm trích xuất các đặc trưng về không-thời gian. Kết quả đầu ra sau đó được truyền qua khối Axial Attention nhằm thu thập các quan hệ tầm xa trong dãy ảnh đầu vào. Trong giai đoạn giải mã, chúng tôi sử dụng một khối tăng mẫu (upsampling) bao gồm hai lớp tích chập ba chiều với hàm kích hoạt ReLU và cơ chế dropout để upscale các đặc trưng đã trích xuất trong giai đoạn mã hóa. Cuối cùng hàm kích hoạt sigmoid được chọn để đưa các giá trị pixel về khoảng hợp lý. Nhờ được tiếp cận với phần cứng mạnh mẽ hơn, trong bài báo này chúng tôi đưa ra một số thay đổi so với kiến trúc ban đầu trong [27] nhằm gia tăng chất lượng dự đoán của mô hình. Chúng tôi sử dụng dãy 6 ảnh đầu vào với cỡ 240×240 thay vì dãy 5 ảnh với cỡ 128×128 như trong [27]. Các thay đổi này cho phép mô hình khai thác cửa sổ quan trắc quá khứ dài hơn (60 phút) với độ phân giải không gian cao hơn, qua đó cải thiện chất lượng dự báo 10 phút kế tiếp trong chu kỳ cập nhật của ra-đa. Kiến trúc học sâu sử dụng trong bài báo này được minh họa trong Hình 4.

3.4.2. Hàm mất mát sử dụng

Để giảm thiên lệch do sự mất cân bằng lớn giữa vùng không mưa/mưa rất nhỏ và vùng mưa vừa/mưa to, hàm MAE có trọng số, kí hiệu là MAE_w làm hàm mất mát. Công thức của MAE_w như sau:

$$MAE_w = \frac{\sum_{i=1}^n w(R_i) |R_i - \hat{R}_i|}{\sum_{i=1}^n w(R_i)} \quad (6)$$

trong đó R_i và $\hat{R}_i$ lần lượt là lượng mưa thực tế và dự báo tại pixel i ; n là số pixel được tính và $w(R_i)$ là trọng số phụ thuộc vào mức mưa của

pixel i . Ở đây $w(R)$ được cho theo từng khoảng như sau:


$$w(R) = \begin{cases} w_0, 0 \leq R < 0,5 \\ w_1, 0,5 \leq R < 1 \\ w_2, 1 \leq R < 2 \\ w_3, 2 \leq R < 5 \\ w_4, 5 \leq R < 10 \\ w_5, 10 \leq R < 30 \\ w_6, R \geq 30 \end{cases} \quad (7)$$

trong đó các trọng số w_k được chọn tăng dần theo mức mưa, tỉ lệ nghịch với tần suất xuất hiện trong dữ liệu nhằm cân bằng đóng góp của các nhóm pixel hiếm vào hàm mất mát. Một lựa chọn

khả thi là $w_k \propto \frac{1}{f_k + \varepsilon}$ trong đó f_k là tỉ lệ pixel thuộc khoảng thứ k lấy từ Bảng 2 và ε là một hằng số nhỏ để chia cho 0; sau đó chuẩn hóa w_k để tránh gradient quá lớn. Trong thí nghiệm, chúng tôi sử dụng bộ trọng số (1,0; 6,0, 8,0; 9,0; 9,0; 10,0; 10,0).

3.4.3. Các tiêu chí đánh giá mô hình học sâu

Chúng tôi sử dụng các tiêu chí sau đây để đánh giá chất lượng dự đoán của mô hình học sâu: RMSE, MAE, SSIM, CSI, FAR, POD, PC và hệ số tương quan Pearson r . Với giá trị quan trắc $\mathbf{y}$ và kết quả dự báo của mô hình $\hat{\mathbf{y}}$ các tiêu chí trên có công thức như sau:



Hình 4. Kiến trúc học sâu đề xuất.

Root Mean Square Error (RMSE):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

Mean Absolute Error (MAE):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

Structural Similarity Index Measure (SSIM):

Chỉ số này bắt nguồn từ lĩnh vực xử lý ảnh. Nó được dùng để đo sự tương đồng về cấu trúc của hai ảnh. Với hai ảnh x và y công thức của SSIM có dạng như sau:

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_x\sigma_y + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (10)$$

trong đó μ_x, μ_y lần lượt là giá trị pixel trung bình của x và y ; σ_x, σ_y lần lượt là phương sai của x và y ; σ_{xy} là hiệp phương sai của x và y . Cuối cùng c_1 và c_2 là hai hằng số của để đảm bảo tính ổn định của biểu thức.

Critical Success Index (CSI):

$$\text{CSI} = \frac{\text{hits}}{\text{hits} + \text{misses} + \text{false alarms}} \quad (11)$$

Công thức tính CSI được cho bởi tỉ lệ các sự kiện được nhận diện đúng trên tổng số các sự kiện xảy ra. Giá trị CSI cao tương ứng với khả năng nhận diện tốt.

False Alarms Ratio (FAR):

$$\text{FAR} = \frac{\text{false alarms}}{\text{hits} + \text{false alarms}} \quad (12)$$

Giá trị FAR cho biết tỉ lệ dự báo không trên tổng số các dự báo có mưa xảy ra. Giá trị FAR thấp tương ứng với khả năng dự báo không thấp.

Probability of Detection (POD):

$$\text{POD} = \frac{\text{hits}}{\text{hits} + \text{misses}} \quad (13)$$

Giá trị POD đo lường khả năng xuất hiện đúng các vùng có mưa. POD càng cao thì mô hình càng ít bỏ sót mưa.

Percentage Correct (PC):

$$\text{PC} = \frac{\text{hits} + \text{true negatives}}{\text{misses} + \text{false alarms} + \text{hits} + \text{true negatives}} \quad (14)$$

Giá trị PC cho biết tỉ lệ các dự báo đúng trên tổng số các dự báo. PC cao phản ánh khả năng dự báo chính xác.

Hệ số tương quan Pearson

Để định lượng mức độ đồng biến tuyến tính giữa trường mưa dự báo và quan trắc, chúng tôi sử dụng hệ số tương quan Pearson r , cho bởi công thức:

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (15)$$

trong đó $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ và $\bar{\hat{y}} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i$.

4. Kết quả và thảo luận

Mô hình được viết bằng ngôn ngữ Python dựa trên thư viện về học sâu PyTorch. Chúng tôi thực hiện huấn luyện và đánh giá mô hình trên GPU NVIDIA A100, cung cấp bởi cụm máy tính toán hiệu năng cao của trường Đại học Bách khoa Thành phố Hồ Chí Minh.

Chúng tôi đánh giá mô hình theo hai nhóm chỉ số:

- Hồi quy theo pixel: SSIM, MAE và RMSE được tính trên toàn bộ pixel và chỉ trên các pixel mưa. Trong đó tập pixel mưa được định nghĩa bởi giá trị quan trắc $R_{true} \geq 0,5 \text{ mm/h}$ nhằm tránh việc sai số bị pha loãng bởi tỉ lệ pixel không mưa rất lớn.

- Phân loại theo ngưỡng mưa $\tau \in \{0,5; 1,0; 2,0; 5,0; 10,0\}$ (mm/h): CSI, POD, FAR, PC. Với mỗi ngưỡng τ , pixel được xem là mưa nếu $R \geq \tau$.

Ngoài ra, chúng tôi báo cáo hệ số tương quan Pearson r giữa mưa dự báo và quan trắc, tính trên toàn bộ pixel và pixel mưa.

4.1. So sánh định lượng giữa các mô hình trên tập kiểm thử 10/2022 và 06/2023

Chúng tôi so sánh ba mô hình: i) Mô hình đề xuất; ii) ConvLSTM thuần túy [16]; và iii) SimVP [19], trên hai tập kiểm thử: 10/2022 và 06/2023. SimVP là một kiến trúc đơn giản nhưng hiệu quả cho bài toán video prediction, trong đó

chuỗi khung hình đầu vào được mã hóa bằng các lớp tích chập để trích xuất đặc trưng không gian, sau đó một mô-đun xử lý theo chiều thời gian thực hiện mô hình hóa động lực biến thiên của đặc trưng theo chuỗi, và cuối cùng một bộ giải mã tích chập tái tạo khung hình dự báo. Do chủ yếu dựa trên các phép tích chập và thiết kế gọn nhẹ, SimVP thường cho tốc độ suy luận tốt và là một mô hình đối sánh mạnh trong nhiều bài toán dự báo chuỗi ảnh.

Để đảm bảo tính khách quan khi đối sánh, cả ba mô hình đều được huấn luyện và đánh giá trong cùng một điều kiện thực nghiệm: sử dụng cùng bộ dữ liệu (sau khi đã lọc để đảm bảo chuỗi thời gian liên tiếp), cùng cách tạo mẫu (6 khung hình quá khứ theo bước 10 phút để dự báo 10 phút kế tiếp), cùng cách tiền xử lý, cùng hàm mất mát MAE_w . Về huấn luyện, tất cả mô hình được tối ưu với AdamW (tốc độ học 10^{-4} , weight decay 10^{-4}) trong 50 epoch. Tốc độ học được điều chỉnh bằng schedule ReduceLROnPlateau với tiêu chí cực đại hóa chỉ số đánh giá trên tập xác thực, hệ số giảm 0,5 và độ kiên nhẫn 5. Mô hình tốt nhất được chọn dựa trên điểm tổng hợp $CSI_{0,5} + CSI_{1,0} + CSI_{2,0} - 0,2MAE_{rainy}$ trong đó MAE_{rainy} được tính trên các pixel mưa ($R_{true} \geq 0,5 \text{ mm/h}$). Kết quả so sánh được trình bày trong Bảng 3 và Bảng 4.

Kết quả trong Bảng 3 và Bảng 4 xác nhận mô hình đề xuất đạt SSIM cao nhất trên cả hai tập kiểm thử và đồng thời giảm sai số trên các pixel mưa so với hai mô hình đối chứng (ConvLSTM thuần túy và SimVP). Trên tập kiểm thử 10/2022, SSIM của mô hình đề xuất đạt 0,793, trong khi MAE (rainy) và RMSE (rainy) lần lượt giảm từ 2,511 và 7,135 (ConvLSTM) cũng như 2,460 và 6,745 (SimVP) xuống 2,226 và 6,432. Trên tập kiểm thử độc lập 06/2023, mô hình đề xuất tiếp tục duy trì hiệu năng tốt với SSIM = 0,790, đồng thời cho sai số thấp hơn trên pixel mưa: MAE (rainy) và RMSE (rainy) đạt 2,095 và 6,600, so với 2,281 và 7,117 (ConvLSTM) và 2,235 và 6,764 (SimVP). Những kết quả này cho thấy mô hình đề xuất cải thiện đáng kể chất lượng dự báo định lượng trên vùng mưa và duy trì tính ổn định khi kiểm thử theo thời gian.

Bảng 3. Các chỉ số hồi quy SSIM/MAE/RMSE trên tập kiểm thử 10/2022

Mô hình	SSIM	MAE (all)	MAE (rainy)	RMSE (all)	RMSE (rainy)
ConvLSTM	0,774	0,150	2,511	1,648	7,135
SimVP	0,780	0,166	2,460	1,565	6,745
Đề xuất	0,793	0,134	2,225	1,485	6,431

Bảng 4. Các chỉ số hồi quy SSIM/MAE/RMSE trên tập kiểm thử 06/2023

Mô hình	SSIM	MAE (all)	MAE (rainy)	RMSE (all)	RMSE (rainy)
ConvLSTM	0,773	0,143	2,281	1,662	7,117
SimVP	0,776	0,159	2,235	1,589	6,764
Đề xuất	0,789	0,132	2,095	1,541	6,600

4.2. Đánh giá phân loại theo ngưỡng: CSI, POD, FAR, PC

Kết quả phân loại theo các ngưỡng mưa 0,5; 1; 2; 5; 10 mm/h trên tập kiểm thử 10/2022 được tổng hợp trong các Bảng 5a, 5b, 5c, 5d, 5e.

Bảng 5a. Kết quả phân loại theo ngưỡng 0,5 mm/h trên tập kiểm thử 10/2022

Mô hình	CSI@0,5	POD@0,5	FAR@0,5	PC@0,5
ConvLSTM	0,6773	0,8336	0,2168	0,9793
SimVP	0,5278	0,9602	0,4604	0,9552
Đề xuất	0,7016	0,8693	0,2156	0,9807

Bảng 5b. Kết quả phân loại theo ngưỡng 1 mm/h trên tập kiểm thử 10/2022

Mô hình	CSI@1	POD@1	FAR@1	PC@1
ConvLSTM	0,6593	0,7978	0,2085	0,9843
SimVP	0,6238	0,8133	0,2720	0,9813
Đề xuất	0,6947	0,8319	0,1918	0,9861

Bảng 5c. Kết quả phân loại theo ngưỡng 2 mm/h trên tập kiểm thử 10/2022

Mô hình	CSI@2	POD@2	FAR@2	PC@2
ConvLSTM	0,6050	0,7220	0,2112	0,9880
SimVP	0,5828	0,7082	0,2331	0,9871
Đề xuất	0,6471	0,7531	0,1786	0,9896

Bảng 5d. Kết quả phân loại theo ngưỡng 5 mm/h trên tập kiểm thử 10/2022

Mô hình	CSI@5	POD@5	FAR@5	PC@5
ConvLSTM	0,4562	0,5367	0,2475	0,9928
SimVP	0,4501	0,5503	0,2881	0,9924
Đề xuất	0,5238	0,6110	0,2141	0,9938

Bảng 5e. Kết quả phân loại theo ngưỡng 10 mm/h trên tập kiểm thử 10/2022

Mô hình	CSI@10	POD@10	FAR@10	PC@10
ConvLSTM	0,3259	0,3738	0,2821	0,9963
SimVP	0,3642	0,4494	0,3423	0,9962
Đề xuất	0,4239	0,4935	0,2499	0,9967

Kết quả phân loại theo các ngưỡng mưa 0,5; 1; 2; 5; 10 mm/h trên tập kiểm thử 6/2023 được tổng hợp trong các Bảng 6a, 6b, 6c, 6d, 6e.

Bảng 6a. Kết quả phân loại theo ngưỡng 0,5 mm/h trên tập kiểm thử 06/2023

Mô hình	CSI@0,5	POD@0,5	FAR@0,5	PC@0,5
ConvLSTM	0,6746	0,8389	0,2250	0,9783
SimVP	0,5211	0,9596	0,4672	0,9527
Đề xuất	0,6896	0,8661	0,2281	0,9791

Bảng 6b. Kết quả phân loại theo ngưỡng 1 mm/h trên tập kiểm thử 06/2023

Mô hình	CSI@1	POD@1	FAR@1	PC@1
ConvLSTM	0,6489	0,7953	0,2209	0,9841
SimVP	0,6112	0,7951	0,2745	0,9813
Đề xuất	0,6734	0,8187	0,2086	0,9853

Bảng 6c. Kết quả phân loại theo ngưỡng 2 mm/h trên tập kiểm thử 06/2023

Mô hình	CSI@2	POD@2	FAR@2	PC@2
ConvLSTM	0,5864	0,7121	0,2314	0,9887
SimVP	0,5602	0,6893	0,2506	0,9878
Đề xuất	0,6189	0,7367	0,2053	0,9898

Bảng 6d. Kết quả phân loại theo ngưỡng 5 mm/h trên tập kiểm thử 06/2023

Mô hình	CSI@5	POD@5	FAR@5	PC@5
ConvLSTM	0,4691	0,5652	0,2660	0,9941
SimVP	0,4620	0,5721	0,2941	0,9938
Đề xuất	0,5204	0,6227	0,2400	0,9947

Bảng 6e. Kết quả phân loại theo ngưỡng 10 mm/h trên tập kiểm thử 06/2023

Mô hình	CSI@10	POD@10	FAR@10	PC@10
ConvLSTM	0,3669	0,4311	0,2888	0,9967
SimVP	0,3860	0,4772	0,3313	0,9966
Đề xuất	0,4379	0,5221	0,2690	0,9970

Các kết quả phân loại theo ngưỡng mưa trong các Bảng 5a–5e và Bảng 6a–6e chỉ ra rằng mô hình đề xuất đạt CSI cao nhất ở tất cả các ngưỡng (0,5; 1; 2; 5; 10 mm/h) trên cả hai tập kiểm thử. Đáng chú ý, ưu thế được thể hiện rõ hơn ở các ngưỡng mưa vừa–to (5 và 10 mm/h). Ví dụ, trên tập 10/2022 tại ngưỡng 10 mm/h, CSI của mô hình đề xuất đạt 0,4239, cao hơn ConvLSTM (0,3259) và SimVP (0,3642); trên tập 06/2023 tại ngưỡng 10 mm/h, CSI của mô hình đề xuất đạt 0,4379, cao hơn ConvLSTM (0,3669) và SimVP (0,3860).

So sánh POD và FAR cho thấy sự khác biệt về mức độ cân bằng giữa khả năng phát hiện mưa và kiểm soát cảnh báo giả giữa các mô hình. SimVP đạt POD rất cao ở ngưỡng 0,5 mm/h (xấp xỉ 0,96) nhưng đồng thời có FAR lớn (xấp xỉ 0,47), phản ánh xu hướng dự báo dư ở ngưỡng thấp và làm suy giảm CSI. Ngược lại, mô hình đề xuất duy trì POD cao đồng thời kiểm soát FAR tốt hơn, do đó đạt CSI vượt trội một cách nhất quán. Chỉ số PC nhìn chung cao ở cả ba mô hình do dữ liệu mất cân bằng không mưa/mưa; vì vậy, CSI cùng với POD và FAR phản ánh rõ hơn chất lượng dự báo theo ngưỡng mưa trong bối cảnh nghiệp vụ.

4.3. Tương quan Pearson và phân tích scatter plot

Đối với mô hình đề xuất, hệ số tương quan Pearson được tính trên các tập kiểm thử như sau:


10/2022: $r_{\text{all}} = 0,7230$ và $r_{\text{rainy}} = 0,6496$.

06/2023: $r_{\text{all}} = 0,6876$ và $r_{\text{rainy}} = 0,6155$


Hai scatter plot giữa lượng mưa dự báo và quan trắc (chỉ tính trên các pixel có mưa) tương ứng với hai tập kiểm thử được cho trong Hình 5a và Hình 5b.

Hệ số tương quan Pearson phản ánh việc mức độ đồng biến tuyến tính giữa trường mưa dự báo và quan trắc được duy trì ổn định trên hai tập

kiểm thử: trên tập 10/2022, $r_{\text{all}} = 0,7230$ và $r_{\text{rainy}} = 0,6496$; trên tập 06/2023, $r_{\text{all}} = 0,6876$ và $r_{\text{rainy}} = 0,6155$. Giá trị r_{all} cao hơn r_{rainy} trên cả hai tập kiểm thử tương thích với đặc trưng mất cân bằng của dữ liệu mưa: vùng không mưa/mưa nhỏ chiếm ưu thế giúp quan hệ tuyến tính dễ đạt được hơn, trong khi tương quan trên pixel mưa phản ánh đúng hơn độ khó của dự báo cường độ mưa. Correlation plot cho thấy xu hướng đánh giá thấp mưa lớn (nhiều điểm nằm dưới đường thẳng $y = x$ ở vùng R_{true} lớn). Kết quả này phù hợp với quan sát rằng chất lượng suy giảm ở các ngưỡng mưa rất lớn là thách thức phổ biến của nowcasting dựa trên ảnh radar.




Hình 5a. Scatter plot giữa lượng mưa dự báo và quan trắc trên tập kiểm thử 10/2022.




Hình 5b. Scatter plot giữa lượng mưa dự báo và quan trắc trên tập kiểm thử 06/2023.

4.4. Minh họa định tính


Để đánh giá trực quan khả năng nắm bắt hình thái và biên dạng vùng mưa, chúng tôi trình bày một số trường hợp tiêu biểu cho cả hai giai đoạn kiểm thử. Minh họa cho kết quả đối chiếu giữa bản đồ mưa dự đoán và bản đồ mưa quan trắc được thể hiện trong Hình 6a, 6b, 6c (10/2022) và Hình 7a, 7b, 7c (06/2023). Mỗi hình bao gồm các bản đồ mưa trong 1 giờ trước (từ thời điểm $t - 50$ đến thời điểm t), bản đồ mưa ở thời điểm $t + 10$ và bản đồ mưa dự đoán (được gắn nhãn prediction).




Hình 6a. So sánh bản đồ mưa dự đoán và bản đồ mưa quan trắc ngày 01/10/2022.




Hình 6b. So sánh bản đồ mưa dự đoán và bản đồ mưa quan trắc ngày 02/10/2022.




Hình 6c. So sánh bản đồ mưa dự đoán và bản đồ mưa quan trắc ngày 10/10/2022.



Hình 7a. So sánh bản đồ mưa dự đoán và bản đồ mưa quan trắc ngày 01/06/2023.



Hình 7b. So sánh bản đồ mưa dự đoán và bản đồ mưa quan trắc ngày 04/06/2023.



Hình 7c. So sánh bản đồ mưa dự đoán và bản đồ mưa quan trắc ngày 21/06/2023.

So sánh trực quan giữa các bản đồ mưa dự báo và trường mưa quan trắc cho phép khẳng định mô hình đề xuất tái hiện tương đối tốt cấu trúc và hình thái không gian của các vùng mưa trong hạn dự báo 10 phút. Cụ thể, mô hình thường nắm bắt đúng vị trí tương đối, hướng dịch chuyển, cũng như phạm vi và biên dạng của các dải/ô mưa chính; các vùng mưa liên tục được dự báo có tính mạch lạc và ít xuất hiện các mảng nhiễu rời rạc, qua đó phản ánh khả năng khai thác đặc trưng không gian–thời gian hiệu quả. Trong nhiều trường hợp, mô hình cũng thể hiện năng lực duy trì được hình thái vùng mưa vừa–to và

xu hướng biến thiên theo thời gian (mở rộng/thu hẹp) tương đối phù hợp với quan trắc.

Tuy nhiên, các hình minh họa cũng bộc lộ một số hạn chế đặc trưng của các mô hình dự báo dựa trên ảnh. Thứ nhất, dự báo thường có xu hướng làm trơn trường mưa, khiến ranh giới vùng mưa trở nên kém sắc nét so với quan trắc và đôi khi làm mờ các cấu trúc quy mô nhỏ. Thứ hai, mô hình khó tái hiện các đỉnh mưa cực đại: tại các ổ mưa rất mạnh, giá trị cực trị thường bị đánh giá thấp và vùng cực đại có xu hướng bị trải đều ra lân cận. Hạn chế này cho thấy việc chất lượng dự báo suy giảm ở các ngưỡng mưa lớn và phản ánh thách thức chung của nowcasting mưa đối lưu: các cực trị phát triển nhanh và biến động mạnh khó được suy ra đầy đủ chỉ từ chuỗi quan trắc quá khứ ngắn.

4.5. Đánh giá dự báo đa bước đến 60 phút

Để đáp ứng yêu cầu cảnh báo sớm 60 phút, chúng tôi đánh giá mô hình theo các mốc dự báo 10, 20, 30, 40, 50, 60 phút bằng phương pháp suy diễn lặp ở Mục 3.3. Các chỉ số được tính riêng theo từng mốc dự báo trên tập kiểm thử 10/2022 và tập kiểm thử độc lập 06/2023.

Bảng 7a. Chỉ số hồi quy theo các hạn dự báo trên tập dữ liệu 10/2022

Hạn dự báo (phút)	SSIM	MAE (rainy)	RMSE (rainy)
10	0,7927	2,2251	6,4311
20	0,7527	2,8947	7,7645
30	0,7342	3,3038	8,4736
40	0,7235	3,5560	8,8378
50	0,7153	3,7099	9,0101
60	0,7081	3,8085	9,0959

Bảng 7b. Chỉ số hồi quy theo các mốc dự báo trên tập dữ liệu 6/2023

Hạn dự báo (phút)	SSIM	MAE (rainy)	RMSE (rainy)
10	0,7892	2,0947	6,6005
20	0,7396	2,6603	7,7186
30	0,7149	2,9991	8,3188
40	0,7002	3,2082	8,6421
50	0,6891	3,3358	8,7986
60	0,6798	3,4148	8,8724

Kết quả ở các Bảng 7a và 7b phản ánh sự tăng trưởng của sai số theo hạn dự báo. Việc sai số tăng dần phù hợp với lỗi tích lũy khi thực hiện dự báo trượt và do bản chất khó dự báo của các hệ mưa đối lưu khi hạn dự báo tăng. Tuy vậy, SSIM vẫn duy trì ở mức tương đối (xấp xỉ 0,68–0,71 tại 60 phút), phản ánh mô hình vẫn nắm bắt được cấu trúc quy mô lớn của vùng mưa ở hạn dài hơn, dù chi tiết cực trị suy giảm.

Bảng 8a. Chỉ số phân loại theo các mốc dự báo trên tập dữ liệu 10/2022

Hạn dự báo (phút)	CSI@0,5	FAR@0,5	CSI@10	FAR@10
10	0,7016	0,2156	0,4239	0,2499
20	0,5928	0,2915	0,2042	0,3326
30	0,5150	0,3425	0,0731	0,4300
40	0,4550	0,3824	0,0206	0,5439
50	0,4054	0,4204	0,0059	0,6496
60	0,3647	0,4574	0,0020	0,6826

Bảng 8b. Chỉ số phân loại theo các mốc dự báo trên tập dữ liệu 6/2023

Hạn dự báo (phút)	CSI@0,5	FAR@0,5	CSI@10	FAR@10
10	0,6896	0,2281	0,4379	0,2690
20	0,5730	0,3173	0,2369	0,3426
30	0,4940	0,3779	0,1012	0,4095
40	0,4358	0,4250	0,0354	0,5029
50	0,3898	0,4668	0,0112	0,6194
60	0,3522	0,5052	0,0036	0,7195

Kết quả ở Bảng 8a và 8b cho thấy ở ngưỡng mưa nhẹ (0,5 mm/h), CSI giảm dần khi hạn dự báo tăng nhưng vẫn đạt khoảng 0,35 tại 60 phút, cho thấy mô hình vẫn hữu ích để theo dõi xu thế và phạm vi vùng mưa trong cửa sổ cảnh báo 20–60 phút. Ngược lại, ở ngưỡng mưa lớn (10 mm/h), CSI suy giảm nhanh đồng thời FAR tăng mạnh khi hạn dự báo tăng, phản ánh hạn chế phổ biến của phương pháp dự báo ảnh đối với cực trị mưa mạnh trong hạn dự báo dài hơn.

4.6. Tổng kết

Qua các kết quả thực nghiệm đã trình bày có thể nhận thấy:

- So sánh mô hình. Mô hình đề xuất đạt hiệu năng tốt nhất một cách nhất quán trên cả các chỉ

số hồi quy (SSIM/MAE/RMSE) và các chỉ số phân loại theo ngưỡng (CSI/POD/FAR). So với ConvLSTM thuần túy, việc bổ sung cơ chế khai thác ngữ cảnh không gian–thời gian giúp tăng khả năng nắm bắt cấu trúc vùng mưa; so với SimVP, mô hình đề xuất đạt cân bằng tốt hơn giữa phát hiện mưa và hạn chế cảnh báo giả (FAR thấp hơn).

- Khả năng tổng quát theo thời gian. Kết quả trên tập kiểm thử 06/2023 duy trì gần với 10/2022 (SSIM xấp xỉ 0,79; CSI ở 0,5 mm/h ~0,69 và ở 10 mm/h ~0,44), cho thấy mô hình có khả năng tổng quát theo năm tương đối tốt trong điều kiện dữ liệu được kiểm soát tính liên tục theo thời gian và sử dụng hàm mất mát có trọng số.

- Mở rộng cảnh báo 60 phút: Trên cơ sở mô hình dự báo một bước 10 phút, nghiên cứu triển khai suy diễn lặp để thực hiện chuỗi dự báo tại các mốc 10–60 phút theo cơ chế cập nhật cuộn chiếu. Kết quả đánh giá theo từng hạn dự báo cho thấy kỹ năng suy giảm dần do tích lũy sai số, tuy nhiên dự báo vẫn hữu ích để theo dõi xu thế và phạm vi vùng mưa trong cửa sổ cảnh báo 20–60 phút (đặc biệt ở các ngưỡng mưa thấp–vừa).

Giới hạn còn tồn tại. Scatter plot và đánh giá theo ngưỡng lớn cho thấy xu hướng đánh giá thấp mưa lớn và làm trơn các cấu trúc cực trị.

5. Kết luận

Bài báo đề xuất một mô hình học sâu mới dựa trên các kiến trúc hiện đại (CNN, ConvLSTM, Axial Attention) nhằm giải quyết bài toán dự báo mưa hạn cực ngắn từ phản hồi ra-đa của trạm Nhà Bè. Mô hình được huấn luyện theo thiết lập dự báo một bước 10 phút (từ 60 phút quá khứ), đồng thời được mở rộng sang dự báo đa bước đến 60 phút bằng phương pháp suy diễn lặp (recursive rollout) với mục đích phục vụ quy trình cảnh báo theo các mốc 10–60 phút. Trên tập kiểm thử 10/2022 và kiểm thử độc lập 6/2023, mô hình đạt chất lượng cao ở hạn 10 phút (SSIM xấp xỉ 0,79; CSI@0,5 khoảng 0,69–0,70) và vẫn duy trì mức kỹ năng hữu ích ở hạn 60 phút (SSIM khoảng 0,68–0,71; CSI@0,5 khoảng 0,35–0,36), qua đó phù hợp để theo dõi xu thế và phạm vi vùng mưa trong cửa sổ cảnh

báo 20–60 phút. Về khả năng ứng dụng, cần tính đến độ trễ dữ liệu ra-đa và thời gian suy luận, do đó trong vận hành nên kết hợp cơ chế cập nhật cuộn chiếu và điều chỉnh phần đầu hạn dự báo cho phù hợp. Các hạn chế chính vẫn nằm ở xu hướng làm trơn trường mưa và khó tái hiện các cực trị mưa lớn khi hạn dự báo tăng.

Trong tương lai, nhóm tác giả sẽ tiếp tục thử nghiệm với các kiến trúc học sâu mới với mục tiêu khắc phục điểm yếu nêu trên cũng như thử nghiệm với các bộ dữ liệu thời tiết khác và tinh chỉnh mô hình để đạt độ chính xác cao hơn. Một hướng nghiên cứu triển vọng khác đó là sử dụng các nguồn dữ liệu thời tiết đa nguồn nhằm giúp nắm bắt chính xác hơn sự biến động của các yếu tố thời tiết.

Lời cảm ơn

Bài báo này là một phần kết quả của đề tài cấp Bộ Nông nghiệp và Môi trường “Nghiên cứu ứng dụng trí tuệ nhân tạo và phân tích dữ liệu lớn đa nguồn trong dự báo, cảnh báo dông sét, mưa đá”, mã số TNMT.2024.06.06. Nhóm tác giả trân trọng cảm ơn Trung tâm Ươm tạo Doanh nghiệp Công nghệ của Trường Đại học Bách khoa, Đại học Quốc gia Thành phố Hồ Chí Minh đã hỗ trợ hạ tầng tính toán phục vụ quá trình thực hiện nghiên cứu. Nhóm tác giả cũng xin chân thành cảm ơn Ban Biên tập và các phản biện về những nhận xét, góp ý xác đáng và chi tiết, qua đó giúp chúng tôi rà soát, chỉnh sửa và hoàn thiện bản thảo cả về nội dung lẫn hình thức trình bày.

Lời cam đoan

Nhóm 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.

Tài liệu tham khảo

- [1] J. Coiffier, Fundamentals of Numerical Weather Prediction, Cambridge University Press,

- Cambridge, 2011,
<https://doi.org/10.1017/CBO9780511734458>.
- [2] M. V. Khiem, W.-C. Woo, W.-K. Wong, S. L. Yeung, D. D. Tien, M. K. Hung, D. D. Quan, P. T. P. Dung, N. T. Nga, C. T. H. Trang, Case Study of Using the Blending Radar-Numerical Weather Prediction Product in Nowcasting, *VNU Journal of Science: Earth and Environmental Sciences*, Vol. 37, No. 3, 2021, pp. 63-72,
<https://doi.org/10.25073/2588-1094/vnuces.4686>.
 - [3] M. K. Hung, D. D. Tien, D. D. Quan, T. A. Duc, P. T. P. Dung, L. R. Hole, H. G. Nam, Assessments of Use of Blended Radar-Numerical Weather Prediction Product in Short-Range Warning of Intense Rainstorms in Localized Systems (SWIRLS) for Quantitative Precipitation Forecast of Tropical Cyclone Landfall on Vietnam's Coast, *Atmosphere*, Vol. 14, No. 8, 2023, Article 1201,
<https://doi.org/10.3390/atmos14081201>.
 - [4] P. Bauer, A. Thorpe, G. Brunet, The Quiet Revolution of Numerical Weather Prediction, *Nature*, Vol. 525, No. 7567, 2015, pp. 47-55,
<https://doi.org/10.1038/nature14956>.
 - [5] J. Leinonen, U. Hamann, U. Germann, Seamless Lightning Nowcasting with Recurrent-Convolutional Deep Learning, *Artificial Intelligence for the Earth Systems*, Vol. 1, No. 4, 2022, Article e220043,
<https://doi.org/10.1175/AIES-D-22-0043.1>.
 - [6] J. Leinonen, U. Hamann, I. V. Sideris, U. Germann, Thunderstorm Nowcasting with Deep Learning: A Multi-Hazard Data Fusion Model, *Geophysical Research Letters*, Vol. 50, No. 8, 2023, Article e2022GL101626,
<https://doi.org/10.1029/2022GL101626>.
 - [7] S. Ravuri, K. Lenc, M. Willson, D. Kangin, R. Lam, P. Mirowski, M. Fitzsimons, M. Athanassiadou, S. Kashem, S. Madge, R. Prudden, A. Mandhane, A. Clark, A. Brock, K. Simonyan, R. Hadsell, N. Robinson, E. Clancy, A. Arribas, S. Mohamed, Skilful Precipitation Nowcasting Using Deep Generative Models of Radar, *Nature*, Vol. 597, No. 7878, 2021, pp. 672-677,
<https://doi.org/10.1038/s41586-021-03854-z>.
 - [8] C. T. H. Trang, L. Q. Dao, T. H. Hoang, L. V. Hung, B. Q. Hung, M. K. Hung, N. T. Hang, D. T. Trang, D. D. Tien, D. D. Quan, H. G. Nam, Application of Machine Learning Models to Geostationary Satellite Data for Tropical Cyclone Identification and Early Warning over the Western North Pacific and the East Sea, *Vietnam Journal of Hydrometeorology*, No. 764, 2024, pp. 1-14,
[https://doi.org/10.36335/VNJHM.2024\(764\).1-14](https://doi.org/10.36335/VNJHM.2024(764).1-14) (in Vietnamese).
 - [9] T.-Y. Lin, P. Goyal, R. Girshick, K. He, P. Dollár, Focal Loss for Dense Object Detection, 2017 IEEE International Conference on Computer Vision (ICCV), 2017, pp. 2999-3007,
<https://doi.org/10.1109/ICCV.2017.324>.
 - [10] N. V. Thu, B. T. K. Hoa, N. M. Cuong, H. T. T. Thuat, N. T. H. Anh, Quantitative Estimating Precipitation Using Himawari-8 Satellite Data Based on the Random Forest Machine Learning, *Vietnam Journal of Hydrometeorology*, No. 755, 2023, pp. 1-12,
[https://doi.org/10.36335/VNJHM.2023\(755\).1-12](https://doi.org/10.36335/VNJHM.2023(755).1-12) (in Vietnamese).
 - [11] D. H. Hoat, L. N. Quyen, V. D. Hong, N. C. Thanh, Building Rainfall Estimation Tool from Radar Reflectivity Using Artificial Intelligence Technique, *Vietnam Journal of Hydrometeorology*, No. 747, 2023, pp. 70-80,
[https://doi.org/10.36335/VNJHM.2023\(747\).70-80](https://doi.org/10.36335/VNJHM.2023(747).70-80) (in Vietnamese).
 - [12] G. Ayzel, T. Scheffer, M. Heistermann, RainNet v1.0: A Convolutional Neural Network for Radar-Based Precipitation Nowcasting, *Geoscientific Model Development*, Vol. 13, No. 6, 2020, pp. 2631-2644, <https://doi.org/10.5194/gmd-13-2631-2020>.
 - [13] L. D. Tinh, D. T. P. Thao, T. D. Thang, D. T. Hop, N. G. Trong, Evaluating the Performance of CNN (Conv1D) and CNN (Conv3D) Models in GNSS Data Analysis, *Vietnam Journal of Hydrometeorology*, No. 771, 2025, pp. 55-64,
[https://doi.org/10.36335/VNJHM.2025\(771\).55-64](https://doi.org/10.36335/VNJHM.2025(771).55-64) (in Vietnamese).
 - [14] N. T. T. Linh, N. V. An, Comparative Evaluation of the Predictive Performance of CNN, LSTM and CNN-LSTM Models for Streamflow Prediction Using Machine Learning, *Vietnam Journal of Hydrometeorology*, No. 771, 2025, pp. 79-89,
<https://vjol.info.vn/index.php/TCKHTV/article/view/110334> (in Vietnamese).
 - [15] Ministry of Agriculture and Environment, Science and Technology Helps Improve the Early Warning System for Natural Disasters,
<https://mae.gov.vn/khoa-hoc-cong-nghe-giup-hoan-thien-he-thong-can-h-bao-som-thien-tai-18176.htm>, 2025 (accessed on: March 18th, 2026) (in Vietnamese).
 - [16] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, W.-C. Woo, Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting, *Advances in Neural Information Processing Systems*, Vol. 28, 2015, pp. 802-810,
https://proceedings.neurips.cc/paper_files/paper/2

- 015/hash/07563a3fe3bbe7e3ba84431ad9d055af-Abstract.html (accessed on: March 18th, 2026).
- [17] X. Shi, Z. Gao, L. Lausen, H. Wang, D. Y. Yeung, W. K. Wong, W. C. Woo, Deep Learning for Precipitation Nowcasting: A Benchmark and A New Model, *Advances in Neural Information Processing Systems*, Vol. 30, 2017, pp. 5617-5627, https://proceedings.neurips.cc/paper_files/paper/2017/hash/a6db4ed04f1621a119799fd3d7545d3d-Abstract.html (accessed on: March 18th, 2026).
- [18] Y. Wang, M. Long, J. Wang, Z. Gao, P. S. Yu, PredRNN: Recurrent Neural Networks for Predictive Learning Using Spatiotemporal LSTMs, *Advances in Neural Information Processing Systems*, Vol. 30, 2017, pp. 879-888, https://proceedings.neurips.cc/paper_files/paper/2017/hash/e5f6ad6ce374177eef023bf5d0c018b6-Abstract.html (accessed on: March 18th, 2026).
- [19] Z. Gao, C. Tan, L. Wu, S. Z. Li, SimVP: Simpler Yet Better Video Prediction, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 3160-3170, <https://doi.org/10.1109/CVPR52688.2022.00317>.
- [20] X. Chen, M. Wang, S. Wang, Y. Chen, R. Wang, C. Zhao, X. Hu, Weather Radar Nowcasting for Extreme Precipitation Prediction Based on the Temporal and Spatial Generative Adversarial Network, *Atmosphere*, Vol. 13, No. 8, 2022, Article 1291, <https://doi.org/10.3390/atmos13081291>.
- [21] Y. Zhang, M. Long, K. Chen, L. Xing, R. Jin, M. I. Jordan, J. Wang, Skilful Nowcasting of Extreme Precipitation with NowcastNet, *Nature*, Vol. 619, No. 7970, 2023, pp. 526-532, <https://doi.org/10.1038/s41586-023-06184-4>.
- [22] L. D. Quyet, V. V. Nghi, N. M. Giam, Thunderstorm Detection Using Doppler Weather Radar, *Vietnam Journal of Hydrometeorology*, No. 612, 2011, pp. 31-37, <http://tapchikttv.vn/article/800> (in Vietnamese).
- [23] C. Thanh, V. T. Nguyen, T. D. Thuc, Application of Titan Software for Recognition, Monitoring, Instantaneous Analysis of Thunderstorm for Ho Chi Minh City, *VNU Journal of Science: Earth and Environmental Sciences*, Vol. 34, No. 1S, 2018, pp. 18-25, <https://doi.org/10.25073/2588-1094/vnuees.4331> (in Vietnamese).
- [24] C. Thanh, N. N. Quy, M. V. Khiem, Assessing the Rain Estimate from the Reflectivity of Nha Be Radar, *VNU Journal of Science: Earth and Environmental Sciences*, Vol. 34, No. 1S, 2018, pp. 10-17, <https://doi.org/10.25073/2588-1094/vnuees.4330> (in Vietnamese).
- [25] D. Q. Tri, N. V. Thu, B. T. K. Hoa, H. A. Nguyen-Thi, V. V. Hoa, L. T. Hue, D. T. Dat, H. T. T. Pham, Application of Radar-Based Precipitation Data Improves the Effectiveness of Urban Inundation Forecasting, *Sustainability*, Vol. 16, No. 9, 2024, Article 3736, <https://doi.org/10.3390/su16093736>.
- [26] J. J. Helmus, S. M. Collis, The Python ARM Radar Toolkit (Py-ART), A Library for Working with Weather Radar Data in the Python Programming Language, *Journal of Open Research Software*, Vol. 4, No. 1, 2016, Article e25, <https://doi.org/10.5334/jors.119>.
- [27] T. G. Khang, N. V. G. Thinh, T. V. Hoai, P. T. An, P. T. Huu, N. M. B. An, Thunderstorm Nowcasting with Recurrent-Convolution Deep Learning: A Case Study in Ho Chi Minh City, 2024 18th International Conference on Advanced Computing and Analytics (ACOMPA), IEEE, 2024, pp. 42-49, <https://doi.org/10.1109/ACOMPA64883.2024.00014>.
- [28] Y. LeCun, Y. Bengio, Convolutional Networks for Images, Speech, and Time Series, in: M. A. Arbib (Ed.), *The Handbook of Brain Theory and Neural Networks*, The MIT Press, Cambridge, MA, 1998, pp. 255-258, <https://mitpress.mit.edu/9780262011488/the-handbook-of-brain-theory-and-neural-networks> (accessed on: March 18th, 2026).
- [29] J. Ho, N. Kalchbrenner, D. Weissenborn, T. Salimans, Axial Attention in Multidimensional Transformers, *arXiv Preprint arXiv:1912.12180*, 2019, <https://doi.org/10.48550/arXiv.1912.12180>.
- [30] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, I. Polosukhin, Attention Is All You Need, *Advances in Neural Information Processing Systems*, Vol. 30, 2017, pp. 5998-6008, https://proceedings.neurips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html (accessed on: March 18th, 2026).