

# THỬ NGHIỆM DỰ BÁO MƯA DO BÃO BẰNG PHƯƠNG PHÁP TỔ HỢP LỰA CHỌN SỬ DỤNG DỮ LIỆU GSMAP VÀ MÔ HÌNH ECMWF CHO KHU VỰC VIỆT NAM

Đoàn Thị The, Phạm Thị Thanh Nga, Trần Duy Thức  
Viện Khoa học Khí tượng Thủy văn và Biến đổi khí hậu

Ngày nhận bài: 6/5/2024; ngày chuyển phản biện: 7/5/2024; ngày chấp nhận đăng: 31/5/2024

**Tóm tắt:** Dự báo mưa đi kèm bão vẫn đối mặt với nhiều thách thức do sự phức tạp của các hệ thống liên quan và sự biến đổi của bão tại các quy mô khác nhau. Các mô hình dự báo hiện nay vẫn tồn tại những hạn chế, gây ra sai số trong việc ước lượng chính xác lượng mưa đi kèm với bão. Sử dụng các mô hình dự báo tổ hợp có nhiều ưu điểm như sự đa dạng trong dữ liệu đầu vào, giảm thiểu sai số và khả năng tận dụng thông tin từ nhiều nguồn khác nhau. Tuy nhiên, việc lấy trung bình của tất cả các thành phần cũng mang lại những hạn chế trong dự báo. Các phương pháp học máy có những lợi thế đáng kể trong việc xử lý dữ liệu, nhận dạng hình ảnh đồng thời phân tích dữ liệu lớn như dữ liệu vệ tinh, cung cấp một phương pháp hiệu quả để giải quyết nhiều vấn đề tồn tại trong dự báo bão nhiệt đới. Trong nghiên cứu này, nhóm tác giả thử nghiệm phương pháp học máy để cải thiện dự báo mưa trong bão bằng cách đánh giá sự tương đồng pixel-by-pixel về lượng mưa và hình dạng giữa các thành phần của mô hình ECMWF và dữ liệu vệ tinh GSMaP. Từ đó, chúng tôi đề xuất một phương pháp tổ hợp lựa chọn các thành phần tốt nhất từ mô hình ECMWF để dự báo mưa trong bão. Kết quả cho thấy, có sự cải thiện đáng kể của phương pháp tổ hợp lựa chọn so với tổ hợp trung bình thông thường thông qua chỉ số MAE, hệ số tương quan, CSI và BSS qua các khoảng thời gian dự báo và ngưỡng mưa khác nhau.

**Từ khóa:** Tổ hợp lựa chọn, dữ liệu vệ tinh GSMaP, mô hình ECMWF, dự báo mưa do bão.

## 1. Giới thiệu

Mưa đi kèm với bão thường có cường độ mưa lớn, trên diện rộng, gây lũ lụt và thiệt hại nghiêm trọng đặc biệt cho các nước thuộc khu vực thuộc Tây Bắc Thái Bình Dương, trong đó có Việt Nam. Ở Việt Nam, thiệt hại do bão và mưa, lũ sau bão ảnh hưởng đến tất cả các lĩnh vực như con người, cơ sở hạ tầng, nông nghiệp, thủy sản... ước tính lên tới chục tỷ đồng hàng năm, ví dụ điển hình một siêu bão đổ bộ gây thiệt hại lớn như Linfa, Molave năm 2020 với tổng thiệt hại ước tính trên 18.938 tỷ đồng, Damrey 12/2017 thiệt hại trên 22.679 tỷ đồng, bão Sơn Tinh năm 2012 thiệt hại ước tính trên 11.169 tỷ đồng, bão Ketsana năm 2009 ước tính thiệt hại trên 16.000 tỷ đồng, và bão Xangsane năm 2006 ước tính thiệt hại trên 10.400

tỷ đồng [1].

Dự báo mưa do bão vẫn là một thách thức hiện nay trên thế giới và Việt Nam [2-4]. Các mô hình dự báo hiện nay vẫn còn có những hạn chế dẫn đến sai số trong dự báo định lượng mưa [4-7]. Sử dụng mô hình dự báo tổ hợp có những ưu điểm lớn [8]. Tuy nhiên, việc lấy trung bình của tất cả các thành phần cũng mang lại các hạn chế trong dự báo, như làm mất đi những thành phần cực trị [9], [10]. Việc kết hợp một vài thành phần hoặc tổng hợp các thành phần của dự báo vốn không phải là một ý tưởng mới [10], nó đã được ứng dụng trong một vài nghiên cứu như của Jun Du và đồng nghiệp năm 2019 [11], của Ming-Chang Wu năm 2018 [12], Liangbo Qi, 2013 [13], D.W Shin năm 2003 [14]. Kết hợp sử dụng các thuật toán học máy và trọng số nhằm tối ưu lựa chọn các thành phần trong dự báo như sử dụng thuật toán di truyền (GA) [12], sử dụng giá trị trung bình (means-SEAV) và giá trị

Liên hệ tác giả: Đoàn Thị The  
Email: doanthe00@gmail.com

trung bình có trọng số (weighted means - SEWE) [13], [15] nhằm lựa chọn các thành phần của các mô hình dự báo gồm mô hình dự báo châu Âu (ECMWF), mô hình của cơ quan khí tượng Nhật Bản (JMA), mô hình của trung tâm dự báo môi trường quốc gia (NCEP) và mô hình của cơ quan khí tượng Trung Quốc đối với 35 cơn bão ở phía Tây Bắc Thái Bình Dương trong năm 2010 và 2011 để dự báo đường đi của bão. Sử dụng phương pháp trung bình có chọn lọc các thành phần có sai số nhỏ hơn trong thời gian ngắn để dự báo đường đi của bão trong nghiên cứu của Masato và cộng sự năm 2015 [16].

Dữ liệu vệ tinh khí tượng đóng một vai trò quan trọng trong việc dự báo thời tiết, trong đó đề cập đến việc dự đoán và giám sát ngắn hạn các điều kiện thời tiết, thường trước từ vài phút đến vài giờ [17-19]. Các ứng dụng ban đầu của dữ liệu vệ tinh hiện nay tập trung vào việc giải thích các hệ thống và hình thái thời tiết cùng với các nguồn dữ liệu khác như các sản phẩm mô hình số (NWP), quan trắc tại bề mặt và quan trắc radar. Khi thông tin từ dữ liệu vệ tinh được kết hợp với các quan sát radar, bề mặt và thám không, các quá trình quan trọng trong các giai đoạn phát triển của bão có thể được hiểu rõ hơn phục vụ cho các dự báo bão [19-22].

Tuy nhiên, việc sử dụng dữ liệu cùng với mô hình còn hạn chế trong dự báo mưa bão bởi nó phụ thuộc vào các tham số hóa và các quá trình vật lý trong bão. Hiệu suất dự báo bão nhiệt đới bị hạn chế bởi các cơ chế động lực phức tạp và các yếu tố ảnh hưởng đa dạng vẫn cần được cải thiện [18], [23]. Trong những năm gần đây, những tiến bộ lớn trong dự báo bão đã được thực hiện mặc dù vẫn tồn tại những thách thức trong việc dự đoán các chuyển động dị thường và dự báo đường đi dài hạn [18], [24], [25]. Để giải quyết những vấn đề như vậy, việc áp dụng các phương pháp học máy dần trở thành một xu hướng. Ví dụ trong dự báo bão [18], [26-

30] chúng được sử dụng để đánh giá dữ liệu vệ tinh như lượng mưa [27], [28], sử dụng dữ liệu vệ tinh FY-4 để ước tính cường độ bão [29], [31], đánh giá và phân tích dữ liệu radar [25] và phân tích dữ liệu quan sát bề mặt [26]. Là công nghệ cốt lõi của trí tuệ nhân tạo (AI), nguyên tắc cơ bản của học máy là cung cấp dữ liệu cho máy tính và để chúng suy ra các quy tắc từ đó, để máy có thể khám phá các giá trị tiềm năng của dữ liệu và tự động cải thiện hiệu suất của chúng [18], [32]. Các phương pháp học máy có thể được sử dụng để thực hiện việc lựa chọn tính năng, phân tích sự tương đồng [18], [33], phân cụm [18], [34], [35], và hồi quy/phân loại [36] được cho là có ích cho dự báo bão [18], [30].

Chính vì vậy, trong nghiên cứu này, chúng tôi thử nghiệm phương pháp học máy trong việc cải thiện dự báo mưa trong bão bằng việc đánh giá sự tương đồng pixel-by-pixel về lượng và sự tương đồng về hình dạng của dữ liệu mưa được dự báo từ mô hình dự báo Châu Âu ECMWF với dữ liệu vệ tinh GSMaP thông qua các chỉ số thống kê kết hợp phương pháp trọng số để dự báo tổ hợp lựa chọn từ các thành phần dự báo tốt nhất của mô hình ECMWF cho dự báo mưa trong bão. Vì vậy, phương pháp đánh giá bằng phương pháp học máy hồi quy/phân loại thông qua các chỉ số tương đồng và các chỉ số thống kê được trình bày trong Phần 2 của nghiên cứu này; Phần 3 trình bày kết quả đánh giá sự tương đồng, phân tích trọng số và đánh giá kết quả dự báo của phương pháp tổ hợp lựa chọn các thành phần tốt nhất cho dự báo mưa trong bão. Cuối cùng là kết luận và thảo luận được trình bày trong Phần 4.

## 2. Dữ liệu sử dụng và phương pháp nghiên cứu

### 2.1. Dữ liệu sử dụng

Dữ liệu vệ tinh và mô hình được sử dụng trong nghiên cứu như sau:

Dữ liệu	Độ phân giải	Thời gian	Nguồn
<u>GSMaP NRT</u>	0,1 độ, 1 giờ	2019-2022	Japan Aerospace Exploration Agency (JAXA) <a href="https://www.gportal.jaxa.jp">https://www.gportal.jaxa.jp</a>
<u>ECMWF: 51 thành phần (Ensemble)</u>	0,25 độ, 1 giờ	2019-2022	European Centre for Medium-Range Weather Forecasts (ECMWF)

Trong đó, dữ liệu được thu thập theo thời gian bắt đầu và kết thúc của các cơn bão trong giai đoạn năm 2019-2022 (Bảng 1), dữ liệu được xử lý theo các thời điểm dự báo cho mỗi 6 giờ

để được 108 lần dự báo. Các kết quả đánh giá và phân tích được trình bày theo các hạn dự báo 12 giờ và 24 giờ.

Bảng 1. Các cơn bão ảnh hưởng đến Biển Đông và Việt Nam giai đoạn 2019-2022

ID	Tên	Thời gian bắt đầu	Thời gian kết thúc	ID	Tên	Thời gian bắt đầu	Thời gian kết thúc
201901	PABUK	2019010106	2019010412	2021	ETAU	2020110712	2020111018
201904	MUN	2019070212	2019070400	2022	VAMCO	2020111100	2020111606
201907	WIPHA	2019073100	2019080306	2023	KROVANH	2020121812	2020122500
201912	PODUL	2019082800	2019082918	2103	CHOI-WAN	2021060118	2021060500
201922	MATMO	2019102812	2019103018	2107	CEMPAKA	2021071700	2021072500
201924	NAKRI	2019110412	2019111018	2109	LUPIT	2021080212	2021080712
201928	KAMMURI	2019120306	2019120506	2113	CONSON	2021090618	2021091312
201929	PHANFONE	2019122400	2019122806	2117	LIONROCK	2021100500	2021101018
2002	NURI	2020061018	2020061406	2118	KOMPASU	2021101100	2021101412
2003	SINLAKU	2020073100	2020080300	2122	RAI	2021121612	2021122106
2006	MEKKHALA	2020080900	2020081106	2203	CHABA	2022062900	2022070718
2007	HIGOS	2020081606	2020082006	2207	MULAN	2022080800	2022081106
2011	NOUL	2020091500	2020091818	2209	MA-ON	2022082100	2022082518
2016	NANGKA	2020101100	2020101412	2216	NORU	2022092106	2022092906
2017	SAUDEL	2020102000	2020102512	2219	SONCA	2022101306	2022101500
2018	MOLAVE	2020102506	2020102900	2220	NESAT	2022101412	2022102006
2019	GONI	2020103118	2020110606	2222	NALGAE	202210606	2022110300
2020	ATSANI	2020110512	2020110706				

## 2.2. Phương pháp nghiên cứu

### 2.2.1. Phương pháp đánh giá sự tương đồng (pattern similarity)

Phương pháp đánh giá sự tương đồng pixel-by-pixel về lượng và sự tương đồng về hình dạng đã được sử dụng trong nhiều các nghiên cứu [37], [38], trong nghiên cứu này, chúng tôi

sử dụng chỉ số tương quan Correlation để đánh giá sự tương đồng về lượng (giá trị pixel) của dữ liệu thành phần mô hình ECMWF so với dữ liệu GSMaP. Chỉ số tương đồng về cấu trúc SSIM (Structural Similarity Index) và Cosine Similarity (COSINSIM) để đánh giá sự tương đồng về không gian. Các công thức của chỉ số được trình bày như sau:

Chỉ số	Công thức	Ý nghĩa
SSIM (Structural Similarity Index) [39]	$SSIM(x, y) = l(x, y)^\alpha \cdot c(x, y)^\beta \cdot s(x, y)^\gamma$ <p>Trong đó: Công thức SSIM dựa trên ba phép đo so sánh giữa các mẫu của x và y; độ chói (l), sự tương phản (c) và cấu trúc (s) y; <math>\alpha</math>; <math>\beta</math>; <math>\gamma</math> là các giá trị trọng số của l, c, s. SSIM có giá trị trong khoảng từ -1 đến 1, đạt giá trị bằng 1 trong trường hợp hai bộ dữ liệu giống hệt nhau. Chỉ số này có giá trị càng lớn thì tương ứng với model càng tốt.</p>	Chỉ số tương đồng về cấu trúc

Chỉ số	Công thức	Ý nghĩa
Cosine Similarity (COSINSIM) [40]	$\text{cosine similarity} = S_C(A, B) := \cos(\theta) = \frac{A \cdot B}{\ A\  \ B\ } = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$ <p>Trong đó <math>A_i</math> và <math>B_i</math> là thành phần thứ <math>i</math> của hai vectơ <math>A</math> và <math>B</math></p>	Để đánh giá sự tương đồng về không gian

### 2.2.2. Các chỉ số đánh giá sản phẩm mưa dự báo

a) Chỉ số đánh giá dự báo tất định:

Các chỉ số đánh giá cho sản phẩm dự báo tổ hợp lựa chọn và giá trị mưa GSMaP. Các chỉ số gồm:

Chỉ số	Công thức	Ý nghĩa
Sai số tuyệt đối trung bình MAE - Mean Absolute Error	$MAE = \frac{1}{n} \sum_{i=1}^n  y_i - \hat{y}_i $	Giá trị MAE nằm trong khoảng $(0, +\infty)$ , giá trị của nó càng nhỏ thì độ chính xác càng lớn. Khi $MAE = 0$ , giá trị của mô hình hoàn toàn trùng khớp với giá trị quan trắc, mô hình được xem là "lý tưởng".
Hệ số tương quan (Correlation Coefficient)	$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$	Hệ số tương quan có giá trị từ -1,0 đến 1,0. Kết quả được tính ra lớn hơn 1,0 hoặc nhỏ hơn -1 có nghĩa là có lỗi trong phép đo tương quan.

Đối với chỉ số đánh giá hiệu suất dự báo sử dụng chỉ số CSI-Critical Success Index điểm số thành công còn được gọi là điểm đe dọa với công thức:

$$CSI = a / (a + b + c)$$

Trong đó:  $a$  là dự báo có, quan trắc có;  $b$  là dự báo có, quan trắc không;  $c$  là dự báo không, quan trắc có.

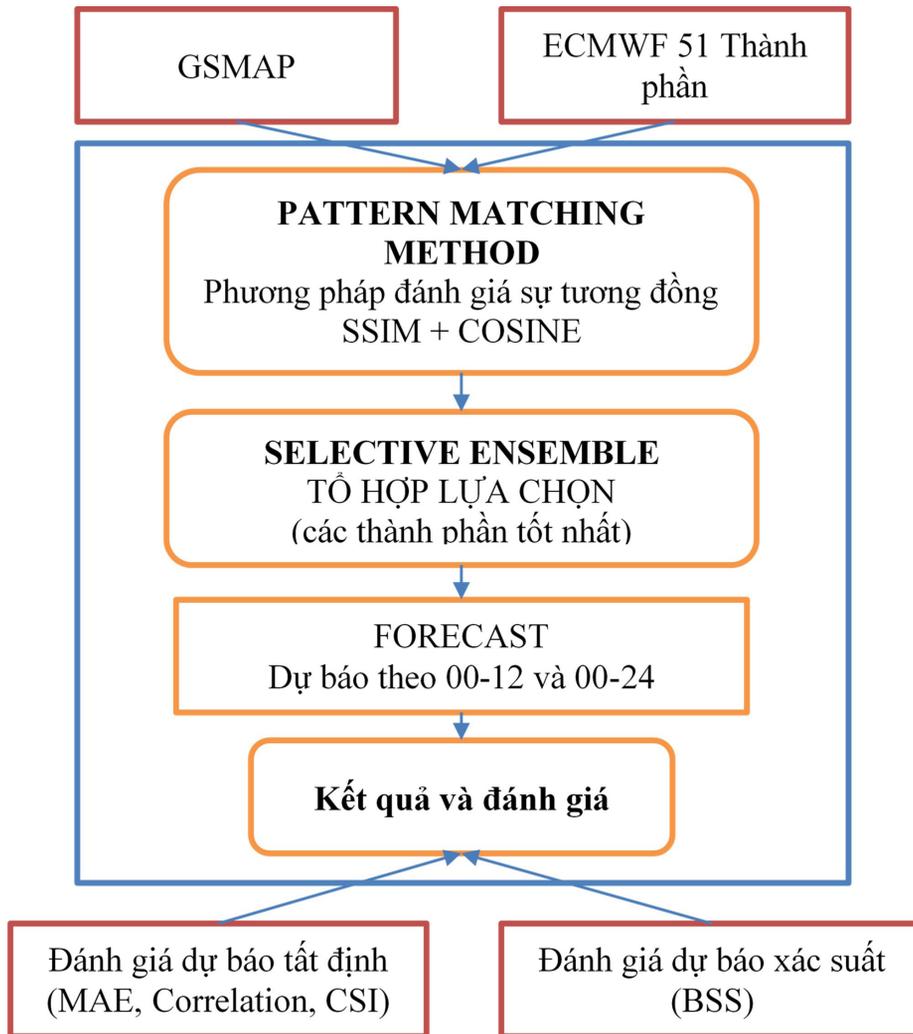
b) Chỉ số dự báo xác suất

Đối với đánh giá dự báo xác suất, nhóm nghiên cứu sử dụng chỉ số điểm số kỹ năng BSS (Brier skill score) để so sánh giá trị dự báo với

một giá trị dự báo tham chiếu (thường lấy là điều kiện thời tiết trung bình tương ứng xác định từ chuỗi số liệu thực đo). BSS miêu tả phần trăm dự báo được cải thiện so với dự báo tham chiếu, có giá trị trong khoảng  $(-\infty$  tới 1). Giá trị lý tưởng là 1.

### 2.2.3. Sơ đồ nghiên cứu

Bằng việc áp dụng phương pháp học máy trong việc phân tích dữ liệu mưa bão từ vệ tinh GSMaP và dữ liệu mô hình tổ hợp ECMWF 51 thành phần thông qua phương pháp đánh giá sự tương đồng sử dụng chỉ số thống kê, sơ đồ Hình 1 dưới đây mô tả chi tiết các bước thực hiện trong nghiên cứu này:



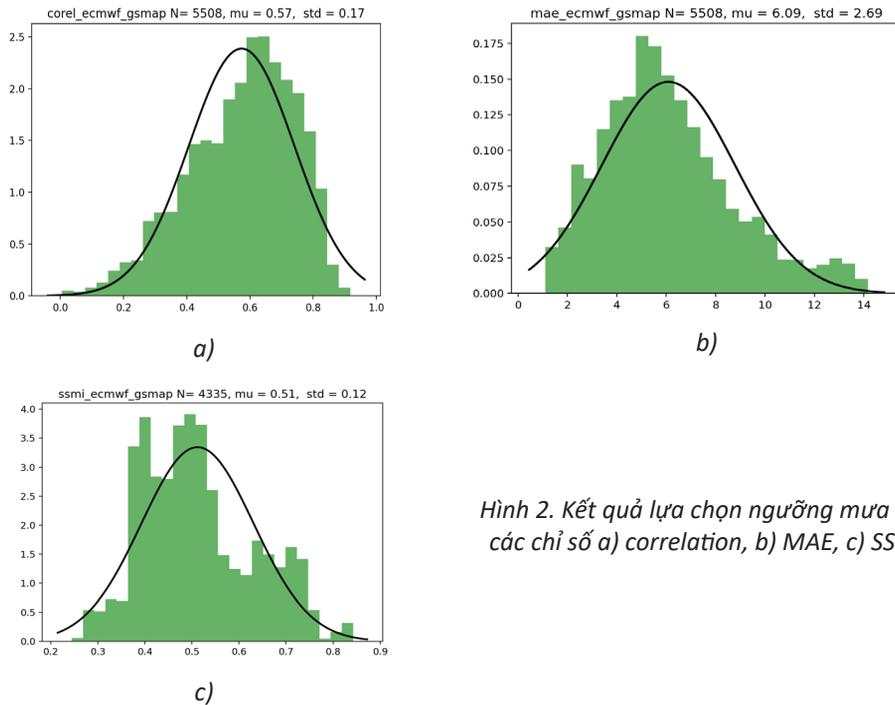
Hình 1. Sơ đồ nghiên cứu xây dựng tổ hợp lựa chọn đánh giá mưa bão

### 3. Kết quả

#### 3.1. Kết quả đánh giá sự tương đồng

Hình 2 dưới đây mô tả hàm mật độ xác suất của các giá trị correlation (a), mean absolute error - MAE (b) và structural similarity index - SSIM (c) được tính toán từ 108 lần dự báo và 51 thành phần của mô hình Châu Âu ECMWF. Kết quả này cho thấy rõ hình dạng phân bố chuẩn của tất cả các hàm mật độ xác suất. Trong đó, giá

trị trung bình của correlation là 0,57, của MAE là 6.06 và của SSIM là 0,51. Những giá trị này đã được sử dụng như là ngưỡng để lựa chọn các thành phần tốt nhất trong hạn dự báo từ 00-06 giờ. Sự tuân thủ theo phân bố chuẩn của các hàm mật độ xác suất này cung cấp một cái nhìn tổng quan về độ chính xác và phân phối của dữ liệu, hỗ trợ quá trình đánh giá và lựa chọn thành phần hiệu quả trong mô hình.

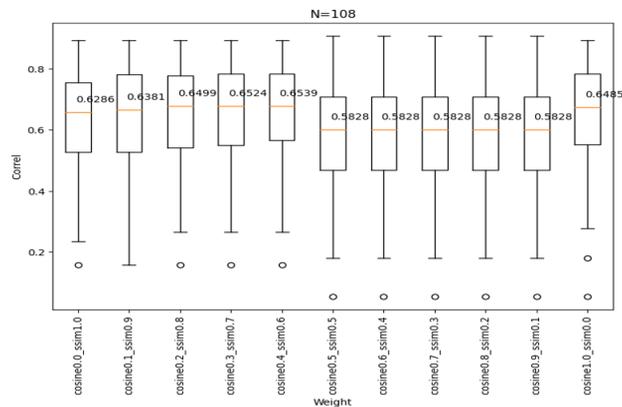


Hình 2. Kết quả lựa chọn ngưỡng mưa cho các chỉ số a) correlation, b) MAE, c) SSIM

Để thực hiện quá trình nhận dạng tương tự dựa trên diện mưa (tương đồng theo không gian), chúng tôi áp dụng phương pháp kết hợp hai chỉ số là SSIM (Structural Similarity Index) và COSINSIM (Cosine Similarity) thông qua việc lựa chọn cặp trọng số. Quá trình này được thực hiện theo các bước chi tiết sau:

- Tính toán giá trị SSIM và Cosine Similarity trong hạn dự báo từ 00-06 giờ.
- Lập trọng số  $ssmi\_w$  từ 0 đến 1 với bước nhảy là 0.1, sau đó tính giá trị hỗn hợp theo công thức:  $value = ssmi\_w * SSIM + cosine\_w * Cosine\ Similarity$ .

- Xác định giá trị trung bình (ngưỡng mưa) tương ứng với từng cặp hệ số  $ssmi\_w$  và  $cosine\_w$ .
- Lập qua các trọng số và tính toán giá trị tổng của SSIM và Cosine Similarity. Nếu giá trị của thành viên (member) nào lớn hơn ngưỡng tương ứng với hệ số, thì lựa chọn thành phần đó.
- Tính ENS MEAN của các thành phần được chọn và tính hệ số tương quan so với dữ liệu GSMaP.
- Vẽ biểu đồ BOX PLOT để tìm ra trọng số tương ứng với cặp hệ số tốt nhất.



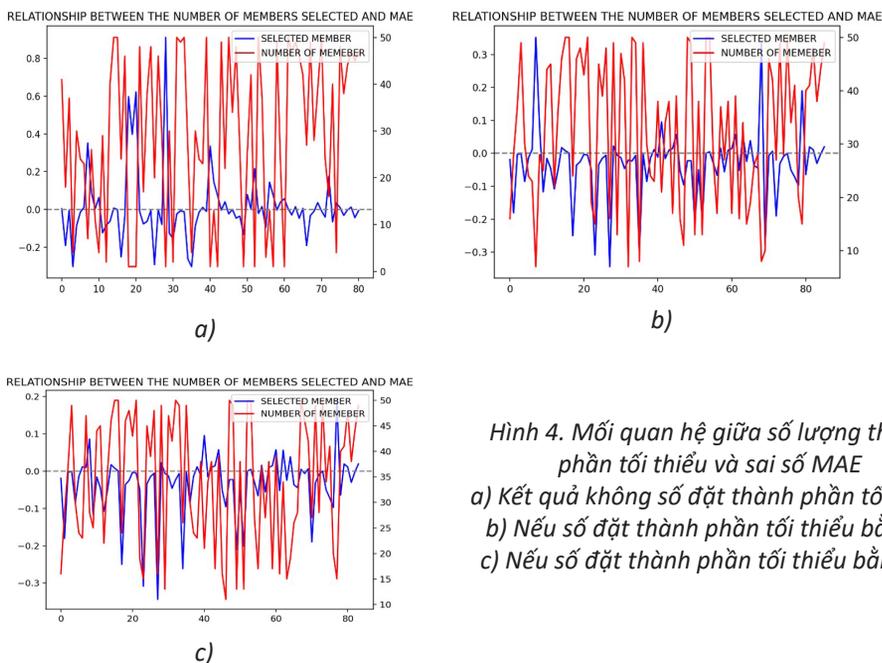
Hình 3. Khoảng sai số tương ứng với từng cặp hệ số SSIM và Cosine similarity

Hình 3 cho thấy rằng, trong trường hợp chỉ sử dụng độ đo tương đồng hình ảnh SSIM với trọng số cosine là 0,0 và SSIM là 1,0, hoặc ngược lại với cosine là 1,0 và SSIM là 0,0, đều không đạt được hiệu suất như khi kết hợp cả 2 chỉ số. Việc kết hợp cả hai độ đo cosine và SSIM với trọng số tương ứng là cosine 0,4 và SSIM 0,6 đã mang lại kết quả tốt nhất. Sự kết hợp này dường như tận dụng được các ưu điểm của cả hai phương pháp, tạo ra một phương tiện hiệu quả để đánh giá sự tương đồng giữa các thành phần. Việc gán trọng số cho cả hai độ đo làm tăng khả năng nhận biết và đánh giá chất lượng hình ảnh, giúp cân nhắc đến cả khía cạnh toàn diện của sự tương đồng và tương quan giữa chúng. Nhìn chung, sự kết hợp linh hoạt giữa cosine và SSIM, với trọng số được điều chỉnh phù hợp, đã chứng minh khả năng nâng cao đáng kể hiệu suất đánh giá hình ảnh so với việc sử dụng mỗi độ đo một cách đơn lẻ.

Sau khi sử dụng cặp hệ số SSIM và Cosine similarity, chúng tôi đã lựa chọn được các thành phần trong 51 thành phần có độ tương đồng với dữ liệu mưa GSMaP cao nhất, từ đó tổ hợp cho các dự báo tiếp theo. Lựa chọn số lượng thành phần tối thiểu là một khía cạnh quan trọng trong quá trình tối ưu hóa chất lượng dự báo. Qua các thử nghiệm của chúng

tôi, chúng ta đã nhận thấy rằng việc quá ít các thành phần được chọn trong khoảng dự báo từ 00 - 06 có thể dẫn đến sai số lớn hơn so với mô hình nguyên gốc (raw ensemble) ban đầu ở khoảng thời gian 00-12.

Hình 4 mô tả mối quan hệ giữa số lượng thành phần tối thiểu và giá trị MAE của các thành phần được lựa chọn trừ đi mô hình nguyên gốc tương ứng. Trong đó, (a) đại diện cho trường hợp không đặt giá trị thiểu số, (b) là trường hợp lấy giá trị thiểu số bằng 5 và (c) là trường hợp lấy giá trị thiểu số bằng 10. Kết quả cho thấy, khi không đặt số thành phần tối thiểu, đường màu xanh biểu diễn mối quan hệ nằm trong khoảng giá trị  $-0,25$  đến  $0,85$ . Khi số lượng thành phần tối thiểu bằng 5, khoảng giá trị của đường màu xanh thu hẹp xuống từ  $-0,3$  đến  $0,3$ . Điều này chứng tỏ đã có nhiều trường hợp cải thiện hơn so với mô hình nguyên gốc và sai số giảm đáng kể. Khi lựa chọn số lượng thành phần tối thiểu là 10, gần như tất cả các trường hợp xấu đã biến mất, chỉ còn 1-2 trường hợp duy nhất. Điều này làm nổi bật vai trò quan trọng của số lượng thành phần tối thiểu trong việc cải thiện chất lượng dự báo của các thành viên đã được lựa chọn. Việc này không chỉ giúp tăng tính ổn định của dự báo mà còn làm giảm thiểu sai số và cải thiện độ tin cậy.

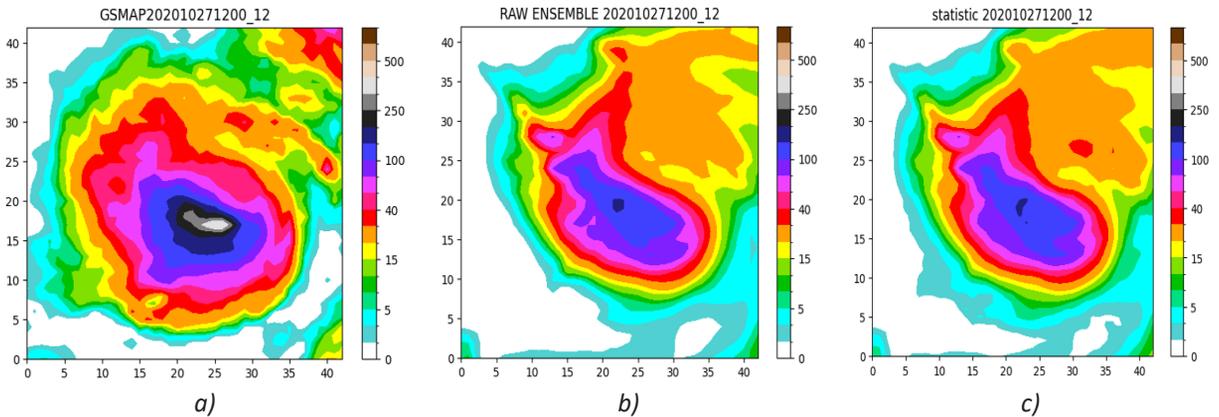


Hình 4. Mối quan hệ giữa số lượng thành phần tối thiểu và sai số MAE  
a) Kết quả không số đặt thành phần tối thiểu  
b) Nếu số đặt thành phần tối thiểu bằng 5  
c) Nếu số đặt thành phần tối thiểu bằng 10

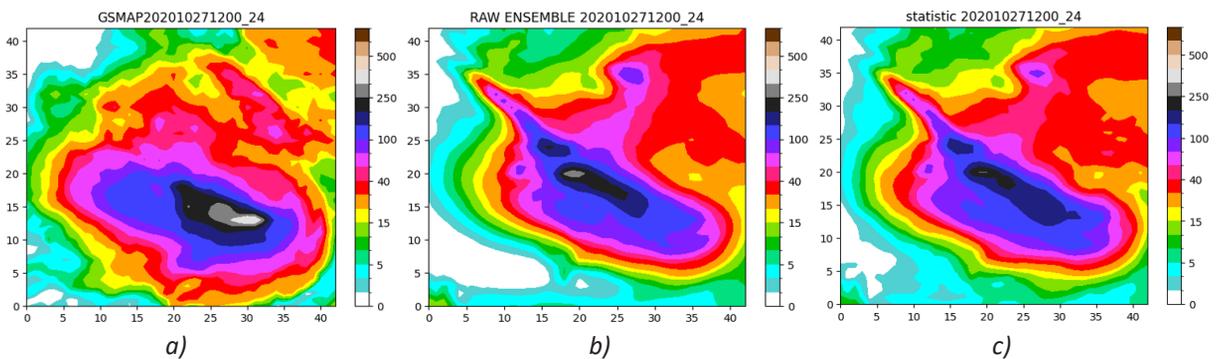
Như vậy, nhóm nghiên cứu đã sử dụng ngưỡng lựa chọn số thành phần tối thiểu cho tổ hợp lựa chọn là 5 cho các nghiên cứu dự báo. Hình 5, Hình 6 dưới đây trình bày kết quả một trường hợp điển hình đánh giá sự tương đồng về lượng.

Hình 5 là kết quả mô phỏng lượng mưa tích lũy quanh tâm bão MOLAVE trong 12 giờ của ngày 27/10/2020. So sánh với dữ liệu từ GSMaP (Hình 5a) với mô hình tổ hợp nguyên gốc (raw

ensemble) (Hình 5b) và kết quả từ tổ hợp chọn lọc (Hình 5c), có thể thấy rằng, nói chung, các phương án đều cho thấy một sự tương đồng đáng kể trong diện mưa, tuy nhiên vẫn có sự chênh lệch giữa các mô hình và sự cải thiện dự báo về lượng của mô hình tổ hợp chọn lọc là chưa đáng kể. Đối với hạn dự báo 24 h (Hình 6), không thấy sự cải thiện đáng kể nào của các phương án so với GSMaP. Có thể ở hạn dự báo dài hơn, sự cải thiện giảm đi nhiều.



Hình 5. Kết quả mô phỏng mưa lớn ở hạn 00-12 ngày 27/10/2020 của bão MOLAVE cho các phương án: a) GSMaP, b) tổ hợp nguyên gốc (raw ensemble), c) tổ hợp lựa chọn



Hình 6. Kết quả mô phỏng mưa lớn ở hạn 00-24 ngày 27/10/2020 của bão MOLAVE cho các phương án: a) GSMaP, b) tổ hợp nguyên gốc (raw ensemble), c) tổ hợp lựa chọn

### 3.2. Kết quả đánh giá dự báo bất định

Hình 7 thể hiện tỷ lệ % số lần dự báo tốt hơn tổ hợp nguyên gốc (raw ensemble) theo chỉ số MAE và chỉ số Correlation từ kết quả phân tích 108 phiên dự báo. Kết quả này là tổng hợp và phản ánh khả năng cải thiện của các phương án tổ hợp lựa chọn so với tổ hợp nguyên gốc. Kết quả cho thấy phương án tổ hợp lựa chọn mang lại kết quả khả quan đối với cả hai chỉ số. Ở cả

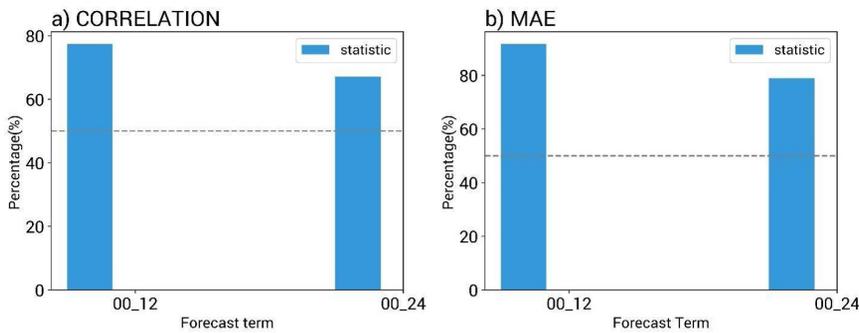
hai hạn dự báo 00-12 và 00-24 chỉ số tương quan correlation đạt tỷ lệ cải thiện trên 70% trong khi đó chỉ số MAE đạt tỷ lệ cải thiện trên 80% khi so sánh với mô hình tổ hợp nguyên gốc. Điều này chứng tỏ sự hiệu quả của phương pháp tổ hợp lựa chọn trong dự báo cả về chất lượng và độ chính xác.

Hình 8 là biểu đồ thể hiện giá trị MAE của từng phiên dự báo trừ đi mô hình tổ hợp nguyên gốc (raw ensemble), khi giá trị này càng

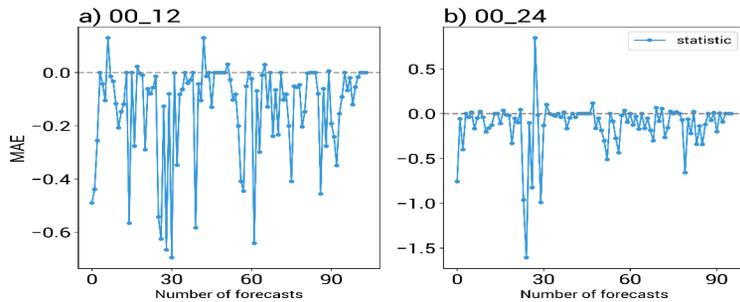
âm cho thấy sự cải thiện của mô hình tổ hợp lựa chọn so với mô hình gốc, điều này phản ánh sự giảm thiểu sai số trong dự báo. Kết quả cho thấy, ở hạn dự báo 00-12, phương án tổ hợp lựa chọn mang lại sự cải thiện nhiều so với mô hình nguyên gốc, sự cải thiện của chỉ số MAE nằm trong khoảng 0-0,7 cho thấy hiệu suất tốt trong dự báo, các giá trị âm đặc biệt ở phần đỉnh của biểu đồ chỉ ra rằng nhiều phiên dự báo đạt được sự cải thiện đáng kể so với mô hình tổ hợp nguyên gốc. Tương tự như vậy, ở hạn dự báo 00-24 h, cũng cho thấy sự cải thiện đáng kể với chỉ số dao động trong khoảng 0-1,5. Tuy nhiên vẫn có một số trường hợp giá trị MAE dương nghĩa là tổ hợp lựa chọn cho kết quả thấp hơn tổ hợp nguyên gốc. Điều này là thách thức đặc

biệt và không thể cải thiện được hiệu suất của mô hình.

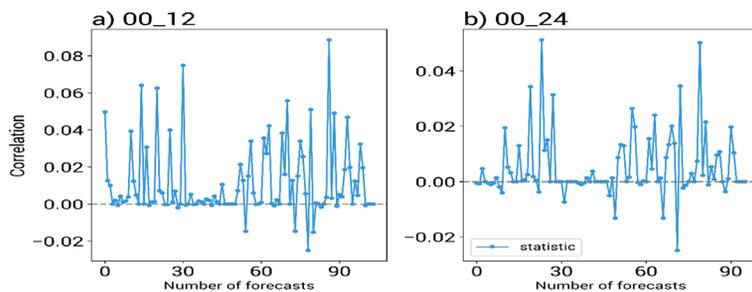
Hình 9 là biểu đồ thể hiện giá trị Correlation của từng phiên dự báo trừ đi mô hình tổ hợp nguyên gốc (raw ensemble) thông qua toàn bộ 108 phiên dự báo, trong biểu đồ này giá trị dương cho thấy sự cải thiện của mô hình tổ hợp lựa chọn so với tổ hợp nguyên gốc. Kết quả cho thấy sự cải thiện cả về hạn dự báo 00-12 và 00-24, tuy nhiên sự cải thiện là không nhiều vì các chỉ số cải thiện chỉ từ 0-0,08. Tuy vậy, đa số tại các phiên dự báo đều có sự cải thiện hơn so với mô hình tổ hợp nguyên gốc, điều này có ý nghĩa quan trọng trong dự báo thời tiết đặc biệt là trong điều kiện thời tiết đặc biệt như mưa do bão.



Hình 7. Tỷ lệ % số lần dự báo tốt hơn mô hình tổ hợp nguyên gốc (raw ensemble) chỉ số MAE và Correlation



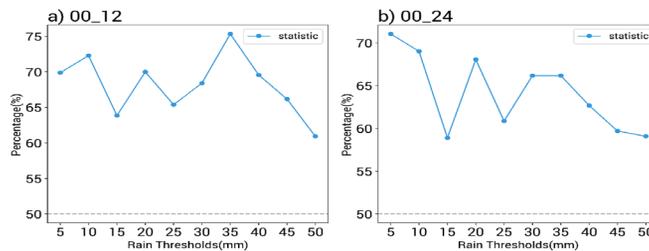
Hình 8. Chỉ số MAE của mô hình tổ hợp lựa chọn so với mô hình nguyên gốc cho hạn dự báo 12 h và 24 h



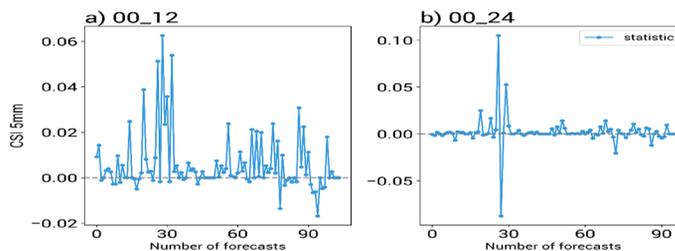
Hình 9. Chỉ số Correlation của mô hình tổ hợp lựa chọn so với mô hình nguyên gốc cho hạn dự báo 12 h và 24 h

Hình 10 là tỷ lệ % số lần dự báo tốt hơn mô hình nguyên gốc (raw ensemble) của chỉ số CSI theo các ngưỡng mưa khác nhau, kết quả cho thấy ở tất cả các ngưỡng mưa tại thời điểm dự báo đến 12 h và 24 h, mô hình tổ hợp lựa chọn đều cho kết quả dự báo tốt hơn mô hình tổ hợp nguyên gốc, cao nhất ở ngưỡng mưa >5 mm với trên 70% và tại các ngưỡng mưa dưới 40 mm đều cho xác suất dự báo cao hơn 60% và giảm dần khi các ngưỡng mưa lớn hơn.

Hình 11 thể hiện giá trị CSI của từng phiên



Hình 10. Tỷ lệ % số lần dự báo tốt hơn mô hình nguyên gốc (raw ensemble) của chỉ số CSI

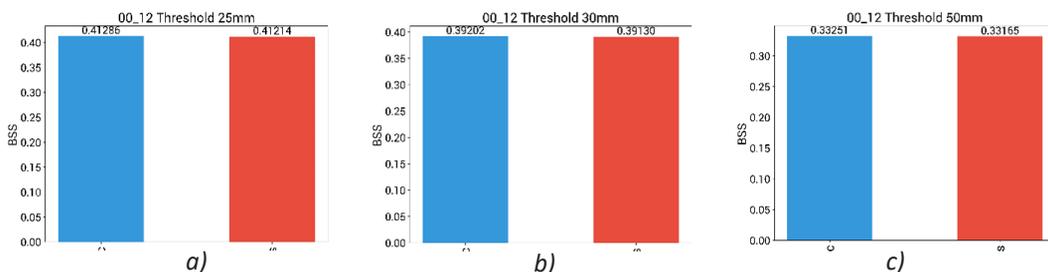


Hình 11. Chỉ số CSI ở ngưỡng mưa trên 5 mm của mô hình tổ hợp lựa chọn so với mô hình nguyên gốc cho hạn dự báo 12 h và 24 h

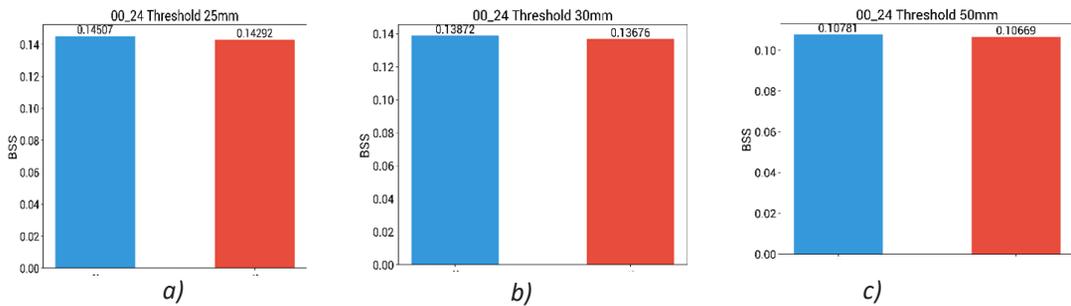
### 3.3. Kết quả đánh giá dự báo xác suất

Hình 12 và Hình 13 là kết quả chỉ số BSS của mô hình tổ hợp lựa chọn so với mô hình tổ hợp nguyên gốc tại lát dự báo 00-12 và 00-24 ở các ngưỡng mưa 25 mm, 30 mm và 50 mm. Giá trị

BSS lớn hơn 0 nghĩa là có sự cải thiện so với tổ hợp nguyên gốc. Quan sát biểu đồ cho thấy tại các ngưỡng mưa khác nhau và các thời gian khác nhau đều cho thấy xu hướng cải thiện hiệu suất dự báo so với mô hình tổ hợp nguyên gốc tuy nhiên giá trị cải thiện là rất nhỏ.



Hình 12. Kết quả chỉ số BSS tại lát dự báo 00-12 giờ ở các ngưỡng mưa: a) 25mm, b) 30 mm c) 50 mm (màu xanh là mô hình tổ hợp lựa chọn, màu đỏ là mô hình nguyên gốc)



Hình 13. Kết quả chỉ số BSS tại lát dự báo 00-24 giờ ở các ngưỡng mưa: a) 25 mm, b) 30 mm c) 50 mm (màu xanh là mô hình tổ hợp lựa chọn, màu đỏ là mô hình tổ hợp nguyên gốc)

#### 4. Kết luận

Nghiên cứu đã tiến hành đánh giá sự tương đồng và hiệu quả của các phương pháp kết hợp SSIM và Cosine Similarity trong dự báo lượng mưa, dựa trên dữ liệu từ mô hình Châu Âu ECMWF và dữ liệu vệ tinh GSMaP. Kết quả cho thấy việc kết hợp hai chỉ số này với trọng số SSIM là 0,6 và Cosine Similarity là 0,4 đã cải thiện đáng kể độ chính xác so với việc sử dụng riêng lẻ từng chỉ số. Cụ thể, các thành phần được chọn lọc dựa trên cặp chỉ số này thể hiện hiệu suất vượt trội trong dự báo mưa ngắn hạn và trung hạn, giúp giảm thiểu sai số dự báo (MAE) và tăng độ tương quan (Correlation) so với mô hình tổ hợp nguyên gốc. Các kết quả mô phỏng lượng mưa trong bão cho thấy, mặc dù các phương án đều cho thấy sự tương đồng đáng kể với dữ liệu thực tế từ GSMaP, sự cải thiện của mô hình tổ hợp chọn lọc so với mô hình nguyên gốc là chưa thực sự rõ rệt ở hạn dự báo 24 giờ. Tuy vậy, ở hạn dự báo ngắn hơn (00-12 giờ), phương án tổ hợp lựa chọn đã mang lại sự cải thiện rõ rệt về

chỉ số MAE và tỷ lệ % số lần dự báo tốt hơn theo chỉ số Correlation.

Các đánh giá về chỉ số CSI ở ngưỡng mưa khác nhau cho thấy mô hình tổ hợp lựa chọn có khả năng cải thiện dự báo tốt hơn mô hình nguyên gốc, đặc biệt là ở ngưỡng mưa nhỏ hơn 5 mm. Tuy nhiên, hiệu suất dự báo ở các ngưỡng mưa lớn hơn vẫn còn hạn chế, chưa cải thiện nhiều.

Nghiên cứu đã chứng minh rằng việc áp dụng mô hình tổ hợp lựa chọn sử dụng phương pháp chỉ số đã cho thấy sự cải thiện đáng kể chất lượng và độ chính xác của dự báo lượng mưa, đặc biệt trong điều kiện mưa liên quan đến bão. Những kết quả này khẳng định tính khả thi và hiệu quả của phương pháp tổ hợp lựa chọn trong dự báo mưa, một trong những yếu tố quan trọng của thời tiết nguy hiểm. Tuy nhiên, nghiên cứu này chỉ mới dừng lại ở việc thử nghiệm áp dụng phương pháp học máy thông qua chỉ số thống kê (đánh giá sự tương đồng), nhóm nghiên cứu sẽ trình bày các kết quả áp dụng phương pháp học máy thông qua phân cụm và hồi quy/phân loại trong các nghiên cứu tiếp theo.

**Lời cảm ơn:** Bài báo là kết quả trong nội dung nghiên cứu phương pháp nhận dạng tương tự áp dụng cho bài toán dự báo mưa do bão thuộc đề tài nhà nước mã số ĐTĐL.CN-59/21.

#### Tài liệu tham khảo

- Văn phòng thường trực ban chỉ đạo quốc gia về phòng chống thiên tai, *Tổng hợp báo cáo thiệt hại hàng năm 2006, 2009, 2012, 2017, 2020*. <https://phongchongthientai.mard.gov.vn/>.
- World Meteorological Organization (WMO) (2017), *Global Guide to Tropical Cyclone Forecasting*.
- Zhan Zhang, et al. (2023), "A review of recent advances (2018-2021) on tropical cyclone intensity change from operational perspectives, part 1: Dynamical model guidance", *Tropical Cyclone Research and Review*, 12(1), 30-49.
- Liu, J.-Q.L., Z.-L.; Wang, Q.-Q (2021), "Quantitative Precipitation Forecasting Using an Improved Probability-Matching Method and Its Application to a Typhoon Event", *Atmosphere*, 2021(12 (10)).

5. Lanqian Li et al. (2024), "Short-term forecast large-scale error characteristics and their relationship with precipitation forecast skill under two rainfall regimes", *Atmospheric Research*, 298(2024, 107152).
6. Zhang kang Shu, et.al. (2021), "Evaluation and Application of Quantitative Precipitation Forecast Products for Mainland China Based on TIGGE Multimodel Data", *J. Hydrometeor*, 22: p. 1199-1219.
7. Wang, C. et al. (2023), "Quantitative Precipitation Forecasts Using Numerical Models: The Example of Taiwan", In: Park, S.K. (eds) in *Numerical Weather Prediction: East Asian Perspectives*, Springer Atmospheric Sciences: Springer, Cham.
8. World Meteorological Organization (WMO) (2012), *Guidelines on Ensemble Prediction Systems and Forecasting*, Geneva: WMO.
9. Andrew M. E. Grose et al. (2002), "Possibilities and Limitations for Quantitative Precipitation Forecasts Using Nowcasting Methods with Infrared Geosynchronous Satellite Imagery", *Journal of Applied Meteorology* 2002, 763–785.
10. Fotios Petropoulos, D.A. et al. (2022), "Forecasting: theory and practice", *International Journal of Forecasting: Elsevier*, Volume 38, Issue 3, July–September 2022, 705-871.
11. Du, J.e.a. (2019), "Ensemble Methods for Meteorological Predictions", In: Duan, Q., Pappenberger, F., Wood, A., Cloke, H., Schaake, J. (eds) *Handbook of Hydrometeorological Ensemble Forecasting*. Berlin, Heidelberg: Springer, .
12. Wu, M.-C.Y. et al. (2018), "Typhoon Rainfall Forecasting by Means of Ensemble Numerical Weather Predictions with a GA-Based Integration Strategy", *Atmosphere*, Vol 9, Issue 11, 425. <https://doi.org/10.3390/atmos9110425>.
13. Liangbo Qi, H.Y., Peiyan Chen (2013), "Selective ensemble-mean technique for tropical cyclone track forecast by using ensemble prediction systems", *Quarterly Journal of the Royal Meteorological Society*, 140 (680). <https://doi.org/10.1002/qj.2196>
14. D.W. SHIN et al. (2003), "Ensemble Configurations for Typhoon Precipitation Forecasts", *Journal of the Meteorological Society of Japan*, 81 (4), 446 - 449.
15. Yugang Du, L.Q., Xiaogang Cao (2016), "Selective ensemble-mean technique for tropical cyclone track forecast by using time-lagged ensemble and multi-centre ensemble in the western North Pacific: Multi-centre Ensemble for Tropical Cyclone Track Forecast", *Quarterly Journal of the Royal Meteorological Society*, 142(699).
16. Masato Nishimura, M.Y. (2015), "Selective Ensemble Mean Technique for Tropical Cyclone Track Forecasts Using Multi-Model Ensembles", *Tropical Cyclone Research and Review*, 4(2): p. 71-78.
17. Astitha, M. (2020), "Weather Forecasting and Modeling Using Satellite Data", *Remote Sensing (ISSN 2072-4292)*. This special issue belongs to the section "Atmospheric Remote Sensing".
18. Zhen Wang, J.Z. et al. (2022), "A Review on the Application of Machine Learning Methods in Tropical Cyclone Forecasting", *Earth Sci., Sec. Atmospheric Science*, vol. 10, <https://doi.org/10.3389/feart.2022.902596>.
19. Jun Li, J.Z. et al. (2024), "Quantitative Applications of Weather Satellite Data for Nowcasting: Progress and Challenges", *J. Meteor. Res.*, 38(3), 1-15, DOI:10.1007/s13351-024-3138-6.
20. Purdom, J.F.W. (1984), "Use of satellite soundings and imagery for nowcasting and very-short-range forecasting", *ESA Nowcasting 2. Mesoscale Observations and Very-Short-Range Weather Forecasting*, 99-112.
21. Purdom, J.F.W. (2003), "Local severe storm monitoring and prediction using satellite data", *MAUSAM*, 54: p. 141-154. DOI: <https://doi.org/10.54302/mausam.v54i1.1498>.
22. Luying Ji, X.Z. et al. (2020), "Multimodel Ensemble Forecasts of Precipitation Based on an Object-Based Diagnostic Evaluation", *Mon. Wea. Rev.*, 148(2591–2606).
23. Ma, L.M. (2014), "Research Progress on China Typhoon Numerical Prediction Models and Associated Major Techniques", *Prog. Geophys.*, 29(3): p. 1013–1022.

24. Emanuel, K. (2018), "100 Years of Progress in Tropical Cyclone Research", *Meteor. Monogr.*, 59(11-68): p. 1-15.
25. Chen, X.P. et al (2020), "Rainfall Modeling and Prediction by Radar Echo Data Based on Machine Learning", *J. Nanjing Univ. Inf. Sci. Technol. Nat. Sci. Ed.*, 12(4): p. 483–494.
26. Mercer, A., and Grimes, A (2015), "Diagnosing Tropical Cyclone Rapid Intensification Using Kernel Methods and Reanalysis Datasets", *Procedia Comput. Sci.*, 61(422–427).
27. Hu, K. et al. (2017), "Satellite Imagery Cloud Classification Based on Transfer Learning", *Trans. Atmos. Sci.*, 2017. 40(6): p. 856-863.
28. Zhang, M. (2017), "Estimating Intensity of Tropical Cyclone over the Western North Pacific Based on TY-3C/MWTS-II Data", *Meteor. Monogr.*, 43(5), 573-580.
29. Pradhan, R. et al. (2018), "Tropical Cyclone Intensity Estimation Using a Deep Convolutional Neural Network", *IEEE Trans. Image Process.*, 27(3), 692–702.
30. Chen, R. et al. (2020), "Machine Learning in Tropical Cyclone Forecast Modeling: A Review", *Atmosphere* 2020. 11(7), 676, <https://doi.org/10.3390/atmos11070676>
31. Zhao Chen, X.Y. et al. (2018), "Cyclone Intensity Estimation Using Multispectral Imagery from the FY-4 Satellite", in *2018 International Conference on Audio, Language and Image Processing (ICALIP) 2018*. IEEE.
32. Zhou, Z.H. (2006), *Machine Learning*, Beijing: Tsinghua university press.
33. Kim, Y.-D., and Choi, S. (2007), *Nonnegative Tucker Decomposition*. Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit, 1-8.
34. Thanh Nga, P.T., Ha, P. T., & Hang, V. T. (2021), "Satellite-Based Regionalization of Solar Irradiation in Vietnam by k-Means Clustering", *Journal of Applied Meteorology and Climatology*, 60(3), 391-402.
35. Melnykov, V. et al. (2021), *On Finite Mixture Modeling and Model-Based Clustering of Directed Weighted Multilayer Networks*, *Pattern Recognit*, 112(107641). DOI:10.1016/j.patcog.2020.107641.
36. Suykens, J.A.K., and Vandewalle, J. (1999), "Least Squares Support Vector Machine Classifiers", *Neural process. Lett*, 9(3): p. 293-300.
37. Xiaole Ji, Y.B., Yanchen Bo et al; (2012), "The method of assessing shape similarity of object-based classification result of remote sensing imagery", *Conference: Earth Observation and Remote Sensing Applications (EORS/A), 2012 Second International Workshop on*.
38. Orman, A. (2023), *Image Retrieval Using Pixel Similarity*. LicenseCC BY 4.0.
39. Z. Wang, E.P.S., A.C. Bovik, (2003), "Multiscale structural similarity for image quality assessment", in *The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, 2003*. Pacific Grove, CA, USA: IEEE.
40. Alake, R. (2023), *Understanding Cosine Similarity and Its Applications*. Expert Contributors.

## SELECTIVE ENSEMBLE FORECAST OF TC-INDUCED RAINFALL USING GSMAP DATA FOR VIET NAM REGION

**Doan Thi The, Pham Thi Thanh Nga, Tran Duy Thuc**

*The Viet Nam Institute of Meteorology, Hydrology and Climate Change*

*Received: 6/5/2024; Accepted: 31/5/2024*

**Abstract:** *Typhoon cyclone rainfall forecasting is a significant challenge due to the complexity of meteorological systems and various contributing factors. Current forecasting models still exhibit limitations that result in precipitation forecast errors. Ensemble forecasting models offer advantages such as input*

*data diversity, error minimization, and the ability to leverage information from multiple sources. However, averaging all ensemble members can also impose constraints on forecast accuracy.*

*Machine learning methods have considerable advantages in data processing, image recognition, and analyzing big datasets such as satellite data, providing an effective approach to address many existing issues in tropical cyclone (typhoon cyclone - TC) forecasting. In this study, we employ machine learning methods to improve rainfall forecasts during typhoon cyclones in Viet Nam by evaluating pixel-by-pixel similarities in rainfall values and shapes between ECMWF model data and GSMaP satellite data. From this, we propose a selective ensemble method that selects the best components from the ECMWF model to forecast rainfall during TC.*

*The results demonstrate a significant improvement of the ensemble selection method over the raw ensemble in terms of Mean Absolute Error (MAE), correlation coefficient, Critical Success Index (CSI), and Brier Skill Score (BSS) across various forecast periods and precipitation thresholds.*

**Keywords:** *Ensemble selection, GSMaP satellite data, ECMWF model, TC rainfall forecasting.*