

BỘ GIÁO DỤC
VÀ ĐÀO TẠO

VIỆN HÀN LÂM KHOA HỌC
VÀ CÔNG NGHỆ VIỆT NAM

HỌC VIỆN KHOA HỌC VÀ CÔNG NGHỆ



HOÀNG THỊ MINH CHÂU

**NGHIÊN CỨU PHÁT TRIỂN MÔ HÌNH DỰ BÁO MỨC NƯỚC HỒ
ĐA MÔ THỨC TỪ ẢNH VỆ TINH VÀ DỮ LIỆU VẬN HÀNH HỒ**

TÓM TẮT LUẬN ÁN TIẾN SĨ MÁY TÍNH

Ngành: Hệ thống thông tin

Mã số: 9 48 01 04

Hà Nội - 2026

**Công trình được hoàn thành tại: Học viện Khoa học và Công nghệ,
Viện Hàn lâm Khoa học và Công nghệ Việt Nam**

Người hướng dẫn khoa học:

Người hướng dẫn 1: PGS.TS. Trần Thị Ngân

Người hướng dẫn 2: PGS.TS. Nguyễn Long Giang

Phản biện 1: PGS.TS. Phạm Văn Hải

Phản biện 2: TS. Trần Đức Nghĩa

Luận án được bảo vệ trước Hội đồng đánh giá luận án tiến sĩ cấp Học viện
hợp tại Học viện Khoa học và Công nghệ, Viện Hàn lâm Khoa học và Công
nghệ Việt Nam vào hồi 14 giờ 00, ngày 21 tháng 4 năm 2026.

Có thể tìm hiểu luận án tại:

1. Thư viện Học viện Khoa học và Công nghệ
2. Thư viện Quốc gia Việt Nam

MỞ ĐẦU

1. Tính cấp thiết của nghiên cứu

Hồ chứa giữ vai trò quan trọng trong điều tiết dòng chảy, giảm lũ, cấp nước và phát điện, góp phần phát triển kinh tế – xã hội và ổn định hệ sinh thái. Tuy nhiên, biến đổi khí hậu đang làm thay đổi chu trình thủy văn, gia tăng các hiện tượng cực đoan và gây biến động phi tuyến trong chuỗi mực nước hồ. Nhiều hồ trên thế giới ghi nhận xu hướng suy giảm mực nước, dẫn đến mất cân đối nguồn nước, suy giảm chất lượng nước và gia tăng rủi ro an toàn hạ du, trong khi vai trò cắt lũ của hồ ngày càng trở nên cấp thiết.

Trong vận hành hồ chứa, độ tin cậy của dự báo mực nước là yếu tố then chốt cho các quyết định điều tiết và xả nước; dự báo sai có thể gây ngập lụt hoặc thiếu hụt nguồn nước. Do đó, phát triển các mô hình dự báo mực nước hồ chính xác, linh hoạt và thích ứng với biến đổi khí hậu là yêu cầu cấp bách, góp phần nâng cao hiệu quả quản lý tài nguyên nước, bảo đảm an ninh nguồn nước và giảm rủi ro do thiên tai.

2. Tóm lược các nghiên cứu về bài toán dự báo mực nước hồ

Các nghiên cứu trước đây về dự báo mực nước hồ có thể chia thành hai nhóm chính: nhóm tiếp cận truyền thống và nhóm tiếp cận học sâu.

- **Nhóm tiếp cận truyền thống:** Bao gồm các mô hình thủy lực/thủy văn [29-31], các mô hình hồi quy như ARIMA [32, 33], SARIMA [34, 35]... hoặc các mô hình học máy truyền thống [36 - 46].
- **Nhóm tiếp cận học máy/học sâu:** Sử dụng mô hình học máy hoặc học sâu như RNN/LSTM/BiLSTM/... trong dự báo mực nước hồ từ nguồn dữ liệu ảnh vệ tinh.

Trong những năm gần đây, các phương pháp dự báo mực nước hồ đa mô thức đã được phát triển mạnh mẽ [47–53]. Trọng tâm của hướng nghiên cứu này là cơ chế hợp nhất các nguồn dữ liệu khác loại (dữ liệu ảnh và dữ liệu số) nhằm xây dựng các mô hình dự báo có tính toàn diện, phản ánh đồng thời đặc trưng không gian và động thái theo thời gian của hệ thống hồ chứa.

Tiếp cận dự báo mực nước hồ đa mô thức đang thu hút nhiều sự quan tâm, tập trung vào việc khai thác sự kết hợp giữa ảnh vệ tinh và dữ liệu vận hành hồ chứa với các mô hình học sâu nhằm ước lượng mực nước hồ. Cách tiếp cận này cho phép đồng thời tận dụng thông tin không gian phong phú và khả năng bao phủ rộng của ảnh vệ tinh, cùng với đặc trưng chuỗi thời gian có độ phân giải cao và tính liên tục của dữ liệu vận hành thủy văn, từ đó nâng cao độ chính xác và tính ổn định của kết quả dự báo.

Trong những năm gần đây, ảnh vệ tinh đã trở thành một nguồn dữ liệu có giá trị cao và ngày càng được khai thác rộng rãi trong nhiều lĩnh vực khác nhau. Tiêu biểu, Ul Islam và cộng sự [59] đã sử dụng dữ liệu viễn thám để phân tích sự thay đổi về phân bố không gian và quy mô hạ tầng tại quận Peshawar (Pakistan), trong khi Song và cộng sự [60] ứng dụng ảnh vệ tinh trong lĩnh vực hàng hải, cho thấy tiềm năng lớn của dữ liệu ảnh trong việc mô tả các hiện tượng không gian – thời gian phức tạp.


Trong lĩnh vực thủy văn, ảnh vệ tinh thể hiện vai trò đặc biệt quan trọng nhờ khả năng bao phủ không gian rộng, tính liên tục theo thời gian và khả năng quan sát

từ xa. Nhiều nghiên cứu [61, 62] đã khai thác các chuỗi ảnh vệ tinh để theo dõi và dự báo biến động mực nước hồ trên quy mô lớn và trong các giai đoạn dài hạn. Đặc biệt, ảnh vệ tinh cho phép cung cấp thông tin mực nước tại những khu vực khó hoặc không thể triển khai hệ thống quan trắc thực địa, như vùng thường xuyên ngập lụt, các lưu vực sông xa xôi hay các hồ chứa quy mô lớn [63]. Bên cạnh đó, với chu kỳ cập nhật ngày càng ngắn và độ phân giải ngày càng cao, dữ liệu ảnh vệ tinh có khả năng phát hiện kịp thời cả những biến động nhỏ lẫn các thay đổi đột ngột của mực nước hồ, qua đó góp phần nâng cao độ chính xác và độ tin cậy của các mô hình dự báo [64].

Về cơ bản, các phương pháp học sâu đa mô thức đều tuân theo một quy trình xử lý thông tin tổng quát gồm 3 giai đoạn để ánh xạ các loại dữ liệu khác nhau vào một không gian dự báo thống nhất:

- *Giai đoạn biểu diễn*: Các loại dữ liệu khác nhau được tiền xử lý và chuyển đổi về các định dạng phù hợp (véc-tơ, ma trận hoặc tensor).
- *Giai đoạn hợp nhất*: Đây là bước quan trọng nhất, nơi thông tin từ các loại dữ liệu khác nhau được kết hợp lại. Quá trình này có thể diễn ra thông qua các phép toán như nối, cộng hoặc các cơ chế phức tạp hơn như cơ chế chú ý. Mục tiêu là tìm ra một biểu diễn chung chứa đựng thông tin tổng hợp của cả không gian và thời gian.
- *Giai đoạn suy luận*: Từ biểu diễn chung, mô hình sử dụng các tầng kết nối đầy đủ để thực hiện dự báo giá trị mực nước đầu ra.

Sự khác biệt căn bản giữa các nghiên cứu nằm ở việc "Giai đoạn hợp nhất" diễn ra ở đâu trong kiến trúc mạng. Dựa trên tiêu chí này, các phương pháp được phân loại thành ba chiến lược chính: Hợp nhất sớm, Hợp nhất trung gian và Hợp nhất muộn. Các phương pháp được mô tả ở Hình 0.1.



Hình 0.1. Phân loại các phương pháp hợp nhất đa mô thức

3. Khoảng trống nghiên cứu

a) Việc khai thác ảnh vệ tinh trong dự báo mực nước hồ hiện nay vẫn còn tồn tại những khoảng trống nghiên cứu đáng kể, đặc biệt trong bối cảnh các mô hình dự báo đa mô thức kết hợp dữ liệu ảnh và dữ liệu số thủy văn.

Phần lớn các nghiên cứu hiện nay sử dụng các kiến trúc CNN hoặc ResNet để trích xuất đặc trưng không gian từ ảnh vệ tinh, trong khi dữ liệu vận hành hồ và các chuỗi thủy văn thường được xử lý độc lập bằng các mô hình đơn giản như MLP hoặc các tầng kết nối đầy đủ. Các đặc trưng trích xuất chủ yếu được chuẩn hóa và hợp nhất bằng các chiến lược hợp nhất đơn giản, thường là phép nối véc-tơ tại các tầng trung gian hoặc tầng đầu ra của mô hình.

Cách tiếp cận này bộc lộ nhiều hạn chế:

Thứ nhất, cơ chế hợp nhất đặc trưng còn mang tính cơ học, chưa phản ánh đầy đủ mối liên hệ nội tại và sự tương tác động giữa thông tin không gian từ ảnh vệ tinh và động lực thời gian của hệ thống thủy văn.

Thứ hai, các phụ thuộc thời gian dài hạn – vốn có ý nghĩa quyết định trong quá trình tích nước, xả nước và điều tiết hồ chứa – chưa được khai thác hiệu quả do thiếu sự tích hợp chặt chẽ với các kiến trúc học sâu chuyên biệt cho dữ liệu chuỗi như LSTM, GRU hoặc Transformer.

Thứ ba, nhiều mô hình nhạy cảm với dữ liệu nhiễu, ảnh mây che phủ hoặc thiếu hụt ảnh vệ tinh, dẫn đến khả năng xử lý dữ liệu bất thường và tính ổn định dự báo còn hạn chế.

Cuối cùng, độ phức tạp tính toán cao của một số mô hình đa mô thức hiện có làm gia tăng thời gian huấn luyện và cản trở khả năng triển khai trong các hệ thống dự báo vận hành thực tế

b) Thiếu phân tích về đặc trưng dữ liệu mực nước hồ đa mô thức, tích hợp chặt chẽ dữ liệu ảnh vệ tinh và dữ liệu vận hành hồ. Đồng thời chưa xây dựng các hệ thống dự báo mực nước hồ đa mô thức, tích hợp chặt chẽ dữ liệu ảnh vệ tinh và dữ liệu vận hành hồ trong một kiến trúc thống nhất, nhằm khai thác hiệu quả các phụ thuộc không gian – thời gian ở nhiều thang đo khác nhau. Mục tiêu là nâng cao độ chính xác, tính ổn định và khả năng khái quát hóa của mô hình, đồng thời hướng tới khả năng ứng dụng thực tiễn trong công tác quản lý và vận hành hồ chứa.

4. Mục tiêu nghiên cứu của luận án

Mục tiêu tổng quát: Nghiên cứu xây dựng mô hình dự báo mực nước hồ đa mô thức, với nguồn dữ liệu sử dụng trong các mô hình là ảnh vệ tinh khu vực hồ và dữ liệu vận hành hồ.

Mục tiêu cụ thể:

- Đề xuất mô hình dự báo mực nước hồ đa mô thức, trong đó các đặc trưng không gian trích xuất từ ảnh vệ tinh được hợp nhất với các đặc trưng số từ dữ liệu vận hành hồ trong một không gian biểu diễn thống nhất để thực hiện dự báo.
- Thiết lập các thực nghiệm để đánh giá tính đúng đắn và hiệu suất dự báo của các mô hình đề xuất với mục tiêu là giảm sai số dự báo, nhất là trong các trường hợp có nhiễu.

- Đồng thời xây dựng hệ thống dự báo mực nước hồ đa mô thức trên nền tảng web, hỗ trợ tích hợp, lưu trữ và phân tích dữ liệu ảnh vệ tinh và dữ liệu thủy văn theo thời gian thực, phục vụ công tác quản lý và vận hành hồ chứa.

5. Những đóng góp chính của luận án

Nhằm nâng cao độ chính xác trong dự báo mực nước hồ, qua đó góp phần cải thiện hiệu quả vận hành và quản lý hồ chứa, luận án này đề xuất các đóng góp khoa học chính như sau:

- Thứ nhất, luận án đề xuất mô hình dự báo mực nước hồ đa mô thức HOG-GRU trong [CT1] cho bài toán dự báo mực nước hồ khi mực nước hồ thay đổi đột ngột trong ngày.
- Thứ hai, luận án đề xuất mô hình dự báo mực nước hồ đa mô thức Colubrid-Net trong [CT2], khi mực nước hồ gây ra biến đổi về diện tích không gian mặt nước hồ.
- Thứ ba, luận án tiến hành thực nghiệm để đánh giá hiệu suất dự báo của các mô hình đề xuất trên và xây dựng hệ thống dự báo mực nước hồ đa mô thức trên nền tảng web trong các công trình [CT3, CT4, CT5].

6. Cấu trúc luận án

- **Phần mở đầu:** trình bày tính cấp thiết, tổng quan nghiên cứu, mục tiêu, phạm vi, phương pháp và các đóng góp của luận án.
- **Chương 1:** giới thiệu về bài toán dự báo mực nước hồ và đặc điểm của nó. Bên cạnh đó, chương này cung cấp các kiến thức cơ sở quan trọng phục vụ quá trình thiết kế và hoàn thiện các mô hình dự báo được đề xuất ở các chương sau.
- **Chương 2:** đề xuất hai mô hình dự báo mực nước hồ đa mô thức HOG-GRU và Colubrid-Net để dự báo mực nước hồ trung bình ngày, với mô tả chi tiết kiến trúc, phương pháp trích xuất – hợp nhất đặc trưng từ ảnh vệ tinh và dữ liệu chuỗi thời gian, cũng như quy trình xây dựng và huấn luyện mô hình.
- **Chương 3:** trình bày các thực nghiệm đánh giá hiệu quả của các mô hình đề xuất, bao gồm mô tả khu vực nghiên cứu, dữ liệu ảnh Sentinel-2 và dữ liệu vận hành hồ, thiết kế thực nghiệm, chỉ tiêu đánh giá, kết quả và thảo luận, đồng thời giới thiệu hệ thống dự báo mực nước hồ đa mô thức.
- **Kết luận và hướng phát triển:** Phân Kết luận và hướng phát triển tổng hợp các kết quả đạt được, nêu bật những đóng góp khoa học và ứng dụng, đồng thời chỉ ra hạn chế và đề xuất các định hướng nghiên cứu tiếp theo.
- **Danh mục công trình công bố**
- **Tài liệu tham khảo**

Chương 1. CƠ SỞ LÝ THUYẾT

Nội dung chương này trình bày các kiến thức cơ sở liên quan đến bài toán dự báo mực nước hồ, bao gồm khái niệm bài toán dự báo mực nước hồ và các đặc điểm cơ bản của bài toán. Đồng thời, chương cũng giới thiệu các kiến thức phục vụ cho các hướng nghiên cứu được triển khai trong Chương 2 và Chương 3 của luận án, như: ảnh vệ tinh Sentinel-2; các mô hình dự báo mực nước hồ dựa trên phương pháp hồi quy; các mô hình dự báo mực nước hồ dựa trên học sâu; các kỹ thuật xử lý ảnh hỗ trợ cho bài toán dự báo mực nước hồ. Bên cạnh đó, các chỉ số đánh giá mô hình, phương pháp phân tích ANOVA.

Chương 2. ĐỀ XUẤT MÔ HÌNH DỰ BÁO MỰC NƯỚC HỒ ĐA MÔ THỨC

2.1. Mở đầu

Trên cơ sở phân tích các đặc điểm của bài toán dự báo mực nước hồ chứa trong điều kiện dữ liệu đa nguồn, **chương này tập trung trình bày hai mô hình dự báo mực nước hồ đa mô thức**. Các mô hình khai thác đồng thời dữ liệu ảnh vệ tinh Sentinel-2 và dữ liệu mực nước hồ quan trắc, nhằm dự báo mực nước hồ trung bình theo ngày đối với các hồ chứa có sự biến đổi hình dạng mặt nước theo mực nước. Dữ liệu ảnh vệ tinh đóng vai trò nguồn thông tin không gian bổ trợ, giúp tăng cường khả năng biểu diễn và hỗ trợ dữ liệu vận hành hồ trong quá trình dự báo.


Điểm mới chung của các mô hình đề xuất không chỉ nằm ở việc kết hợp dữ liệu ảnh và dữ liệu số, mà còn ở cách thức trích xuất đặc trưng ảnh và chiến lược hợp nhất đặc trưng. Thay vì sử dụng phép ghép nối đặc trưng đơn giản như trong nhiều nghiên cứu trước, luận án đề xuất các cơ chế hợp nhất có định hướng, đồng thời cải tiến backbone trích xuất đặc trưng ảnh nhằm khai thác hiệu quả hơn thông tin không gian từ ảnh vệ tinh. Hai mô hình đề xuất là HOG-GRU[CT1] và Colubrid-Net[CT2].

Các kết quả nghiên cứu của chương 2 được công bố trong các công trình [CT1, CT2] tại phần “DANH MỤC CÔNG TRÌNH CÔNG BỐ”.

2.2. Đề xuất mô hình dự báo đa mô thức HOG-GRU

2.2.1. Mô hình dự báo

Mô hình đề xuất được minh họa trong *Hình 2.1*. Mô hình sử dụng đồng thời ảnh vệ tinh và dữ liệu mực nước hồ thực đo làm đầu vào. Ảnh vệ tinh trước hết được chuyển thành mặt nạ hồ, sau đó áp dụng HOG để trích xuất đặc trưng dưới dạng véc-tơ và chuẩn hóa bằng chuẩn L2 nhằm thu được biểu diễn đặc trưng cuối cùng. Véc-tơ đặc trưng ảnh này được chuẩn hóa về cùng không gian với dữ liệu mực nước hồ đã được chuẩn hóa về $[0, 1]$, rồi kết hợp thông qua hàm kết hợp đặc trưng $P(y_b, f_i)$ để tạo thành biến ngoại sinh mới. Cuối cùng, biến ngoại sinh và chuỗi mực nước ban đầu được chuẩn hóa về miền $[0, 1]$ và đưa vào mô hình GRU để dự báo mực nước hồ ở thời điểm tiếp theo.



Hình 2.1. Mô hình dự báo đề xuất HOG-GRU

2.2.2. Xử lý dữ liệu

Ảnh khu vực hồ An Khê được thu thập và gán nhãn theo Mục 3.2 (Chương 3) trong giai đoạn 01/01/2019–31/12/2022, thu được 18 ảnh Sentinel-2 đã gán nhãn dưới dạng mặt nạ ranh giới, lưu ở định dạng “.txt”, với giá trị pixel 0 cho đối tượng và 255 cho nền. Các ảnh mặt nạ được chuyển sang ảnh mức xám nhằm giảm độ phức tạp dữ liệu mà vẫn bảo toàn thông tin cần thiết (Hình 2.2), sau đó chuẩn hóa về kích thước 320×320. Tiếp theo, bộ ước lượng MMSE được sử dụng để giảm nhiễu và cải thiện chất lượng ảnh, kết hợp nội suy đa điểm dựa trên hệ số tương quan Pearson để bổ sung các tháng bị thiếu, đảm bảo mỗi tháng có một ảnh đại diện. Kết quả nội suy bổ sung 30 ảnh, nâng tổng số ảnh mặt nạ lên 48. Cuối cùng, dữ liệu được làm mịn, gán chỉ mục thời gian theo tháng và chuẩn hóa bằng phương pháp Min–Max trong môi trường Python.



Hình 2.2. Ví dụ minh họa ảnh mặt nạ hồ An Khê


Dữ liệu vận hành của hai hồ An Khê và Ka Nak sau xử lý gồm 1.461 mẫu, được lập chỉ mục tuần tự theo ngày, ưu tiên tính nhất quán và khả năng hợp nhất vào mô hình dự báo, chuỗi dữ liệu mực nước đầu vào được chuẩn hóa về [0-1].

2.2.3. Trích xuất đặc trưng ảnh và xử lý nhiễu

Ảnh mặt nạ hồ được chuẩn hóa cường độ điểm ảnh về khoảng $[0,1]$ và đưa vào thuật toán HOG. Mỗi ảnh mặt nạ được biểu diễn bởi một véc-tơ đặc trưng. Các véc-tơ này có độ dài phụ thuộc vào kích thước ảnh đầu vào và được chuẩn hóa bằng chuẩn L2 nhằm đảm bảo tính ổn định và nhất quán của đặc trưng. Sau bước đó thu được tập giá trị đặc trưng HOG. Được minh họa tại *Hình 2.3*. Chuẩn hóa L2 được sử dụng theo công thức sau:

$$g_i = \sqrt{\sum v_i^2} \quad (2.1)$$

Trong đó: v_i là giá trị của từng phần tử trong véc-tơ đặc trưng HOG, g_i là biểu thị cường độ tổng thể của đặc trưng, giúp nhấn mạnh các giá trị nổi bật và giảm ảnh hưởng của nhiễu nhỏ trong ảnh.



Hình 2.3. Sơ đồ thuật toán HOG

2.2.4. Hợp nhất dữ liệu mực nước và đặc trưng ảnh

Hàm hợp nhất $P(y_t, f_t)$ được biểu diễn trong công thức (2.2):

$$P(y_t, f_t) = \frac{y_t f_t}{1 + f_t} \left[1 - S(y_t - a) \right] + \mu \left[S(y_t - a) - S(y_t - b) \right] + \left(y_t + \frac{\mu}{f_t} \right) S(y_t - b) \quad (2.2)$$

Trong đó

$$S(x) = \begin{cases} 0; & x \leq 0 \\ 3x^2 - 2x^3; & 0 < x < 1, \\ 1; & x \geq 1 \end{cases} \quad (2.3)$$

y_t là giá trị mực nước tại thời điểm t và $y_t > 0$, f_t là hệ số tỉ lệ tương ứng với mỗi y_t , đại diện cho giá trị đặc trưng ảnh đã được chuẩn hóa về cùng không gian với dữ liệu mực nước hồ, với $f_t > 0$, μ là giá trị trung bình của chuỗi y_t , a và b lần lượt là giới hạn trên và dưới của khoảng tin cậy, được xác định bởi:

$$a = \mu - \frac{\sigma}{\sqrt{N}} * \alpha \quad (2.4), \quad b = \mu + \frac{\sigma}{\sqrt{N}} * \alpha$$

Tham số α không phải là tốc độ học mà là hệ số z-score, được sử dụng để xác định khoảng tin cậy của chuỗi mực nước. Trong nghiên cứu này, $\alpha = 3.291$, tương ứng với mức tin cậy 99,9%. Các giá trị nằm trong khoảng $[a, b]$ được xem là bình thường, trong khi những giá trị nằm ngoài khoảng này được xác định là bất thường và được làm nổi bật thông qua hàm hợp nhất.

2.2.5. Triển khai và huấn luyện mô hình GRU

Dữ liệu mực nước hồ và đặc trưng hợp nhất từ ảnh vệ tinh được chuẩn hóa Min-Max về $[0,1]$ và chia thành các tập huấn luyện, kiểm định và kiểm thử theo tỷ lệ 7:1.5:1.5.

Nghiên cứu cài đặt mô hình GRU để dự báo mực nước hồ từ chuỗi thời gian đa biến, với đầu vào dạng (time steps, features). Kiến trúc gồm hai lớp GRU (64 và 32 nút) xen kẽ hai lớp Dropout 30%, và một lớp Dense đầu ra với hàm sigmoid cho giá trị dự báo chuẩn hóa. Mô hình được huấn luyện bằng Adam ($\text{lr} = 1\text{e-}3$), hàm mất mát MSE, trong 300 epoch, batch size 32, kết hợp ModelCheckpoint để lưu mô hình tốt nhất.

2.3. Đề xuất mô hình dự báo mực nước hồ đa mô thức Colubrid-Net

Bài toán dự báo mực nước hồ chứa là một bài toán dự báo không gian – thời gian phức tạp, đòi hỏi phải đồng thời nắm bắt động lực thủy văn theo thời gian và đặc trưng không gian của hồ. Về mặt hình thức, bài toán được mô tả như việc học một hàm ánh xạ:


$$f: X \times S \rightarrow R$$

Trong đó, $X \subseteq \mathbb{R}^{T \times d}$ biểu diễn tập dữ liệu chuỗi thời gian đa biến gồm T bước thời gian với d đặc trưng, $S \subseteq \mathbb{R}^{H \times W \times C}$ là dữ liệu ảnh vệ tinh có chiều cao H , chiều rộng W và C kênh phổ, còn đầu ra là một giá trị vô hướng biểu thị mực nước dự báo.

2.3.1. Ý tưởng của mô hình đề xuất

Lưu ý đề xuất một kiến trúc đa mô thức mới, tích hợp cơ chế trích xuất đặc trưng không gian dựa trên U-Net với mô hình hóa chuỗi thời gian, như minh họa trong Hình 2.4. Ý tưởng cốt lõi của thiết kế này là động thái mực nước hồ chứa chịu ảnh

hướng đồng thời bởi các mẫu thời gian ngắn hạn trong dữ liệu quan trắc thủy văn và các đặc trưng không gian mang tính ổn định, lâu dài của hệ thống hồ chứa.



Hình 2.4. Kiến trúc Colubrid-Net

Quy trình xử lý của mô hình bao gồm ba thành phần chính:

1. Mô-đun trích xuất đặc trưng không gian đa tỉ lệ xây dựng trên kiến trúc U-Net (U-Net-based multiscale spatial feature extractor - UMSFE), thực hiện xử lý ảnh vệ tinh hồ chứa nhằm trích xuất các biểu diễn đặc trưng không gian theo cấu trúc phân cấp;
2. Mô-đun trích xuất đặc trưng thời gian dựa trên mạng perceptron đa tầng (Multilayer perceptron temporal feature extractor - MTFE), chuyển đổi dữ liệu chuỗi thời gian thành các véc-tơ nhúng thời gian có mật độ cao;
3. Mô-đun hợp nhất theo thời gian dựa trên BiLSTM (TF-BiLSTM), đảm nhiệm việc suy luận không-thời gian tổng hợp trên các đặc trưng đa mô thức đã được hợp nhất.

Đóng góp chính của Phương pháp đề xuất là khai thác trích xuất đặc trưng đa tỉ lệ từ cả bộ mã hóa và bộ giải mã của U-Net nhằm nắm bắt đồng thời đặc trưng cục bộ và bối cảnh toàn cục, qua đó nâng cao biểu diễn không gian và độ chính xác dự báo

mực nước hồ. Mô hình kết hợp đặc trưng không gian từ ảnh vệ tinh (UMSFE) và đặc trưng thời gian từ chuỗi dữ liệu (MTFE), sử dụng nội suy thời gian để đồng bộ độ phân giải, hợp nhất đa mô thức bằng phép nối và dự báo mực nước bằng BiLSTM với hàm mất mát MSE.

Các khái niệm cơ sở:

Ký hiệu $I_t \in \mathbb{R}^{H \times W}$ là ảnh vệ tinh quan trắc hồ chứa tại thời điểm t , và $x_t \in \mathbb{R}^d$ biểu diễn véc-tơ chuỗi thời gian đa biến tương ứng, bao gồm mực nước, lưu lượng xả, lưu lượng vào hồ, cùng các đặc trưng được xây dựng thêm như chỉ báo mùa vụ và các biến trễ.

Mục tiêu của bài toán là dự báo mực nước y_{t+l} tại thời điểm kế tiếp, dựa trên các quan trắc lịch sử $\{I_{t-\tau+l}, \dots, I_t\}$ và $\{x_{t-\tau+l}, \dots, x_t\}$ trong một cửa sổ hồi quy có kích thước τ .

2.3.2. Kiến trúc UMSFE

1) Mạng C3STR (C3 Swin Transformer)

Kiến trúc UMSFE sử dụng mạng C3 Swin Transformer nhằm khắc phục những hạn chế của CNN trong việc mô hình hóa các mối quan hệ không gian đa tỉ lệ trong ảnh vệ tinh [96]. Mô-đun C3 nguyên gốc được đề xuất trong YOLOv5 [97] tuy hiệu quả trong trích xuất đặc trưng cục bộ, nhưng có trường tiếp nhận hạn chế, do đó chưa đủ khả năng nắm bắt các mối quan hệ toàn cục cần thiết để biểu diễn các chi tiết nhỏ ở mức tinh. Trong nghiên cứu này, ảnh vệ tinh của hệ thống hồ chứa chứa đựng thông tin không gian không đồng nhất ở nhiều thang đo khác nhau, từ kết cấu bề mặt nước chi tiết đến ranh giới lưu vực ở quy mô thô, đòi hỏi các kiến trúc có khả năng trích xuất đặc trưng đa tỉ lệ một cách mạnh mẽ và hiệu quả.

Swin Transformer (ST) [98] cải tiến Vision Transformer (ViT) [99] bằng cách đưa vào cơ chế tự chú ý phân cấp dựa trên các cửa sổ dịch chuyển, qua đó giảm độ phức tạp tính toán từ bậc hai xuống tuyến tính, đồng thời vẫn duy trì khả năng mô hình hóa ngữ cảnh toàn cục. C3STR khai thác các ưu điểm này thông qua kiến trúc hai nhánh, như minh họa trong *Hình 2.5.(a)*: một nhánh xử lý đặc trưng bằng ST nhằm nắm bắt các phụ thuộc dài hạn và ngữ cảnh toàn cục, như thể hiện trong *Hình 2.5.(b)*, trong khi nhánh còn lại bảo toàn đặc trưng ban đầu thông qua ánh xạ đồng nhất để đảm bảo dòng lan truyền gradient ổn định. Mỗi khối Swin Transformer (ST) luân phiên giữa cơ chế tự chú ý đa đầu dựa trên cửa sổ (Window-based Multi-Head Self-Attention - W-MSA) và W-MSA dịch chuyển (Shifted Window Multi-Head Self-Attention - SW-MSA), như minh họa trong *Hình 2.5.(c)* và được biểu diễn bằng các công thức sau:

$$\hat{z}^l = \text{W-MSA}(\text{LN}(z^{l-1})) + z^{l-1} \quad (2.4)$$

$$z^l = \text{MLP}(\text{LN}(\hat{z}^l)) + \hat{z}^l \quad (2.5)$$


$$\hat{z}^{l+1} = \text{SW-MSA}(\text{LN}(z^l)) + z^l \quad (2.6)$$

$$z^{l+1} = \text{MLP}(\text{LN}(\hat{z}^{l+1})) + \hat{z}^{l+1} \quad (2.7)$$

trong đó, l là chỉ số tầng trong khối ST; z^{l-1} , z^l , z^{l+1} là các biểu diễn đặc trưng của ảnh đầu vào, $\hat{z}^{l-1}$, $\hat{z}^l$, $\hat{z}^{l+1}$ là biểu diễn tạm thời đặc trưng của ảnh đầu vào tại các

tầng liên tiếp $l-1, l, l+1$, đây là các tensor đặc trưng không gian được cập nhật tuần tự qua từng khối Transformer. LN (Layer Normalization) chuẩn hóa theo kênh đặc trưng, giúp ổn định quá trình huấn luyện và cải thiện khả năng hội tụ của mô hình.

Chiến lược phân hoạch cửa sổ chia các đặc trưng đầu vào thành các cửa sổ không chồng lấn kích thước $M \times M$ để thực hiện cơ chế tự chú ý cục bộ, trong khi ác cửa sổ dịch chuyển ở các lớp tiếp theo cho phép trao đổi thông tin giữa các vùng khác nhau. Đối với ảnh vệ tinh hồ chứa, mô-đun C3STR có khả năng nắm bắt các đặc trưng không gian tỉ lệ, từ những cấu trúc tinh như trạng thái bề mặt nước đến các ngữ cảnh thô hơn, bao gồm hình học hồ chứa và các kiểu sử dụng đất xung quanh.



Hình 2.5. Tổng quan kiến trúc của mô-đun C3STR. (a) Thiết kế hai nhánh của C3STR; (b) cấu trúc xử lý phân cấp của mô-đun Swin Transformer (ST) với cơ chế gộp mảnh (patch merging) và các khối Transformer; (c) cấu trúc của một khối ST gồm các mô-đun được sắp xếp tuần tự.

2) Hàm kích hoạt Snake động

Để tăng cường khả năng mô hình hóa phi tuyến, chúng tôi sử dụng hàm kích hoạt Snake động [100] cho cả nhánh mã hóa và giải mã. Hàm kích hoạt Snake cung cấp một dạng kích hoạt tuần hoàn có khả năng học, phù hợp để mô hình hóa các phép biến đổi đặc trưng phức tạp, và được biểu diễn như sau:

$$\text{Snake}(x) = x + \frac{1}{\alpha} \sin^2(\alpha x) \quad (2.8)$$

trong đó α là tham số tần số có thể học, điều khiển tính tuần hoàn và biên độ của thành phần hình sin. Không giống các hàm kích hoạt cố định như ReLU hay GELU, tham số α có khả năng thích nghi trong quá trình huấn luyện, cho phép mô

hình tự điều chỉnh đặc tính phi tuyến theo từng nhiệm vụ cụ thể, qua đó tối ưu hóa việc trích xuất đặc trưng từ ảnh vệ tinh hồ chứa.

3) Kiến trúc đề xuất

Mô-đun trích xuất đặc trưng không gian của nghiên cứu được thiết kế nhằm học biểu diễn đa tỉ lệ từ ảnh vệ tinh hồ chứa, và bộ mã hóa (encoder) của mô hình tuân theo chiến lược giảm mẫu phân cấp, được mô tả như sau:

$$e_l = \text{DoubleConv}(I_l) \quad (2.9)$$

$$e_i = \text{Down}(e_{i-1}), i \in \{2, 3, 4\} \quad (2.10)$$

$$e_5 = \text{DownC3STR}(e_4) \quad (2.11)$$

trong đó DoubleConv thực hiện hai phép tích chập liên tiếp kèm theo chuẩn hóa theo lô và hàm kích hoạt; Down thực hiện phép gộp cực đại trước khi áp dụng khối tích chập kép; và DownC3STR tích hợp mô-đun C3STR nhằm tăng cường khả năng biểu diễn đặc trưng tại điểm nghẽn. Sau đó, bộ giải mã tái tạo thông tin không gian thông qua quá trình tăng mẫu và các kết nối tắt như sau:

$$d_l = \text{Up}(e_5, e_4) \quad (2.12)$$

$$d_i = \text{Up}(d_{i-1}, e_{5-i}), i \in \{2, 3, 4\} \quad (2.13)$$

Nghiên cứu định nghĩa tập đặc trưng của bộ mã hóa $E = \{e_3, e_4, e_5\}$ và tập đặc trưng của bộ giải mã $D = \{d_1, d_2, d_3, d_4\}$. Mỗi bản đồ đặc trưng sau đó được đưa qua phép gộp trung bình tổng quát (Generalized Mean pooling – GeM), được xác định bởi công thức:

$$\text{GeM}(F) = (1/HW \sum_{i=1}^H \sum_{j=1}^W F_{i,j}^p)^{1/p} \quad (2.14)$$

trong đó p là tham số có thể học. Biểu diễn không gian cuối cùng thu được bằng cách nối (ký hiệu $\oplus$) tất cả các đặc trưng đã được gộp:

$$f^{spa} = \text{LayerNorm}(\oplus (\cup_{F \in E \cup D} \text{GeM}(F))) \quad (2.15)$$

sau đó được chiếu qua một mạng MLP hai lớp để thu được véc-tơ đặc trưng không gian cuối cùng $z^{spa} \in R^{1024}$.

2.3.3. Kiến trúc MTFE

Nhánh thời gian của mô hình xử lý dữ liệu chuỗi thời gian đa biến thông qua các lớp MLP. Trước hết, các đặc trưng đầu vào của mô hình được chuẩn hóa theo dạng $\tilde{x}_t = \text{StandardScale}(x_t)$, và sau đó quá trình trích xuất đặc trưng theo thời gian được thực hiện theo các bước:

$$h_1 = \text{ReLU}(W_1 \tilde{x}_t + b_1) \quad (2.16)$$

$$h_2 = \text{ReLU}(W_2 h_1 + b_2) \quad (2.17)$$

$$h_3 = \text{ReLU}(W_3 h_2 + b_3) \quad (2.18)$$

$$z^{temp} = \text{ReLU}(W_4 h_3 + b_4) \quad (2.19)$$

Ở đây, W_i và b_i là các tham số có thể học được, và chiều của véc-tơ đầu ra là $z^{temp} \in R^{1024}$, đóng vai trò là biểu diễn nén giàu thông tin cho chuỗi thời gian thủy văn trước khi được hợp nhất với đặc trưng không gian

2.3.4. Căn chỉnh theo thời gian và nội suy đặc trưng ảnh

Để giải quyết sự không tương thích về mặt thời gian giữa dữ liệu ảnh vệ tinh theo tháng và dữ liệu chuỗi thời gian theo ngày, luận án phát triển một cơ chế nội suy theo thời gian, cho phép mở rộng các đặc trưng ảnh từ độ phân giải theo tháng lên độ phân giải theo ngày, đồng thời bảo toàn đặc trưng biến thiên theo mùa và đưa vào các thông thái thời gian mang tính thực tế.

Cụ thể, với tập đặc trưng ảnh theo tháng $\{z_m^{spa}\}_{m=1}^M$, trong đó M là số tháng quan trắc, chúng tôi sinh ra tập đặc trưng theo ngày $\{z_d^{spa}\}_{d=1}^D$ cho D ngày bằng cách sử dụng chiến lược nội suy sau đây. Đối với mỗi ngày d trong tháng m , đặc trưng nội suy cơ sở được tính là $z_d^{base} = z_m^{spa}$. Để mô hình hóa tính biến thiên theo thời gian phản ánh những thay đổi thực tế của điều kiện hồ chứa, chúng tôi áp dụng các nhiễu loạn mang tính mùa vụ và ngẫu nhiên theo công thức sau:

$$s_d = \alpha_s \sin \left(\frac{2\pi \cdot \text{day_of_year}(d)}{365} \right) \quad (2.20)$$

$$\epsilon_d \sim \mathcal{N}(0, \sigma^2 I) \quad (2.21)$$

$$z_d^{spa} = z_d^{base} + s_d + \epsilon_d \quad (2.22)$$

trong đó $\alpha = 0.05$ điều khiển biên độ biến thiên theo mùa, $\sigma = 0.02$ xác định mức độ của các nhiễu loạn ngẫu nhiên, và I là ma trận đơn vị. Chiến lược nội suy này bảo toàn các đặc trưng không gian nền tảng được trích xuất từ ảnh vệ tinh theo tháng, đồng thời đưa vào các biến thiên theo thời gian có kiểm soát nhằm phản ánh bản chất động của hệ thống hồ chứa.

2.3.5. BiLSTM trong hợp nhất theo thời gian

Các đặc trưng đa mô thức được hợp nhất thông qua phép nối, được xác định như sau:

$$z_t = z_t^{spa} \oplus z_t^{temp} \in R^{2048} \quad (2.23)$$

Để xử lý sự không khớp về mặt thời gian giữa ảnh vệ tinh theo tháng và chuỗi số liệu đo đạc theo ngày, chúng tôi sử dụng phương pháp nội suy theo thời gian nhằm mở rộng các đặc trưng ảnh theo tháng lên độ phân giải ngày, như đã trình bày trong Mục 2.3.4. Mô hình hóa chuỗi sử dụng BiLSTM hai lớp với số chiều ẩn $h = 128$, và quá trình này có thể được biểu diễn bằng các phương trình sau:

$$i_t = \sigma(W_{ii}z_t + b_{ii} + W_{hi}h_{t-1} + b_{hi}) \quad (2.24)$$

$$f_t = \sigma(W_{if}z_t + b_{if} + W_{hf}h_{t-1} + b_{hf}) \quad (2.25)$$

$$o_t = \sigma(W_{io}z_t + b_{io} + W_{ho}h_{t-1} + b_{ho}) \quad (2.26)$$

$$g_t = \tanh(W_{ig}z_t + b_{ig} + W_{hg}h_{t-1} + b_{hg}) \quad (2.27)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (2.28)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.29)$$

Trong thiết lập hai chiều, trạng thái ẩn cuối cùng tại thời điểm t được thu bằng cách nối trạng thái ẩn xuôi và ngược cụ thể:

$$h_t^{bi} = h_t^{fwd} \oplus h_t^{bwd} \quad (2.30)$$

Sau đó, dự báo cuối cùng được tạo ra thông qua một tầng đầu ra hai lớp

$$\hat{y}_{t+1} = W_{out} ReLU(W_{proj} h_t^{bi} + b_{proj}) + b_{out} \quad (2.31)$$

Nhằm thu được một giá trị vô hướng biểu diễn mực nước hồ dự báo ở thời điểm thứ $t+1$.

2.4. Kết luận chương


Mô hình HOG-GRU được đề xuất nhằm khắc phục hạn chế của các phương pháp dự báo đa mô thức trước đây bằng cách sử dụng thuật toán HOG thay cho các mạng CNN phức tạp trong trích xuất đặc trưng ảnh vệ tinh, qua đó giảm chi phí tính toán, rút ngắn thời gian huấn luyện và tăng tốc suy luận. Đồng thời, mô hình đề xuất cơ chế hợp nhất đặc trưng giữa ảnh vệ tinh và chuỗi mực nước, giúp cải thiện khả năng nhận diện các biến động mực nước đột ngột. Tuy nhiên, hạn chế của HOG-GRU là đặc trưng ảnh vẫn được gán cố định theo tháng, chưa phản ánh đầy đủ tính động theo thời gian của hồ chứa.

Từ đó, luận án phát triển mô hình Colubrid-Net với kiến trúc đa mô thức nâng cao, sử dụng U-Net cải tiến tích hợp khối C3STR nhằm khai thác đồng thời đặc trưng cục bộ và quan hệ không gian toàn cục từ ảnh vệ tinh đa tỷ lệ. Bên cạnh đó, mô hình đề xuất cơ chế căn chỉnh thời gian và nội suy mùa vụ để chuyển đặc trưng ảnh từ tần suất tháng sang ngày, đồng bộ với chuỗi số liệu thủy văn. Sau khi hợp nhất đặc trưng, mạng BiLSTM được sử dụng để học phụ thuộc thời gian hai chiều và nâng cao độ chính xác dự báo mực nước hồ hằng ngày. Các kết quả trong chương 2 đã được công bố trong công trình [CT1, CT2] thuộc “**DANH MỤC CÔNG TRÌNH CÔNG BỐ**”.

Chương 3. KẾT QUẢ THỰC NGHIỆM VÀ XÂY DỰNG MÔ HÌNH DỰ BÁO MỨC NƯỚC HỒ

3.1. Khu vực nghiên cứu

Hệ thống hồ An Khê – Ka Nak (tỉnh Gia Lai) được lựa chọn làm khu vực nghiên cứu điển hình do có điều kiện tự nhiên phức tạp, địa hình dốc và chế độ vận hành liên hồ, gây ra biến động mực nước nhanh và phi tuyến. Hai hồ nằm trong vùng thường xuyên chịu mưa lớn, lũ xảy ra nhanh và hạn kéo dài, với biên độ dao động mực nước lớn và khó dự báo. Đây là khu vực có rủi ro cao trong điều tiết lũ, đòi hỏi các mô hình dự báo mực nước chính xác và kịp thời, đặc biệt khi tích hợp dữ liệu đa mô thức.



Hình 3.1. Vị trí địa lý hồ An Khê và Ka Nak

3.2. Quy trình thu thập và gán nhãn ảnh vệ tinh Sentinel-2

Trong phần này, luận án mô tả chi tiết quy trình thu thập và gán nhãn ảnh vệ tinh Sentinel-2. Dữ liệu ảnh vệ tinh được thu thập từ chương trình Copernicus, một thành phần quan trọng của chương trình không gian Liên minh Châu Âu. Các ảnh này được lấy từ vệ tinh Sentinel-2. Hiện tại, chương trình Copernicus cho phép người dùng toàn cầu truy cập miễn phí nền tảng Open Hub¹ mã nguồn mở. Trong luận án này, các tiêu chí sau được áp dụng để truy xuất ảnh vệ tinh từ Copernicus:

- Chọn mức xử lý Mức xử lý là Level 2A; ngưỡng che phủ mây đặt < 20%;
- Giai đoạn thu thập dữ liệu khu vực hồ An Khê từ ngày 1 tháng 1 năm 2018 đến ngày 31 tháng 12 năm 2023;
- Các kênh màu được chọn bao gồm R4 (đỏ), G3 (xanh lục) và B2 (xanh lam).

Với các tiêu chí lựa chọn như trên, ảnh thu được có độ sắc nét và giống ảnh thực tế tự nhiên của hồ. Kết quả thu được 34 ảnh vệ tinh khu vực hồ chứa An Khê.

¹ <https://dataspace.copernicus.eu/>

Các ảnh vệ tinh sau khi tải về được xử lý để trích xuất khu vực hồ An Khê bằng phần mềm SNAP². Quá trình gán nhãn ảnh được thực hiện theo các tiêu chí thống nhất và phù hợp nhằm xây dựng tập dữ liệu cùng với nhãn tương ứng cho từng ảnh. Trong phần mềm SNAP, các bước sau được thực hiện để xác định tọa độ khu vực hồ:

Bước 1: Chọn tệp ZIP và mở nó với các kênh màu R4 (đỏ), G3 (xanh lục) và B2 (xanh lam). Phóng to hình ảnh hiển thị đến vị trí hồ An Khê.

Bước 2: Sử dụng công cụ vẽ hình chữ nhật để khoanh vùng khu vực hồ An Khê.

Bước 3: Lấy tọa độ định dạng WKT từ Geometry và lưu tạm thời vào bộ nhớ.

Bước 4: Mở GraphBuilder³, tạo tập con (chọn các kênh 4, 3, 2) và lưu biểu đồ.

Bước 5: Chỉnh sửa đa giác trong biểu đồ với tọa độ của khu vực hồ.

Bước 6: Xuất tệp đầu ra cuối cùng dưới dạng Mygraph.xml.

Các tệp dữ liệu được tải xuống từ trang web Copernicus và xử lý trong phần mềm SNAP. Các tọa độ của đa giác được áp dụng cho khu vực hồ, sau đó phần mềm tự động tạo các ảnh cắt ở định dạng PNG. Các ảnh thu được là khu vực hồ An Khê. Các ảnh này được minh họa ở Hình 3.2. Từ các ảnh đã thu thập, bước tiếp theo là gán nhãn khu vực mặt nước của hồ An Khê bằng công cụ CVAT⁴ trong môi trường gán nhãn cho bài toán phân đoạn đối tượng với một lớp duy nhất (hồ). Cụ thể, các tệp ảnh vệ tinh được tải lên và gán nhãn theo các nguyên tắc sau: khu vực cần phân đoạn là vùng mặt nước, đặc trưng bởi màu sắc tương đối đồng nhất và liên tục; các điểm được đặt để xác định ranh giới giữa vùng nước và vùng không phải nước; các điểm này được nối lại để tạo thành một đa giác thể hiện chính xác nhất hình dạng của hồ chứa, như minh họa trong Hình 3.3. Sau khi hoàn tất quá trình gán nhãn, dữ liệu được lưu trữ trong cơ sở dữ liệu MongoDB với hai trường chính là “**images**” và “**labels**”.



Hình 3.2. Ví dụ hình ảnh Sentinel-2 khu vực hồ An Khê Hình 3.3. Ảnh hồ sau gán nhãn hồ

3.3. Mô tả dữ liệu thực nghiệm

Dữ liệu ảnh Sentinel-2 khu vực hồ An Khê và Ka Nak được thu thập từ 1/1/2019 đến 31/12/2022, thu thập theo quy trình mô tả ở Mục 3.2. Hồ An Khê được 18 ảnh, hồ Ka Nak được 32 ảnh. Dữ liệu vận hành hồ của hai hồ cũng được thu thập cùng thời gian đó. Các trường dữ liệu thu thập gồm: Thời gian, mực nước hồ, lưu lượng đến,

² <https://step.esa.int/main/download/snap-download/>

³ https://docs.yworks.com/yfiles-html/dguide/graph_builder/graph_builder-GraphBuilder.html

⁴ <https://www.cvat.ai/>

lưu lượng xả. Dữ liệu được thu thập theo từng giờ. Sau đó dữ liệu được xử lý và tính mực nước trung bình theo ngày được 1.461 quan trắc theo ngày (Hình 3.4 minh họa)

1	Hồ chứa	LVS/Hồ/Ngày/Giờ	LVS/Hồ chứa/Ngày	Mức nước hồ (m)	Lưu lượng đến hồ (m ³ /s)	Tổng lưu lượng xả (m ³ /s)[Thực tế]
2	An Khê	0	2/4/2022	428.37	40.15	49
3	An Khê	1	2/4/2022	428.36	40.23	49
4	An Khê	2	2/4/2022	428.35	40.32	49
5	An Khê	3	2/4/2022	428.34	40.26	49
6	An Khê	4	2/4/2022	428.33	40.19	49

Hình 3.4. Ví dụ minh họa dữ liệu vận hành hồ ngày 2/4/2022

3.4. Đánh giá hiệu năng mô hình HOG-GRU

Nghiên cứu tiến hành so sánh mô hình HOG-GRU được đề xuất với các mô hình dự báo tiên tiến thường được sử dụng cho dữ liệu chuỗi thời gian, bao gồm RNN, LSTM, GRU, HOG-RNN và HOG-LSTM. Kết quả được chỉ ra trong Bảng 3.1.

Bảng 3.1. Các chỉ số đánh giá hiệu năng của các mô hình dự báo được áp dụng cho toàn bộ dữ liệu kiểm tra của hồ An Khê.

Mô hình	MSE	RMSE	MAE	Tracking Signal	Phương sai
RNN	0.10637	0.32615	0.24107	-0.17156	0.10773
HOG-RNN	0.08613	0.29348	0.20533	0.16751	0.08745
LSTM	0.11056	0.33250	0.23836	-0.12391	0.10433
HOG-LSTM	0.08604	0.29332	0.20479	-0.05545	0.08608
GRU	0.10527	0.32445	0.23795	-0.18261	0.10108
HOG-GRU	0.08060	0.28390	0.20446	-0.00032	0.08473

Ngoài ra, nghiên cứu đánh giá hiệu năng mô hình trên một tập dữ liệu chứa các điểm bất thường nhằm kiểm chứng khả năng dự báo trong các điều kiện phi tuyến và cực đoạn. Kết quả tương ứng được trình bày trong Bảng 3.2.

Bảng 3.2. Các chỉ số đánh giá hiệu năng của các mô hình trên tập dữ liệu chứa các điểm bất thường của hồ An Khê.

Mô hình	MSE	RMSE	MAE	Tracking Signal	Phương sai
RNN	0.11297	0.33611	0.24897	0.15842	0.12088
HOG-RNN	0.09136	0.30230	0.21256	-0.16571	0.09974
LSTM	0.11699	0.34203	0.24521	0.11173	0.11658
HOG-LSTM	0.09120	0.30199	0.21249	0.05765	0.10191
GRU	0.11133	0.33367	0.24472	0.17023	0.11204
HOG-GRU	0.08546	0.29234	0.21044	-0.02169	0.09783

Luận án cũng tiến hành cài đặt thực nghiệm và đánh giá các mô hình trên cả bộ dữ liệu hồ chứa Ka Nak, kết quả thể hiện trong Bảng 3.3.

Bảng 3.3. Các chỉ số đánh giá hiệu năng của các mô hình dự báo mực nước hồ được áp dụng cho toàn bộ tập dữ liệu kiểm tra của hồ Ka Nak.

Mô hình	MAE	MSE	RMSE	Tracking Signal	Phương sai
RNN	0.95277	1.11083	1.05396	-0.46232	19.33899
LSTM	0.65120	0.63653	0.79783	-0.02049	21.21868
GRU	0.62975	0.58228	0.76307	0.01026	22.01869
HOG-RNN	0.50916	0.39607	0.62934	-0.54665	23.75432
HOG-LSTM	0.45496	0.31161	0.55822	-0.43542	24.72102
HOG-GRU	0.37937	0.20795	0.45601	-0.03985	22.69440

Trong phần này, luận án tiến hành thực nghiệm so sánh kết quả của hai mô hình dự báo đa mô thức đề xuất VGG19-SARIMAX [CT4] và HOG-GRU. Kết quả thực nghiệm được trình bày trong Bảng 3.4.

Bảng 3.4. So sánh chỉ số đánh giá mô hình VGG19-SARIMAX và HOG-GRU.

Mô hình	MAE	MSE	RMSE	Tracking Signal	Train time (minutes)
VGG19-SARIMAX	0.26858	0.10492	0.32392	0.14551	2880
HOG-GRU	0.20408	0.08355	0.28905	0.02625	2

• **Nhận xét:**

Luận án đã thực hiện chuỗi thực nghiệm toàn diện nhằm đánh giá hiệu suất của mô hình HOG-GRU, trong đó kết quả cho thấy mô hình đề xuất đạt hiệu quả vượt trội so với các phương pháp so sánh. Các kết quả này không chỉ khẳng định tính hợp lý của chiến lược hợp nhất dữ liệu được đề xuất, mà còn cho thấy việc sử dụng HOG để trích xuất đặc trưng ảnh giúp giảm đáng kể chi phí tính toán trong khi vẫn duy trì chất lượng dự báo, so với các phương pháp dựa hoàn toàn trên mạng học sâu.

Trong phần đánh giá này, luận án tiến hành phân tích và đánh giá tác động của các tham số và thành phần trong hàm hợp nhất đến hiệu năng dự báo của mô hình dự báo đề xuất HOG-GRU.

• ***Việc thêm các trọng số vào thành phần của hàm hợp nhất $P(y_b, f_i)$ có ảnh hưởng như thế nào đến hiệu suất của mô hình dự báo?***

Công thức của hàm hợp nhất $P(y_b, f_i)$ sau khi thêm các trọng số w_1 , w_2 và w_3 , được biến đổi thành công thức $P'(y_b, f_i)$ như sau:

$$P'(y_i, f_i) = w_1 \frac{y_i f_i}{1 + f_i} [1 - S(y_i - a)] + w_2 \mu [S(y_i - a) - S(y_i - b)] + w_3 \left(y_i + \frac{\mu}{f_i} \right) S(y_i - b) \quad (3.1)$$

Qua việc xem xét công thức $P'(y_b, f_i)$, có thể thấy rằng khi các trọng số bằng nhau và đều bằng 1 thì phương trình trở về dạng ban đầu $P(y_b, f_i)$. Trường hợp các trọng số $w_1 = w_2 = w_3 = 1$, như vậy được gọi là **Kịch bản 1**.

Tiếp theo, các thí nghiệm mở rộng được thực hiện với ba kịch bản khác nhau, trong đó giá trị trọng số được thay đổi như sau:

- **Kịch bản 2:** $w_1 = 2, w_2 = 1, w_3 = 1$
- **Kịch bản 3:** $w_1 = 1, w_2 = 2, w_3 = 1$
- **Kịch bản 4:** $w_1 = 1, w_2 = 1, w_3 = 2$

Trong các kịch bản này, w_1 được sử dụng để nhấn mạnh giới hạn cận dưới, w_2 nhấn mạnh các điểm trung bình (bình thường) và w_3 nhấn mạnh giới hạn trên. Kết quả thực nghiệm được trình bày trong Bảng 3.5.

Bảng 3.5. Kết quả đánh giá hiệu năng của mô hình HOG-GRU trên các kịch bản trọng số khác nhau của hàm hợp nhất.

	MAE	MSE	RMSE	Tracking Signal	Phương sai
Kịch bản 1	0.20408	0.08355	0.28905	0.02625	0.08451
Kịch bản 2	0.20619	0.08380	0.28955	0.10364	0.09358
Kịch bản 3	0.20901	0.08544	0.29230	0.18383	0.09358
Kịch bản 4	0.21381	0.08966	0.29944	-0.09678	0.09730

• **Đánh giá ảnh hưởng của α trong hàm hợp nhất $P(y_t, f_t)$ tới hiệu năng mô hình**

Dựa trên Bảng 3.6, tham số α có ảnh hưởng rõ rệt đến hiệu năng mô hình HOG-GRU. Khi α giảm, các sai số MAE, MSE và RMSE tăng nhẹ, cho thấy khoảng tin cậy mức nước hẹp hơn làm mô hình kém ổn định và giảm độ chính xác. Đồng thời, Tracking Signal chuyển từ dương nhỏ sang âm, phản ánh sự xuất hiện thiên lệch hệ thống trong dự báo. Tuy nhiên, giá trị trung bình của chuỗi dự báo hầu như không đổi, cho thấy α không ảnh hưởng đáng kể đến xu hướng trung bình tổng thể.

Bảng 3.6. Đánh giá mô hình HOG-GRU với α khác nhau trong hàm hợp nhất.

	MAE	MSE	RMSE	Tracking Signal	Phương sai
$\alpha = 1.645(90\%)$	0.21223	0.08692	0.29481	-0.05273	0.09281
$\alpha = 1.960(95\%)$	0.20939	0.08349	0.28894	-0.05881	0.07864
$\alpha = 3.291(99.9\%)$	0.20408	0.08355	0.28905	0.02625	0.08451

• **Đánh giá đóng góp của từng thành phần trong hàm hợp nhất đối với hiệu năng của mô hình dự báo.**

Phân tích này nhằm định lượng vai trò và hiệu quả của từng yếu tố trong cơ chế hợp nhất, bằng cách lần lượt loại bỏ từng thành phần nâng cao và thay thế bằng biểu diễn cơ sở tương ứng. Kết quả được trình bày trong bảng 3.7.

Bảng 3.7. Đánh giá hiệu suất của mô hình HOG-GRU khi loại bỏ từng thành phần riêng lẻ khỏi hàm hợp nhất $P(y_t, f_t)$.

	MAE	MSE	RMSE	Tracking Signal	Phương sai
Kịch bản 1	0.20611	0.08745	0.29572	0.20639	0.09589
Kịch bản 2	0.20746	0.08442	0.29055	0.03358	0.09525
Kịch bản 3	0.21508	0.08517	0.29184	-0.20966	0.08571
Kịch bản 4	0.20408	0.08355	0.28905	0.02625	0.08571

- **Kịch bản 1:** Thành phần nhấn mạnh cận dưới bị loại bỏ, khi đó hàm hợp nhất $P(y_t, f_t)$ sẽ được điều chỉnh thành hàm $P_I(y_t, f_t)$.

$$P_I(y_t, f_t) = y_t [1 - S(y_t - a)] + \mu [S(y_t - a) - S(y_t - b)] + \left(y_t + \frac{\mu}{f_t} \right) S(y_t - b) \quad (3.2)$$

- **Kịch bản 2:** Thành phần nhấn mạnh mực nước trung bình đã bị loại bỏ, khi đó hàm $P(y_b, f_f)$ sẽ được điều chỉnh thành hàm $P_2(y_b, f_f)$.

$$P_2(y_i, f_i) = \frac{y_i f_i}{1 + f_i} [1 - S(y_i - a)] + y_i [S(y_i - a) - S(y_i - b)] + \left(y_i + \frac{\mu}{f_i} \right) S(y_i - b) \quad (3.3)$$

- **Kịch bản 3:** Thành phần nhấn mạnh cận trên đã bị loại bỏ, khi đó hàm hợp nhất $P(y_b, f_f)$ sẽ được điều chỉnh thành hàm $P_3(y_b, f_f)$.

$$P_3(y_i, f_i) = \frac{y_i f_i}{1 + f_i} [1 - S(y_i - a)] + \mu [S(y_i - a) - S(y_i - b)] + y_i S(y_i - b) \quad (3.4)$$

- **Kịch bản 4:** Hàm hợp nhất $P(y_b, f_f)$ được giữ nguyên như ban đầu.

• Nhận xét:

fLượn án đã tiến hành thực nghiệm nhiều kịch bản khác nhau cho các thành phần trong hàm hợp nhất $P(y_b, f_f)$, các kết quả đều chỉ ra hàm hợp nhất mà phương pháp sử dụng cho hiệu quả tốt hơn cả.

3.5. Đánh giá hiệu năng mô hình Colubrid-Net

Các thực nghiệm được thực hiện trên ảnh Sentinel-2 và dữ liệu vận hành hồ An Khê, với quy trình tiền xử lý và thiết lập thống nhất theo mô hình HOG-GRU nhằm đảm bảo khả năng so sánh công bằng. Kết quả (Bảng 3.8) cho thấy các mô hình không tích hợp đặc trưng không gian có sai số lớn (RF: MAE = 0.7329; MLP: MAE = 4.7447), trong khi việc bổ sung thông tin không gian giúp cải thiện đáng kể hiệu suất (VGG19+GRU: MAE = 0.2356).

Trong nhóm các phương pháp tiên tiến, transformer theo thời gian đạt MAE = 0.026 nhưng có R^2 thấp (0.381) và KGE = 0.703, còn nghiên cứu của Chau et al. đạt MAE = 0.117. Colubrid-Net cho kết quả tốt nhất với MAE = 0.0242, R^2 = 0.969 và KGE = 0.972, cải thiện 7.4% so với transformer theo thời gian và 79.3% so với Chau et al., khẳng định vai trò then chốt của trích xuất đặc trưng không gian bằng transformer kết hợp nội suy theo thời gian trong nâng cao độ chính xác và độ tin cậy dự báo mực nước hồ.

Bảng 3.8. Bảng kết quả so sánh hiệu năng các mô hình dự báo

Mô hình	Đặc trưng không gian	MAE	MSE	RMSE	R^2	KGE
Linear Regression	No	1.730	4.386	2.094	0.175	0.118
Ridge Regression	No	1.730	4.387	2.094	0.175	0.118
Lasso Regression	No	1.726	4.483	2.117	0.157	0.084
SV Regression	No	0.419	0.366	0.605	0.931	0.9972
Random Forest	No	0.732	0.8971	0.947	0.831	0.894
Gradient Boosting	No	0.493	0.442	0.665	0.916	0.959
XGBoost	No	2.941	18.280	4.275	-2.436	0.140
LightGBM	No	0.577	0.553	0.744	0.895	0.950

Mô hình	Đặc trưng không gian	MAE	MSE	RMSE	R ²	KGE
CatBoost	No	0.537	0.504	0.710	0.905	0.957
AdaBoost	No	0.200	0.447	0.306	0.911	0.954
Decision Tree	No	2.828	19.925	4.463	-2.746	-0.051
K-Nearest Neighbors	No	3.025	18.342	4.282	-2.448	0.205
MLP	No	4.744	45.808	6.768	-7.612	-0.665
VGG19 w/GRU	Yes	0.235	0.129	0.360	0.929	0.967
U-Net w/GRU	Yes	0.215	1.861	1.364	0.482	0.633
Proposed w/GRU	Yes	0.031	0.007	0.008	0.972	0.967
VGG w/ BiLSTM	Yes	0.026	0.002	0.047	0.936	0.965
U-Net w/BiLSTM	Yes	0.032	0.002	0.049	0.967	0.965
Temporal Transformers [101]	No	0.026	0.009	0.030	0.381	0.703
Chau et al. [CT4]	Yes	0.117	0.268	0.145	-	-
Colubrid-Net	Yes	0.024	0.002	0.046	0.969	0.972

Bảng 3.9. So sánh hiệu suất các kiến trúc hồi quy

Kiến trúc	MAE	MSE	RMSE
MLP	0.1235	0.0168	0.1296
GRU	0.0236	0.0027	0.0523
Bi-GRU	0.0415	0.0035	0.0595
LSTM	0.0255	0.0023	0.0485
BiLSTM	0.0242	0.0022	0.0464

Để đánh giá ảnh hưởng của các phương pháp mô hình hóa theo thời gian khác nhau, Bảng 3.9 trình bày kết quả so sánh các kiến trúc hồi quy khác nhau trên mô hình đề xuất. Những kết quả này cho thấy việc khai thác ngữ cảnh thời gian hai chiều giúp mô hình nắm bắt hiệu quả cả các phụ thuộc lịch sử và xu hướng “hướng tới tương lai” trong động lực học của hệ thống hồ chứa, qua đó khẳng định tính hợp lý của việc lựa chọn BiLSTM trong kiến trúc Colubrid-Net.


Bảng 3.10 làm rõ vai trò quan trọng của hàm kích hoạt động *snake* trong kiến trúc đề xuất. Cấu hình snake/snake đạt hiệu suất tối ưu hơn các cấu hình còn lại.

Bảng 3.10. So sánh các hàm kích hoạt trong bộ mã hóa và bộ giải mã

Hàm kích hoạt (bộ mã hóa/bộ giải mã)	MAE	MSE	RMSE
ReLU/ ReLU	0.2481	0.0714	0.2673
ReLU/ Snake	0.2848	0.0883	0.2971
Snake/ ReLU	0.3015	0.1046	0.3234
Snake/ Snake	0.0242	0.0022	0.0464

3.6. Hệ thống dự báo mực nước đa mô thức


3.6.1. Kiến trúc của hệ thống



Hình 3.5. Kiến trúc tổng thể hệ thống dự báo mực nước hồ

Hệ thống được thiết kế theo kiến trúc client-server (Hình 3.5): Hệ thống gồm hai tác nhân chính là người dùng và người ra quyết định, truy cập thông qua giao diện web/ứng dụng để khai thác kết quả dự báo và hỗ trợ vận hành hồ chứa. Tầng ứng dụng và dịch vụ bao gồm dashboard, dịch vụ ứng dụng và quản trị hệ thống, đảm nhiệm trực quan hóa dữ liệu, cung cấp API và giám sát vận hành. Tầng mô hình AI triển khai mô hình dự báo mực nước đa mô thức VGG19-SARIMAX. Tầng dữ liệu thực hiện thu thập, làm sạch, đồng bộ và lưu trữ dữ liệu từ ảnh Sentinel-2, dữ liệu thủy văn, khí tượng và vận hành hồ chứa. Tầng hạ tầng gồm các máy chủ web, ứng dụng, xử lý dữ liệu, GPU, cơ sở dữ liệu và lưu trữ, bảo đảm luồng dữ liệu và khả năng triển khai thực tế của hệ thống.

3.6.2. Mô hình AI (VGG19-SARIMAX) trong hệ thống



Hình 3.6. Mô hình dự báo mực nước hồ VGG19-SARIMAX

Toàn bộ quy trình xử lý và hợp nhất dữ liệu trong mô-đun này được phát triển dựa trên phương pháp luận đã được trình bày trong mô hình dự báo đa mô thức VGG19-SARIMAX ở trong công trình [CT4].

Kết quả đầu ra của hệ thống là chuỗi giá trị dự báo mực nước hồ theo từng bước thời gian định trước, cung cấp nguồn thông tin đáng tin cậy và kịp thời phục vụ quản lý, điều hành hồ, cũng như hỗ trợ ra quyết định trong quy hoạch và quản lý tổng hợp tài nguyên nước.

3.7. Kết luận chương

Trong chương này, luận án đã thực hiện các thực nghiệm nhằm kiểm chứng tính đúng đắn và đánh giá hiệu năng của các mô hình dự báo mực nước hồ được đề xuất. Kết quả thực nghiệm cho thấy các mô hình đạt độ chính xác tốt và có khả năng ứng dụng trong bài toán dự báo thực tế. Đồng thời, hệ thống dự báo mực nước hồ được xây dựng như một ứng dụng thử nghiệm, minh chứng tính khả thi trong việc triển khai các mô hình đề xuất thành sản phẩm thực tiễn. Kiến trúc hệ thống được thiết kế linh hoạt, cho phép thay thế mô hình VGG19-SARIMAX bằng các mô hình HOG-GRU hoặc Colubrid-Net khi cần. Các kết quả của chương đã được công bố trong các công trình [CT4, CT5] thuộc “**DANH MỤC CÔNG TRÌNH CÔNG BỐ**”.

KẾT LUẬN VÀ HƯỚNG PHÁT TRIỂN

1) Những kết quả chính của luận án

Trong bối cảnh biến đổi khí hậu ngày càng phức tạp, dự báo mực nước hồ đóng vai trò quan trọng trong quản lý tài nguyên nước, vận hành hồ chứa và giảm thiểu rủi ro thiên tai. Tuy nhiên, các phương pháp hiện nay vẫn còn hạn chế về độ chính xác, khả năng khái quát hóa và yêu cầu dữ liệu đầu vào lớn. Luận án tập trung phát triển mô hình dự báo mực nước hồ đa mô thức, kết hợp dữ liệu vận hành hồ và ảnh vệ tinh Sentinel-2 nhằm nâng cao độ chính xác dự báo và hỗ trợ hiệu quả công tác quản lý hồ chứa. Các đóng góp mới về mặt học thuật của luận án bao gồm:

1. Luận án đề xuất mô hình HOG-GRU là mô hình dự báo mực nước hồ đa mô thức, kết hợp dữ liệu quan trắc thủy văn và ảnh vệ tinh từ Sentinel-2. Đặc trưng ảnh được trích xuất bằng thuật toán HOG. Đặc trưng ảnh này làm thông tin bổ trợ cho dữ liệu mực nước hồ, thông qua hàm hợp nhất có tính chất làm nổi bật các điểm dữ liệu mực nước bất thường xuất hiện khi có mưa lũ hoặc hạn hán. Cuối cùng, mạng GRU khai thác đồng thời các đặc trưng trên để dự báo mực nước hồ ở bước thời gian tiếp theo.
2. Luận án đề xuất mô hình Colubrid-Net, một kiến trúc học sâu đa mô thức nhằm nâng cao độ chính xác dự báo mực nước hồ qua việc khai thác hiệu quả các phụ thuộc không - thời gian. Mô hình này sử dụng kiến trúc trích xuất đặc trưng ảnh đa tỉ lệ từ ảnh vệ tinh, đồng thời tích hợp chặt chẽ với dữ liệu chuỗi thời gian thủy văn. Để khắc phục vấn đề không đồng bộ theo thời gian giữa dữ liệu ảnh vệ tinh có tần suất theo tháng và dữ liệu mực nước đo đạc theo ngày, luận án đề xuất một cơ chế nội suy theo thời gian có xét đến yếu tố mùa vụ, giúp đồng bộ hóa dữ liệu đầu vào và nâng cao tính nhất quán của quá trình học mô hình.
3. Xây dựng Hệ thống dự báo mực nước hồ đa mô thức trên nền tảng web, tích hợp dữ liệu quan trắc thủy văn và dữ liệu viễn thám từ Sentinel-2, nhằm hỗ trợ hiệu quả công tác quản lý tài nguyên nước, vận hành hồ chứa và ra quyết định trong quản lý các công trình thủy lợi – thủy điện.

2) Hạn chế và hướng phát triển của luận án

Bên cạnh các kết quả đạt được, luận án vẫn tồn tại một số hạn chế. Bộ dữ liệu nghiên cứu mới được xây dựng trên hai hồ chứa thuộc cùng một hệ thống thủy điện tại Gia Lai giai đoạn 2019–2022, trong khi số lượng ảnh Sentinel-2 khả dụng còn hạn chế do ảnh hưởng của mây che phủ. Điều này có thể ảnh hưởng đến khả năng học biểu diễn không gian – thời gian và làm giảm tính khái quát của mô hình khi áp dụng cho các hồ có điều kiện vận hành và đặc điểm thủy văn khác nhau.

Trong thời gian tới, nghiên cứu sẽ mở rộng dữ liệu theo nhiều vùng khí hậu khác nhau, tích hợp thêm các biến khí tượng – thủy văn như lượng mưa, lưu lượng đến hồ, lưu lượng xả và bốc hơi nhằm nâng cao độ chính xác dự báo. Đồng thời, luận án định hướng phát triển các mô hình tối ưu siêu tham số, học trực tuyến, học đa nhiệm và cơ chế hợp nhất dữ liệu thích nghi để tăng khả năng vận hành ổn định trong điều kiện thực tế. Đây là hướng nghiên cứu tiềm năng nhằm xây dựng hệ thống dự báo mực nước hồ thông minh, có khả năng ứng dụng rộng rãi trong quản lý và điều hành tài nguyên nước.

DANH MỤC CÔNG TRÌNH CÔNG BỐ

[CT1]	Hoang Thi Minh Chau , Tran Thi Ngan, Nguyen Long Giang, Nguyen Nhu Son (2026). HOG-GRU: a novel multi-modal water level forecasting model integrating satellite imagery and reservoir operation data. <i>Data Technologies and Applications</i> , 60(2), 297-329. DOI: 10.1108/DTA-07-2025-0545 (SCIE, Q2).
[CT2]	Nguyen Duc Quang Anh, Nguyen Minh Anh, Tran Thi Ngan, Hoang Thi Minh Chau (2025). Colubrid-Net: A unified cross-modal framework for hydrological forecasting in An Khe Reservoir, Vietnam. in <i>IEEE Geoscience and Remote Sensing Letters</i> , vol. 23, pp. 1-5, 2026, Art no. 1500905. DOI: 10.1109/LGRS.2025.3645672 (SCIE, Q1).
[CT3]	Hoang Thi Minh Chau , Tran Thi Ngan, Nguyen Long Giang, Tran Manh Tuan, Tran Kim Chau. (2025). A Hybrid Deep Learning Method for Forecasting Reservoir Water Level from Sentinel-2 Satellite Images. <i>Computers, Materials & Continua</i> , 83(3), 4915. DOI: 10.32604/cmc.2025.062784 (SCIE, Q3).
[CT4]	Hoang Thi Minh Chau , Tran Thi Ngan, Nguyen Long Giang, Tran Kim Chau, Hoang Duc Trung, Ton Nu Mai Khanh. (2024, December). An Integration of VGG19 and SARIMAX in Water Level Forecasting Using Satellite Imagery and Time Series Data. In <i>International Conference on Smart Objects and Technologies for Social Good</i> (pp. 16-28). Springer Nature Switzerland. Scopus Q4 .
[CT5]	Hoang Thi Minh Chau , Tran Thanh Lam, Hoang Duc Trung, Tran Thi Ngan, Nguyen Long Giang, Nguyen Nhu Son, Phung The Huan. (2025). A new multi-modal forecasting system for water level estimation. In <i>International Conference on Advances in Information and Communication Technology</i> . Springer Nature Switzerland. Scopus Q4 .