

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**

LUẬN ÁN TIẾN SĨ MÁY TÍNH

Hà Nội – 2026

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**

LUẬN ÁN TIẾN SĨ MÁY TÍNH

Ngành: Hệ thống thông tin

Mã số: 9 48 01 04

**Xác nhận của Học viện
Khoa học và Công nghệ**

PHÓ GIÁM ĐỐC



Nguyễn Thị Trung

**Người hướng dẫn 1
(Ký, ghi rõ họ tên)**

PGS.TS. Trần Thị Ngân

**Người hướng dẫn 2
(Ký, ghi rõ họ tên)**

PGS.TS. Nguyễn Long Giang

Hà Nội – 2026

LỜI CAM ĐOAN

Tôi hiện là nghiên cứu sinh chuyên ngành Hệ thống thông tin tại Học viện Khoa học và Công nghệ - Viện Hàn lâm Khoa học và Công nghệ Việt Nam. Tôi xin khẳng định rằng luận án này được hình thành từ quá trình nghiên cứu khoa học do cá nhân tôi trực tiếp triển khai một cách độc lập, dưới sự tư vấn, định hướng và giám sát chuyên môn của PGS.TS. Trần Thị Ngân và PGS.TS. Nguyễn Long Giang.

Toàn bộ các kết quả, phân tích và luận giải khoa học được trình bày trong luận án phản ánh trung thực quá trình nghiên cứu đã thực hiện, bảo đảm yêu cầu về độ tin cậy, tính khách quan và sự minh bạch trong học thuật. Các kết quả này chưa từng được công bố, sử dụng hay lặp lại trong bất kỳ công trình khoa học nào khác trước thời điểm nộp luận án. Dữ liệu, bảng biểu và hình ảnh minh họa sử dụng trong luận án đều có nguồn gốc rõ ràng, được tôi trực tiếp thu thập, xử lý và phân tích, hoặc được trích xuất từ các kết quả hợp pháp của đề tài nghiên cứu liên quan.

Tôi xin hoàn toàn chịu trách nhiệm trước Hội đồng đánh giá luận án và Học viện Khoa học và Công nghệ - Viện Hàn lâm Khoa học và Công nghệ Việt Nam về tính trung thực, tính độc lập cũng như toàn bộ nội dung khoa học được trình bày trong luận án này.

Hà Nội, ngày 8 tháng 5 năm 2026

Tác giả luận án



Hoàng Thị Minh Châu

LỜI CẢM ƠN

Trong chặng đường học tập và nghiên cứu để đạt được thành quả ngày hôm nay, Nghiên cứu sinh (NCS) đã trải qua một hành trình nhiều nỗ lực, thử thách nhưng cũng đầy may mắn, bởi NCS luôn nhận được sự động viên, quan tâm và dìu dắt tận tình của quý Thầy/Cô, gia đình, đồng nghiệp và bạn bè.

Trước hết, NCS xin bày tỏ lòng tri ân sâu sắc nhất tới hai thầy cô hướng dẫn khoa học là PGS.TS. Trần Thị Ngân và PGS.TS. Nguyễn Long Giang. Hai thầy cô đã tận tình chỉ bảo, định hướng cho NCS từ những bước đầu tiên trong nghiên cứu, học tập trong từng nội dung, truyền cho NCS niềm say mê khoa học và luôn động viên NCS vượt qua những giai đoạn khó khăn trong quá trình học tập và nghiên cứu. Những kiến thức, sự tận tâm và tình cảm mà thầy cô dành cho NCS sẽ luôn là nguồn động viên quý báu, để NCS có được những thành công như ngày hôm nay và làm tiền đề vững chắc trong công việc trên chặng đường phía trước.

NCS xin chân thành cảm ơn quý Thầy/Cô trong các Hội đồng, các thầy cô phản biện độc lập đã dành thời gian quý báu đọc, góp ý, đánh giá và đưa ra những nhận xét sâu sắc, khách quan, giúp NCS hoàn thiện luận án một cách chặt chẽ và khoa học hơn.

NCS xin trân trọng cảm ơn Ban Lãnh đạo, quý Thầy/Cô và cán bộ các phòng, ban của Học viện Khoa học và Công nghệ, Viện Công nghệ thông tin thuộc Viện Hàn lâm Khoa học và Công nghệ Việt Nam đã luôn tạo điều kiện thuận lợi cho NCS trong suốt quá trình học tập và nghiên cứu tại đây.

NCS cũng xin gửi lời cảm ơn chân thành tới Ban giám hiệu, phòng ban chức năng, các đồng nghiệp Trường Đại học Kinh tế - Kỹ thuật Công nghiệp nơi NCS đang công tác đã luôn động viên, tạo điều kiện thuận lợi nhất về thời gian và công việc để NCS có thể tập trung toàn thời gian hoàn thành nhiệm vụ học tập, nghiên cứu luận án tiến sĩ này.

NCS xin trân trọng gửi lời cảm ơn đến quý thầy cô trong Lab AI4.0, đặc biệt là Thầy Trưởng Lab, cùng các em nghiên cứu viên tại Trung tâm AIRC – Viện Công nghệ thông tin, Đại học Quốc gia Hà Nội đã luôn hỗ trợ và tạo điều kiện thuận lợi cho NCS trong suốt quá trình nghiên cứu. Những chia sẻ về chuyên môn, kinh nghiệm học thuật quý báu cùng sự giúp đỡ tận tình của quý

Thầy/Cô và các anh chị em đã góp phần quan trọng trong việc hoàn thiện các kết quả của luận án này.

Để hoàn thiện luận án này NCS xin trân trọng cảm ơn PGS.TS. Trần Kim Châu và TS. Trần Mạnh Tuấn (Trường Đại học Thủy Lợi) đã tận tình hỗ trợ chuyên môn trong lĩnh vực thủy văn. Các thầy đã hỗ trợ và chia sẻ nhiều kiến thức chuyên môn quý báu trong lĩnh vực này để NCS hiểu sâu sắc hơn và hoàn thiện được các kết quả nghiên cứu luận án của mình.

Đặc biệt, NCS xin dành lời biết ơn sâu sắc nhất tới gia đình thân yêu của mình. NCS xin cảm ơn bố mẹ hai bên nội ngoại đã luôn động viên, khích lệ, chia sẻ những khó khăn và dõi theo từng bước đi trên con đường của mình. NCS xin cảm ơn chồng, các con – những người luôn ở bên cạnh, động viên, cảm thông, sẻ chia và là điểm tựa vững chắc để NCS có thêm nghị lực vượt qua mọi áp lực, khó khăn trong suốt thời gian qua.

Cuối cùng, NCS xin cảm ơn anh chị em, bạn bè thân thiết đã luôn động viên, khích lệ NCS trong quá trình học tập, nghiên cứu.

Tác giả luận án



Hoàng Thị Minh Châu

MỤC LỤC

LỜI CAM ĐOAN	i
LỜI CẢM ƠN.....	ii
MỤC LỤC.....	iv
DANH MỤC CÁC THUẬT NGỮ, CÁC CHỮ VIẾT TẮT	vii
DANH MỤC HÌNH VẼ.....	ix
DANH MỤC BẢNG BIỂU	x
MỞ ĐẦU	1
1. Tính cấp thiết.....	1
2. Tổng quan các nghiên cứu về bài toán dự báo mực nước hồ	2
3. Khoảng trống nghiên cứu.....	12
4. Mục tiêu nghiên cứu của luận án.....	13
5. Đối tượng nghiên cứu của luận án.....	13
6. Phạm vi nghiên cứu	14
7. Phương pháp nghiên cứu.....	14
8. Những đóng góp chính trong luận án.....	14
9. Cấu trúc luận án.....	15
Chương 1. CƠ SỞ LÝ THUYẾT.....	17
1.1. Bài toán dự báo mực nước hồ.....	17
1.2. Đặc điểm của bài toán dự báo mực nước hồ	17
1.3. Ảnh vệ tinh Sentinel-2.....	19
1.4. Các mô hình dự báo mực nước hồ truyền thống.....	21
1.4.1. Một số mô hình thủy văn thủy lực.....	21
1.4.2. Các mô hình hồi quy	23
1.5. Một số mô hình học sâu	29
1.6. Các kỹ thuật và mô hình xử lý ảnh cho bài toán dự báo mực nước hồ	33
1.7. Chỉ số đánh giá mô hình dự báo và phân tích ANOVA hai chiều	36
1.8. Kết luận chương	38
Chương 2. ĐỀ XUẤT MÔ HÌNH DỰ BÁO MỰC NƯỚC HỒ ĐA MÔ THỨC.....	39
2.1. Mở đầu	39
2.2. Đề xuất mô hình dự báo mực nước hồ đa mô thức HOG-GRU	41

2.2.1. Mô hình dự báo.....	42
2.2.2. Xử lý dữ liệu	43
2.2.3. Trích xuất đặc trưng ảnh và xử lý nhiễu.....	45
2.2.4. Hợp nhất dữ liệu mực nước và đặc trưng ảnh	47
2.2.5. Triển khai và huấn luyện mạng GRU	49
2.3. Đề xuất mô hình dự báo mực nước hồ đa mô thức Colubrid-Net	50
2.3.1. Ý tưởng của mô hình đề xuất	50
2.3.2. Kiến trúc UMSFE	53
2.3.3. Kiến trúc MTFE.....	56
2.3.4. Căn chỉnh theo thời gian và nội suy đặc trưng ảnh	56
2.3.5. BiLSTM trong hợp nhất theo thời gian	58
2.4. Thảo luận về mô hình đề xuất HOG-GRU và Colubrid-Net.....	58
2.5. Kết luận chương	60
Chương 3. KẾT QUẢ THỰC NGHIỆM VÀ XÂY DỰNG HỆ THỐNG DỰ BÁO MỰC	
NƯỚC HỒ	63
3.1. Khu vực nghiên cứu.....	63
3.2. Quy trình thu thập và gán nhãn ảnh vệ tinh Sentinel-2	65
3.3. Mô tả dữ liệu thực nghiệm	69
3.3.1. Dữ liệu ảnh vệ tinh khu vực hồ chứa An Khê và Ka Nak	69
3.3.2. Dữ liệu chuỗi thời gian vận hành hồ chứa.....	70
3.4. Đánh giá hiệu năng mô hình HOG-GRU	70
3.5. Đánh giá hiệu năng mô hình Colubrid-Net	83
3.5.1. Thiết lập thí nghiệm.....	83
3.5.2. Chỉ số đánh giá	83
3.5.3. Môi trường thực nghiệm.....	84
3.5.4. Kết quả thực nghiệm:.....	84
3.5.5. Đánh giá ảnh hưởng của các hàm kích hoạt	87
3.6. Xây dựng hệ thống dự báo mực nước hồ đa mô thức	87
3.6.1. Kiến trúc hệ thống dự báo mực nước hồ	87
3.6.2. Quy trình hoạt động của hệ thống	90
3.6.3. Quản lý dữ liệu của hệ thống.....	92
3.6.4. Mô hình AI (VGG19-SARIMAX) trong hệ thống.....	93

3.6.5. Minh họa kết quả dự báo của hệ thống.....	94
3.7. Kết luận chương	96
KẾT LUẬN.....	101
DANH MỤC CÔNG TRÌNH CÔNG BỐ.....	105
TÀI LIỆU THAM KHẢO	106

DANH MỤC CÁC THUẬT NGỮ, CÁC CHỮ VIẾT TẮT

Tiếng Anh	Viết tắt	Diễn giải
Adaptive Neuro-based Fuzzy Inference System	ANFIS	Mạng nơ-ron mờ thích nghi
Artificial Intelligence	AI	Trí tuệ nhân tạo
Akaike Information Criterion	AIC	Tiêu chí thông tin Akaike
Analysis of Variance	ANOVA	Phân tích phương sai
Artificial Neural Network	ANN	Mạng nơ-ron nhân tạo
Bidirectional Long Short-Term Memory	BiLSTM	Mô hình dự báo với bộ nhớ dài-ngắn hạn hai chiều
Convolutional Long Short-Term Memory	ConvLSTM	Mạng bộ nhớ dài ngắn tích chập
Convolutional Neural Network	CNN	Mạng nơ-ron tích chập
Deep Learning	DL	Học sâu
Extreme Learning Machine	ELM	Học máy cực trị
Gated Recurrent Unit	GRU	Đơn vị mạng nơ-ron hồi quy có cổng
Histogram of Oriented Gradients	HOG	Đặc trưng ảnh dựa trên Histogram
Hyper Text Transfer Protocol	HTTP	Giao thức truyền tải siêu dữ liệu
Kling-Gupta Efficiency	KGE	Chỉ số đánh giá mô hình dự báo, phản ánh toàn diện hiệu năng qua khả năng tái hiện xu thế biến động, độ chệch trung bình và độ biến thiên của chuỗi mực nước quan trắc
Intersection over Union	IoU	Vùng chồng lấn trong ảnh
Long Short-Term Memory	LSTM	Mô hình dự báo với bộ nhớ dài-ngắn hạn

Tiếng Anh	Viết tắt	Diễn giải
Machine Learning	ML	Học máy
Mean Absolute Error	MAE	Lỗi trung bình tuyệt đối
Mean Squared Error	MSE	Lỗi bình phương trung bình
Minimum Mean Square Error	MMSE	Lỗi bình phương trung bình nhỏ nhất
Multi-Layer Perceptron	MLP	Mạng nơ-ron nhiều lớp
Nash-Sutcliffe Efficiency	NSE	Chỉ số đánh giá mức độ phù hợp giữa giá trị dự báo của mô hình và số liệu quan trắc
Recurrent Neural Network	RNN	Mạng nơ-ron hồi quy
Root Mean Square Error	RMSE	Căn bậc hai của lỗi trung bình bình phương
Coefficient of Determination	R^2	Hệ số xác định
Seasonal AutoRegressive Integrated Moving Average with eXogenous regressors	SARIMAX	Mô hình tự hồi quy hợp nhất trung bình trượt theo mùa với các biến ngoại sinh
Segmentation Network	SegNet	Kỹ thuật kết hợp các khối tích chập với khối downsampling trong mô hình phân đoạn theo ngữ nghĩa
U-shaped Network	Unet	Mô hình phân đoạn đối xứng
Visual Geometry Group 19-layer network	VGG19	Backbone học sâu với 19 lớp
You Only Look Once	YOLO	Mô hình nhận dạng đối tượng theo họ CNN

DANH MỤC HÌNH VẼ

<i>Hình 0.1. Các phương pháp dự báo mực nước hồ.....</i>	<i>2</i>
<i>Hình 0.2. Phân loại các phương pháp hợp nhất đa mô thức.....</i>	<i>5</i>
<i>Hình 1.1. Lưu đồ mạng RNN.....</i>	<i>30</i>
<i>Hình 1.2. Lưu đồ mạng LSTM.....</i>	<i>31</i>
<i>Hình 1.3. Lưu đồ mạng BiLSTM.....</i>	<i>32</i>
<i>Hình 1.4. Lưu đồ mạng GRU.....</i>	<i>33</i>
<i>Hình 1.5. Sơ đồ mạng VGG19.....</i>	<i>34</i>
<i>Hình 1.6. Kiến trúc mô hình C3STR.....</i>	<i>35</i>
<i>Hình 2.1. Khung dự báo đề xuất HOG-GRU.....</i>	<i>42</i>
<i>Hình 2.2. Ví dụ minh họa ảnh mặt nạ hồ An Khê.....</i>	<i>44</i>
<i>Hình 2.3. Sơ đồ thuật toán HOG.....</i>	<i>46</i>
<i>Hình 2.4. Kiến trúc Colubrid-Net.....</i>	<i>52</i>
<i>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.</i>	<i>53</i>
<i>Hình 3.1. Vị trí địa lý hồ An Khê và Ka Nak.....</i>	<i>63</i>
<i>Hình 3.2. Quy trình thu thập và gán nhãn dữ liệu.....</i>	<i>65</i>
<i>Hình 3.3. Minh họa cửa sổ tải ảnh khu vực cần lấy ảnh Sentinel-2.....</i>	<i>66</i>
<i>Hình 3.4. Ví dụ về hình ảnh vệ tinh khu vực hồ An Khê.....</i>	<i>68</i>
<i>Hình 3.5. Ảnh vệ tinh khu vực hồ sau gán nhãn.....</i>	<i>68</i>
<i>Hình 3.6. Ví dụ dữ liệu chuỗi thời gian hồ chứa An Khê ngày 02/04/2022.....</i>	<i>70</i>
<i>Hình 3.7. Biểu đồ thể hiện kết quả dự báo của các mô hình RNN, HOG-RNN, LSTM, HOG-LSTM, GRU và HOG-GRU.....</i>	<i>73</i>
<i>Hình 3.8. Kiến trúc tổng thể hệ thống dự báo mực nước hồ.....</i>	<i>88</i>
<i>Hình 3.9. Sơ đồ quy trình hoạt động của hệ thống dự báo mực nước hồ.....</i>	<i>90</i>
<i>Hình 3.10. Mô hình dự báo mực nước hồ VGG19-SARIMAX.....</i>	<i>93</i>
<i>Hình 3.11. Minh họa lựa chọn dữ liệu đầu vào cho hệ thống dự báo.....</i>	<i>94</i>
<i>Hình 3.12. Minh họa lựa chọn khoảng thời gian muốn dự báo.....</i>	<i>95</i>
<i>Hình 3.13. Minh họa kết quả dự báo mực nước hồ.....</i>	<i>95</i>

DANH MỤC BẢNG BIỂU

<i>Bảng 1.1. Thông số các dải quang phổ của ảnh vệ tinh Sentinel-2.....</i>	<i>20</i>
<i>Bảng 2.1. Tóm tắt các giá trị tính toán trong Ví dụ 1.....</i>	<i>49</i>
<i>Bảng 2.2. So sánh mô hình dự báo đề xuất HOG-GRU và Colubrid-Net</i>	<i>59</i>
<i>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.</i>	<i>71</i>
<i>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.</i>	<i>71</i>
<i>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.</i>	<i>74</i>
<i>Bảng 3.4. Đánh giá hiệu năng của các mô hình HOG-RNN, HOG-LSTM và HOG-GRU bằng phương pháp kiểm định chéo 5-fold.</i>	<i>76</i>
<i>Bảng 3.5. Kết quả đánh giá phân tích phương sai hai chiều giữa các mô hình và các chỉ số đánh giá.</i>	<i>76</i>
<i>Bảng 3.6. So sánh chỉ số đánh giá mô hình VGG19-SARIMAX và HOG-GRU.</i>	<i>77</i>
<i>Bảng 3.7. Kết quả đánh giá hiệu năng của mô hình HOG-GRU trên các kịch bản trọng số khác nhau của hàm hợp nhất.</i>	<i>78</i>
<i>Bảng 3.8. Kết quả đánh giá hiệu năng của mô hình HOG-GRU với giá trị α khác nhau trong hàm hợp nhất.</i>	<i>80</i>
<i>Bảng 3.9. Đánh giá hiệu năng của mô hình HOG-GRU khi loại bỏ từng thành phần riêng lẻ khỏi hàm hợp nhất $P(y_t, f_t)$.</i>	<i>82</i>
<i>Bảng 3.10. So sánh hiệu năng các mô hình dự báo</i>	<i>84</i>
<i>Bảng 3.11. So sánh hiệu năng các kiến trúc hồi quy</i>	<i>86</i>
<i>Bảng 3.12. Đánh giá các hàm kích hoạt trong bộ mã hóa và bộ giải mã</i>	<i>87</i>

MỞ ĐẦU

1. Tính cấp thiết

Hồ chứa giữ vị trí then chốt trong hệ thống tài nguyên nước, thực hiện đồng thời nhiều chức năng quan trọng như điều tiết dòng chảy, giảm thiểu rủi ro do lũ lụt, cung cấp nước cho sinh hoạt và sản xuất nông nghiệp, cũng như phục vụ phát điện. Thông qua các chức năng này, hồ chứa góp phần đáng kể vào quá trình phát triển kinh tế - xã hội và duy trì sự ổn định của các hệ sinh thái nước của các quốc gia [1].

Tuy nhiên, dưới tác động ngày càng rõ rệt của biến đổi khí hậu toàn cầu, các quá trình thủy văn đang trở nên phức tạp và khó dự đoán hơn. Sự thay đổi này được thể hiện qua tính bất ổn của chế độ mưa, gia tăng bốc hơi bề mặt, cùng với áp lực ngày càng lớn từ hoạt động khai thác và sử dụng tài nguyên nước của con người [2, 3]. Hệ quả là tần suất và cường độ của các hiện tượng khí tượng - thủy văn cực đoan, bao gồm mưa lớn, hạn hán kéo dài và ngập lụt, có xu hướng gia tăng [4-7], khiến diễn biến mực nước hồ ngày càng mang tính phi tuyến và khó dự báo [8]. Trong hệ thống thủy văn, mực nước hồ được xem là một biến số có độ nhạy cao, phản ánh trạng thái cân bằng tổng thể của nguồn nước, đồng thời hợp nhất tác động tổng hợp của các yếu tố khí hậu và đặc điểm không gian - cảnh quan của lưu vực [9-12].

Mực nước tại nhiều hồ chứa và hồ tự nhiên trên phạm vi toàn cầu có xu hướng suy giảm trong nhiều năm gần đây, phản ánh tác động tổng hợp của biến đổi khí hậu và nhu cầu sử dụng nước ngày càng gia tăng [13, 14]. Hệ quả là sự mất cân đối nguồn nước, suy giảm chất lượng nước [15, 16], đồng thời làm gia tăng rủi ro mất an toàn công trình và đe dọa các khu vực hạ du. Bên cạnh chức năng tích trữ nước, hồ chứa còn đóng vai trò như một bộ đệm tự nhiên giúp làm giảm đỉnh lũ [17], đặc biệt quan trọng trong bối cảnh tần suất và cường độ các trận lũ cực đoan gia tăng mạnh [4]. Nghiên cứu chỉ ra trong giai đoạn 2010 - 2020, các đợt ngập lụt đã ảnh hưởng tới hơn 3,6 tỷ người trên toàn thế giới [5], gây thiệt hại nghiêm trọng trên nhiều quốc gia: Bangladesh, Ấn Độ, Mozambique, Đức, Trung Quốc, Malaysia và Hoa Kỳ [6]; đồng thời, mức độ thiệt hại này được dự báo có thể tăng gấp hai lần vào năm 2050 [7].

Trong quá trình vận hành hồ chứa, các phương án phân phối và điều tiết dòng chảy phụ thuộc lớn vào mức độ tin cậy của thông tin dự báo mực nước hồ

[18-21]. Việc chậm trễ trong xả lũ có thể làm gia tăng nguy cơ ngập lụt trên diện rộng, trong khi xả nước sớm khi dự báo lượng mưa chưa đủ chính xác lại dễ dẫn đến tình trạng thiếu hụt nguồn nước phục vụ sinh hoạt và sản xuất [22]. Vì vậy, độ chính xác của dự báo mực nước hồ được xem là yếu tố then chốt, làm cơ sở cho công tác lập kế hoạch điều tiết nguồn nước, đáp ứng nhu cầu tưới tiêu và cấp nước đô thị [23], đồng thời góp phần nâng cao hiệu quả phát điện và bảo đảm an toàn công trình hồ đập.

Trong bối cảnh biến đổi khí hậu ngày càng thể hiện rõ rệt cùng với áp lực gia tăng từ nhu cầu khai thác và sử dụng nước, nhiều nghiên cứu gần đây đã nhấn mạnh tầm quan trọng của **việc phát triển các mô hình dự báo mực nước hồ có độ chính xác cao, khả năng thích ứng tốt và phù hợp với sự biến động của các đặc trưng thủy văn** [24-28]. Các mô hình này không chỉ hỗ trợ công tác vận hành hồ theo hướng chủ động và linh hoạt hơn, mà còn đóng vai trò quan trọng trong việc xây dựng và lựa chọn các phương án ứng phó, điều chỉnh kịp thời nhằm hạn chế thiệt hại do các hiện tượng thiên tai gây ra.

Nhiều nghiên cứu đã cho thấy rằng khả năng dự báo chính xác mực nước hồ có ý nghĩa đặc biệt quan trọng đối với công tác điều phối và sử dụng tài nguyên nước trong dài hạn. Hoạt động này góp phần nâng cao mức độ chủ động trong bảo đảm nguồn nước, hạn chế các tác động bất lợi đến hệ sinh thái, đồng thời hỗ trợ quá trình ra quyết định trong quản lý và khai thác tài nguyên nước một cách hiệu quả.

2. Tổng quan các nghiên cứu về bài toán dự báo mực nước hồ



Hình 0.1. Các phương pháp 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. Các nhóm này được mô tả ở *Hình 0.1*.

- **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, dữ liệu vận hành hồ.

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 0.2*.

- **Hợp nhất sớm**

Chiến lược hợp nhất sớm, hay còn gọi là hợp nhất ở cấp độ dữ liệu, thực hiện việc kết hợp các nguồn thông tin ngay tại tầng đầu vào của mô hình. Trong quy trình này, dữ liệu từ các nguồn khác nhau (ảnh vệ tinh và số liệu quan trắc) được tiền xử lý, đồng bộ hóa về không gian - thời gian và ghép nối thành một véc-tơ hoặc tensor thống nhất trước khi đưa vào mạng nơ-ron để trích xuất đặc trưng chung.



Hình 0.2. Phân loại các phương pháp hợp nhất đa mô thức

Gao và cộng sự [47] đã phát triển một mô hình học sâu nhằm ước lượng các chỉ số thủy văn quan trọng của sông ngòi (mức nước, độ rộng lòng sông, diện tích mặt nước) trực tiếp từ ảnh vệ tinh đa thời gian. Dữ liệu bao gồm ảnh radar Sentinel-1 và ảnh quang học Sentinel-2 (chu kỳ 5-10 ngày) tại trung lưu sông Dương Tử, kết hợp với dữ liệu mức nước thực đo. Mô hình CNN-LSTM được thiết kế theo cơ chế hợp nhất sớm, trong đó các đặc trưng không gian từ ảnh radar và quang học được hợp nhất ngay tại tầng đầu để học chuỗi biến đổi theo thời gian. Phương pháp này cho phép mô hình đồng thời nắm bắt đặc trưng hình thái và chu kỳ dao động thủy văn, song hạn chế là yêu cầu lượng dữ liệu lớn, đồng bộ cao và khó áp dụng trong điều kiện mây che phủ hoặc mưa dày đặc. Tsai và Tseng [48] thực hiện một nghiên cứu tổng hợp nhằm đánh giá hiệu quả của ba chiến lược hợp nhất (hợp nhất sớm, hợp nhất trung gian, hợp nhất muộn) trong dự báo tầm nhìn khí quyển. Dữ liệu bao gồm ảnh MODIS (kênh quang học, hồng ngoại) và chuỗi dữ liệu khí tượng - môi trường ($PM_{2.5}$, độ ẩm, gió, nhiệt độ). Trong cấu trúc hợp nhất sớm, dữ liệu ảnh và chuỗi thời gian được nối trực tiếp trước khi đưa vào mô hình CNN-LSTM. Kết quả cho thấy cách tiếp cận này giúp mô hình học được các mối tương quan mức thấp, nhưng hiệu quả dự báo thấp hơn so với hợp nhất trung gian do hạn chế về độ đồng bộ và nhiễu ảnh.

Ưu điểm lớn nhất của Hợp nhất sớm là khả năng tận dụng tối đa thông tin gốc để tìm ra các tương quan tiềm ẩn ngay từ bước đầu tiên. Tuy nhiên, thách thức lớn nhất đặt ra cho phương pháp này là yêu cầu về độ đồng bộ cực cao của dữ liệu; sự thiếu hụt hoặc nhiễu ở một nguồn (ví dụ: ảnh bị mây che phủ) có thể lan truyền sai số và ảnh hưởng tiêu cực đến toàn bộ quá trình huấn luyện do mô hình coi tất cả các đầu vào là một khối thống nhất không thể tách rời.

- Hợp nhất trung gian

Hợp nhất trung gian, hay hợp nhất ở tầng đặc trưng, hiện là chiến lược phổ biến và được đánh giá cao nhất trong các bài toán thủy văn phức tạp nhờ khả năng cân bằng giữa bảo toàn ngữ nghĩa dữ liệu và học tương tác sâu. Kiến trúc này sử dụng các nhánh mạng con riêng biệt để trích xuất đặc trưng trừu tượng từ từng nguồn dữ liệu trước khi hợp nhất. Tùy thuộc vào cơ chế tương tác và vai trò của các nhánh dữ liệu trong quá trình tổng hợp, nhóm phương pháp này được phân chia thành hai hướng tiếp cận chính: Hợp nhất đối xứng và Hợp nhất bất đối xứng.

- Hợp nhất đối xứng

Trong kiến trúc hợp nhất đối xứng, các nguồn dữ liệu khác nhau (ảnh vệ tinh và số liệu quan trắc) được xem là có vai trò ngang hàng và được xử lý thông qua các nhánh mạng song song. Các véc-tơ đặc trưng sau khi được trích xuất độc lập sẽ được hợp nhất trực tiếp tại một tầng trung gian thông qua các phép toán như nối, cộng hoặc nhân mà không có sự phân biệt chính - phụ.

Các nghiên cứu điển hình cho xu hướng này thường tập trung vào việc tối ưu hóa khả năng trích xuất đồng thời. Wang và cộng sự [49] áp dụng mô hình CNN hai nhánh song song để phát hiện ranh giới hải dương từ dữ liệu đa mô thức. Mỗi nguồn được xử lý độc lập, sau đó hợp nhất ở tầng giữa. Mặc dù mô hình nhận diện ranh giới tốt hơn so với phương pháp truyền thống, song sai khác độ phân giải và nhiễu cảm biến vẫn là thách thức lớn. Ma và cộng sự [50] đề xuất mô hình lai CNN-LSTM để dự báo mực nước hồ tại các trạm thủy điện bậc thang. CNN đảm nhiệm trích chọn đặc trưng không gian - thời gian từ chuỗi đầu vào (mưa, dòng chảy, mực nước hồ), trong khi LSTM học quan hệ động lực theo thời gian. Đây là dạng hợp nhất trung gian, khi các đặc trưng từ nhiều nguồn khí tượng - thủy văn được học riêng và kết hợp tại tầng giữa. Jin và cộng sự [51] tập trung vào dự báo mực nước hồ bằng dữ liệu viễn thám đa mô thức trong điều kiện thiếu dữ liệu thực địa. Mô hình học sâu (LSTM, BiLSTM, GRU) được xây dựng theo cơ chế hợp nhất mức đặc trưng, trong đó các đặc trưng từ ảnh viễn thám (diện tích mặt nước, thể tích chứa) và dữ liệu thủy văn được hợp nhất ở tầng ẩn. Kết quả cho thấy sự kết hợp này giúp tăng độ chính xác (R^2 tăng $>1\%$) và giảm RMSE, MAE đáng kể.

Ưu điểm cốt lõi của hướng tiếp cận đối xứng là sự công bằng trong việc khai thác thông tin, giúp mô hình không bị lệch lạc về phía nguồn dữ liệu nào, tuy nhiên nó đòi hỏi kỹ thuật thiết kế mạng tinh vi để cân bằng số lượng và quy mô đặc trưng giữa các nhánh.

- Hợp nhất bất đối xứng

Khác với kiến trúc đối xứng, hướng tiếp cận hợp nhất bất đối xứng sử dụng các cơ chế học nâng cao nhằm điều hướng quá trình hợp nhất, trong đó các nguồn dữ liệu được gán trọng số động hoặc phân cấp vai trò theo ngữ cảnh. Phương pháp này đặc biệt hữu ích khi chất lượng dữ liệu đầu vào không đồng đều hoặc cần hợp nhất tri thức vật lý - chuyên gia vào mô hình. Gần đây, các nghiên cứu tập trung mạnh vào cơ chế chú ý và lựa chọn độ, giúp mô hình dự

báo tự điều chỉnh mức độ đóng góp của từng nguồn dữ liệu theo thời gian và không gian.

Guo và cộng sự [52] đề xuất mô hình TAMMs, một hệ thống học sâu đa mô thức dựa trên cơ chế chú ý theo thời gian, nhằm mô hình hóa và dự báo biến động trong chuỗi ảnh vệ tinh. Mô hình khắc phục hạn chế của CNN hoặc LSTM truyền thống vốn chỉ xử lý riêng biệt miền không gian hoặc thời gian. Dữ liệu sử dụng gồm chuỗi ảnh Sentinel-2, cùng các biến phụ trợ như khí tượng, NDVI và NDTI. TAMMs thuộc nhóm hợp nhất trung gian theo cơ chế chú ý, với mỗi nguồn được mã hóa riêng (mã hóa không gian ảnh và mã hóa thời gian cho chuỗi phụ trợ), sau đó hợp nhất bằng khối chú ý để mô hình tập trung vào các thời điểm và vùng ảnh hưởng chính. Kết quả cho thấy TAMMs tái hiện tốt quan hệ không gian - thời gian và dự báo xu thế biến đổi chính xác hơn, dù chi phí tính toán cao và khả năng diễn giải còn hạn chế. Li và cộng sự [53] phát triển mô hình SRFNet, một kiến trúc học sâu đa mô thức cho dự báo phạm vi ngập lụt, kết hợp ảnh vệ tinh và chuỗi dữ liệu số. Nghiên cứu khắc phục hạn chế của các mô hình CNN hoặc LSTM truyền thống khi phải xử lý dữ liệu có độ phân giải không gian - thời gian khác nhau. Dữ liệu gồm ảnh Sentinel-1 (SAR), Sentinel-2, DEM cùng chuỗi mưa và lưu lượng tại trạm. Mỗi nguồn được đưa qua một mạng cơ sở (CNN hoặc GRU) và hợp nhất qua mô-đun Selective Receptive Field (SRF), có khả năng tự điều chỉnh vùng cảm thụ theo mức độ đóng góp của từng loại dữ liệu. Nhờ đó, mô hình tập trung vào các khu vực có biến động thủy văn mạnh hoặc nhạy cảm với mưa. SRFNet đạt hiệu quả cao trong xử lý dữ liệu đa mô thức đa thời gian, song yêu cầu tài nguyên tính toán lớn và phải tái huấn luyện khi áp dụng cho lưu vực mới.

Ampas và cộng sự [30] giới thiệu phương pháp lai kết hợp giữa mô hình vật lý thủy văn SWAT và mạng Transformer để dự báo dòng chảy tại một lưu vực ở Hy Lạp. Nghiên cứu tận dụng ưu thế của mô hình vật lý về tính giải thích và độ tin cậy, đồng thời bổ sung khả năng học phi tuyến của mô hình học sâu. Dữ liệu gồm đầu ra SWAT (lưu lượng, bốc hơi, mưa), dữ liệu thời tiết quan trắc - dự báo và DEM. Cách tiếp cận hợp nhất lai ghép được thực hiện bằng việc đưa đầu ra SWAT vào Transformer như một kênh thông tin phụ, cho phép mạng học sâu học phân sai lệch giữa mô phỏng và quan trắc. Kết quả cho thấy sai số RMSE giảm 20-30% so với từng mô hình riêng lẻ, chứng minh tiềm năng kết hợp tri thức vật lý với dữ liệu học sâu trong dự báo thủy văn.

Về tổng thể, nhóm hợp nhất bất đối xứng thể hiện ưu thế rõ rệt trong khả năng học trọng số động, loại bỏ nhiễu và hợp nhất tri thức vật lý vào mô hình, giúp nâng cao hiệu quả dự báo trong các hệ thống thủy văn phức tạp. Tuy nhiên, hướng tiếp cận này cũng đặt ra thách thức về thiết kế hàm mất mát, tối ưu tham số và chi phí huấn luyện, đặc biệt khi áp dụng trên các bộ dữ liệu quy mô lớn hoặc có tính dị nguồn cao.

- Hợp nhất muộn

Hợp nhất muộn, hay hợp nhất ở cấp độ quyết định, là phương pháp tách biệt hoàn toàn quá trình huấn luyện. Các mô hình độc lập được xây dựng và tối ưu hóa riêng biệt trên từng nguồn dữ liệu để đưa ra các dự báo riêng. Các kết quả dự báo này sau đó được tổng hợp lại thông qua các quy tắc thống kê (như lấy trung bình, bỏ phiếu) hoặc sử dụng một mô hình học máy cấp cao để đưa ra kết quả cuối cùng.

Mukhamediev và cộng sự [54] đề xuất ước lượng mực nước sông Ili (Kazakhstan) từ ảnh Sentinel-2 bằng mô hình học máy tổ hợp (Random Forest, XGBoost, CatBoost). Các mô hình con được huấn luyện độc lập và kết hợp ở đầu ra bằng cơ chế stacking hoặc trung bình trọng số. Đây là dạng late hợp nhất điển hình, giúp tăng độ ổn định và giảm nhiễu, đạt $R^2 \approx 0.89$. Tuy nhiên, phương pháp bị giới hạn do phụ thuộc ảnh quang học và thiếu dữ liệu hiệu chỉnh mặt đất. Tsai và Tseng [48] cũng áp dụng hợp nhất muộn để tổng hợp kết quả từ hai mô hình độc lập bao gồm mô hình xử lý ảnh và mô hình chuỗi khí tượng. Mặc dù độ chính xác thấp hơn hợp nhất trung gian, song phương pháp này thể hiện tính linh hoạt và khả năng chống thiếu hụt dữ liệu ở một nhánh, phù hợp với các ứng dụng thực tế trong thủy văn - viễn thám.

Ưu điểm nổi bật của hợp nhất muộn là tính mô-đun hóa cao, dễ dàng hợp nhất các mô hình có cấu trúc hoàn toàn khác nhau và mạnh mẽ trong việc xử lý trường hợp thiếu hụt dữ liệu ở một nhánh. Tuy nhiên, hạn chế lớn nhất là phương pháp này bỏ qua các mối tương quan và tương tác sâu giữa các đặc trưng của các nguồn dữ liệu khác nhau, do đó độ chính xác thường thấp hơn hợp nhất trung gian trong các bài toán yêu cầu sự hiểu biết tổng thể về hệ thống thủy văn.

- Hạn chế của phương pháp dự báo mực nước hồ đa mô thức

Xu hướng hợp nhất đa mô thức được xem là giải pháp tối ưu để bù đắp các khiếm khuyết trên, tuy nhiên việc kết hợp hai loại dữ liệu khác biệt về bản chất

của các dữ liệu ảnh vệ tinh và dữ liệu vận hành hồ (ảnh và số) đặt ra những thách thức chưa được giải quyết triệt để.

Thách thức của chiến lược hợp nhất sớm:

- Sự nhạy cảm với nhiễu: Do dữ liệu được gộp chung thành một véc-tơ/tensor đầu vào duy nhất, mô hình coi tất cả các nguồn có vai trò như nhau. Bất kỳ sự thiếu hụt hay nhiễu ở một nguồn (ví dụ: một bức ảnh bị mây che phủ một phần) sẽ lan truyền sai số trực tiếp vào mạng, phá vỡ cấu trúc học tập và làm giảm độ chính xác tổng thể.
- Vấn đề bất đồng bộ: Dữ liệu ảnh và số liệu thường có tần suất thu thập khác nhau. Việc đồng bộ hóa dữ liệu để ghép nối ở đầu vào thường gây mất mát thông tin hoặc tạo ra dữ liệu giả.

Thách thức của chiến lược hợp nhất muộn:

- Thiếu liên kết sâu: Việc huấn luyện các mô hình con độc lập và chỉ tổng hợp kết quả ở bước cuối cùng khiến hệ thống bỏ qua các mối tương quan phức tạp tiềm ẩn giữa đặc trưng hình thái (từ ảnh) và đặc trưng khí tượng (từ số liệu). Ví dụ, mô hình không học được rằng sự thay đổi hình dáng mặt nước trên ảnh có liên quan mật thiết đến lượng mưa tích lũy 3 ngày trước đó. Đây là một sự lãng phí tài nguyên thông tin lớn.

Thách thức của chiến lược hợp nhất trung gian:

Đây là hướng đi tiềm năng nhất nhưng cũng phức tạp nhất, với hai thách thức cốt lõi:

- Khoảng cách ngữ nghĩa: Đặc trưng trích xuất từ ảnh (không gian 2D) và đặc trưng từ chuỗi thời gian (1D) nằm trong các không gian biểu diễn khác nhau. Việc ghép nối chúng một cách cơ học (như Concatenation) thường không hiệu quả nếu không có cơ chế căn chỉnh phù hợp.
- Cơ chế cân bằng trọng số động: Trong thực tế, độ tin cậy của các nguồn dữ liệu thay đổi theo thời gian (ví dụ: vào ngày mưa bão, ảnh vệ tinh quang học không tin cậy, mô hình cần dựa vào số liệu mưa và Radar; ngược lại vào ngày đẹp trời, ảnh vệ tinh cung cấp thông tin không gian chính xác hơn). Các mô hình hợp nhất trung gian truyền thống thường sử dụng trọng số cố định hoặc chia sẻ, dẫn đến việc không thể tự động thích ứng và ưu tiên nguồn dữ liệu chất lượng hơn trong từng ngữ cảnh cụ thể.

- Tổng quan một số nghiên cứu trong nước

Việc nghiên cứu dự báo mực nước hồ là một vấn đề chưa có nhiều nghiên cứu chuyên sâu trong nước, một số kết quả nghiên cứu trong nước tiêu biểu như sau:

Năm 2024, Trần Thị Tuyết và cộng sự [55] đã ứng dụng hai mô hình học máy phổ biến là SVR (Support Vector Regression) và LSTM (Long Short-Term Memory) để dự báo mực nước hồ Buôn Tua Srah tại lưu vực sông Srê Pôk, Việt Nam. Dữ liệu thủy văn từ năm 2017–2023 được sử dụng với các bước dự báo khác nhau (6h, 12h, 24h, 48h, 72h) và các tổ hợp dữ liệu đầu vào tại thời điểm hiện tại, 24h và 72h trước thời điểm dự báo. Mục tiêu là xác định cấu hình dữ liệu tối ưu cho từng mô hình. Kết quả cho thấy, SVR và LSTM đạt hiệu năng tương đương trong các bước dự báo ngắn hạn (6h–24h) với sai số MAE thấp nhất lần lượt là 0,03m, 0,05m và 0,08m. Tuy nhiên, ở các bước dự báo dài hơn (48h, 72h), mô hình SVR cho kết quả chính xác hơn. Đặc biệt, bộ dữ liệu đầu vào tốt nhất cho SVR bao gồm mực nước hồ, lưu lượng đến, lưu lượng xả và thể tích hồ tại thời điểm 24h trước. Trong khi đó, LSTM cho kết quả tốt hơn khi chỉ sử dụng dữ liệu mực nước hồ tại thời điểm 72h trước.

Năm 2022, Đinh Nhật Quang và cộng sự [56] đã nghiên cứu xây dựng ba mô hình học máy gồm Hồi quy tuyến tính (LR), Random Forest (RFR) và LightGBM (LGBMR) để dự đoán mực nước hằng ngày trên sông Kiến Giang từ dữ liệu giai đoạn 1977–2020. Độ chính xác được đánh giá qua các chỉ số R^2 , NSE, MAE và RMSE, trong đó mô hình LR đạt kết quả tốt nhất với $R^2 = 0.959$; NSE = 0.958; MAE = 6.67 cm và RMSE = 12.2 cm.

Năm 2021, Trần Nguyễn Minh Thư và cộng sự [57] đã nghiên cứu đề xuất hệ thống dự báo mực nước trạm Cần Thơ bằng mô hình LSTM kết hợp phương pháp Stacking và đặc trưng dòng chảy. Dữ liệu đầu vào gồm mực nước của 1–5 trạm (Tân Châu, Châu Đốc, Vàm Nao, Mỹ Thuận) và lượng mưa, thu thập hàng giờ từ 2012–2015 để huấn luyện, đánh giá trên năm 2016 và 2020. Mô hình xét đến độ trễ dòng chảy và sử dụng dữ liệu 72 giờ trước đó để dự báo mực nước trong 1h, 12h và 24h tiếp theo. Kết quả cho thấy mô hình Stacking có sai số RMSE thấp hơn LSTM đơn lẻ, cụ thể RMSE dự báo 12h là 8.2 cm và 24h là 8.6 cm, so với 9.9 cm và 9.7 cm của mô hình LSTM trước đó.

Năm 2021, Đỗ Văn Đình và cộng sự [58], nghiên cứu đề xuất mô hình học máy hỗn hợp để dự báo mực nước sông cao nhất và thấp nhất trong ngày, gồm

hai thành phần: tuyến tính (SVD) và phi tuyến (SVM). Dữ liệu đầu vào là mực nước các ngày trước Mô hình được kiểm nghiệm trên tập dữ liệu thực tế gồm 1.460 ngày (từ 01/01/2017 đến 31/08/2020) tại trạm thủy văn Bá Nha, hạ lưu sông Thái Bình, tỉnh Hải Dương. Kết quả cho thấy mô hình đạt sai số trung bình tuyệt đối (MAE) là 0,12m, cho thấy hiệu quả cao trong dự báo.

Một số nghiên cứu trong nước về dự báo mực nước hồ hiện nay chủ yếu dừng ở việc ứng dụng trực tiếp các mô hình học sâu cơ bản, sử dụng dữ liệu vận hành như mực nước, lưu lượng vào và lưu lượng xả để thực hiện dự báo, mà **chưa khai thác sâu tiềm năng cải tiến mô hình thông qua đa mô thức.**

3. Khoảng trống nghiên cứu

Dựa trên việc tổng hợp và phân tích có hệ thống các công trình nghiên cứu liên quan đến bài toán dự báo mực nước hồ, có thể thấy một số vấn đề sau:

- 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.

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 năng 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. Đối tượng nghiên cứu của luận án

Luận án tập trung tìm hiểu và phân tích về bài toán dự báo mực nước hồ:

- Một số mô hình học sâu, các kỹ thuật xử lý ảnh vệ tinh Sentinel-2 cho bài toán dự báo mực nước hồ, bao gồm các tham số thủy văn tác động đến mực nước hồ.
- Tập trung vào ảnh vệ tinh Sentinel-2 khu vực hồ và dữ liệu vận hành hồ.

- Các chỉ số và kỹ thuật phân tích kiểm tra hiệu năng của mô hình dự báo mực nước hồ.

6. Phạm vi nghiên cứu

- Nghiên cứu các mô hình dự báo mực nước hồ đa mô thức tập trung vào bài toán dự báo mực nước hồ trung bình theo ngày.
- Nghiên cứu các mô hình học sâu trích xuất đặc trưng ảnh vệ tinh và các mô hình học sâu dự báo mực nước hồ cho các hồ chứa có thay đổi về bề mặt diện tích nước khi mực nước hồ thay đổi.
- Vận dụng các tiêu chí đánh giá mô hình dự báo và phân tích ANOVA hai chiều để kiểm định hiệu quả mô hình đề xuất.

7. Phương pháp nghiên cứu

Nghiên cứu lý thuyết: Thu thập và đánh giá các nghiên cứu có liên quan đến bài toán dự báo mực nước hồ. Từ việc xem xét các hạn chế, khoảng trống nghiên cứu và các thách thức còn tồn tại trong các hướng tiếp cận hiện hành, luận án xây dựng các mô hình dự báo mực nước hồ hiệu quả hơn.

Nghiên cứu thực nghiệm: Các thuật toán được đề xuất được triển khai, đánh giá và kiểm chứng thông qua việc đối chiếu với một số kỹ thuật dự báo mực nước hồ hiện đại, nhằm kiểm chứng mức độ hiệu quả và ưu thế của cách tiếp cận trong luận án. Các mô hình dự báo mực nước hồ có thể áp dụng cho các hồ khác nhau mà có sự thay đổi về diện tích mặt nước khi mực nước thay đổi. Dữ liệu vận hành của hai hồ được thu thập từ số liệu thực đo thông qua các thiết bị chuyên dụng trong ngành thủy văn, trong khi dữ liệu ảnh Sentinel-2 được khai thác từ hệ thống Copernicus của trung tâm Vũ trụ Châu Âu hỗ trợ.

8. Những đóng góp chính trong 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 năng 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].

9. Cấu trúc luận án

Luận án được tổ chức theo cấu trúc gồm: Mở đầu; Chương 1, Chương 2 và Chương 3 (các chương trọng tâm); Kết luận và hướng phát triển của đề tài; Danh mục các công trình khoa học đã công bố của tác giả; và Tài liệu tham khảo. Nội dung chi tiết của từng phần được khái quát như sau:

Phần Mở đầu trình bày tính cấp thiết của đề tài nghiên cứu trong bối cảnh biến đổi khí hậu và yêu cầu nâng cao độ chính xác trong vận hành hồ chứa. Trên cơ sở tổng quan có hệ thống các công trình nghiên cứu trong và ngoài nước liên quan đến bài toán dự báo mực nước hồ, luận án chỉ ra những hạn chế còn tồn tại và khoảng trống nghiên cứu cần được tiếp tục làm rõ. Từ đó, mục tiêu nghiên cứu được xác định một cách cụ thể, đồng thời làm rõ đối tượng nghiên cứu, phạm vi nghiên cứu, phương pháp tiếp cận, cũng như những đóng góp khoa học và thực tiễn của luận án.

Chương 1 tập trung giới thiệu bài toán dự báo mực nước hồ và các đặc thù của bài toán này dưới góc nhìn thủy văn và công nghệ thông tin. Chương này đồng thời trình bày các cơ sở lý thuyết, mô hình và phương pháp liên quan, đóng vai trò nền tảng cho việc thiết kế, phát triển và hoàn thiện các mô hình dự báo được đề xuất trong các chương tiếp theo.

Chương 2 là một trong những nội dung cốt lõi của luận án, trong đó đề xuất hai mô hình dự báo mực nước hồ đa mô thức là HOG-GRU và Colubrid-Net, nhằm dự báo mực nước hồ trung bình theo ngày. Chương này trình bày chi tiết ý tưởng nghiên cứu, kiến trúc tổng thể của các mô hình, phương pháp trích xuất và 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 nhằm đánh giá tính đúng đắn và hiệu quả của các mô hình HOG-GRU và Colubrid-Net được đề xuất. Nội dung chương bao gồm mô tả khu vực nghiên cứu, quy trình thu thập và tiền xử lý dữ liệu ảnh Sentinel-2 khu vực hồ chứa, cùng với các bộ dữ liệu vận hành hồ được sử dụng. Bên cạnh đó, chương này trình bày thiết kế thực nghiệm, các chỉ tiêu đánh giá, kết quả thực nghiệm và thảo luận chuyên sâu về hiệu năng dự báo của

các mô hình. Đồng thời, hệ thống dự báo mực nước hồ đa mô thức được đề xuất cũng được mô tả chi tiết trong chương này.

Kết luận và hướng phát triển tổng hợp các kết quả nghiên cứu chính mà luận án đã đạt được, làm rõ những đóng góp nổi bật về mặt khoa học và ứng dụng. Đồng thời, phần này cũng phân tích những hạn chế còn tồn tại, từ đó đề xuất các định hướng nghiên cứu tiếp theo và khả năng mở rộng trong tương lai.

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 và các kiến thức nền liên quan đến nội dung luận án.

1.1. Bài toán dự báo mực nước hồ

Bài toán dự báo mực nước hồ [24] là quá trình ước lượng mực nước của hồ trong tương lai dựa trên các yếu tố thủy văn, khí tượng và điều kiện vận hành,... nhằm phục vụ công tác điều tiết hồ, quản lý tài nguyên nước và giảm thiểu rủi ro thiên tai như lũ lụt và hạn hán. Bài toán này đóng vai trò quan trọng trong việc tối ưu hóa vận hành hồ, đảm bảo an toàn cho khu vực hạ lưu, đáp ứng nhu cầu cấp nước, phát điện và duy trì ổn định hệ sinh thái, đặc biệt trong bối cảnh biến đổi khí hậu và nhu cầu sử dụng nước ngày càng gia tăng.

Dữ liệu đầu vào của bài toán là các dữ liệu chuỗi thời gian (mực nước hồ, lưu lượng dòng chảy, lưu lượng xả,...); dữ liệu ảnh vệ tinh (ảnh Sentinel-2, Sentinel-1...); dữ liệu không gian địa lý (bản đồ sử dụng đất, bản đồ thiết kế hồ đập...); dữ liệu văn bản (bản tin thời tiết, báo cáo lịch sử thiên tai...) [24].

1.2. Đặc điểm của bài toán dự báo mực nước hồ

Bài toán dự báo mực nước hồ là một bài toán điển hình trong lĩnh vực thủy văn - tài nguyên nước, mang nhiều đặc trưng phức tạp của dữ liệu thực tế và có ý nghĩa quan trọng trong vận hành hồ, phòng chống lũ và quản lý tài nguyên nước. Bài toán có một số đặc điểm rõ nét như sau [24-28]:

- **Chuỗi thời gian:** Trước hết, đây là một bài toán có tính chuỗi thời gian rõ rệt, bởi mực nước hồ được quan trắc liên tục theo các mốc thời gian xác định (giờ, ngày, tháng) và hình thành nên một chuỗi dữ liệu có thứ tự thời gian. Các quan sát trong chuỗi không độc lập mà tồn tại mối quan hệ phụ thuộc chặt chẽ, trong đó giá trị mực nước hồ tại thời điểm hiện tại chịu ảnh hưởng trực tiếp từ các giá trị trong quá khứ thông qua cơ chế tích lũy nước, dòng chảy đến và chế độ xả hồ. Đặc điểm này được phản ánh rõ qua hiện tượng tự tương quan, khi mực nước hồ tại thời điểm t có mối liên hệ đáng kể với các thời điểm $t-1$, $t-2$,... Nhiều nghiên cứu đã chỉ ra rằng việc khai thác hiệu quả thông tin lịch sử trong chuỗi thời gian là yếu tố then chốt để nâng cao độ chính xác dự báo mực nước hồ, đặc biệt thông qua các mô hình chuỗi thời gian như ARIMA, SARIMA hay các mô hình học sâu như LSTM và GRU.

- **Tính mùa vụ và xu hướng biến động:** Trong điều kiện tự nhiên, mực nước hồ thường dao động theo chu kỳ mùa mưa - mùa khô, phản ánh đặc điểm khí hậu và thủy văn của lưu vực. Sự lặp lại có tính chu kỳ này tạo nên thành phần mùa vụ trong chuỗi dữ liệu, trong khi các thay đổi dài hạn về khí hậu, quy trình vận hành hồ hoặc nhu cầu khai thác nước có thể hình thành các xu hướng tăng hoặc giảm theo thời gian. Sự tồn tại đồng thời của xu hướng và mùa vụ khiến chuỗi mực nước hồ thường không dừng, làm gia tăng độ phức tạp cho bài toán dự báo. Các nghiên cứu thực nghiệm cho thấy việc không xem xét đầy đủ các thành phần này có thể dẫn đến sai lệch lớn trong kết quả dự báo, đặc biệt đối với các mô hình tuyến tính đơn giản.

- **Ảnh hưởng của nhiều yếu tố đầu vào:** Một đặc điểm quan trọng khác của bài toán dự báo mực nước hồ là sự phụ thuộc vào nhiều yếu tố đầu vào mang tính đa biến. Mực nước hồ không chỉ phụ thuộc vào chính các giá trị mực nước hồ trong quá khứ mà còn chịu ảnh hưởng của nhiều biến thủy văn và khí tượng như lượng mưa trên lưu vực, dòng chảy đến, lưu lượng xả, bốc hơi, cũng như các yếu tố liên quan đến vận hành hồ chứa. Mối quan hệ giữa các biến này thường phức tạp và có độ trễ theo thời gian, đòi hỏi các mô hình dự báo phải xử lý đồng thời thông tin đa chiều và tính chất động của hệ thống. Các nghiên cứu ứng dụng mô hình học máy và học sâu cho thấy việc hợp nhất hợp lý các biến đầu vào có thể cải thiện đáng kể hiệu quả dự báo so với các mô hình đơn biến truyền thống.

- **Sự tồn tại đồng thời của thành phần tuyến tính và phi tuyến:** Ngoài ra, chuỗi mực nước hồ còn thể hiện tính phi tuyến và sự xuất hiện của các biến động cực đoan. Trong nhiều trường hợp, mối quan hệ giữa các yếu tố đầu vào và mực nước hồ không tuân theo quy luật tuyến tính, đặc biệt trong các giai đoạn xảy ra mưa lớn, lũ đột ngột hoặc thay đổi chế độ vận hành hồ. Các hiện tượng này tạo ra những biến động bất thường trong chuỗi dữ liệu, khiến các mô hình tuyến tính gặp nhiều hạn chế trong việc mô phỏng chính xác. Do đó, nhiều nghiên cứu gần đây đã đề xuất các mô hình lai kết hợp giữa phương pháp thống kê và học sâu nhằm tận dụng ưu điểm của cả hai hướng tiếp cận trong việc mô tả đồng thời thành phần tuyến tính và phi tuyến của chuỗi mực nước hồ.

- **Sự xuất hiện của nhiễu và dữ liệu thiếu:** Bên cạnh những đặc điểm về cấu trúc dữ liệu, chất lượng dữ liệu quan trắc cũng là một thách thức đáng kể trong bài toán dự báo mực nước hồ. Dữ liệu thực tế thường tồn tại nhiễu, sai số

đo đạc, các khoảng trống do gián đoạn quan trắc hoặc sự không đồng đều về bước thời gian. Những vấn đề này có thể ảnh hưởng nghiêm trọng đến quá trình huấn luyện và đánh giá mô hình nếu không được xử lý phù hợp. Do đó, các bước tiền xử lý như lọc nhiễu, điền giá trị thiếu và chuẩn hóa dữ liệu được xem là yêu cầu bắt buộc trong hầu hết các nghiên cứu dự báo mực nước hồ hiện nay.

- **Yêu cầu về độ chính xác và tính phản ứng kịp thời:** bài toán dự báo mực nước hồ đặt ra yêu cầu cao về độ chính xác và tính ứng dụng thực tiễn. Kết quả dự báo không chỉ mang ý nghĩa học thuật mà còn được sử dụng trực tiếp trong vận hành hồ chứa, cảnh báo lũ, điều tiết cấp nước và đảm bảo an toàn công trình. Do đó, các mô hình dự báo cần đáp ứng khả năng dự báo đa bước theo nhiều khoảng thời gian khác nhau và được đánh giá bằng các chỉ tiêu sai số phù hợp với mục tiêu ứng dụng. Thực tiễn cho thấy việc lựa chọn mô hình phù hợp với đặc điểm chuỗi thời gian mực nước hồ đóng vai trò quyết định đến hiệu quả áp dụng trong quản lý tài nguyên nước và giảm thiểu rủi ro thiên tai.

1.3. Ảnh vệ tinh Sentinel-2

Sentinel-2 là một trong những vệ tinh quan sát Trái Đất thuộc Chương trình Copernicus do Cơ quan Vũ trụ châu Âu (European Space Agency - ESA) triển khai, với mục tiêu cung cấp dữ liệu quang học đa phổ độ phân giải cao phục vụ công tác giám sát tài nguyên thiên nhiên, nông nghiệp, rừng, chất lượng nước, cũng như biến động môi trường và khí hậu toàn cầu. Hệ thống gồm hai vệ tinh song song là Sentinel-2A (phóng năm 2015) và Sentinel-2B (phóng năm 2017), hoạt động trên cùng quỹ đạo nhưng lệch pha 180° , cho phép rút ngắn chu kỳ lặp quan sát xuống 5 ngày tại xích đạo và 2-3 ngày tại các vĩ độ trung bình [61-62].

Đặc điểm kỹ thuật [61-62]:

Mỗi vệ tinh Sentinel-2 được trang bị cảm biến MultiSpectral Instrument (MSI), có khả năng thu nhận ảnh trên 13 dải phổ. Các dải phổ này được thiết kế để phục vụ nhiều mục đích quan sát khác nhau, đặc biệt là giám sát thảm thực vật và tài nguyên nước mặt. Đối với dữ liệu ảnh viễn thám, mặc dù trong viễn thám thủy văn, các kênh cận hồng ngoại (NIR), hồng ngoại sóng ngắn (SWIR) và các chỉ số phổ như NDWI/MNDWI có cơ sở vật lý vững chắc trong việc tách mặt nước nhờ đặc tính hấp thụ mạnh của nước ở các dải sóng này, luận án lựa chọn sử dụng ba kênh RGB (B2, B3, B4) của ảnh Sentinel-2 nhằm phục vụ mục tiêu khai thác đặc trưng hình thái và không gian của mặt hồ thông

qua các mô hình học sâu. Trong bài toán dự báo mực nước hồ, các thông tin về hình dạng, biên mặt nước và sự biến đổi không gian theo thời gian của hồ chứa có ý nghĩa quyết định hơn so với việc phân loại phổ đơn thuần. Ba kênh RGB cung cấp biểu diễn trực quan gần với ảnh quan sát tự nhiên, giúp mô hình học sâu nắm bắt tốt cấu trúc hình thái của mặt hồ.

Bên cạnh đó, việc sử dụng ảnh RGB cho phép tận dụng hiệu quả các mô hình mạng nơ-ron tích chập đã được tiền huấn luyện trên các tập dữ liệu ảnh tự nhiên quy mô lớn. Cách tiếp cận này góp phần nâng cao khả năng học đặc trưng, giảm nguy cơ quá khớp và tăng tính ổn định của mô hình trong bối cảnh số lượng ảnh vệ tinh hạn chế và chuỗi thời gian thủy văn dài. Đồng thời, phương pháp này giúp đơn giản hóa quy trình tiền xử lý dữ liệu, hạn chế các vấn đề liên quan đến chuẩn hóa phổ và sự khác biệt phản xạ giữa các thời điểm chụp ảnh.

Thông số các dải quang phổ của ảnh vệ tinh Sentinel-2 được sử dụng cho dữ liệu ảnh trong bài được trình bày trong Bảng 1.1.

Bảng 1.1. Thông số các dải quang phổ của ảnh vệ tinh Sentinel-2

STT	Dải quang phổ (kênh ảnh)	Bước sóng trung tâm (nm)		Độ phân giải (m)
		Sentinel-2A	Sentinel-2B	
1	Band 1 - Coastal aerosol	443.9	442.3	60
2	Band 2 - Blue	496.6	492.1	10
3	Band 3 - Green	560	559	10
4	Band 4 - Red	664.5	665	20
5	Band 5 - Vegetation Red Edge 1	740.2	739.1	20
6	Band 6 - Vegetation Red Edge 2	782.5	779.7	20
7	Band 7 - Vegetation Red Edge 3	782.5	779.7	20
8	Band 8 - NIR	835.1	833	10
9	Band 8A - Vegetation Red Edge 4	864.8	864	20
10	Band 9 - Water vapour	945	943.2	60
11	Band 10 - Cirrus	1373.5	1376.9	60
12	Band 11 - SWIR1	1613.7	1610.4	20
13	Band 12 - SWIR2	2202.4	2185.7	20

Ưu điểm và tính ứng dụng [61-62]:

Ảnh Sentinel-2 có nhiều ưu điểm nổi bật so với các nguồn dữ liệu viễn thám truyền thống như Landsat hoặc MODIS, bao gồm:

- Miễn phí và công khai, dễ dàng truy cập thông qua nền tảng Copernicus.
- Độ phân giải cao (10-20 m).
- Độ phủ không gian rộng (290 km), thuận tiện cho việc ghép cảnh và phân tích khu vực lớn.
- Được hiệu chỉnh khí quyển tự động, đảm bảo tính ổn định và so sánh được giữa các thời điểm khác nhau.

Nhờ các đặc điểm này, Sentinel-2 hiện là một nguồn dữ liệu quang học hữu ích và đáng tin cậy nhất phục vụ nghiên cứu, quản lý và dự báo tài nguyên nước trên thế giới nói chung và tại Việt Nam nói riêng.

1.4. Các mô hình dự báo mực nước hồ truyền thống

1.4.1. Một số mô hình thủy văn thủy lực

- **Mô hình MIKE 11**

MIKE 11 [65, 66] là mô hình thủy lực một chiều do Viện Thủy lực Đan Mạch (DHI) phát triển, được sử dụng rộng rãi trong mô phỏng và dự báo mực nước, lưu lượng và quá trình lan truyền lũ trong các hệ thống sông, kênh và hồ chứa. Cơ sở lý thuyết của MIKE 11 dựa trên hệ phương trình Saint–Venant một chiều, mô tả dòng chảy không ổn định trong lòng dẫn hở thông qua hai phương trình cơ bản là phương trình liên tục và phương trình động lượng. Phương trình liên tục biểu diễn sự bảo toàn khối lượng của dòng chảy, có dạng:

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = q_l \quad (1.1)$$

trong đó A là diện tích mặt cắt ướt, Q là lưu lượng, q_l là lưu lượng phân bố dọc sông, x và t lần lượt là tọa độ không gian và thời gian. Phương trình động lượng thể hiện sự bảo toàn động lượng của dòng chảy, được viết dưới dạng:

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(\frac{Q^2}{A} \right) + gA \frac{\partial h}{\partial x} + g \frac{Q|Q|}{C^2 AR} = 0 \quad (1.2)$$

trong đó h là mực nước, g là gia tốc trọng trường, R là bán kính thủy lực và C là hệ số nhám Chezy (hoặc có thể biểu diễn thông qua hệ số Manning).

Hệ phương trình này được MIKE 11 giải bằng phương pháp sai phân hữu hạn ẩn sáu điểm Abbott–Ionescu, cho phép mô phỏng ổn định và chính xác quá trình biến đổi mực nước và lưu lượng theo thời gian. Nhờ cơ sở vật lý rõ ràng, khả năng liên kết với mô-đun mưa – dòng chảy và mô-đun vận hành công trình, MIKE 11 được xem là công cụ hiệu quả trong dự báo mực nước, mô phỏng lũ và hỗ trợ quản lý, vận hành hệ thống sông và hồ chứa, mặc dù vẫn phụ thuộc mạnh vào chất lượng dữ liệu đầu vào và hiệu chỉnh tham số.

- **Mô hình HEC-RAS**

HEC-RAS (Hydrologic Engineering Center – River Analysis System) [67-68] là mô hình thủy lực do Trung tâm Kỹ thuật Thủy văn của Quân đội Hoa Kỳ (USACE) phát triển, được sử dụng rộng rãi trong mô phỏng và dự báo mực nước, lưu lượng, lũ và ngập lụt trên sông, kênh và vùng ngập. HEC-RAS cho phép mô phỏng dòng chảy một chiều (1D), hai chiều (2D) và kết hợp 1D/2D, trong đó mô hình 1D được áp dụng phổ biến cho các bài toán dự báo mực nước dọc sông. Cơ sở lý thuyết của HEC-RAS dựa trên hệ phương trình Saint–Venant mô tả dòng chảy không ổn định trong lòng dẫn hở. Phương trình liên tục thể hiện sự bảo toàn khối lượng của dòng chảy, có dạng:

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = q_l \quad (1.3)$$

trong đó A là diện tích mặt cắt ướt, Q là lưu lượng, q_l là lưu lượng phân bố dọc theo sông, x và t lần lượt là tọa độ không gian và thời gian. Phương trình động lượng mô tả sự biến đổi động lượng của dòng chảy theo thời gian và không gian, được viết dưới dạng:

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(\frac{Q^2}{A} \right) + gA \frac{\partial h}{\partial x} + gA(S_f - S_0) = 0 \quad (1.4)$$

trong đó h là mực nước, g là gia tốc trọng trường, S_0 là độ dốc đáy sông và S_f là độ dốc tổn thất năng lượng do ma sát, thường được xác định theo công thức Manning:

$$S_f = \frac{n^2 Q^2}{A^2 R^{4/3}} \quad (1.5)$$

với n là hệ số nhám Manning và R là bán kính thủy lực. HEC-RAS giải hệ phương trình này bằng phương pháp sai phân hữu hạn ẩn, cho phép mô phỏng

ổn định quá trình lan truyền sóng lũ và biến đổi mực nước theo thời gian. Nhờ giao diện thân thiện, cơ sở lý thuyết rõ ràng và khả năng mở rộng sang mô phỏng ngập 2D, HEC-RAS được sử dụng rộng rãi trong dự báo lũ, tính toán mực nước thiết kế, đánh giá ngập lụt và phân tích tác động của các công trình thủy lợi – thủy điện, dù độ chính xác của mô hình vẫn phụ thuộc đáng kể vào chất lượng số liệu hình học, biên và quá trình hiệu chỉnh tham số.

1.4.2. Các mô hình hồi quy

- **ARIMA (Autoregressive Integrated Moving Average)**

ARIMA, cụm từ viết tắt thông dụng của Autoregressive Integrated Moving Average, được các tác giả Box và Jenkin đưa ra trong năm 1971 [69], ứng dụng vào các mô hình tính toán cho chuỗi thời gian. Tới năm 1991, Brock và David [70] đã đưa ra các mô tả chi tiết về mô hình ARIMA này. Hiện nay, mô hình ARIMA là một mô hình được sử dụng rộng rãi vào dự báo chuỗi thời gian. Nó được đánh giá là một mô hình tốt cho việc xử lý các dữ liệu chuỗi thời gian dạng tuyến tính [71].

Trong nghiên cứu của Mina và đồng nghiệp năm 2017 [72], tác giả đã đánh giá về khá nhiều bộ dữ liệu (6 bộ dữ liệu). Nhưng vấn đề của bài nghiên cứu là chỉ đánh giá riêng mô hình ARIMA (2,0,0), không hề có các đánh giá đối với các tham số khác. Điều này có thể khiến cho mô hình của tác giả đưa ra chưa chắc đã là tốt nhất, dù chỉ tính riêng với mô hình tuyến tính ARIMA.

Trong nghiên cứu [73], tác giả Viccione và đồng nghiệp đã cố gắng dự báo mực nước trong các bể chứa của thành phố, ứng dụng vào tự động hóa việc đóng mở các van nước vào. Các tác giả đã chỉ ra việc mô hình ARIMA áp dụng khá tốt cho dữ liệu ở đây. Tuy nhiên, dữ liệu nước được sử dụng có độ nhiễu khá nhỏ, cho nên có thể áp dụng tốt mô hình ARIMA vào. Cùng với đó, các mô hình được đề xuất cho các kết quả khác nhau rất nhỏ dù đã thay đổi rất lớn các tham số, cho nên cũng chưa đánh giá được tính ưu việt của mô hình. Và mô hình cũng không đánh giá và so sánh được kết quả giữa mô hình ARIMA với các mô hình mạng thần kinh nhân tạo.

Các thành phần của mô hình ARIMA:

Mô hình ARIMA là sự kết hợp của các mô hình thành phần AR, MA, I, vì vậy nó vẫn giữ nguyên các tham số trong các thành phần:

- AR: tự hồi quy- một giá trị đằng sau có thể được tính toán thông qua một công thức (hay hàm số) của các giá trị đứng trước nó (hay còn gọi là các giá trị quá khứ của chuỗi thời gian).

- I: sai phân- sử dụng sai phân để tạo tính dừng cho chuỗi thời gian. Trong trường hợp chuỗi thời gian đã là chuỗi dừng thì đơn giản $d = 0$.

- MA: trung bình trượt- là một trung bình các trọng số của nhiễu trắng (các giá trị white noise).

Đầu tiên chúng ta sẽ xem xét siêu tham số d trong mô hình ARIMA. Với mô hình ARIMA (hoặc nói rộng hơn là trong mô hình AR), chuỗi thời gian phải là một chuỗi dừng. Bởi vì trong một mô hình sử dụng phương pháp tự hồi quy thì nó sử dụng chính các giá trị trong quá khứ của nó (vì thế mà mô hình có độ trễ) để tính toán các giá trị tiếp theo. Các mô hình tự hồi quy khi đó sẽ hoạt động được với các yếu tố độc lập.

Trong số các cách để đưa một chuỗi về chuỗi dừng, cách dùng sai phân là một cách đơn giản. Với cách sai phân, ta tính toán chênh lệch giữa các giá trị liên tiếp của chuỗi ban đầu, để tạo ra một chuỗi mới. Với một số trường hợp phức tạp, chúng ta có thể phải áp dụng sai phân nhiều lần.

Giá trị d trong mô hình là một số nguyên không âm, là giá trị nhỏ nhất của số lần sai phân mà khi ta dùng d lần sai phân thì chuỗi của chúng ta trở thành chuỗi dừng. Với một chuỗi đã là chuỗi dừng, ta dễ thấy ngay $d = 0$.

Trong ARIMA, giá trị d thể hiện cho phần "I", Integrated.

Tiếp theo, chúng ta sẽ xem xét các giá trị p và q trong mô hình (chúng ta gọi chúng là các siêu tham số của mô hình ARIMA).

Ở đây, p là siêu tham số của phần tự hồi quy trong mô hình (phần AR của mô hình ARIMA) (tiếng Anh là "order of the 'Auto Regressive' (AR) term"). Tham số p là một số nguyên dương, thể hiện số lượng giá trị trong quá khứ của chuỗi thời gian đã được sử dụng để dùng cho tính toán các giá trị ước dự báo. Giá trị của p đề cập tới "độ trễ" của việc lấy dữ liệu đầu vào của mô hình. Giải thích rõ ràng hơn thì là để tính toán giá trị x_t của chuỗi thời gian thì mô hình sử dụng một hàm số có tổng cộng p biến, là $x_{t-1}, x_{t-2}, \dots, x_{t-p}$.

Còn giá trị q là siêu tham số tương ứng của phần trung bình trượt trong mô hình (phần MA trong mô hình ARIMA). q là một số nguyên dương. Mô

hình tự hồi quy thuần túy (chỉ có AutoRegression- AR) là mô hình mà x_t chỉ phụ thuộc vào các giá trị quá khứ của chính nó.

$$y_t = x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t \quad (1.6)$$

Trong đó, các giá trị ϕ_1 tới ϕ_p khác 0 là các tham số phân tích hồi quy, còn ε_t là sai số ngẫu nhiên thỏa mãn các giả thiết của nhiễu trắng (ồn trắng) của thời điểm t (tại thời điểm đang được tính toán).

Trong đó, ký hiệu y_t là giá trị đầu ra của mô hình tại bước thứ t , để phân biệt với đầu vào là các giá trị x_i ($i=1...T$). Nhưng ở đây, mô hình dự báo có đầu ra là giá trị tiếp theo của chuỗi thời gian, nên công thức viết là $y_t = x_t$ để thể hiện x_t là đầu ra của mô hình). Tương tự như vậy, mô hình trung bình trượt thuần túy (chỉ có Moving Average- MA) là mô hình trong đó x_t chỉ phụ thuộc vào các nhiễu trắng ε_t .

$$x_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}. \quad (1.7)$$

trong đó các tham số θ_1 tới θ_q khác 0, giá trị nhiễu trắng ε_i là của các mô hình AutoRegressive có độ trễ tương ứng. Các nhiễu trắng $\varepsilon_t, \varepsilon_{t-1} \dots$ là các nhiễu lấy từ các phương trình sau của mô hình:

$$\begin{aligned} x_t &= \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_t x_0 + \varepsilon_t \\ x_{t-1} &= \phi_1 x_{t-2} + \phi_2 x_{t-3} + \dots + \phi_t x_0 + \varepsilon_{t-1} \\ &\dots \end{aligned} \quad (1.8)$$

Đó là mô hình AR và MA tương ứng. Như vậy, ta có thể kết hợp các thành phần riêng biệt trên để tạo ra mô hình ARIMA, là mô hình mà chuỗi thời gian được sai phân một vài lần (hoặc thậm chí không cần sai phân nếu chuỗi đã dừng) để làm cho chuỗi dữ liệu gốc thành chuỗi dừng và sau đó kết hợp các thành phần AR và MA. Vì vậy, phương trình của mô hình ARMA sẽ trở thành:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (1.9)$$

Các giá trị quá khứ được dùng là p giá trị trước x_t , còn các nhiễu trắng thì là trước q giá trị. Do đó, mục tiêu của chúng ta trong mô hình ARIMA là xác định các giá trị của p , d và q . Một tham số trong các tham số p , d , q có thể

được lấy bằng 0. Khi đó, mô hình ARIMA sẽ rút bớt đi thành phần mô hình tương ứng, trở thành mô hình ARMA, AR hoặc MA. Cơ bản chúng ta có thể xây dựng mô hình ARIMA theo 4 bước sau:

Bước 1: xác định tính dừng của chuỗi thời gian. Khi xác định được chuỗi thời gian là dừng thì mới có thể sử dụng các mô hình Auto Regression và Moving Average. Nếu chuỗi thời gian gốc là không dừng thì chúng ta cần lấy sai phân của chuỗi để tạo ra chuỗi có tính dừng (xác định giá trị của d , trong trường hợp này là $d = 0$).

Bước 2: ước lượng các tham số p và q của mô hình.

Bước 3: tính toán các giá trị của chuỗi thời gian để xác định độ chính xác của mô hình. Hiệu chỉnh các tham số p, d, q đưa ra các ước lượng tốt hơn về các tham số này.

Bước 4: dự đoán chuỗi thời gian (với một khoảng tin cậy).

- **SARIMA (Seasonal Autoregressive Integrated Moving Average)**

Seasonal Autoregressive Integrated Moving Average (SARIMA), hay còn gọi là Seasonal ARIMA, là một sự mở rộng quan trọng của mô hình ARIMA truyền thống. Mô hình này được phát triển nhằm xử lý thêm yếu tố mùa vụ — một đặc điểm thường xuất hiện trong nhiều loại dữ liệu chuỗi thời gian thực tế như dữ liệu khí hậu, tiêu dùng, sản xuất, và kinh tế.

Về bản chất, SARIMA là một mô hình ARIMA được bổ sung thêm các thành phần có tính chu kỳ (seasonal components) để mô hình hóa sự lặp lại theo mùa trong dữ liệu. Nhờ khả năng nắm bắt được cả xu hướng dài hạn lẫn các biến động mang tính mùa vụ, mô hình SARIMA đã và đang được sử dụng rộng rãi trong các ứng dụng phân tích và dự báo chuỗi thời gian. Đây là công cụ hữu hiệu trong nhiều lĩnh vực, từ dự báo doanh số bán hàng, dự đoán nhu cầu năng lượng, đến phân tích dịch tễ học hay theo dõi hiện tượng khí hậu. Tính linh hoạt và khả năng mô hình hóa tốt các mẫu biến động có chu kỳ khiến SARIMA tiếp tục là lựa chọn đáng tin cậy cho nhiều nhà nghiên cứu và chuyên gia dữ liệu trong bối cảnh hiện nay.

Bằng cách tách tính mùa ra khỏi dữ liệu chuỗi thời gian, phương pháp SARIMA đã cho kết quả tốt hơn trong nhiều lớp trường hợp. Cách tách mùa, hay được sử dụng là phương pháp STL [74] hoặc công thức Fourier.

Các thành phần của mô hình SARIMA:

Mô hình SARIMA có thêm 3 hyperparameters nữa (có thể dịch là siêu tham số) so với mô hình ARIMA, tương ứng với AR, I, MA của thành phần mùa trong dữ liệu. Ngoài ra, nó cũng bổ sung 1 tham số nữa để tính thời gian cho tính mùa. Như vậy, mô hình SARIMA được hình thành bằng cách đưa thêm các tham số theo mùa vào ARIMA. Phần theo mùa của mô hình bao gồm các tham số giống với các thành phần không theo mùa của mô hình ARIMA. Khi đó, mô hình SARIMA sẽ cần phải chọn các tham số (parameters) và siêu tham số (hyperparameters) cho cả 2 thành phần của dữ liệu: thành phần xu hướng (trend) và thành phần mùa (seasonal):

Thành phần xu hướng – Trend: vẫn có 3 siêu tham số giống như của mô hình ARIMA. Chúng là các siêu tham số sau đây:

- p : bậc của tự hồi quy của xu hướng (Trend autoregression order).
- d : bậc sai phân của xu hướng (Trend difference order)
- q : bậc trung bình trượt của xu hướng (Trend moving average order).

Thành phần mùa – Seasonal: có 4 siêu tham số mới, trong đó có 3 siêu tham số (hyperparameters) giống với mô hình ARIMA và một siêu tham số để chỉ ra thời gian lặp của tính mùa

- P : bậc của tự hồi quy của mùa (Seasonal autoregressive order).
- D : bậc sai phân của mùa (Seasonal difference order).
- Q : bậc trung bình trượt của mùa (Seasonal moving average order).
- s : số giá trị trong mỗi chu kỳ của thành phần mùa trong dữ liệu

Khi đó, ta có thể viết mô hình SARIMA thành công thức như sau:

$$SARIMA(p, d, q)(P, D, Q)_s \quad (1.10)$$

Một ví dụ của mô hình SARIMA được cho sau đây, ứng dụng với một bộ dữ liệu có tính chu kỳ theo năm.

$$SARIMA(3, 1, 2)(1, 1, 1)_{12} \quad (1.11)$$

Trong đó, tham số s là một tham số có ảnh hưởng tới tất cả các siêu tham số P, D, Q (hyperparameters). Trong trường hợp ở ví dụ này thì $s = 12$ là do bộ dữ liệu mang tính mùa theo tháng của năm. Chu kỳ được lặp lại theo mỗi năm. Còn giá trị $P = 1$ tức là chúng ta đang sử dụng 1 chu kỳ trong quá khứ để dự báo, hay khi viết bằng công thức thì sẽ là lấy các giá trị tới thời điểm $t - s * P$

hay $t - 2$. Còn giả sử trong trường hợp khác, ta sử dụng $P = 2$, tức là ta đã dùng các giá trị quá khứ tới $t - 24$. Còn về 2 giá trị D, Q thì cũng tương tự như mô hình ARIMA, giá trị của D là số lần lấy sai phân của dữ liệu mùa (ở đây $D = 1$ tức là ta đã sai phân một lần) và Q là số nhiễu trắng ε mà ta sử dụng.

Ngoài ra, trong mô hình SARIMA có thể sử dụng thêm 1 tham số nữa là số lượng mùa gọi là s . Một mô hình SARIMA (hay ARIMA theo mùa) sử dụng sự khác biệt ở độ trễ bằng với số mùa s để tách ra các hiệu ứng phụ theo mùa. Khi đó, mô hình SARIMA (ARIMA có theo mùa) cũng vẫn bao gồm các thành phần tự hồi quy (AR) và trung bình trượt (MA) ở độ trễ s . Các yếu tố mùa (seasonal) có thể được chọn thông qua phân tích cẩn thận dữ liệu, xem xét các mối tương quan của các bước thời gian s (ví dụ: 1, 2, 3,...). Trong một số mô hình, chúng ta có thể bỏ qua giá trị của tham số s , bởi vì thành phần có tính mùa của dữ liệu đã được phân tích riêng.

Công thức của mô hình SARIMA:

Cho chuỗi thời gian $\{x_t | t = 1, 2, \dots, T\}$, khi đó một mô hình SARIMA $(p, d, q)(P, D, Q)$ sẽ được thực hiện theo các phương trình sau đây:

$$\phi(L)(1-L)^d \Phi(L^s)(1-L^s)^D x_t = c + \theta(L)\Theta(L)\varepsilon_t. \quad (1.12)$$

Trong đó:

- $\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$ là thành phần tự hồi quy (Auto Regressive operator- AR) với tham số p (gọi là bậc p). Đây là thành phần của xu hướng trong chuỗi thời gian gốc.

- $\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q$ là thành phần trung bình trượt (Moving Average operator- MA) của tham số q (gọi là bậc q). Đây là thành phần của xu hướng trong chuỗi thời gian gốc.

- d là số lần lấy sai phân chuỗi thời gian (thành phần xu hướng). Chỉ khi nào chuỗi thời gian không có tính dừng thì mới lấy $d = 0$. Ví dụ như trong nghiên cứu của Shumway (2006) [24], tác giả đã sử dụng tất cả các giá trị $d \leq 2$ cho các phép thử.

- $\Phi(L) = 1 - \Phi_1 L^s - \Phi_2 L^{2s} - \dots - \Phi_P L^P$ là thành phần tự hồi quy của phần mùa (Seasonal Auto Regressive operator- S-AR) của siêu tham số P (cũng gọi là bậc P).

- $\Theta(L) = 1 - \Theta_1 L^s - \Theta_2 L^{2s} - \dots - \Theta_Q L^Q$ là thành phần trung bình trượt của thành phần mùa của chuỗi thời gian gốc (Seasonal Moving Average operator-S-MA) của siêu tham số Q (cũng gọi là bậc Q).

- D : cũng giống như tham số d , siêu tham số D là số lần lấy sai phân của thành phần mùa của chuỗi thời gian gốc. Tính mùa có tính chu kỳ nên trong phần nhiều các trường hợp, $D = 1$ (seasonality effect), còn $D = 0$ khi mà dữ liệu gốc không có tính mùa.

- ε_t là phần dư ước tính tại thời điểm t , được phân phối giống nhau và độc lập như một biến ngẫu nhiên bình thường với giá trị trung bình bằng 0 (ε_t là nhiễu trắng); và phương sai σ (σ_ε^2).

Cơ bản chúng ta có thể xây dựng mô hình SARIMA theo 4 bước sau:

- **Bước 1:** xác định tính dừng của chuỗi thời gian. Khi xác định được chuỗi thời gian là dừng thì mới có thể sử dụng các mô hình Auto Regression và Moving Average.

- **Bước 2:** ước lượng các tham số của mô hình.

- **Bước 3:** kiểm tra độ chính xác của mô hình đã chọn; các cải tiến nếu khả thi cũng được thiết lập trong giai đoạn này.


- **Bước 4:** tính toán các giá trị dự báo của mô hình trong tương lai của chuỗi, được phân phối với khoảng tin cậy nào đó.

Như vậy trong chương này, chúng ta đã giới thiệu một số mô hình tuyến tính đơn giản, do đó dễ dàng cài đặt và ít tiêu tốn tài nguyên tính toán. Tuy nhiên, các mô hình này thường phù hợp với các dữ liệu ít biến động (mang tính phi tuyến thấp). Trong chương tiếp theo, chúng ta sẽ trình bày một số mô hình phi tuyến nhằm xử lý các tập dữ liệu chuỗi thời gian phức tạp hơn.

1.5. Một số mô hình học sâu

• Mạng RNN

Trước khi giới thiệu mạng LSTM và GRU, phần này sẽ trình bày cấu trúc của mô hình RNN vì cả hai mạng LSTM và GRU đều là các biến thể của mạng RNN với cùng một khung cơ bản. Mạng RNN bao gồm một chuỗi các mô-đun có cấu trúc cơ bản tương tự nhau. *Hình 1.1*, minh họa cấu trúc cơ bản của mạng RNN.



Hình 1.1. Lưu đồ mạng RNN

Trong đó, x_t là véc-tơ đầu vào tại thời điểm t . Tại bước thời gian thứ t của ô RNN thì h_t là đầu ra cuối cùng. Thuật ngữ h_t để chỉ trạng thái ẩn trong RNN. Dựa trên trạng thái ẩn (h_{t-1}) tại bước thời gian trước đó $t - 1$ để tính ra trạng thái ẩn h_t và véc-tơ đầu vào (x_t) tại thời điểm hiện tại t . Phương trình cụ thể cho một trạng thái ẩn (h_t) như sau:


$$h_t = \tanh(Ux_t + Vh_{t-1} + a) \quad (1.13)$$

Ở mỗi bước thời gian, các cấu trúc cơ bản có các tham số giống nhau, gồm a , U và V , trong đó $\tanh$ là hàm kích hoạt, a là véc-tơ sai số, U và V là các ma trận trọng số đóng vai trò như là các tham số cho trạng thái ẩn h và đầu vào x tương ứng.

Đầu ra cuối cùng của RNN phụ thuộc vào đầu vào tại bước thời gian hiện tại và thông tin tính toán từ lớp ẩn ở bước thời gian trước đó [75]. RNN có khả năng tận dụng tất cả thông tin dù độ dài của chuỗi là bao nhiêu. Tuy nhiên, do vấn đề Gradient nên tính chính xác của RNN sẽ giảm khi độ dài của chuỗi thời gian quá lớn. Mạng LSTM giải quyết hạn chế đó của RNN [76].

- **Mạng LSTM**

Mạng nơ-ron LSTM giống mô hình RNN truyền thống. Tuy nhiên các hoạt động bên trong các ô của LSTM phức tạp hơn, cho phép LSTM học được các phụ thuộc ngắn hạn dài. So với RNN truyền thống, mạng LSTM có một trạng thái ô bổ sung mà thông tin có thể được lưu trữ. Cấu trúc cơ bản của một ô LSTM được minh họa trong Hình 1.2, trong đó x_t là véc-tơ đầu vào, h_t , (h_{t-1}) là trạng thái ẩn của ô LSTM tại bước thời gian t , ($t-1$); c_t , (c_{t-1}) là trạng thái ô của ô LSTM tại bước thời gian t , ($t-1$). Cấu trúc của ô LSTM cho thấy cả trạng thái ô (c_t) và trạng thái ẩn (h_t) của nó được chuyển tiếp đến bước thời gian tiếp theo [77, 78].



Hình 1.2. Lưu đồ mạng LSTM

LSTM có ba cổng giữ và điều chỉnh trạng thái ô (c_t) và trạng thái ẩn (h_t), bao gồm một cổng quên (f_t), một cổng đầu vào (i_t) và một cổng đầu ra (o_t). Ba cổng này hoạt động như bộ lọc, phục vụ các mục đích khác nhau. Cổng quên (f_t) xác định thông tin nào sẽ được loại bỏ khỏi trạng thái ô (c_t). Cổng đầu vào (i_t) xác định thông tin mới nào sẽ được lưu trữ trong trạng thái ô (c_t). Cổng đầu ra (o_t) chỉ định thông tin từ trạng thái ô được sử dụng làm đầu ra (o_t). Thông qua các chức năng của ba cổng này, các ô LSTM có thể bắt được mối tương quan phức tạp trong cả chuỗi thời gian ngắn và dài hạn, đây là một cải tiến giúp hiệu năng dự báo tốt hơn so với RNN truyền thống.

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci} \circ c_{t-1} + b_i) \quad (1.14)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf} \circ c_{t-1} + b_f) \quad (1.15)$$

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (1.16)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (1.17)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co} \circ c_t + b_o) \quad (1.18)$$


$$h_t = o_t \circ \tanh(c_t) \quad (1.19)$$

Trong đó, σ là hàm sigmoid logistic; W , b lần lượt là ma trận tham số và véc-tơ bias, “ $\circ$ ” là phép nhân Hadamard.

- **Mạng BiLSTM**

Mạng BiLSTM được phát triển từ mạng LSTM [79], mạng gồm có hai lớp LSTM, một lớp xử lý thông tin từ hiện tại đến quá khứ (backward) và một

lớp xử lý thông tin. Mô hình mạng BiLSTM được biểu diễn trong Hình 1.3.



Hình 1.3. Lưu đồ mạng BiLSTM

- **Mạng GRU**

Do cấu trúc phức tạp của mạng LSTM, quá trình huấn luyện để phát triển các mạng LSTM thường tiêu tốn nhiều thời gian. Để quá trình huấn luyện được nhanh hơn, các mạng GRU đã được đề xuất như một sửa đổi của các mạng LSTM với cấu trúc đơn giản hơn [80, 81].

Cấu trúc chi tiết của tế bào GRU (Hình 1.4) với trạng thái ẩn h_t và trạng thái tế bào d_t được hợp nhất thành một. Mạng GRU có hai cổng điều khiển: cổng cập nhật W_t và cổng đặt lại s_t . Cổng cập nhật W_t kiểm soát mức độ thông tin trạng thái h_{t-1} từ bước thời gian trước ($t-1$) được mang vào bước thời gian hiện tại t . Lượng thông tin từ bước thời gian trước được giữ lại càng nhiều khi cổng cập nhật càng lớn. Cổng đặt lại s_t kiểm soát lượng thông tin từ trạng thái trước được ghi vào bộ ứng viên hiện tại d_t . Cổng đặt lại càng nhỏ thì lượng thông tin từ trạng thái trước được ghi vào càng ít.

Trong cấu trúc của mạng GRU, các phương trình cập nhật được biểu diễn bằng các công thức sau:

$$s_t = \sigma(V_{xs}x_t + V_{hs}h_{t-1} + a_s) \quad (1.20)$$


$$w_t = \sigma(V_{xw}x_t + V_{hw}h_{t-1} + a_w) \quad (1.21)$$

$$\hat{d}_t = \tanh(V_{xd}x_t + V_{hd}(s_t \otimes h_{t-1}) + a_d) \quad (1.22)$$

$$d_t = (1 - w_t) \otimes d_{t-1} + w_t \otimes \hat{d}_t \quad (1.23)$$

$$h_t = d_t \quad (1.24)$$

Trong đó, V_{xs} , V_{hs} , V_{xw} và V_{hw} là các ma trận trọng số của mạng. a_s và a_w là các véc-tơ sai số và s_t và W_t là các véc-tơ cho các giá trị kích hoạt của cổng cập nhật và cổng đặt lại.



Hình 1.4. Lưu đồ mạng GRU

1.6. Các kỹ thuật và mô hình xử lý ảnh cho bài toán dự báo mực nước hồ

• Thuật toán HOG

Histogram of Oriented Gradients (HOG)[82, 83] là một trong những phương pháp phổ biến để trích xuất đặc trưng hình ảnh, đặc biệt hiệu quả trong việc nhận diện các đối tượng như con người hoặc các vật thể có biên rõ ràng trong ảnh. Nguyên lý cơ bản của HOG dựa trên việc mô tả các cạnh và hướng gradient trong vùng cục bộ của hình ảnh, từ đó biểu diễn hình dạng của đối tượng thông qua một tập hợp các histogram có hướng.

Quy trình trích xuất đặc trưng HOG có thể được tóm tắt thành ba bước chính như sau:

Bước 1: Tính Gradient. Ở bước này, Gradient theo phương ngang G_u và Gradient theo phương dọc G_v của các điểm ảnh trong một vùng không gian nhỏ gọi là *cell* được xác định. Gọi $I(u,v)$ là giá trị cường độ sáng tại vị trí điểm ảnh (u,v) , các gradient tại (u,v) được tính toán như sau:

$$G_u(u, v) = I(u + 1, v) - I(u - 1, v) \quad (1.25)$$

$$G_v(u, v) = I(u, v + 1) - I(u, v - 1) \quad (1.26)$$

Độ lớn gradient $N(u,v)$ và hướng gradient $\theta(u,v)$ được định nghĩa như sau:

$$N(u, v) = \sqrt{G_u(u, v)^2 + G_v(u, v)^2} \quad (1.27)$$

$$\theta(u, v) = \arctan \left(\frac{G_v(u, v)}{G_u(u, v)} \right) \quad (1.28)$$


Trong đó (u, v) là tọa độ điểm ảnh, với u biểu thị cột (trục ngang) và v biểu thị hàng (trục dọc).

Bước 2: Ánh xạ hướng gradient. Để xây dựng histogram, cường độ gradient của từng điểm ảnh trong cell được phân bổ vào các bin hướng thích hợp dựa trên hướng gradient của nó.

Bước 3: Chuẩn hóa và mã hóa đặc trưng. Ở giai đoạn này, các histogram của cell được chuẩn hóa trong một cụm cell gọi là *block*. Tất cả các histogram trong cửa sổ phát hiện sau đó được kết hợp để tạo thành véc-tơ mô tả đặc trưng HOG hoàn chỉnh.

- **Mạng VGG19**

VGG-19 là một mạng nơ-ron tích chập sâu, được phát triển bởi nhóm nghiên cứu tại Visual Geometry Group (VGG), Đại học Oxford [84]. Mạng VGG-19 là một phiên bản mở rộng của VGG-16 với tổng cộng 19 lớp, bao gồm 16 lớp tích chập và 3 lớp kết nối đầy đủ (fully connected layers). Sơ đồ mạng VGG19 chi tiết được trình bày tại Hình 1.5.




Hình 1.5. Sơ đồ mạng VGG19

Mạng này được sử dụng rộng rãi trong các bài toán phân loại hình ảnh, nhận dạng đối tượng và trích xuất đặc trưng, nhờ vào kiến trúc đơn giản nhưng hiệu quả trong việc học đặc trưng từ hình ảnh.

Cấu trúc của mạng VGG19, có kiến trúc sâu với nhiều lớp tích chập và max-pooling được xếp chồng lên nhau. Cấu trúc chi tiết bao gồm:

Khối 1 gồm 2 lớp tích chập với 64 kênh và 1 lớp max-pooling. Khối 2 gồm 2 lớp tích chập với 128 kênh và 1 lớp max-pooling. Khối 3 gồm 4 lớp tích chập với 256 kênh và 1 lớp max-pooling. Khối 4 gồm 4 lớp tích chập với 512 kênh và 1 lớp max-pooling. Khối 5 gồm 4 lớp tích chập với 512 kênh và 1 lớp max-pooling. Và cuối cùng là lớp kết nối đầy đủ gồm 2 lớp 4096 nơ-ron, 1 lớp 1000 nơ-ron (cho phân loại 1000 lớp của ImageNet) và 1 lớp softmax để xuất đầu ra. Các lớp tích chập đều sử dụng bộ lọc 3x3, stride = 1 và hàm kích hoạt ReLU. Các lớp max-pooling có kích thước 2x2, stride = 2.

- **Mạng C3 Swin Transformer (C3STR)**



Hình 1.6. Kiến trúc mô hình C3STR

Hình 1.6 minh họa mô-đun C3STR [85] bao gồm một lớp C3 đơn, hai lớp Layer Normalization (LN), một lớp Winner-Takes-All (WTA), một lớp MLP, và hai cấu trúc kết nối dư. Trước hết, mô-đun C3 thực hiện phép tích chập để

hợp nhất các đặc trưng của bao thần kinh thị và chuẩn hóa bản đồ đặc trưng bằng LayerNorm. Tiếp theo, mô-đun WTA kết hợp cơ chế chú ý theo cửa sổ (Window-based Multi-Head Self-Attention – W-MSA) với chú ý cửa sổ dịch chuyển (Shifted Window Multi-Head Self-Attention – SW-MSA).

Như thể hiện trong *Hình 1.6*, cơ chế W-MSA chia đầu vào thành các cửa sổ cục bộ và thực hiện tính toán tự chú ý trong từng cửa sổ nhằm tăng cường tương tác giữa thông tin cục bộ và toàn cục. Tuy nhiên, việc chỉ sử dụng W-MSA đôi khi không nắm bắt được đầy đủ các đặc trưng toàn cục của bao thần kinh thị trong ảnh siêu âm nhãn cầu do giới hạn về kích thước cửa sổ. Vì vậy, SW-MSA được đưa vào, trong đó các cửa sổ được dịch chuyển một khoảng cố định ở mỗi lớp, giúp mô hình hiểu tốt hơn toàn bộ ảnh siêu âm nhãn cầu và trích xuất hiệu quả hơn các đặc trưng toàn cục của bao thần kinh thị.

Sau đó, mô-đun MLP sử dụng các lớp kết nối đầy đủ để điều chỉnh và tái tổ chức các đặc trưng đã được tương tác thông qua mô-đun WTA, qua đó giúp mô hình khai thác tốt hơn các đặc trưng thu được từ cơ chế chú ý. Cuối cùng, các đặc trưng của bao thần kinh thị sau khi được xử lý qua kết nối dư thứ nhất được kết hợp với các đặc trưng trích xuất bởi mô-đun MLP thông qua kết nối dư thứ hai, từ đó làm tăng độ sâu của mạng.

1.7. Chỉ số đánh giá mô hình dự báo và phân tích ANOVA hai chiều

Việc chỉ sử dụng một chỉ số thống kê đơn lẻ thường không đủ để phản ánh toàn diện hiệu quả của các mô hình dự báo thủy văn. Do đó, luận án kết hợp nhiều chỉ số đánh giá, bao gồm sai số tuyệt đối trung bình (MAE), sai số bình phương trung bình (MSE), căn bậc hai sai số bình phương trung bình (RMSE) và Tracking Signal để kiểm định độ chính xác và độ tin cậy của mô hình. Bên cạnh đó, nghiên cứu còn áp dụng phân tích phương sai hai chiều (Two-way ANOVA) [86, 87] nhằm đánh giá sự khác biệt có ý nghĩa thống kê giữa các mô hình dự báo, qua đó cung cấp cái nhìn sâu hơn về hiệu năng của mô hình đề xuất.

Độ đo MAE, MSE và RMSE

Các công thức toán học của MAE, MSE và RMSE được trình bày trong các phương trình (1.29)-(1.31) dưới đây.

$$MAE = \frac{1}{n} \sum_{i=1}^n |D_i - \hat{D}_i| \quad (1.29)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (D_i - \hat{D}_i)^2 \quad (1.30)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (D_i - \hat{D}_i)^2} \quad (1.31)$$

Trong đó: n là số lượng điểm dữ liệu; D_i là giá trị thực tại điểm dữ liệu thứ i ; và $\hat{D}_i$ là giá trị dự báo tại điểm dữ liệu thứ i .

Chỉ số Tracking Signal (TS)

Chỉ số Tracking Signal để đánh giá mức độ sai lệch giữa giá trị dự báo và giá trị thực theo chuỗi thời gian [88]. Chỉ số này thường được dùng để phát hiện các bất thường hoặc xu hướng lệch trong dự báo. Công thức tính Tracking Signal được trình bày như sau:

$$TS = \frac{\sum_{i=1}^n (D_i - \hat{D}_i)}{MAD} \quad (1.32)$$

Trong đó: n là số lượng điểm dữ liệu; D_i là giá trị thực tại điểm dữ liệu thứ i ; và $\hat{D}_i$ là giá trị dự báo tại điểm dữ liệu thứ i . MAD (Mean Absolute Deviation) là sai số tuyệt đối trung bình được tính bởi công thức:

$$MAD = \frac{1}{n} \sum_{i=1}^n |D_i - \hat{D}_i| \quad (1.33)$$

Khi giá trị Tracking Signal tiến gần về 0, điều đó cho thấy mô hình dự báo hoạt động ổn định và không xuất hiện sai lệch đáng kể. Nếu Tracking Signal nằm trong khoảng $[-4, 4]$, mô hình dự báo được xem là đáng tin cậy; ngược lại, nếu vượt ra ngoài ngưỡng này, độ tin cậy của mô hình giảm xuống. Trong trường hợp chỉ số này đạt giá trị lớn (dương hoặc âm), điều đó có thể cho thấy mô hình dự báo đang gặp vấn đề và cần được hiệu chỉnh lại.

Phân tích ANOVA hai chiều

Phân tích phương sai hai chiều (Two-way ANOVA) là một kỹ thuật thống kê dùng để đánh giá đồng thời ảnh hưởng của hai biến độc lập mang tính phân loại lên một biến phản hồi dạng liên tục. Phương pháp này cho phép xem xét không chỉ tác động riêng của từng nhân tố mà còn kiểm tra xem liệu sự kết hợp giữa hai nhân tố đó có tạo ra hiệu ứng tương tác đối với biến kết quả hay không.

1.8. Kết luận chương

Qua quá trình nghiên cứu tổng quan, luận án nhận thấy các phương pháp truyền thống gồm mô hình thủy văn – thủy lực dựa trên cơ sở vật lý như MIKE 11, HEC-RAS có ưu điểm trong mô phỏng cơ chế dòng chảy và vận hành hồ chứa, tuy nhiên thường yêu cầu số lượng lớn tham số đầu vào, chi phí tính toán cao và phụ thuộc đáng kể vào chất lượng số liệu quan trắc. Trong khi đó, các mô hình chuỗi thời gian như ARIMA, SARIMA chủ yếu khai thác xu thế và tính mùa vụ, nên còn hạn chế trong việc biểu diễn các quan hệ phi tuyến và các biến động bất thường của mực nước hồ. Các phương pháp học máy truyền thống như SVM, SVR có khả năng xử lý phi tuyến tốt hơn, nhưng vẫn gặp khó khăn trong việc học đặc trưng sâu và mô hình hóa phụ thuộc thời gian dài hạn.

Sự phát triển mạnh mẽ của các mô hình học sâu đã mở ra hướng tiếp cận mới cho bài toán dự báo mực nước hồ. Các kiến trúc mạng học sâu như RNN, LSTM, GRU, BiLSTM cho thấy hiệu quả cao trong xử lý dữ liệu chuỗi thời gian, đặc biệt trong việc học các quan hệ ngắn hạn và dài hạn của quá trình thủy văn. Tuy nhiên, nếu chỉ sử dụng dữ liệu vận hành hồ chứa thì các mô hình này vẫn chưa tận dụng được nguồn thông tin không gian quan trọng phản ánh trạng thái thực của hồ như diện tích mặt nước, hình thái hồ và biến động vùng ngập theo thời gian. Vì vậy, việc tích hợp thêm dữ liệu ảnh vệ tinh vào mô hình dự báo là hướng đi cần thiết nhằm nâng cao độ chính xác và khả năng thích ứng của hệ thống dự báo.

Để khai thác hiệu quả nguồn dữ liệu này, cần áp dụng các kỹ thuật trích xuất đặc trưng ảnh như HOG, CNN, VGG19, U-Net và các biến thể hiện đại. Các phương pháp này cho phép nhận dạng và biểu diễn hiệu quả các thông tin không gian như ranh giới mặt nước, diện tích hồ, đặc trưng hình thái và sự thay đổi theo thời gian.

Từ những phân tích trên có thể thấy rằng, thách thức cốt lõi không chỉ nằm ở việc sử dụng thêm dữ liệu ảnh vệ tinh, mà còn ở cơ chế hợp nhất tối ưu giữa dữ liệu ảnh và dữ liệu vận hành hồ chứa để tạo ra mô hình dự báo chính xác, ổn định và có khả năng ứng dụng thực tiễn. Xuất phát từ yêu cầu đó, Chương 2 của luận án sẽ tập trung đề xuất mô hình dự báo mực nước hồ đa mô thức kết hợp đặc trưng ảnh vệ tinh với chuỗi mực nước hồ nhằm nâng cao hiệu quả dự báo. Những kiến thức trong Chương 1 sẽ là nền tảng để xây dựng các mô hình dự báo mới trong Chương 2 của luận án.

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

2.1. Mở đầu

Bài toán dự báo mực nước hồ 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, $X \subseteq R^{T \times d}$ biểu diễn tập dữ liệu chuỗi thời gian đa biến gồm T bước thời gian với d đặc trưng, $S \subseteq R^{H \times W \times C}$ 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.

Các phương pháp dự báo mực nước hồ truyền thống chủ yếu dựa trên các mô hình thuần thời gian, bỏ qua bối cảnh không gian, hoặc sử dụng các biểu diễn thời gian đơn giản, không đủ khả năng phản ánh chi tiết các đặc trưng hình thái của hồ chứa. Thách thức cốt lõi nằm ở tính không đồng nhất của các dữ liệu đầu vào: trong khi các phép đo thủy văn theo thời gian thể hiện các quy luật mùa vụ phức tạp và các phụ thuộc phi tuyến, thì dữ liệu ảnh vệ tinh lại cung cấp thông tin hình thái phong phú về bề mặt hồ chứa, thảm phủ thực vật xung quanh và các kiểu sử dụng đất, những yếu tố có ảnh hưởng trực tiếp đến các quá trình thủy văn. Các phương pháp hiện có vẫn gặp khó khăn trong việc tích hợp hiệu quả các nguồn thông tin bổ trợ này, đồng thời duy trì độ chính xác dự báo mực nước hồ ổn định trên các khoảng thời gian dự báo khác nhau.

Trong những năm gần đây, các mô hình dự báo đa mô thức hợp nhất ảnh vệ tinh với dữ liệu phi ảnh đã trở thành xu hướng nổi bật trong lĩnh vực công nghệ thông tin và thủy văn [89 - 94]. Nhiều nghiên cứu đã chứng minh hiệu quả của cách tiếp cận này. Năm 2021, Jiang và cộng sự [89] đã áp dụng phương pháp hợp nhất dữ liệu đa mô thức để dự báo mực nước trong mạng lưới cống thoát nước đô thị.

Năm 2022, Bai và cộng sự [90] đề xuất MANET (Multimodal Auxiliary Network), một mô hình học sâu kết hợp đặc trưng ảnh trích xuất bằng CNN với thông tin khí tượng thông qua lớp hợp nhất dựa trên MLP, giúp cải thiện đáng kể độ chính xác trong phân loại mây và hệ thống thời tiết. Năm 2022, Ahmed và cộng sự [91] đã đề xuất một phương pháp học sâu kết hợp lượng mưa và

mực nước sông để dự báo mực nước sông. Rowley và Karakuş (2023) [92] xây dựng một khung AI đa mô thức cho dự báo chất lượng không khí, hợp nhất ảnh vệ tinh (NDVI, AOD, RGB) với dữ liệu khí tượng và kinh tế - xã hội, trong đó chiến lược hợp nhất sớm cho hiệu quả cao nhất. Năm 2023, Burrichter và cộng sự [93] đã phát triển một mô hình học sâu không gian - thời gian sử dụng dữ liệu thời tiết và địa hình để dự báo ngập lụt đô thị. Năm 2025, Chacón-Maldonado và cộng sự [94] kết hợp ảnh Sentinel-2 với dữ liệu khí tượng, sử dụng CNN để trích xuất đặc trưng không gian và huấn luyện các mô hình học máy như Random Forest, XGBoost và DNN, trong đó mô hình CNN + Random Forest cho kết quả tốt nhất.

Những kết quả này nhấn mạnh tầm quan trọng của việc hợp nhất các loại dữ liệu khác nhau nhằm nâng cao độ chính xác trong dự báo và hỗ trợ ra quyết định trong lĩnh vực thủy văn và quản lý rủi ro.

Trên cơ sở phân tích các đặc điểm của bài toán dự báo mực nước hồ 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.

Cụ thể, mô hình HOG-GRU [CT1] sử dụng thuật toán Histogram of Oriented Gradients (HOG) để trích xuất đặc trưng không gian từ ảnh vệ tinh. So với các mô hình học sâu thuần túy, HOG có chi phí tính toán thấp hơn, giúp mô hình đạt hiệu quả cao về tài nguyên và thời gian xử lý. Bên cạnh đó, luận án đề xuất một hàm hợp nhất mới giữa đặc trưng ảnh và đặc trưng dữ liệu vận hành hồ, trong đó thông tin không gian từ ảnh vệ tinh được tích hợp theo cách làm nổi bật các trạng thái bất thường trong chuỗi dữ liệu mực nước. Nhờ vậy,

khi đưa vào mô hình GRU để học quan hệ theo thời gian, khả năng dự báo tại các thời điểm xuất hiện biến động bất thường được cải thiện rõ rệt so với các phương pháp trước đây.

Song song với đó, luận án đề xuất mô hình Colubrid-Net [CT2], một kiến trúc học sâu đa mô thức thống nhất nhằm nâng cao độ chính xác dự báo mực nước hồ thông qua việc khai thác hiệu quả các phụ thuộc không gian – thời gian. Mô hình này sử dụng kiến trúc trích xuất đặc trưng ảnh tiên tiến để học các đặc trưng không gian 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, nghiên cứu đề xuất một cơ chế nội suy 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.

Trong các phần sau, luận án sẽ trình bày chi tiết hai đề xuất. Các kết quả nghiên cứu trong chương này đã 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 mực nước hồ đa mô thức HOG-GRU

Trong phần này, luận án đề xuất mô hình dự báo mực nước hồ HOG-GRU, được xây dựng trên cơ sở kết hợp giữa kỹ thuật trích xuất đặc trưng ảnh hiệu quả và mô hình học sâu mạnh cho dữ liệu chuỗi thời gian. Việc lựa chọn hai thành phần HOG và GRU được cân nhắc dựa trên đặc điểm của bài toán dự báo mực nước hồ, nơi cần đồng thời khai thác thông tin không gian từ ảnh vệ tinh và động lực thời gian từ số liệu quan trắc.


Đối với dữ liệu ảnh vệ tinh, luận án lựa chọn thuật toán HOG để trích xuất đặc trưng. HOG có ưu điểm nổi bật là biểu diễn đối tượng thông qua phân bố hướng gradient cục bộ, nhờ đó làm nổi bật các cấu trúc hình học quan trọng như ranh giới mặt nước, đường bờ hồ, hình dạng hồ chứa và biến động diện tích mặt nước, đồng thời giảm ảnh hưởng của các thông tin ít liên quan như màu sắc hoặc nhiễu nền. Về nguyên lý, ảnh đầu vào được chia thành nhiều vùng nhỏ, tại mỗi vùng HOG tính toán histogram hướng gradient, sau đó tổng hợp thành véc-tơ đặc trưng toàn cục đại diện cho trạng thái hồ chứa. So với các mạng CNN và các mạng học sâu khác, HOG có ưu điểm là chi phí tính toán thấp, không yêu cầu huấn luyện lớn, thời gian xử lý nhanh và phù hợp với tập

dữ liệu ảnh vệ tinh có số lượng hạn chế, rất phù hợp với điều kiện thực tế của bài toán nghiên cứu.

Đối với dữ liệu chuỗi thời gian, luận án lựa chọn mạng GRU vì đây là kiến trúc học sâu được thiết kế chuyên biệt cho dữ liệu tuần tự. GRU sử dụng các cơ chế cổng cập nhật và cổng đặt lại để lựa chọn thông tin cần ghi nhớ hoặc loại bỏ, từ đó mô hình hóa hiệu quả các phụ thuộc ngắn hạn và dài hạn trong chuỗi mực nước hồ. So với LSTM, GRU có cấu trúc gọn hơn, số lượng tham số ít hơn nên huấn luyện nhanh hơn, giảm nguy cơ quá khớp và vẫn duy trì khả năng dự báo chính xác. Điều này đặc biệt phù hợp với dữ liệu thủy văn có tính mùa vụ, xu thế dài hạn và thường xuất hiện các dao động bất thường.

2.2.1. Mô hình dự báo

Mô hình dự báo đề xuất được minh họa trong *Hình 2.1* sử dụng đồng thời ảnh vệ tinh Sentinel-2 và dữ liệu quan trắc thủy văn của hồ An Khê tại các thời điểm khác nhau làm đầu vào. Cả hai nguồn dữ liệu đều trải qua quy trình tiền xử lý nhằm đảm bảo tính nhất quán và khả năng hợp nhất trong một khung dự báo thống nhất.



Hình 2.1. Khung dự báo đề xuất HOG-GRU

Đối với dữ liệu ảnh vệ tinh, ảnh sau tiền xử lý được chuyển đổi thành mặt nạ đối tượng nhằm tách riêng vùng mặt nước của hồ. Các mặt nạ này tiếp tục được chuẩn hóa về kích thước 320×320 pixel và đưa vào mô hình trích xuất đặc trưng HOG. Phương pháp HOG tạo ra véc-tơ đặc trưng mô tả cấu trúc và dạng hình học của vùng hồ; véc-tơ này được chuẩn hóa bằng L2 norm để thu được biểu diễn đặc trưng ảnh cuối cùng.

Đối với dữ liệu mực nước hồ, chuỗi thời gian được tái lấy mẫu theo ngày nhằm tăng tính đồng nhất và giảm nhiễu, chuẩn hóa về khoảng giá trị $[0, 1]$. Sau khi xây dựng được véc-tơ đặc trưng ảnh, mô hình thực hiện ánh xạ không gian để liên kết không gian đặc trưng ảnh với không gian của dữ liệu thủy văn. Hai véc-tơ đặc trưng thu được sau đó được kết hợp bằng phép nối theo chiều ngang, tạo thành tập biến ngoại sinh phục vụ cho quá trình học mô hình.

Toàn bộ các biến ngoại sinh cùng chuỗi thời gian mực nước hồ tiếp theo được chuẩn hóa về miền $[0, 1]$ để đáp ứng yêu cầu đầu vào của mạng nơ-ron GRU. Mạng GRU được huấn luyện đồng thời trên chuỗi thời gian mực nước hồ và các biến ngoại sinh, từ đó dự báo mực nước hồ tiếp theo.

2.2.2. Xử lý dữ liệu

Trong phần này, luận án sẽ trình bày chi tiết quy trình tiền xử lý được áp dụng riêng cho tập dữ liệu hình ảnh và tập dữ liệu chuỗi thời gian, nhằm đảm bảo hai nguồn dữ liệu đạt yêu cầu về chất lượng và khả năng hợp nhất trước khi đưa vào mô hình dự báo HOG-GRU.

Quy trình tiền xử lý cho tập dữ liệu hình ảnh

Ảnh khu vực hồ An Khê được thu thập và gán nhãn theo Mục 3.2 - Chương 3, thời gian thu thập từ 1/1/2019 đến 31/12/2022. Kết quả quy trình đó thu được tập dữ liệu 18 ảnh Sentinel-2 và đã tiến hành gán nhãn 18 ảnh này, với các điểm ranh giới, được coi là mặt nạ, để xây dựng một chu vi xung quanh các đối tượng mục tiêu. Các nhãn được gán được lưu trữ dưới dạng tệp.txt. Việc gán giá trị pixel là 0 cho đối tượng và 255 cho nền là một thực hành phổ biến trong các tác vụ phân loại cấp độ pixel (phân đoạn).

Chuyển đổi ảnh sang mức xám là một phương pháp hợp lý trong bối cảnh này. Vì ảnh mặt nạ chỉ chứa hai giá trị pixel (0 và 255), việc chuyển sang mức xám (một kênh duy nhất với giá trị từ 0 đến 255) giúp giảm độ phức tạp của dữ liệu mà không làm mất các đặc trưng quan trọng. Cách tiếp cận này mang tính

logic và làm rõ lý do sử dụng ảnh mức xám để đơn giản hóa quá trình huấn luyện, đồng thời vẫn bảo toàn thông tin cần thiết.



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

Những hình ảnh mặt nạ này được chuyển đổi sang ảnh mức xám, minh họa *Hình 2.2*. Tiếp theo, tất cả các ảnh được điều chỉnh về kích thước đồng nhất 320x320x1. Bộ ước lượng Sai số Bình phương Trung bình Nhỏ nhất (MMSE) được áp dụng để khôi phục chất lượng ảnh và giảm nhiễu nhằm tăng độ rõ nét. Ngoài ra, nội suy đa điểm được thực hiện để bổ sung dữ liệu bị thiếu. Quá trình này nhằm đảm bảo rằng mỗi tháng trong năm có một ảnh đại diện. Các bước chính của quy trình này bao gồm:

- **Bước 1:** Thực hiện phân tích thống kê số lượng hình ảnh cho mỗi tháng để xác định những tháng bị thiếu trong mỗi năm.
- **Bước 2:** Nội suy được áp dụng dựa trên hệ số tương quan Pearson. Trong bước này, hình ảnh hàng tháng từ những năm trước được sử dụng để nội suy cho tháng còn thiếu của năm hiện tại.

Đầu ra của phép nội suy bao gồm 30 hình ảnh mặt nạ hồ cho các tháng trước đó bị thiếu. Sau khi nội suy, tổng số hình ảnh mặt nạ là 48. Để làm mịn dữ liệu, tất cả các hình ảnh này sẽ được đưa qua bộ lọc, cùng với lập chỉ mục thời gian tương ứng cho từng tháng trong năm trên hình ảnh. MinMax tỷ lệ được áp dụng như chuẩn hóa dữ liệu bằng cách sử dụng các thư viện trong ngôn ngữ lập trình Python.

Tương tự quy trình xử lý đối với hồ An Khê, tập ảnh gốc Sentinel-2 của hồ Ka Nak sau tiền xử lý và nội suy đã được mở rộng từ 32 ảnh gốc lên tổng cộng 48 ảnh, nhằm tăng cường mật độ thông tin theo thời gian và cải thiện tính liên tục của chuỗi dữ liệu phục vụ huấn luyện mô hình.

Quy trình tiền xử lý cho tập dữ liệu thời gian

Dữ liệu chuỗi thời gian thủy văn cho hồ được thu thập từ ngày 1/1/2019 đến ngày 31/12/2022. Dữ liệu được thu thập theo giờ. Sau khi tính trung bình các trường dữ liệu theo ngày, tập dữ liệu này bao gồm 1.461 mẫu được lập chỉ mục tuần tự theo ngày.

Trong trường hợp của khu vực An Khê, mùa lũ có thể tác động đáng kể đến mực nước của hồ. Mùa lũ thường kéo dài từ tháng 5 đến tháng 10 hàng năm, trong khi những tháng còn lại thường được coi là mùa khô. Do đó, dữ liệu trong mùa lũ thể hiện các đặc điểm khác nhau so với dữ liệu ngoài mùa lũ. Nếu dữ liệu đầu vào không phân biệt giữa các mùa (lũ hoặc khô), mô hình có thể gặp khó khăn trong việc dự báo chính xác mực nước hồ, vì các yếu tố này có thể có tác động khác nhau phụ thuộc vào mùa.

2.2.3. Trích xuất đặc trưng ảnh và xử lý nhiễu


Trong nghiên cứu này, phương pháp HOG được áp dụng cho ảnh vệ tinh Sentinel-2 nhờ khả năng trích xuất hiệu quả các đặc trưng biên và hình dạng, giúp làm nổi bật ranh giới đối tượng đồng thời giảm chiều dữ liệu mà vẫn bảo toàn thông tin quan trọng. So với các phương pháp học sâu, HOG có ưu điểm là đơn giản hơn, ít tốn tài nguyên tính toán, dễ diễn giải, hoạt động ổn định với tập dữ liệu hạn chế và tạo ra các đặc trưng gọn nhẹ - phù hợp với các mô hình dự báo truyền thống [52, 53]. Sơ đồ nguyên lý của thuật toán HOG được minh họa trong *Hình 2.3*.

Đầu vào của thuật toán HOG là ảnh mặt nạ hồ đã được chuẩn hóa, trong đó giá trị cường độ điểm ảnh được điều chỉnh về khoảng $[0, 1]$. Sau khi áp dụng HOG, kết quả thu được là một véc-tơ đặc trưng biểu diễn hình thái học của vùng mặt nước tương ứng trong ảnh mặt nạ.

Thuật toán HOG được thiết lập với các tham số cấu hình sau nhằm trích xuất đặc trưng hình dạng từ ảnh nhị phân của hồ:

1. Orientations = 9: xác định số lượng bin hướng gradient trên mỗi ô, qua đó quy định độ phân giải góc của biểu đồ gradient.

2. Pixels per cell = (8, 8): mỗi ô được chia thành các vùng con kích thước 8×8 pixel, giúp trích xuất các đặc trưng cục bộ.
3. Cells per block = (2, 2): mỗi block bao gồm 2×2 ô, cho phép chuẩn hóa đặc trưng nhằm tăng độ ổn định trước các thay đổi về ánh sáng và độ tương phản.



Hình 2.3. Sơ đồ thuật toán HOG

Sau khi thuật toán HOG được áp dụng, mỗi đối tượng ảnh sẽ được gán một véc-tơ đặc trưng HOG, trong đó độ dài véc-tơ đặc trưng phụ thuộc vào kích thước ảnh đầu vào. Để chuẩn hóa và đánh giá mức độ nổi bật tổng thể của đặc trưng, chuẩn hóa L2 được sử dụng theo công thức sau:

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

Trong đó: v_i là giá trị của từng phần tử trong véc-tơ đặc trưng HOG, g_t 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.

Phép chuẩn hóa này giúp tăng tính ổn định và độ tin cậy của véc-tơ đặc trưng khi được sử dụng trong các mô hình học sâu hoặc thuật toán phân tích ảnh tiếp theo.

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

Trước khi hợp nhất dữ liệu mực nước hồ với các đặc trưng được trích xuất từ ảnh vệ tinh, các giá trị đặc trưng ảnh - vốn đã được chuẩn hóa bằng chuẩn L2 norm - được chuẩn hóa lại bằng phương pháp Min-Max để đưa về cùng miền giá trị với dữ liệu mực nước. Việc đưa cả hai tập dữ liệu về cùng một thang đo giúp đảm bảo tính tương thích và đồng nhất giữa hai loại dữ liệu. Quá trình chuẩn hóa này không chỉ tăng tốc độ hội tụ của mô hình mà còn cải thiện tính ổn định trong giai đoạn huấn luyện mô hình.

Trong bước tiếp theo, một thuật toán hợp nhất đặc trưng được áp dụng nhằm khuếch đại các giá trị bất thường trong chuỗi dữ liệu mực nước hồ. Hàm $P(y_t, f_t)$ được xác định dựa trên các yếu tố sau:

1. Các giá trị đặc trưng ảnh được kết hợp với chuỗi thời gian mực nước hồ để nhấn mạnh các điểm dữ liệu thể hiện dao động bất thường.
2. Nhằm nâng cao khả năng phát hiện các mẫu bất thường trong chuỗi dữ liệu, chuỗi gốc được mở rộng thành ba miền thống kê riêng biệt: giá trị cực đại (max), trung bình (mean) và cực tiểu (min). Trước hết, khoảng tin cậy 99.9% được tính toán từ bộ dữ liệu gốc để xác định khuynh hướng trung tâm, trong đó các điểm dữ liệu nằm trong khoảng này được phân loại vào miền “mean”. Hai miền “max” và “min” sau đó được xác định bằng cách mở rộng hoặc thu hẹp ranh giới của khoảng tin cậy, từ đó nhấn mạnh các sai lệch và tăng độ nhạy trong phát hiện dị thường.

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

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

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 hồ 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 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 công thức (2.4) và (2.5):

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

$$b = \mu + \frac{\sigma}{\sqrt{N}} * \alpha \quad (2.5)$$

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 hồ. Trong nghiên cứu này, $\alpha = 3.291$, tương ứng với mức tin cậy 99.9% [95]. 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.

Trong đó, hàm $P(y_t, f_t)$ hội tụ theo từng biến giữa hai biến y_t và f_t trên đoạn $[0, 1]$. Hàm $S(x)$ là hàm hội tụ trên đoạn $[0, 1]$.

Ví dụ 1: Giả sử dữ liệu ban đầu gồm $N = 1.000$ mẫu. Giá trị mực nước hồ y_t nằm trong khoảng $[414, 456]$ và đặc trưng ảnh F_t nằm trong khoảng $[0.45, 0.55]$. Áp dụng công thức $P(y_t, f_t)$ theo các bước sau: chuẩn hóa giá trị F_t về cùng miền giá trị với y_t để thu được f_t , sau đó tính các giá trị a, b và μ theo y_t . Chi tiết các bước tính toán được trình bày như sau:

Bước 1: Tính các giá trị a, b và μ dựa trên chuỗi dữ liệu y_t thu được: $\mu = \text{mean}(Y) = 435$, $\sigma = \text{std}(Y) = 12.124$, $N = 1.000$, $\alpha = 3.291$ và các giới hạn trên và dưới được xác định theo công thức sau:

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

Thay các giá trị tham số vào, ta thu được các giá trị a và b như sau:

$$a \square 433.74, \quad b \square 436.26$$

Bước 2: Chuẩn hóa giá trị F_t với $F_{\min} = 0.45$ và $F_{\max} = 0.55$ sang miền giá trị của y_t với $y_{\min} = 414$ và $y_{\max} = 456$. Kết quả, giá trị chuẩn hóa của F_t là f_t được tính theo công thức:

$$f_t = y_{\min} + \frac{F_t - F_{\min}}{F_{\max} - F_{\min}} (y_{\max} - y_{\min}) \quad (2.6)$$

Với $F_t = [0.45, 0.46, 0.48, 0.49, 0.50, 0.52, 0.53, 0.54, 0.55, 0.51]$ khi đó thu được:

$$f_t = [414.0, 418.2, 426.6, 430.8, 435.0, 443.4, 447.6, 451.8, 456.0, 439.2]$$

Bước 3: Áp dụng công thức $P(y_t, f_t)$, để tính toán, kết quả trung gian được thể hiện trong Bảng 2.1.

Bảng 2.1. Tóm tắt các giá trị tính toán trong Ví dụ 1

y_t	F_t	f_t	$x_1 = y_t - a$	$S(x_1)$	$x_2 = y_t - b$	$S(x_2)$	$P(y_t, f_t)$
414.0	0.45	414.0	-19.74	0.00	-22.26	0.00	413.00
433.5	0.46	418.2	-0.24	0.00	-2.76	0.00	432.50
434.1	0.48	426.6	0.36	0.29	-2.16	0.00	433.65
434.5	0.49	430.8	0.76	0.85	-1.76	0.00	434.78
435.0	0.50	435.0	1.26	1.00	-1.26	0.00	435.00
436.0	0.52	443.4	2.26	1.00	-0.26	0.00	436.00
436.5	0.53	447.6	2.76	1.00	0.24	0.15	435.37
437.0	0.54	451.8	3.26	1.00	0.74	0.83	437.46
445.0	0.55	456.0	11.26	1.00	8.74	1.00	445.95
456.0	0.51	439.2	22.26	1.00	19.74	1.00	456.99

2.2.5. Triển khai và huấn luyện mạng GRU

Trước khi huấn luyện mạng GRU, cả dữ liệu mực nước hồ và đầu ra thu được từ hàm hợp nhất $P(y_t, f_t)$ đều được chuẩn hóa bằng phương pháp Min-Max về khoảng $[0, 1]$. Bước tiền xử lý này tạo ra một bộ dữ liệu mới gồm hai đặc trưng: mực nước hồ đã chuẩn hóa và dữ liệu hợp nhất đã chuẩn hóa, cả hai đều được căn chỉnh trong cùng miền giá trị $[0, 1]$.

Bộ dữ liệu sau khi chuẩn hóa được chia thành ba tập con: huấn luyện, kiểm định và kiểm thử theo tỷ lệ 7:1.5:1.5, tương ứng.

Trong nghiên cứu này, một mô hình học sâu dựa trên kiến trúc GRU được xây dựng và huấn luyện nhằm dự báo mực nước hồ. Mô hình được thiết kế để xử lý chuỗi thời gian đa biến, bao gồm cả dữ liệu mực nước hồ lịch sử và các đặc trưng hợp nhất trích xuất từ ảnh vệ tinh. Dữ liệu đầu vào được cấu trúc theo dạng (time steps, features). Kiến trúc mô hình GRU đề xuất bao gồm các thành phần chính sau:

- Lớp GRU thứ nhất gồm 64 nút (neurons) sử dụng hàm kích hoạt *tanh*. Tham số *return_sequences = True* được bật để lưu toàn bộ chuỗi trạng thái ẩn, giúp lớp kế tiếp có thể học được các quan hệ phụ thuộc theo thời gian sâu hơn.
- Lớp Dropout đầu tiên với tỷ lệ dropout = 30% được thêm vào nhằm giảm hiện tượng overfitting và cải thiện khả năng khái quát hóa của mô hình trên dữ liệu chưa thấy trước đó.
- Lớp GRU thứ hai gồm 32 nút, cũng sử dụng hàm kích hoạt *tanh*. Tuy nhiên, lớp này được cấu hình với *return_sequences = False*, nghĩa là chỉ trả về trạng thái ẩn cuối cùng, đại diện cho toàn bộ chuỗi đầu vào.
- Lớp Dropout thứ hai, cũng với tỷ lệ 30%, được thêm ngay sau lớp GRU thứ hai nhằm tăng độ ổn định và khả năng tổng quát của mô hình.
- Cuối cùng là Lớp đầu ra (Dense layer) là lớp kết nối đầy đủ gồm một neuron duy nhất với hàm kích hoạt *sigmoid*, giúp chuẩn hóa đầu ra về khoảng giá trị $[0, 1]$, tương ứng với mực nước hồ đã chuẩn hóa.

Đầu ra của mô hình là một giá trị duy nhất, biểu thị mực nước hồ dự báo cho bước thời gian tiếp theo.

Mô hình được biên dịch bằng bộ tối ưu hóa Adam với tốc độ học được thiết lập là $1e-3$. Hàm mất mát được sử dụng là Mean Squared Error (MSE), phù hợp cho các bài toán hồi quy. Trong quá trình huấn luyện, mô hình được đào tạo trên tập dữ liệu huấn luyện (training dataset) và đánh giá hiệu năng trên tập dữ liệu kiểm định (validation set). Số lượng epoch được thiết lập là 300, với kích thước batch size là 32. Bên cạnh đó, cơ chế ModelCheckpoint được áp dụng nhằm lưu lại trọng số tốt nhất của mô hình - tương ứng với giá trị mất mát trên tập kiểm định nhỏ nhất đạt được trong quá trình huấn luyện.

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

2.3.1. Ý tưởng của mô hình đề xuất

- **Ý tưởng:**

Luận án 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 chịu ảnh hưởng 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.

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.

Trong *Hình 2.4*, mô hình sẽ xử lý hai luồng dữ liệu riêng biệt. Dữ liệu chuỗi thời gian sẽ đi qua mạng MTFE trích xuất đặc trưng thời gian, dữ liệu ảnh sẽ đi qua UMSFE trích xuất ra đặc trưng ảnh. Đặc trưng số và đặc trưng ảnh sẽ đi qua mô-đun TF-BiLSTM, tại đây đặc trưng ảnh theo tháng sẽ được nội suy thêm biến mùa vụ, nhiễu để thành đặc trưng ảnh theo ngày của tháng đó. Đặc trưng theo ngày mới này sẽ được hợp nhất với đặc trưng chuỗi thời gian bằng hàm ghép nối. Sau đó giá trị mới này sẽ đi qua mạng BiLSTM để dự báo ra mực nước hồ tiếp theo.

Đóng góp chính của phương pháp nằm ở chiến lược trích xuất đặc trưng đa tỉ lệ, trong đó khai thác đồng thời các biểu diễn từ cả mã hóa (encoder) và giải mã (decoder) của kiến trúc U-Net, cho phép mô hình nắm bắt hiệu quả các mẫu cục bộ chi tiết cũng như bối cảnh toàn cục ở quy mô lớn. Cách tiếp cận này cho phép mô hình nắm bắt song song các mẫu cục bộ chi tiết và bối cảnh toàn cục ở mức độ thô, từ đó nâng cao hiệu quả biểu diễn không gian và cải thiện độ chính xác của bài toán dự báo mực nước hồ.

Mô hình xử lý dữ liệu ảnh vệ tinh thông qua mô-đun UMSFE để trích xuất đặc trưng không gian, đồng thời xử lý dữ liệu chuỗi thời gian bằng MTFE để trích xuất đặc trưng theo thời gian. Mô-đun nội suy theo thời gian được sử dụng để mở rộng các đặc trưng ảnh vệ tinh từ độ phân giải theo tháng lên độ phân giải theo ngày. Sau đó, mô-đun hợp nhất bằng phép nối kết hợp các đặc trưng

đa mô thức, và mạng BiLSTM thực hiện mô hình hóa chuỗi hai chiều nhằm dự báo mực nước, với hàm mất mát MSE được sử dụng trong quá trình tối ưu.



Hình 2.4. Kiến trúc Colubrid-Net


- **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+1} tại thời điểm kế tiếp, dựa trên các quan trắc lịch sử $\{I_{t-\tau+1}, \dots, I_t\}$ và $\{x_{t-\tau+1}, \dots, x_t\}$ trong một cửa sổ hồi quy có kích thước τ .

2.3.2. Kiến trúc UMSFE

1) Mạng C3STR (C3 Swin Transformer)



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.

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:

$$\hat{z}^l = \text{W-MSA} \left(\text{LN}(z^{l-1}) \right) + z^{l-1} \quad (2.7)$$

$$z^l = \text{MLP} \left(\text{LN}(\hat{z}^l) \right) + \hat{z}^l \quad (2.8)$$

$$\hat{z}^{l+1} = \text{SW-MSA} \left(\text{LN}(z^l) \right) + z^l \quad (2.9)$$

$$z^{l+1} = \text{MLP} \left(\text{LN}(\hat{z}^{l+1}) \right) + \hat{z}^{l+1} \quad (2.10)$$

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 các 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.

2) Hàm kích hoạt Snake động

Để tăng cường khả năng mô hình hóa phi tuyến, mô hình 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:

$$\text{Snake}(x) = x + \frac{1}{\alpha} \sin^2(\alpha x) \quad (2.11)$$

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 của mô hình tuân theo chiến lược giảm mẫu phân cấp, được mô tả như sau:

$$e_1 = \text{DoubleConv}(I_t) \quad (2.12)$$

$$e_i = \text{Down}(e_{i-1}), i \in \{2, 3, 4\} \quad (2.13)$$

$$e_5 = \text{DownC3STR}(e_4) \quad (2.14)$$

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:

$$d_1 = \text{Up}(e_5, e_4) \quad (2.15)$$

$$d_i = \text{Up}(d_{i-1}, e_{5-i}), i \in \{2, 3, 4\} \quad (2.16)$$

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:

$$GeM(F) = (1/HW \sum_{i=1}^H \sum_{j=1}^W F_{i,j}^p)^{1/p} \quad (2.17)$$

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:

$$f^{spa} = \text{LayerNorm}(\oplus (\cup_{F \in \mathcal{E} \cup \mathcal{D}} GeM(F))) \quad (2.18)$$

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 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:

$$h_1 = \text{ReLU}(W_1 \tilde{x}_t + b_1) \quad (2.19)$$

$$h_2 = \text{ReLU}(W_2 h_1 + b_2) \quad (2.20)$$

$$h_3 = \text{ReLU}(W_3 h_2 + b_3) \quad (2.21)$$

$$z^{temp} = \text{ReLU}(W_4 h_3 + b_4) \quad (2.22)$$

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 động 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, mô hình 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, mô hình áp dụng các nhiễu loạn mang tính mùa vụ và ngẫu nhiên theo công thức sau:

$$s_d = \alpha_s \sin \left(\frac{2\pi \cdot \text{day_of_year}(d)}{365} \right) \quad (2.23)$$

$$\epsilon_d \sim \mathcal{N}(0, \sigma^2 I) \quad (2.24)$$

$$z_d^{spa} = z_d^{base} + s_d + \epsilon_d \quad (2.25)$$

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.

Cụ thể, giả sử ảnh vệ tinh tháng 7 sau khi trích xuất thu được véc-tơ đặc trưng đã chuẩn hóa là $[0.72, 0.54, 0.33]$. Đối với ngày 05/7, khi bổ sung thành phần mùa vụ $+0.03$ và nhiễu ngẫu nhiên $+0.01$, véc-tơ đặc trưng theo ngày được cập nhật thành $[0.76, 0.58, 0.37]$. Tương tự, tại ngày 20/7, với thành phần mùa vụ $+0.04$ và nhiễu -0.02 , véc-tơ đặc trưng trở thành $[0.74, 0.56, 0.35]$.

Ví dụ này cho thấy, mặc dù cùng xuất phát từ một ảnh đại diện của tháng, đặc trưng không gian ở từng ngày vẫn được điều chỉnh linh hoạt để phản ánh xu thế biến động tự nhiên của hồ chứa theo thời gian. Nhờ đó, dữ liệu đầu vào mang tính động và sát thực tế hơn, khắc phục hạn chế của mô hình HOG-GRU, nơi một ảnh theo tháng được gán cố định cho toàn bộ các ngày trong tháng, dẫn đến thiếu khả năng biểu diễn biến đổi nội tháng.

Tóm lại, sự không đồng bộ giữa dữ liệu ảnh vệ tinh Sentinel-2 (chu kỳ thu nhận theo tháng) và chuỗi quan trắc mực nước hồ (theo ngày) được xử lý thông qua cơ chế nội suy thời gian có xét yếu tố mùa vụ trong mô hình Colubrid-Net. Cụ thể, các đặc trưng không gian trích xuất từ ảnh vệ tinh tại thời điểm t_m được mở rộng sang miền thời gian ngày bằng phương pháp nội suy tuyến tính theo khoảng thời gian giữa hai thời điểm ảnh liên tiếp, đồng thời kết hợp một thành phần điều chỉnh mùa vụ nhằm phản ánh quy luật biến động mực nước theo chu kỳ thủy văn của hồ (mùa mưa – mùa khô). Sai số nội suy được kiểm soát thông qua bước chuẩn hóa đặc trưng và được đánh giá gián tiếp bằng thực nghiệm (trong Chương 3 của luận án) so sánh giữa các kịch bản có và không áp dụng cơ chế đồng bộ thời gian. Kết quả cho thấy khi tích hợp nội suy mùa vụ, các chỉ số MAE, RMSE và KGE của mô hình đều được cải thiện, chứng tỏ sai số nội suy ở mức nhỏ và không làm suy giảm hiệu năng dự báo tổng thể. Đồng thời, cơ chế này giúp duy trì tính liên tục của chuỗi đặc trưng không gian – thời

gian, qua đó nâng cao khả năng khai thác thông tin đa mô thức trong bài toán dự báo mực nước hồ.

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:

$$z_t = z_t^{spa} \oplus z_t^{temp} \in R^{2048} \quad (2.26)$$

Để xử lý sự không khớp về mặt thời gian giữa ảnh vệ tinh theo tháng và chuỗi số liệu đo đạc theo ngày, luận án 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 2.3.5. 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:

$$i_t = \sigma(W_{ii}z_t + b_{ii} + W_{hi}h_{t-1} + b_{hi}) \quad (2.27)$$

$$f_t = \sigma(W_{if}z_t + b_{if} + W_{hf}h_{t-1} + b_{hf}) \quad (2.28)$$

$$o_t = \sigma(W_{io}z_t + b_{io} + W_{ho}h_{t-1} + b_{ho}) \quad (2.29)$$

$$g_t = \tanh(W_{ig}z_t + b_{ig} + W_{hg}h_{t-1} + b_{hg}) \quad (2.30)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (2.31)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.32)$$

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:

$$h_t^{bi} = h_t^{fwd} \oplus h_t^{bwd} \quad (2.33)$$

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

$$\hat{y}_{t+1} = W_{out} \text{ReLU}(W_{proj} h_t^{bi} + b_{proj}) + b_{out} \quad (2.34)$$

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

2.4. Thảo luận về mô hình đề xuất HOG-GRU và Colubrid-Net

Trong chương này, luận án trình bày hai mô hình dự báo mực nước hồ theo hướng đa mô thức, gồm HOG-GRU và Colubrid-Net. Cả hai mô hình đều khai thác đồng thời dữ liệu ảnh vệ tinh Sentinel-2 của khu vực hồ chứa và chuỗi quan trắc mực nước trong quá khứ nhằm dự báo mực nước trong tương lai. Việc tích hợp hai nguồn dữ liệu khác nhau cho phép mô hình đồng thời nắm

bắt đặc trưng không gian từ ảnh viễn thám và động học thời gian của chuỗi thủy văn, từ đó cải thiện độ chính xác của kết quả dự báo.

Tuy cùng hướng tiếp cận đa mô thức, hai mô hình có cấu trúc kiến trúc và cơ chế trích xuất đặc trưng khác nhau. Các điểm khác biệt chính giữa HOG-GRU và Colubrid-Net được tổng hợp và trình bày trong Bảng 2.2 dưới đây.

Bảng 2.2. So sánh mô hình dự báo đề xuất HOG-GRU và Colubrid-Net

Mô hình	HOG-GRU	Colubrid-Net
1. Loại mô hình	Mô hình dự báo mực nước đa mô thức đơn giản kết hợp đặc trưng ảnh thủ công và mạng học sâu chuỗi thời gian.	Mô hình đa mô thức học sâu theo kiến trúc end-to-end, tích hợp trích xuất đặc trưng không gian và mô hình hóa chuỗi thời gian.
2. Dữ liệu đầu vào	Ảnh vệ tinh Sentinel-2 (mặt nạ hồ) và chuỗi quan trắc mực nước hồ	Ảnh vệ tinh Sentinel-2 và dữ liệu chuỗi thời gian đa biến (mực nước, lưu lượng,...)
3. Tiền xử lý ảnh	Chuyển ảnh sang mặt nạ nhị phân, chuyển sang mức xám, chuẩn hóa kích thước 320×320	Ảnh được xử lý trực tiếp để khai thác đặc trưng không gian đa tỉ lệ
4. Phương pháp trích xuất đặc trưng không gian	Sử dụng Histogram of Oriented Gradients (HOG) để trích xuất đặc trưng biên và hình dạng vùng hồ	Sử dụng UMSFE (U-Net Multiscale Spatial Feature Extractor) kết hợp C3 Swin Transformer để học đặc trưng không gian đa tỉ lệ
5. Biểu diễn đặc trưng ảnh	Véc-tơ đặc trưng HOG được chuẩn hóa bằng L2-norm	Tensor đặc trưng không gian đa cấp thu được từ encoder và decoder của U-Net
6. Xử lý dữ liệu chuỗi thời gian	Chuỗi mực nước hồ được chuẩn hóa và đưa trực tiếp vào GRU	Chuỗi thời gian được mã hóa bằng MTFE (Multilayer Perceptron Temporal Feature Extractor)

Mô hình	HOG-GRU	Colubrid-Net
7. Cơ chế hợp nhất dữ liệu	Hợp nhất thông qua hàm $P(y_t, f_t)$ và phép concatenation giữa đặc trưng ảnh và chuỗi mực nước	Hợp nhất đặc trưng đa mô thức bằng concatenation sau nội suy thời gian, sau đó đưa vào mô hình học chuỗi
8. Mô hình học chuỗi thời gian	GRU hai tầng (64 và 32 neurons) để mô hình hóa phụ thuộc theo thời gian	BiLSTM hai chiều, cho phép khai thác phụ thuộc quá khứ và tương lai trong cửa sổ thời gian
9. Khả năng khai thác đặc trưng không gian	Hạn chế, chủ yếu dựa trên đặc trưng hình học cục bộ do HOG trích xuất	Mạnh hơn nhờ Transformer + U-Net, có khả năng học quan hệ không gian toàn cục và đa tỉ lệ
10. Chi phí tính toán	Thấp	Cao
11. Khả năng tổng quát hóa	Phụ thuộc nhiều vào chất lượng đặc trưng HOG	Tốt hơn nhờ học đặc trưng tự động và biểu diễn không gian – thời gian sâu
12. Nhận xét chung	HOG-GRU là mô hình lai giữa xử lý ảnh truyền thống và học sâu, phù hợp với bối cảnh dữ liệu ảnh vệ tinh hạn chế và chi phí tính toán thấp. Kiến trúc đơn giản, dễ diễn giải.	Colubrid-Net là kiến trúc học sâu đa mô thức tiên tiến, cho phép khai thác đồng thời đặc trưng không gian đa tỉ lệ từ ảnh vệ tinh và động lực thời gian của hệ thống thủy văn, từ đó cải thiện đáng kể độ chính xác dự báo mực nước hồ. Chi phí tính toán cao hơn. Mô hình phức tạp hơn

2.5. Kết luận chương

Trong chương này, luận án đã đề xuất hai mô hình dự báo mực nước hồ đa mô thức gồm HOG-GRU và Colubrid-Net, trong đó tích hợp đồng thời thông tin từ ảnh vệ tinh khu vực hồ chứa và dữ liệu vận hành hồ theo chuỗi thời gian. Các mô hình được thiết kế nhằm khai thác hiệu quả đặc trưng hình học và

sự biến động không gian của mặt nước trích xuất từ ảnh viễn thám, kết hợp với động lực thời gian của các yếu tố thủy văn, qua đó nâng cao độ chính xác dự báo mực nước hồ so với các phương pháp sử dụng đơn nguồn dữ liệu.

Mô hình HOG-GRU được đề xuất nhằm khắc phục một số hạn chế của các phương pháp dự báo đa mô thức trước đây. Thay vì sử dụng các mạng CNN phức tạp để trích xuất đặc trưng ảnh vệ tinh, mô hình áp dụng thuật toán HOG để trích xuất đặc trưng ảnh, giúp giảm đáng kể chi phí tính toán, rút ngắn thời gian huấn luyện và tăng tốc quá trình suy luận. Bên cạnh đó, luận án đề xuất hàm hợp nhất đặc trưng thông minh giữa dữ liệu ảnh vệ tinh và chuỗi mực nước, cho phép mô hình nhận diện tốt hơn các thời điểm mực nước biến động đột ngột – vốn là điểm yếu của nhiều mô hình truyền thống. Tuy nhiên, hạn chế của HOG-GRU là đặc trưng ảnh vệ tinh vẫn được gán cố định theo tháng cho toàn bộ các ngày trong tháng, nên chưa phản ánh đầy đủ tính động theo thời gian của hồ chứa. Từ hạn chế đó, luận án tiếp tục phát triển mô hình Colubrid-Net, một kiến trúc dự báo đa mô thức thế hệ mới. Mô hình sử dụng U-Net cải tiến, tích hợp khối C3STR kết hợp ưu điểm của cấu trúc C3 và Swin Transformer, giúp khai thác đồng thời đặc trưng cục bộ và quan hệ không gian toàn cục, từ đó nâng cao hiệu quả trích xuất đặc trưng ảnh đa tỷ lệ từ dữ liệu vệ tinh. Đồng thời, Colubrid-Net đề xuất cơ chế căn chỉnh thời gian và nội suy mùa vụ, chuyển đặc trưng ảnh vệ tinh từ tần suất theo tháng sang theo ngày để đồng bộ với chuỗi số liệu thủy văn. Sau bước hợp nhất đặc trưng, mô hình sử dụng mạng BiLSTM để học phụ thuộc thời gian hai chiều và dự báo mực nước hồ hằng ngày với độ chính xác cao hơn.

Hai mô hình đề xuất hiện tại đang dự báo mực nước trung bình theo ngày của hồ chứa. Nhưng bản chất của các mô hình chuỗi như GRU, BiLSTM không phụ thuộc cứng vào đơn vị thời gian cụ thể mà phụ thuộc vào cấu trúc phụ thuộc nội tại của chuỗi dữ liệu. Nói cách khác, mô hình học quan hệ giữa các trạng thái theo thứ tự thời gian, chứ không học “ngày” hay “giờ” như một khái niệm tuyệt đối. Do đó, khi chuyển từ dữ liệu ngày sang giờ hoặc tuần, điều cần điều chỉnh không phải là kiến trúc mô hình mà là cách tổ chức lại dữ liệu đầu vào, đặc biệt là độ dài cửa sổ trễ và tần suất lấy mẫu. Ví dụ, với dữ liệu theo giờ, mô hình sử dụng cửa sổ từ 24 đến 72 bước để phản ánh chu kỳ ngày–đêm, trong khi với dữ liệu theo ngày có thể sử dụng cửa sổ 7 đến 30 ngày để nắm bắt xu thế mùa vụ. Nếu không điều chỉnh các tham số này, mô hình sẽ không học đúng

cấu trúc tự tương quan của dữ liệu, dẫn đến suy giảm hiệu năng. Vì vậy, đóng góp của luận án không chỉ nằm ở mô hình, mà ở việc xây dựng một khung xử lý linh hoạt theo thời gian, cho phép mô hình thích ứng với nhiều kịch bản vận hành khác nhau trong thực tế, từ dự báo ngắn hạn đến trung và dài hạn.


Ở chương tiếp theo, luận án tiến hành thực nghiệm và đánh giá các mô hình đề xuất trên một số hồ chứa tại Việt Nam nhằm kiểm chứng tính đúng đắn, độ tin cậy và hiệu quả dự báo. Đồng thời, chương này cũng trình bày việc xây dựng hệ thống dự báo mực nước hồ, trong đó lõi tính toán cho phép tích hợp linh hoạt các mô hình HOG–GRU và Colubrid-Net, phục vụ công tác vận hành và quản lý hồ chứa.

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

Chương 3. KẾT QUẢ THỰC NGHIỆM VÀ XÂY DỰNG HỆ THỐNG DỰ BÁO MỨC NƯỚC HỒ

3.1. Khu vực nghiên cứu

Mặc dù các mô hình dự báo mực nước hồ trong luận án được xây dựng theo hướng tổng quát, có khả năng áp dụng cho nhiều loại hồ chứa khác nhau, hệ thống hồ An Khê và Ka Nak (tỉnh Gia Lai, Việt Nam) được lựa chọn làm khu vực nghiên cứu điển hình nhằm đánh giá tính đúng đắn và hiệu quả của các mô hình đề xuất. *Hình 3.1* mô tả vị trí hai hồ chứa. Việc lựa chọn này dựa trên sự kết hợp giữa điều kiện tự nhiên phức tạp, đặc điểm vận hành liên hồ, cũng như các thách thức thực tiễn trong công tác dự báo và điều tiết mực nước hồ tại khu vực.



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

Hai hồ An Khê và Ka Nak nằm trong vùng núi có địa hình dốc, bị chia cắt mạnh, với mạng lưới sông suối dày đặc và điều kiện thủy – khí tượng biến động lớn theo không gian và thời gian. Khu vực thường xuyên chịu ảnh hưởng của các hiện tượng cực đoan như mưa lớn cục bộ, lũ xảy ra nhanh và các giai đoạn khô hạn kéo dài, làm cho quá trình hình thành và truyền lũ diễn ra trong thời

gian ngắn, đồng thời khiến mực nước hồ phản ứng nhanh và phi tuyến đối với sự thay đổi của dòng chảy đến.

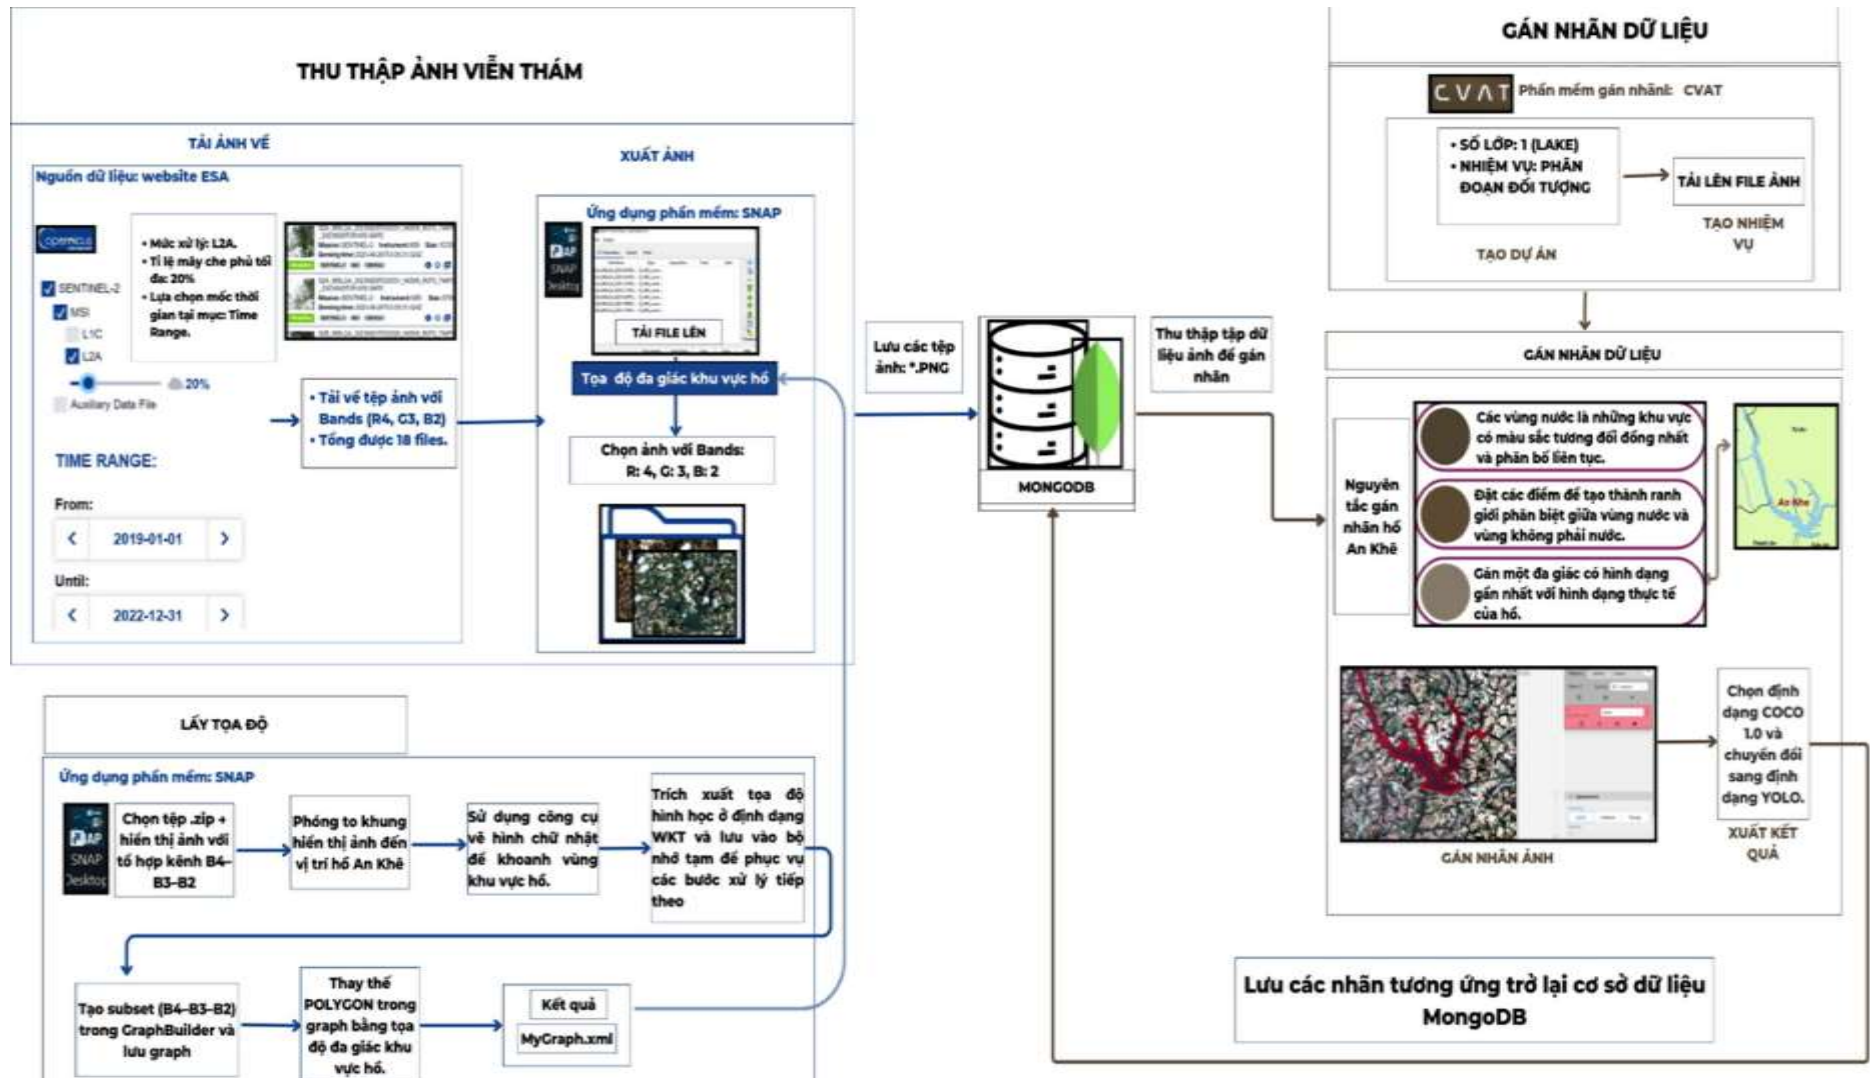
Phân tích số liệu quan trắc cho thấy mực nước hồ An Khê dao động trong khoảng từ 417,41 m đến 429,99 m, trong khi hồ Ka Nak có biên độ biến thiên lớn hơn đáng kể, từ 392,92 m đến 551,23 m. Sự khác biệt về biên độ dao động mực nước phản ánh tác động tổng hợp của đặc điểm hình thái hồ, điều kiện địa hình lưu vực, phân bố mưa không đồng đều và chế độ vận hành liên hồ. Trong các đợt mưa lớn, mực nước hai hồ có thể biến đổi nhanh trong thời gian ngắn, làm gia tăng độ khó của bài toán dự báo.

Bên cạnh đó, An Khê và Ka Nak là hai hồ có mối liên kết thủy lực chặt chẽ, cách nhau khoảng 25 km, được nối với nhau thông qua một lưu vực trung gian có địa hình và lớp phủ bề mặt đa dạng. Sự thay đổi nhanh của dòng chảy vào hai hồ, kết hợp với độ dốc lớn của lưu vực và sự phân bố mưa không đồng đều theo không gian, dẫn đến các dao động mực nước mạnh và khó dự báo, đặc biệt trong các sự kiện mưa lũ cực đoan.

Thực tế vận hành hai hồ này, đã ghi nhận nhiều sự cố xả lũ gây thiệt hại đáng kể cho khu vực hạ du. Điển hình, năm 2011, việc xả lũ đột ngột của hệ thống thủy điện An Khê – Ka Nak đã gây ngập lụt, cuốn trôi hoa màu và tài sản của người dân huyện Kbang, với tổng thiệt hại ước tính khoảng 10 tỷ đồng. Tiếp đó, tháng 11 năm 2013, hoạt động xả lũ của công trình tiếp tục gây thiệt hại nghiêm trọng cho người dân thị xã An Khê và các huyện phía Đông Nam tỉnh Gia Lai, với mức thiệt hại được ghi nhận khoảng 15 tỷ đồng. Các sự kiện này cho thấy rủi ro lớn nếu công tác dự báo mực nước và điều tiết hồ không đủ chính xác và kịp thời.

Theo quan điểm trong học máy, nếu một mô hình có thể học tốt trong các điều kiện có độ bất định cao và phi tuyến mạnh, thì có cơ sở để kỳ vọng khả năng tổng quát hóa tốt hơn so với các trường hợp đơn giản. Bên cạnh đó, việc lựa chọn hai hồ trong cùng một hệ thống cũng cho phép đánh giá khả năng mô hình nắm bắt quan hệ liên hồ. Trong tương lai, luận án sẽ thí nghiệm thêm trên các lưu vực song khác nhau có thể thông qua học chuyển giao hoặc kiểm chứng chéo giữa các vùng.

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




Hình 3.2. Quy trình thu thập và gán nhãn dữ liệu

Trong phần này, luận án mô tả chi tiết quy trình thu thập và gán nhãn ảnh vệ tinh Sentinel-2, được minh họa trong *Hình 3.2*. Quy trình này được đề xuất trong công trình [CT3] của luận án.

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.

Để thu thập ảnh Sentinel-2 khu vực hồ chứa, trước tiên người dùng truy cập cổng dữ liệu Copernicus Data Space Ecosystem tại địa chỉ <https://dataspace.copernicus.eu/> và đăng ký tài khoản. Sau đó, truy cập mục dữ liệu Sentinel-2 để mở giao diện tìm kiếm như *Hình 3.3*. Tại đây, người dùng nhập tên khu vực hoặc xác định vùng hồ chứa cần thu thập ảnh để thực hiện tìm kiếm và tải dữ liệu.



Hình 3.3. Minh họa cửa sổ tải ảnh khu vực cần lấy ảnh Sentinel-2

Trong luận án này, các tiêu chí sau được áp dụng để truy xuất ảnh vệ tinh từ Copernicus:

¹ <https://dataspace.copernicus.eu/>

- Chọn mức xử lý Mức xử lý là Level 2A; ngưỡng che phủ mây đặt < 20%;
- Giai đoạn thu nhận dữ liệu ví dụ khu vực hồ An Khê từ ngày 1 tháng 1 năm 2019 đến ngày 31 tháng 12 năm 2022;
- 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 tính chân thực cao, phản ánh gần nhất đặc trưng của ảnh thực tế tự nhiên. Tổng cộng có 34 ảnh vệ tinh khu vực hồ được sử dụng trong tập dữ liệu này.


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 dưới định dạng WKT từ Geometry và lưu tọa độ đó 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 3.4*.

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

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



Hình 3.4. Ví dụ về hình ảnh vệ tinh khu vực hồ An Khê

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. Toàn bộ các nhãn sau khi tạo lập đều được rà soát và hiệu chỉnh lại bởi chuyên gia trong lĩnh vực viễn thám và thủy văn nhằm đảm bảo độ tin cậy của tập dữ liệu huấn luyện, như minh họa trong *Hình 3.5*. 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 3.5. Ảnh vệ tinh khu vực hồ sau gán nhãn

Trong luận án này, ảnh vệ tinh Sentinel-2 được sử dụng với ba kênh phổ RGB (B2, B3, B4). Mặc dù trong viễn thám thủy văn các kênh cận hồng ngoại (NIR), hồng ngoại sóng ngắn (SWIR) hoặc các chỉ số phổ như NDWI/MNDWI thường được áp dụng để tách mặt nước dựa trên đặc tính hấp thụ phổ của nước, luận án này tập trung khai thác đặc trưng hình thái và cấu trúc không gian của mặt hồ phục vụ bài toán dự báo mực nước hồ. Đối với nhiệm vụ này, thông tin về hình dạng, ranh giới mặt nước và sự biến đổi không gian của hồ chứa theo thời gian đóng vai trò quan trọng hơn so với phân tích phổ thuần túy. Ba kênh RGB cung cấp biểu diễn gần với ảnh quan sát tự nhiên, giúp các mô hình học sâu nhận diện hiệu quả các đặc trưng hình học và cấu trúc không gian của mặt nước hồ.

Ngoài ra, việc sử dụng ảnh RGB cho phép tận dụng các mạng nơ-ron tích chập đã được tiền huấn luyện trên các tập dữ liệu ảnh tự nhiên quy mô lớn, từ đó cải thiện khả năng học đặc trưng và giảm nguy cơ quá khớp trong bối cảnh số lượng ảnh vệ tinh còn hạn chế. Cách tiếp cận này cũng đơn giản hóa quy trình tiền xử lý dữ liệu, hạn chế các vấn đề liên quan đến chuẩn hóa phổ và sai khác phản xạ giữa các thời điểm quan trắc, đồng thời góp phần nâng cao tính ổn định của mô hình dự báo.

3.3. Mô tả dữ liệu thực nghiệm

3.3.1. Dữ liệu ảnh vệ tinh khu vực hồ chứa An Khê và Ka Nak

Bộ dữ liệu ảnh vệ tinh của hai hồ chứa An Khê và Ka Nak được thu thập trong giai đoạn từ ngày 01/01/2019 đến ngày 31/12/2022, theo quy trình mô tả tại Mục 3.1. Đối với hồ An Khê, thu thập được 18 ảnh vệ tinh, trong khi hồ Ka Nak thu được 32 ảnh. Sự chênh lệch về số lượng ảnh giữa hai hồ xuất phát từ tiêu chí lựa chọn dữ liệu của nghiên cứu, trong đó chỉ sử dụng các ảnh thể hiện rõ khu vực hồ chứa và không bị che phủ bởi mây, nhằm đảm bảo chất lượng thông tin không gian phục vụ cho quá trình phân tích và mô hình hóa. Dữ liệu được thu thập và gán nhãn theo quy trình trong Mục 3.2. Kết quả thu được tập ảnh gốc và tập nhãn của ảnh khu vực hồ chứa.

Bên cạnh đó, quá trình thu thập và lựa chọn ảnh được thực hiện theo nguyên tắc đảm bảo tính bao phủ theo chu kỳ tháng trong năm (từ tháng 1 đến tháng 12) trong toàn bộ giai đoạn nghiên cứu bốn năm. Do ảnh hưởng của điều kiện quan trắc thực tế và chất lượng ảnh vệ tinh (như mây che phủ hoặc nhiễu ảnh), một số tháng trong từng năm có thể không thu thập được ảnh phù hợp (ví

dự năm 2019 có thể thiếu ảnh vào tháng 9 hoặc tháng 12). Tuy nhiên, các tháng còn thiếu này được bổ sung bằng ảnh thu thập từ các năm khác trong cùng giai đoạn nghiên cứu, qua đó vẫn đảm bảo bộ dữ liệu phản ánh đầy đủ đặc trưng biến thiên theo mùa của hồ chứa.

3.3.2. Dữ liệu chuỗi thời gian vận hành hồ chứa.

Bộ dữ liệu chuỗi thủy văn vận hành hồ chứa cũng được thu thập từ các thiết bị đo đặc thủy văn chuyên dụng. Thời gian thu thập trùng với thời gian thu thập ảnh vệ tinh của hai khu vực hồ An Khê và Ka Nak. Các trường dữ liệu thu thập gồm: Thời gian, mực nước hồ, lưu lượng đến, 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 3.6* minh họa một ví dụ về bộ dữ liệu vận hành hồ chứa An Khê được thu thập theo bước thời gian giờ, tại thời điểm ngày 02 tháng 04 năm 2022.

1	Hồ chứa	LVS/Hồ/Ngày/Giờ	LVS/Hồ chứa/Ngày	Mực 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
7	An Khê	5	2/4/2022	428.32	40.12	49
8	An Khê	6	2/4/2022	428.31	40.03	53
9	An Khê	7	2/4/2022	428.3	39.86	51
10	An Khê	8	2/4/2022	428.29	39.89	48.5
11	An Khê	9	2/4/2022	428.29	33.42	33.3
12	An Khê	10	2/4/2022	428.32	33.83	8
13	An Khê	11	2/4/2022	428.35	33.85	8
14	An Khê	12	2/4/2022	428.38	33.85	8
15	An Khê	13	2/4/2022	428.41	33.87	8
16	An Khê	14	2/4/2022	428.44	33.84	8
17	An Khê	15	2/4/2022	428.47	33.83	8
18	An Khê	16	2/4/2022	428.47	33.67	35.7
19	An Khê	17	2/4/2022	428.45	32.28	48.5
20	An Khê	18	2/4/2022	428.43	24.45	48.5
21	An Khê	19	2/4/2022	428.4	4.37	48.5
22	An Khê	20	2/4/2022	428.37	14.67	44.5
23	An Khê	21	2/4/2022	428.36	35.89	44.5
24	An Khê	22	2/4/2022	428.35	35.89	44.5
25	An Khê	23	2/4/2022	428.35	34.42	34.4

Hình 3.6. Ví dụ dữ liệu chuỗi thời gian hồ chứa An Khê ngày 02/04/2022

3.4. Đánh giá hiệu năng mô hình HOG-GRU

Dữ liệu của thực nghiệm phần này được tiến hành xử lý như Mục 2.2.2.

Sau đó luận án đã 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 (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

Như thể hiện trong Bảng 3.1, các kết quả đánh giá cho thấy mô hình HOG-GRU đạt hiệu năng tổng thể tốt nhất trên toàn bộ tập dữ liệu kiểm tra của hồ An Khê, thể hiện qua các giá trị sai số thấp nhất ở tất cả các chỉ số đánh giá: $MSE = 0.08060 \pm 0.08473$, $RMSE = 0.28390 \pm 0.08473$, $MAE = 0.20446 \pm 0.08473$ và $Tracking\ Signal = -0.00032 \pm 0.08473$. Giá trị trung bình thấp cùng với độ lệch chuẩn nhỏ cho thấy độ biến thiên thấp, chứng tỏ mô hình có tính ổn định cao và khả năng khái quát tốt trên tập kiểm tra.

So với các mô hình đối sánh (RNN, LSTM, GRU, HOG-RNN và HOG-LSTM), HOG-GRU không chỉ đạt mức sai số thấp hơn đáng kể mà còn thể hiện độ biến thiên nhỏ hơn giữa các lần thực nghiệm, qua đó khẳng định độ tin cậy và tính vững của phương pháp đề xuất. Trong so sánh chi tiết, mô hình HOG-GRU giúp giảm MSE khoảng 23.6% và RMSE khoảng 12.5% so với mô hình GRU thông thường, cho thấy việc hợp nhất đặc trưng không gian từ ảnh HOG giúp mô hình học sâu khai thác hiệu quả hơn các mối quan hệ phụ thuộc không gian - thời gian trong dữ liệu thủy văn.

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


Mô hình	MSE	RMSE	MAE	Tracking Signal	Phương sai
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

So với các biến thể HOG-RNN và HOG-LSTM, HOG-GRU tiếp tục thể hiện ưu thế vượt trội, khẳng định khả năng tăng cường trong việc xử lý các quan hệ phụ thuộc dài hạn và duy trì độ ổn định của dự báo khi kết hợp thêm thông tin đặc trưng từ ảnh. Đáng chú ý, giá trị Tracking Signal gần bằng 0 (-0.00032) phản ánh khả năng mô hình bám sát xu thế thực tế và phản hồi kịp thời trước những biến động đột ngột của mực nước hồ. Bên cạnh đó, độ biến thiên thấp ở các chỉ số sai số tiếp tục chứng minh mô hình hoạt động ổn định và bền vững, thể hiện khả năng chống nhiễu tốt - một thuộc tính quan trọng trong các ứng dụng dự báo thủy văn đáng tin cậy.

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 đoan. Kết quả tương ứng được trình bày trong Bảng 3.2.

Các kết quả trong Bảng 3.2 cho thấy mô hình HOG-GRU tiếp tục đạt hiệu năng cao nhất trong số tất cả các mô hình so sánh, với các chỉ số sai số thấp nhất ($\text{MSE} = 0.08546 \pm 0.09783$, $\text{RMSE} = 0.29234 \pm 0.09783$, $\text{MAE} = 0.21044 \pm 0.09783$, $\text{TS} = -0.02169 \pm 0.09783$). Giá trị sai số trung bình thấp cùng độ lệch chuẩn nhỏ khẳng định mô hình duy trì được tính ổn định và khả năng khái quát tốt, ngay cả khi dự báo tập dữ liệu bất thường với đặc tính biến thiên mạnh và chứa nhiễu nhiều.

Giá trị Tracking Signal gần bằng 0 và độ biến thiên thấp cho thấy mô hình có khả năng nắm bắt chính xác xu thế thực tế, phản ứng nhanh với các dao động mực nước hồ đột ngột và duy trì sự ổn định trong các điều kiện thủy văn cực đoan. Nhìn chung, mô hình HOG-GRU hợp nhất đa mô thức đề xuất không chỉ đạt độ chính xác dự báo cao mà còn thể hiện tính vững và độ tin cậy vượt trội, chứng minh hiệu quả của việc hợp nhất thông tin không gian-thời gian trong dự báo thủy văn phi tuyến.



Hình 3.7. Biểu đồ thể hiện kết quả dự báo của các mô hình RNN, HOG-RNN, LSTM, HOG-LSTM, GRU và HOG-GRU

Các biểu đồ trong Hình 3.7 thể hiện kết quả dự báo mực nước hồ được tạo ra bởi các mô hình học sâu so sánh với dữ liệu quan trắc thực tế. Phân tích trực quan cho thấy các mô hình có hợp nhất đặc trưng ảnh HOG đều cho độ chính xác dự báo cao hơn so với các mô hình gốc tương ứng. Cụ thể, Hình 3.7b cho thấy mô hình HOG-RNN tạo ra đường dự báo (màu đỏ) bám sát đường mực nước hồ thực tế (màu xanh) hơn so với mô hình RNN tiêu chuẩn trong Hình 3.7a, đặc biệt trong các giai đoạn dao động nhanh. Tương tự, mô hình HOG-LSTM (Hình 3.7d) cho mức độ khớp tốt hơn đáng kể với dữ liệu quan trắc so với mô hình LSTM gốc (Hình 3.7c).

Mô hình HOG-GRU (Hình 3.7f) vượt trội hơn mô hình GRU (Hình 3.7e) cả về độ chính xác dự báo lẫn độ ổn định, đặc biệt tại các thời điểm đạt đỉnh hoặc đáy khi mực nước hồ biến động đột ngột. Trong số tất cả các mô hình được đánh giá, HOG-GRU (Hình 3.7f) thể hiện sự tương đồng nhất quán và chính xác nhất giữa đường dự báo (đỏ) và đường thực tế (xanh) trong phần lớn chuỗi thời gian. Đặc biệt, tại các thời điểm mực nước hồ biến thiên đột ngột, HOG-GRU vẫn duy trì được sự ổn định và độ chính xác dự báo, vượt trội hơn tất cả các mô hình đối sánh khác.

Những kết quả trực quan này tiếp tục củng cố bằng chứng về hiệu quả của việc hợp nhất đặc trưng dựa trên ảnh trong việc cải thiện độ chính xác dự báo chuỗi thời gian thủy văn.

Để kiểm chứng khả năng khái quát hóa của phương pháp đề xuất, luận án áp dụng mô hình cho hồ Ka Nak, Gia Lai, Việt Nam. Đặc điểm của hồ được mô tả trong Mục 3.1. Ảnh vệ tinh Sentinel-2 hồ Ka Nak thu được tổng cộng 32 ảnh và 16 ảnh bổ sung được tạo ra thông qua nội suy nhằm bổ sung các tháng còn thiếu trong năm. Tổng số ảnh cuối cùng thu được là 48 ảnh, đảm bảo có ít nhất một ảnh đại diện cho mỗi tháng trong giai đoạn nghiên cứu. Các kết quả thực nghiệm được tóm tắt 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

Kết quả trình bày trong Bảng 3.3 cho thấy mô hình HOG-GRU đạt hiệu năng tốt nhất trên tập dữ liệu kiểm tra của hồ Ka Nak, với các chỉ số sai số thấp nhất ($MAE = 0.37937 \pm 22.69440$, $MSE = 0.20795 \pm 22.69440$, $RMSE = 0.45601 \pm 22.69440$, $TS = -0.03985 \pm 22.69440$). Giá trị trung bình thấp cùng

độ lệch chuẩn nhỏ chứng minh rằng mô hình duy trì được tính ổn định cao và khả năng khái quát tốt.

So với các mô hình học sâu truyền thống (RNN, LSTM, GRU), mô hình đề xuất HOG-GRU thể hiện sự cải thiện đáng kể về độ chính xác dự báo-giảm MSE hơn 60% và giảm RMSE hơn 40%. Khi so sánh với các biến thể hợp nhất HOG khác (HOG-RNN, HOG-LSTM), HOG-GRU tiếp tục vượt trội, phản ánh khả năng tăng cường trong việc nắm bắt các quan hệ phụ thuộc dài hạn và thích ứng hiệu quả với dữ liệu thủy văn phi tuyến.

Giá trị Tracking Signal gần bằng 0 (- 0.03985) tiếp tục khẳng định mô hình bám sát xu thế mực nước hồ thực tế, phản hồi nhanh trước các biến động đột ngột và duy trì độ ổn định vững chắc ngay cả trong điều kiện dữ liệu nhiễu.

Trong phần này, luận án thực hiện quy trình kiểm định chéo k-fold kết hợp với phân tích phương sai ANOVA trên bộ dữ liệu hồ An Khê nhằm đánh giá một cách toàn diện hiệu năng dự báo và mức độ ổn định của mô hình HOG-GRU được đề xuất. Cụ thể, để phục vụ phân tích ANOVA, quy trình kiểm định chéo 5-fold được áp dụng cho bộ dữ liệu gốc đối với ba mô hình dự báo: HOG-RNN, HOG-LSTM và HOG-GRU. Quy trình phân chia dữ liệu được thiết kế như sau:

- **Bước 1:** Chia ngẫu nhiên bộ dữ liệu gốc thành năm fold lớn.
- **Bước 2:** Tiếp tục chia ngẫu nhiên mỗi fold lớn thành năm fold nhỏ hơn.
- **Bước 3:** Trong mỗi fold nhỏ, phân bổ dữ liệu theo thứ tự thời gian với tỷ lệ 3/5 cho tập huấn luyện, 1/5 cho tập kiểm định và 1/5 cho tập kiểm tra (phân bổ tuần tự, không chọn ngẫu nhiên).
- **Bước 4:** Gộp các tập huấn luyện, kiểm định và kiểm tra của các fold lớn theo đúng thứ tự ban đầu (tức là gộp tất cả tập huấn luyện lại với nhau, tất cả tập kiểm định lại với nhau và tất cả tập kiểm tra lại với nhau).
- **Bước 5:** Lặp lại các bước từ 1 đến 4 năm lần.
- **Bước 6:** Cuối cùng, tạo ra năm bộ dữ liệu được phân chia độc lập, sau đó được sử dụng để huấn luyện các mô hình.

Kết quả đánh giá kiểm định chéo 5-fold được trình bày trong Bảng 3.4.

Trong Bảng 3.4, hàng giá trị “Trung bình” cho thấy giá trị MAE của các mô hình HOG-RNN, HOG-LSTM và HOG-GRU lần lượt là 0.2022822, 0.2034760 và 0.1985352. Trong số này, mô hình HOG-GRU thể hiện hiệu năng dự báo tốt nhất với MAE thấp nhất. Đối với chỉ số Tracking Signal (TS), các

giá trị tương ứng của ba mô hình là 0.1019040, 0.0655876 và -0.081397. Vì tất cả các giá trị TS nằm trong khoảng cho phép $[-4, 4]$, có thể kết luận rằng cả ba mô hình đều đáng tin cậy cho dự báo.

Bảng 3.4. Đánh giá hiệu năng của các mô hình HOG-RNN, HOG-LSTM và HOG-GRU bằng phương pháp kiểm định chéo 5-fold.

	MAE			TS		
	HOG-RNN	HOG-LSTM	HOG-GRU	HOG-RNN	HOG-LSTM	HOG-GRU
Fold 1	0.201562	0.207726	0.197386	0.05282	0.036896	-0.111729
Fold 2	0.203726	0.205669	0.196408	0.062263	0.143295	0.034366
Fold 3	0.208741	0.202889	0.205471	0.176976	0.090141	-0.233906
Fold 4	0.200245	0.199514	0.19794	0.185118	0.099314	-0.014729
Fold 5	0.197137	0.201582	0.195471	0.032343	-0.041708	-0.080987
Trung bình	0.202282	0.203476	0.198535	0.101904	0.0655876	-0.081397

Dựa trên các kết quả thu được từ kiểm định chéo 5-fold, luận án tiến hành phân tích phương sai hai chiều với mức ý nghĩa $p = 0.05$ để đánh giá ảnh hưởng của yếu tố mô hình (HOG-RNN, HOG-LSTM, HOG-GRU) và yếu tố chỉ số đánh giá (MAE, TS), cũng như tương tác giữa hai yếu tố này. Hai giả thuyết thống kê được nêu như sau:

- H_0 : Không có sự khác biệt đáng kể về yếu tố mô hình (HOG-RNN, HOG-LSTM, HOG-GRU) hoặc yếu tố chỉ số (MAE, TS) và không tồn tại tương tác giữa hai yếu tố.
- H_1 : Tồn tại ít nhất một sự khác biệt đáng kể trong yếu tố mô hình (sự khác biệt giữa HOG-RNN, HOG-LSTM, HOG-GRU), yếu tố chỉ số (sự khác biệt giữa MAE và TS), hoặc tương tác giữa yếu tố mô hình và yếu tố chỉ số.

Bảng 3.5. Kết quả đánh giá phân tích phương sai hai chiều giữa các mô hình và các chỉ số đánh giá.

	sum_sq	df	F	PR(>F)
C(mô hình)	0.0494	2	7.0850	3.82×10^{-3}
C(chỉ số)	0.2238	1	64.1648	3.08×10^{-8}

C(mô hình): C(chỉ số)	0.0449	2	6.43047	5.80×10^{-3}
Residual (phần dư)	0.0837	24		

Kết quả trong Bảng 3.5 cho thấy tất cả các giá trị p đều nhỏ hơn 0.05 (mô hình: 3.82×10^{-3} ; chỉ số: 3.08×10^{-8} ; mô hình $\times$ chỉ số: 5.80×10^{-3}), cho thấy tất cả các yếu tố đều có ý nghĩa thống kê. Do đó, giả thuyết không H_0 bị bác bỏ và giả thuyết thay thế H_1 được chấp nhận.

Thành phần Residual trong bảng ANOVA đại diện cho phần biến thiên chưa được giải thích bởi các yếu tố mô hình, chỉ số đánh giá và tương tác giữa chúng. Giá trị residual tương đối nhỏ cho thấy phần lớn biến thiên của dữ liệu đã được giải thích bởi các yếu tố được lựa chọn trong nghiên cứu.

Sự khác biệt ở yếu tố mô hình cho thấy các sai số dự báo giữa HOG-RNN, HOG-LSTM và HOG-GRU là khác nhau rõ rệt. Sự khác biệt ở yếu tố chỉ số xác nhận rằng MAE và TS phản ánh các mức sai số trung bình khác biệt đáng kể. Hơn nữa, sự tương tác mô hình $\times$ chỉ số cho thấy các mô hình không có hiệu năng giống nhau khi được đánh giá dựa trên MAE và TS.

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 3.6.

Bảng 3.6. 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

Như được trình bày trong Bảng 3.6, mô hình HOG-GRU đạt các giá trị MAE, MSE, RMSE và thời gian huấn luyện lần lượt là 0.20408, 0.08355, 0.28905 và 2 phút. So với mô hình VGG19-SARIMAX, HOG-GRU cho thấy mức cải thiện đáng kể, với hiệu năng tăng tương đối đạt 24% đối với MAE, 20.4% đối với MSE, 10.8% đối với RMSE và giảm đáng kể thời gian huấn luyện (xấp xỉ 99.9%).

Những kết quả này chứng minh rằng sự kết hợp giữa trích xuất đặc trưng ảnh dựa trên HOG, hàm hợp nhất đề xuất và mạng GRU đã nâng cao đáng kể hiệu năng dự báo, tạo ra một mô hình vừa có độ chính xác cao vừa tối ưu về hiệu quả tính toán.

Như vậy, mô hình HOG-GRU đã hợp nhất hiệu quả đặc trưng không gian và đặc trưng thời gian thông qua cơ chế hợp nhất được đề xuất, đạt được độ chính xác, tính ổn định và độ bền vững cao. Những phát hiện này cho thấy khung mô hình HOG-GRU là một giải pháp tiềm năng và có khả năng khái quát hóa tốt cho các bài toán dự báo thủy văn phi tuyến và hỗ trợ ra quyết định trong vận hành hồ.

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 $P(y_t, f_t)$ có ảnh hưởng như nào đến hiệu năng của mô hình dự báo?***

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

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

Qua việc xem xét công thức $P'(y_t, f_t)$, có thể thấy rằng khi các trọng số bằng nhau và đều bằng 1 thì phương trình trở về dạng ban đầu $P(y_t, f_t)$. 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 3.7.

Bảng 3.7. 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

Dựa trên kết quả trình bày trong Bảng 3.7, hiệu năng của mô hình HOG-GRU thay đổi đáng kể khi điều chỉnh các hệ số trọng số w_1 , w_2 , w_3 trong hàm hợp nhất. Khi cả ba trọng số bằng nhau ($w_1 = w_2 = w_3 = 1$), mô hình đạt hiệu năng dự báo tốt nhất, thể hiện qua các chỉ số sai số thấp nhất (MAE = 0.20408, MSE = 0.08355, RMSE = 0.28905) cùng với giá trị Tracking Signal (TS) nhỏ dương (TS = 0.02625), phản ánh sự cân bằng giữa việc dự báo thấp hơn và cao hơn thực tế. Phương sai là 0.08451 ở mức thấp nhất so với các kịch bản khác, cho thấy độ biến thiên của mô hình nhỏ và hiệu năng mô hình có độ ổn định cao. Cấu hình này, được gọi là kịch bản 1, đại diện cho trường hợp tối ưu, trong đó mô hình duy trì hiệu năng cân bằng trên các dải dữ liệu thấp, trung bình và cao.

Khi các trọng số được điều chỉnh, hiệu năng của mô hình dự báo có xu hướng giảm:

- Kịch bản 2 ($w_1 = 2$, $w_2 = 1$, $w_3 = 1$): Việc tăng trọng số w_1 , đại diện cho giới hạn dưới, khiến mô hình nhấn mạnh các giá trị thấp. Sai số có xu hướng tăng nhẹ (MAE = 0.20619, RMSE = 0.28955), đồng thời giá trị Tracking Signal tăng lên 0.10364, cho thấy mô hình có xu hướng đánh giá thấp các giá trị thực tế trong các giai đoạn mực nước hồ thấp.
- Kịch bản 3 ($w_1 = 1$, $w_2 = 2$, $w_3 = 1$): Khi tăng trọng số w_2 , mô hình tập trung nhiều hơn vào các giá trị trung bình. Giá trị Tracking Signal đạt mức cao nhất (0.18383), cho thấy mô hình có xu hướng thiên lệch mạnh về khoảng giá trị trung bình. Mặc dù các dự báo trở nên mượt mà hơn, nhưng mô hình mất khả năng phản ứng nhanh với các biến động cực đoan, dẫn đến sai số tổng thể cao hơn (MAE = 0.20901, RMSE = 0.29230).
- Kịch bản 4 ($w_1 = 1$, $w_2 = 1$, $w_3 = 2$): Khi tăng trọng số w_3 , mô hình tập trung nhiều hơn vào các giá trị cận trên. Đây là cấu hình kém hiệu quả

nhất, với MAE = 0.21381, RMSE = 0.29944 và TS âm (-0.09678), cho thấy mô hình có xu hướng ước lượng quá mức các giá trị thực tế. Ngoài ra, phương sai tăng đáng kể là 0.09730, phản ánh sự suy giảm về độ ổn định của mô hình.

Kết quả tổng thể cho thấy việc phân bổ trọng số không cân bằng làm giảm hiệu năng dự báo của mô hình. Khi một trọng số cụ thể được nhấn mạnh quá mức, mô hình có xu hướng thiên lệch về vùng dữ liệu tương ứng, dẫn đến sai số tăng và giảm độ ổn định trong chuỗi thời gian dự báo. Ngược lại, việc phân bổ trọng số đồng đều giúp mô hình duy trì khả năng khái quát hóa, cân bằng giữa các khoảng giá trị thấp, trung bình và cao, từ đó đạt được hiệu năng dự báo tối ưu.

- ***Đánh giá ảnh hưởng của giá trị α trong hàm hợp nhất $P(y, f)$ tới hiệu năng mô hình***

Để đánh giá ảnh hưởng của giá trị α trong hàm hợp nhất đến hiệu năng của mô hình, nghiên cứu này đã tiến hành thực nghiệm với ba kịch bản: $\alpha = 1.645$ (90%), $\alpha = 1.960$ (95%) và $\alpha = 3.291$ (99.9%) - giá trị α được sử dụng trong mô hình đề xuất ban đầu. Kết quả thực nghiệm của các kịch bản này được trình bày trong Bảng 3.8.

Bảng 3.8. Kết quả đánh giá hiệu năng của mô hình HOG-GRU với giá trị α khác nhau trong hàm hợp nhất.

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

Dựa trên Bảng 3.8, có thể thấy rằng tham số α có ảnh hưởng đáng kể đến hiệu năng của mô hình HOG-GRU trong hàm hợp nhất. Cụ thể, khi giá trị α giảm từ 3.291 (tương ứng mức độ tin cậy 99.9%) xuống 1.960 (95%) và 1.645 (90%), các chỉ số lỗi MAE, MSE và RMSE có xu hướng tăng nhẹ. Điều này cho thấy khi khoảng tin cậy $[a, b]$ hẹp hơn (tức giá trị α nhỏ hơn), mô hình trở nên kém ổn định hơn và độ chính xác dự báo giảm. Đồng thời, chỉ số Tracking Signal thay đổi từ giá trị dương nhỏ (0.02625 tại $\alpha = 3.291$) sang các giá trị âm

(-0.05881 và -0.05273 khi α giảm), ngụ ý rằng mô hình bắt đầu thể hiện sự thiên lệch có hệ thống trong quá trình dự báo, tức khả năng theo sát xu hướng thực tế bị giảm. Ngược lại, giá trị trung bình của chuỗi dự báo gần như không thay đổi (mức nước hồ dao động quanh mốc 428.3 m), cho thấy việc điều chỉnh α không ảnh hưởng đáng kể đến xu hướng trung bình tổng thể của chuỗi thời gian.

Tổng thể, các kết quả chứng minh rằng việc chọn giá trị α lớn hơn (tương ứng với mức độ tin cậy cao hơn) giúp mô hình HOG-GRU đạt được sự ổn định cao hơn, giảm lỗi dự báo và giảm thiên lệch có hệ thống. Trường hợp $\alpha = 3.291$ (mức độ tin cậy 99.9%) mang lại hiệu năng tốt nhất, cho thấy đây là giá trị α tối ưu cho mô hình đề xuất.

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

Để làm rõ đóng góp của từng thành phần trong hàm hợp nhất đề xuất, nghiên cứu đã tiến hành một loạt các thực nghiệm bằng cách loại bỏ có chọn lọc từng thành phần của hàm hợp nhất $P(y_t, f_t)$ trong khi giữ nguyên các thành phần còn lại. Mục tiêu của phân tích này là đánh giá một cách định lượng vai trò và hiệu quả của từng yếu tố trong cơ chế hợp nhất tổng thể.

Cụ thể, thuật toán được điều chỉnh bằng cách loại bỏ lần lượt từng thành phần nâng cao trong hàm hợp nhất và thay thế các giá trị nổi bật tương ứng của nó bằng biểu diễn cơ sở ban đầu. Các kịch bản thực nghiệm như sau:

- **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 $P_1(y_t, f_t)$. Hàm mới có công thức toán học như sau:

$$P_1(y_t, f_t) = y_t [1 - S(y_t - a)] + \mu [S(y_t - a) - S(y_t - b)] + \left(y_t + \frac{\mu}{f_t} \right) S(y_t - b) \quad (3.2)$$

- **Kịch bản 2:** Thành phần nhấn mạnh mực nước hồ trung bình đã bị loại bỏ, khi đó hàm $P(y_t, f_t)$ sẽ được điều chỉnh thành hàm $P_2(y_t, f_t)$. Hàm mới có công thức toán học như sau:

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

- **Kịch bản 3:** Thành phần nhấn mạnh cận trên đã bị loại bỏ, khi đó hàm hợp nhất $P(y_t, f_t)$ sẽ được điều chỉnh thành hàm $P_3(y_t, f_t)$. Hàm mới có công thức toán học như sau:

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

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

Các kết quả thực nghiệm liên quan được trình bày trong Bảng 3.9.

Bảng 3.9. Đánh giá hiệu năng 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

Kết quả được trình bày trong Bảng 3.9 cho thấy, khi từng thành phần của hàm hợp nhất bị loại bỏ theo thứ tự (các kịch bản 1, 2 và 3), hiệu năng của mô hình giảm so với cấu hình gốc (kịch bản 4). Phát hiện này nhấn mạnh vai trò then chốt của từng thành phần trong việc hợp nhất và cân bằng thông tin từ nhiều nguồn dữ liệu đầu vào.

Cụ thể, mô hình gốc đạt giá trị lỗi thấp nhất (MAE = 0.20408; MSE = 0.08355; RMSE = 0.28905) và chỉ số TS = 0.02625, phản ánh cả khả năng mô phỏng ổn định và độ chính xác dự báo cao khi cả ba thành phần của hàm hợp nhất được giữ lại. Trong kịch bản 1 (loại bỏ thành phần nhấn mạnh cận dưới), lỗi tăng nhẹ và chỉ số TS tăng đáng kể, cho thấy mô hình trở nên nhạy cảm hơn với những dao động nhỏ và kém ổn định hơn trong dự báo chuỗi thời gian. Trong kịch bản 2 (loại bỏ thành phần nhấn mạnh mức trung bình), lỗi cũng tăng nhẹ và mô hình mất khả năng duy trì cân bằng ở các giá trị trung bình. Suy giảm rõ rệt nhất xảy ra ở kịch bản 3, khi thành phần nhấn mạnh cận trên bị loại bỏ, dẫn đến tăng lỗi đáng kể (MAE = 0.21508) và giá trị TS âm, gợi ý rằng mô hình đã mất khả năng nhận diện mức nước đỉnh, gây ra trễ pha và giảm độ tin cậy trong dự báo mực nước hồ.

Những kết quả này xác nhận rằng từng thành phần của hàm hợp nhất đều đóng góp tích cực vào hiệu năng tổng thể của mô hình. Trong số đó, thành phần nhấn mạnh cận trên có ảnh hưởng lớn nhất, đóng vai trò chủ chốt trong việc duy trì độ chính xác và ổn định của dự báo. Do đó, việc bảo toàn cấu trúc đầy

đủ của hàm hợp nhất là cần thiết để tối ưu hóa khả năng học sâu và mô phỏng động lực thủy văn của mô hình HOG-GRU.

3.5. Đánh giá hiệu năng mô hình Colubrid-Net

3.5.1. Thiết lập thí nghiệm

Các thí nghiệm sử dụng bộ dữ liệu đa mô thức thu thập tại hồ chứa thủy điện An Khê, tỉnh Gia Lai, Việt Nam, trong giai đoạn từ 01/01/2019 đến 31/12/2022 [CT4]. Bộ dữ liệu bao gồm ảnh vệ tinh với 18 ảnh Sentinel-2 được khai thác từ hệ sinh thái Copernicus Data Space, được tiền xử lý và nội suy thành 48 ảnh theo tháng; cùng với dữ liệu chuỗi thời gian thủy văn gồm 1.461 quan trắc theo ngày, bao gồm mực nước, tổng lưu lượng xả, lưu lượng vào hồ, các chỉ báo mùa vụ và các đặc trưng trễ ba ngày được xây dựng bổ sung.

Bộ dữ liệu được chia theo thứ tự thời gian nhằm đảm bảo tính nhất quán của chuỗi, với 70% cho tập huấn luyện (từ tháng 01/2019 đến tháng 05/2021), 20% cho tập kiểm định (từ tháng 06/2021 đến tháng 12/2021) và 10% cho tập kiểm tra (từ tháng 01/2022 đến tháng 12/2022).

3.5.2. Chỉ số đánh giá

Hiệu năng của mô hình đề xuất được đánh giá bằng năm chỉ số, phản ánh các khía cạnh khác nhau của độ chính xác dự báo: MAE đo độ lệch trung bình, MSE phạt mạnh các sai số lớn, RMSE thể hiện độ nhạy của sai số theo thang đo, R^2 đánh giá khả năng giải thích phương sai, và KGE cung cấp đánh giá đa thành phần thông qua tương quan, mức biến thiên và độ chệch. Các chỉ số này được tính như sau:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.5)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.8)$$

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (3.9)$$

trong đó, n là kích thước mẫu; y_i và $\hat{y}_i$ lần lượt là giá trị quan trắc và giá trị dự báo; $\bar{y}$ là giá trị trung bình của các quan trắc; và r là hệ số tương quan

Pearson. Tham số $\alpha = \sigma_{\hat{y}}/\sigma_y$ biểu thị tỷ lệ biến thiên, còn $\beta = \mu_{\hat{y}}/\mu_y$ biểu thị tỷ lệ độ lệch.

3.5.3. Môi trường thực nghiệm

Quá trình cài đặt và huấn luyện mô hình được thực hiện trên nền tảng PyTorch 1.12, kết hợp với CUDA 11.6 để tăng tốc tính toán trên GPU, và sử dụng card đồ họa NVIDIA 4070 Ti Super. Tất cả các mô hình được huấn luyện bằng bộ tối ưu Adam với tốc độ học ban đầu 10^{-3} và kích thước lô (batch size) là 32. Kiến trúc UMSFE sử dụng 64 kênh ban đầu và số kênh này được nhân đôi tại mỗi giai đoạn giảm mẫu. Các chuỗi thời gian được xây dựng với cửa sổ hồi cứu $\tau=4$ bước thời gian. Ảnh vệ tinh đầu vào được chuẩn hóa về kích thước 320×320 pixel và đưa về miền giá trị $[0,1]$. Mô hình được tối ưu hóa bằng hàm mất mát sai số bình phương trung bình (MSE) kết hợp với chuẩn hóa L2.

3.5.4. Kết quả thực nghiệm:

Luận án thực nghiệm so sánh mô hình đề xuất với các phương pháp dự báo khác, bao gồm nhóm chỉ sử dụng dữ liệu vận hành hồ và nhóm kết hợp thêm ảnh vệ tinh Sentinel-2. Kết quả được trình bày trong Bảng 3.10.

Bảng 3.10 trình bày kết quả so sánh toàn diện giữa các mô hình cơ sở và các phương pháp tiên tiến. Các phương pháp học máy truyền thống không tích hợp đặc trưng không gian có sai số lớn, với MAE của mô hình Random Forest là 0.7329 và của MLP lên tới 4.7447. Khi tích hợp thông tin không gian, hiệu năng được cải thiện rõ rệt; cụ thể, mô hình VGG19 + GRU đạt MAE = 0.2356.

So với các phương pháp khác, các mô hình transformer theo thời gian [8] đạt MAE cạnh tranh ở mức 0.026 nhưng khả năng giải thích phương sai còn hạn chế với $R^2=0.381$ và độ tin cậy chưa cao với KGE = 0.703. Nghiên cứu trước đây trên hồ An Khê trong [CT4] đạt MAE = 0.117. Trong khi đó, mô hình Colubrid-Net đạt hiệu năng tối ưu với MAE = 0.0242, $R^2=0.969$ và KGE = 0.972, tương ứng cải thiện 7.4% so với transformer theo thời gian và 79.3% so với kết quả trong [CT4], đồng thời vượt trội đáng kể về khả năng giải thích phương sai và độ tin cậy của mô hình.

Bảng 3.10. So sánh hiệu năng các mô hình dự báo

Mô hình	Thêm đặc trưng không gian	MAE	MSE	RMSE	R ²	KGE
Linear Regression	Không	1.730	4.386	2.094	0.175	0.118
Ridge Regression	Không	1.730	4.387	2.094	0.175	0.118
Lasso Regression	Không	1.726	4.483	2.117	0.157	0.084
SV Regression	Không	0.419	0.366	0.605	0.931	0.9972
Random Forest	Không	0.732	0.8971	0.947	0.831	0.894
Gradient Boosting	Không	0.493	0.442	0.665	0.916	0.959
XGBoost	Không	2.941	18.280	4.275	-2.436	0.140
LightGBM	Không	0.577	0.553	0.744	0.895	0.950
CatBoost	Không	0.537	0.504	0.710	0.905	0.957
AdaBoost	Không	0.200	0.447	0.306	0.911	0.954
Decision Tree	Không	2.828	19.925	4.463	-2.746	-0.051
K-Nearest Neighbors	Không	3.025	18.342	4.282	-2.448	0.205
MLP	Không	4.744	45.808	6.768	-7.612	-0.665
VGG19 w/GRU	Có	0.235	0.129	0.360	0.929	0.967
U-Net w/GRU	Có	0.215	1.861	1.364	0.482	0.633
Proposed w/GRU	Có	0.031	0.007	0.008	0.972	0.967
VGG w/ BiLSTM	Có	0.026	0.002	0.047	0.936	0.965
U-Net w/BiLSTM	Có	0.032	0.002	0.049	0.967	0.965
Temporal Transformers [101]	Có	0.026	0.009	0.030	0.381	0.703
Chau et al. [CT4]	Có	0.117	0.268	0.145	-	-
Colubrid-Net	Có	0.024	0.002	0.046	0.969	0.972

Trong Bảng 3.10, sự xuất hiện của các giá trị MAE và MSE lớn ở một số mô hình như XGBoost, Decision Tree, KNN và MLP có thể được lý giải từ góc độ đặc trưng dữ liệu thủy văn và khả năng biểu diễn của các thuật toán học máy. Trước hết, nhiều mô hình học máy truyền thống không được thiết kế để mô hình hóa phụ thuộc theo thời gian dài hạn của chuỗi mực nước hồ. Trong thực tế, biến động mực nước chịu chi phối bởi các quá trình thủy văn phức tạp như dòng chảy đến, quy trình vận hành điều tiết hồ và tính mùa vụ của chế độ khí hậu, do đó các phương pháp dựa trên cấu trúc cây hoặc khoảng cách như

Decision Tree hay KNN khó nắm bắt được động lực tích lũy theo thời gian của hệ thống. Bên cạnh đó, chuỗi mực nước hồ thường chứa các biến động cực trị trong các giai đoạn mưa lớn hoặc xả lũ, làm gia tăng tính nhiễu và tính phi tuyến của dữ liệu.

Các mô hình như KNN hoặc MLP có xu hướng nhạy cảm với các giá trị ngoại lai, khiến sai số dự báo trung bình tăng lên đáng kể. Ngoài ra, trong bối cảnh kích thước tập dữ liệu huấn luyện không lớn, các mô hình có độ linh hoạt cao như Decision Tree hoặc MLP dễ gặp hiện tượng quá khớp, tức là học quá chi tiết các mẫu trong tập huấn luyện nhưng lại suy giảm khả năng tổng quát hóa trên tập kiểm tra. Một yếu tố quan trọng khác nữa là các mô hình có sai số lớn trong bảng chủ yếu chỉ sử dụng dữ liệu chuỗi thời gian đơn phương thức, nên không khai thác được thông tin không gian của hệ thống hồ chứa, chẳng hạn như biến động diện tích mặt nước hoặc đặc trưng hình thái của hồ và lưu vực. Trong khi đó, các mô hình đa mô thức có khả năng tích hợp đặc trưng không gian từ ảnh vệ tinh cùng với chuỗi thời gian thủy văn, giúp phản ánh đầy đủ hơn trạng thái vật lý của hồ và do đó đạt được độ chính xác dự báo cao hơn.

Những kết quả này cho thấy kiến trúc đề xuất, kết hợp trích xuất đặc trưng không gian dựa trên transformer và nội suy theo thời gian, đóng vai trò then chốt trong việc nâng cao độ chính xác dự báo mực nước hồ.

Để đánh giá ảnh hưởng của các phương pháp mô hình hóa theo thời gian khác nhau, Bảng 3.11 trình bày kết quả so sánh các kiến trúc hồi quy khác nhau trên mô hình đề xuất. Mô hình MLP đạt $MAE = 0.1235$, cho thấy những hạn chế rõ rệt của các phương pháp không hồi quy trong việc nắm bắt các phụ thuộc theo thời gian, trong khi mô hình GRU đạt $MAE = 0.0236$. Đáng chú ý, Bi-GRU cho hiệu năng kém hơn với $MAE = 0.0415$, cho thấy cơ chế xử lý hai chiều xuôi–ngược có thể làm gia tăng độ phức tạp không cần thiết. Mô hình LSTM đạt $MAE = 0.0255$, trong khi BiLSTM cho kết quả tốt nhất với $MAE = 0.0242$, $MSE = 0.0022$ và $RMSE = 0.0464$.

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 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 3.11. So sánh hiệu năng 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

3.5.5. Đánh giá ảnh hưởng của các hàm kích hoạt

Bảng 3.12 làm rõ vai trò quan trọng của hàm kích hoạt động *snake* trong kiến trúc đề xuất. Cấu hình snake/snake đạt hiệu năng tối ưu với MAE = 0.0310, tương ứng với mức cải thiện 87,5% so với cấu hình cơ sở ReLU/ReLU có MAE = 0.2481. Đáng chú ý, các cấu hình kết hợp không đồng nhất như ReLU/snake và snake/ReLU cho hiệu năng kém hơn so với cấu hình cơ sở, cho thấy việc sử dụng hàm kích hoạt nhất quán giữa các nhánh bộ mã hóa–giải mã là yếu tố then chốt để học đặc trưng hiệu quả. Đặc biệt, cấu hình snake/ReLU cho kết quả rất kém với MAE = 0.3015, cho thấy lựa chọn hàm kích hoạt bất đối xứng có thể làm gián đoạn quá trình học biểu diễn của mô hình.

Bảng 3.12. Đánh giá 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. Xây dựng hệ thống dự báo mực nước hồ đa mô thức

Luận án xây dựng mô hình dự báo mực nước hồ đa mô thức trên nền tảng web. Dữ liệu đầu vào của mô hình là ảnh vệ tinh khu vực hồ chứa và dữ liệu vận hành hồ. Kết quả của nội dung này đã được công bố trong công trình [CT5] thuộc “**DANH MỤC CÔNG TRÌNH CÔNG BỐ**”.

3.6.1. Kiến trúc hệ thống dự báo mực nước hồ

Kiến trúc tổng thể hệ thống dự báo mực nước hồ được mô tả trong Hình 3.8.



Hình 3.8. Kiến trúc tổng thể hệ thống dự báo mực nước hồ

Ở tầng tác nhân, hệ thống gồm hai tác nhân chính là người dùng và người ra quyết định. Hai tác nhân này không tương tác trực tiếp với các mô hình bên dưới mà truy cập hệ thống thông qua giao diện web hoặc ứng dụng. Người dùng chủ yếu khai thác các chức năng xem kết quả dự báo, tra cứu lịch sử và theo dõi biến động mực nước hồ. Trong khi đó, người ra quyết định có vai trò vận hành, giám sát và cấu hình hệ thống, đồng thời sử dụng thông tin đầu ra để hỗ trợ điều hành hồ chứa.

Ở tầng ứng dụng và dịch vụ, hệ thống được chia thành ba khối chức năng chính gồm dashboard, dịch vụ ứng dụng và quản trị, điều hành hệ thống. Dashboard là nơi trực quan hóa kết quả dự báo mực nước hồ, biểu đồ chuỗi thời gian, ảnh vùng mặt nước và các cảnh báo liên quan. Khối dịch vụ ứng dụng đóng vai trò trung gian giữa giao diện người dùng và các thành phần xử lý phía sau, cung cấp API để truy vấn dữ liệu, quản lý kết quả dự báo, tra cứu lịch sử và phát thông báo. Khối quản trị và điều hành đảm nhiệm các chức năng quản lý người dùng, quản lý nguồn dữ liệu, cấu hình tham số mô hình, thiết lập lịch chạy và giám sát hệ thống thông qua log và cơ chế truy vết.

Ở tầng mô hình AI, hệ thống triển khai hệ thống dự báo mực nước đa mô thức VGG19-SARIMAX, mô hình được mô tả chi tiết ở Mục 3.6.4.


Ở tầng dữ liệu, sơ đồ thể hiện rõ ba thành phần dữ liệu: Dữ liệu bên ngoài, khối thu thập và đồng bộ dữ liệu, và kho dữ liệu. Dữ liệu bên ngoài bao gồm ảnh Sentinel-2, dữ liệu mực nước, lưu lượng, khí tượng, vận hành hồ và các dữ liệu liên quan như GIS, DEM hoặc metadata. Khối thu thập và đồng bộ dữ liệu thực hiện kết nối API/Web Service, tự động thu thập dữ liệu, kiểm tra và làm sạch dữ liệu, đồng thời chuẩn hóa và đồng bộ theo thời gian. Sau đó, dữ liệu được lưu trong kho dữ liệu, bao gồm cơ sở dữ liệu chuỗi thời gian, cơ sở dữ liệu metadata, hệ thống lưu trữ file ảnh/mặt nạ và nhật ký lịch sử dự báo. Việc tách riêng dữ liệu ngoài với khối thu thập và kho dữ liệu giúp sơ đồ thể hiện đúng hơn quy trình dữ liệu đi từ môi trường bên ngoài vào hệ thống.

Ở tầng hạ tầng triển khai, sơ đồ mô tả rõ các thành phần hạ tầng triển khai, gồm web server/reverse proxy, application server, data processing server, GPU server, database server và storage server. Mỗi máy chủ đảm nhiệm một chức năng riêng trong quá trình vận hành hệ thống: web server nhận yêu cầu truy cập từ người dùng, application server xử lý logic nghiệp vụ, data processing server thực hiện ETL và tiền xử lý, GPU server chạy các mô hình học máy, database server lưu trữ dữ liệu có cấu trúc và storage server quản lý các tệp lớn như ảnh vệ tinh và mặt nạ. Cách biểu diễn này giúp người đọc hình dung được cách triển khai thực tế của hệ thống trên hạ tầng máy chủ cụ thể.

Xét tổng thể, *Hình 3.8* không chỉ mô tả các thành phần riêng lẻ mà còn thể hiện được luồng dữ liệu, luồng điều khiển và luồng phản hồi giữa các tầng. Đây là cơ sở kiến trúc quan trọng để triển khai hệ thống dự báo mực nước hồ đa mô thức.

3.6.2. Quy trình hoạt động của hệ thống

Quy trình hoạt động của hệ thống dự báo mực nước hồ đa mô thức được minh họa trong *Hình 3.9*. Trong quy trình, thể hiện rõ cách các tác nhân và thành phần trong hệ thống tương tác với nhau theo từng luồng chức năng. Sơ đồ được chia thành ba luồng chính gồm: luồng người dùng tra cứu dự báo, luồng người vận hành điều khiển hệ thống, và luồng đồng bộ, quản lý dữ liệu. Việc tách thành các luồng riêng giúp làm rõ cơ chế hoạt động của hệ thống từ khâu truy vấn, suy luận, lưu trữ đến điều hành và cập nhật dữ liệu.



Hình 3.9. Sơ đồ quy trình hoạt động của hệ thống dự báo mực nước hồ

Ở luồng 1, người dùng bắt đầu tương tác với hệ thống bằng cách gửi yêu cầu thông qua giao diện người dùng. Sau khi nhận được request, giao diện chuyển tiếp yêu cầu tới bộ điều khiển (phần phụ trợ). Bộ điều khiển tiếp tục truy vấn cơ sở dữ liệu để lấy dữ liệu đầu vào và lịch sử cần thiết phục vụ dự báo. Đồng thời, bộ điều khiển cung cấp dữ liệu cho mô hình AI để thực hiện suy luận. Sau khi mô hình hoàn tất quá trình dự báo, kết quả được trả ngược về bộ điều khiển, sau đó tổng hợp và gửi lại giao diện người dùng. Cuối cùng, giao diện hiển thị kết quả dự báo cho người dùng dưới dạng thông tin trực quan.

Luồng này thể hiện cách hệ thống đáp ứng yêu cầu tra cứu của người dùng theo cơ chế client–server.

Ở luồng 2, tác nhân người vận hành thực hiện các thao tác điều hành và cấu hình hệ thống. Người vận hành gửi yêu cầu điều khiển đến giao diện hoặc trực tiếp đến bộ điều khiển, chẳng hạn như thiết lập tham số mô hình, điều chỉnh lịch chạy hoặc kích hoạt quá trình suy luận. Bộ điều khiển ghi nhận các cấu hình này vào cơ sở dữ liệu, đồng thời kích hoạt mô hình AI chạy theo yêu cầu. Trong quá trình thực thi, mô hình ghi lại kết quả và log hoạt động, sau đó trả trạng thái thực thi về bộ điều khiển. Bộ điều khiển tiếp tục truyền thông tin trạng thái hoạt động đến giao diện để người vận hành theo dõi. Luồng này cho thấy hệ thống không chỉ phục vụ truy vấn kết quả mà còn hỗ trợ vận hành và giám sát ở mức hệ thống.

Ở luồng 3, hệ thống thực hiện đồng bộ và quản lý dữ liệu. Khi có dữ liệu mới, bộ điều khiển tiến hành cập nhật dữ liệu vào kho lưu trữ hoặc cơ sở dữ liệu. Sau khi cập nhật hoàn tất, cơ sở dữ liệu xác nhận lại trạng thái cập nhật. Trong trường hợp cần thiết, bộ điều khiển có thể kích hoạt chạy lại mô hình để sinh ra dự báo mới dựa trên dữ liệu vừa được cập nhật. Luồng này cho thấy hệ thống có khả năng làm việc theo cơ chế cập nhật liên tục hoặc bán tự động, phù hợp với bài toán dự báo theo chuỗi thời gian và dữ liệu không gian thay đổi theo thời gian.

Về mặt cấu trúc, *Hình 3.9* thể hiện rõ các thành phần chính của hệ thống gồm người dùng, giao diện người dùng, bộ điều khiển, mô hình AI, cơ sở dữ liệu và người vận hành. Các thành phần này được tổ chức theo dạng trình tự tương tác, trong đó mỗi bước đều có vai trò và hướng đi rõ ràng. Cách mô tả này giúp làm nổi bật logic vận hành của hệ thống, đồng thời cho thấy sự liên kết chặt chẽ giữa giao diện, xử lý nghiệp vụ, suy luận mô hình và quản trị dữ liệu của hệ thống.

Nhìn chung, *Hình 3.9* bổ sung cho *Hình 3.8* bằng cách mô tả chi tiết hơn cách hệ thống hoạt động theo từng bước. Nếu *Hình 3.8* cho thấy kiến trúc tổng thể ở mức phân tầng, thì *Hình 3.8* làm rõ trình tự tương tác giữa các tác nhân và các thành phần chức năng trong thực thi thực tế. Hai hình này do đó có tính kế thừa logic với nhau và cùng góp phần hoàn chỉnh phần mô tả kiến trúc hệ thống dự báo mực nước hồ.

3.6.3. Quản lý dữ liệu của hệ thống

Hệ thống sử dụng MongoDB kết hợp với GridFS nhằm đảm bảo khả năng quản lý dữ liệu một cách hiệu quả, linh hoạt và có khả năng mở rộng cao. MongoDB được lựa chọn nhờ ưu thế vượt trội trong việc xử lý dữ liệu phi cấu trúc, đặc biệt phù hợp cho việc lưu trữ các loại dữ liệu đa dạng như ảnh vệ tinh, chuỗi thời gian thủy văn và siêu dữ liệu liên quan. Trong khi đó, GridFS được hợp nhất để xử lý các tệp có dung lượng lớn như ảnh vệ tinh độ phân giải cao hoặc mặt nạ phân đoạn bằng cách chia nhỏ chúng thành các khối dữ liệu, giúp tối ưu hóa hiệu năng lưu trữ, truy xuất và truyền tải.


Để đạt được sự cân bằng giữa hiệu năng truy xuất và tính linh hoạt trong quản lý dữ liệu, hệ thống áp dụng chiến lược lưu trữ lai, kết hợp giữa hai phương pháp embedding và referencing. Cụ thể, các đối tượng dữ liệu nhỏ như metadata, thông tin vị trí, hoặc tham số dự báo được nhúng trực tiếp vào tài liệu trong cơ sở dữ liệu nhằm rút ngắn thời gian truy vấn và giảm độ phức tạp trong xử lý. Ngược lại, các tệp dữ liệu có dung lượng lớn như ảnh viễn thám hoặc mặt nạ phân đoạn được lưu trữ gián tiếp thông qua cơ chế tham chiếu bằng GridFS, giúp giảm kích thước tài liệu và đơn giản hóa quá trình quản lý, sao lưu và mở rộng dữ liệu. Cách tiếp cận này mang lại hiệu quả cân bằng giữa tốc độ truy cập, khả năng mở rộng và tính ổn định của hệ thống trong môi trường dữ liệu lớn.

Quy trình hoạt động bắt đầu khi backend tiếp nhận dữ liệu đầu vào do người dùng tải lên thông qua giao diện web, bao gồm ảnh vệ tinh Sentinel-2 và tệp chuỗi thời gian thủy văn. Sau khi tiếp nhận, hệ thống tiến hành tiền xử lý dữ liệu để đảm bảo định dạng và cấu trúc phù hợp với mô hình dự báo trí tuệ nhân tạo. Tiếp đó, dữ liệu được đưa vào mô hình AI để thực hiện các tác vụ như phân đoạn ảnh, trích xuất đặc trưng và dự báo mực nước hồ. Kết quả dự báo sau khi tính toán sẽ được trả về backend, lưu trữ vào MongoDB, đồng thời chuyển tiếp đến giao diện người dùng dưới dạng định dạng JSON, cho phép người dùng trực quan hóa kết quả, xem biểu đồ dự báo theo thời gian và tải về dữ liệu khi cần thiết.

Mô hình dự báo mực nước hồ đa mô thức VGG19-SARIMAX, được mô tả trong *Hình 3.10*. Dữ liệu đầu vào gồm ảnh vệ tinh Sentinel-2 khu vực hồ chứa và dữ liệu vận hành hồ. Mô hình sẽ xử lý hai luồng dữ liệu khác nhau, dữ liệu ảnh vệ tinh sẽ đi qua mạng YOLOv9 để tạo ảnh mặt nạ hồ, tập ảnh mặt nạ

hồ này sẽ được xử lý để đưa vào mô hình VGG19 trích xuất ra đặc trưng ảnh. Tập dữ liệu chuỗi thời gian sau tiên xử lý được đưa qua một lớp kết nối đầy đủ để thu được véc-tơ đặc trưng chuỗi thời gian. Tiếp theo, hai véc-tơ đặc trưng thu được sẽ được chuẩn hóa và thực hiện phép nối theo chiều ngang để hình thành một véc-tơ đặc trưng mới. Véc-tơ đặc trưng hợp nhất này được sử dụng làm đầu vào cho mô hình SARIMAX. Đầu ra của toàn bộ quy trình là giá trị mực nước dự báo.

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



Hình 3.10. 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]. Dữ liệu ảnh vệ tinh được đưa qua mạng YOLOv9 để tạo tập mặt nạ hồ theo thời gian, sau đó được đưa vào mô hình VGG19 để tạo ra véc-tơ đặc trưng của ảnh. Tập dữ liệu chuỗi thời gian đã được tiên xử lý được gửi đến một lớp hoàn toàn kết nối để nhận được véc-tơ đặc trưng chuỗi thời gian. Việc nối kết được thực hiện trên hai véc-tơ đặc trưng thu được bằng cách chuẩn hóa chúng và sau đó gộp chúng lại theo chiều

ngang thành một véc-tơ đặc trưng mới. Véc-tơ đặc trưng duy nhất này được sử dụng làm dữ liệu đầu vào cho mô hình SARIMAX để dự báo ra mực nước tiếp theo.

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.

3.6.5. Minh họa kết quả dự báo của hệ thống

Hệ thống dự báo mực nước hồ đa mô thức được đề xuất được phát triển với thiết kế giao diện thân thiện, trực quan và dễ sử dụng, cho phép người dùng tương tác linh hoạt, truy xuất kết quả dự báo có độ chính xác cao, đồng thời quan sát, phân tích dữ liệu thông qua các biểu đồ trực quan nhằm hỗ trợ quá trình ra quyết định trong quản lý và vận hành hồ. Hệ thống dự báo mực nước hồ đa mô thức dựa trên nền tảng web, được minh họa qua các Hình 3.11 – 3.13.

Dự Báo Mực Nước Dự đoán Xin chào | Đổi mật khẩu | Đăng xuất | 33%

Nhập dữ liệu dự đoán

Hình ảnh hồ nước:

1 Chọn hình ảnh

Vui lòng chọn hình ảnh

File dữ liệu (.csv):

2 Chọn file CSV

Vui lòng chọn file CSV

Thời gian của ảnh:

Tháng 1 2020

3 Thời gian của ảnh chụp dựa trên dữ liệu mực nước hồ

Ảnh chụp vệ tinh

Kết quả dự đoán


Vui lòng nhập dữ liệu và nhấn nút 'Dự đoán' để bắt đầu.

Hiện thị dạng đồ thị

Thời gian	Mực nước hồ (m)	Diện tích hồ (m²)	Tổng lưu lượng nước (m³)
7/1/2023 0:00	428.85	52	35.84
7/1/2023 1:00	428.84	52	35.52
7/1/2023 2:00	428.84	52	35.76
7/1/2023 3:00	428.84	52	36.62
7/1/2023 4:00	428.83	52	34.57
7/1/2023 5:00	428.83	52	35.84

Dữ liệu mực nước hồ theo thời gian

Hình 3.11. Minh họa lựa chọn dữ liệu đầu vào cho hệ thống dự báo



Hình 3.12. Minh họa lựa chọn khoảng thời gian muốn dự báo



Hình 3.13. Minh họa kết quả dự báo mực nước hồ

Kết quả cho thấy, việc hợp nhất đồng thời dữ liệu ảnh vệ tinh và chuỗi thời gian mực nước hồ đã chứng minh khả năng nâng cao độ chính xác dự báo

đáng kể so với các phương pháp chỉ sử dụng đơn lẻ một loại dữ liệu. Cách tiếp cận đề xuất không chỉ nâng cao hiệu quả trong công tác dự báo thủy văn, mà còn định hướng tiềm năng ứng dụng của việc hợp nhất dữ liệu viễn thám và mô hình học máy trong quản lý, điều hành hồ và hỗ trợ ra quyết định trong quản lý nguồn tài nguyên nước.

3.7. Kết luận chương

Trong chương này, luận án đã tiến hành các thực nghiệm để chứng minh tính đúng đắn và hiệu năng của mô hình dự báo đa mô thức HOG-GRU và Colubrid-Net đề xuất. Trong đó:

- **Mô hình HOG-GRU:**

Mô hình đề xuất HoG-GRU thể hiện khả năng khái quát hóa tốt, cho phép áp dụng linh hoạt cho nhiều hồ chứa khác nhau trong các điều kiện thủy văn đa dạng. Kết quả thực nghiệm trên hai hồ chứa An Khê và Ka Nak cho thấy mô hình HOG-GRU đạt các giá trị MAE, RMSE và MSE thấp nhất, đồng thời chỉ số Tracking Signal xấp xỉ bằng không, phản ánh độ chính xác cao và tính ổn định của mô hình dự báo.

Các phân tích so sánh cũng chỉ ra rằng các mô hình HOG-RNN, HOG-LSTM và HOG-GRU đều vượt trội hơn so với các mô hình cơ sở tương ứng (RNN, LSTM và GRU) trên tất cả các chỉ tiêu đánh giá. Kết quả này khẳng định tính hiệu quả của hàm hợp nhất $P(y_t, f_t)$ trong việc kết hợp thông tin đa mô thức từ ảnh vệ tinh và dữ liệu thủy văn, qua đó nâng cao khả năng phát hiện và dự báo các biến động đột ngột của mực nước hồ.

Phân tích chi tiết các thành phần và tham số trong hàm $P(y_t, f_t)$ cho thấy hiệu năng của mô hình HOG-GRU chịu ảnh hưởng đáng kể bởi cách lựa chọn và phân bổ các tham số trong hàm hợp nhất:

- (1) **Phân bổ trọng số:** Việc phân bổ trọng số không cân bằng làm suy giảm hiệu quả dự báo của mô hình. Khi một trọng số cụ thể được nhấn mạnh quá mức, mô hình có xu hướng thiên lệch về miền dữ liệu tương ứng, dẫn đến sai số lớn và giảm tính ổn định của chuỗi dự báo. Ngược lại, phân bổ trọng số đồng đều giúp mô hình duy trì khả năng khái quát hóa và cân bằng trên các miền giá trị thấp, trung bình và cao, từ đó đạt hiệu quả dự báo tối ưu. Trong luận án, phân tích nhạy cảm đối với các hệ số

trọng số w_1, w_2, w_3 trong hàm hợp nhất đã được thực hiện thông qua các kích bản ablation nhằm đánh giá vai trò của từng thành phần trong quá trình tích hợp đặc trưng ảnh viễn thám và chuỗi số liệu mực nước. Kết quả thực nghiệm cho thấy cấu hình cân bằng $w_1 = w_2 = w_3$ đạt hiệu năng dự báo tốt nhất, với các chỉ số sai số (MAE, MSE, RMSE) nhỏ nhất và giá trị Tracking Signal gần bằng 0, cho thấy sự cân bằng giữa xu hướng dự báo thiếu và thừa. Khi tăng riêng lẻ từng trọng số, mô hình có xu hướng thiên lệch về một miền dữ liệu nhất định, làm giảm độ ổn định và độ chính xác của kết quả dự báo. Do đó, luận án khuyến nghị sử dụng cấu hình trọng số cân bằng như một thiết lập mặc định; trong các ứng dụng thực tế, các tham số này có thể được hiệu chỉnh linh hoạt để phù hợp với đặc trưng thủy văn của từng hệ thống hồ chứa.

(2) **Ảnh hưởng của tham số α :** Việc lựa chọn tham số $\alpha=3,291$ trong hàm hợp nhất $P(y_t, f_t)$ được dựa trên cơ sở thống kê của z-score, trong đó giá trị này tương ứng với mức tin cậy 99.9% của phân bố chuẩn nhằm xác định khoảng tin cậy $[a, b]$ của chuỗi mực nước hồ. Các giá trị nằm trong khoảng này được xem là trạng thái bình thường, trong khi các giá trị ngoài khoảng được nhấn mạnh để tăng khả năng nhận diện các dao động bất thường trong chuỗi thời gian. Kết quả thực nghiệm cho thấy khi giảm α xuống các mức 95% và 90%, các chỉ số sai số (MAE, MSE, RMSE) có xu hướng tăng và chỉ số Tracking Signal chuyển sang giá trị âm, phản ánh sự suy giảm độ ổn định của mô hình. Do đó, mức 99.9% được lựa chọn nhằm đảm bảo cân bằng giữa độ nhạy phát hiện dị thường và độ ổn định dự báo. Tuy nhiên, giá trị tối ưu của α có thể thay đổi tùy theo đặc trưng phân bố mực nước của từng hồ chứa. Vì vậy, tham số này cần được hiệu chỉnh thực nghiệm trong khoảng 90%–99.9% khi áp dụng cho các hệ thống thủy văn khác nhau.

(3) **Cấu trúc của hàm hợp nhất:** Mỗi thành phần trong hàm hợp nhất đều đóng góp tích cực vào hiệu năng tổng thể của mô hình. Việc duy trì đầy

đủ ba thành phần gồm cận dưới, giá trị trung bình và cận trên trong hàm hợp nhất giúp mô hình đạt độ chính xác dự báo cao nhất. Trong đó, thành phần cận trên đóng vai trò chi phối, cho phép mô hình nắm bắt chính xác các đỉnh mực nước và các biến động cực trị.

- **Mô Hình Colubrid-Net:**

Colubrid-Net, một kiến trúc đa mô thức hợp nhất mới, kết hợp ảnh vệ tinh và dữ liệu chuỗi thời gian nhằm nâng cao độ chính xác dự báo mực nước hồ. Để giải quyết sự không đồng bộ về thời gian giữa dữ liệu ảnh vệ tinh có tần suất quan trắc theo tháng và số liệu mực nước đo theo ngày, nghiên cứu đề xuất một cơ chế nội suy theo thời gian có xét đến yếu tố biến thiên theo mùa.

Luận án đã tiến hành một loạt các thử nghiệm với cả mô hình cho dữ liệu vận hành hồ như (Linear Regression, Ridge Regression, Lasso Regression, SV Regression, Random Forest, Gradient boosting, XGBoost, LigtGBM, CatBoost, AdaBoost, Decision Tree, K-Nearest Neighbors, MLP, Temporal Transforms[8QA]), và cả các mô hình sử dụng cả dữ liệu ảnh và dữ liệu vận hành hồ như (VGG19 w/GRU, U-Net w/GRU, w/GRU, VGG w/BiLSTM, U-Net w/BiLSTM, Chau et al.[CT4]), kết quả cho thấy mô hình đề xuất cho hiệu năng tốt hơn.

Luận án đã tiến hành thực nghiệm để làm rõ vai trò quan trọng của hàm kích hoạt động *snake* trong kiến trúc đề xuất. Kết quả thực nghiệm chỉ ra đây là lựa chọn tối ưu cho mô hình đề xuất.

Số lượng ảnh vệ tinh thu thập được theo tháng, dữ liệu mực nước hồ thu thập theo ngày. Dữ liệu ảnh vệ tinh trong luận án được sử dụng như nguồn thông tin bổ trợ, nhằm cung cấp đặc trưng không gian phản ánh sự biến đổi hình thái mặt nước và vùng hồ theo thời gian, trong khi chuỗi mực nước vận hành hàng ngày vẫn là nguồn dữ liệu chính cho dự báo. Việc căn chỉnh thời gian và nội suy đặc trưng ảnh được thực hiện để đồng bộ với tần suất dữ liệu ngày, giúp mô hình khai thác xu thế biến đổi liên tục của hồ chứa. Do các đặc trưng ảnh chủ yếu đóng vai trò bổ sung ngữ cảnh không gian, nên mức độ ảnh hưởng của sai số nội suy đến kết quả dự báo là hạn chế.

- **Đánh giá thực nghiệm hai mô hình trên bộ dữ liệu hồ An Khê:**

Luận án đã tiến hành thực nghiệm đồng thời hai mô hình đề xuất là HOG-GRU và Colubrid-Net trên cùng bộ dữ liệu hồ chứa An Khê (mô tả tại Mục 3.3), nhằm bảo đảm tính thống nhất về dữ liệu đầu vào và khách quan trong đánh giá hiệu năng dự báo. Việc so sánh trên cùng một tập dữ liệu cho phép phản ánh rõ ràng mức độ cải thiện của từng kiến trúc mô hình.

Kết quả tại Bảng 3.1 cho thấy mô hình HOG-GRU đạt các chỉ số sai số gồm $MSE = 0.08060$, $RMSE = 0.28390$ và $MAE = 0.20446$. Trong khi đó, theo Bảng 3.10, mô hình Colubrid-Net đạt hiệu năng vượt trội với $MSE = 0.002$, $RMSE = 0.046$ và $MAE = 0.024$. Việc các chỉ số sai số giảm mạnh chứng tỏ Colubrid-Net có khả năng mô hình hóa chính xác hơn diễn biến mực nước hồ, đặc biệt trong điều kiện chuỗi dữ liệu có tính phi tuyến và biến động theo mùa.

Kết quả này cho thấy các cải tiến của Colubrid-Net đã phát huy hiệu quả rõ rệt. Cụ thể, mô hình sử dụng kiến trúc trích xuất đặc trưng ảnh sâu hơn dựa trên U-Net cải tiến tích hợp C3STR, giúp khai thác tốt thông tin không gian đa tỷ lệ từ ảnh vệ tinh; cơ chế căn chỉnh thời gian và nội suy đặc trưng ảnh giúp đồng bộ dữ liệu ảnh theo tháng với chuỗi số liệu thủy văn theo ngày; đồng thời chiến lược hợp nhất đa mô thức kết hợp với mạng TF-BiLSTM giúp học hiệu quả mối quan hệ không gian – thời gian giữa các nguồn dữ liệu. Nhờ đó, chất lượng dự báo mực nước được nâng cao đáng kể so với mô hình HOG-GRU.

Tuy nhiên, do cấu trúc mạng sâu và phức tạp hơn, Colubrid-Net có số lượng tham số lớn hơn nên thời gian huấn luyện và suy luận cao hơn HOG-GRU. Điều này phản ánh mối quan hệ đánh đổi phổ biến giữa độ chính xác dự báo và chi phí tính toán. Trong thực tiễn triển khai, HOG-GRU phù hợp với các hệ thống yêu cầu xử lý nhanh, tài nguyên tính toán hạn chế hoặc cần cập nhật thường xuyên; trong khi Colubrid-Net phù hợp với các ứng dụng ưu tiên độ chính xác cao, hỗ trợ ra quyết định vận hành hồ chứa trong các tình huống quan trọng như mùa lũ hoặc hạn hán kéo dài.

Bên cạnh đó, chương này đề xuất một hệ thống dự báo mực nước hồ đa mô thức triển khai trên nền tảng web. Mặc dù các mô hình học sâu như HOG-GRU và Colubrid-Net cho thấy độ chính xác dự báo cao trong môi trường nghiên cứu, các mô hình này đòi hỏi tài nguyên tính toán lớn, thời gian suy luận cao và hạ tầng phần cứng phù hợp, nên việc triển khai trong hệ thống vận hành thời gian thực còn gặp nhiều hạn chế. Ngược lại, mô hình VGG19-SARIMAX có kiến trúc tương đối gọn nhẹ, dễ triển khai, chi phí tính toán thấp, đồng thời vẫn bảo đảm khả năng khai thác đồng thời thông tin ảnh viễn thám và dữ liệu chuỗi thời gian thủy văn. Đặc biệt, thành phần SARIMAX có tính diễn giải tốt,

thuận lợi cho việc phân tích xu thế biến động mực nước và đánh giá tác động của các biến ngoại sinh trong vận hành hồ chứa. Vì vậy, VGG19-SARIMAX được sử dụng trong hệ thống nhằm bảo đảm tính ổn định, khả năng mở rộng và tính khả thi trong điều kiện hạ tầng thực tế. Lựa chọn này không làm giảm giá trị các đóng góp phương pháp luận của luận án, mà thể hiện định hướng cân bằng giữa hiệu quả nghiên cứu và yêu cầu triển khai ứng dụng. Trong tương lai, khi hạ tầng tính toán được nâng cấp, các mô hình học sâu tiên tiến sẽ được tích hợp để tiếp tục nâng cao độ chính xác và hiệu năng tổng thể của hệ thống.

Các kết quả của chương này được công bố trong công trình [CT4], [CT5] trong “DANH MỤC CÔNG TRÌNH CÔNG BỐ”.

KẾT LUẬN

1) Những kết quả chính của luận án

Trong bối cảnh biến đổi khí hậu ngày càng diễn biến phức tạp, kéo theo sự gia tăng cả về tần suất lẫn cường độ của các hiện tượng thời tiết cực đoan, việc nâng cao năng lực dự báo mực nước hồ đóng vai trò then chốt trong quản lý tài nguyên nước, vận hành hồ và giảm thiểu rủi ro thiên tai. Công tác dự báo mực nước hồ hiện nay vẫn đang dựa trên nhiều nhóm phương pháp, từ các mô hình thủy văn truyền thống dựa trên cơ chế vật lý đến các mô hình thống kê và mô hình học máy hiện đại. Tuy nhiên, phần lớn các phương pháp này vẫn tồn tại nhiều hạn chế: độ chính xác chưa cao, khả năng khái quát hóa còn hạn chế khi điều kiện khí tượng thủy văn thay đổi và đặc biệt là yêu cầu nguồn dữ liệu đầu vào chi tiết mà nhiều lưu vực, hồ không đáp ứng được.

Trước những thách thức đó, nhu cầu phát triển các phương pháp dự báo tiên tiến, linh hoạt và có khả năng mô phỏng hiệu quả các mối quan hệ phi tuyến phức tạp của hệ thống thủy văn trong điều kiện dữ liệu còn hạn chế trở nên vô cùng cấp thiết. Sự phát triển nhanh chóng của công nghệ viễn thám trong những năm gần đây đã mở ra nguồn dữ liệu phong phú, liên tục theo thời gian và có độ phủ không gian rộng. Đây là nền tảng quan trọng cho việc mở rộng các hướng tiếp cận mới, đặc biệt là hợp nhất dữ liệu ảnh vệ tinh vào mô hình dự báo mực nước hồ.

Song song với đó, sự tiến bộ mạnh mẽ của các mô hình học sâu, như mạng nơ-ron tích chập, mạng nơ-ron hồi quy (RNN, GRU, LSTM) và các kiến trúc lai, đang mở ra khả năng vượt trội trong việc trích xuất đặc trưng dữ liệu, phát hiện các quan hệ phi tuyến tiềm ẩn và tăng cường hiệu quả dự báo so với các phương pháp truyền thống. Việc kết hợp giữa dữ liệu viễn thám và mô hình học sâu hứa hẹn tạo ra một hướng tiếp cận hiệu quả, thích ứng tốt hơn với sự biến động của hệ thống khí tượng - thủy văn trong bối cảnh biến đổi khí hậu.

Dựa trên cơ sở tổng hợp lý thuyết, phân tích mô hình và thực nghiệm trên bộ dữ liệu của hồ, luận án đạt được các kết quả chính sau:

- Đề xuất mô hình dự báo đa mô thức HOG-GRU
- Đề xuất mô hình dự báo đa mô thức Colubrid-Net
- Luận án cũng xây dựng khung dự báo mực nước hồ đa mô thức trên ứng dụng web. Cho phép người dùng trực quan hóa dữ liệu, theo dõi diễn biến

mực nước hồ và hỗ trợ hiệu quả quá trình giám sát, phân tích và ra quyết định của các cơ quan quản lý hồ.

Các kết quả đạt được của luận án có tiềm năng ứng dụng rộng rãi trong thực tiễn, đặc biệt là trong việc xây dựng và phát triển các hệ thống dự báo mực nước hồ đa mô thức có độ tin cậy cao, hỗ trợ hiệu quả cho công tác quản lý tài nguyên nước, vận hành hồ và ra quyết định trong điều kiện biến động khí tượng - thủy văn.

2) Hạn chế và Hướng phát triển của luận án

Mặc dù các kết quả thực nghiệm cho thấy mô hình đề xuất đạt độ chính xác khả quan, luận án vẫn tồn tại một số giới hạn liên quan đến quy mô và tính đại diện của dữ liệu huấn luyện. Cụ thể, bộ dữ liệu được xây dựng trên hai hồ chứa thuộc cùng một hệ thống thủy điện tại tỉnh Gia Lai trong giai đoạn 2019–2022. Sau bước tiền xử lý và loại bỏ các ảnh bị nhiễu mây hoặc suy giảm chất lượng, số lượng ảnh Sentinel-2 khả dụng còn tương đối hạn chế (18 ảnh đối với hồ An Khê và 32 ảnh đối với hồ Ka Nak), trong khi chuỗi mực nước quan trắc theo ngày gồm 1.461 mẫu. Cấu trúc dữ liệu như vậy tạo ra sự mất cân đối giữa miền không gian và miền thời gian, có thể ảnh hưởng đến khả năng học biểu diễn không gian–thời gian một cách đầy đủ của mô hình.

Các mô hình dự báo đa mô thức trong luận án được thiết kế theo hướng tích hợp đặc trưng không gian trích xuất từ ảnh viễn thám với chuỗi số liệu mực nước nhằm tăng cường năng lực biểu diễn và cải thiện độ chính xác dự báo. Tuy nhiên, hiệu quả của cơ chế hợp nhất này phụ thuộc đáng kể vào độ đa dạng và mức độ bao phủ của dữ liệu đầu vào, nhất là khi cần mô hình hóa các quan hệ phi tuyến phức tạp và các trạng thái thủy văn cực trị. Việc dữ liệu chỉ phản ánh điều kiện khí hậu – thủy văn của một khu vực cụ thể có thể khiến mô hình học thiên lệch theo đặc trưng địa phương, từ đó hạn chế khả năng khái quát hóa khi áp dụng cho các hồ có chế độ vận hành và bối cảnh tự nhiên khác biệt, như hồ tự nhiên không điều tiết, hồ đa mục tiêu với quy trình khai thác phức tạp, hoặc các hồ thuộc vùng khí hậu khác.

Do đó, cần phân tích sâu hơn ảnh hưởng của kích thước mẫu và miền dữ liệu đến tính ổn định, độ tin cậy và khả năng chuyển giao của mô hình. Trong các nghiên cứu tiếp theo, có thể mở rộng tập dữ liệu theo hướng đa vùng sinh khí hậu, triển khai kiểm định chéo liên hồ để đánh giá tính tổng quát, cũng như

tích hợp dữ liệu từ nhiều hệ thống thủy văn khác nhau nhằm nâng cao tính phổ quát của khung mô hình đề xuất.

Về định hướng phát triển, luận án tập trung vào một số hướng nghiên cứu có tiềm năng cải thiện hiệu năng và tăng cường tính ứng dụng thực tiễn của mô hình. Thứ nhất, luận án tối ưu hóa các siêu tham số bằng các thuật toán tìm kiếm toàn cục như tối ưu bầy đàn (PSO) hoặc thuật toán di truyền (GA) giúp tìm kiếm mô hình tối ưu, từ đó nâng cao độ chính xác và giảm sai số dự báo. Thứ hai, việc bổ sung thêm các biến thủy văn – khí tượng như lưu lượng đến hồ, lượng mưa, lưu lượng xả, bốc hơi hoặc các chỉ số khí hậu quy mô lớn sẽ giúp mô hình nắm bắt tốt hơn cơ chế vật lý chi phối biến động mực nước.

Luận án sẽ phát triển một kiến trúc hệ thống gồm nhiều lớp chức năng, bao gồm lớp thu nhận dữ liệu, lớp kiểm soát chất lượng, lớp hợp nhất dữ liệu và lớp dự báo thích nghi. Trong đó, cơ chế gán trọng số động đóng vai trò quan trọng, cho phép hệ thống đánh giá độ tin cậy của từng nguồn dữ liệu tại mỗi thời điểm. Ví dụ, khi ảnh vệ tinh bị mây che phủ, hệ thống sẽ tự động giảm trọng số của nguồn ảnh và tăng cường sử dụng dữ liệu từ cảm biến hoặc dự báo khí tượng. Đồng thời, mô hình có thể được cập nhật theo cơ chế học trực tuyến để thích nghi với sự thay đổi của môi trường. Cách tiếp cận này giúp hệ thống dự báo hoạt động ổn định và đáng tin cậy hơn trong điều kiện thực tế.

Ngoài ra, luận án sẽ triển khai mô hình học đa nhiệm để đồng thời dự báo nhiều đại lượng động lực như mực nước, lưu lượng vào và lưu lượng xả để khai thác hiệu quả cấu trúc phụ thuộc chéo giữa các biến, qua đó cải thiện hiệu năng tổng thể. Mô hình đa nhiệm không chỉ là một kỹ thuật học máy nhằm tăng độ chính xác, mà còn là một cách tiếp cận có ý nghĩa về mặt vật lý. Trong bài toán hồ chứa, các đại lượng như mực nước, lưu lượng vào và lưu lượng xả không tồn tại độc lập, mà liên kết với nhau thông qua phương trình cân bằng nước. Nếu mô hình học riêng lẻ từng biến, có thể xuất hiện các dự báo mâu thuẫn với quy luật vật lý, ví dụ như mực nước tăng nhưng lưu lượng vào không đổi. Do đó, việc xây dựng mô hình học đa nhiệm cho phép học đồng thời nhiều đại lượng trong cùng một kiến trúc, từ đó tận dụng được phụ thuộc chéo giữa các biến và giảm không gian nghiệm của bài toán. Điều này giúp mô hình vừa học từ dữ liệu, vừa tôn trọng các ràng buộc vật lý, nâng cao tính ổn định và khả năng ứng dụng. Trong thực tế vận hành, nhà quản lý không chỉ quan tâm đến

một đại lượng riêng lẻ mà cần một bức tranh tổng thể để đưa ra quyết định. Vì vậy, hướng tiếp cận đa nhiệm là phù hợp với yêu cầu thực tiễn.

Cuối cùng, luận án phát triển các kiến trúc hợp nhất dữ liệu dựa trên học sâu cho phép học trực tiếp các hàm phi tuyến giữa các nguồn dữ liệu không đồng nhất (ảnh viễn thám và chuỗi quan trắc), thay thế cho các phương pháp tuyến tính truyền thống, sẽ góp phần giảm sai số tích lũy và tăng cường khả năng khái quát hóa của mô hình trong các bối cảnh thủy văn khác nhau.

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. <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> , Vol. 83, Iss. 3. 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> , vol.648, pp. 16-28. Cham: 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> , vol. 1832, pp. 256–264. Cham: Springer Nature Switzerland. (Scopus Q4).

TÀI LIỆU THAM KHẢO

- [1] Barzegar, R., Aalami, M. T., & Adamowski, J. (2021). Coupling a hybrid CNN-LSTM deep learning model with a boundary corrected maximal overlap discrete wavelet transform for multiscale lake water level forecasting. *Journal of Hydrology*, 598, 126196.
- [2] Chen, S., Johnson, F., Drummond, C., Glamore, W., 2020. A new method to improve the accuracy of remotely sensed data for wetland water balance estimates. *J. Hydrol.: Reg. Stud.* 29, 100689
- [3] Zappa, M., Bernhard, L., Spirig, C., Pfaundler, M., Stahl, K., Kruse, S., Seidl, I., Stahli, M., 2014. A prototype platform for water resources monitoring and early recognition of critical droughts in Switzerland. *Proceedings of the International Association of Hydrological Sciences* 364, 492-498.
- [4] Yi, S., Kondolf, G. M., Sandoval-Solis, S., & Dale, L. (2022). Application of machine learning-based energy use forecasting for inter-basin water transfer project. *Water Resources Management*, 36, 5675-5694.
- [5] Choi, Y., Ahn, J., Ji, J., Lee, E., & Yi, J. (2020). Effects of inter-basin water transfer project operation for emergency water supply. *Water Resources Management*, 34, 2535-2548.
- [6] Choi, J., Kim, H., & Wang, B. (2020). Interdecadal variation of Changma (Korean summer monsoon rainy season) retreat date in Korea. *International Journal of Climatology*, 40, 1348-1360.
- [7] Cho, Y., Woo, S., Noh, J., & Lee, E. (2020). Application of the weather radar-based quantitative precipitation estimations for flood runoff simulation in a dam watershed. *Journal of Korea Water Resources Association*, 53, 155-166.
- [8] Li, G., Zhu, H., Jian, H., Zha, W., Wang, J., Shu, Z., Yao, S., & Han, H. (2023). A combined hydrodynamic model and deep learning method to predict water level in ungauged rivers. *Journal of Hydrology*, 625, 130025.
- [9] Shrestha, U. B., Gautam, S., & Bawa, K. S. (2012). Widespread climate change in the Himalayas and associated changes in local ecosystems. *PLoS One*, 7(5), e36741.

- [10] Plisnier, P. D., Nshombo, M., Mgana, H., & Ntakimazi, G. (2018). Monitoring climate change and anthropogenic pressure at Lake Tanganyika. *Journal of Great Lakes Research*, 44(6), 1194-1208.
- [11] Williamson, C. E., Saros, J. E., Vincent, W. F., & Smol, J. P. (2009). Lakes and reservoirs as sentinels, integrators, and regulators of climate change. *Limnology and Oceanography*, 54(6, Part 2), 2273-2282.
- [12] Adams, K. D., & Sada, D. W. (2014). Surface water hydrology and geomorphic characterization of a playa lake system: Implications for monitoring the effects of climate change. *Journal of Hydrology*, 510, 92-102.
- [13] Sillmann, J., & Roeckner, E. (2008). Indices for extreme events in projections of anthropogenic climate change. *Climatic Change*, 86, 83-104.
- [14] Nourani, V., Tootoonchi, R., & Andaryani, S. (2021). Investigation of climate, land cover and lake level pattern changes and interactions using remotely sensed data and wavelet analysis. *Ecological Informatics*, 64, 101330.
- [15] Valizadeh, N., El-Shafie, A., Mirzaei, M., Galavi, H., Mukhlisin, M., & Jaafar, O. (2014). Accuracy enhancement for forecasting water levels of reservoirs and river streams using a multiple-input-pattern fuzzification approach. *The Scientific World Journal*, 2014, Article ID 487641.
- [16] Voulanas, D., Theodossiou, N., & Hatzigiannakis, E. (2021). Assessment of potential hydrological climate change impacts in the Kastoria basin (Western Macedonia, Greece) using EURO-CORDEX regional climate models. *Global NEST Journal*, 23(1), 35-46.
- [17] He, X., Pan, M., Wei, Z., Wood, E. F., & Sheffield, J. (2020). A global drought and flood catalogue from 1950 to 2016. *Bulletin of the American Meteorological Society*, 101, E508-E535.
- [18] Kondolf, M., & Yi, J. (2022). Dam renovation to prolong reservoir life and mitigate dam impacts. *Water*, 14, 1464.
- [19] Gwon, Y., Son, K., Lee, K., & Choi, G. (2020). Development and utility evaluation of a multi-composite water balance model. *Journal of Korean Society of Hazard Mitigation*, 20, 239-250.
- [20] Di Baldassarre, G., Wanders, N., AghaKouchak, A., Kuil, L., Rangelcroft, S., Veldkamp, T. I. E., Garcia, M., van Oel, P. R., Breinl, K.,

- & Van Loon, A. F. (2018). Water shortages worsened by reservoir effects. *Nature Sustainability*, 1, 617-622.
- [21] Karami, S., & Karami, E. (2020). Sustainability assessment of dams. *Environment, Development and Sustainability*, 22, 2919-2940.
- [22] amali, A. A., Tabatabaee, R., & Randhir, T. O. (2021). Ecotourism and socioeconomic strategies for Khansar River watershed of Iran. *Environment, Development and Sustainability*, 23, 17077-17093.
- [23] Benenati, E. P., Shannon, J. P., Blinn, D. W., Wilson, K. P., & Hueftle, S. J. (2000). Reservoir-river linkages: Lake Powell and the Colorado River, Arizona. *Journal of the North American Benthological Society*, 19, 742-755.
- [24] Bartolai, A. M., He, L., Hurst, A. E., Mortsch, L., Paehlke, R., & Scavia, D. (2015). Climate change as a driver of change in the Great Lakes-St. Lawrence River Basin. *Journal of Great Lakes Research*, 41, 45-58.
- [25] Finlayson, C. M., Davis, J. A., Gell, P. A., Kingsford, R. T., & Parton, K. A. (2013). The status of wetlands and the predicted effects of global climate change: The situation in Australia. *Aquatic Sciences*, 75, 73-93.
- [26] Coops, H., Beklioglu, M., & Crisman, T. L. (2003). The role of water-level fluctuations in shallow lake ecosystems-Workshop conclusions. *Hydrobiologia*, 506, 23-27.
- [27] Haghighi, A. T., & Kløve, B. (2015). A sensitivity analysis of lake water level response to changes in climate and river regimes. *Limnological Ecology and Management of Inland Waters*, 51, 118-130.
- [28] Yuan, Y., Zeng, G., Liang, J., Huang, L., Hua, S., Li, F., Zhu, Y., Wu, H., Liu, J., He, X., & He, Y. (2015). Variation of water level in Dongting Lake over a 50-year period: Implications for impacts of anthropogenic and climatic factors. *Journal of Hydrology*, 525, 450-456.
- [29] Lee, T., Singh, V. P., & Ha, T. (2022). UAV photogrammetry-based flood early warning system applied to Migok-Cheon stream, South Korea. *Journal of Hydrologic Engineering*, 27(9), 05022010.
- [30] Ampas, H., Refanidis, I., & Ampas, V. (2025). Hybrid hydrological forecasting through a physical model and a weather-informed transformer model: A case study in Greek watershed. *Applied Sciences*, 15(12), 6679.

- [31] Young, C. C., Liu, W. C., & Hsieh, W. L. (2015). Predicting the water level fluctuation in an alpine lake using physically based, artificial neural network, and time series forecasting models. *Mathematical Problems in Engineering*, 2015(1), 708204.
- [32] Choubin, B., & Malekian, A. (2017). Combined gamma and M-test-based ANN and ARIMA models for groundwater fluctuation forecasting in semiarid regions. *Environmental Earth Sciences*, 76(15), 1-10.
- [33] Viccione, G., Guarnaccia, C., Mancini, S., & Quartieri, J. (2020). On the use of ARIMA models for short-term water tank levels forecasting. *Water Supply*, 20(3), 787-799.
- [34] Zamani Sabzi, H., Abudu, S., Alizadeh, R., Soltanisehat, L., Dilekli, N., & King, J. P. (2018). Integration of time series forecasting in a dynamic decision support system for multiple reservoir management to conserve water sources. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 40(11), 1398-1416.
- [35] Atashi, V., Gorji, H. T., Shahabi, S. M., Kardan, R., & Lim, Y. H. (2022). Water level forecasting using deep learning time-series analysis: A case study of red river of the north. *Water*, 14(12), 1971.
- [36] de Melo, G. A., Sugimoto, D. N., Tasinaffo, P. M., Santos, A. H. M., Cunha, A. M., & Dias, L. A. V. (2019). A new approach to river flow forecasting: LSTM and GRU multivariate models. *IEEE Latin America Transactions*, 17(12), 1978-1986.
- [37] Costa Nogueira Jr., A., de Sousa Almeida, J. L., Auger, G., & Watson, C. D. (2021). Reduced order modeling of dynamical systems using artificial neural networks applied to water circulation. *arXiv*. <https://arxiv.org/abs/2103.10931>.
- [38] Yaseen, Z. M., Naghshara, S., Salih, S. Q., Kim, S., Malik, A., & Ghorbani, M. A. (2020). Lake water level modeling using newly developed hybrid data intelligence model. *Theoretical and Applied Climatology*, 141(3-4), 1285-1300.
- [39] Jovic, S., Vasic, P. S., & Jakšić, T. R. (2018). Sensorless estimation of lake level by soft computing approach. *Sensor Review*, 38(1), 117-119.
- [40] Nguyen, T. T., Huu, Q. N., & Li, M. J. (2016). Forecasting time series water levels on Mekong River using machine learning models. In

Proceedings of the IEEE International Conference on Knowledge and Systems Engineering (pp. 292-297). IEEE.

- [41] Wang, K., Hu, T. F., Zhang, P. P., Huang, W. Q., Mao, J. Q., Xu, Y. F., & Shi, Y. (2022). Improving lake level prediction by embedding support vector regression in a data assimilation framework. *Water*, 14, 3718.
- [42] Guyennon, N., Salerno, F., Rossi, D., Rainaldi, M., Calizza, E., & Romano, E. (2021). Climate change and water abstraction impacts on the long-term variability of water levels in Lake Bracciano (Central Italy): A random forest approach. *Journal of Hydrology: Regional Studies*, 37, 100880.
- [43] Koch, J., Gotfredsen, J., Schneider, R., Troldborg, L., Stisen, S., & Henriksen, H. J. (2021). High resolution water table modelling of the shallow groundwater using a knowledge-guided gradient boosting decision tree model. *Frontiers in Water*, 3, 81.
- [44] Latif, S. D., Ahmed, A. N., Sherif, M., Sefelnasr, A., & El-Shafie, A. (2021). Reservoir water balance simulation model utilizing machine learning algorithm. *Alexandria Engineering Journal*, 60(1), 1365-1378.
- [45] Mosavi, A., Ozturk, P., & Chau, K. W. (2018). Flood prediction using machine learning models: Literature review. *Water*, 10(11), 1536.
- [46] Gharehbaghi, A., Ghasemlounia, R., Ahmadi, F., & Albaji, M. (2022). Groundwater level prediction with meteorologically sensitive gated recurrent unit (GRU) neural networks. *Journal of Hydrology*, 612, 128262.
- [47] Gao, Q., Liu, D., Zhang, W., & Liu, Y. (2024). Deep learning-based key indicator estimation in rivers by leveraging remote sensing image analysis. *IEEE Access*, 12, 72277-72287.
- [48] Tsai, H. Y., & Tseng, M. H. (2024). Evaluating multimodal techniques for predicting visibility in the atmosphere using satellite images and environmental data. *Electronics*, 13(13), 2585.
- [49] Wang, Z., Chen, G., Han, Y., Ma, C., & Lv, M. (2021). Southwestern Atlantic Ocean fronts detected from satellite-derived SST and chlorophyll. *Remote Sensing*, 13(21), 4402.
- [50] Ma, X., Hu, H., & Ren, Y. (2023). A hybrid deep learning model based on feature capture of water level influencing factors and prediction error

- correction for water level prediction of cascade hydropower stations under multiple time scales. *Journal of Hydrology*, 617, 129044.
- [51] Jin, Y., Liu, D., & Huang, J. (2024). Forecasting of Reservoir Water Level by Remote Sensing and Deep Learning. *Preprint*. DOI: 10.21203/rs.3.rs-3984208/v1.
- [52] Guo, Z., Wang, Y., Jian, P., Chen, X., & Peng, W. (2025). TAMMs: Temporal-aware multimodal model for satellite image change understanding and forecasting. *arXiv preprint arXiv:2506.18862*.
- [53] Li, Z., Chen, Z., Chen, L., Tang, X., & Chen, N. (2025). SRFNet: Multi-modal based selective receptive field neural network for time series forecast of flood range. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- [54] Mukhamediev, R. I., Terekhov, A., Sagatdinova, G., Amirgaliyev, Y., Gopejenko, V., Abayev, N., ... & Symagulov, A. (2023). Estimation of the water level in the Ili River from Sentinel-2 optical data using ensemble machine learning. *Remote Sensing*, 15(23), 5544.
- [55] Trần Thị Tuyết, Đỗ Anh Đức, Hoàng Diệu Hằng (2024). Nghiên cứu ứng dụng mô hình học máy vào dự báo mực nước hồ Buôn Tua Sarh. Tạp chí Khoa học và Công nghệ thủy lợi, số 85 – 2024.
- [56] Đinh Nhật Quang, Tạ Quang Chiêu, Đào Thị Huệ, Nguyễn Thị Kim Ngân (2022). Dự báo mực nước trên sông Kiên Giang sử dụng phương pháp hồi quy. Khoa học kỹ thuật thủy lợi và môi trường, số 80 (9/2022).
- [57] Trần Nguyễn Minh Thư, Phạm Xuân Hiền, Nguyễn Duy Khương, Nguyễn Hồng Thái (2021). Dự báo mực nước sông Cần Thơ dựa vào đặc trưng dòng chảy và phương 14 pháp tập hợp mô hình. Kỷ yếu Hội nghị KHCN Quốc gia lần thứ XIV về Nghiên cứu cơ bản và ứng dụng Công nghệ thông tin (FAIR), Tp.HCM, ngày 23 24/12/2021.
- [58] Đỗ Văn Đình, Nguyễn Trọng Quỳnh, Vũ Văn Cảnh, Phạm Văn Nam (2021). Dự báo mực nước sông cao nhất, thấp nhất trong ngày sử dụng mô hình hỗn hợp. Tạp chí Nghiên cứu khoa học, Trường Đại học Sao Đỏ, ISSN1859-4190, Số1(72)2021.
- [59] Ul Islam, S., Jan, S., Waheed, A., Mehmood, G., Zareei, M., & Alanazi, F. (2022). Land-cover classification and its impact on Peshawar's land

- surface temperature using remote sensing. *Computers, Materials & Continua*, 70(2), 4123-4145.
- [60] Song, S., Zhang, R., Hu, M., & Huang, F. (2024). Fine-grained ship recognition based on visible and near-infrared multimodal remote sensing images: Dataset, methodology and evaluation. *Computers, Materials & Continua*, 79(3), 5243.
- [61] Singh, A., & Vyas, V. (2022). A review on remote sensing application in river ecosystem evaluation. *Spatial Information Research*, 30(6), 759-772.
- [62] Wang, L., Tang, Q., Li, W., Wang, X., Zhang, H., Xu, J., et al. (2023). Remote sensing image analysis and cyanobacterial bloom prediction method based on ACL3D-Pix2Pix. *Desalination and Water Treatment*, 297, 138-159.
- [63] Avisse, N., Tilmant, A., Müller, M. F., & Zhang, H. (2017). Monitoring small reservoirs' storage with satellite remote sensing in inaccessible areas. *Hydrology and Earth System Sciences*, 21(12), 6445-6459.
- [64] Schumann, G., Di Baldassarre, G., & Bates, P. D. (2009). The utility of spaceborne radar to render flood inundation maps based on multialgorithm ensembles. *IEEE Transactions on Geoscience and Remote Sensing*, 47(8), 2801-2807.
- [65] Panda, R. K., Pramanik, N., & Bala, B. (2010). Simulation of river stage using artificial neural network and MIKE 11 hydrodynamic model. *Computers & Geosciences*, 36(6), 735-745.
- [66] Slieman, A. A., & Kozlov, D. (2023). Verification of MIKE 11-NAM Model for runoff modeling using ANN, FIS, and ARIMA methods in poorly studied basin. In *E3S Web of Conferences* (Vol. 401, p. 01035). EDP Sciences.
- [67] Muñoz, D. F., Yin, D., Bakhtyar, R., Moftakhari, H., Xue, Z., Mandli, K., & Ferreira, C. (2022). Inter-model comparison of Delft3D-FM and 2D HEC-RAS for total water level prediction in coastal to inland transition zones. *JAWRA Journal of the American Water Resources Association*, 58(1), 34-49.

- [68] Al-Hussein, A. A., Khan, S., Ncibi, K., Hamdi, N., & Hamed, Y. (2022). Flood analysis using HEC-RAS and HEC-HMS: a case study of Khazir River (Middle East—Northern Iraq). *Water*, 14(22), 3779.
- [69] G.E.P. Box and G. Jenkins (1970), “Time Series Analysis, Forecasting and Control”, Holden-Day, San Francisco, CA.
- [70] Brockwell Peter J. and Davis Richard A. (1991), “Time Series: Theory and Methods”, *International Conference on Machine Learning*.
- [71] Zhen Yu et al. (2017), “ARIMA modelling and forecasting of water level in the middle reach of the Yangtze River”, *4th International Conference on Transportation Information and Safety (ICTIS)*, pp. 172–177.
- [72] Mina Ranjbar and Mohammadreza Khaledian (2017), “Using ARIMA time series model in forecasting the trend of changes in qualitative parameters of Sefidrud River”, *International Research Journal of Applied and Basic Sciences*, 8 (3), pp. 346–351.
- [73] G. Viccione et al. (2019), “On the use of ARIMA models for short term water tank levels forecasting”, *Water Science & Technology Water Supply*, 20 (3), p. 1.
- [74] R. B. Cleveland et al. (1990), “SARIMA modelling approach for railway passenger flow forecasting”, *Journal of Official Statistics*, 6 (7), pp. 3–73.
- [75] Zhao, Z., Chen, W., Wu, X., Chen, P. C. Y., & Liu, J. (2017). LSTM network: A deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68-75.
- [76] Sak, H. (2014). Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition. *arXiv preprint arXiv:1402.1128*.
- [77] Cheng, M., Fang, F., Kinouchi, T., Navon, I. M., & Pain, C. C. (2020). Long lead-time daily and monthly streamflow forecasting using machine learning methods. *Journal of Hydrology*, 590, 125376.
- [78] Rahimzad, M., Moghaddam Nia, A., Zolfonoon, H., Soltani, J., Danandeh Mehr, A., & Kwon, H. H. (2021). Performance comparison of an LSTM-based deep learning model versus conventional machine learning algorithms for streamflow forecasting. *Water Resources Management*, 35(12), 4167-4187.

- [79] Méndez, Manuel, Mercedes G. Merayo, and Manuel Núñez. "Long-term traffic flow forecasting using a hybrid CNN-BiLSTM model." *Engineering Applications of Artificial Intelligence*, vol. 121, ID. 106041, 2023.
- [80] Le, X.-H., Ho, H. V., & Lee, G. (2020). Application of gated recurrent unit (GRU) network for forecasting river water levels affected by tides. In *APAC 2019: Proceedings of the 10th International Conference on Asian and Pacific Coasts* (pp. 673-680). Springer.
- [81] Zhao, X., Lv, H., Wei, Y., Lv, S., & Zhu, X. (2021). Streamflow forecasting via two types of predictive structure-based gated recurrent unit models. *Water*, 13(1), 91.
- [82] Dong, C., Liu, J., Xu, F., & Liu, C. (2019). Ship detection from optical remote sensing images using multi-scale analysis and Fourier HOG descriptor. *Remote Sensing*, 11(13), 1529.
- [83] Nagendar, Y., Alsalami, Z., Kulkarni, M., Das, A., & Keoy, K. H. (2024). Supervised machine learning based land cover classification using Sentinel satellite imagery. In *2024 International Conference on Data Science and Network Security (ICDSNS)* (pp. 1-4). IEEE.
- [84] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [85] B. Lim, S. " O. Arik, N. Loeff, and T. Pfister, "Temporal fusion transformers for interpretable multi-horizon time series forecasting," *Int. J. Forecasting*, vol. 37, no. 4, pp. 1748–1764, Oct. 2021.
- [86] Sawyer, S. F. (2009). Analysis of variance: The fundamental concepts. *Journal of Manual & Manipulative Therapy*, 17(2), 27E-38E.
- [87] Alstrøm, P., & Madsen, P. (1996). Tracking signals in inventory control systems: A simulation study. *International Journal of Production Economics*, 45(1-3), 293-302.
- [88] Yaseen, Z. M., Sulaiman, S. O., Deo, R. C., & Chau, K. W. (2019). An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *Journal of Hydrology*, 569, 387-408.

- [89] Jiang, Y., Li, C., Sun, L., Guo, D., Zhang, Y., & Wang, W. (2021). A deep learning algorithm for multi-source data fusion to predict water quality of urban sewer networks. *Journal of Cleaner Production*, 318, 128533.
- [90] Bai, C., Zhao, D., Zhang, M., & Zhang, J. (2022). Multimodal information fusion for weather systems and clouds identification from satellite images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 7333-7345.
- [91] Ahmed, A. A., Deo, R. C., Ghahramani, A., Feng, Q., Raj, N., Yin, Z., & Yang, L. (2022). New double decomposition deep learning methods for stream-flow water level forecasting using remote sensing modis satellite variables, climate indices and observations. *Climate Indices and Observations*.
- [92] Rowley, A., & Karakuş, O. (2023). Predicting air quality via multimodal AI and satellite imagery. *Remote Sensing of Environment*, 293, 113609..
- [93] Burrichter, B., Hofmann, J., Koltermann da Silva, J., Niemann, A., & Quirmbach, M. (2023). A spatiotemporal deep learning approach for urban pluvial flood forecasting with multi-source data. *Water*, 15(9), 1760.
- [94] Chacón-Maldonado, A. M., Asencio-Cortés, G., & Troncoso, A. (2025). A multimodal hybrid deep learning approach for pest forecasting using time series and satellite images. *Information Fusion*, 103350.
- [95] Z-score (2025). Standard Normal Distribution Table. URL: <https://www.mathsisfun.com/data/standard-normal-distribution-table.html>
- [96] M. Hou, Z. Lan, Q. Hong, X. Zhu, and H. Nie, “A tool for printed circuit board defect detection based on the YOLO algorithm,” in *Proc. 19th Int. Conf. Natural Comput., Fuzzy Syst. Knowl. Discovery (ICNC FSKD)*, Jul. 2023, pp. 1–7.
- [97] G. Jocher, “Ultralytics/YOLOv5: V7.0–YOLOv5 SOTA realtime instance segmentation,” Zenodo, CERN (Eur. Org. Nucl. Res.), Switzerland, Tech. Rep., 2022.
- [98] Z. Liu et al., “Swin transformer: Hierarchical vision transformer using shifted windows,” in *Proc. IEEE/CVF Int. Conf. Comput. Vis. (ICCV)*, Oct. 2021, pp. 9992–10002.

- [99] A. Dosovitskiy et al., “An image is worth 16×16 words: Transformers for image recognition at scale,” 2020, arXiv:2010.11929.
- [100] L. Ziyin, T. Hartwig, and M. Ueda, “Neural networks fail to learn periodic functions and how to fix it,” in *Proc. Adv. Neural Inf. Process. Syst.*, 2020, pp. 1583–1594.
- [101] B. Lim, S. “ O. Arik, N. Loeff, and T. Pfister, “Temporal fusion transformers for interpretable multi-horizon time series forecasting,” *Int. J. Forecasting*, vol. 37, no. 4, pp. 1748–1764, Oct. 2021