

A Study on the Analysis and Improvement of Artificial Intelligence Based Multimodal Red Tide Prediction

Jaehee Lee*, Junhyuk Park*, Seungyong Seong*, Chaeun Seo*, Hyo-Beom Ahn**

*Undergraduate Student, Div. of Artificial Intelligence, Kongju National University, Cheonan, Korea

**Full Professor, Div. of Artificial Intelligence, Kongju National University, Cheonan, Korea

[Abstract]

Red tide outbreaks cause severe damage to marine ecosystems, necessitating robust early warning systems. However, traditional models based on single data sources struggle with the nonlinear complexity of environmental factors. This study proposes a multimodal prediction model integrating GOCI satellite imagery and oceanographic numerical data. By combining spatial-temporal satellite features with time-series environmental variables, the model predicts red tide occurrences across 31 Korean coastal regions. The proposed model achieved a Precision of 0.64, Recall of 0.82, and F1-score of 0.72, significantly outperforming existing LSTM-based methods (F1-score = 0.574). These results demonstrate the potential of multimodal integration for real-time red tide forecasting and decision support.

▶ **Key words:** Multimodal Artificial Intelligence, Red Tide, Deep Learning, LSTM, Cross Attention, Multi-Head Learning

[요 약]

적조는 해양 생태계와 수산업에 큰 피해를 유발할 수 있어 사후 대응뿐 아니라 사전 예측과 조기 경보가 중요하다. 그러나 적조는 다양한 해양 환경 요인의 비선형 상호작용에 의해 발생하므로 단일 데이터 기반 예측 모델은 실무 적용에 한계를 가진다. 이에 본 연구에서는 GOCI 위성 영상과 해양 환경 수치 데이터를 결합한 멀티모달 기반 적조 예측 모델을 제안한다. 제안 모델은 위성 영상의 시공간 정보와 해양 환경 시계열 데이터를 통합적으로 학습하여 적조 발생 가능성을 예측한다. 실험 결과 제안 모델은 Precision 0.64, Recall 0.82, F1-score 0.72의 성능을 보였으며, 기존 LSTM 기반 적조 예측 연구(F1-score 0.574) 대비 향상된 성능을 확인하였다. 이러한 결과는 적조 예측 기반 의사결정 지원 및 향후 실시간 예보 시스템 구축 가능성을 제시한다.

▶ **주제어:** 멀티모달 인공지능, 적조, 딥러닝, 장단기 메모리, 크로스 어텐션, 다중 헤드 학습

-
- First Author: Jaehee Lee, Corresponding Author: Hyo-Beom Ahn
 - *Jaehee Lee (jaehee7813@gmail.com), Div. of Artificial Intelligence, Kongju National University
 - *Junhyuk Park (pjun0315@icloud.com), Div. of Artificial Intelligence, Kongju National University
 - *Seungyong Seong (phnyong@gmail.com), Div. of Artificial Intelligence, Kongju National University
 - *Chaeun Seo (codms4952@naver.com), Div. of Artificial Intelligence, Kongju National University
 - **Hyo-Beom Ahn (hbahn@kongju.ac.kr), Div. of Artificial Intelligence, Kongju National University
 - Received: 2026. 01. 19, Revised: 2026. 03. 25, Accepted: 2026. 04. 02.

I. Introduction

적조는 미세한 식물 플랑크톤이 비정상적으로 증식해 생태계, 수산업, 인체 건강 등에 피해를 유발할 수 있는 자연현상이며 실제 피해로 이어질 경우 환경적·사회적·경제적 손실을 수반한다. 적조는 발생 시 대규모 황토 살포, 비상대응 등으로 피해 저감이 가능하나 이를 위해서는 선제적인 예측과 경보가 필수적이다. 적조는 다양한 환경변수의 복합적 상호작용으로 발생하므로 전통적 수학적 모델링만으로 일반적인 달린 해를 도출하기 어렵고 이에 따라 선형 회귀(Linear Regression), SVM(Support Vector Machine) 등 전통적 머신러닝부터 CNNs(Convolutional Neural Network), RNNs(Recurrent Neural Network) 등 딥러닝까지 다양한 예측 기법이 시도되어 왔다. 그러나 자연현상으로서의 복잡성으로 인해 실무 적용 수준의 성과는 여전히 제한적인 것으로 보인다.

이러한 한계를 보완하기 위해 본 연구에서는 위성 영상 데이터와 해양 환경 수치 데이터를 결합한 멀티모달 기반 적조 예측 모델을 제안한다. 제안 모델은 위성 영상에서 시공간적 특징을 학습하기 위해 ConvLSTM(Convolutional Long Short-Term Memory) 구조를 사용하고, 수치 시계열 데이터의 불규칙한 시간 간격을 반영하기 위해 PhasedLSTM(Phased Long Short-Term Memory)을 적용한다. 또한 서로 다른 데이터 유형 간 상호작용을 효과적으로 반영하기 위해 Cross Attention 기반 멀티모달 융합 구조를 도입하였다. 더불어 국내 여러 해역을 동시에 예측하기 위해 Multi-Head 구조를 적용하여 지역별 예측을 수행할 수 있도록 모델을 설계하였다.

본 논문의 구성은 다음과 같다. 2장에서는 적조 탐지 및 예측과 관련된 기존 연구를 정리한다. 3장에서는 본 연구에서 사용한 데이터와 전처리 과정을 설명한다. 4장에서는 제안하는 멀티모달 적조 예측 모델의 구조를 설명한다. 5장에서는 실험 환경과 결과를 제시하고 이를 분석한다. 마지막으로 6장에서는 연구의 결론과 향후 연구 방향을 제시한다.

II. Preliminaries

1. Theoretical Background

1.1 Red Tide

적조는 해양에서 식물성 플랑크톤이 급격히 증식하여 해수의 색이 변하는 현상을 의미한다. 플랑크톤의 종류에

따라 붉은색 외에도 갈색, 황토색, 녹색 등 다양한 색으로 나타나지만, 일반적으로 적조라는 용어가 통용된다. 적조 발생의 잠재적 주요 요인으로는 영양염류의 증가, 적절한 수온과 일조 조건, 그리고 안정적인 해수 성층 구조가 제시된다. 국내에서는 주로 남해안에서 발생하여 해류를 따라 동해안으로 확산되며 최근에는 서해안에서도 발생 빈도가 증가하는 경향을 보인다. 적조는 발생 조건에 따라 수백 미터에서 수천 제곱킬로미터에 이르는 해역으로 확산될 수 있으며 수일에서 수개월까지 지속되기도 한다. 이러한 적조 현상은 수산업과 관광업을 포함한 지역 사회 전반에 걸쳐 상당한 경제적 피해를 유발한다[1].

1.2 Multimodal Artificial Intelligence

멀티모달 인공지능(Multimodal Artificial Intelligence)은 서로 다른 유형의 데이터를 동시에 처리하고 통합적으로 이해하는 인공지능 기술을 의미한다. 단일 데이터 유형에 의존하던 기존 인공지능과 달리 각 모달리티의 특성을 고려하여 정보를 활용하며 공유 잠재 공간(Shared Latent Space) 상에서 데이터 간 연관성을 학습한다. 이후 융합(Fusion) 단계에서 각 모달리티의 벡터가 결합된다. 최근에는 트랜스포머(Transformer)의 크로스 어텐션(Cross Attention) 메커니즘이 이러한 역할을 수행하여 모달리티 간 상호 의존성을 효과적으로 포착한다. 최종적으로 융합된 표현을 기반으로 분류 또는 생성과 같은 과제를 수행한다. 이러한 구조는 단일 모달리티 기반 접근법에 비해 복합적인 맥락 정보를 정밀하게 반영할 수 있으며 특정 모달리티의 불안정성을 다른 모달리티가 보완함으로써 예측 성능과 강건성을 향상시킨다[2].

1.3 Convolutional LSTM(ConvLSTM)

ConvLSTM은 시공간 예측을 위해 LSTM의 전이 연산을 완전연결 대신 합성곱으로 치환한 구조다. FC-LSTM은 시간 의존성은 학습하지만 입력과 상태를 벡터화하면서 공간 구조가 소실되는 반면, ConvLSTM은 수식 1과 같이 은닉상태와 셀 상태를 행·열 채널 차원의 텐서로 유지한다. 따라서 입력에서 상태, 상태에서 상태 전이를 합성곱으로 정의한 게이트 연산을 통해 공간적 국소 상관을 보존한 채 시간 축으로 정보를 전달한다[3].

$$\begin{aligned}
i &= \sigma \left(W_{(\xi)} * X_t + W_{(hi)} * H_{(t-1)} \right) \\
&\quad + W_{(ci)} \odot C_{(t-1)} + b_i \\
f_t &= \sigma \left(W_{(xf)} * X_t + W_{(hf)} * H_{(t-1)} \right) \\
&\quad + W_{(cf)} \odot C_{(t-1)} + b_f \\
C_t &= f_t \odot C_{(t-1)} + i_t \odot \\
&\quad \tanh \left(W_{(xc)} * X_t + W_{(hc)} * H_{(t-1)} + b_c \right) \\
o_t &= \sigma \left(W_{(xo)} * X_t + W_{(ho)} * H_{(t-1)} \right) \\
&\quad + W_{(co)} \odot C_{(t-1)} + b_o \\
H_t &= o_t \odot \tanh(C_t)
\end{aligned} \tag{1}$$

실험에서는 Moving-MNIST와 기상 레이더 nowcasting에서 FC-LSTM 대비 오차 및 교차엔트로피가 감소하는 등 성능 개선이 보고되었다. 이러한 특성으로 ConvLSTM은 레이더·위성 영상, 환경 격자, 교통 밀도 맵 등 격자형 공간 데이터의 시간적 변화를 예측하는 문제에 적합할 것으로 보인다[3].

1.4 PhasedLSTM

PhasedLSTM은 불규칙한 시간 간격·이벤트 기반으로 관측되는 시계열을 효율적으로 처리하기 위해 제안된 순환 구조다. 입력·망각·출력 게이트에 시간 게이트를 추가해 셀이 열림과 닫힘 구간을 주기적으로 구분한다. 시간 게이트에 대한 연산을 수식 2와 같이 나타내었다. 시간 게이트는 주기 τ , 위상 s , 활성비율 r 로 정의되며 현재 시간의 위상 Φ_t 에 따라 게이트가 활성화되는 구간에서만 셀 상태가 실질적으로 업데이트된다[4].

$$\begin{aligned}
\Phi_t &= \text{mod} \left(\frac{t-s}{\tau}, 1 \right) \\
k_t &= \begin{cases} \frac{2\Phi_t}{r_{on}}, & 0 \leq \Phi_t < \frac{r_{on}}{2} \\ 2 - \frac{2\Phi_t}{r_{on}}, & \frac{r_{on}}{2} \leq \Phi_t < r_{on} \\ a\Phi_t, & \text{otherwise} \end{cases} \tag{2}
\end{aligned}$$

이러한 희소 업데이트는 관측이 드문 구간을 자연스럽게 건너뛰어 불필요한 연산과 메모리 사용을 줄이고 정보가 들어오는 시점에 학습을 집중시킨다. 또한 서로 다른 샘플링 주기를 갖는 복수 센서 입력을 단일 모델로 통합할 때 각 스트림의 이벤트 타이밍을 보존한 채 시간 게이트로 업데이트 타이밍을 맞출 수 있어 비동기 입력 처리에 유리하다는 점이 강조된다[4].

1.5 Cross Attention

Cross Attention은 한 모달리티의 표현을 Query로 다른 모달리티의 표현을 Key-Value로 두어 두 입력의 상호 의존성을 학습하는 메커니즘이며 Transformer의 Scaled

Dot Product Attention에서 Query-Key 내적을 통해 정렬 가중치를 산출한다[10]. 본 연구에서는 수치 모달리티의 최종 은닉 벡터를 Query, 영상 모달리티의 시공간 특징 맵을 Key-Value로 설정하여 두 표현을 정렬하고, 관측 주기·해상도·스케일 차이로 단순 연결과 평균 결합이 포착하기 어려운 상호작용을 선택적으로 반영한다. 수식적으로는 수식 3과 같이 먼저 수치 벡터를 선형 변환하여 Query를 생성한다[5].

$$Q_i = q_i W_Q \in \mathbb{R}^{1 \times E} \tag{3}$$

수식 4와 수식 5에선 영상 모듈에서 얻은 특징 텐서 V_i 는 공간 차원을 펼친 뒤 각각 Key와 Value로 변환된다.

$$K_i = V_i W_K \in \mathbb{R}^{(HW) \times E} \tag{4}$$

$$V_i' = V_i W_V \in \mathbb{R}^{(HW) \times E} \tag{5}$$

Query와 Key의 내적은 영상의 모든 공간 위치에 대한 중요도 점수를 나타내며 차원 E에 대해 스케일링된 후 Softmax를 통해 수식 6과 같이 정규화된 가중치 a_i 를 산출한다.

$$a_i = \text{softmax} \left(\frac{Q_i K_i^T}{\sqrt{E}} \right) \in \mathbb{R}^{1 \times (HW)} \tag{6}$$

이 가중치는 Value에 대한 가중합으로 변환되어 수식 7과 같이 영상 모달리티로부터 수치 모달리티가 현재 시점에서 중요하다고 판단한 핵심 정보만을 추출한 벡터 c_i 를 형성한다.

$$c_i = a_i V_i' \in \mathbb{R}^E \tag{7}$$

마지막으로 Cross Attention을 통해 추출된 표상 c_i 와 수치 모달리티의 표현 q_i 는 연결 연산을 통해 최종 융합 벡터로 구성된다[10].

2. Related Works

최근 인공지능 기술의 발전과 해양 관측 데이터의 축적에 따라 적조 발생을 사전에 예측하고 피해를 최소화하기 위한 연구가 활발히 진행되고 있다. 초기 연구들은 수온이나 염분과 같은 단일 환경 변수를 기반으로 한 통계적 예측에 주로 의존하였다. 이후 위성 영상 데이터가 활용되면서 해수 표층의 분광 반사 특성과 공간 패턴을 분석하는 연구가 증가하였으며 최근에는 딥러닝을 이용하여 시공간 특징을 학습하려는 연구들이 보고되고 있다. 또한 최근 연구들은 단일 데이터 기반 접근의 한계를 극복하기 위해 위성 영상과 해양 수치 데이터를 함께 활용하는 방향으로 확

장되고 있다.

본 연구는 해양 관측 수치 데이터와 위성 영상 데이터를 결합하여 적조 발생 여부를 예측하는 멀티모달 모델을 제안한다. 수치형 시계열과 영상 시계열을 각각 시계열 인코더로 표현한 후 Cross Attention 기반 융합을 통해 두 모달리티 간 상호작용을 학습함으로써 적조 발생에 영향을 미치는 복합적인 환경 변화를 효과적으로 모델링하고자 한다.

2.1 Satellite-based Red Tide Detection

위성 원격탐사 기반 연구는 해수의 분광 반사도 특성을 활용하여 적조 발생 구역을 공간적으로 식별하는 데 주로 초점을 두어 왔다. 고해상도 PlanetScope 위성 영상을 이용하여 U-Net 기반 딥러닝 모델로 남해안 적조 영역을 분할한 연구는 위성 영상 기반 적조 탐지의 유효성을 보여주었다[6]. 또한 GOCI(Geostationary Ocean Color Imager) 자료의 분광 특성을 활용한 연구에서는 로지스틱 회귀와 의사결정나무를 이용한 적조 탐지 기법이 제안되었고, SVM(Support Vector Machine)과 Random Forest 등 다양한 기계학습 모형의 성능을 비교한 연구도 보고되었다[7][8][9]. 이들 연구는 위성 영상이 제공하는 공간적 정보를 바탕으로 적조 발생 영역을 효과적으로 탐지할 수 있음을 보여주었으나, 대부분 단일 시점 또는 제한된 시계열 영상에 기반한 탐지 문제에 집중되어 있어 해양 환경의 시간적 변동성과 적조 발생의 선행 징후를 충분히 반영하는 데에는 한계가 있다. 따라서 위성 영상 기반 공간 정보와 더불어 해양 환경의 시계열 변화를 함께 고려하는 예측 중심 접근이 필요하다.

2.2 Numerical Data-based Red Tide Prediction

해양 수치 데이터를 이용한 적조 예측 연구는 수온, 염분 등 다양한 환경 변수의 시계열 변화를 분석하여 적조

발생 가능성을 예측하는 방향으로 발전해 왔다[10]. 해양 환경 데이터를 활용하여 BPNN, GRNN, SVM 등의 머신러닝 기반 모형을 비교함으로써 적조 발생 예측의 가능성을 분석한 연구가 보고되었으며[11], 국내 해양 관측 자료를 이용하여 해양 환경 변수와 적조 발생 간의 관계를 분석하고 예측에 유의한 변수를 탐색한 연구들도 수행되었다 [12][13][14].

이러한 연구들은 환경 변수의 시간적 변화를 반영할 수 있다는 장점이 있으나, 위성 영상이 제공하는 공간적 정보와 해수 표층의 분광 특성을 함께 고려하기 어렵다는 한계를 가진다. 따라서 적조 발생을 정밀하게 예측하기 위해서는 해양 수치 자료의 시간적 정보와 위성 영상의 공간-분광 정보를 통합하는 접근이 필요하다.

2.3 Multimodal Approaches for Marine Environmental Prediction

최근 해양 환경 예측 연구에서는 단일 데이터 기반 접근의 한계를 극복하기 위해 서로 다른 데이터 유형을 결합하는 멀티모달 기반 접근이 주목받고 있다. 위성 영상은 해수 표층의 공간적 분포와 분광 특성을 제공하지만 해양 수치 데이터는 시간에 따른 환경 변화를 반영할 수 있다. 따라서 두 데이터 유형을 함께 활용할 경우 해양 환경의 시공간적 특성을 효과적으로 모델링할 수 있다. 그러나 기존 연구들은 대부분 위성 영상 기반 탐지 또는 수치형 시계열 기반 예측 중 하나에 집중되어 있으며 위성 영상과 해양 수치 데이터를 동시에 활용하여 적조 발생을 예측하는 연구는 상대적으로 제한적이다.

이에 본 연구에서는 GOCI 위성 영상과 해양 수치 데이터를 결합한 멀티모달 기반 딥러닝 모델을 제안한다. 제안 모델은 ConvLSTM을 이용한 시공간 특징 추출과 PhasedLSTM 기반 시계열 학습을 결합하고 Cross

Table 1. Existing studies on red tide detection and prediction

Reference	Data Type	Method
[6]	Image(PlanetScope Satellite)	U-Net
[7]	Image(GOCI Satellite)	U-Net
[8]	Image(Sentinel-2 Satellite)	CNN-based model
[9]	Image(SAR satellite)	Deep CNN
[10]	Numerical Ocean Data	Logistic Regression Decision Tree
[11]	Numerical Ocean Data	BPNN GRNN SVM
[12]	Image Spectral Feature	SVM Random Forest
[13]	Numerical Ocean Data	LSTM
[14]	Numerical Environmental Data	Random Forest SVM

Attention 구조를 통해 두 모달리티 간 상호작용을 학습함으로써 적조 발생 가능성을 예측한다.

3. Differentiation from Previous Research

기존의 적조 예측 연구들은 위성 영상 기반의 탐지, 해양 수치 데이터 기반의 시계열 예측의 두 가지 기법으로 진행되었다. 그러나 이러한 단일 모달리티 접근 방식은 본질적인 한계를 지닌다. 위성 영상 기반 연구는 해수면의 광범위한 공간 정보를 제공하지만 구름이나 안개 등 기상 여건에 따른 데이터 노이즈 발생 시 예측 신뢰도가 급격히 하락한다. 그리고 표층 이외의 수질 변화를 직접적으로 반영하기 어렵다. 해양 수치 데이터 기반 연구는 수온, 염분 등 핵심 환경 변수를 정밀하게 반영할 수 있다. 그러나 특정 관측 지점의 국지적 정보에 국한되어 적조의 광범위한 이동 및 확산 패턴을 설명하기에는 한계가 있다. 본 연구는 이러한 기존 연구들의 한계를 극복하기 위해 다음과 같은 세 가지 측면에서 차별성을 나타내었다.

3.1 Multimodal

GOCI 위성 이미지로부터 추출한 시공간적 특징과 JOISS(Jurisdictional Ocean Information Sharing System) 등에서 수집한 해양 환경 수치 시계열 데이터를 결합한 멀티모달 프레임워크를 제안한다. 이러한 데이터 통합 방식은 적조의 공간적 확산 패턴과 다양한 환경적 요인을 동시에 고려하는 통합적 분석을 가능하게 한다. 특히, 실제 해양 관측 환경에서 빈번히 발생하는 데이터의 결측이나 노이즈 문제에 대응하기 위해 특정 모달리티의 정보를 다른 모달리티가 상호 보완하도록 설계함으로써 예측의 강건성을 확보하였다. 결과적으로 이러한 멀티모달 접근 방식은 데이터의 불확실성을 줄인다.

3.2 Multi-Head

31개 지역의 적조 예측을 개별적인 헤드로 구성된 Multi-Head 구조를 선택하였다. 해류나 기상 조건에 의해 인접 지역으로 확산되는 적조의 특성을 고려할 때 각 지역의 예측 태스크가 유기적으로 연결되어 해역 전체의 시공간적 흐름을 함께 학습하게 된다. 결과적으로 모델은 개별 지역의 고유한 특성을 유지하면서도 지역 간의 상관관계를 효과적으로 반영하여 단일 모델 대비 정교하고 일반화된 예측 성능을 확보할 수 있다.

3.3 Future Prediction

기존의 실시간 적조 탐지 연구는 발생 초기 단계에서 즉각적인 대응에 한계가 존재한다. 본 연구는 멀티모달 딥러닝 아키텍처를 통해 적조의 발생 가능성을 예측함으로써 사전 예방 중심으로 적조 대응을 전환하고자 한다.

III. Data Preprocessing

1. Data Overview

본 연구는 적조 예측을 위한 멀티모달 모델 구축을 목적으로 위성 영상과 해양 수치 관측 자료를 통합하였다. 위성 자료는 정지궤도 해색위성(GOCI)의 L1B 산출물로 원본 공간 해상도는 $948 \times 1,252$ 픽셀이다[15]. 수치 자료는 해양수산부 해양 환경 정보 포털(MEIS)의 해양 수질 자동 측정망과 해양 환경 측정망에서 수집하였다. 자동 측정망은 수온, pH, 용존산소량, 탁도, 염분 등을 5분 간격으로 관측하며, 환경측정망은 월별·계절별 조사를 통해 영양염류($\text{NH}_3\text{-N}$, $\text{NO}_3\text{-N}$ 등)와 클로로필 a 등 적조 관련 변수를 제공한다. 관측 기간은 2011년 4월 1일부터 2021년 3월 31일까지이며 적조 발생 여부는 적조 속보를 기준으로 발생(1)과 미발생(0)의 이진 레이블로 정의하였다. 총 10,392개 관측(조사 일자-권역 조합) 중 미발생(0)이 10,251건(98.64%), 발생(1)이 141건(1.36%)으로 적조 발생 사례가 극히 적은 강한 클래스 불균형 구조를 보인다. 이는 모델 학습 과정에서 불균형 완화 전략이 필수적임을 의미한다.

2. Data Analysis and Preprocessing

수집된 위성 및 수치형 자료는 멀티모달 모델 학습에 적합하도록 시-공간 정합성 확보, 결측치 구조 파악, 입력 특성의 과학적 타당성 검토를 중심으로 전처리하였다.

2.1 Analysis and Processing of Satellite Data

본 연구에서는 정지궤도 해색위성 GOCI의 하루 8회 관측 자료 중 03:16 UTC(KST 12:16) 영상을 활용하였다. 이는 주요 적조 유발종인 *Cochlodinium polykrikoides*가 일주 수직 이동을 통해 정오 무렵 표층에 집적되는 특성과, 높은 태양 고도로 인해 대기 산란 영향이 감소하여 해수 표면 반사 신호가 명료해지는 관측 조건을 고려한 것이다[3]. 전처리 단계에서는 한반도 주변을 ROI로 설정하고 각 분광 밴드를 동일한 픽셀 크기로 정규화하였다. 특징 추출 과정에서는 B5(Red)와 B8(NIR) 밴드를 이용해 수식 8과 같이 NDVI를 산출하였다.

$$NDVI = \frac{(B8 - B5)}{(B8 + B5)} \quad (8)$$

식물성 플랑크톤은 엽록소의 분광 특성을 공유하므로 NDVI는 고밀도 플랑크톤 증식 여부를 반영하는 지표가 된다. 일반적으로 육상 식생 분석에 널리 사용되는 분광 지수로 알려져 있으나 엽록소 기반의 분광 반응을 반영한다는 특성으로 인해 해양 환경 분석에서도 지표로 활용될 수 있다. 적조 현상은 식물성 플랑크톤의 급격한 증식에 의해 발생하며, 이러한 생물학적 활동은 해수의 분광 반사 특성 변화로 나타날 수 있다. 이러한 이유로 일부 해양 원격탐사 연구에서는 NDVI 또는 NDVI와 유사한 분광 지수를 이용하여 해양 생물 생산성이나 플랑크톤 농도 변화를 분석한 사례가 보고된 바 있다. 본 연구에서도 위성 영상 기반 적조 예측을 위한 입력 특징으로 NDVI 영상을 사용하여 해양 표층의 분광 변화 패턴을 모델이 학습할 수 있도록 하였다. RGB 영상과 NDVI 지수 맵을 각각 입력으로 사용한 CNN 성능 비교 결과, NDVI 활용 시 F1-score가 더 높게 나타나 분광 지수 기반 정량화의 효과가 확인되었다. 이에 본 연구에서는 NDVI 컬러맵 이미지 데이터를 최종 영상 입력으로 사용하였으며 수신 오류나 전면 구름 피복으로 유효 영상이 확보되지 않은 16일의 데이터는 학습에서 제외하였다.

2.2 Analysis and Processing of Numerical Data

수치형 자료는 GOCI 영상과의 정합을 위해 31개 행정 구역 단위로 권역화하였다. 시간 정합은 위성 관측 시각 (12:15 KST)에 맞춰 12:00 KST 관측값을 일별 대표값으로 사용하였고, 공간 정합은 Table 2.와 같이 인접 정점을 시·군 단위로 통합해 산술평균함으로써 국지 변동성에 따른 과적합과 결측 영향을 완화하였다. 변수는 적조 발생 기전과의 연관성을 기준으로 저층 데이터 등 부적합 항목

을 제외하고 총질소·총인 산출 공식을 반영해 정제하였으며 일사량·일강수량을 포함해 최종 8개(수온, 염분, 용존산소량, 암모니아성 질소, 총인, 일사량, 일강수량, 클로로필-a)를 확정하였다. 적조 레이블은 국립수산물과학원 자료를 기반으로 구축하였고, 2011년 4월부터 2021년 3월 기간 총 10,392건의 관측값으로 데이터셋을 구성하였다[15]. 탐색 분석 결과, 변수별 결측치 규모는 다음과 같다. 전체 10,392개 관측 중 수온과 염분은 각각 33건(약 0.37%), 용존산소량은 432건(약 4.83%), 암모니아성 질소는 2,546건(약 28.44%), 총인은 67건(약 0.75%), 일사량은 650건(약 7.26%), 클로로필 a는 1,300건(약 14.52%)이 결측으로 나타났다. 본 연구는 전처리 기반 대체 대신 불규칙 관측 간격을 직접 처리하는 PhasedLSTM의 Time Gate 메커니즘을 병행하여 정보 손실을 구조적으로 완화하였다. 한편 클래스 불균형 문제를 완화하기 위해 SMOTE와 같은 오버샘플링 기법이 사용되기도 하지만 시계열 기반 환경 데이터에서는 인위적인 샘플 생성이 시공간적 연속성을 훼손할 가능성이 있다. 따라서 본 연구에서는 데이터 증강 대신 손실 함수 가중치 기반 접근을 적용하였다. 또한 시계열 데이터의 특성을 고려하여 데이터 분할 과정에서 시간 순서를 유지하였다. 전체 데이터는 관측 시점을 기준으로 80:10:10의 비율에 따라 훈련(Train), 검증(Validation), 테스트(Test) 세트로 분할되었다. 세부적으로는 훈련 세트 8,313개, 검증 세트 1,039개, 테스트 세트 1,040개를 각각 할당하였으며 이는 과거 데이터를 학습하여 미래 시점을 예측하는 실제 운영 환경에서의 일반화 성능을 검증하기 위함이다. 이는 미래 시점의 정보가 학습 과정에 유입되는 미래 정보 누수(Temporal Leakage)를 방지하기 위해 무작위 분할(Random Split)은 사용하지 않았다. 이러한 시간 기반 분할 방식은 실제 예측 환경에서의 일반화 성능을 보다 현실적으로 평가하기 위한 목적이

Table 2. Geographic Region Mapping Table

Region	Mapping	Region	Mapping
양양남대천하구	양양	강구	영덕
여수신, 여자만, 전주포, 가막만, 광양죽랑	여수	거진, 고성자란안	고성
죽변, 영일만, 포항구, 포항신	포항	구룡포	포항
거제도, 옥포, 장승포	거제	남해	남해
온산, 울산매암	울산	대천	보령
조천, 표선, 한림, 대정, 서귀포, 성산포	제주	섬진강하구, 광양망덕, 초남, 광양만	광양
주문진, 강릉남대천하구	강릉	속초	속초
진주만, 삼천포	사천	신안	신안
통영신, 통영외안, 진해안, 삼덕	통영	인천용도	인천
태안, 천수만, 대산	서산	마산	창원
축산, 삼척오십천하구	삼척	영산목포	목포
가로림만	태안	금강하구	군산
감천, 기장, 다대포, 대변, 부산 수영, 부산진, 신항, 낙동	부산	천수만	천수만
감포	경주	-	-

다. 또한 시계열 데이터의 시간적 종속성을 고려하여 일반적인 k -fold 교차검증은 적용하지 않았다. 무작위 교차검증 방식은 미래 시점의 정보가 학습 데이터에 포함될 가능성이 있어 시계열 예측 문제에서 정보 누수(data leakage)를 유발할 수 있다. 따라서 실제 예측 환경과 유사한 평가를 위해 시간 기반 데이터 분할 방식을 사용하였다.

IV. Proposed Methodology

1. Problem Definition

본 연구에서 목표로 한 31개 지역의 적조 발생 여부 예측 문제는 관측일자 $t \in T$, 권역 $r \in R$ 별 적조 발생 여부 $y_{t,r} \in \{0, 1\}$ 로 정의된다.

2. Model Architecture

본 연구에서 제안한 모델은 GOCI에서 추출한 NDVI 컬러맵 이미지 데이터와 적조 관련 수치형 데이터를 입력으로 받아, 별개의 모듈로 처리한 후 특징 융합 모듈을 통해 단일 표현을 생성한다. 전체 구조는 Fig. 1.과 같이 시공간 특징 추출을 맡는 ConvLSTM, 비동기 시계열 처리를 담당하는 PhasedLSTM, 멀티모달 융합을 구현하는 Cross Attention 모듈로 구성되며 최종적으로 Multi-Head Structure를 통해 각 지역에 대한 예측 결과를 개별적으로 출력한다. 적조 발생은 해류 이동, 수온 변화, 플랑크톤 증식 등 다양한 해양 환경 요인의 복합적인 상호작용에 의해 발생하는 시공간적 현상이다. 위성 영상에서는 적조 분

포의 공간적 패턴이 나타나며, 해양 환경 수치 데이터는 시간에 따라 변화하는 시계열 특성을 갖는다. 이러한 특성을 동시에 반영하기 위해 본 연구에서는 위성 영상의 시공간 특징을 효과적으로 학습할 수 있는 ConvLSTM 구조를 적용하였다. 또한 해양 환경 관측 데이터의 불규칙한 시계열 구조와 비동기적인 동적 변화를 모델링하기 위해 PhasedLSTM을 사용하였다. PhasedLSTM은 Time Gate 메커니즘을 통해 불규칙한 시간 간격을 갖는 시계열 데이터를 처리하도록 설계된 순환 신경망 구조이다. 일반적인 LSTM은 일정한 시간 간격의 입력을 가정하지만 PhasedLSTM은 시간 게이트를 통해 특정 시간 구간에서만 상태 업데이트가 이루어지도록 설계되어 불규칙한 관측 간격을 갖는 데이터에 보다 적합한 구조를 갖는다. 이후 두 데이터 표현 간의 상호 의존성을 학습하기 위해 Cross Attention 기반 융합 구조를 적용하였으며, 지역별 해양 환경 특성을 반영하기 위해 Multi-Head 구조를 통해 각 해역에 대한 예측 결과를 개별적으로 출력하도록 설계하였다.

또한 데이터 불균형 문제를 완화하기 위해 본 연구에서는 양성 클래스 가중치(pos_weight)를 적용한 가중치 기반 BCE(Binary Cross Entropy)를 사용하였다. pos_weight는 수식 9와 같이 전체 데이터에서 비적조 클래스 샘플 수를 적조 클래스 샘플 수로 나누어 산출하였으며 실제 학습에 사용된 값은 86.1274였다. 이는 적조 클래스의 손실 기여도를 상대적으로 증가시켜 희소한 적조 패턴에 대한 학습을 강화하기 위한 설정이다.

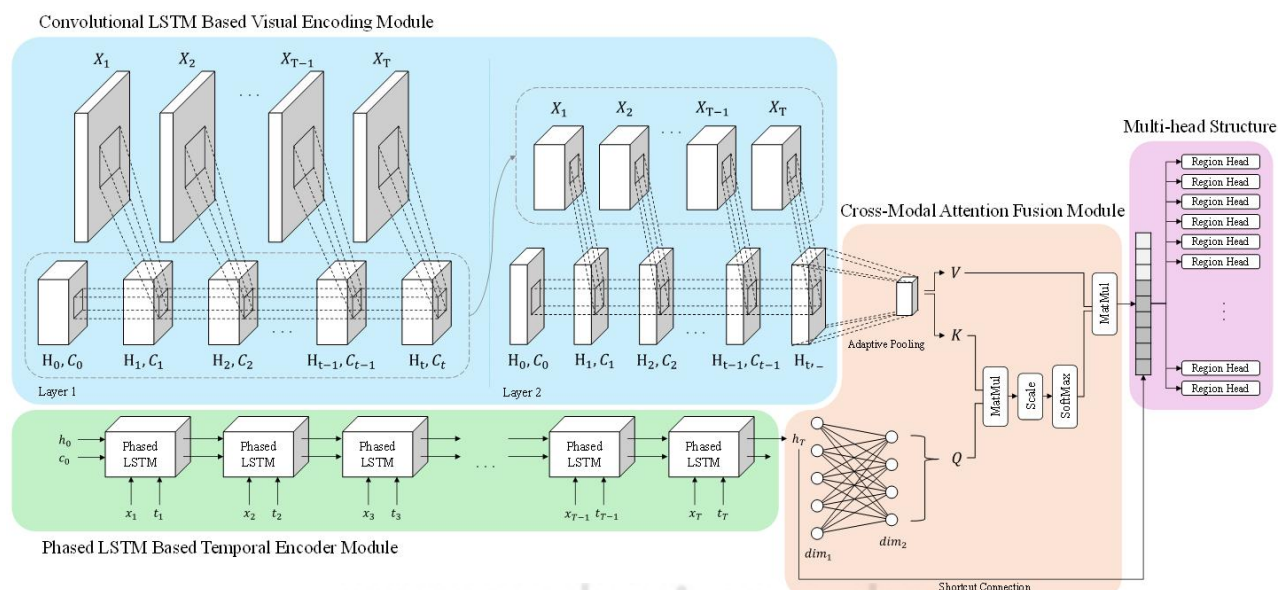


Fig. 1. Overview of the Multimodal AI Model for Red Tide Prediction

$$pos_weight = \frac{N_{negative}}{N_{positive}} \quad (9)$$

2.1 ConvLSTM Based Visual Encoding Module

본 연구에서는 ConvLSTM을 적용한 영상 처리 모듈을 설계하여 해석별 분포와 같은 공간 구조와 시계열 변동을 동시에 반영하는 적조 예측 모델을 구성하였다. 본 모듈은 시점별 입력 영상 특징과 이전 은닉상태를 결합한 뒤 합성곱 기반 게이트 연산을 통해 상태를 갱신함으로써 공간 인접성을 보존한 상태에서 시간축 정보를 누적한다. 이러한 처리 흐름은 Fig. 2.의 수도코드에 제시하였다. 이는 시점별 수치만을 입력으로 하는 순환 모델에 비해 공간적 인접성에 의존하는 발생·확산 패턴을 더 일관되게 포착하도록 한다.

Algorithm 1 ConvLSTM

Input : $X \in \mathbb{R}^{B \times T \times C_m \times H \times W}$
Output : $H_{1:T} \in \mathbb{R}^{B \times T \times C_h \times H \times W}$

1. $(H_0, C_0) \leftarrow (0, 0)$
2. **for** $t \leftarrow 1$ to T **do**
3. $Z_t \leftarrow \text{Concat}_{chan}(X_t, H_{t-1})$
4. $(\Gamma_i, \Gamma_f, \Gamma_o, \Gamma_g) \leftarrow \text{Split}(\text{Conv2D}(Z_t), 4)$
5. $i_t \leftarrow \sigma(\Gamma_i), f_t \leftarrow \sigma(\Gamma_f)$
6. $o_t \leftarrow \sigma(\Gamma_o), g_t \leftarrow \tanh(\Gamma_g)$
7. $C_t \leftarrow f_t \odot C_{t-1} + i_t \odot g_t$
8. $H_t \leftarrow o_t \odot \tanh(C_t)$
9. **end for**
10. **return** $H_{1:T}$

Fig. 2. A Pseudo Code of ConvLSTM

각 시점에서 합성곱 기반 게이트 연산으로 은닉/셀 상태를 갱신하고, 이를 시간축으로 누적하여 영상 시퀀스의 시공간 표현을 형성한다.

2.2 PhasedLSTM Based Temporal Encoder Module

본 연구에서는 결측률이 높고 관측 공백이 잦은 수치 시계열을 처리하기 위해 PhasedLSTM을 적용한 시계열 처리 모듈을 설계하였다. 본 모듈은 시간 게이트 k_t 를 통해 특정 시점에서만 상태 업데이트를 활성화하고 그 외 구간에서는 이전 상태를 유지함으로써 불규칙 샘플링과 이벤트성 입력이 혼재한 상황에서도 수렴 안정성과 계산 효율을 동시에 확보하도록 구성된다. 이러한 처리 흐름은 Fig. 3.의 수도코드에 제시하였다.

Algorithm 2 PhasedLSTM

Input : $X \in \mathbb{R}^{B \times T \times D}$, (optional) timestamps t_t
Output : $h_T \in \mathbb{R}^{B \times H}$ (or $H_{1:T}$)

1. $(h_0, c_0) \leftarrow (0, 0), \tau \leftarrow \exp(\tau_{param}), r_{on} \leftarrow \sigma(r_{on}), s \leftarrow \sigma(s)$
2. **for** $t \leftarrow 1$ to T **do**
3. $time \leftarrow (t-1)$ or t_t
4. $\Phi \leftarrow fmod(time - s \odot \tau, \tau) / \tau$
5. $k_t \leftarrow \begin{cases} \frac{\Phi}{r_{on}}, & 0 \leq \Phi < r_{on} \\ ((\Phi - r_{on}) / (1 - r_{on})) \cdot 0.1, & \text{else} \end{cases}$
6. $(i, f, g, o) \leftarrow \text{LSTM_Gates}(X_t, h_{t-1})$
7. $\tilde{c}_t \leftarrow f \odot c_{t-1} + i \odot g$
8. $c_t \leftarrow k_t \odot \tilde{c}_t + (1 - k_t) \odot c_{t-1}$
9. $h_t \leftarrow k_t \odot (o \odot \tanh(c_t)) + (1 - k_t) \odot h_{t-1}$
10. **end for**
11. **return** h_T (or $H_{1:T}$)

Fig. 3. A Pseudo Code of PhasedLSTM

각 시점에서 시간 게이트 k_t 를 계산한 뒤 후보 상태 갱신을 k_t 로 혼합하여 관측 공백 구간에서의 불필요한 상태 변동을 억제한다.

2.3 Cross-Modal Attention Fusion Module

Fig. 4.과 같이 최종 융합 표현 $z_i = [q_i; c_i] \in \mathbb{R}^{H_n + E}$ 는 이후 분류기 또는 다중 헤드 예측 구조에 전달되어 두 모달리티에서 얻은 상호보완적 정보를 반영한 적조 발생 확률을 산출하게 된다.

Algorithm 3 Cross Attention

Input : $q \in \mathbb{R}^{B \times D_q}, v \in \mathbb{R}^{B \times D_v}$
Output : $c \in \mathbb{R}^{B \times d}$

1. $Q \leftarrow qW_Q, K \leftarrow vW_K, V \leftarrow vW_V$
2. $\alpha \leftarrow \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)$ (single-token $\Rightarrow \alpha = 1$)
3. $c \leftarrow \alpha V$
4. **return** c

Fig. 4. A Pseudo Code of Cross Attention

2.4 Multi-Head Structure

최종 융합 표현은 각 지역별 헤드로 분기된다. 헤드 간 가중치를 공유하지 않음으로써 권역별 특성을 반영한 독립적 결정을 수행하며 ReLU와 Dropout을 포함한 개별 구조를 통해 적조 발생 여부를 출력한다. 학습 시에는 약 1.1%의 극심한 데이터 불균형을 고려하여 가중치 기반 이진 교차 엔트로피(Weighted BCE: B) 손실함수를 사용한다. 구체적으로 수식 9에 대해 수식 10으로 정의하며 양성 표본의 기여를 확대하기 위해 $w_+ \gg w_-$ 로 설정한다.

$$y_i \in \{0, 1\}, \hat{p}_i = \sigma(z_i) \quad (10)$$

$$B = -\frac{1}{N} \sum_{i=1}^N (w + y_i \log(\hat{p}_i) + w - (1 - y_i) \log(1 - \hat{p}_i)) \quad (11)$$

최적화는 1, 2차 모멘트 추정 기반의 Adam 알고리즘을 적용하여 안정적인 수렴 속도를 확보한다.

3. Experimental Setup and Hyperparameter Tuning

제안 모델의 전체 학습 가능 파라미터 수는 총 1,435,936개이며 구체적으로는 시공간 특징 추출을 위한 ConvLSTM에 265,344개, 시계열 처리를 위한 PhasedLSTM에 273,152개가 할당되었다. 또한 모달리간 융합을 담당하는 Cross Attention은 41,344개, 지역별 특성을 반영하는 출력 헤드는 856,096개의 파라미터로 구성되어 있다. 또한 실제 운영 환경에서의 효율성을 검증하기 위해 추론 시간을 측정할 결과 Batch size 4 기준 $27,662 \pm 1,108$ ms/batch를 기록하였다.

본 연구의 실험을 위해 구성된 환경은 Table 3.와 같다.

Table 3. Experimental Environment Specifications

Category	Specification
CPU	Intel Core i9-12900K @ 3.2 GHz
Logical Processors	24 Threads
RAM	64 GB
GPU	NVIDIA GeForce RTX 3090
VRAM	24 GB
Operating System	Microsoft Windows 11 Pro
Development Environment	Python 3.10.18 PyTorch 2.8.0+cu126

모델 학습에 사용된 주요 하이퍼파라미터와 학습 설정은 다음과 같이 설정하였다.

Table 4. Hyperparameters and Experimental Settings

Category	Value
Batch size	4
Learning rate	5×10^{-5}
Epochs	100
Optimizer	Adam
Adam β_1	0.9
Adam β_2	0.999
Adam ϵ	$1e-8$
Random seed	Not fixed
Number of Parameters	1,435,936

본 연구에서 실험 수행 시 random seed를 별도로 고정하지 않았다. 데이터 분할은 학습 데이터(Train set), 검증 데이터(Validation set), 평가 데이터(Test set)로 구성되며 Validation set은 모델의 하이퍼파라미터 및 임계값

(threshold) 설정을 위한 기준으로 사용되었다. 최종 성능 평가는 학습 과정에 사용되지 않은 Test set을 통해 수행하였다.

V. Research Results

적조는 발생이 비주기적인 자연 현상이므로 예측 모델에서 데이터 불균형 문제는 필연적으로 발생한다. 이로 인한 클래스 불균형은 모델의 성능을 왜곡해서 평가될 수 있다. 단순히 전체 정확도(Accuracy)만을 지표로 사용하면 모델이 다수인 비적조 클래스만 예측하더라도 수치상 높은 성능을 보일 수 있다. 따라서 정밀도(Precision), 재현율(Recall), F1-score와 같은 다각적인 지표를 우선적으로 고려해야 한다[16]. 기존 문헌에서는 일부 비교 모델에 대해 Accuracy만 보고되고 Precision, Recall, F1-score는 제시되지 않은 경우가 있었다. 이에 해당 비교 모델들을 동일한 데이터셋과 평가 조건에서 직접 재실험하여 Accuracy뿐만 아니라 Precision, Recall, F1-score를 모두 산출하였고 이를 비교표에 반영함으로써 지표 누락 문제를 보완하였다.

Table 5. Performance comparison of red tide occurrence prediction models

Research	Models	F1-score	Pre	Recall	Acc
Ours	Multimodal	0.72	0.64	0.82	0.99
[11]	BPNN	0.17	0.12	0.31	0.75
	GRNN	0.15	0.11	0.28	0.78
	SVM	0.21	0.16	0.35	0.86
[13]	LSTM	0.574	0.405	0.96	0.89
[14]	Random Forest SVM	0.63	0.64	0.63	0.98

제안된 모델을 독립 검증 세트로 평가한 결과, F1-score 0.72를 기록하며 Table 5.와 같이 기존 LSTM 모델 대비 약 0.15 이상의 성능 향상을 보였다. 이는 NDVI 위성 영상과 해양 수치 자료를 통합한 멀티모달 구조가 단일 시계열 모델보다 적조 발생의 복합 메커니즘을 더 효과적으로 반영함을 입증한다.

기존 U-Net 등 픽셀 기반 모델은 사후 탐지(Detection)에 특화되어 미래 예측(Forecasting)이 어렵다는 한계가 있으나 본 모델은 ConvLSTM, PhasedLSTM, Cross Attention을 결합해 시공간 패턴과 환경 변동성을 동시에 학습함으로써 선제적 경보가 가능하다. 결과적으로 제안 모델은 기존 예측 모델 대비 성능 개선과 실무적 실효성을 동시에 달성하였다.

Table 6. Representative Cases of Red Tide Occurrence Prediction on the Test Set

Date	Station Name	Ground Truth	Predicted Probability	Final Prediction	Case Type
2020-08-14	진해만	1	0.9132	1	TP
2020-08-21	통영연안	0	0.8441	1	FP
2020-09-02	고성만	1	0.4723	0	FN
2020-09-07	광양만	0	0.0312	0	TN

제안 모델은 실제 관측 데이터에 대해 높은 신뢰도의 추론 결과를 보였다. 2020년 8월 14일 진해만 사례에서는 0.9132의 높은 확률로 적조 발생을 정확히 예측(True Positive)하였으며 9월 7일 광양만 사례에서도 0.0312의 낮은 확률로 비발생 상황을 안정적으로 판별(True Negative)하였다. 반면 8월 21일 통영 연안의 오경보(False Positive, 0.8441) 및 9월 2일 고성만의 미탐지(False Negative, 0.4723) 사례는 해양 환경의 극심한 비선형성과 변동성으로 인한 예측의 난이도를 보였다. 이러한 개별 증례 분석은 제안 모델이 단순 수치를 넘어 실제 해양의 복잡한 상황에 유의미하게 반응하고 있음을 나타낸다.

1. Ablation Study

본 연구에서는 제안하는 멀티모달 프레임워크의 구조적 타당성과 각 구성 요소의 기여도를 검증하기 위해 소거 실험(Ablation Study) 및 비교 실험을 수행하였다.

먼저 멀티모달 융합 구조의 실효성을 정량적으로 입증하고자 단일 모달리티만을 활용한 소거 실험을 진행하였다. 실험 결과 수치 데이터 기반의 PhasedLSTM만을 사용했을 때의 F1-score는 0.37, 위성 영상 기반의 ConvLSTM만을 사용했을 때의 F1-score는 0.08을 기록하였다. 이는 단일 데이터 소스만으로는 복잡한 해양 환경 변화와 적조 발생 기전을 충분히 설명하기에 한계가 있음을 나타낸다. 반면 두 모달리티를 유기적으로 결합한 제안 모델은 0.72의 F1-score를 달성하였으며 이는 개별 모듈 대비 성능을 대폭 향상시킨 결과로 모달리티 간의 시너지 효과를 증명한다.

또한 제안 모델의 주요 구성 요소가 예측 성능에 미치는 영향을 확인하기 위해 추가적인 비교 실험을 수행하였다. 먼저 시계열 인코더로 일반 LSTM을 사용할 경우, 정밀도(Precision)는 0.31, 재현율(Recall)은 0.74, F1-score가 0.44로 나타나 제안 모델에 비해 낮은 성능을 보였다. 이는 PhasedLSTM이 불규칙한 관측 간격을 갖는 시계열 데이터에 대해 보다 안정적인 학습이 가능함을 확인하였다.

그리고 위성 이미지 데이터로 RGB를 사용할 경우, 정밀도(Precision)는 0.48, 재현율(Recall)은 0.54, F1-score가 0.51로 NDVI 기반 입력을 사용하는 경우보다 낮은 성능을 보였다. 이러한 결과는 NDVI가 엽록소 기반 분광 특성을 반영하여 적조 발생과 관련된 해양 환경 변화를 보다 효과적으로 표현할 수 있음을 의미한다.

VI. Conclusions

본 연구는 위성 영상의 시공간 변동성을 반영하는 ConvLSTM과 불규칙한 수치 데이터에 최적화된 PhasedLSTM을 통합한 멀티모달 적조 예측 모델을 제안하였다. 특히 Cross attention 메커니즘과 멀티 헤드 구조를 적용하여 국내 31개 해역의 지역적 특성을 반영하도록 설계하였다. 실험 결과, 제안 모델은 F1-score 0.72를 기록하며 기존 LSTM 모델(0.574) 대비 약 0.15의 성능이 향상되었다. 이는 실시간 탐지에 국한된 기존 픽셀 기반 모델들과 달리 미래 시점의 예측이 가능하다는 점에서 실무적 의사결정 지원에 차별화된 강점을 가진다.

본 연구는 위성 영상과 해양 수치 데이터를 결합한 멀티모달 기반 적조 예측 모델을 제안하였으나 몇 가지 한계를 가진다. 먼저 적조 발생 데이터의 비율이 전체 데이터에 비해 매우 낮은 불균형 구조를 가지므로 향후 더 다양한 적조 사례 데이터를 확보하는 것과 함께 클래스 가중치 조정, 오버샘플링, 언더샘플링, Focal Loss 등 다양한 불균형 대응 전략을 적용한 비교 연구가 필요하다. 그리고 연구에서 확인된 일부 해양 수치 데이터의 높은 결측률 문제를 근본적으로 해결하기 위해 관측 단계에서부터 데이터 손실을 최소화할 수 있는 안정적인 실시간 해양 관측 환경 구축과 데이터 무결성 확보를 위한 시스템적 보완이 병행되어야 한다. 또한 NDVI 기반 위성 영상을 주요 영상 입력으로 사용하였으나 향후 Chlorophyll-a와 같은 해양 특화 분광 지수를 함께 활용하면 더욱 정밀한 적조 예측이 가능할 것으로 기대된다. 마지막으로 특정 해역 데이터를 기반으로 모델을 학습하였으므로 향후 다양한 해역 데이터에 대한 일반화 성능 검증이 필요하다.

결론적으로 본 연구는 복합 해양 데이터를 활용한 고성능 예측 체계를 구축함으로써 향후 실질적인 적조 예보 및 예방 정책 수립을 위한 핵심적인 기술 기반을 마련하였다. 향후 연구에서는 제안 모델의 실제 적용 가능성을 높이기 위해 위성 영상과 해양 수치 데이터를 실시간으로 수집·처리하고, 예측 결과를 경보 및 의사결정 지원에 연계하는

실시간 적조 예측 시스템으로 확장할 필요성이 있다. 또한 다양한 적조 사례 데이터 확보와 함께 다양한 해역 데이터에 대한 일반화 성능을 검증하고 클래스 불균형 문제를 완화하기 위한 여러 대응 전략의 효과를 비교·분석함으로써 실제 해양 환경에 적용 가능한 적조 예측 모델로 발전시킬 필요가 있다.

REFERENCES

- [1] H. G. Lee, J. S. Park, and S. S. Kim, "Analysis of Environmental Factors Affecting the Outbreak of *Cochlodinium polykrikoides* Blooms," *Journal of the Korean Society of Marine Environment & Safety*, Vol. 24, No. 7, pp. 813-821, December 2018. DOI: 10.7837/kosomes.2018.24.7.813
- [2] T. Baltrušaitis, C. Ahuja, and L.-P. Morency, "Multimodal machine learning: A survey and taxonomy," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 41, No. 2, pp. 423-443, February 2019. DOI: 10.1109/TPAMI.2017.2754907
- [3] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W.-C. Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," in *Proceedings of the Advances in Neural Information Processing Systems (NeurIPS)*, pp. 802-810, Montreal, Canada, December 2015. DOI: 10.5555/2969239.2969329
- [4] D. Neil, M. Pfeiffer, and S.-C. Liu, "Phased LSTM: Accelerating recurrent network training for long or event-based sequences," in *Proceedings of the Advances in Neural Information Processing Systems (NeurIPS)*, pp. 3882-3890, Barcelona, Spain, December 2016. DOI: 10.5555/3157382.3157524
- [5] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, "Attention is all you need," in *Proceedings of the Advances in Neural Information Processing Systems (NeurIPS)*, pp. 5998-6008, Long Beach, USA, December 2017. DOI: 10.5555/3295222.3295480
- [6] J. Shin, Y.-H. Jo, J.-H. Ryu, B.-K. Khim, and S. M. Kim, "High Spatial-Resolution Red Tide Detection in the Southern Coast of Korea Using U-Net from PlanetScope Imagery," *Sensors*, Vol. 21, No. 13, pp. 4447, June 2021. DOI: 10.3390/s21134447
- [7] Y. Han, T. Ding, P. Cui, X. Wang, B. Zheng, X. Shen, Z. Ma, Y. Zhang, H. Pan, and S. Yang, "Red Tide Detection Method Based on Improved U-Net Model-Taking GOCI Data in East China Sea as an Example," *Sensors*, Vol. 23, No. 22, p. 9195, November 2023. DOI: 10.3390/s23229195
- [8] C. Schloer and R. Hänsch, "Harmful Cyanobacterial Bloom Detection using Deep Learning and Sentinel-2 Imagery," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, pp. 1-11, 2025. DOI: 10.1109/JSTARS.2025.1234567
- [9] K. Phetanan et al., "SAR Remote Sensing for Monitoring Harmful Algal Blooms Using Deep Learning Models," *Remote Sensing Letters*, pp. 1-10, 2025. DOI: 10.1080/15481603.2025.2524202
- [10] S. H. Park, H. M. Kim, B. G. Kim, D. H. Hwang, E. U. Unzaya, and H. J. Yoon, "A study on detection techniques for *Cochlodinium polykrikoides* red tide using logistic regression and decision tree models," *Journal of the Korea Institute of Electronic Communication Sciences*, Vol. 13, No. 4, pp. 777-786, August 2018. DOI: 10.13067/JKIECS.2018.13.4.777
- [11] S. Park, K. Kim, J. Lee, and S. Lee, "Prediction of red tide occurrence using neural networks and SVM," *IEIE Transactions on Smart Processing*, Vol. 48, No. 5, pp. 39-45, May 2011. DOI: 10.5573/ieek.2011.48.5.039
- [12] M. Park, N. Kim, B. Kim, and H. Yoon, "A comparative study of machine learning models for red tide detection," *Journal of the Korea Institute of Electronic Communication Sciences*, Vol. 16, No. 6, pp. 1363-1372, December 2021. DOI: 10.13067/JKIECS.2021.16.6.1363
- [13] H. Kim, T. Kim, and G. Son, "Analysis of domestic ocean data for red tide prediction," *Proceedings of the JOISS Ocean Science Big Data Utilization Competition*, pp. 45-50, Busan, South Korea, 2021.
- [14] W. U. A. Rathore, J. Ni, C. Ke, and Y. Xie, "BloomSense: Integrating Automated Buoy Systems and AI to Monitor and Predict Harmful Algal Blooms," *Water*, Vol. 17, No. 11, p. 1691, June 2025. DOI: 10.3390/w17111691
- [15] National Ocean Satellite Center, <https://nosc.go.kr/main.do>.
- [16] J. M. Johnson and T. M. Khoshgoftaar, "Survey on deep learning with class imbalance," *Journal of Big Data*, Vol. 6, No. 1, pp. 1-54, March 2019. DOI: 10.1186/s40537-019-0191-5

Authors



Jaehee Lee is currently an undergraduate student in the Division of Artificial Intelligence at Kongju National University, Korea, and in his third year of the B.S. program.

Jaehee Lee has been studying as an undergraduate researcher at the AI Security Lab in the Division of Artificial Intelligence at Kongju National University, Korea, since 2025. His research interests include AI for Marine Science and AI Security.



Junhyuk Park is currently an undergraduate student in the Division of Artificial Intelligence at Kongju National University, Korea, and in his fourth year of the B.S. program.

Junhyuk Park has been studying as an undergraduate researcher at the AI Security Lab in the Division of Artificial Intelligence at Kongju National University, Korea, since 2024. His research interests include Natural Language Processing(NLP) and Audio Signal Processing.



Seungyong Seong is currently an undergraduate student in the Division of Artificial Intelligence at Kongju National University, Korea, and in his fourth year of the B.S. program.

Seungyong Seong has been studying as an undergraduate researcher at the DSDL Lab in the Division of Artificial Intelligence at Kongju National University, Korea, since 2025. His research interests include brain-computer interfaces(BCI) and biomedical signal processing.



Chaeun Seo is currently an undergraduate student in the Division of Artificial Intelligence at Kongju National University, Korea, and in her fourth year of the B.S. program.

Chaeun Seo has been studying as an undergraduate researcher at the AI Safety Lab in the Division of Artificial Intelligence at Kongju National University, Korea, since 2025. Her research interests include Computer Vision and AI Safety and Security.



Hyo-Beom Ahn received the B.S. in Computer Science and M.S., and Ph.D. in Computer Science and Statistics from Dankook University, Korea in 1992, 1994, 2002 respectively.

Dr. Ahn has been with the Department of Information and Telecommunication at Kongju National University since then, and since 2021, he has been affiliated with the Division of Artificial Intelligence at the same university. He is interested in Computer Networks, Network Security.