

National Ocean Satellite Center

Algorithm Theoretical Basis Document

준실시간 해수면온도

(Near Real-Time Sea Surface Temperature)

Version 1.0

해양수산부
국립해양조사원
Korea Hydrographic and Oceanographic Agency
Ministry of Oceans and Fisheries
Republic of Korea

목 차

1. 개요	1
1.1. 목적	1
1.2. 대상자	1
1.3. 내용요약	1
1.4. 문서 개정내역	1
1.5. 약어목록	2
2. 알고리즘 소개	3
2.1. 개요	3
2.2. 이론적 배경	3
2.3. 알고리즘 흐름도	5
2.4. 입력 자료	7
2.5. 산출물	8
3. 산출물 비교 및 검증	10
3.1. 비교 및 검증자료	10
3.2. 검증방법	10
3.3. 비교 및 검증결과 분석	11
4. 특이사항	16
5. 참고문헌	17
6. 부록	17

표 목 차

<표 1-1>	수정 이력	1
<표 1-2>	약어 설명	2
<표 2-1>	인공신경망 모델 설계 구조	4
<표 2-2>	해수면온도 위성합성장, 해양 수치모델, 인공지능(AI) 장·단점 비교	8
<표 2-3>	준실시간 해수면온도 메타정보	9
<표 3-1>	준실시간 해수면온도와 북서태평양 KHOA SST 비교 결과	11
<표 3-2>	OSTIA 해수면온도 자료와의 비교 결과('21-'24년)	14
<표 3-3>	국립해양조사원 조위관측소 해수면온도와의 비교	14

그림 목 차

[그림 2-1]	점진적 학습 전략 모식도	5
[그림 2-2]	점진적 학습 과정 예시('23년 12월 31일)	5
[그림 2-3]	준실시간 해수면온도 산출 과정	6
[그림 2-4]	해양 수치모델 자료 전처리 과정	6
[그림 2-5]	슬라이딩 윈도우를 적용한 타일링 처리	7
[그림 2-6]	산출 결과 비교 예시('25년 11월 11일)	8
[그림 3-1]	준실시간 해수면온도와 북서태평양 KHOA SST 공간 비교('21, '22년도)	12
[그림 3-2]	준실시간 해수면온도와 북서태평양 KHOA SST 공간 비교('23, '24년도)	12
[그림 3-3]	조위관측소 자료와의 산점도 비교	15
[그림 4-1]	유효해상도 비교 예시('21년 4월 16일)	16

1. 개요

1.1. 목적

본 알고리즘 설명서(Algorithm Theoretical Basis Document, ATBD)를 통해 준실시간 해수면온도(Near Real-Time Sea Surface Temperature, NRTSST) 자료의 산출 과정 및 검증 결과를 제공하고자 한다.

1.2. 대상자

본 설명서는 준실시간 해수면온도를 산출하기 위한 알고리즘의 이론적 배경과 구축 체계에 대한 정보를 제공한다. 구체적인 내용은 각 장에서 설명하고 있다.

1.3. 내용요약

본 설명서는 준실시간 해수면온도 알고리즘의 구축 체계에 대해 기술하였다. 1장에서는 목적, 대상자, 문서 개정내역 등 전반적인 개요에 대해 기술하였으며, 2장에서는 구축 배경 등에 관한 소개와 이론적 배경, 알고리즘 흐름도, 입력자료, 산출물 등 알고리즘에 대한 전반적인 소개를 작성하였다. 3장에서는 해당 알고리즘의 성능 비교 및 검증 결과에 대해 기술하였다. 4장, 5장, 6장은 특이사항 및 참고문헌, 부록에 대해 각각 기술하였다.

본 알고리즘은 국립해양조사원 국가해양위성센터에서 수행한 「2025년 해양위성정보 종합분석 및 활용지원」 사업의 일환으로 구축되었다. 본 알고리즘의 산출물은 연안 이상 수온의 조기 탐지, 해양 예보 시스템의 초기장 등 각종 연안·해양 활용 서비스에서 요구되는 시의성과 공간 연속성을 충족시킬 수 있을 것으로 기대된다.

1.4. 문서 개정내역

<표 1-1> 수정 이력

문서버전	수정내용	수정일	작성자
1.0	초안 작성	2025.12.05.	국가해양위성센터

1.5. 약어목록

<표 1-2> 약어 설명

약어	내용
ATBD	알고리즘 설명서 (Algorithm Theoretical Basis Document)
NRTSST	준실시간 해수면온도 (Near Real-Time Sea Surface Temperature)
SST	해수면온도 (Sea Surface Temperature)
OI	최적내삽법 (Optimum Interpolation)
KHOA SST	Korea Hydrographic and Oceanographic Agency Sea Surface Temperature
AI	인공지능 (Artificial Intelligence)
CNN	합성곱 신경망 (Convolutional Neural Network)
LSTM	장·단기 메모리 순환 신경망 (Long Short-Term Memory)
ReLU	Rectified Linear Unit
MSE	평균제곱오차 (Mean Squared Error)
Adam	Adaptive Moment Estimation
ESA	유럽우주국 (European Space Agency)
CMEMS	Copernicus Marine Environment Monitoring Service
NEMO	Nucleus for European Modeling of the Ocean
OSTIA	Operational Sea Surface Temperature and Ice Analysis
RMSE	평균 제곱근 오차 (Root Mean Squared Error)
UTC	협정 세계시 (Universal Time Coordinated)
MURSST	Multi-scale Ultra-high Resolution Sea Surface Temperature
ODYSSEA	Operating a network of integrated observatory systems in the Mediterranean Sea
R^2	결정계수 (coefficient of determination)

2. 알고리즘 소개

2.1. 개요

기존 해수면온도(Sea Surface Temperature, SST) 위성합성장은 다양한 국내·외 위성자료를 최적내삽법(Optimum Interpolation, OI) 기반으로 결합하여 산출된다(국립해양조사원, 2024; 박경애, 김영호, 2009). 통상적으로 D-2일 기준으로 산출되며, 이는 위성 간 관측 시간의 차이, 구름 등으로 인한 결측, 품질 검수를 위한 보정 절차 등 다양한 이유로 인해 불가피하게 발생하는 시차이다. 해수면온도 위성합성장은 여러 자료를 공통된 그리드로 통합하기 때문에 공간적 완전성과 품질 관리 측면에서 분명한 장점을 가진다(박경애, 김영호, 2009). 그러나 통상적으로 발생하는 시차는 연안 이상 수온 감시, 해양 재난 대응, 실시간 또는 준실시간 해양 모니터링 등 시의성이 중요한 분야에서 제약으로 작용한다. 이러한 문제를 개선하고자 준실시간 해수면온도 산출 체계를 구축하였다.

본 알고리즘은 기존의 해수면온도 위성합성장(Korea Hydrographic and Oceanographic Agency Sea Surface Temperature, KHOA SST)과 해양 수치모델 자료를 활용하는 인공지능(Artificial Intelligence, AI) 기반의 모형으로 구축되었다(정기준 등, 2024; 김의현 등, 2025). 제시한 AI 모형은 KHOA SST의 고해상도 관측 정보와 해양 수치모델의 연속적 SST 분포를 결합하여 두 자료 간 시·공간적 관계를 효과적으로 학습할 수 있었다(김의현 등, 2025).

본 알고리즘의 최종 목표는 KHOA SST, 해양 수치모델, AI 모형을 융합하여 기존 OI 기반 KHOA SST의 유효해상도(Effective resolution) 저하와 D-2일 수준의 시간 지연 한계를 보완하는 것이다. 이를 위해 국내·외 관측 및 다양한 해수면온도 위성합성장과 성능 비교·검증을 수행하였다. 이를 통해 준실시간 해수면온도 산출 체계의 실용성과 활용 가능성을 체계적으로 평가하고자 했다.

2.2. 이론적 배경


제시한 AI 모형은 합성곱 신경망(Convolutional Neural Network, CNN)의 공간 패턴 인식 능력과 장·단기 메모리 순환 신경망(Long Short-Term Memory, LSTM)의 시계열 처리 능력을 결합한 ConvLSTM 구조를 기반으로 한다(Shi *et al.*, 2015). ConvLSTM은 시간에 따라 변화하는 영상·격자 형태의 시·공간 자료를 처리하는 데 특화된 인공신경망이다. 각 시점의 공간 분포를 보존함과 동시에 연속된 시간 정보를 바탕으로 하여 예측이 가능하다(정시훈 등, 2020). 제시한 AI 모형은 은닉층(Hidden layer)에 3개의 ConvLSTM2D 레이어(layer)로 구성하였다. 각 레이어는 3×3 픽셀(pixel) 크기의 커널(kernel)과 32개의 필터(filter)를 사용하도록 구성하였다. 패딩(padding) 옵션은 'same'으로 적용하여 입력과 동일한 격자 크기를 유지하고자 했다. 각 ConvLSTM2D 레이어 뒤에는 Batch Normalization을 추가하여 학습 안정성과 수렴 속도를 향상시켰다. 은닉층의 활성화함수(Activation function)로는 ReLU(Rectified Linear Unit)을 사용하여 비선형성을 확보하였고, 최종 출력층에는 선형(linear) 활성화함수를 적용하여 연속형 SST를

예측하는 회귀 문제로 정식화하였다. 손실함수는 평균제곱오차(MSE, Mean Squared Error)를 사용하였으며, 최적화 알고리즘으로는 ‘Adam(Adaptive Moment Estimation)’을 채택하여 학습 효율과 성능을 동시에 확보하였다(<표 2-1>).


<표 2-1> 인공신경망 모델 설계 구조

레이어 타입	출력 크기	파라미터 수
input_1 (InputLayer)	[(None, 7, 64, 64, 1)]	0
sequential (Sequential)	multiple	0
conv_lstm2d (ConvLSTM2D)	[(None, 7, 64, 64, 32)]	105,728
batch_normalization (BatchNormalization)	[(None, 7, 64, 64, 32)]	128
conv_lstm2d_1 (ConvLSTM2D)	[(None, 7, 64, 64, 32)]	204,928
batch_normalization_1 (BatchNormalization)	[(None, 7, 64, 64, 32)]	128
conv_lstm2d_2 (ConvLSTM2D)	[(None, 7, 64, 64, 32)]	204,928
batch_normalization_2 (BatchNormalization)	[(None, 7, 64, 64, 32)]	128
conv_lstm2d_3 (ConvLSTM2D)	[(None, 64, 64, 1)]	3,304
- Total params : 519,272 - Trainable params : 519,080 - Non-trainable params : 192 - 출력층 : Linear Activation Function - 손실함수 : 평균제곱오차(MSE, Mean Squared Error)		

AI 모형의 안정적 수렴과 일반화 성능 향상, 그리고 학습 효율 제고를 위해 두 단계의 점진적 학습 전략을 적용하였다([그림 2-1], [그림 2-2]). 첫 번째 단계인 초기학습(spin-up training)은 SST의 장기 평균 패턴과 계절 변동성 등 거시적 구조를 우선적으로 학습하는 과정이다. 이 단계에서는 모델이 전체적인 시·공간 분포 특성을 안정적으로 파악하는 데 중점을 두었다. 두 번째 단계인 전이학습(transfer learning)은 초기학습에서 얻은 가중치를 초기값으로 사용하여 국지적 SST 특성과 소규모·단기 변동성을 세밀하게 학습하도록 미세조정(fine-tuning)하는 과정이다. 이를 통해 (1) 초기 불안정 가중치 문제를 완화하고, (2) 과적합(over-fitting)을 줄이며, (3) 불필요한 계산 비용을 절감하는 효과를 얻고자 했다.



[그림 2-1] 점진적 학습 전략 모식도

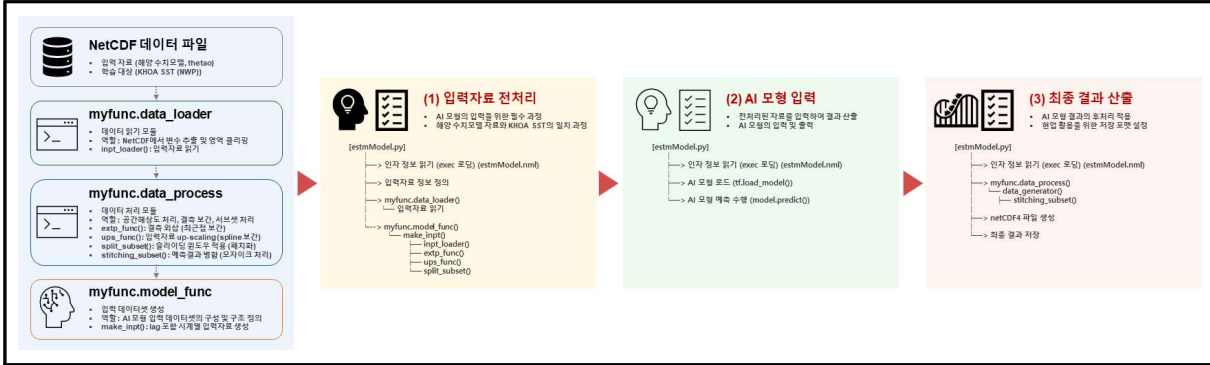


[그림 2-2] 점진적 학습 과정 예시('23년 12월 31일)

2.3. 알고리즘 흐름도


준실시간 해수면온도의 산출 과정은 다음과 같이 구성하였다([그림 2-3]). 첫 번째 과정은 학습된 AI 모형의 입력 자료로 활용하기 위한 해양 수치모델 자료의 전처리

과정이다. 해양 수치모델 자료는 AI 모형의 학습 대상인 KHOA SST 공간해상도와 상이하기 때문에 입력 자료로 활용하기 위한 전처리 과정이 필수적이다. 전처리된 해양 수치모델 자료는 AI 모형에 입력하기 위해 시·공간 차원에 ‘슬라이딩 윈도우(Sliding window)’ 기법을 적용하였다. 두 번째 과정은 해당 자료를 AI 모형에 입력하여 KHOA SST에 근사한 결과를 산출하는 과정이다. 마지막으로 산출된 결과에 모자이크 기법을 적용하여 최종적인 준실시간 해수면온도를 산출하게 된다.



[그림 2-3] 준실시간 해수면온도 산출 과정

해양 수치모델 자료의 전처리는 KHOA SST와 격자·공간해상도를 통일하여 두 자료의 시·공간 정보가 AI 모형에 일관되도록 입력하는 과정이다([그림 2-4]). 해당 과정은 최근접(nearest-neighbor) 방법을 적용하여 KHOA SST와 동일하도록 재매핑(re-mapping)하였다. 이때 해안선 주변의 육지 마스킹도 최근접 값으로 채움으로써 경계면에서의 인공적인 불연속을 줄이고자 하였다. ‘슬라이딩 윈도우’ 기법을 적용하는 과정은 SST의 시·공간 패턴 인식 성능을 강화하기 위한 과정이다. 공간 차원에서는 64 × 64 픽셀 단위로 영상을 타일링(tiling)하였고, 윈도우 간격(stride)에 따라 중첩되도록 구성하여 국지적인 세부 구조를 보존하면서도 원시 자료의 공간해상도를 동시에 확보하고자 했다([식 2-1, 식 2-2]). 시간 차원에서는 D-6일부터 D-0일까지 7일 길이의 시퀀스(sequence)를 구성하여 AI 모형이 시간에 따른 SST 변화를 인식하도록 설계하였다.




[그림 2-4] 해양 수치모델 자료 전처리 과정

$$n_i = \left\lfloor \frac{n_{cols} - window_size}{moving_stride} \right\rfloor + 1 \quad [식\ 2-1]$$

$$n_j = \left\lfloor \frac{n_{rows} - window_size}{moving_stride} \right\rfloor + 1 \quad [식\ 2-2]$$

AI 모형의 산출 과정은 Python 3.8.13 환경에서 TensorFlow 2.0을 기반으로 구현하였다. 고성능 GPU(NVIDIA RTX 4090 기준)를 사용하여 동아시아 영역에 대해 약 10분 이내의 결과를 산출할 수 있었다. 기존 동아시아 KHOA SST의 경우 D-2일 기준으로 약 90분 소요되는 것에 비해 산출 처리 속도가 크게 향상되었으며, 운용 효율성과 실시간성 측면에서 뚜렷한 장점을 보였다. 최종적인 결과를 산출하기 위해 타일링 결과를 중첩한 합계(summation) 지도와 가중치(weight) 지도를 계산하였고, 이 두 자료를 나누는 방식으로 모자이크 처리하였다([그림 2-5]).



[그림 2-5] 슬라이딩 윈도우를 적용한 타일링 처리

2.4. 입력 자료

준실시간 해수면온도를 산출하기 위해 유럽우주국(European Space Agency, ESA)의 CMEMS(Copernicus Marine Environment Monitoring Service)에서 제공하는 전구 해양 예측 자료를 입력 자료로 활용하였다. 해당 자료는 NEMO(Nucleus for European Modelling of the Ocean) 플랫폼 기반의 전구 해양 수치모델 결과로, $0.83^\circ \times 0.83^\circ$ 크기의 공간해상도를 가진다. AI 모형에 필요한 변수로는 일평균 표층 수온(thetao)를 활용하였다. 해양 수치모델은 해양 물리방정식을 바탕으로 3차원 해양 상태를 모의하고 구름의 영향을 받지 않는다는 장점이 있으나, 초기·경계 조건과 물리 모수화(parameter)에 민감하다는 한계가 있다. 반면, 해수면온도 위성합성장은 관측 기반으로 정밀도가 높지만 결측과 시간 지연 문제가 존재하므로, 두 자료는 상호 보완적인 장·단점을 가진다(<표 2-2>). 본 알고리즘은 이러한 상보성을 AI로 융합하여 보다 안정적이고 현실적인


준실시간 해수면온도를 산출하고자 했다.

<표 2-2> 해수면온도 위성합성장, 해양 수치모델, 인공지능(AI) 장·단점 비교

구분	해수면온도 위성합성장	해양 수치모델	인공지능(AI)
유형	관측기반 보간자료 (위성 + <i>in-situ</i>)	수치 시뮬레이션 예측	데이터 기반 예측
특성	- 일일 분석 자료(L4) - 결측 보간	- 해양 물리방정식 기반 3차원 해양상태 재현	- 시·공간 패턴 학습 - 결측 보간
장점	- 높은 정밀도 - 글로벌 커버리지 - 정규화된 그리드	- 해양 물리과정 내재 - 구름 영향 없음 - 타 변수와의 연동성	- 단기예측 성능 우수 - 위성 + 모델 통합 - 실시간 예측 가능
단점	- 기상 영향으로 결측 - 보간에 따른 왜곡 - 관측 시각 불일치 - 연안 품질 저하	- 초기·경계조건 민감 - 물리 파라미터화 오류 - 고성능 HPC 필요 - 국지적 특성 반영 ↓	- 학습 자료 의존 ↑ - 성능 일반화 문제
공간해상도	중-고해상도(1-5 km)	중해상도(1-12 km)	유동적
시간해상도	1일 / 6시간 단위	시간 단위	유동적
운영성	중간(통상 D-2일)	중간(모델연산, 자료동화)	높음(실시간)

2.5. 산출물

최종 산출물은 NetCDF4 형식으로 제공된다(<표 2-3>). 기존 동아시아 KHOA SST와 동일한 영역(위도 20-53°N, 경도 117-150°E) 및 공간해상도(1 km)로 당일(D-0일) 기준의 결과를 1일 1회 산출한다([그림 2-6]).



[그림 2-6] 산출 결과 비교 예시('25년 11월 11일)

<표 2-3> 준실시간 해수면온도 메타정보

메타정보	영문	정보
컨벤션	Convention	CF-1.8
위성명	platform	-
센서명(sensor)	instrument	-
타원체(Ellipsoid) 정보	geographic_element	WGS84
좌표참조시스템	geographic_crs_name	WGS84, EPSG:4326
좌표계 수평기준 정보	horizontal_datum_name	WGS84
표준시간	time_standard	UTC
위도 좌표 최소값	geospatial_lat_min	20.0
위도 좌표 최대값	geospatial_lat_max	53.0
경도 좌표 최소값	geospatial_lon_min	117.0
경도 좌표 최대값	geospatial_lon_max	150.0
위도 좌표 단위	geospatial_lat_units	degree
경도 좌표 단위	geospatial_lon_units	degree
사용된 슬롯번호	input_slots	-
사용슬롯수	number_of_total_slots	-
생산영역	dataset_area	Z003
입력자료	source	cmems_mod_glo_phy-thetao_anfc_0.083deg_PID-m
알고리즘명	algorithm	KHOA_NRTSST
처리 알고리즘 버전	algorithm_version	1.0
공간해상도	spatial_resolution	0.01
X 공간해상도	geospatial_lat_resolution	0.01
Y 공간해상도	geospatial_lon_resolution	0.01
시간해상도	temporal_resolution	1
공간해상도 단위	spatial_resolution_unit	degree
시간해상도 단위	temporal_resolution_unit	day
픽셀 수(X*Y)	number_of_pixel	3301*3301
커버리지 시작시간	time_coverage_start	2025-12-01T12:00:00Z
커버리지 종료시간	time_coverage_end	2025-12-01T12:00:00Z
산출물 생성 과정	history	Created using KHOA_NRTSST algorithm
산출물 생성 날짜	date_created	2025-12-01T09:00:00Z
산출물 이름	product_name	NRTSST
산출물 설명	title	Near Real-Time Sea Surface Temperature
산출물 파일명	product_file_name	KHOA_NRTSST_L4_Z003_D01_WGS001K_U20251201.nc
산출물 버전	product_version	1.0
산출물 레벨	processing_level	L4
사업명	project_name	Integrated Analysis and Application Support for Marine Satellite Data
배포처 홈페이지	publisher_url	http://www.nosc.go.kr
배포처	publisher_name	KHOA
배포기관 이메일	publisher_email	nosc@korea.kr
생산기관명	creator_name	KHOA
생산기관 홈페이지	creator_url	http://www.khoa.go.kr
생산기관 E-mail주소	creator_email	nosc@korea.kr
파일 포맷 버전	file_format_version	NetCDF 4.0
안내문	comment	-

3. 산출물 비교 및 검증

준실시간 해수면온도에 대한 성능 평가는 다음과 같이 네 가지 측면에 대해 수행하였다. 첫째, AI 모형의 학습·검증 기간에 대해 준실시간 해수면온도와 KHOA SST를 비교하여 검증 지표를 계산하였다. 이를 통해 학습된 AI 모형의 재현 성능을 정량적인 수치로 평가하고자 했다. 둘째, 국외 해수면온도 위성합성장인 OSTIA(Operational Sea Surface Temperature and Ice Analysis)를 기준으로 준실시간 해수면온도의 공간 분포를 비교하였다. 이를 통해 준실시간 해수면온도의 현업 활용 가능성을 평가하고자 했다. 셋째, 국립해양조사원 조위관측소 자료를 이용하여 지점별 성능 지표를 계산하였다. 이를 통해 연안에서의 성능을 평가하고자 했다. 마지막으로 KHOA SST와 준실시간 해수면온도의 평균 제곱근 오차(Root Mean Squared Error, RMSE) 차이에 대해 대응표본 t-검정을 수행하여 두 산출물 간 성능 차이의 통계적 유의성을 확인했다.

3.1. 비교 및 검증자료

본 알고리즘의 AI 모형은 북서태평양 영역 KHOA SST 자료를 이용하였고, 이 중 동아시아 영역만을 학습 대상으로 활용하였다. AI 모형의 학습을 위해 '21-'23년도 자료를 이용하였고, 검증은 '24년도 자료를 이용하였다.

연안에서의 성능 평가를 위해 국립해양조사원 조위관측소 자료를 이용하였다. KHOA SST의 기준 시점과 동일하게 협정 세계시(Universal Time Coordinated, UTC) 기준 정오(12시) 자료를 사용하였고, 총 51곳의 조위관측소 중 SST를 관측하는 34곳의 자료를 이용하였다. 더불어 국외 해수면온도 위성합성장인 OSTIA, MURSST(Multi-scale Ultra-high Resolution Sea Surface Temperature), ODYSSEA(Operating a network of integrated observatory systems in the Mediterranean Sea)와도 비교하여 준실시간 해수면온도의 성능을 검증하였다.

3.2. 검증방법

AI 모형의 재현 성능을 평가하고자 학습 및 검증 기간에 대한 RMSE와 결정계수(coefficient of determination, R^2) 등 기본적인 지표를 계산하였다. 해당 지표는 일일 자료를 대응하여 계산하였고, 연도별로 평균하여 차이를 비교하였다.

현업 활용 가능성을 평가하고자 OSTIA 자료를 이용하여 총 4가지 산출물(동아시아 영역 KHOA SST, 북서태평양 영역 KHOA SST, 준실시간 해수면온도, 해양 수치모델)에 대한 성능을 평가하였다. AI 모형의 재현 성능과 동일하게 일일 자료에 대한 성능 지표를 계산하였고, 이를 전체 기간('21-'24년도)에 대한 평균과 표준편차로 표현하였다.

국내·외 해수면온도 위성합성장과 조위관측소 자료를 대응하여 비교하고자 위치 정보를 이용한 유클리디안(Euclidean) 거리를 계산하였다. 가장 최소가 되는 거리의 정보를 대응되는 지점으로 가정하여 전체 기간에 대한 성능 지표를 계산하였다.

통계적 성능 차이를 검정하기 위해 다음과 같은 가정 하에 통계 가설을 설정하였다.

단순 RMSE 차이는 통계적 불확실성을 반영할 수 없기 때문에 ‘두 산출물 사이의 RMSE 차이가 정규분포를 따른다’는 가정 하에 동일 오차 여부를 검정하였다. 이때 귀무가설(H_0)는 ‘두 산출물의 성능 차이가 없다(즉, 우연에 의해 발생한 차이)’로 설정하였으며, 95% 신뢰수준에서의 유의확률(p-value)과 효과크기(Cohen’s d)를 계산하였다.


3.3. 비교 및 검증결과 분석

AI 모형의 재현 성능을 평가한 결과, RMSE는 0.22°C , R^2 는 0.99의 높은 정밀도를 확인할 수 있었다(<표 3.1>). 모든 연도별 비교 결과도 유사하게 확인되었으며, 이를 통해 AI 모형이 과적합 없이 안정적으로 학습되었음을 확인했다. 공간 분포 비교에서도 연도별 차이가 크지 않았으며([그림 3-1], [그림 3-2]), 회귀선 기울기와 절편 역시 각각 1과 0에 근사하여 체계적(systematic) 편차(bias)가 크지 않음을 확인할 수 있었다(<표 3.1>).


<표 3-1> 준실시간 해수면온도와 북서태평양 KHOA SST 비교 결과

연도	MAE($^{\circ}\text{C}$)	MSE($^{\circ}\text{C}$)	RMSE($^{\circ}\text{C}$)	R^2	Slope	Intercept($^{\circ}\text{C}$)
2021년	0.1208	0.0280	0.1675	0.9994	0.9984	-0.0014
2022년	0.1584	0.0537	0.2318	0.9989	1.0146	-0.3546
2023년	0.2245	0.0715	0.2674	0.9984	0.9952	0.3034
2024년	0.1758	0.0437	0.2090	0.9991	0.9904	0.0857
전체	0.1699	0.0492	0.2189	0.9999	0.9990	0.0083

OSTIA와의 평균 RMSE를 비교한 결과, 북서태평양 영역 KHOA SST, 동아시아 영역 KHOA SST, 준실시간 해수면온도, 해양 수치모델 순서로 유사성이 높았다(<표 3.2>). 반면, RMSE 표준편차를 기준으로 준실시간 해수면온도, 해양 수치모델, 북서태평양 영역 KHOA SST, 동아시아 영역 KHOA SST 순서로 값이 낮음을 확인할 수 있었다. 표준편차는 공간 연속성 지표로서 이상값(outlier) 없이 공간 구조를 얼마나 안정적으로 잘 재현하는지 나타낸다. KHOA SST는 OI 기반으로 결측을 복원하기 때문에 공간적인 연속성이 상대적으로 낮아 표준편차가 크게 나타난다. 반면, 해양 수치모델은 해양 물리 과정이 내재되기 때문에 공간 연속성이 높으며 표준편차가 작게 나타난다. 본 알고리즘의 산출 결과는 해수면온도 위성합성장과 해양 수치모델의 특성을 모두 반영하기 때문에 KHOA SST와 해양 수치모델보다 공간적으로 더욱 안정적인 분포를 보였다.



[그림 3-1] 준실시간 해수면온도와 북서태평양 KHOA SST 공간 비교('21, '22년도)



[그림 3-2] 준실시간 해수면온도와 북서태평양 KHOA SST 연도별 공간 비교('23, '24년도)


<표 3-2> OSTIA 해수면온도 자료와의 비교 결과('21-'24년)

비교 자료	구분	MAE(°C)		RMSE(°C)	
		평균	표준편차	평균	표준편차
OSTIA	동아시아 KHOA SST	0.426	0.101	0.646	0.150
	북서태평양 KHOA SST	0.397	0.076	0.588	0.111
	준실시간 해수면온도	0.536	0.047	0.750	0.058
	해양 수치모델	0.686	0.069	0.856	0.086

준실시간 해수면온도는 조위관측소 SST와의 비교에서 RMSE 1.40°C의 차이를 보였으며, R^2 0.95의 결과를 확인할 수 있었다(<표 3-3>, [그림 3-3]). 이는 KHOA SST의 비교 결과보다 약 0.2-0.6°C 정도 큰 차이를 보였으나, 국외 해수면온도 위성합성장과는 동등하거나 더 낮은 수준의 RMSE 차이를 보였다. KHOA SST를 포함한 국내·외 위성합성장은 D-2일 자료를 제공한다. 반면, 준실시간 해수면온도의 경우 D-0일 자료를 제공한다. 이러한 점을 고려했을 때 준실시간 해수면온도는 시의성과 정확도, 효용성을 동시에 만족한 결과로 해석된다.

<표 3-3> 국립해양조사원 조위관측소 해수면온도와의 비교

구분	비교자료 수	MAE(°C)	RMSE(°C)	R^2
동아시아 KHOA SST	45,300	0.8157	1.2987	0.9588
북서태평양 KHOA SST	44,859	0.4739	0.8554	0.9822
준실시간 해수면온도	45,300	1.0597	1.4025	0.9520
OSTIA	38,379	1.0213	1.4690	0.9492
MURSST	30,623	1.2503	1.7842	0.9211
ODYSSEA	30,084	1.2069	1.6748	0.9365




[그림 3-3] 조위관측소 자료와의 산점도 비교

대응표본 t-검정을 수행한 결과, 평균 RMSE 차이는 0.5471°C , 신뢰구간은 $0.5343\text{-}0.5599^{\circ}\text{C}$ 로 계산되었다. 유의확률은 0.05 미만의 값에 근사한 것을 확인할 수 있었다. 이는 귀무가설이 기각되는 결과로, 북서태평양 영역 KHOA SST가 준실시간 해수면온도보다 약 0.5471°C 정도 통계적으로 우수한 성능임을 의미한다. 다만, 그 차이의 효과크기는 0.385로 낮은 수준에 해당했다. 다시 말해, 두 산출물의 성능 차이는 실질적으로 체감하기 어려운 수준으로 계산되었다. 이는 실제 활용 측면에서 두 산출물 간 성능 차이는 크지 않고 실질적으로는 거의 유사한 수준으로 볼 수 있다.

4. 특이사항

유효해상도는 실제 현상을 어느 정도 공간 규모까지 재현할 수 있는지를 나타내는 지표이다. 북서태평양 영역 KHOA SST와 준실시간 해수면온도를 비교한 결과, 두 산출물의 이론적 공간해상도는 $0.01^{\circ} \times 0.01^{\circ}$ 로 동일하지만 실제 유효해상도는 준실시간 해수면온도가 더욱 우수한 것으로 나타났다([그림 4-1]). 기존 KHOA SST는 OI 기반 품질 관리와 결측 보정 과정을 거치면서 관측 밀도가 낮은 해역에 대해 강한 평활화가 적용된다. 이 과정에서 유효해상도 저하는 불가피하게 발생하게 된다. 반면, 준실시간 해수면온도는 KHOA SST, 해양 수치모델, AI를 융·복합하기 때문에 높은 수준의 유효해상도를 확보할 수 있었다. 이를 통해 연속적인 세부 공간 구조를 잘 재현하는 것으로 확인되었다.



[그림 4-1] 유효해상도 비교 예시('21년 4월 16일)

준실시간 해수면온도는 단순히 “빨리 만드는 SST”를 넘어 공간 구조의 품질 측면에서도 기존 산출물 대비 경쟁력 있는 수준의 정보를 제공하고자 했다. 이는 연안 감시 및 해양 예보와의 연계 측면에서도 다양한 현업 활용 가능성을 가진다. D-0일 기준의 고해상도 SST는 연안에서 발생하는 급격한 수온 변화, 냉·온수대 형성, 폭염·저수온과 같은 이상 수온 사건을 조기에 탐지하는데 유리하며, 해양재난 대응 의사결정에 직접적인 기여가 가능하다. 또한 해양 예측 모델의 초기장으로 활용될 경우, 보다 현실적인 상태에서 예측을 시작할 수 있기에 예보 정확도 향상과 스피업(spin-up) 시간 단축을 동시에 기대할 수 있다. 어업 및 자원 관리 측면에서도 SST 구조와 밀접하게 연관된 어장 형성·이동 특성을 파악하는 데 중요한 입력 자료로 활용될 수 있다.

5. 참고문헌

김의현, 김광진, 이승록, 최홍배, (2025). 위성합성장·수치모델·AI 융·복합을 통한 준실시간 해수면온도 산출 및 검증. 2025년도 한국해양학회 추계학술대회.

국립해양조사원, (2024). 해수면온도 합성장(KHOA SST) 알고리즘 설명서(Algorithm Theoretical Basis Document, ATBD).

박경애, 김영호, (2009). 인공위성 해수면온도 3-D 최적 내삽 합성장 생산 방법과 한계점. 한국지구과학학회지, 30(2), pp.223-233.

정기준, 최홍배, 김의현, 김동수, 김문선, 박수정, (2024). 딥러닝과 수치모델을 이용한 위성 합성장의 표층수온 실시간 예측. 해양공간정보학회지, 13(1), pp.21-31.

정시훈, 김영준, 박수민, 임정호, (2020). 시계열 기계학습을 이용한 한반도 남해 해수면 온도 예측 및 고수온 탐지. 대한원격탐사학회지, 36(5-3), pp.1077-1093.

Xingjian Shi, Zhourong Chen, Hao Wang, Dit-Yan Yeung, Wai-kin Wong, Wang-chun Woo, (2015). Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. Advances in neural information processing systems, 28.

6. 부록

해당 사항 없음