

주 의	북극 빙권변화 정량 분석을 위한 원격탐사 연구 세종대학교	마이크로파 위성을 이용한 북극 해빙 거칠기와 해빙두께 변화 연구 A Study on variation of the Arctic sea-ice surface roughness and thickness using microwave satellite observations 세종대학교산학협력단
---	--	---

제 출 문

극지연구소장 귀하

본 보고서를 “북극 빙권변화 정량 분석을 위한 원격탐사 연구” 과제의 위탁연구 “마이크로파 위성을 이용한 북극 해빙 거칠기와 해빙두께 변화 연구” 과제의 최종보고서로 제출합니다.



2026. 01. 31.

(본과제) 총괄연구책임자 : 김 현 철

위탁연구기관명 : 세종대학교산학협력단

위탁연구책임자 : 홍 성 욱

위탁참여연구원 : 조 선 아

“ : 오 성 택

“ : 유 한 솔

“ : 김 예 린

“ : 박 정 은

“ : 최 윤 정

“ : 한 경 훈

“ : 김 연 준

보고서 초록

위탁연구과제명		마이크로파 위성을 이용한 북극 해빙 거칠기와 해빙두께 변화 연구					
위탁연구책임자		홍성욱	해당단계 참여연구원수	9	해당단계 연구비	90,000,000	
연구기관명 및 소속부서명		세종대학교 산학협력단		참여기업명			
국제공동연구		상대국명 : 상대국연구기관명 :					
요약(연구결과를 중심으로 개조식 500자이내)						보고서 면수	53
1. 북극 해빙 거칠기 생성 연구 - SMAP 위성 기반 해빙 거칠기 산출(2015년 7월-2022년 6월) 및 겨울철 두꺼운 해빙 영역 내 산출 제약 확인 - Conditional GAN 기반 D2D 모델 개발을 통한 가상의 L-band 거칠기 생성 - 최대 1987년 9월까지 약 38년간의 일관된 장기 해빙 거칠기 시계열 자료 확보 - 가상의 거칠기와 원자료 간의 높은 정확도 달성(CC 0.93, RMSE 0.07cm, MAE 0.04 cm) 2. 북극 해빙 거칠기 변화 연구 - 2단계 예측 프레임워크 구축: DMSP 19.35 GHz 밝기 온도 12개월 예측 후 L-band 거칠기 생성 연계 - DMSP 편광 밝기온도 예측 결과, 리드 타임 증가에 따른 오차 증가에도 원자료와의 CC 0.95 이상 높은 상관성 유지 - 최종 L-band 거칠기 12개월 예측 결과, 원자료와의 CC 0.92 이상 상관성 유지 3. 북극 해빙 농도 예측 연구 - PyCaret 기반 변수 중요도 분석을 통해 핵심 기상 변수 5종 선정(SST, T2m 등) - ERA5 기상 변수 통합 학습 시, 예측 성능 대폭 개선(CC 11% 향상, RMSE 12% 감소) - 북극 해빙 농도의 계절별 변동 패턴 재현 및 예측 성능 검증 완료							
색 인 어 (각 5개 이상)	한 글	북극, 해빙 거칠기, 해빙 농도, SMAP, DMSP, 딥러닝, CGAN					
	영 어	Arctic, Sea Ice Roughness, Sea Ice Concentration, SMAP, DMSP, Deep Learning, CGAN					

요 약 문

I. 제 목

마이크로파 위성을 이용한 북극 해빙 거칠기와 해빙두께 변화 연구

II. 연구개발의 목적 및 필요성

최근 북극 해빙 면적과 다년생 해빙 비율의 급격한 감소는 지구 온난화의 가속과, 이상 기후 발생에 상당한 영향을 미치고 있어, 해빙 상태에 대한 분석과 미래 예측의 중요성이 지속적으로 증가하고 있다. 따라서 해빙의 물리적 특성을 반영하는 해빙 거칠기와 농도는 주요 변수로서 장기적인 시계열 자료의 확보가 중요하다. 이에 본 연구에서는 딥러닝 모델을 활용하여 L-band 기반 해빙 거칠기의 장기 시계열을 생성하고, 해빙 거칠기 및 농도의 12개월 예측하고자 하였다. 이러한 연구 결과는 북극 해빙 변동에 대한 물리적 이해도를 제고하는 동시에, 관측 기간이 제한된 위성 자료의 시공간적 한계를 보완하는 기반을 제공하며, 향후 장기 기후 변화 분석과 북극 해빙 예측 연구의 확장을 위한 기초 자료로 활용될 수 있다.

III. 연구개발의 내용 및 범위

○ 과거 북극 해빙 거칠기 생성

SMAP 위성의 L-band 수직 및 수평 편광 밝기온도와 CMEMS 표면온도 자료를 활용하여 2015년 7월부터 2022년 6월까지의 L-band 기반 해빙 거칠기를 산출하였다. Conditional GAN 기반의 Data-to-Data(D2D) 모델을 개발하여 DMSP 위성 시리즈의 19.35GHz 편광 밝기온도를 입력으로 사용하고, SMAP 기반 L-band 거칠기를 출력으로 하는 도메인 변환 학습을 수행하였다. 학습된 모델을 통해 1987년 9월부터 2015년 6월까지 약 28년간의 가상의 L-band 기반 해빙 거칠기를 생성하여, 전체 약 38년에 걸친 장기 시계열 자료를 구축하였다.

○ 북극 해빙 거칠기 12개월 예측

해빙 거칠기의 미래 예측을 위해 2단계 예측 프레임워크를 구축하였다. 1단계에서는 DMSP 19.35GHz 수직 및 수평 편광 밝기온도에 대한 12개월 예측 모델을 각각 개발하였으며, 과거 12개월 자료를 입력으로 미래 12개월을 예측하는 D2D 모델 구조를 적용하였다. 2단계에서는 앞서 개발된 L-band 거칠기 생성 모델을 활용하여 1단계에서 예측된 DMSP 밝기온도로부터 최종 L-band 거칠기를 생성하였다.

○ 북극 해빙 농도 12개월 예측

NSIDC에서 제공하는 DMSP 기반 해빙 농도 장기 시계열 자료를 수집하고, ERA5 재분석 자료로부터 해빙 변동에 영향을 미치는 기상 변수를 확보하였다. Python 기반 머신러닝 라이브러리인 PyCaret을 활용하여 Gradient Boosting Regressor, Light Gradient Boosting

Machine 등 4종의 머신러닝 모델 기반의 변수 중요도 분석을 수행하였으며, 그 결과 해수면 온도, 2m 기온, 지표 기압, 10m 풍속, 증발량을 핵심 기상 변수로 선정하였다. D2D 모델에 해빙 농도 자료와 선정된 기상 변수를 통합 입력하여 12개월 예측 모델을 구축하고, 기상 변수 도입 전후의 성능 비교를 통해 예측 개선 효과를 정량적으로 검증하였다.

IV. 연구개발결과

○ 과거 북극 해빙 거칠기 생성 결과

D2D 모델로 생성된 가상의 L-band 거칠기는 실제 SMAP 관측 기반 거칠기 산출물과 높은 일관성을 보였다. 테스트 기간(2021년 7월-2022년 6월)에 대한 정량적 평가 결과 Pearson CC 0.9289, bias 0.0037cm, RMSE 0.0691cm, MAE 0.0443cm를 기록하여 약 2cm 거칠기 범위 대비 2-3% 수준의 낮은 오차율을 달성하였다. 해빙이 급격히 결빙되거나 용해되는 시기에 평균보다 높은 오차가 확인되었으며, 겨울철 두꺼운 해빙 영역의 산출의 제한이 확인되었다. 그러나 전반적인 시공간 패턴이 일치함이 확인되었으며, 이를 통해 1987년 9월부터 2015년 6월까지 과거 L-band 거칠기를 성공적으로 생성하여 장기 시계열 자료를 구축하였다.

○ 북극 해빙 거칠기 12개월 예측 결과

1단계 DMSP 밝기온도 예측 모델은 수직 편광에서 CC 0.95 이상, 수평 편광에서 CC 0.96 이상의 높은 상관성을 유지하였다. RMSE는 수직 편광에서 약 8 K, 수평 편광에서 10 K 이상으로 다소 높았으나 전반적인 공간 패턴은 우수하게 예측되었다. 겨울철 예측 성능이 여름철 대비 상대적으로 우수하였으며, 이는 겨울철 해빙의 안정적인 공간 분포에 기인한다. 2단계에서 생성된 최종 L-band 거칠기는 SMAP 관측 기반 거칠기와 CC 0.92의 높은 상관성을 보였으며, 전반적인 지역적 분포 패턴이 유사하게 나타났다. 다만 두꺼운 해빙 영역에서 과대 추정 경향이 확인되어, 향후 물리적 제약 조건의 모델 내재화가 필요함을 확인하였다.

○ 북극 해빙 농도 12개월 예측 결과

머신러닝 기반 변수 중요도 분석을 통해 선정된 5종의 기상 변수를 D2D 모델에 통합하여, 해빙 농도 단일 입력 모델 대비 CC가 0.6996에서 0.7776으로 약 11.15% 향상되었고, RMSE는 0.1540에서 0.1359로 약 11.75% 감소하여 유의미한 예측 성능 개선을 확인하였다. 개선 모델은 그린란드 동해안 및 보퍼트 해 인근의 해빙 농도를 더욱 선명하게 예측하였으며, 이는 연안 지역의 기상 변동이 모델에 효과적으로 반영된 결과로 분석된다. 시계열 분석에서는 여름철 용해기의 과대 추정 경향이 일부 관찰되었으나, 재결빙이 시작되는 10-12월 구간에서는 원자료의 증가 추세를 정밀하게 추적하였다. 전반적으로 계절적 변동 주기를 효과적으로 재현하여 장기 예측 안정성이 확보되었음을 확인하였다.

V. 연구개발결과의 활용계획

본 연구에서 개발된 L-band 기반 해빙 거칠기 및 해빙 농도 생성·예측 기술은 북극 해빙 변화 분석과 예측 정확도 향상을 위한 후속 연구로 확장될 수 있다. 향후에는 겨울철 두꺼운 해빙 영역의 산출 제약을 개선하기 위해 눈 덮개 영향을 고려할 계획이며, 시계열 학습에 특화된 딥러닝 구조와 앙상블 예측 기법을 도입함으로써 계절 전이 구간의 예측 정밀도를 향상시키는 연구로 확장할 계획이다.

S U M M A R Y

I. Title

A Study on variation of the Arctic sea-ice surface roughness and thickness using microwave satellite observations

II. Purpose and Necessity of R&D

The rapid decline in Arctic sea ice extent and the proportion of multiyear ice has significantly accelerated global warming and increased the occurrence of extreme weather events, thereby highlighting the growing importance of accurate analysis and prediction of sea ice conditions. Sea ice roughness and concentration, which reflect the physical characteristics of sea ice, are key variables for understanding Arctic sea ice variability, and the availability of long-term time series data is essential for such analyses. In this study, deep learning models were employed to generate a long-term time series of L-band-based sea ice roughness and to predict sea ice roughness and concentration up to 12 months ahead. The resulting datasets enhance the physical understanding of Arctic sea ice variability while overcoming the spatiotemporal limitations of satellite observations, thereby providing a foundation for long-term climate change studies and extended Arctic sea ice prediction research.

III. Contents and Extent of R&D

○ Generation of Historical Arctic Sea Ice Roughness

L-band-based sea ice roughness was derived for the period from July 2015 to June 2022 using SMAP L-band vertically and horizontally polarized brightness temperatures and CMEMS surface temperature data. A Conditional GAN-based Data-to-Data (D2D) model was developed to perform domain translation from DMSP satellite 19.35 GHz polarized brightness temperatures to SMAP-based L-band sea ice roughness. Using the trained model, virtual L-band sea ice roughness data were generated for the period from September 1987 to June 2015, resulting in a long-term time series spanning approximately 38 years.

○ 12-Month Prediction of Arctic Sea Ice Roughness

A two-stage prediction framework was established to forecast future sea ice

roughness. In the first stage, separate D2D models were developed to predict vertically and horizontally polarized DMSP 19.35 GHz brightness temperatures up to 12 months ahead using the previous 12 months as input. In the second stage, the predicted brightness temperatures were used as inputs to the L-band roughness generation model to produce the final 12-month forecast of L-band sea ice roughness.

○ 12-Month Prediction of Arctic Sea Ice Concentration

Long-term DMSP-based sea ice concentration data from NSIDC were collected, along with meteorological variables affecting sea ice variability from the ERA5 reanalysis dataset. Variable importance analysis was conducted using four machine-learning models, including Gradient Boosting Regressor and Light Gradient Boosting Machine, implemented via the PyCaret library. Sea surface temperature, 2 m air temperature, surface pressure, 10 m wind speed, and evaporation were identified as key predictors. These variables were integrated with sea ice concentration data into the D2D model to construct a 12-month prediction system, and the improvement in prediction performance due to the inclusion of meteorological variables was quantitatively evaluated.

IV. R&D Results

○ Results of Historical Sea Ice Roughness Generation

The virtual L-band sea ice roughness generated by the D2D model showed high consistency with SMAP observation-based roughness products. Quantitative evaluation during the test period (July 2021–June 2022) yielded a Pearson correlation coefficient of 0.9289, a bias of 0.0037 cm, an RMSE of 0.0691 cm, and an MAE of 0.0443 cm, corresponding to an error of approximately 2–3% relative to the ~2 cm roughness range. Larger errors were observed during rapid freezing and melting periods, and limitations were identified in thick winter ice regions. Nevertheless, the overall spatiotemporal patterns were well reproduced, enabling the successful reconstruction of historical L-band sea ice roughness from September 1987 to June 2015.

○ Results of 12-Month Sea Ice Roughness Prediction

The first-stage DMSP brightness temperature prediction models maintained high correlations, with CC values exceeding 0.95 for vertical polarization and 0.96 for horizontal polarization. Although RMSE values were relatively high (approximately 8 K for vertical and over 10 K for horizontal polarization), the overall spatial patterns were well preserved. Prediction performance was superior in winter compared to summer, reflecting the more stable spatial distribution of sea ice during winter. The final L-band roughness generated in the second stage showed a high correlation (CC = 0.92) with SMAP-based roughness and similar regional

distribution patterns. However, an overestimation tendency in thick ice regions was identified, indicating the need for incorporating physical constraints into the model.

○ Results of 12-Month Sea Ice Concentration Prediction

By integrating the five selected meteorological variables into the D2D model, the correlation coefficient improved from 0.6996 to 0.7776 (approximately 11.15 %), while RMSE decreased from 0.1540 to 0.1359 (approximately 11.75 %), demonstrating a significant enhancement in prediction performance. The improved model more clearly reproduced sea ice concentration gradients along the eastern coast of Greenland and the Beaufort Sea, attributed to the effective incorporation of coastal meteorological variability. Time-series analysis revealed some overestimation during the summer melt season, whereas the increasing trend during the refreezing period from October to December was accurately captured. Overall, the seasonal cycle was well reproduced, confirming the stability of long-term predictions.

V. Application Plans of R&D Results

The L-band-based sea ice roughness and concentration generation and prediction techniques developed in this study can be extended to further research aimed at improving the accuracy of Arctic sea ice analysis and forecasting. Future work will focus on addressing winter season limitations in thick ice regions by accounting for snow cover effects and on enhancing prediction accuracy during seasonal transition periods through the integration of time-series-oriented deep learning architectures and ensemble prediction techniques.

목 차

제 1 장 서론	11
1. 연구개발의 목적	11
2. 연구개발의 필요성	11
3. 연구개발 범위	12
제 2 장 국내외 기술개발 현황	13
1. 해빙 거칠기 산출 기술	13
2. 해빙 농도 산출 기술	14
제 3 장 연구개발수행 내용 및 결과	16
제 1절 과거 북극 해빙 거칠기 생성 연구	16
1. 이론적, 실험적 접근 방법	16
가. 편광 반사도	16
나. 거칠기 산출 알고리즘	16
다. Data-to-Data	18
2. 연구자료	19
가. SMAP 위성 밝기 온도 자료	19
나. 표면 온도 자료	19
다. DMSP 위성 시리즈 19.35 GHz 밝기 온도 자료	20
라. 자료 획득 경로	20
3. 연구내용	20
가. 해빙 거칠기 산출물	21
나. 학습 모델	23
다. 모델 학습 및 검증 자료 구축	24
4. 연구결과	24
가. 가상의 과거 해빙 거칠기	24

제 2절 북극 해빙 거칠기 예측 연구	30
1. 이론적, 실험적 접근 방법	39
가. Data-to-Data	30
2. 연구자료	30
가. DMSP 위성 시리즈 19.35 GHz 밝기 온도 자료	30
3. 연구내용	30
가. 학습 모델	30
나. 모델 학습 및 검증 자료 구축	31
4. 연구결과	32
가. DMSP 19.35 GHz 편광 밝기 온도 예측	32
나. L-band 거칠기 예측	37
제 3절 북극 해빙 농도 예측 연구	39
1. 이론적, 실험적 접근 방법	39
가. Data-to-Data	39
나. PyCaret	39
2. 연구자료	39
가. 해빙 농도 자료	39
나. ERA5 기상 변수	40
다. 자료 획득 경로	40
3. 연구내용	40
가. 학습 모델	40
나. 기상 변수 도입의 효과	41
다. 머신러닝 기반 학습 자료 선정	41
라. 모델 학습 및 검증 자료 구축	42
4. 연구결과	42
가. NSIDC 해빙 농도와의 비교	43
나. 해빙 농도 시계열 분석	43
제 4 장 연구개발목표 달성도 및 대외기여도	45
제 1절 연구개발목표 달성도	45
제 2절 대외기여도	46
1. 학술적 파급효과	46

2. 경제적 파급효과	46
제 5 장 연구개발결과의 활용계획	49
제 6 장 참고문헌	50



제 1 장 서론

1. 연구개발의 목적

수동형 마이크로파 위성 자료와 딥러닝 기술을 기반으로 북극 해빙 거칠기와 해빙 농도의 장기 시계열 생성 및 12개월 예측 시스템을 구축하는 것을 목적으로 한다.

2. 연구개발의 필요성

해빙은 지구의 반사율을 조절하고 대기과 해양 간의 에너지 및 운동량 교환을 차단하는 기후 변화의 핵심 지표이다. 1979년 위성 기반의 관측이 시작된 이래, 북극 해빙 면적은 전 계절에 걸쳐 유의미하게 감소하고 있으며 특히 여름철 해빙은 10년당 평균 약 13%의 급격한 감소 추세를 보이고 있다(Stroeve et al., 2012). 또한, 여름철에도 녹지 않고 유지되는 두꺼운 다년빙의 비율이 1980년대 중반 전체 해빙의 약 3분의 1을 차지하던 것에 비해 최근에는 5% 미만으로 급감하며, 북극 해역은 과거보다 훨씬 얇고 파쇄되기 쉬운 단년빙 위주의 체계로 재편되었다(Kwok, 2018). 이러한 북극 해빙의 급격한 감소는 북극 증폭 현상을 유도하여 전 지구적 에너지 균형을 무너뜨리고, 한파와 폭염 등 극단적인 이상기후를 빈번하게 발생시키고 있어 해빙 정보 수집 및 미래 변화 이해의 중요성이 지속적으로 증가하고 있다(Screen and Simmonds, 2010).

해빙의 대표적 물성인 해빙 농도는 특정 해역에서 해빙이 차지하는 면적 비율을 나타내며, 해빙 면적 산출 및 부피 추정을 위한 가장 기초적이고 필수적인 물리 매개변수이다. 위성을 이용한 원격 탐사는 북극의 지리적 접근 제약과 직접 관측의 어려움을 극복하고 지난 수십 년간 광범위한 해빙 정보를 제공해 왔으나, 기존의 산출 방식은 대기 상태나 센서 특성에 따른 관측 불확실성이 상존한다는 한계가 있다. 특히, 기존의 통계적 예측 모델은 해빙과 기상 인자 간의 복잡한 비선형적 상호작용을 충분히 반영하지 못하며, 장기 시계열 예측 시 단순한 계절적 반복 패턴에 의존하는 경향을 보여 실제 변동성을 예측하는 데 어려움이 있다. 해빙 거칠기는 해빙 표면의 거친 정도를 나타내는 물성으로, 표면 반사율에 영향을 미치고 용해 시기를 결정짓는 중요한 변수임에도 불구하고 관측 자료의 부족과 산출 알고리즘의 불확실성으로 인해 장기적인 변동성 분석에 제약이 따랐다.

이에 본 연구에서는 딥러닝 기반 도메인 변환 기술을 활용하여 약 40년에 이르는 장기 북극 해빙 거칠기 시계열 자료를 생성하고, 해빙 거칠기와 농도의 12개월 예측을 수행하였다. 이를 위해 단순한 통계적 추정이나 기존 알고리즘의 보완을 넘어, 조건부 생성적 적대 신경망 기반의 Data-to-Data(D2D) 모델을 구축하여 도입하였다. 특히 해빙 농도 예측 연구에서는 위성 관측 자료뿐만 아니라 해빙 변동에 직접적인 물리적 영향을 미치는 ERA5 기상 재분석 자료를 학습에

사용함으로써, 기상 인자와 해빙 간의 인과관계를 모델 내부에 내재화하고 예측의 물리적 타당성을 확보하였다. 또한 L-band 해빙 거칠기 생성 및 예측 연구는 DMSP 위성의 장기 관측 자료로부터 가상의 L-band 해빙 거칠기 생성하여, 북극 해빙의 장기적 진화 과정을 연속적으로 분석할 수 있는 새로운 토대를 제공한다. 이러한 장기간 해빙 자료와 예측 결과는 급격한 기후 변화에 대응하기 위한 과학적 근거를 제공할 뿐만 아니라, 북극항로의 가용성 평가(Smith and Stephenson, 2013)와 극지 활동의 안전성 및 경제적 효율성 제고에도 실질적으로 기여할 수 있을 것으로 기대된다.

3. 연구개발 범위

- 가. 과거 북극 해빙 거칠기 생성 연구
- 나. 북극 해빙 거칠기 12개월 예측 연구
- 다. 북극 해빙 농도 12개월 예측 연구



제 2 장 국내외 기술개발 현황

1. 해빙 거칠기 산출 기술

해빙 표면 거칠기는 해빙의 물리적 상태와 구조적 진화를 반영하는 중요 변수로, 열적, 전자기적 특성뿐 아니라 다양한 해빙 산출 알고리즘의 정확도에도 직접적인 영향을 미친다. 그러나 충분한 시공간 해상도를 가지는 관측 자료를 통해 직접적으로 확보하기 어렵고, 원격 탐사 과정에 내재된 불확실성에 민감하여 획득이 까다롭다는 특징이 있다.

레이더 고도계, 레이저 고도계, 마이크로파 산란계와 같은 능동형 센서 기반의 해빙 거칠기는 표면 지형을 직접 측정하는 방식으로 해빙 표면의 기하학적 특성을 정량적으로 파악할 수 있다는 장점이 있으나, 관측 범위가 제한적이거나 재방문 주기가 길어 시공간적으로 연속된 해빙 변화 과정을 모니터링하기에는 제약이 있다. 레이저 고도계를 기반의 해빙 거칠기 정량화는 전자기적 산란 특성이 아닌 해빙 표면 높이에 대한 기하학적 요철을 관측하여 수행되었다(Hibler, 1972; Dierking, 1995; Von Saldern et al., 2006). Doble et al. (2011)은 항공기 기반 레이저 스캐너를 이용하여 해빙 표면의 고해상도 고도 정보를 확보하고, 이를 바탕으로 거칠기를 정량화하였다. 특히 해빙 거칠기와 해빙 하부 구조를 나타내는 ice draft 간의 상관성을 분석하여 해빙 상하부의 연계를 평가하였다. 또한 Beckers et al. (2015)은 레이저 고도계와 항공기 기반 레이저 스캐너 관측 결과를 비교한 바 있으며, Miernecki et al. (2020)은 SMOSice2014 Campaign의 저고도 항공 관측 자료를 기반으로 해빙면의 수치 표고 모델을 생성함으로써 decimeter-scale 수준의 거칠기를 산출하였다. 레이더 고도계를 이용한 방식으로는 Cryosat-2의 L1B 자료를 활용한 해빙 거칠기가 대표적이며, 1650m x 380m의 높은 공간 해상도로 제공한다는 장점이 있다. 그러나 해당 방식은 레이더 파형에 대한 최소 제공법을 적용하여 산출되므로, 후방산란각에 민감하게 반응하여 물리적 교란이 발생할 가능성이 있다는 한계가 수반된다. 그 외에도 C-band의 HH 편광 helicopter-borne HUTSCAT 산란계 자료를 통한 해빙 거칠기에 대한 통계적 추론(Simila et al., 2001) 및 Radarsat-2 기반 해빙 거칠기가 C-band Synthetic Aperture Radar(SAR)에 미치는 영향 분석(Fors et al., 2015) 등이 이루어졌으며, Upward-looking sonar sensors나 fix mounted helicopter-borne electromagnetic 시스템을 통한 해빙 거칠기 측정 연구(Peterson et al., 2008)등이 진행된 바 있다.

한편, 수동형 마이크로파 위성을 활용한 해빙 거칠기 산출은 해빙 표면에서 자연적으로 방출되는 복사 에너지를 관측함으로써 거칠기 정보를 간접적으로 추정한다. 6-25 km의 높은 공간 해상도를 특징으로 하기 때문에 넓은 공간 범위를 관측할 수 있다는 장점이 있다. 일반적으로 해빙 표면의 거칠기가 증가할수록 다중 산란 효과가 증가하여 밝기 온도가 감소하는 경향을 보이며, 이러한 변화는 유효 방사율을

통해 polarization ratio나 gradient ratio의 변화로 나타난다. Advanced Microwave Scanning Radiometer Earth Observing System(AMSR-E) 위성 기반의 연구가 주로 이루어졌으며, AMSR-E의 18.7 GHz 채널을 활용하여 편광 반사율 추정을 통해 0.25-0.55 cm 범위의 small-scale 해빙 거칠기를 산출한 연구가 진행된 바 있다(Hong, 2010). 해당 알고리즘은 현재 국가기상위성센터의 현업 자료 산출에도 적용되고 있다. 이후 Hong & Shin (2010)과 Shin et al. (2011)에서 해빙 거칠기 시계열 변화의 감소 추세가 확인되었다. Bi et al. (2013)에서는 동일한 AMSR-E 위성의 3개 채널 (6.9, 10.7, 89 GHz)을 기반으로 주파수별 해빙 거칠기의 민감도를 정량적으로 분석하여 수동형 마이크로파 기반 해빙 산출 알고리즘의 정확도 향상을 위한 보조 변수로서의 활용 가능성을 평가하였다. 아울러 복사전달모델을 통해 해빙 거칠기가 해빙 농도 알고리즘의 오차에 직접적인 영향을 미침을 확인하고, 특히 10.7 GHz 채널이 알고리즘 보정을 위한 핵심 주파수임을 확인한 연구가 있다(Stroeve et al., 2006). 이러한 연구들은 해빙 변화의 모니터링과 타 해빙 변수 산출의 정밀도 향상을 위해 해빙 거칠기 정보가 필수적임을 보여준다.

2. 해빙 농도 산출 기술

북극 해빙 농도는 광범위한 지역에 대해 일정한 주기로 관측이 가능한 위성 원격 탐사 자료를 핵심 기반으로 산출되고 있다. 그러나 해빙 농도 정보는 위성 센서가 가진 물리적 분해능과 알고리즘의 연산 과정에서 발생하는 불확실성을 필연적으로 포함하기 때문에, 미세한 변동성을 정밀하게 포착하기에는 기술적 제약이 따른다. 고해상도 SAR나 광학 위성을 활용한 산출 방법은 수십 미터 단위의 세밀한 해빙 분포를 제공할 수 있으나, 기상 조건에 따른 관측 제약이 크고 북극 전역을 매일 관측하기에는 재방문 주기와 공간적 커버리지가 부족하다는 한계가 있다. SAR 영상을 활용한 해빙 농도 산출 연구가 다수 진행된 바 있으며(Wang et al., 2020; Jiang et al., 2023), 이러한 연구들은 국부적인 해빙 경계선 확정에는 효과적이지만 기후 변화 분석을 위한 장기 시계열 자료로 활용하기에는 자료의 연속성이 떨어진다는 단점이 있다.

수동 마이크로파 위성 기반의 해빙 농도의 경우, 6-25 km의 공간 해상도를 가져 북극 전체를 일일 단위로 수용한다는 장점이 있으나, 정밀한 해빙 경계나 연안 지역의 농도를 산출하는 데는 한계가 존재한다. 초기 해빙 농도 산출에는 밝기 온도의 편광 및 주파수 특성을 이용한 NASA Team 알고리즘(Cavalieri et al., 1984)과 선형적 통계 특성을 활용한 Bootstrap 알고리즘(Comiso, 1986)이 주로 사용되었다. 이러한 고전적 방법론들은 지난 수십 년간의 해빙 감소 추세를 파악하는 데 기여했으나, 여름철 용해 연못을 개방 수역으로 오인하거나 육지 인근의 밝기 온도 간섭으로 인한 오차를 포함한다는 한계가 존재한다. 이를 개선하기 위해 89 GHz 고주파수 채널을 활용한 ARTIST Sea Ice 알고리즘이

개발되어 6.25 km 수준의 비교적 높은 해상도를 확보한 연구가 진행되었으며(Spreen et al., 2008), 최근에는 유럽을 중심으로 다중 알고리즘을 융합하여 일관성 있는 기후 데이터 레코드를 구축하려는 노력이 이어지고 있다(Kern et al., 2019; Lavergne et al., 2019).

최근에는 위성 관측 자료의 물리적 한계를 극복하기 위해 비선형적 학습이 가능한 딥러닝 기법을 도입하는 추세이다. 데이터 기반의 신경망 모델은 과거의 복잡한 해빙 패턴을 학습하여 미래를 예측하는 데 탁월한 성능을 보이며, 국내에서도 Convolutional Neural Network 기반 모델을 구축하여 위성 자료와 기상 재분석 자료를 결합한 예측 연구가 활발히 수행된 바 있다(Chi and Kim, 2017; Kim et al., 2020). 특히 단순한 수치 예측을 넘어 이미지 생성 기법인 Generative Adversarial Network 등을 활용해 공간 분포의 정밀도를 높이는 연구가 국외에서 시도되고 있으며, 국내 연구진들 또한 Special Sensor Microwave Imager and Sounder(SSMIS) 및 Advanced Microwave Scanning Radiometer 2(AMSR2) 자료를 기반으로 한 머신러닝 산출 기술을 고도화하며 북극 해빙 모니터링의 정확도를 제고하고 있다(Han et al., 2018; Park et al., 2020). 이러한 흐름은 기상 변수 최적화 및 딥러닝 모델 기반의 해빙 변수 예측 기술 확보를 위한 본 연구의 방향성에도 부합하며, 기존 산출 기법의 불확실성을 줄이는 데 중요한 기술적 토대가 되고 있다.



제 3 장 연구개발수행 내용 및 결과

제 1절 과거 북극 해빙 거칠기 생성 연구

1. 이론적, 실험적 접근 방법

가. 편광 반사도

전자기파 산란 이론에 따르면, 표면에서의 편광 반사 특성은 입사 전자기파의 파장과 표면 거칠기의 상대적 규모에 의해 결정된다. 표면 거칠기에 해당되는 표면 높이가 무작위로 분포한다고 가정하면 통계적으로 가우시안 분포를 따르는 확률 밀도 함수로 정의할 수 있고, 이를 통해 파장(λ)과 거칠기(σ)의 비율로서 산란 강도를 정량화할 수 있다. 따라서 표면 거칠기의 영향을 나타내는 감쇠 정도는 다음과 같은 지수 함수 형태로 표현된다(Choudhury et al., 1979; Wu and Fung, 1972).

$$\chi(h) = e^{-h \cos^2 \theta} \quad (1)$$

여기서 θ 는 반사각을, h 는 표면 거칠기와 파장 간의 상대적 관계를 나타낸다.

$$h = \left(\frac{4\pi}{\lambda} \sigma \right)^2 \quad (2)$$

이러한 물리적 특성을 반영하여 Ulaby et al. (1982)은 정반사성 표면에서의 Fresnel 반사도($R_{S,P}$)에 감쇠 함수가 곱해진 형태의 거친 표면의 반사도($R_{R,P}$)를 도출하는 반경험적(semi-empirical) 모델을 제시하였다.

$$R_{R,P} = R_{S,P} \cdot e^{-\left(\frac{4\pi}{\lambda} \sigma \cos \theta \right)^2} \quad (3)$$

나. 거칠기 산출 알고리즘

표면의 small-scale 거칠기는 수동형 마이크로파 관측에서 편광 반사 특성에 직접적인 영향을 미치며, 이는 $R_{R,P}$ 의 변화로 나타난다. 따라서 식 (3)을 거칠기 파라미터인 σ 에 대해 정리하여 다음과 같이 정량화할 수 있다.

$$\sigma = \frac{\lambda}{4\pi \cos \theta} \sqrt{\ln \left(\frac{R_{S,P}}{R_{R,P}} \right)} \quad (4)$$

하지만 실제 위성 센서가 관측하는 해빙 표면은 이상적인 정반사성 표면이 아니므로 관측된 편광 반사도만을 활용하여 σ 를 산출하기 위해서는 $R_{S,P}$ 를 관측 가능한 변수로 변환하는 과정이 필요하다.

선행 연구(Hong, 2009; 2010, 2013)에 따르면, 정반사 조건에서의 수직 편광 반사도는 수평 편광 반사도와 θ 의 관계를 통해 근사할 수 있다. 이를 Hong approximation이라 하며, 복잡한 Fresnel 방정식을 간소화하여 다음과 같이 표현한다.

$$R_{S,V} = (R_{S,H})^{\sec^2 \theta} \quad (5)$$

또한 Brewster 각 부근에서는 수평 편광의 경우 거친 표면과 매끄러운 표면 간의 반사도 차이가 미미한 반면($R_{S,H} \approx R_{R,H}$), 수직 편광에서는 그 차이가 유의미하게 발생한다는 물리적 특성을 이용한다. 이러한 관계를 앞선 거칠기 표현식인 식 (4)에 대입하면 해빙 표면의 small-scale 거칠기는 수직 및 수평 편광 반사도의 비로 정리된다.

$$\sigma = \frac{\lambda}{4\pi \cos \theta} \cdot \sqrt{\ln \left(\frac{R_{R,V}^{\sec^2 \theta}}{R_{R,H}} \right)} \quad (6)$$

편광 반사도는 표면 온도 T_S 와 수직 편광 밝기 온도 $T_{B,V}$ 및 수평 편광 밝기 온도 $T_{B,H}$ 를 이용해 다음과 같이 표현된다(Comiso et al., 2003).

$$R_{R,P} = 1 - \frac{T_{B,P}}{T_S} \quad (P = V \text{ or } H) \quad (7)$$

이를 최종적으로 대입함으로써 표면에서의 small-scale 거칠기를 산출하기 위한 편광 밝기온도 기반의 산출식은 다음과 같이 정의된다.

$$\sigma = \frac{\lambda}{4\pi \cos \theta} \cdot \sqrt{\ln \left[\frac{\left(1 - \frac{T_{B,H}}{T_S} \right)^{\sec^2 \theta}}{\left(1 - \frac{T_{B,V}}{T_S} \right)} \right]} \quad (8)$$

본 알고리즘은 해빙을 포함한 다양한 특성의 표면 전반에 대해 적용이 가능하며, 해빙 표면 특성 변화를 정량적으로 분석하는 데 효과적으로 사용될 수 있다.

다. Data-to-Data

본 연구에서 과거 해빙 거칠기 생성을 위해 사용한 D2D는 조건부 생성적 적대 신경망(Conditional Generative Adversarial Nets, CGAN)을 기반으로 한 Pix2Pix 구조를 확장한 모델로, 입력 자료의 물리적 값 자체를 보존한 상태에서 도메인 변환을 수행할 수 있도록 설계되었다. 기존 Pix2Pix 모델이 정규화된 이미지 값을 입력으로 사용하는 데 반해, D2D 모델은 수치적 특성을 직접 반영함으로써 위성 원자료의 특성을 보존한다(Han et al., 2022). D2D 모델의 기본 구조에 해당되는 CGAN은 생성자와 판별자로 구성된 상호 경쟁적 학습을 통해 성능을 고도화한다. 생성자는 조건부 입력 x 를 바탕으로 목표 자료 y 의 분포를 학습하여 출력 $G(x)$ 을 생성하게 되고, 판별자는 생성된 $G(x)$ 와 y 의 비교를 통해 Real/Fake 여부를 판별하도록 학습된다.

Pix2Pix 프레임워크는 이러한 CGAN 구조를 이미지 간 변환 문제에 적용한 대표적인 모델로 입출력 이미지가 쌍을 이루는 지도 학습 방식으로 진행된다. 구조적 측면에서 생성자는 인코더-디코더 기반의 U-Net을 채택하여 계층 간 skip connection을 통해 입력 데이터의 국소적 정보와 전역적 정보를 효과적으로 전달한다. 판별자는 이미지의 전체적인 형태를 단일 판단의 대상으로 삼으며, 추가적으로 Patch-GAN 구조를 사용하여 세부적인 공간 패턴의 정확도를 높이도록 설계된다(Isola et al., 2017).

D2D 모델은 이러한 Pix2Pix를 기반으로 하되, 모델 입출력 자료의 전처리 및 후처리 과정이 추가되었다. 전처리 과정에서는 모델 입력인 실제 위성 원자료 값을 Min-Max 정규화를 통해 0에서 1 사이의 범위로 변환한다.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (9)$$

이때 위성 원자료 값 사용시, 결측값 등의 불필요한 값들이 필연적으로 포함되므로 학습 과정에서 발생할 수 있는 노이즈를 제어하고 학습 안정성을 확보하기 위해 해당 값들은 -1로 설정된다. 이후 학습이 완료되면 생성된 $G(x)$ 를 역정규화(Denormalization) 과정을 통해 원자료의 물리적 범위로 복원하여 최종적인 값을 산출한다. D2D의 학습은 다음과 같은 적대적 손실(adversarial loss, $\mathcal{L}_{cGAN}(G, D)$)과 L1 손실($\mathcal{L}_{L1}(G)$)을 결합한 목적 함수를 최적화하는 과정으로 진행된다.

$$\mathcal{L}_{cGAN}(G, D) = \mathbb{E}_{x,y} [\log D(x, y)] + \mathbb{E}_{x,y} [\log (1 - D(x, G(x, z)))] \quad (10)$$

$$\mathcal{L}_{L1}(G) = \mathbb{E}_{x,y,z} [\|y - G(x,z)\|_1] \quad (11)$$

$$G^* = \arg \min_G \max_G \mathcal{L}_{eGAN}(G,D) + \lambda \mathcal{L}_{L1}(G) \quad (12)$$

2. 연구자료

가. SMAP 위성 밝기 온도 자료

L-band 기반 거칠기를 산출하기 위하여 Soil Moisture Active Passive(SMAP) 위성의 수동형 센서로부터 생성된 Enhanced Level 3 Radiometer Global Daily 9km EASE-Grid Soil Moisture 자료(SPL3SMP_E, Version 4)를 사용하였다. SMAP 위성은 준극궤도 운용을 통해 고위도 지역에 대해 높은 재방문 빈도를 제공하며, 약 1000 km의 관측 폭으로 전 지구를 2-3일 이내에 커버할 수 있다. 탑재된 복사계는 1.41GHz의 L-band 대역에서 약 40°의 입사각으로 지표를 관측하며, Radio Frequency Interference 영향을 완화하기 위한 설계가 적용되어 있다.

SPL3SMP_E 자료는 SMAP Level-1C 밝기온도 관측값을 기반으로 생성된 Level-2 지표면 산출물을 일 단위로 합성한 Level-3 자료로, 9 km의 공간 해상도와 일일 시간 해상도를 가진다. 본 연구에서는 사용된 자료 간 공간해상도 일치를 위해 9 km 격자 자료를 25 km로 보간하였으며, 2015년 7월 1일부터 2022년 6월 30일까지 수집된 수직 및 수평 편광 밝기 온도를 사용하였다.

나. 표면 온도 자료

편광 밝기 온도와 함께 거칠기 산출에 필요한 또 다른 핵심 입력 변수는 표면 온도 자료이다. 이를 위해 본 연구에서는 Copernicus Marine Environment Monitoring Service(CMEMS)에서 제공하는 재분석 기반의 표면 온도 자료를 활용하였다. 해당 자료는 북위 58°이상 북극 해역에 대해 다양한 위성 센서를 통해 관측된 수심 20 cm에서의 해수면 온도 자료와 적외선 위성 센서 기반의 해빙 표면 온도 자료로 구성되어 있다. 일일 시간 해상도와 0.05° 격자의 공간 해상도로 제공되며, 덴마크 기상청에서 개발한 최적 보간 기법을 기반으로 간극 없이 생산된다. 본 연구에서는 다른 자료와의 공간 해상도 일치를 위하여 25 km 격자로 보간하여 활용하였으며, 2015년 7월 1일부터 2022년 6월 30일까지 수집된 자료를 사용하였다.

다. DMSP 위성 시리즈 19.35 GHz 밝기 온도 자료

D2D 모델을 활용한 과거 해빙 거칠기 생성을 위해 Defense Meteorological Satellite Program(DMSP) 위성 시리즈에 탑재된 수동형 마이크로파 센서인 Special Sensor Microwave/Imager(SSM/I)와 SSMIS의 자료를 활용하였다. DMSP 위성은 약 1,700 km에 달하는 넓은 관측 폭과 준극궤도 운용을 기반으로 전 지구를 1-2일 이내에 커버할 수 있으며, 다수의 DMSP F-시리즈 위성들을 통해 약 40년에 걸친 일관성 있는 장기 관측 자료를 제공한다. 두 센서 모두 19.35 GHz, 22.235 GHz, 37 GHz 대역에서 약 53°의 입사각으로 지표를 관측하고 있다.

본 연구에서는 SSM/I와 SSMIS의 센서들을 DMSP F-13 위성을 기준으로 교차보정하여 제공하는 제품인 Calibrated Enhanced-Resolution Passive Microwave Daily EASE-Grid 2.0 Brightness Temperature ESDR 자료(NSIDC-0630, Version 2)를 사용하였다. 보유한 주파수 대역 중 SMAP의 1.41 GHz와 상대적으로 가장 근접한 19.35 GHz의 수직 및 수평 편광 밝기 온도 자료를 선정했으며, 1987년 9월 1일부터 2022년 6월 30일까지 수집하였다. 해당 자료는 25 km의 공간 해상도와 일일 시간 해상도를 가진다.

라. 자료 획득 경로

앞서 언급된 위성 자료들은 다음의 경로를 통해 수집이 가능하다.

- SMAP 밝기 온도: https://nsidc.org/data/spl3smp_e/versions/4
- CMEMS 표면 온도: <https://doi.org/10.48670/moi-00123>
- DMSP 밝기 온도: <https://nsidc.org/data/nsidc-0630/versions/2>

3. 연구내용

본 연구는 수십 년에 걸친 북극 해빙 거칠기의 장기 변동성을 분석하기 위한 선행 연구로서, 장기간에 걸친 해빙 거칠기 자료를 구축하는 것을 목적으로 수행되었다. 사전 연구에서 활용된 L-band 기반의 해빙 거칠기는 SMAP 위성 운용 기간인 2015년 4월 이후부터 가용한 상태로, 이를 이용한 분석 기간이 10년 이내로 제한된다는 한계를 가진다. 이러한 시간적 제약을 극복하기 위해 본 연구에서는 딥러닝 기반의 D2D 모델을 개발하여 SMAP 운용 이전 시기에 대해서도 L-band 기반 해빙 거칠기 산출물과 물리적으로 연관된 자료를 생성하고자 하였다. 이를 통해 보다 장기적인 북극 해빙 거칠기 변동성 분석을 위한 기초 자료를 확보하고자 한다.

가. 해빙 거칠기 산출물

북극 해빙 거칠기는 식 (8)에 정의된 알고리즘을 바탕으로 SMAP 위성의 L-band 수직 및 수평 편광 밝기 온도와 CMEMS 표면 온도를 적용하여 산출하였다. 해당 알고리즘은 표면 유형에 관계없이 거칠기 산출이 가능하며, 본 연구에서는 해빙과 바다를 포함하는 북위 65° 이상의 영역을 대상으로 수행되었다. 해빙 영역에 대한 거칠기 값만을 추출하고자 할 경우엔 해빙 농도 15 %를 임계값으로 설정하여 마스킹 적용함으로써 바다 영역을 제외할 수 있다. 산출된 거칠기는 일반적으로 약 2 cm 이내의 small-scale을 가진다. 그림 1은 여름철에 해당하는 2016년 8월 1일의 일일 거칠기 분포를 시각화한 것으로, 해수면의 거칠기는 0 cm에 가까운 낮은 수치를 보이며, 해빙 표면은 약 1 cm 이상으로 주변 개빙 구역과 뚜렷하게 대비되는 값을 나타낸다.

겨울철에는 북위 70° 이상, 특히 추코트 해와 동시베리아 해를 거쳐 북극해 중심부로 이어지는 다년생 해빙 영역에서 해빙 거칠기 산출이 제한되는 것이 확인되었다. 이는 L-band 밝기 온도가 가진 물리적 감도 특성과 본 연구에서 활용한 CMEMS 표면 온도의 정확도 문제가 복합적으로 작용한 결과로 분석된다. L-band는 약 21 cm의 긴 파장을 가지고 있어 해빙 내부의 brine pockets나 air bubbles와 같은 미세 구조에 의한 체적 산란의 영향이 미미하다(Kaleschke et al., 2010). 따라서 L-band의 밝기 온도는 주로 해빙 두께와 염분에 의해 결정되고, 두꺼운 단년생 또는 다년생 해빙은 염분 배출 현상으로 인해 낮은 염분 농도를 가지므로(Kovacs, 1996), 주된 지배 요인은 해빙 두께가 된다. Tietsche et al. (2018)에 따르면 L-band 위성인 SMOS에서 관측된 밝기 온도는 해빙 두께가 약 0.6 m 이하인 구간에는 뚜렷한 민감도를 보이나, 그 이상의 두께 구간에서는 포화 현상이 나타나 민감도가 급격히 감소한다. 이는 그림 2에서 확인할 수 있다. 이러한 유효 민감도 범위는 해빙의 염분과 온도 조건에 따라 최대 1.5 m까지 도달할 수




그림 1. L-band 기반 거칠기 산출 예시(2016년 8월 1일).




그림 2. 겨울철 SMOS L-band TB와 SIT 산출물 간의 산점도(Tietsche et al., 2018).

있다. 이는 겨울철 해빙이 일정 두께 이상일 경우, L-band 밝기 온도의 변화가 거의 나타나지 않는 영역이 존재함을 의미한다. 한편, 해빙 표면 온도는 해빙 두께가 증가함에 따라 감소하는 경향을 가지며, 겨울철에는 -30°C 이하로 감소할 수 있다. 결과적으로 겨울철의 경우, 밝기 온도는 포화된 상태를 유지하는 반면 표면 온도는 감소하는 해빙 영역이 형성되게 되고, 이로 인해 표면온도가 밝기온도보다 낮아지는 물리적 관계에 위배되는 조건이 발생하게 된다.

그림 3은 겨울철인 2016년 1월 1일에 대해 CMEMS 표면온도와 SMAP의 수직 및 수평 편광 밝기 온도 간의 차이를 시각화한 것으로, 북극 중심부 해빙 영역에서 차이가 음수로 나타나는 지역이 확인된다. 이와 같은 조건은 거칠기 산출 알고리즘의 수치적 오류를 야기하여, 해당 영역에서 거칠기 산출을 제한하는 요인으로 작용한다. 또한 본 연구에서 사용된 CMEMS 표면 온도 자료는 눈층의 존재를 정량적으로 반영하고 있지 않기 때문에 실제 해빙 표면이 아닌 눈 덮개 상단의 온도를 반영할 가능성이 있다. 이 경우 실제 해빙 표면 온도보다 약 15 K 정도 낮게 산출될 수 있으며(Kilic et al., 2019), 그 결과 겨울철 CMEMS 표면 온도는 실제보다 과소 추정될 수 있다.




그림 3. (a) CMEMS 표면 온도, (b-c)CMEMS 표면 온도와 L-band 수직 및 수평 편광 밝기 온도 차이(2016년 1월 1일).

결과적으로 본 연구에서 산출된 거칠기 자료는 결빙기인 10월부터 이듬해 4월 사이에는 북극해 주변의 두꺼운 해빙 분포 영역을 중심으로 산출이 제한되는 영역이 발생함에 유의해야 하며, 그 외의 기간에는 북극 전반의 해빙 영역에서 안정적으로 산출이 가능하다.

나. 학습 모델

장기간에 걸친 북극 해빙 거칠기 자료를 확보하기 위하여, 본 연구에서는 L-band 기반 해빙 거칠기 산출물과 물리적으로 일관된 과거 자료를 생성하는 것을 목표로 D2D 모델을 구축하였다. D2D 모델은 CGAN을 기반의 구조이므로 생성자와 판별자의 상호 경쟁적 학습을 통해 입력 자료와 출력 자료가 쌍을 이루는 지도 학습 방식으로 훈련된다. 이러한 구조는 한 도메인의 자료를 다른 도메인의 자료로 변환하는 데 적합하므로, 관측 시점이 서로 다른 위성 자료를 이용해 과거 시점의 해빙 거칠기 산출물을 재구성하는 본 연구의 목적에 부합하는 모델로 판단되어 채택하였다.

그림 4는 본 연구에서 사용된 D2D 모델 프레임워크를 도식화한 것이다. 생성자는 입력 자료 X 를 기반으로 SMAP 원자료로부터 산출된 해빙 거칠기와 동등한 수준의 출력 Y 를 생성하게 된다. 입력 자료 X 는 장기간의 과거 자료 생성을 가능케 하기 위하여 DMSP 위성 시리즈에 탑재된 SSM/I 및 SSMIS 센서에서 관측된 19.35 GHz 수직 및 수평 편광 밝기 온도로 구성된다. 출력 자료 Y 는 SMAP 위성 자료 기반 L-band 거칠기 자료에 해당된다. 학습 과정에서 입력 자료 X 는 실제 출력 Y 및 생성된 출력 Y' 과 각각 쌍을 이루어 판별자에 제공되며, 판별자는 두 출력 간의 차이를 구분하는 역할을 수행한다. 생성자는 판별자가 생성된 출력 Y' 을 실제 출력 Y 로 인식하도록 목적 함수를 최소화하는 방향으로 학습이 진행되며, 이 과정에서 반복적인 fine-tuning을 통해 출력 자료의 품질이 점진적으로 향상되게 된다.

D2D 모델은 이미지 변환이 아닌 연속적인 원자료 값의 변환을 수행하기 위해 모델의 전후처리 과정으로서 Min-Max 정규화 과정이 포함되며, 이를 통해 입출력 쌍




그림 4. D2D 모델 프레임워크

의 유효한 값들은 0과 1사이의 범위로 변환된다. 결측값이나 pole hole을 포함하는 관심 영역 외의 영역에 대해서는 구분을 명확히 하기 위해 -1의 값을 할당하였으며, 이에 따라 최종적으로 모델에 입력되는 자료의 값 범위는 -1에서 1로 설정되었다. 모델 학습이 완료된 후에는 생성된 L-band 기반 거칠기 값에 대해 역정규화를 수행하여 실제 물리적 해석이 가능한 스케일로 복원하였다. 따라서 개발된 D2D 모델을 활용하면 DMSP 위성 자료를 사용할 수 있는 최대 1987년 9월 1일까지의 과거 기간에 대한 L-band 기반 북극 해빙 거칠기 자료를 생성할 수 있다.

다. 모델 학습 및 검증 자료 구축

D2D 모델 학습과 검증, 테스트는 SMAP 위성 자료 기반 L-band 거칠기와 DMSP 위성 시리즈의 19.35 GHz 수직 및 수평 편광 밝기 온도의 일자료가 사용되었다. 입출력 자료 값의 공간적 일관성을 확보하여 안정적인 학습이 수행될 수 있도록, 계절에 따라 변동하는 해빙 범위에 국한하지 않고 바다 영역까지 포함하는 북위 65° 이상의 데이터를 사용하였다. 거칠기와 DMSP 자료의 공간 해상도는 각각 9 km와 25 km로 서로 다르기 때문에 DMSP의 위경도를 기준으로 최근접 이웃 보간법을 적용하여 공간 해상도를 일치시켰다. 입출력 자료의 크기는 $n \times 256 \times 256$ 으로 구성된다(n 은 채널수에 해당). 전체 연구 자료 기간은 1987년 9월 1일부터 2022년 6월 30일까지로, 모델 학습에는 2015년 7월 1일부터 2020년 6월 30일까지(1,791쌍), 검증에는 2020년 7월 1일부터 2021년 6월 30일까지(363쌍), 테스트에는 2021년 7월 1일부터 2022년 6월 30일까지(365쌍)의 자료를 할당하였다. SMAP 관측 이전 시기에 해당되는 2015년 7월 이전의 9,776개 자료는 unseen 자료로 분류하여 장기 거칠기 생성에 활용하였다.

4. 연구결과

가. 가상의 과거 해빙 거칠기

(1) 정량적 평가

일 년 기간의 테스트 자료 셋을 사용하여 D2D 모델로 생성된 가상의 L-band 거칠기에 대한 정량적 평가를 수행하였다. 평가를 위해 Pearson correlation coefficient(CC), bias, Root mean square Error(RMSE), Mean Absolute Error(MAE)를 지표로 설정하여 L-band 관측 기반의 거칠기 산출물과 모델로 생성된 L-band 거칠기를 비교하였다.

그림 5는 학습에 사용된 해빙 및 바다 영역에 대한 실제 거칠기 산출물과 가상의

생성된 거칠기 간의 산점도로 통계 수치와 선형 회귀 분석 결과를 함께 보여준다. CC가 0.9289로 매우 강한 상관성을 나타냈고, bias는 0.0037 cm로 무시할 수 있는 수준의 오차를 보였다. 선형 회귀선은 일대일 기준선을 밀접하게 따르고 있으며, 이는 실제 값과 생성된 값 간의 우수한 일관성을 의미한다. 또한 RMSE와 MAE는 각각 0.0691 cm와 0.0443 cm로, 해당 수치는 약 2 cm의 거칠기 범위 대비 약 2-3 % 수준의 낮은 오차율에 의미한다. 따라서 이러한 결과를 통해 D2D 모델이 국지적인 이상치 발생 없이 실제 L-band 거칠기의 전반적인 공간적, 통계적 특성을 안정적으로 재현하고 있음을 확인할 수 있다.




그림 5. L-band 관측 기반의 거칠기와 가상의 D2D 생성 결과 산포도.

추가로 테스트 기간인 2021년 7월 1일부터 2022년 6월까지의 시계열 자료를 기반으로 L-band 관측 기반 거칠기와 D2D 모델 생성 L-band 거칠기의 일평균 변동 양상을 비교 분석하였다(그림 6). 해당 기간 동안 관측 기반 거칠기는 여름철에 상대적으로 낮은 값을 보이다가 결빙기로 진행됨에 따라 점진적으로 증가하는 계절적 변동 특성을 보였으며, D2D 모델로 생성된 거칠기 또한 이러한 계절성 기반의 장기 변동 패턴을 잘 유지되는 것이 확인되었다. 일 단위의 단기 변동성 측면에서는 11월과 3월에 가장 차이가 두드러졌으며, 이 차이는 평균 약 0.06 cm 수준의 작은 오차로 나타났다. 이는 해당 기간에 해빙 면적 변화가 급격히 발생하기 때문으로 이해할 수 있다. 따라서 이러한 결과를 통해 D2D 모델이 L-band 관측 기반 해빙 거칠기의 계절적 변화와 일일 변동을 동시에 잘 재현하고 있음을 확인할 수 있으며, 과거 시점에서의 자료 확장에 활용하기에 충분한 신뢰성을 가진 성능을 갖추었음을 입증한다.




그림 6. 일평균 L-band 거칠기의 시계열 (테스트 셋, 2021년 7월 - 2022년 6월).

(2) 정성적 평가

그림 7은 테스트 기간을 대표하는 2021년 9월 1일, 12월 1일, 2022년 3월 1일, 6월 1일자 자료를 대상으로 한 정성적 비교 결과를 보여준다. 해당 결과에서는 거의 일관된 값을 가지는 바다를 제외하고 해빙 거칠기만을 비교하기 위해 해빙 농도 15%를 기준으로 해빙 영역만을 남긴 결과를 나타내었다. D2D 생성 결과는 L-band 관측 기반 해빙 거칠기의 전반적인 공간 패턴을 유사하게 재현하고 있는 것이 확인되었다. 9월과 6월 사례의 경우, 얇은 해빙에서의 낮은 거칠기와 두꺼운 해빙에서의 높은 거칠기 경향이 공간적으로 일관되게 나타났다. 반면, 12월과 3월 사례에서는 앞서 설명된 L-band 밝기 온도의 포화 특성 및 CMEMS 표면 온도 자료의 물리적 불일치로 인해 약 1 m 이상의 두꺼운 해빙 영역에서 거칠기 산출이 제한되는 것이 확인되었다. 차이 분포를 살펴보면, 특정 시기나 지역에 편향된 오차가 발생하기 보다는 대부분의 영역에서 ± 0.5 cm 이내의 편차가 산발적인 분포를 보였는데, 이는 전체 분포 패턴의 평균적 일치를 최적화하도록 설정된 D2D 모델의 학습 목표에서 기인한 결과로 보인다. 해빙이 급격히 결빙되거나 융해되는 시기인 12월과 3월은 9월과 6월에 비해 약 0.2 cm 수준의 상대적으로 큰 오차가 관찰되었으며, 이는 앞선 일평균 시계열 분석 결과의 변동 양상과 일관된 경향으로 확인된다. 따라서 D2D의 생성 결과는 전반적인 거칠기 추세 복원에는 효과적이나, 해빙 상태가 급격히 변화하는 시기에는 국지적인 정밀도가 다소 하락할 수 있음이 확인되었다. 이러한 결과는 향후 장기 해빙 거칠기의 시계열 복원 시 시기별 오차 특성을 반영한 추가 보정을 통해 개선될 수 있으며, 통계 지표와 공간적 정합성을

종합적으로 고려해 볼 때 본 연구에서 개발된 D2D 모델은 실제 L-band 기반 거칠기 산출물의 과거 기간 확장을 위한 보조 수단으로서 충분한 타당성을 확보한 것으로 판단된다.

(3) 과거 L-band 기반 거칠기

D2D 모델을 활용하여 과거 시점의 L-band 기반 거칠기를 생성하였으며, 그림 8은 1987년 9월 1일부터 2015년 6월 30까지 D2D 모델로 생성한 장기 일평균 시계열 변화를 보여준다. 이러한 결과는 SMAP 위성의 운용 기간 제약으로 인해 10년 미만에 불과했던 관측 기반 L-band 거칠기 자료를 약 38년에 달하는 장기 자료 셋으로 확장했다는 점에서 의의가 있다. 이를 통해 과거부터 현재를 아우르는 연속적이고 일관된 거칠기 분석이 가능해지게 된다. D2D 기반 과거 L-band 거칠기 시계열에서도 실제 관측 기반 L-band 거칠기와 동일한 계절적 주기성이 확인되었다. 이때 겨울철의 평균 거칠기 값은 일정한 수준을 유지하는 반면, 여름철 평균 거칠기 값은 2000년대 후반 이후부터 급격히 감소하는 추세가 관찰되었다. 이는 일평균 거칠기 계산 과정에서 해빙과 바다를 모두 포함하기 때문으로, 거칠기가 낮은 바다 영역의 비중이 증가된 결과로 해석할 수 있다. 이러한 여름철 감소 경향성은 최근 가속화되고 있는 북극 해빙 면적의 감소 추세와도 일치한다.

그림 9는 D2D 모델로 생성된 과거 L-band 해빙 거칠기 생성 예시로, SMAP 위성이 운용되지 않는 1987년 9월 1일과 2010년 7월 1일에 대한 공간 분포를 보여준다. 이렇게 생성 및 구축된 장기 시계열 자료는 향후 북극 해빙의 표면 특성과 기후 변화 간의 상관관계를 더욱 장기적이고 체계적인 관점에서 분석할 수 있는 기초 데이터로 활용될 수 있다.




그림 7. 테스트 기간의 L-band 관측 기반 및 D2D 생성된 해빙 거칠기 비교:
 (a)2021년 9월 1일, (b)2021년 12월 1일, (c)2022년 3월 1일, (d)2022년 6월 1일.




그림 8. 과거 일평균 L-band 거칠기의 시계열 (1987년 9월 - 2015년 6월).




그림 9. D2D 모델 기반 L-band 거칠기 생성물 예시:
(a)1987년 9월 1일, (b)2010년 7월 1일.

제 2절 북극 해빙 거칠기 예측 연구

1. 이론적, 실험적 접근 방법

가. Data-to-Data

L-band 기반 북극 해빙 거칠기의 12개월 예측을 수행하기 위하여 앞서 '제 1절. 과거 북극 해빙 거칠기 생성 연구'에서 사용되었던 D2D 모델을 동일하게 적용하였다. 해당 모델은 서로 다른 도메인 간의 변환을 수행하는 구조를 가지기 때문에 입출력 자료 쌍을 어떻게 구성하는지에 따라 예측 연구에도 사용이 가능하다. D2D 모델에 대한 상세한 설명은 앞선 '3장-1절-1-다'에서 이미 제시한 바 있다.

2. 연구자료

가. DMSP 위성 시리즈 19.35 GHz 밝기 온도 자료

본 연구에서는 L-band 거칠기 예측 모델을 개발하기 위해 DMSP F-시리즈에 탑재된 SSM/I 및 SSMIS 센서의 19.35 GHz 수직 및 수평 편광 밝기 온도 자료를 사용하였다. 해당 자료는 앞서 '3장-1절-2-다'에서 설명된 DMSP 편광 밝기 온도 자료와 동일하며, 본 연구에서는 1988년 1월 1일부터 2024년 8월 31일까지의 기간에 해당하는 자료를 월평균하여 활용하였다.

3. 연구내용

표면 거칠기는 해빙의 물리적 상태 변화와 구조적 진화를 반영하는 중요 지표로 북극 해빙의 미래 변화를 예측하는 데 중요한 정보를 제공한다. 이에 본 연구에서는 북극 해빙 변화의 선제적 분석을 위해 월평균 L-band 거칠기를 대상으로 12개월 월별 예측 모델을 개발하였다.

가. 학습 모델

L-band 거칠기의 12개월 월별 예측 과정은 그림 10과 같이 2단계의 프레임워크를 통해 수행된다. 첫 번째 단계로, 긴 관측 기록을 가진 DMSP 위성 시리즈의 19.35 GHz 수직 및 수평 편광 밝기 온도 자료를 각각 독립적인 D2D 모델로 학습하여 향후 12개월에 대한 밝기 온도를 예측한다. 각 편광별 밝기 온도 예측 모델의 입력 자료 X 는 예측을 시작하고자 하는 기준 시점 t 를 기준으로 $t-12$ 부터 $t-1$ 의 연속된




그림 10. L-band 거칠기의 12개월 월별 예측 프레임워크.

과거 12개월 중첩 자료로 구성되고, 출력 자료 Y 는 예측 목표 기간인 t 부터 $t+11$ 의 12개월 중첩 자료로 구성된다. 학습 과정에서 생성자와 판별자는 식 (10)의 목적 함수를 최소화하는 방향으로 경쟁적하며 학습을 진행한다.

이후 두 번째 단계에서는 앞선 '제 1절. 과거 북극 해빙 거칠기 생성 연구에서 검증된 L-band 거칠기 생성 모델을 활용하였다. 1단계에서의 DMSP 밝기 온도 예측치를 앞서 개발된 생성 모델의 입력 변수로 사용함으로써, 최종 예측 목표 시점의 L-band 거칠기를 생성한다. 앞서 개발된 L-band 거칠기 생성 모델은 DMSP의 수직 및 수평 편광 밝기 온도를 채널 중첩된 형태로 입력받는 구조이기 때문에, 1단계에서 예측된 밝기 온도 결과물을 생성 모델의 입력으로 적용할 수 있다. 이때, 1단계에서는 육지가 포함되어 학습이 이루어지므로, 2단계에 입력 전에 육지 마스킹이 수행되었다. 이와 같이 계절적 변동성이 일관되고 장기간 관측 자료가 확보된 DMSP 편광 밝기 온도를 중간 매개변수로 우선 예측하는 방식은, L-band 거칠기를 직접 예측하는 방식에 비해 최종 산출물의 안정성과 예측 신뢰도를 향상시킬 수 있다.

나. 모델 학습 및 검증 자료 구축

1단계인 DMSP 밝기 온도 예측 모델의 학습, 검증 및 테스트에는 DMSP 위성 시리즈의 19.35 GHz 수직 및 수평 편광 월평균 자료가 사용되었다. 모델의 안정적인 학습을 위해 해빙뿐만 아니라 육지와 바다를 모두 포함하는 북위 65° 이상의 영역을 학습 도메인으로 설정하였다. 이에 따라 입출력 자료는 12개월의 시계열 정보를

포함하는 12 x 256 x 256 크기로 구성된다. 자료 셋은 학습에 1988년 1월부터 2022년 8월까지(393쌍)의 자료를 할당하였고, 검증에 2020년 10월부터 2023년 8월까지(12쌍), 테스트에 2021년 10월부터 2024년 8월까지(12쌍)의 자료를 사용하였다. 2단계의 모델 학습 방법에 대해서는 앞선 '3장-1절-3-다'에서 이미 제시했으므로, 본 단락에서는 생략한다.

4. 연구결과

테스트 기간의 자료 셋을 사용하여 D2D 모델로 12개월 예측된 가상의 DMSP 19.35 GHz 수직 및 수평 편광 밝기 온도에 대한 정량적, 정성적 평가를 수행하였다. 정량적 평가 지표로는 CC와 bias, RMSE가 사용되었다. 이후 예측된 DMSP 밝기 온도 자료를 기반으로 최종적인 12개월 예측된 가상의 L-band 거칠기 자료를 생성했고, 이를 SMAP 위성 관측 자료 기반의 L-band 거칠기 산출물과 비교하였다.

가. DMSP 19.35 GHz 편광 밝기 온도 예측

(1) 정량적 평가

그림 11은 테스트 셋 기간에 대한 DMSP 19.35 GHz 수직 편광 밝기 온도의 12개월 예측 결과의 정량적 통계 지표를 보여준다. CC는 1개월 예측에서 0.972로 가장 높은 값을 보였고 예측 리드 타임이 증가할수록 감소하는 경향을 나타냈다. 그럼에도 불구하고 10개월 이후의 예측에서도 약 0.95 수준을 유지하여, D2D 예측 모델이 실제 DMSP 관측 자료의 계절 변동성을 효과적으로 학습하고 높은 일관성을 유지하고 있음을 확인하였다. Bias는 모든 리드 타임에 걸쳐 ± 2 K 이내로 나타났으며, 6개월 예측까지는 약간의 과대 추정을 보이다가 이후부터는 과소 추정으로 전환되는 경향을 보였다. 또한 4-7개월 예측 구간에서는 bias가 거의 0 K에 가까워져 원자료와의 편향이 거의 없는 것이 확인되었다. RMSE는 CC의 변화 양상과 일관되게 예측 리드 타임이 증가할수록 점차 증가하는 경향을 보였다. 특히 3-9개월 예측 구간에서 약 8 K 수준의 일관된 값을 유지하다가 11개월 예측에서 약 9 K으로 가장 큰 오차가 나타났는데, 이러한 결과는 예측 기간이 길어질수록 D2D 예측 모델의 밝기 온도 재현 능력이 상대적으로 저하될 수 있음을 의미한다.




그림 11. DMSP 19.35 GHz 수직 편광 밝기 온도 12개월 예측 통계 수치.

그림 12는 DMSP 19.35 GHz 수평 편광 밝기 온도의 12개월 예측 결과에 대한 정량적 통계 결과를 나타낸다. CC는 1개월 예측에서 약 0.975로 가장 상관성이 높았고, 리드 타임 증가에 따라 변동은 있으나 전 기간에 걸쳐 0.96 이상의 높은 상관성을 유지하였다. Bias의 경우, 1-3개월 예측 구간에서는 -2 K 미만의 과소 추정 경향이 나타났으며, 4개월 예측 이후부터는 과대 추정으로 전환되어 수직 편광과 상반된 오차 경향을 보였다. 수직 편광에서 6개월 예측 시점에 bias가 0 K에 근접했던 것과 유사하게, 수평 편광에서는 7개월 예측 시점에서 편향이 최소화되는 것이 확인되었다. RMSE는 수직 편광의 예측 결과와 마찬가지로 예측 리드 타임이 증가할수록 점차 증가하는 경향이 나타났는데, 전반적으로 10-13 K 수준의 상대적으로 높은 오차 범위를 보였다. 이는 수평 편광이 수직 편광에 비해 표면 거칠기와 유전적 상태 변화에 더 민감하게 반응하기 때문으로 해석된다. 따라서 수평 편광 예측 결과에서는 지역적 이상치 발생 정도가 수직 편광에 비해 다소 높게 나타날 수 있지만, 그림에도 우수한 CC 값을 통해 전반적인 밝기 온도 패턴은 효과적으로 예측하고 있음을 알 수 있다. 또한 예측된 수직 및 수평 편광 밝기 온도 결과를 계절별로 비교한 결과, 겨울철 예측 성능이 여름철에 비해 상대적으로 우수하게 유지되는 것으로 나타났다. 이는 여름철에는 해빙의 융해로 인해 해빙 가장자리와 표면의 물리적 상태가 변화하여 밝기 온도의 변동성이 커지는 반면, 겨울철에는 해빙의 공간




그림 12. DMSP 19.35 GHz 수평 편광 밝기 온도 12개월 예측 통계 수치.

분포가 넓게 유지되기 때문에 예측 안정성이 향상되기 때문이다. 이러한 결과들을 종합해볼 때, D2D 예측 모델이 예측 리드 타임 증가에 따른 오차 증가에도 불구하고, 계절적 특성을 적절히 반영하여 전 기간에 걸친 북극 지역의 밝기 온도 변동을 안정적으로 예측함을 알 수 있다.

(2) 정성적 평가

그림 13과 14는 2022년 4월부터 2023년 3월까지의 자료를 입력으로 사용하여, 2023년 4월부터 2024년 3월까지 DMSP 19.35 GHz 수직 및 수평 편광 밝기온도를 12개월 예측한 결과로, 각 그림의 (a)-(d)는 각각 리드 타임 1, 4, 7, 10개월에 해당하는 예측 결과를 제시한다. 공간 분포 측면에서 D2D 예측 모델은 북극 전역에 걸쳐 실제 DMSP 위성 관측 자료의 주요 패턴을 유사하게 재현하는 것으로 나타났다. 해빙이 분포하는 중심부의 상대적으로 높은 밝기 온도 영역과 바다의 낮은 밝기 온도 영역을 명확히 구분하고 있으며, 대규모 공간 패턴이 안정적으로 유지되었다. 그러나 계절 변화에 따른 해빙 면적의 변동과 그에 따른 밝기 온도 변화로 인해 해빙-바다 경계를 중심으로 상대적으로 큰 오차가 발생하는 경향이 확인되었다. 앞서 정량적 분석 결과와 일관되게, 해빙 면적이 넓게 유지되는 4월과 1월의 예측




그림 13. DMSP 19.35 GHz 수직 편광 밝기 온도 예측 결과:
(a)리드타임 1개월, (b)리드타임 4개월, (c)리드타임 7개월, (d)리드타임 10개월.




그림 14. DMSP 19.35 GHz 수평 편광 밝기 온도 예측 결과:
(a)리드타임 1개월, (b)리드타임 4개월, (c)리드타임 7개월, (d)리드타임 10개월.

결과에서는 산포도가 일대일 기준선 부근에 밀집되어 작은 오차 분포가 나타났다. 반면 해빙이 녹고 있는 7월과 재결빙이 시작되는 10월에는 해빙-바다 경계 영역에 해당하는 180-220 K 범위에서 산포도의 분산이 확대되는 경향이 확인되었다. 이러한 결과는 해빙 상태가 빠르게 변화하는 시기에 모델 예측의 불확실성이 증가할 수 있음을 의미한다. 그럼에도 불구하고 개발된 D2D 예측 모델은 수직 및 수평 편광 모두에서 실제 관측 자료의 공간적, 계절적 패턴과 물리적 분포 특성을 효과적으로 예측하고 있기 때문에, 예측된 두 편광 성분의 밝기 온도 결과는 과거 해빙 거칠기 생성을 위한 신뢰성 있는 자료로서 다음 단계인 L-band 해빙 거칠기 생성 모델에 적합한 입력 자료로 활용할 수 있다.

나. L-band 거칠기 예측

개발된 DMSP 밝기 온도 예측 모델과 L-band SIR 생성 모델을 연계한 2단계 프레임워크를 통해 최종적인 L-band 거칠기 12개월 예측을 수행하였다. SMAP 관측 자료 기반의 L-band 거칠기 산출물과 예측된 DMSP 밝기 온도를 입력으로 생성된 가상의 L-band 거칠기를 비교했을 때 0.92의 높은 CC 값을 보여주었다.

그림 15는 DMSP 예측 편광 밝기 온도와 이를 기반으로 생성한 리드 타임 9개월 시점의 2022년 9월 L-band 거칠기 결과이다. 이때 동일한 타겟 월이라 하더라도 예측 리드 타임이 짧은 경우에 예측 성능이 향상되는 결과를 보였다. 이는 앞서 정량적 평가에서 확인된 바와 같이, 1개월 리드 타임의 예측 결과가 5개월 리드 타임 결과에 비해 L-band 거칠기의 물리적 특성을 더 정밀하게 생성한다는 것을 의미한다.




그림 15. DMSP 예측 편광 밝기온도 기반 L-band 해빙 거칠기 예측 결과(2022년 9월, 리드타임 9개월).

그림 16은 2022년 7월 15일의 SMAP 원자료 기반 일일 L-band 거칠기와 예측 모델 기반 2022년 7월 월평균 L-band 거칠기를 비교한 결과이다. 예측 모델 결과가 두꺼운 해빙 영역에서 거칠기를 과대 추정하는 경향을 보였으나, 전반적인 지역적 분포 패턴은 원자료 기반 거칠기와 매우 유사함이 확인되었다.

다만, 본 연구에서 사용된 L-band 거칠기 산출 알고리즘의 물리적 특성상 모델 결과물을 사용할 때 주의가 필요하다. 해빙 두께 1 m 이상의 두꺼운 해빙 영역에서는 산출 제약이 존재하므로 유효 값을 제공하지 않아야 하나, D2D 생성 모델의 학습 과정에 이러한 물리적 관계를 반영할 수 없기에 겨울철 두꺼운 해빙 영역에서 비정상적인 거칠기 값을 생성하는 현상이 확인되었다. 따라서 현재는 후처리로서 해빙 두께 자료를 활용하여 두께에 따른 유효 거칠기 산출 영역을 마스킹해야 한다. 이러한 물리적 제약의 모델 내 내재화 방안은 향후 연구를 통해 개선될 예정이다.




그림 16. (좌)SMAP 원자료 기반 및 (우)예측 모델 기반 L-band 해빙 거칠기 비교.

제 3절 북극 해빙 농도 예측 연구

1. 이론적, 실험적 접근 방법

가. Data-to-Data

북극 해빙 농도의 12개월 예측을 수행하기 위하여 앞서 '제 1절. 과거 북극 해빙 거칠기 생성 연구'에서 사용되었던 D2D 모델의 구조를 적용하였다. 해당 모델은 서로 다른 도메인 간의 변환을 수행하는 구조를 가지기 때문에 입출력 자료 쌍을 어떻게 구성하는지에 따라 예측 연구에도 사용이 가능하다. D2D 모델에 대한 상세한 설명은 앞선 '3장-1절-1-다'에서 이미 제시한 바 있다.

나. PyCaret

D2D 모델의 성능 개선을 위해 최적의 기상 변수를 선정하는 과정에서 Python 기반의 오픈소스 라이브러리인 PyCaret을 활용하였다. PyCaret은 전처리, 모델 학습, 튜닝 및 분석 과정을 자동화하여 단시간 내에 다양한 머신러닝 알고리즘의 성능을 비교할 수 있게 한다. 본 연구에서는 이를 통해 복잡한 북극 기후 인자들 사이에서 해빙 농도와 상관성이 가장 높은 핵심 변수를 효율적으로 도출하였다.

2. 연구자료

본 연구에서는 해빙 농도 12개월 예측 모델을 개발하기 위하여, 장기간의 시계열 분석에 용이한 월평균 해빙 농도 자료와 해빙 변동에 영향을 미치는 주요 기상 변수 자료를 수집하였다.

가. 해빙 농도 자료

12개월 단위의 장기 해빙 농도 예측 모델을 구축하기 위해서는 장기간 축적된 시계열 자료가 필수적이다. 이에 1970년대 후반부터 현재까지 연속적인 관측이 수행되고 있는 DMSP 시리즈 기반의 해빙 농도 산출물을 주요 학습 자료로 선정하였다.

NASA NSIDC에서 제공되는 NOAA/NSIDC Climate Data Record of Passive Microwave Sea Ice Concentration(G02202, Version 4)를 사용하였으며, 해당 자료는 SMMR, SSM/I, SSMIS 등 서로 다른 위성 센서 간의 정밀한 검보정 과정을 거쳐 제공된다. 이는 장기 변동성 연구에서 발생할 수 있는 센서 교체에 따른 오차를

최소화하고 물리적 일관성을 확보한 자료라는 점에서 본 예측 연구에 채택되었다. 해당 자료는 일일 시간 해상도와 25 km의 공간 해상도를 가지며, 모델 학습의 효율성과 시계열적 연속성을 고려하여 1979년 1월부터 2022년 12월까지 총 44년간의 자료를 수집 후 월평균하여 사용하였다.

나. ERA5 기상 변수

해빙의 변동은 단순한 과거 패턴의 반복이 아닌 대기 및 해양과의 상호작용에 의해 결정된다. 해빙 농도 예측을 위해 월평균 해빙 농도 자료만 사용할 시, 해빙의 변동성이 아닌 계절적 변동성에 의존하게 되므로 이러한 문제를 최소화하고자 기상 변수를 고려하였다. 따라서 예측 모델의 물리적 정확도를 향상시키기 위해 European Centre for Medium-Range Weather Forecasts (ECMWF) Reanalysis 5 (ERA5) 자료로부터 해빙과 상관성이 높은 주요 기상 인자들을 추가 입력 변수로 사용하였다. ERA5 기상 자료는 약 12 km의 높은 공간 해상도로 제공되며, 앞선 해빙 농도 자료와 동일한 기간인 1979년부터 2022년까지의 장기 월평균 데이터를 수집하였다.

다. 자료 획득 경로

앞서 언급된 위성 자료들은 다음의 경로를 통해 수집이 가능하다.

- 해빙 농도: <https://nsidc.org/data/g02202/versions/4>
- ERA5 기상 변수: 10.24381/cds.f17050d7

3. 연구내용

가. 학습 모델

과거 해빙 자료의 특성을 학습하여 미래 시점의 해빙 농도를 생성하기 위해, 이에 탁월한 성능을 보이는 Pix2Pix의 변형 모델인 D2D를 사용하였다. 앞서 언급한 바와 같이, D2D 모델은 내부적으로 Min-Max 정규화 및 역정규화 과정을 포함하고 있어, 0-100 % 범위의 실제 해빙 농도 값을 생성할 수 있다. 본 연구에서는 ResNet 블록을 포함한 U-Net 구조의 생성자와, 국부적 패턴 판별에 유리한 70 x 70 PatchGAN 판별자를 사용하였다. 예측 모델의 입출력 쌍은 과거 연속된 12개월의 자료를 입력받아 미래 12개월의 월평균 해빙 농도를 예측하는 시퀀스 기반 구조로 구성하였다.

나. 기상 변수 도입의 효과

해빙 농도 예측을 위한 D2D 모델의 입력 자료 구성에 따른 성능 차이를 평가하기 위해, 해빙 농도 단일 변수를 입력으로 사용한 기본 모델과 ERA5 기상 변수를 추가로 포함한 개선 모델을 비교 실험하였다. 그 결과, ERA5 기상 변수를 도입한 개선 모델은 기존 단일 입력 모델 대비 뚜렷한 성능 향상을 보였다. CC는 0.6996에서 0.7776으로 약 11.15% 향상되었으며, RMSE는 0.1540에서 0.1359로 약 11.75% 감소하여, 기상 인자 도입의 타당성이 정량적으로 확인되었다.




그림 17. (좌)해빙 농도 단일 입력 모델과 (우)기상 변수 도입 모델의 해빙 농도 예측 성능 비교.

다. 머신러닝 기반 학습 자료 선정

해빙 예측 성능 향상을 위한 최적의 기상 입력 변수를 선정하기 위해, PyCaret 패키지를 활용한 변수 중요도 분석을 수행하였다. 변동성이 큰 북극 환경의 특성을 반영하기 위해 트리 기반의 머신러닝 모델인 Gradient Boosting Regressor(GBR), Light Gradient Boosting Machine(LGBM), Extra Tree Decision(EXT), Adaptive Boost(ADA)를 적용하여 변수 간의 비선형적 상관 관계를 분석하였다. 네 가지 머신러닝 모델에서 공통적으로 상위 중요도를 가지는 변수들을 비교한 결과, 해수면 온도(sea surface temperature, SST)와 2m 기온(2m temperature, T2m)이 가장 지배적인 영향력을 보였으며, 지표 기압(surface pressure, SFP), 10m 풍속(10m wind speed, WSP), 증발량(evaporation, EVP) 또한 해빙의 유동성에 유의미하게 기여하는 변수임을 확인하였다. 이에 따라 중요도가 일정 수준 이상을 보인 5가지 변수를 최종적인 추가 입력 변수로 확정하였다. 이러한 방식의 입력 변수 구성은 해빙의 열역학적 변화뿐만 아니라 풍속 및 증발량과 같은 역학적 요인을 함께 반영할 수 있기 때문에 예측 모델의 물리적 설명력 향상에 효과적이다.




그림 18. 머신러닝 모델별 기상 변수의 기여도 비교.

라. 모델 학습 및 검증 자료 구축

북위 50°에서 87°까지를 연구 영역으로 설정하였다. 특히 북위 87°는 위성 센서 관측의 한계로 발생하는 Pole Hole 문제를 극복하기 위해, SMMR 센서의 최대 관측 위도를 기준으로 설정하여 장기 자료 내의 불연속성이 발생하지 않도록 하였다. 해빙 농도 15% 미만의 영역은 물리적 임계치를 적용하여 바다 영역으로 분류하고 마스크 처리하였다. 모든 입력 자료는 해빙 농도 자료를 기준으로 25 km 공간 해상도로 일치시켰으며, 전체 자료는 학습 기간으로 1979-2018년, 검증 기간으로 2019-2021년, 테스트 기간으로 2022년을 각각 사용하였다.

4. 연구결과

개발된 D2D 기반 12개월 해빙 농도 예측 모델의 성능을 검증하기 위하여, 일 년 치 테스트 자료 셋을 대상으로 모델 예측 결과와 NSIDC 해빙 농도 원자료 간의 비교 분석을 수행하였다.

가. NSIDC 해빙 농도와 비교

2022년 3월 월평균 해빙 농도 예측 결과를 NSIDC 해빙 농도 원자료와 비교한 결과, 북극 전역에 걸친 해빙의 대규모 공간 분포 패턴이 전반적으로 유사하게 재현됨을 확인하였다(그림 19). 해당 그림은 2022년 1월부터 12월까지의 입력데이터 중 세 번째 입력 변수에 해당되며, 해빙의 경계선 부근에서 나타나는 농도의 점진적 변화와 공간적 연속성이 원자료 값과 정성적으로 높은 유사성을 보였다. 또한 기상 변수가 통합된 D2D 예측 모델은 기존 단일 입력 모델에서 모호하게 표현되었던 그린란드 동해안 및 보퍼트 해 인근의 해빙 농도를 더욱 선명하게 생성하였다. 이는 연안 지역의 기상 변동이 모델에 반영되면서 육지 인근의 복잡한 해빙 분포를 더욱 세밀하게 예측할 수 있게 된 결과로 해석된다.




그림 19. 2022년 3월의 월평균 해빙 농도 예측 결과:
(상)해빙 농도 단일 입력 모델, (하)기상 변수 도입 모델.

나. 해빙 농도 시계열 분석

테스트 셋에 대한 시계열 분석 결과, 모델은 해빙의 계절적 변동 주기를 효과적으로 추적하는 것으로 나타났다. 해빙 농도 자료를 단일로 입력한 예측 모델의 경우, 여름철 융해기가 진행되며 해빙 농도가 가장 낮아지는 시점에서 실제 값에 비해 농도를 높게 예측하는 경향이 관찰되는데, 이는 정규화 과정에서의 발생된 정보 손실

과 학습 모델의 구조적 한계로 판단된다. 반면, 기상 변수를 추가한 개선 모델은 재결빙이 시작되는 10-12월 구간에서 원자료에 나타나는 해빙 농도 회복 추세를 정밀하게 따랐다. 특히 연말로 갈수록 해빙 농도의 증가 패턴이 원자료의 기울기와 거의 일치하는 양상을 보이며, 기상 변수의 도입이 예측 모델의 장기 예측 안정성을 유의미하게 향상시켰음을 확인할 수 있다.




그림 20. 2022년 NSIDC 관측치와 개선 전·후 D2D 모델 예측된 월평균 해빙 농도 시계열 비교: (좌)NSIDC 월평균 해빙 농도, (우상)해빙 농도 단일 입력 모델, (우하)기상 변수 도입 모델.

제 4 장 연구개발목표 달성도 및 대외기여도

제 1절 연구개발목표 달성도

성과목표	세부목표	달성 주요내용	달성도 (%)	비고
과거 북극 해빙 거칠기 생성 연구	위성 밝기온도 자료 수집 및 해빙 거칠기 산출물 생성	- 수동형 마이크로파 위성 밝기온도 자료 수집 - SMAP L-band 해빙 거칠기 일자료 산출	100%	
	딥러닝 기법을 이용한 과거 해빙 거칠기 생성 모델 개발	- 과거 해빙 거칠기 생성 모델 개발	100%	
	모델 생성된 가상의 해빙 거칠기 결과 제시	- 가상의 과거 해빙 거칠기 생성 결과 제시 - 가상의 해빙 거칠기 생성물과 원자료 간의 일관성 분석	100%	
북극 해빙 거칠기 예측 연구	딥러닝 기법을 이용한 미래 해빙 거칠기 예측 모델 개발	- 미래 해빙 거칠기 예측 모델 개발	100%	
	예측 모델을 이용한 해빙 거칠기 산출물 결과 제시	- 미래 해빙 거칠기 결과 제시	100%	
북극 해빙 농도 예측 연구	수동형 마이크로파 위성 해빙 농도 자료 수집	- 해빙 농도 예측 모델 개발을 위한 해빙 농도 산출물 자료 수집	100%	
	딥러닝 기법을 이용한 미래 해빙 농도 예측 모델 개발	- 미래 해빙 농도 예측 모델 개발 - 머신러닝 기반 변수 중요도 분석을 활용한 예측 모델 성능 개선	100%	
	예측 모델을 이용한 해빙 농도 예측 결과 제시	- 1년 예측된 해빙 농도 결과의 정성적, 정량적 결과 제시	100%	

제 2절 대외기여도

1. 학술적 파급효과

본 연구는 수동형 마이크로파 위성 관측 자료를 활용한 북극 해빙 거칠기와 해빙 농도의 생성 및 예측 기법을 개발함으로써, 북극 해빙 연구의 시공간적 한계를 극복했다는 점에서 학술적 의의를 가진다. 특히 관측 기간의 한계로 인해 10년 미만 에 머물렀던 L-band 기반 해빙 거칠기 자료를 DMSP 시리즈 위성의 장기 관측 자료와 D2D 딥러닝 모델을 활용하여 약 40년에 걸친 장기 시계열 자료로 확장하였다. 이를 통해 북극 해빙 표면 특성의 장기 변동성을 수십년 규모에서 분석할 수 있는 과학적 기반을 마련했으며, 급격한 북극 온난화와 연계된 해빙의 물리적 구조 변화를 지속적으로 추적할 수 있는 핵심 지표를 제공한다. 또한 본 연구에서 제안된 D2D 모델은 서로 다른 주파수 대역의 위성 관측 자료 간 물리적 일관성을 유지하면서 도메인 변환과 시계열 예측을 모두 수행할 수 있는 유연한 프레임워크를 제시한다. 이러한 접근법은 기존 이미지 중심의 생성 모델이 가진 한계를 보완하고, 향후 다양한 위성 센서 간 자료 융합 및 시계열 생성 연구에 폭넓게 활용될 수 있다. 아울러 머신러닝 기반 변수 중요도 분석을 통해 해빙 농도 예측에 핵심적인 기상 변수를 체계적으로 선정함으로써, 딥러닝 모델의 물리 기반 해석력을 향상시켰다.

본 연구의 핵심 기술과 성과는 다음과 같이 IEEE TGRS에 게재되었다.

Jo, S., Kim, H. C., & Hong, S. (2025). Reconstructing pre-SMAP archives of polarized brightness temperatures in Arctic sea ice leveraging ResNet-based conditional GANs. IEEE Transactions on Geoscience and Remote Sensing, 63, 1 - 15.

2. 경제적 파급효과

본 연구에서 개발된 해빙 농도 및 거칠기 12개월 예측 결과는 북극 해빙 변화에 따른 경제적 리스크를 사전에 평가하고 대응할 수 있는 기초 정보를 제공함으로써, 다양한 산업 및 정책 분야에서 실질적 활용 가치를 가진다. 특히 해빙 농도 예측 정보는 북극항로의 개방 시기 판단과 최적 항로 계획 수립에 직접적으로 활용될 수 있다. 또한, 본 연구의 예측 자료는 해양 플랜트, 해저 자원 개발 등의 중장기 사업 계획 수립 시 환경 리스크를 사전에 평가하기 위한 과학적 근거 자료로도 활용될 수 있다. 아울러, 본 연구에서 제시한 D2D 예측 프레임워크는 위성 관측 자료가 제한적인 다른 환경 변수에도 적용할 수 있어, 향후 기후 자료 서비스 및 예측 기반 의사결정 지원 시스템으로 확장될 수 있는 잠재력을 보유하고 있다. 더 나아가 본 예측 시스템은 북극 해빙 변화가 중위도 기상과 연계되어 발생하는 극한 기상 현상

에 대한 조기 경보 및 대응 전략 수립을 지원함으로써 사회·경제적 비용 절감과 국민 안전 증진이라는 공공적 가치 창출에도 기여할 수 있다.



Reconstructing Pre-SMAP Archives of Polarized Brightness Temperatures in Arctic Sea Ice Leveraging ResNet-Based Conditional GANs

Suna Jo[✉], Hyun-Cheol Kim[✉], *Member, IEEE*, and Sungwook Hong[✉]

Abstract—This study presents a deep-learning (D2S) model to generate historical vertically polarized (TBv) and horizontally polarized (TBh) brightness temperatures (TBs) at the soil moisture active-passive (SMAP) 1.4 GHz channels using TBv and TBs polarization difference from the Defense Meteorological Satellite Program (DMSP) satellite series' 19.35 GHz channels. The proposed D2S model employed the ResNet9-based generator and PatchGAN-based discriminator, with a composite loss function synergizing mean squared error (mse) and $L1$ losses, similar to the Pix2Pix architecture. Training, validation, and testing were conducted using paired datasets of polarized TBs from SMAP (1.41 GHz) and DMSP (19.35 GHz) collected between July 2015 and June 2022, followed by application to historical data spanning from September 1987 to June 2015. The D2S model demonstrated robust performance in generating both SMAP TBv and TBh, achieving test set average correlation coefficients (CCs) of 0.994 and 0.992, biases of 0.150 and -0.259 K, root-mean-square errors (RMSEs) of 6.463 and 9.011 K, and mean absolute errors (MAEs) of 3.883 and 5.518 K, respectively. Furthermore, this study showed reasonable agreement between the D2S-generated SMAP TBs and soil moisture and ocean salinity (SMOS) TBs and provided preliminary results of thin sea ice thickness (SIT) retrievals, which were further used for evaluating the limitations of the D2S approach in specific sea ice regions. Consequently, the D2S model can provide empirically consistent SMAP-like polarized TB estimates over the Arctic, including periods prior to the L-band operational era. The D2S framework offers significant potential to enhance the reconstruction of historical Arctic sea ice conditions and to support climate change studies by providing surrogate L-band-equivalent information extending back to 1987.

Index Terms—Brightness temperature (TB), conditional generative adversarial network (GAN), defense meteorological satellite program (DMSP), satellite remote sensing, sea ice, soil moisture active-passive (SMAP).

Received 20 March 2025; revised 23 July 2025, 11 November 2025, and 9 December 2025; accepted 15 December 2025. Date of publication 17 December 2025; date of current version 26 December 2025. This work was supported in part by Korea Polar Research Institute (KOPRI) grant funded by the Ministry of Oceans and Fisheries (KOPRI) under Grant PE24040 and Grant PE25040 and in part by the National Research Foundation of Korea (NRF) through Korean Government [Ministry of Science and ICT (MSIT)] under Grant RS-2025-16064562. (Corresponding author: Sungwook Hong.)

Suna Jo is with the Department of Environment and Energy, Sejong University, Gwangjin-gu, Seoul 05006, Republic of Korea (e-mail: sunnjo@sju.ac.kr).

Hyun-Cheol Kim is with the Center of Remote Sensing and GIS, Korea Polar Research Institute, Yeosu-gu, Incheon 21990, Republic of Korea (e-mail: kimhc@kopri.re.kr).

Sungwook Hong is with the Department of Environment and Energy, Center for Earth and Environment Research, Sejong University, Gwangjin-gu, Seoul 05006, Republic of Korea, and also with DeepThoTh Company Ltd., Gwangjin-gu, Seoul 05006, Republic of Korea (e-mail: sesttiya@sejong.ac.kr).

Digital Object Identifier 10.1109/TGRS.2025.3645345

I. INTRODUCTION

SEA ice plays a pivotal role in global climate processes due to its high sensitivity to thermal fluxes and radiative imbalances. Over recent decades, the Arctic region has undergone a substantial decline in sea ice extent and thickness [1], [2], [3], [4], [5], leading to far-reaching consequences. This decline has significantly influenced climate patterns [6], terrestrial energy budgets [7], large-scale atmospheric circulation, and global temperature trends [8], [9], [10]. Additionally, Arctic sea ice variability affects the frequency of Arctic cyclones [11], summer storm anomalies [12], and both tropospheric and stratospheric circulation in the region [13], [14]. The diminishing ice coverage has also created new opportunities for resource exploration and commercial ventures [15], while simultaneously posing substantial threats to regional ecosystems and environmental integrity. These diverse and widespread impacts underscore the growing need for reliable, long-term datasets to support continuous and comprehensive monitoring of the Arctic sea ice environment.

Regardless of the importance of monitoring sea ice, in situ observation methods involving buoys, ships, or airborne platforms remain spatially and temporally constrained due to the extreme Arctic environment. In contrast, satellite remote sensing techniques have facilitated comprehensive and systematic measurements of key sea ice parameters, including extent and thickness, over multiple decades. Various sensors have contributed to this effort, encompassing passive microwave radiometers, synthetic aperture radar, radar and laser altimeters, and scatterometers. In particular, passive microwave instruments have proven indispensable. These efforts began with the electrically scanning microwave radiometer onboard National Aeronautics and Space Administration (NASA)'s Nimbus-5 satellite in 1972 and continued through subsequent generations of sensors such as the special sensor microwave/imager (SSM/I; 1987–2009) and the special sensor microwave imager/sounder (SSMIS; 2003–present) flown on Defense Meteorological Satellite Program (DMSP) platforms, the advanced microwave scanning radiometer for the Earth Observing System (AMSR-E; 2002–2011) aboard Aqua, and its successor, the Advanced Microwave Scanning Radiometer 2 (2012–present), launched as part of the Global Change Observation Mission-Water series. Collectively, these instruments have enabled robust, long-term monitoring and analysis of sea ice dynamics.

1558-0644 © 2025 IEEE. All rights reserved, including rights for text and data mining, and training of artificial intelligence and similar technologies. Personal use is permitted, but republication/redistribution requires IEEE permission.

See <https://www.ieee.org/publications/rights/index.html> for more information.

Authorized licensed use limited to: Sejong Univ. Downloaded on January 26, 2026 at 06:20:39 UTC from IEEE Xplore. Restrictions apply.

제 5 장 연구개발결과의 활용계획

본 연구에서 개발된 L-band 기반 해빙 거칠기 및 해빙 농도 생성, 예측 기술은 향후 북극 해빙 변화 분석과 예측 정확도 향상을 위한 다양한 후속 연구로 확장될 수 있다. 우선, 본 연구에서 확인된 겨울철 두꺼운 해빙 영역에서의 산출 제약을 극복하기 위한 보정 기법 연구가 필요하다. 눈 덮개의 영향을 고려한 표면 온도 보정 알고리즘을 도입하거나, L-band 밝기 온도 포화 구간을 보완할 수 있는 대체 산출 방법이 개발되어야 한다. 이를 위해 복사전달모델을 활용하여 해빙 두께-밝기 온도-표면 온도 간의 관계를 재정립하거나, 다중 주파수 채널의 조합을 통해 포화 영역에서의 민감도를 향상시키는 방안을 모색할 수 있다. 또한 현재 후처리 단계에서 수행되는 해빙 두께 기반 마스킹 방식 대신, 물리 기반 손실 함수나 조건부 학습을 통해 D2D 생성 모델이 유효 산출 범위를 학습 단계에서 자체적으로 인지하도록 개선함으로써 물리적으로 일관된 산출물 생성이 가능할 것으로 생각된다.

예측 연구 측면에서는 현재의 월평균 12개월 예측 결과를 기반으로, 융해기나 결빙기와 같이 변동성이 큰 시기를 보다 정밀하게 예측하기 위해 시계열 학습에 특화된 Long Short-Term Memory나 Transformer 등을 D2D 프레임워크와 결합하는 연구로 확장할 수 있다. 또 단일 모델의 결정론적 예측 대신, 앙상블 예측 기법을 도입하는 연구가 수행될 수 있다. 이를 통해 서로 다른 초기 조건이나 모델 구조를 통합한 다중 예측 결과를 획득함으로써 예측 불확실성을 정량화하고 신뢰 구간을 제시하는 확률론적 예측 시스템으로 발전시킬 수 있다.

제 6 장 참고문헌

- [1] Stroeve, J., Kattsov, V., Barrett, A., Serreze, M., Pavlova, T., Holland, M., & Meier, W. N. (2012). Trends in Arctic sea ice extent from CMIP5, CMIP3 and observations. *Geophysical Research Letters*, 39(16).
- [2] Kwok, R. (2018). Arctic sea ice thickness, volume, and multiyear ice coverage: losses and coupled variability. *Environmental Research Letters*, 13(10), 105005.
- [3] Screen, J. A., & Simmonds, I. (2010). The central role of diminishing sea ice in recent Arctic temperature amplification. *Nature*, 464(7293), 1334 - 1337.
- [4] Smith, L. C., & Stephenson, S. R. (2013). New Trans-Arctic shipping routes navigable by midcentury. *Proceedings of the National Academy of Sciences*, 110(13), E1191 - E1195.
- [5] Hibler, W. III. (1972). Removal of aircraft altitude variation from laser profiles of the Arctic ice pack. *Journal of Geophysical Research*, 77(36), 7190 - 7195.
- [6] Dierking, W. (1995). Laser profiling of the ice surface topography during the Winter Weddell Gyre Study 1992. *Journal of Geophysical Research: Oceans*, 100(C3), 4807 - 4820.
- [7] Von Saldern, C., Haas, C., & Dierking, W. (2006). Parameterization of Arctic sea-ice surface roughness for application in ice type classification. *Annals of Glaciology*, 44, 224 - 230.
- [8] Doble, M. J., Skourup, H., Wadhams, P., & Geiger, C. A. (2011). The relation between Arctic sea ice surface elevation and draft: A case study using coincident AUV sonar and airborne scanning laser. *Journal of Geophysical Research: Oceans*, 116(C8).
- [9] Beckers, J. F., Renner, A. H. H., Spreen, G., Gerland, S., & Haas, C. (2015). Sea-ice surface roughness estimates from airborne laser scanner and laser altimeter observations in Fram Strait and north of Svalbard. *Annals of Glaciology*, 56(69), 235 - 244.
- [10] Miernecki, M., Kaleschke, L., Maaß, N., Hendricks, S., & Søbjaerg, S. S. (2020). Effects of decimetre-scale surface roughness on L-band brightness temperature of sea ice. *The Cryosphere*, 14(2), 461 - 476.
- [11] Similä, M., Arjas, E., Mäkynen, M., & Hallikainen, M. T. (2001). A Bayesian classification model for sea ice roughness from scatterometer data. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7), 1586 - 1595.
- [12] Fors, A. S., Brekke, C., Gerland, S., Doulgeris, A. P., & Beckers, J. F. (2015). Late summer Arctic sea ice surface roughness signatures in C-band SAR data. *IEEE Journal of Selected Topics in Applied Earth Observations*

- and Remote Sensing, 9(3), 1199 - 1215.
- [13] Peterson, I., Prinsenberg, S., & Holladay, J. (2008). Observations of sea ice thickness, surface roughness and ice motion in Amundsen Gulf. *Journal of Geophysical Research: Oceans*, 113(C6).
 - [14] Hong, S., & Shin, I. (2010). Global trends of sea ice: Small-scale roughness and refractive index. *Journal of Climate*, 23(17), 4669 - 4676.
 - [15] Shin, I., Park, J., Suh, A., & Hong, S. (2011). Sea ice remote sensing using AMSR-E data: Surface roughness and refractive index. *Remote Sensing of the Ocean, Sea Ice, Coastal Waters, and Large Water Regions 2011*, 8175, 433 - 438.
 - [16] Bi, H., Yang, X., Li, Z., & Zhou, X. (2013). Sea ice small-scale surface roughness estimation based on AMSR-E observations. *International Journal of Remote Sensing*, 34(12), 4425 - 4448.
 - [17] Stroeve, J. C., Markus, T., Maslanik, J. A., Cavalieri, D. J., Gasiewski, A. J., Heinrichs, J. F., Holmgren, J., Perovich, D. K., & Sturm, M. (2006). Impact of surface roughness on AMSR-E sea ice products. *IEEE Transactions on Geoscience and Remote Sensing*, 44(11), 3103 - 3117.
 - [18] Wang, Y. R., & Li, X. M. (2020). Arctic sea ice cover data from spaceborne SAR by deep learning. *Earth System Science Data Discussions*, 2020, 1 - 30.
 - [19] Jiang, M., Zhong, W., Xu, K., & Jia, Y. (2023). Estimation of Arctic sea ice thickness from Chinese HY-2B radar altimetry data. *Remote Sensing*, 15(5), 1180.
 - [20] Cavalieri, D. J., Gloersen, P., & Campbell, W. J. (1984). Determination of sea ice parameters with the NIMBUS 7 SMMR. *Journal of Geophysical Research: Oceans*, 89(D4), 5355 - 5369.
 - [21] Comiso, J. C. (1986). Characteristics of Arctic winter sea ice from satellite multispectral microwave observations. *Journal of Geophysical Research: Oceans*, 91(C1), 975 - 994.
 - [22] Spreen, G., Kaleschke, L., & Heygster, G. (2008). Sea ice remote sensing using AMSR-E 89-GHz channels. *Journal of Geophysical Research: Oceans*, 113(C2).
 - [23] Kern, S., Lavergne, T., Notz, D., Pedersen, L. T., Tonboe, R. T., Puzermeier, R., & Holfort, S. G. (2019). Satellite passive microwave sea-ice concentration data set intercomparison: closed ice and ship-based observations. *The Cryosphere*, 13(12), 3261 - 3307.
 - [24] Lavergne, T., Sørensen, A. M., Kern, S., Tonboe, R., Notz, D., Aaboe, S., Bell, L., Dybkjær, G., Eastwood, S., Gabarro, C., Heygster, G., Killie, M. A., Kreiner, M. B., Lavelle, J., Saldo, R., Sandven, S., & Holfort, S. G. (2019). Version 2 of the EUMETSAT OSI SAF and ESA CCI sea-ice concentration climate data records. *The Cryosphere*, 13(4), 1107 - 1133.

- [25] Chi, J., & Kim, H. C. (2017). Prediction of Arctic sea ice concentration using a fully data-driven deep neural network. *Remote Sensing*, 9(12), 1305.
- [26] Kim, Y. J., Kim, H. C., Han, D., Lee, S., & Im, J. (2020). Prediction of monthly Arctic sea ice concentrations using satellite and reanalysis data based on convolutional neural networks. *The Cryosphere*, 14(3), 1083 - 1104.
- [27] Han, H., Kim, J. I., Hyun, C. U., & Kim, H. C. (2018). Estimation of sea ice concentration in the Arctic using machine learning techniques from satellite passive microwave data. *Korean Journal of Remote Sensing*, 34(6), 1237 - 1249.
- [28] Park, J., Lee, S., Jo, Y. H., & Kim, H. C. (2020). Retrieval of sea ice concentration from satellite passive microwave data using a machine learning regression-based approach. *Remote Sensing*, 12(12), 1928.
- [29] Choudhury, B. J., Schmugge, T. J., Chang, A., & Newton, R. W. (1979). Effect of surface roughness on the microwave emission from soils. *Journal of Geophysical Research: Oceans*, 84(C9), 5699 - 5706.
- [30] Wu, S. T., & Fung, A. K. (1972). A noncoherent model for microwave emissions and backscattering from the sea surface. *Journal of Geophysical Research*, 77(30), 5917 - 5929.
- [31] Ulaby, F. T., Moore, R. K., & Fung, A. K. (1982). *Microwave remote sensing: Active and passive. Volume II: Radar remote sensing and surface scattering and emission theory.* Addison-Wesley.
- [32] Hong, S. (2009). Retrieval of refractive index over specular surfaces for remote sensing applications. *Journal of Applied Remote Sensing*, 3(1), 033560.
- [33] Hong, S. (2010). Decomposition of unpolarized emissivity. *International Journal of Remote Sensing*, 31(8), 2109 - 2114.
- [34] Hong, S. (2010). Detection of small-scale roughness and refractive index of sea ice in passive satellite microwave remote sensing. *Remote Sensing of Environment*, 114(5), 1136 - 1140.
- [35] Hong, S. (2013). Polarization conversion for specular components of surface reflection. *IEEE Geoscience and Remote Sensing Letters*, 10(6), 1469 - 1472.
- [36] Han, K.-H., Jang, J.-C., Ryu, S., Sohn, E.-H., & Hong, S. (2022). Hypothetical visible bands of Advanced Meteorological Imager onboard the Geostationary Korea Multi-Purpose Satellite-2A using data-to-data translation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 8378 - 8388.
- [37] Isola, P., Zhu, J.-Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1125 - 1134.

- [38] Kaleschke, L., Maaß, N., Haas, C., Hendricks, S., Heygster, G., & Tonboe, R. T. (2010). A sea-ice thickness retrieval model for 1.4 GHz radiometry and application to airborne measurements over low salinity sea ice. *The Cryosphere*, 4(4), 583 - 592.
- [39] Kovacs, A. (1996). Sea ice. Part 1: Bulk salinity versus ice floe thickness. U.S. Army Cold Regions Research and Engineering Laboratory.
- [40] Tietsche, S., Alonso-Balmaseda, M., Rosnay, P., Zuo, H., Tian-Kunze, X., & Kaleschke, L. (2018). Thin Arctic sea ice in L-band observations and an ocean reanalysis. *The Cryosphere*, 12(6), 2051 - 2072.
- [41] Kilic, L., Tonboe, R. T., Prigent, C., & Heygster, G. (2019). Estimating the snow depth, the snow - ice interface temperature, and the effective temperature of Arctic sea ice using AMSR2 and ice mass balance buoy data. *The Cryosphere*, 13(4), 1283 - 12



- 이 연구는 극지연구소의 지원을 받아 수행되었습니다.(PE25040)
- This work was supported by the Korea Polar Research Institute (KOPRI, PE25040)

주 의

1. 이 보고서는 극지연구소 위탁과제 연구결과보고서입니다.
2. 이 보고서 내용을 발표할 때에는 반드시 극지연구소에서 위탁연구과제로 수행한 연구결과임을 밝혀야 합니다.
3. 국가과학기술 기밀유지에 필요한 내용은 대외적으로 발표 또는 공개하여서는 안됩니다.