

위성기반 북극해 해빙특성 추출 알고리즘 개발

Development of algorithms to extract satellite-based
Arctic sea ice characteristics

울산과학기술원

제 출 문

극지연구소장 귀하

본 보고서를 “북극해빙 위성관측을 위한 분석 기술 개발”과제의 위탁연구 “위성기반 북극해 해빙특성 추출 알고리즘 개발”과제의 최종보고서로 제출합니다.

2020. 01. 28.

(본과제) 총괄연구책임자 : 김 현 철

위탁연구기관명 : 울산과학기술원

위탁연구책임자 : 임 정 호

위탁참여연구원 : 이 상 균

“ : 김 미 애

“ : 박 수 민

“ : 심 성 문

“ : 한 대 현

“ : 김 영 준

“ : 강 유 진

“ : 조 동 진

보고서 초록

위탁연구과제명	위성기반 북극해 해빙특성 추출 알고리즘 개발				
위탁연구책임자	임 정 호	해당단계 참여연구원수	총 16명 (각 5, 5, 6명)	해당단계 연구비	총 180 백만원 (각 70, 60, 50 백만원)
연구기관명 및 소속부서명	울산과학기술원 도시환경공학과		참여기업명		
국제공동연구	상대국명 :		상대국연구기관명 :		
요약				보고서 면수	96
<ul style="list-style-type: none"> ● 2017년 1월 1일 부터 2019년 12월 31일까지 연구를 수행하였으며, 북극의 해빙 프리보드 및 월별 리드 비율 산출, 해빙 농도 예측, passive microwave 이용 얇은 해빙 두께 추정 및 해빙 농도 상세화 알고리즘을 개발하였음. ● 1차년도(2017)에 북극 해빙 프리보드 및 해빙 두께 추정 알고리즘 개발과 월별 리드 비율 산출을 위하여 해빙 프리보드 및 두께 추정알고리즘을 개발하였고 월별 북극 리드 비율 산출 알고리즘을 개발하였음. ● 2차년도(2018)에 북극 해빙 농도 단기 예측 알고리즘을 개발 하였음. 해빙 농도에 영향을 미치는 인자의 중요도 파악 및 위성 기반 인자 추출 및 개선 방법을 제안하였고, 재분석 자료 및 다중위성자료를 융합하여 딥러닝 기반 월별 해빙 농도 예측 모델을 개발하였음. 또한, 여름 및 겨울 계절을 구분하여 북극 해빙 농도의 전반적인 변화 및 영향을 미치는 요인을 분석하였음. ● 3차년도(2019)에 Passive microwave 위성의 융합을 통하여 얇은 해빙 두께를 추정하는 모델을 제안하였음. 주파수, 주파수 비율과 기계학습을 활용한 초년생 해빙 두께 추정 모델 개발하였으며, IceBridge 관측자료 기반의 현장자료와 비교를 통하여 알고리즘을 검증하였음. CryoSat-2, CryoSat2-SMOS (CS2SMOS), SMOS에서 산출되는 해빙 두께 자료와의 정량적인 비교·분석을 통하여 모델의 정확도를 분석하였음. ● 3차년도(2019)에 또한 해빙 농도 상세화 알고리즘을 개발하였음. 해빙 농도에 영향을 미치는 인자 파악 및 고해상도 위성 및 모델 인자를 추출 하고, 다양한 통계 기법 및 기계학습을 활용하여 해빙 농도를 상세화하는 알고리즘을 개발하였음. ● 본 연구에서 개발한 북극 해빙 특성 추출 알고리즘을 활용하여 북극 해빙의 변화에 대한 보다 다각적인 분석이 가능할 것으로 기대되며, 딥러닝 기법을 적용하여 보다 수준 높은 원격탐사 산출물을 제공할 수 있을 것으로 기대됨. ● North-American CryoSat-2 science meeting 및 IBRV ARAON Arctic Cruise ARA10B 참석을 통하여 해빙관련 해외의 과학기술정보확보 및 다국적 연구진과의 교류를 수행하였으며, 이를 활용하여 추후 해빙분야 연구에 적극적으로 활용할 수 있을 것으로 기대됨. 					
색 인 어 (각 5개 이상)	한 글	해빙, 해빙 리드, 해빙 농도, 해빙 두께, 원격 탐사			
	영 어	Sea ice, sea ice lead, sea ice concentration, sea ice thickness, remote sensing			

요 약 문

I. 제 목: 위성기반 북극해 해빙특성 추출 알고리즘 개발

II. 연구개발의 목적 및 필요성

- 북극 지역은 온실 효과와 해빙 사이의 양적 피드백을 통해 기후 변화에 크게 기여함
- 북극 해빙의 주요 특성을 추출하는 알고리즘을 개발하여 북극 해빙에 대한 이해를 높일 필요가 있음
- 해빙의 주요 특성으로는 해빙 사이의 리드, 해빙 두께, 해빙 농도 등이 있음
- 고도계를 이용한 해빙 두께 추정은 비교적 두꺼운 얼음에 대해서만 가능했으며 초년빙과 같이 얇은 얼음에 대해서는 적용하기 어려운 한계가 있기 때문에 수동 마이크로파센서를 이용하여 얇은 해빙 두께를 추정하는 연구가 필요함

III. 연구개발의 내용 및 범위

- 북극 리드를 탐지하기 위해 CryoSat-2 baseline C L1b waveform 자료를 사용하였음.
- 기존 초분광 센서 자료 분석에 많이 활용되던 linear mixture analysis를 CryoSat-2 L1b waveform에 적용하고 waveform mixture algorithm을 개발하여 리드를 탐지하였음.
- 해빙 농도의 예측을 위해 수동 마이크로파센서 자료 및 재분석자료를 이용함
- 기계학습 기법 중 랜덤 포레스트와 Convolutional neural network (CNN)을 이용하여 여름철에 대한 월별 해빙 예측 모델을 구축함
- 해빙 농도의 상세화를 위해 Sentinel-1 SAR extended area HH/HV 자료와 Bremen 대학교에서 배포하는 ARTIST 해빙농도를 사용하였음
- 기준으로 삼는 해빙 농도 자료로는 수동 마이크로파센서 기반의 해빙 농도 중 가장 높은 해상도를 가지는 ARTIST 해빙 농도를 이용함
- 초년생 해빙의 두께를 추정하기 위해 수동 마이크로파센서 자료인 AMSR2와 SMOS, SMAP을 이용하였으며 랜덤 포레스트 모델을 적용함
- 비교 및 검증을 위해 Ice Bridge를 이용하였으며, 타 위성에서 제공하는 해빙 두께와 비교하였을 때 향상된 결과를 도출함

IV. 연구개발결과

- Waveform mixture algorithm을 활용하여 탐지된 리드는 고 해상도 MODIS 영상을 통해 검증되었고 기존의 CryoSat-2 기반 리드 탐지 알고리즘과 비교하였음.
- 2011-2016년 1-5월, 10-12월의 전 북극 월별 리드 비율을 산출하였고 최근 해빙의 연간 변화가 크다는 것을 보여주었음.
- 전 북극 월별 리드비율 또한 기존의 알고리즘과 비교하였는데, 고도계 기반의 리드 탐지 기법(CryoSat-2)과 장면 기반의 리드 탐지 기법(MODIS와 AMSR-E)이 명확한 특징을 보였음.
- 랜덤 포레스트 및 CNN을 이용한 월별 해빙 농도 예측 결과를 비교하였을 때, 각각 6.61%와 5.76%의 RMSE를 보였음
- 계절별 분석을 통해서 겨울철에 비해 여름철에 상대적으로 높은 nRMSE를 보였으며, 이를 통해 여름철 해빙 농도에 대한 예측이 겨울철에 비해 어렵다는 것을 확인함
- 상세화 모델의 정확도를 수동 마이크로파센서 기반의 해빙 농도와 정량적 및 정성적으로 비교 분석하였으며, 정량적 비교 결과 예측된 해빙 농도와 ARTIST 해빙 농도 사이의 RMSE는 16.38%, 상관 계수는 0.74를 기록함
- 정성적 분석을 통해서 전반적으로 SAR의 상세한 공간 정보를 잘 반영하는 것으로 나타남
- 초년생 해빙 두께 추정 결과는 약 12.92cm의 RMSE를 보였으며, 이는 CryoSat2 (16.66cm), CryoSat2 & SMOS (19.29cm), SMOS (17.96cm) 과 같은 다른 알고리즘에서 제공하는 해빙 농도의 오차에 비해 향상된 결과를 보임
- 샘플의 불균형을 해결하기 위해 오버샘플링을 수행하였으며, 결과적으로 본 연구에서 수행된 랜덤 포레스트 기반의 초년생 해빙 두께 추정 모델이 기존 산출물 대비 상대적으로 높은 모의력을 보임

V. 연구개발결과의 활용계획

- Waveform mixture algorithm은 기계학습 기법을 포함한 임계값 기반의 리드 탐지와는 달리 CryoSat-2의 baseline 업데이트에 영향을 받지 않기 때문에 앞으로 waveform mixture algorithm의 리드 탐지 기법의 활용도가 더 높아 질것으로 기대됨.
- Waveform mixture algorithm은 Lee et al. (2016)의 DT 기법과 비슷한 성능으로 리드를 탐지하였기 때문에 해빙의 freeboard와 두께 또한 추정 가능함.
- 전 북극 월별 리드 비율은 북극 해빙 농도를 예측하는 입력 자료로 사용될 수 있음.
- 월별 해빙 농도의 예측 결과는 기후 모델링에 활용될 수 있으며, 북극 항로 개척에도 사용될 수 있음
- 해빙 농도의 예측 결과를 리드 및 해빙 두께와의 연관성 분석에 활용할 수 있음
- 수 km 이내에서의 해빙 농도의 변화를 통해 작은 규모의 리드 및 해빙의 변화를 파악할 수 있음

- 상세화된 해빙 농도는 수치 모델의 입력 자료로 이용될 수 있으므로 북극 해빙 모델 및 기후모델 개선에 도움을 줌
- Sentinel-1 A와 B를 활용하면 약 3일의 재탐지 기간을 가지므로 높은 시간 및 공간 해상도의 해빙 농도를 산출할 수 있음
- 수동 마이크로파센서를 이용한 초년빙 두께는 고도계 기반의 해빙 두께 추정 알고리즘의 한계를 상호 보완하여 사용될 수 있음
- 초년빙은 다년빙에 비해 대기 및 해양과 큰 연관을 가지기 때문에, 수동 마이크로파센서 위성을 이용한 초년빙 모니터링은 기후 변화 분석에 사용될 수 있음



S U M M A R Y

(영 문 요 약 문)

I. Title: Development of algorithms to extract satellite-based Arctic sea ice characteristics

II. Purpose and Necessity of R&D

- Arctic regions contribute significantly to climate change through quantitative feedback between greenhouse effects and sea ice.
- It is necessary to develop algorithms that extract the main characteristics of the Arctic sea ice to improve understanding of the Arctic environment.
- The main characteristics of the sea ice are leads between sea ice, sea ice thickness and sea ice concentration.
- Estimation of sea ice thickness using altimeter data was possible only for relatively thick ice, and was difficult to apply for thin ice, a study is needed to estimate the thickness of thin ice using a passive microwave sensor.

III. Contents and Extent of R&D

- In order to identify leads in the Arctic, CryoSat-2 baseline C L1b waveform data were used.
- The concept of linear mixture analysis was adapted to the waveforms from Synthetic Interferometric Radar Altimeter(SIRAL), CryoSat-2, to identify leads to estimate monthly pan-Arctic lead fractions from Jan. to May and Oct. to Dec. between 2011-2016.
- Passive microwave sensor data and reanalysis data were used to predict sea ice concentration.
- Random forest and convolutional neural network (CNN) were used to build a monthly sea ice prediction model for the summer season.

- Sentinel-1 SAR extended area HH / HV data and the ARTIST sea ice concentration from Bremen University were used to build a model for downscaling of the sea ice concentration.
- We used ARTIST sea ice concentration as reference, which has the finest spatial resolution among sea ice concentration datasets that are delineated from passive microwave sensor data.
- We used passive microwave sensor data (AMSR2, SMOS, SMAP) to estimate the thickness of first year ice based on random forest.
- The Ice Bridge data were used for comparison and validation. The results improved when compared to the sea ice thickness provided by existing algorithms.

IV. R&D Results

- Leads detected using the waveform mixture algorithm were validated by high resolution MODIS images and compared to the existing CryoSat-2 based lead detection algorithms.
- Monthly lead fraction maps were produced by the waveform mixture algorithm, which showed a strong inter-annual variability of recent sea ice cover during 2011-2016, excluding summer season (i.e. June to September).
- The monthly sea ice concentration predictions using random forest and CNN resulted in the RMSE of 6.61% and 5.76%, respectively.
- Seasonal analysis showed that nRMSE was relatively higher in summer than in winter, and it was shown that the prediction of summer sea ice concentration was more difficult than in winter.
- The accuracy of the downscaling model was quantitatively and qualitatively compared to the sea ice concentration based on the passive microwave sensor data.
- The quantitative comparison showed that the RMSE between the predicted sea ice concentration and the ARTIST one was 16.38% and the correlation coefficient was 0.74.

- Estimation of first year ice thickness using random forest resulted in an RMSE of about 12.92 cm, which was improved when compared to the existing algorithms including CryoSat2 (16.66 cm), CryoSat2 & SMOS (19.29 cm), and SMOS (17.96 cm).
- The random forest based first-year sea ice thickness estimation model developed in this study consistently showed a relatively high accuracy when compared to the other products.

V. Application Plans of R&D Results

- Unlike the threshold-based lead detection methods, the waveform mixture algorithm is less influenced by the update of baseline version of CryoSat-2 data, which will be useful for future altimeter missions.
- The waveform mixture algorithm can be used in the retrieval algorithm for sea ice thickness.
- Pan-Arctic lead fraction maps will be potentially used for the prediction of sea ice concentration.
- Monthly sea ice concentration forecasts can be used for climate modeling and for exploiting Arctic sea routes.
- Prediction of sea ice concentration can be used to analyze the correlation with leads and sea ice thickness.
- Changes in sea ice concentration within a few kilometers can be used to identify small-scale leads and sea ice changes.
- Downscaled sea ice concentration can be used as input to numerical models, helping to improve Arctic sea ice models and regional/global climate models.
- Thin ice thickness using passive microwave sensor data can be used to complement the limitations of altimeter-based sea ice thickness estimation algorithms.
- Since first year ice has a greater association with the atmosphere and ocean when compared to multi year ice, monitoring of the first year ice thickness using passive microwave satellite data can be used for climate change research.

< 차 례 >

제 1 장 서론	1
제 2 장 국내외 기술개발 현황	2
제 1 절 국내 기술개발 현황	2
제 2 절 국외 기술개발 현황	2
제 3 장 연구개발수행 내용 및 결과	13
제 1 절 북극 해빙 프리보드 및 해빙 두께 추정 알고리즘 개발 및 월별 리드 비율 산출	14
제 2 절 북극 해빙농도 단기 예측 알고리즘 개발	30
제 3 절 2016년 11월 해빙 최소면적에 대한 원인 규명	45
제 4 절 Passive microwave 위성 자료 융합을 통한 초년생 해빙 두께 추정	48
제 5 절 Sentinel-1 SAR와 ARTIST 해빙 농도를 이용한 북극 해빙 농도 상세화	63
제 4 장 연구개발 목표 달성도 및 대외기여도	76
제 1 절 연구개발목표의 달성도	76
제 2 절 관련 분야에의 기여도	78
제 5 장 연구개발결과의 활용계획	79
제 6 장 연구개발과정에서 수집한 해외과학기술정보	80
제 7 장 참고문헌	82

< 표 차례 >

표 3.2.1 해빙 농도 추정과 관련된 최근 연구 동향	31
표 3.2.2 variables descriptions for SIC prediction model	34
표 3.2.3 해빙 농도 예측 모델 간 성능 비교	37
표 3.4.1 Parameter lists for the IceBridge data	53
표 3.4.2 available data sources for sea ice thickness	57
표 3.4.3 available satellite data for SIT estimation	58
표 3.4.4 input variables for thin SIT estimation	58
표 3.4.5 model accuracy comparison with thin sea ice from IceBridge	61
표 4.1.1 연구 개발 목표 진행도	77

< 그림 차례 >

그림 1.1 본 연구의 연구 개발 목표 다이어그램	1
그림 2.1.1 Willmes and Heinemann, 2015의 MODIS IST를 활용한 lead 탐지 결과.	3
그림 2.1.2 2003년부터 2015년까지 북극의 해양 섹터별로 리드의 frequency 분석 (Willmes and Heinemann, 2016).	3
그림 2.1.3 AMSR의 18, 89GHz의 비율을 활용하여 산출된 일일 얇은 해빙 농도의 비 율(Rohrs and Kaleschke, 2012).	4
그림 2.1.4 2013년 2, 3월의 월별 리드 비율(Wernecke and Kaleschke, 2015).	5
그림 2.1.5 Decision trees 기반의 리드 탐지 방법을 활용하여 산출된 북극 해빙 두께 (Lee 등 2016).	7
그림 2.1.6 Waveform mixture analysis를 활용하여 탐지된 리드. 배경은 MODIS 영상이 며 빨간색 점은 리드 파란색 점은 해빙임.	8
그림 2.1.7 북반구와(상) 남반구(하)의 연간 최대해빙확장(좌)과 최소해빙확장(우) 비교. 95% 신뢰도의 연간 경향 (적색)	9
그림 2.1.8 AO와 NAO (North Atlantic Oscillation) 인자에 대해 회귀한 해면기압 (흑색 점선)과 해빙의 움직임 (화살표). (a) AO인자에 회귀한 겨울, (b) AO인자에 회귀한 여름, (c) NAO인자에 회귀한 겨울, (d) AO와 NAO 인자의 차에 회귀한 겨울 지도.	10
그림 3.1.1 대표적인 리드와 해빙의 CryoSat-2 L1b waveform.	15
그림 3.1.2 리드와 해빙의 endmember 추출을 위해 사용된 2011-2016년 1-5월, 10-12 월 동안의 48개 CryoSat-2 orbit 파일들.	18
그림 3.1.3 2015년 10월 10일 waveform mixture algorithm에서 산출한 리드와 해빙의	

abundance (a) 리드 abundance, (b) 해빙 abundance.	19
그림 3.1.4 리드 분류 결과: (a)-(d) Rose (2013)의 리드 분류 결과, (e)-(h) Laxon 등 (2013)의 리드 분류 결과, (i)-(l) Lee 등 (2016)의 리드 분류 결과, (m)-(p) waveform mixture algorithm의 리드 분류 결과.	21
그림 3.1.5 리드 분류 결과의 정량적 비교.	22
그림 3.1.6 2011-2013년 1-5월, 10-12월의 waveform mixture algorithm으로 산출된 전 북극 월별 리드 비율.	23
그림 3.1.7 2014-2016년 1-5월, 10-12월의 waveform mixture algorithm으로 산출된 전 북극 월별 리드 비율.	24
그림 3.1.8 (a-d) 리드의 관측 개수, (e-h) 해빙의 관측 개수, (i-l) 표준편차, 민감도 분석 결과.	25
그림 3.1.9 2011년 1-3월 리드 비율 맵의 비교. (a-c) Rohrs and Kaleschke (2011)의 AMSR-E 기반 리드 비율 맵, (d-h) Willmes and Heinemann (2015)의 MODIS 기반 리드 비율 맵, (g-i) Wernecke and Kaleschke (2015)의 CryoSat-2 기반 리드 비율 맵, (j-l) waveform mixture algorithm을 사용한 CryoSat-2 기반의 리드 비율 맵. ..	27
그림 3.1.10 봄(3-5월), 가을(10-11월), 겨울(12,1,2월)의 월별 리드비율의 평균.	28
그림 3.2.1 Pearson's correlation coefficient between SIC and one-month past variables on melting season (June - Sep.) during 2002-2017	32
그림 3.2.2 relative variable importance based on MSE using Random Forests	33
그림 3.2.3 해빙 농도 예측 연구 흐름도	36
그림 3.2.4 comparison among mean absolute SIC anomaly and MAE for persistence, RF, and CNN models in annual (a-d); melting (e-f); and freezing season (i-l)	38
그림 3.2.5 histograms of SICs based on NSIDC (blue) and three prediction models (red) in melting season	39
그림 3.2.6 monthly prediction accuracies between RF and CNN models	40
그림 3.2.7 annual changes of prediction accuracy of CNN model	41
그림 3.2.8 SICs prediction results in September 2007	42
그림 3.2.9 SICs prediction results in September 2012	43
그림 3.3.1 Anomalies of 2-m air temperature (Aug.-Nov.) and sea ice extent (Nov.-Dec.) on Arctic region	46
그림 3.3.2 teleconnection between atmosphere and SIE	47
그림 3.4.1 Example error characteristic of SMOS and CryoSat ice thickness retrieval from SMOS (Algorithm II*) and CryoSat2 (AWI-retracked) with uncertainties from data products (Kaleschke et al. 2015)	49
그림 3.4.2 Scatter plot of EM bird and SMOS SIT retrieval (Huntemann et al., 2014)	50
그림 3.4.3 scatter polt of AEM in situ and CS2SMOS SIT (Ricker et al., 2017)	51
그림 3.4.4 Comparison of ASPeCT-based ice thickness and the SMOS-SMAP retrieval	

(Patilea et al., 2019)	52
그림 3.4.5 a brief diagram of the IceBridge L4 products	53
그림 3.4.6 IMB buoy diagram (source: http://imb-crrel-dartmouth.org/imb/)	55
그림 3.4.7 IMB installation (source: http://imb-crrel-dartmouth.org/imb/)	56
그림 3.4.8 Ice Watch 자료 공유 사이트 화면 및 자료 분포도 (source: https://icewatch.met.no/)	57
그림 3.4.9 IceBridge data distribution and histogram (left: overall, right: thin ice with 3.125 km-mean, 2015-2019)	59
그림 3.4.10 original SIT dataset (left) and the dataset after oversampling (right)	60
그림 3.4.11 RF-based SIT estimation models (upper: before oversampling; lower: after oversampling)	61
그림 3.5.1 Sentinel-1 HH, HV, 입사각의 예시	66
그림 3.5.2 본 연구에서 사용된 ARTIST 해빙 농도	67
그림 3.5.3 본 연구의 연구 지역 (좌) 및 Sentinel-1 HH 영상의 예시 (우)	68
그림 3.5.4 본 연구의 모식도	69
그림 3.5.5 본 연구에서 쓰인 인공 신경망의 구조	70
그림 3.5.6 SAR를 통해 예측한 해빙 농도와 ARTIST 해빙 농도의 산포도	71
그림 3.5.7 ARTIST 해빙 농도와 본 연구에서 추정된 저해상도 및 고해상도 해빙 농도의 비교	72
그림 3.5.8 ARTIST 해빙 농도와 본 연구에서 추정된 저해상도 및 고해상도 해빙 농도의 비교	72
그림 3.5.9 ARTIST 해빙 농도와 본 연구에서 추정된 저해상도 및 고해상도 해빙 농도의 비교	73
그림 6.1 IBRV ARAON Arctic Cruise ARA10B 참가 사진	81

< 수식차례 >

수식 3.1.1. waveform mixture model	17
수식 3.2.1 MAE equation	34
수식 3.2.2 ACC equation	35
수식 3.2.3 RMSE equation	35
수식 3.2.4 nRMSE equation	35
수식 3.2.5 NSE equation	35
수식 3.4.1 hydrostatic balance equation	53

제 1 장 서론

지구의 빙권은 기후변화에 민감하게 변화 한다. 기후변화로 인하여 기온과 수온이 점차 증가되면서 많은 양의 해빙, 빙하, 빙상, 만년설이 감소하였다. 그 중에서도 해빙의 감소는 지구로 흡수되는 태양복사 에너지양을 증가 시켜 전 지구 기후에 상당한 영향을 준다. 따라서 정확한 해빙의 면적과 두께의 측정은 반드시 필요하다. 위성관측과 다양한 모델들이 해빙의 면적을 측정하고 예측해왔다. 2012년 9월 위성은 북극해빙의 최소면적을 관측하였다. Boe et al., (2009)은 18개의 기후 모델이 예측한 해빙 면적을 분석하여 21세기 말 9월의 북극에는 ice-free가 될 것이라고 예측했다. 더 나아가, Coupled Model Intercomparison Project Phase 5 (CMIP5) 모델을 사용하였을 때는 2030년에 Arctic sea ice free가 될 것이라고 예측했다 (Wang et al., 2012).

본 연구의 최종 목표는 시공간 해상도가 뛰어난 다양한 위성자료의 융합 모델링을 통해 북극 해빙 변화를 보다 정확하게 모니터링 하는 기반을 마련하는 것이다. 기존의 잘 활용되지 않던 북극 해빙 두께 산출물의 정확도를 향상 시켜 그 활용도를 높임으로써 변화하는 북극 환경을 보다 효율적으로 모니터링 할 수 있는 환경을 마련할 수 있을 것이다. 더 나아가 북극 해빙에 영향을 미치는 인자를 파악함으로써 북극 기후 시스템의 변화와 그 영향을 이해하는데 도움을 줄 수 있을 것이다. 또한 북극 해빙 농도의 예측 모델을 개발함으로써 급격하게 변화하는 북극의 미래를 대비할 수 있을 것이다.

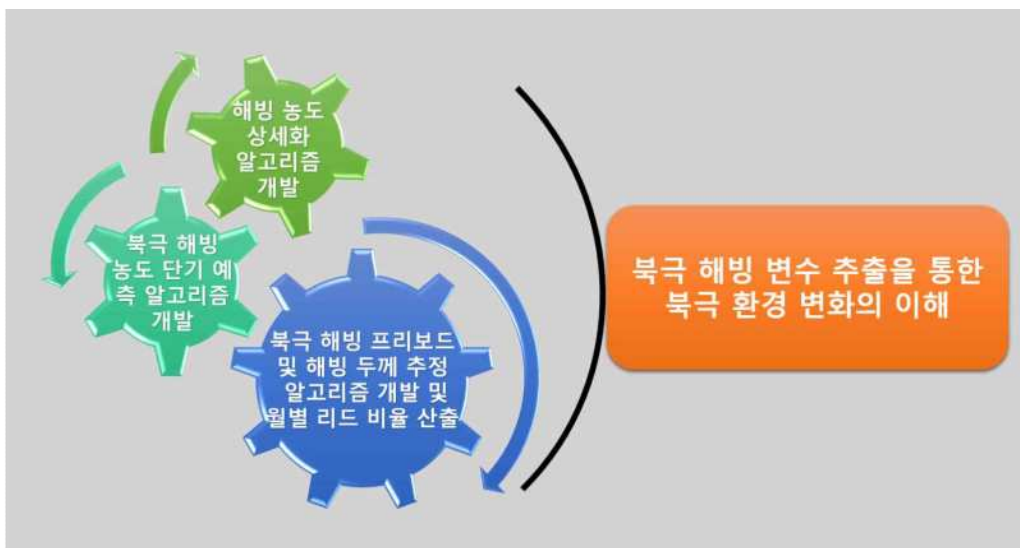


그림 1.1 본 연구의 연구 개발 목표 다이어그램

제 2 장 국내외 기술개발 현황

제 1 절 국내 기술개발 현황

국내에서 위성자료를 활용하여 리드만을 탐지하는 연구는 없었지만 Lee et al. (2016)에서는 CryoSat-2 기반 북극 해빙 freeboard와 두께를 추정하기 위해 CryoSat-2 beam behavior 변수들과 후방산란계수와 규칙기반의 기계학습인 decision trees와 random forest를 활용하여 리드를 탐지하는 알고리즘을 개발하였다. 위성자료를 활용한 해빙 농도 예측 모델은 Chi and Kim (2017)에 의하여 제안되었으나, 본 연구에서는 CNN 기법을 활용한 딥러닝 기반 one-month sea ice concentration prediction model을 제안하였다.

제 2 절 국외 기술개발 현황

1. 북극해빙 프리보드 및 해빙 두께 추정 알고리즘 개발 및 월별 리드 비율 산출

국외에서는 1990년 초반부터 위성자료(AVHRR, DMSP)를 통해 리드를 탐지해왔다. 2000년부터는 MODIS IST(Ice Surface Temperature)와 AMSR, 그리고 고도계(SARAL/Altika, CryoSat-2) 위성이 리드를 탐지하기 위해 많이 활용되었다. Willmes and Heinemann (2015)은 MODIS IST 산출물을 활용하여 1km 해상도의 전 북극 리드 맵을 만들었다. IST는 열적외선 채널을 이용하기 때문에 구름의 영향이 있지만 상대적으로 작은 크기의 리드까지 탐지해 낼 수 있었다. Willmes and Heinemann (2016)에서는 fuzzy cloud artifact라는 기술을 활용하여 구름의 영향을 최소화 하였고 북극 해양의 해류, 수심, shear zone등과 함께 리드의 다이내믹스를 분석하였다.




그림 2.1.1 Willmes and Heinemann, 2015의 MODIS IST를 활용한 lead 탐지 결과.

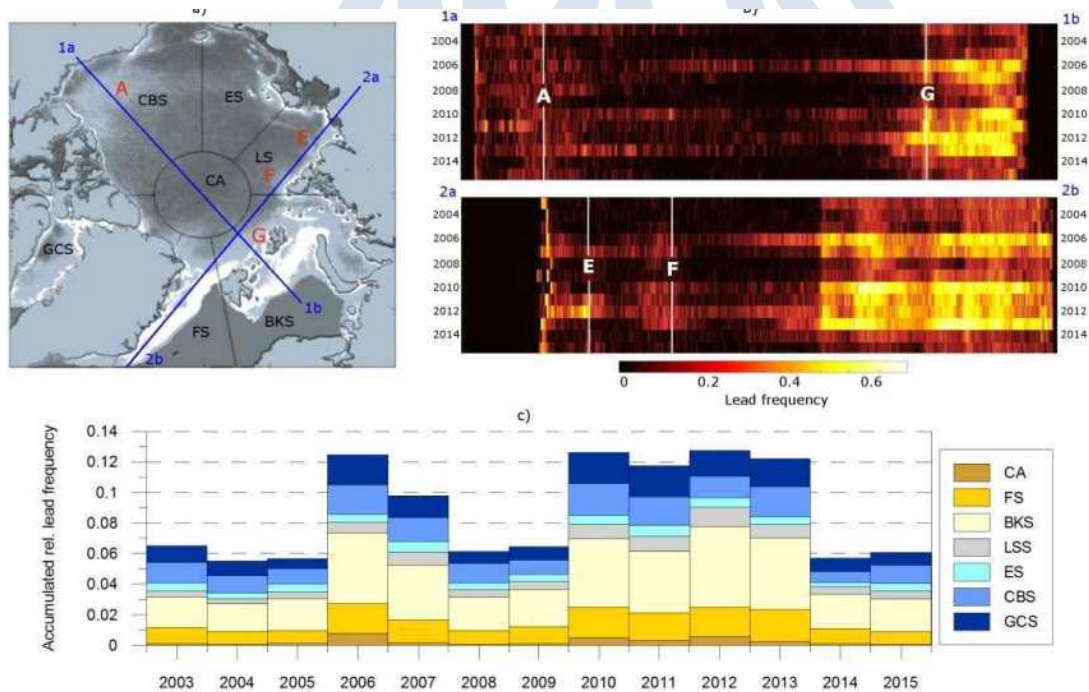


그림 2.1.2 2003년부터 2015년까지 북극의 해양 섹터별로 리드의 frequency 분석 (Willmes and Heinemann, 2016).

Rohrs and Kaleschke (2012)는 AMSR 채널의 polarization ratio를 활용하여 리드를 탐지하였다. AMSR는 passive microwave를 사용하므로 3km 이상의 큰 리드를 탐지 할 수 있었다.




그림 2.1.3 AMSR의 18, 89GHz의 비율을 활용하여 산출된 일일 얇은 해빙 농도의 비율(Rohrs and Kaleschke, 2012).

MODIS와 AMSR와 같은 장면 기반의 위성 이외에도 항공, 위성 기반의 고도계 센서를 활용하여 리드를 탐지하였다. Zygmontowka 등 (2013)은 CryoSat-2의 SIRAL(Synthetic Aperture Interferometric Radar Altimeter)와 비슷한 항공 센서인 ASIRAS(Airborne Synthetic Aperture and Interferometric Radar Altimeter System)와 베이시안 분류기를 활용하여 링컨 해 주변의 적은 지역에서 리드를 탐지하였다. Zakharova 등 (2015)과 Wernecke and Kaleschke (2015)는 각각 SARAL(Satellite with Argos and Altika)와 CryoSat-2 위성을 활용하여 리드를 탐지하였다. Zakharova 등 (2015)은 단순한 임계값을 사용하여 특정 지역의 리드를 탐지하였지만 Wernecke and Kaleschke (2015)는 임계값 최적화를 통해 리드를 탐지하고 전 북극 월별 리드 비율을 산출 하였다.

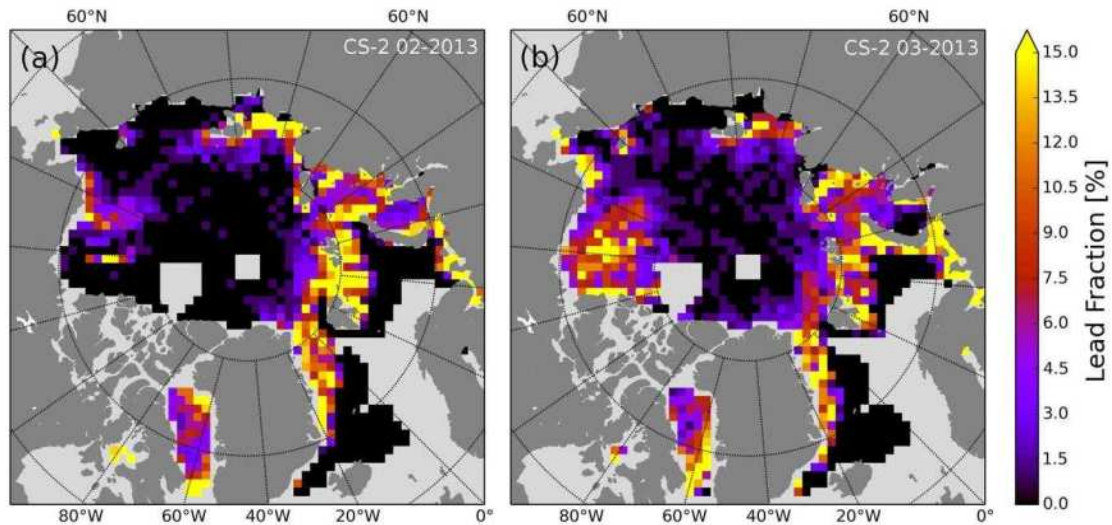


그림 2.1.4 2013년 2, 3월의 월별 리드 비율(Wernecke and Kaleschke, 2015).

급격하게 변화하는 북극 해빙 환경을 모니터링하기 위해 다양한 위성 자료들이 활용되어 해빙 농도, 해빙 면적, 해빙 두께 등의 위성 기반 해빙 관련 변수들이 산출되어 왔다. 그 중에서도 해빙 두께는 그 두께에 따라 북극에 입사하는 태양복사의 반사도가 달라지고 해빙 용융에 의한 담수의 유출량 산출에 중요한 정보를 제공할 수 있을 뿐 아니라 기후 모델의 초기 입력 값이 되어 기후 모델의 북극 해빙 관련 변수의 예측 정확도를 상승 시켜 줄 수 있음에도 불구하고 다른 북극 해빙 관련 변수들과 비교 하여 상대적으로 산출 알고리즘이 복잡하고 그 정확도가 떨어져 해빙 농도, 해빙 면적 산출물에 비해 활용도가 떨어진다.

위성 기반 북극 해빙 두께 산출물은 2003년 NASA(National Aeronautic and Space Administration)의 ICESat(Ice Cloud Elevation satellite) 미션 이후부터 본격적으로 활용되기 시작하였다. ICESat에 탑재된 고도계 센서를 활용하여 해빙 두께를 측정할 시 해빙 리드(lead)를 탐지하는 것이 매우 중요하다. 해빙 리드는 해빙 사이 얇고 길게 생기는 틈으로 리드에서 측정되는 높이를 해수면 높이로 간주하고 이 높이와 해빙 위에서 측정되는 높이의 차이를 해빙 프리보드라 함. 해빙 두께는 해빙 프리보드 높이와 해빙, 해수, 눈의 밀도, 눈의 두께 정보와 함께 hydrostatic 법칙에 따라 계산될 수 있다. 따라서 정확한 리드 탐지가 수행되어야 정확도 높은 해빙 프리보드와 해빙 두께가 산출 될 수 있다.

ICESat 자료를 활용한 리드를 탐지하기 위한 여러 알고리즘이 있었다. Kwok 등 (2003)은 ICESat자료와 동시간대의 SAR(Synthetic Aperture Radar) 자료를 활용하여 리드를 탐지하였지만 시간대가 일치하는 SAR자료가 있어야만 리드 탐지가 가능했고 자료처리 시간이 오래 소요되는 단점이 있다. Zwally 등 (2008)은 ICESat 프로파일의 높이 중 하위 2%의 높이를 리드라 간주하였다. 이 방법은 리드를 찾는 속도가 빠를 수 있으나 계절과 위도에 따라 리드의 비율이 다를 수 있는데 이점을 반영하지 못하였다는 단점이 있다. 마지막으로 Farrell 등 (2009)는 간

단한 임계값을 활용하여 리드를 탐지하였다.

ICESat은 레이저 고도계를 사용하여 foot print가 좁아 두 달 평균자료를 사용해야 전 북극을 커버 할 수 있고 2009년도에 센서의 고장으로 미션이 종료되었다. 2010년 ESA(European Space Agency)에서 lead 탐지 정확도를 높이기 위하여 SAR 고도계 탑재한 CryoSat-2를 발사하였다. 2010년 이후 CryoSat-2를 활용하여 남북극 해빙 두께를 다양한 방법으로 현재까지 추정하고 있다.

Laxon 등 (2013)은 Farrell 등 (2009)와 마찬가지로 간단한 임계값을 활용하여 리드를 탐지하였다. Ricker 등 (2014)는 Laxon (2003)에서 사용되었던 변수에 다른 변수를 더 추가하여 리드를 탐지하고 2013년 3월, 11월의 해빙 프리보드와 해빙두께를 추정하였다. 하지만 자연 상태에서 리드는 다양한 상태로 존재하고 계절에 따라 다르기 때문에 계절과 위도를 고려하지 않고 고정된 임계값을 사용하게 되면 리드를 오탐지하게 되는데 이는 곧 해빙 프리보드와 두께 추정의 정확성을 떨어뜨리게 된다. Lee 등 (2016)은 다양한 북극 리드의 특성을 반영하기 위해 MODIS 영상으로 리드를 파악하고 2011-2014년 3, 4월의 리드의 특성을 반영할 수 있는 5개의 변수(STD; Stack Standard Deviation, SS; Stack Skewness, SK; Stack Kurtosis, PP; Pulse peakiness, Backscatter σ_0)를 각각 리드, 해빙, 해양에 대해서 추출하여 훈련자료를 생성하고 규칙 기계학습인 decision trees 와 random forest를 사용하여 리드를 탐지하고 2011-2014년 3, 4월의 북극 해빙 프리보드와 두께를 추정하였다.

KOPRI
극지연구소

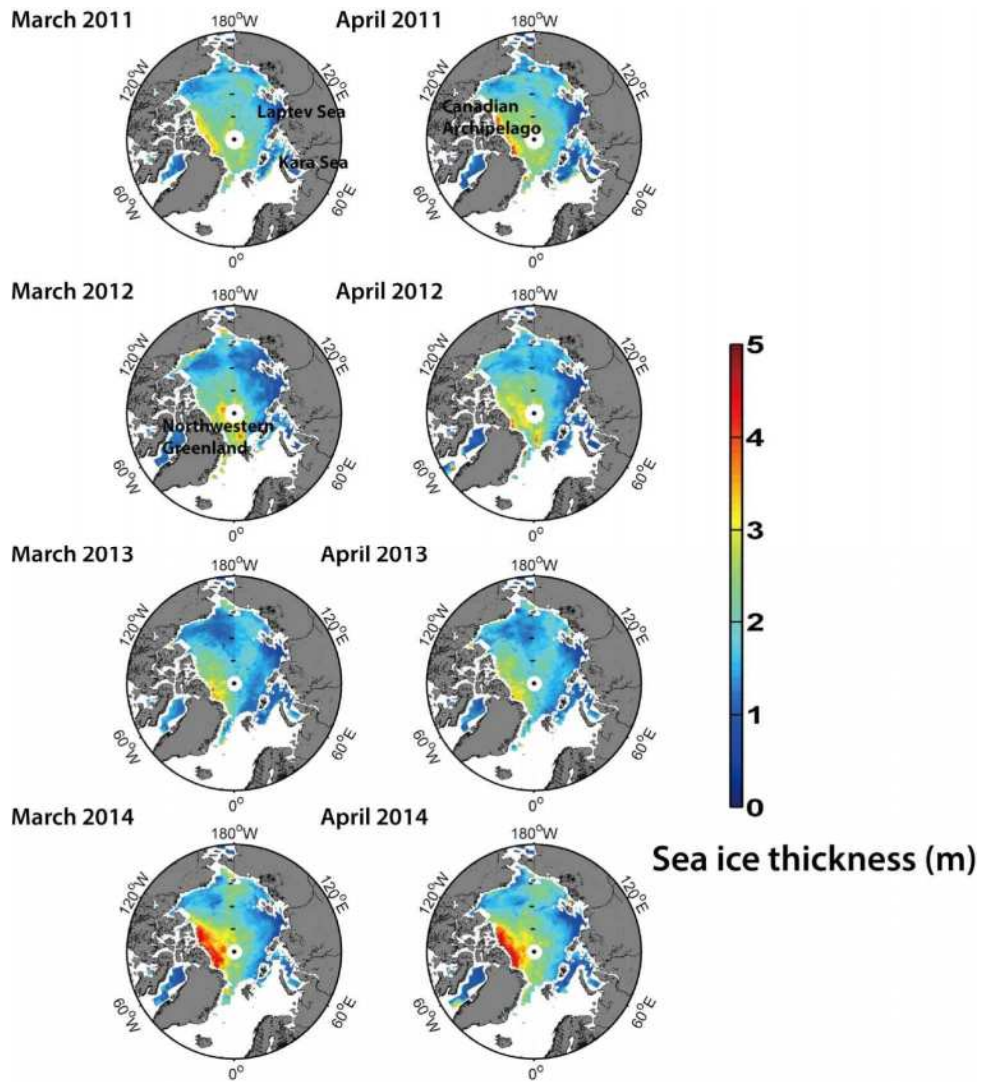


그림 2.15 Decision trees 기반의 리드 탐지 방법을 활용하여 산출된 북극 해빙 두께 (Lee 등 2016).

하지만 Lee 등 (2016)의 리드 탐지 방법은 2011-2014년 3, 4월만 적용할 수 있어 한계점을 가진다. 여름(7-9월)을 제외한 나머지 월의 정확한 해빙 두께를 추정하기 위해서는 해당 월의 리드 샘플이 필요하다. 본 연구에서는 북극 해빙 두께 산출물의 활용도를 높이고자 한다.

여름을 제외한 전 월의 해빙 두께를 추정하기 위해 해당 월의 리드 샘플을 추출하여 각 월 또는 각 계절에 맞는 기계학습 기반 리드 탐지 모델을 개발할 것이다. 개발된 기계학습 기반 리드 탐지 모델을 각 월 또는 각 계절에 적용하여 해빙 프리보드 및 두께를 추정하고 현장관 측자료와의 비교 검증을 통해 해빙 두께의 정확도를 검증할 것이다. 북극 해빙 리드는 위에서 설명하였듯이 고도계를 활용하여 북극 해빙 두께를 추정할 때에도 중요하지만 리드는 독립적으로도 중요한 의미를 가진다. 리드의 해양 온도는 상대적으로 대기에 비해 온도가 높기 때문에 리드는 해양과 대기 사이의 많은 양의 열, 운동량, 수분을 교환하는 역할을 한다. 그 결과 리드 안에서 새로 형성되는 해빙은 계절별 해빙의 질량 변화에 상당한 기여를 한다. 게다가 리

드와 얇은 해빙은 해빙 표류 패턴의 정성적인 평가의 변수가 될 수 있으므로 변화하는 북극 기후 시스템을 대변할 수 있는 변수가 될 수 있다.

따라서 해양과 대기 경계층 사이의 프로세스에 중요한 역할을 하는 리드를 탐지하는 것은 매우 중요하다. 본 연구에서는 기존에 사용되지 않았던 waveform mixture analysis를 사용하여 리드를 탐지했다. Waveform mixture analysis는 spectral mixture model과 같은 개념으로 CryoSat-2 리드 waveform, 해빙 waveform을 각각 end-member로 두고 waveform mixture model을 구축하였으며, 각 CryoSat-2 프로파일에서 리드의 비율이 0.7 이상일 때 리드라 간주하고 리드와 해빙을 구분하였다.




그림 2.1.6 Waveform mixture analysis를 활용하여 탐지된 리드. 배경은 MODIS 영상이며 빨간색 점은 리드 파란색 점은 해빙임.

리드의 구분을 통해 월 평균 북극 전체 리드 비율을 산출할 수 있으며 그 비율을 통해 시계열적으로 변하는 리드의 비율을 파악할 수 있으며 얇은 해빙과 해빙 표류를 정성적으로 파악할 수 있을 것으로 보인다.

2. 북극 해빙 농도 단기 예측 알고리즘 개발

최근까지도 북극지역의 해빙 예측 연구에는 자료동화 기반의 기후모델이 사용되고 있으며 DMSP (Defense Meteorological Satellite Program, 25km)와 SSMIS (Special Sensor Microwave Imager/Sounder, 12.5km, 85-91GHz)의 해빙농도 산출물을 입력자료로 사용하며 해빙 농도 및 확장을 예측하고 있다. P.G. Posey 등 (2015)에서는 자료동화 기반 해빙 농도 예측 모델인 ACNFS (Arctic Cap Nowcast/Forecast System)와 GOF 3.1 (Global Ocean

Forecast System)에 기본 초기자료의 해상도 및 해빙 가장자리 오차를 개선하고자 MASIE/IMS (Multisensor Analyzed Sea Ice Extent/Interactive Multisensor Snow and Ice Mapping System) 해빙 마스크를 사용하기도 하였다. Peng 등 (2013)에서는 해빙의 변화 패턴을 보고자, 장기 누적 (1987년에서 2007년)까지의 위성기반으로 산출된 해빙농도를 이용한 해빙 확장 (sea ice extension)의 변화 추이를 알아보았고, 시계열적 경향성을 파악하였다. 이는 과거의 해빙농도 및 해빙 확장자료를 이용하여 미래 경향을 예측할 수 있음을 의미한다.

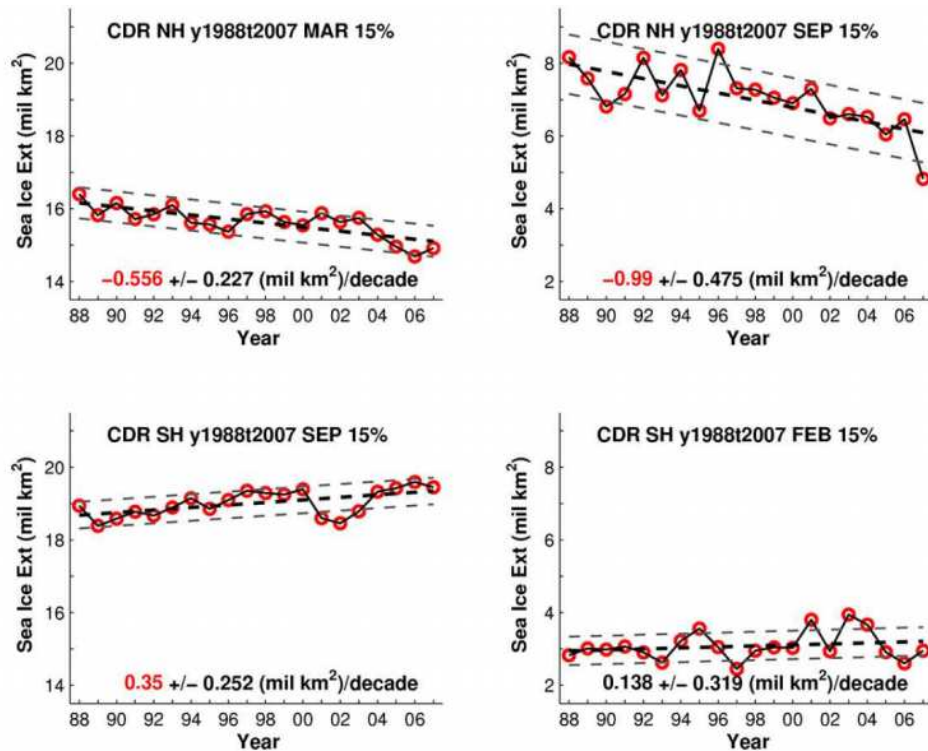


그림 2.1.7 북반구와(상) 남반구(하)의 연간 최대해빙확장(좌)과 최소해빙확장(우) 비교. 95% 신뢰도의 연간 경향 (적색)

Kang 등 (2014)은 GloSea4, NCEP CFSv2, GEOS-5 (National Aeronautics and Space Administration Goddard Earth Observing System version 5), CCCma (the Canadian Centre for Climate modeling and Analysis), CanCM3&4 (Coupled Climate Model versions 3 and 4) 모델들의 앙상블을 이용하여, 해면기압의 EOF (Empirical Orthogonal Function) 패턴 분석을 통해 극진동인자 (Arctic Oscillation index) 변화 예측을 하였다. 표면온도, 상층 바람, 강우의 변칙성 (anomaly) 또한 AO인자와 상관성이 있음을 물리적으로 해석하였다. 이는 해상풍과 AO 변화는 해빙의 움직임 (Sea ice motion)에 영향을 끼치고, 해빙 두께 및 해빙농도에 영향을 주게 된다는 Rigor 등 (2002)의 결과와 비교하여, 해빙 농도 예측에 고려 요소로 사용이 될 수 있다.

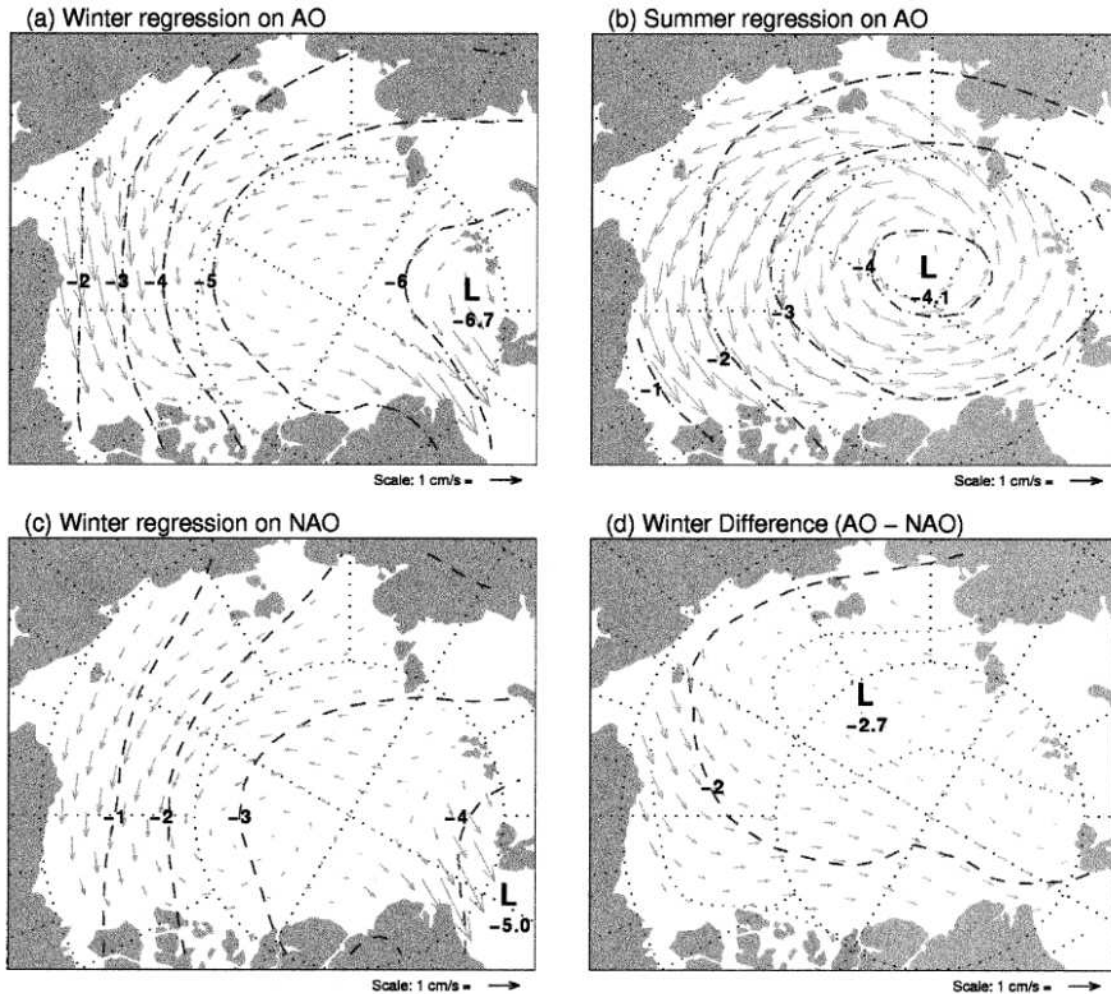


그림 2.18 AO와 NAO (North Atlantic Oscillation) 인자에 대해 회귀한 해면기압 (흑색 점선)과 해빙의 움직임 (화살표). (a) AO인자에 회귀한 겨울, (b) AO인자에 회귀한 여름, (c) NAO인자에 회귀한 겨울, (d) AO와 NAO 인자의 차에 회귀한 겨울 지도.

kang 등 (2014)은 MODIS IST(Ice Surface Temperature), MERRA(Modern-Era Retrospective Analysis for Research and Applications)의 바람장 자료와 기계학습인 SVM(Support Vector Machine)을 통해 해빙면적을 예측하였다. 하지만 전체면적만을 예측하는 것은 해빙 분포를 볼 수 없어 한계점을 가진다. 본 연구에서는 문헌 조사를 통해, 과거의 해빙 농도 및 기상 요소, AO 인자가 미래의 해빙 농도 예측에 상관성이 있음을 파악할 것이다. 위성 기반 자료인 MODIS IST(와 재분석 자료인 MERRA AO, 북극 dipole 인덱스, 바람 속도 등의 변수들과 해빙 농도 사이의 구체적 상관성과 해빙 농도에 영향을 미치는 인자의 중요도를 파악할 것이다. 더 나아가 다중 위성자료의 융합과 다양한 통계기법 및 기계학습을 이용하여 월 해빙 농도 예측 모델을 개발 할 것이다.

3. Passive microwave 위성 자료 융합을 통한 초년생 해빙 두께 추정

해빙은 바다의 표면에서 바다와 대기 사이의 단열재 역할을 하는데 이 때 열 전도율은 해빙의 두께에 반비례하며 Maykut 등 (1978)에 따르면 부분적 해빙의 열 전도율은 겨울철의 두꺼운 해빙에 비해 수십~수백배가 높은 것으로 알려져있다. 초년생 해빙은 두께가 30cm ~ 2m 사이이며 봄과 여름철에 녹고 1년이상 존재하지 않기 때문에 계절에 따라 그 농도와 두께 변화 폭이 크므로 해빙이 대기/해양에 미치는 영향을 파악하기 위해서 초년생 해빙 두께 변화에 대한 보다 정확한 추정이 필요한 실정이다.

해빙 두께를 추정하기 위하여 주파수와 주파수 밝기 온도 비율을 이용하는 방법이 있는데 주파수를 이용한 방법은 SMOS(Soil Moisture and Ocean Salinity)위성에서 투과성이 좋은 L-band (1.4Ghz)를 통한 해빙 두께 추정이 있다 (Kaleschke 등 2010). Iwamoto 등 (2012)은 Chukchi해에 대하여 AMSR-E(Advanced Microwave Scanning Radiometer for EOS)의 89Ghz, 36Ghz 밴드의 수직, 수평 편광 밝기온도 비율로부터 초년생 해빙 두께를 구한 후, MODIS의 열평형 모델로부터 얻은 초년생 해빙 두께와 비교하였고, Iwamoto 등 (2014)은 이를 개선하여 북극 전체에 적용하였다.

하지만 현재까지의 연구들은 passive microwave의 주파수, 주파수 비율과 초년생 해빙의 관계를 통해 초년생 해빙 두께 추정 모델을 만들 때 단순한 선형관계식으로 모델을 만들었으나 선형관계식 보다 기계학습방법을 통한 모델 구축은 더 정확한 해빙 두께 추정 알고리즘을 만들 수 있을 것으로 기대 된다.

4. 해빙 농도 상세화 알고리즘 개발

Passive microwave를 통한 북극 해빙 관측은 대기와 태양의 영향을 거의 받지 않고 연속적으로 자료를 얻을 수 있다는 장점이 있으나 비교적 낮은 해상도 (현재 AMSR2의 경우 10km)로 인하여 거시적인 해빙의 움직임 및 농도 변화 관측은 가능하지만, 작은 변화의 관측에는 어려움이 있다. 이를 해결하기 위해 보다 높은 해상도의 자료가 필요하며 이번 연구에서 해빙 농도 상세화 알고리즘을 개발하고자 한다. 저해상도의 Passive microwave를 통한 해빙 농도 상세화를 위해서는 가중치 부여를 위한 고해상도 인자가 필요하며 해빙 농도에 영향을 미치는 인자들은 다양한데 Ogi와 Wallace (2012)는 북극 여름철 해수면 바람 anomaly와 해빙 농도와의 관계를 연구했고 Choi 등 (2014)은 이른 여름철 구름에 의한 일사량과 늦은 여름철 해빙 농도와의 관계를 연구했는데, 이와 같이 해빙 농도에 영향을 미치는 인자 파악을 통하여 해빙 농도 상세화 알고리즘에 이용하고자 한다. 역학적인 인자 파악 이외에도 고해상도 위성의 해빙 산출물을 해빙 농도 상세화에 이용할 수 있는데 예를 들어 Ahn 등 (2014)은 MODIS 1km 해빙일수비율을 가중치를 이용하여 10km 해상도의 오호츠크해 AMSR2의 해빙 농도 데이터를

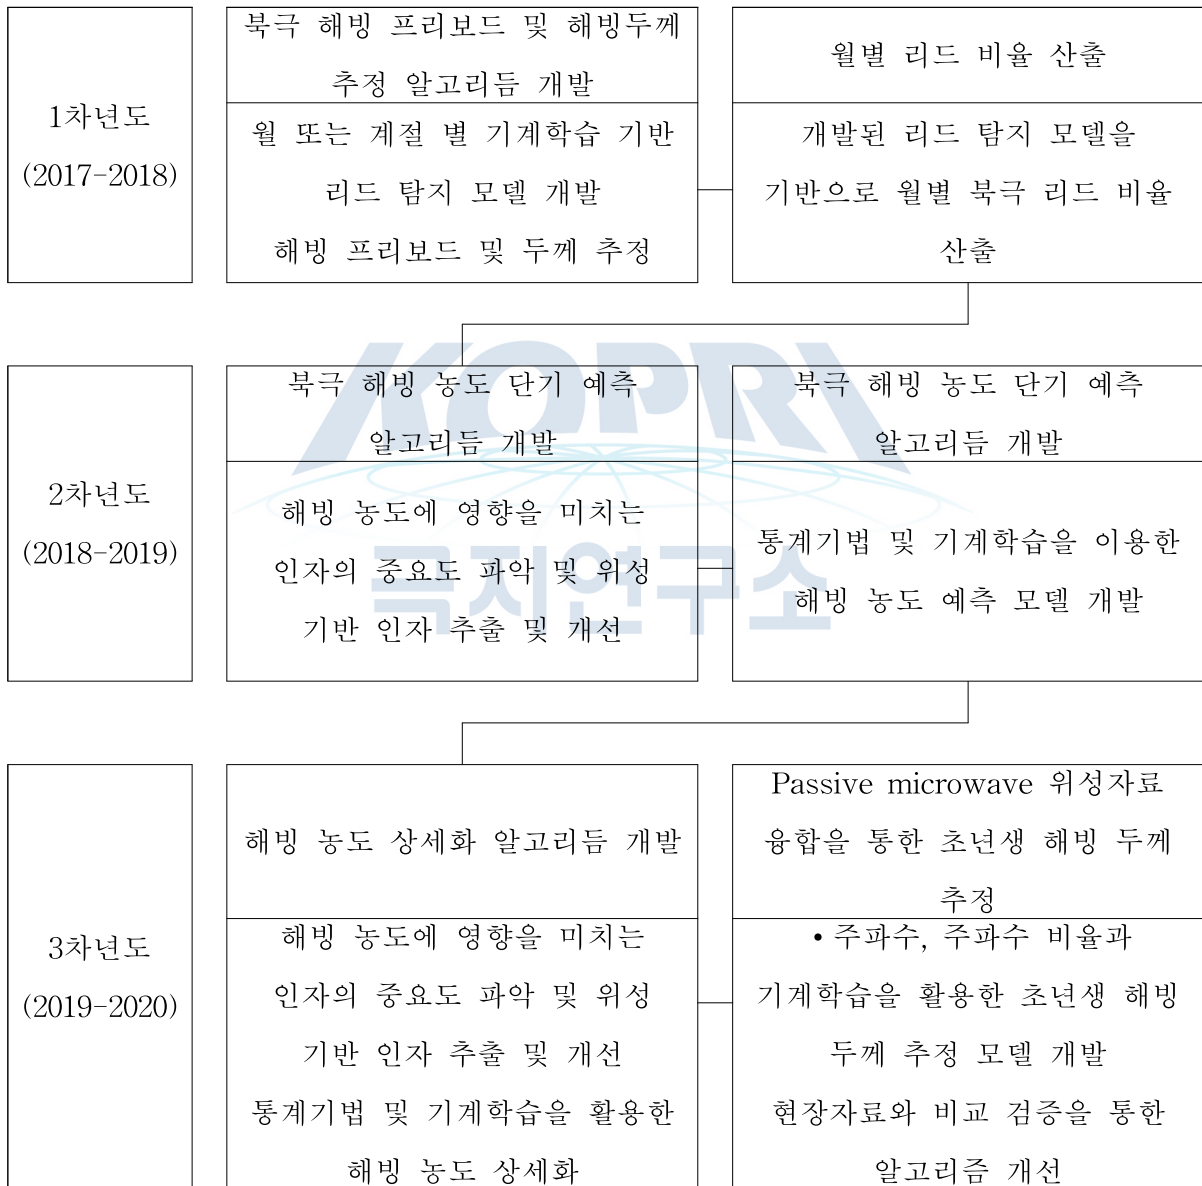
1km로 상세화 하였다. 최근 주목을 받는 기계학습을 이용하여 위성 자료의 공간 해상도를 높일 수 있는데 Ke 등(2016)은 LandSat8 (30m)과 다양한 기계학습 방법(SVM, Cubist, RF 등)을 이용해 MODIS로부터 산출된 증발산량 (1km)의 해상도를 30m로 상세화 연구를 수행하였다.

하지만 아직 해빙 농도를 기계학습을 통하여 상세화 한 연구는 아직 부족하며 본 연구에서는 해빙 농도에 영향을 미치는 고해상도 위성 인자를 파악하고 기계학습 및 통계 기법을 통하여 해빙 농도 상세화 알고리즘을 개발하고자 한다.



제 3 장 연구개발수행 내용 및 결과

본 연구는 기존 문헌과 관련 연구 자료 및 정보를 통해 각 분야의 조사 방법을 정립하여 외국의 선진 연구그룹과 자료 분석 결과의 토의를 통한 자료 해석의 신뢰성을 제고하고자 하였다. 현장조사, 위성관측, 공간모델링 등 다 분야 학제적 자료를 취합하여 상호 보완적으로 해석하였다. 특히, 국내외의 여러 전문가와의 네트워크를 적극 활용하여 연구의 질을 높이고자 하였으며, 본 연구의 추진 체계는 아래와 같이 정리할 수 있다.



제 1 절 북극 해빙 프리보드 및 해빙 두께 추정 알고리즘 개발 및 월별 리드 비율 산출

연구결과	연구 내용
N-FINDR를 활용한 waveform end-member 선정	Lee et al. (2016) 제안된 Decision trees 알고리즘을 사용하여 리드 8,501, 해빙 420,858개의 waveform을 추출하고 리드와 해빙을 대표하는 waveform을 선정하였음.
waveform mixture analysis를 통한 독창적인 북극 리드 탐지	초분광 영상 분석에 많이 활용되는 Linear mixture analysis를 CryoSat-2 waveform에 적용하여 Waveform mixture analysis를 개발하였음.
2011-2016년 1-5, 10-12월 월별 리드 비율 산출	월별 북극 리드 산출물과 대기와 해양의 역학적인 현상과 비교하였음.
월별 리드 비율 타 산출물과 비교	2011년 1-3월 타 위성 기반의 북극 리드비율 산출물과 비교 결과 해상도와 센서의 차이로 인하여 값은 달랐지만 전체적인 리드의 분포는 비슷하였음.

1. 연구에 사용된 자료

북극의 리드(이하 리드)는 해빙 사이에 길게 갈라진 틈으로 북극 해빙의 일반적인 특징이다. 리드에서는 북극 해양과 대기사이의 많은 열, 습도, 운동량을 교환하기 때문에 북극 전체에서 차지하는 비율은 낮지만 중요하다. Lupkes et al. (2008)에 따르면 리드 비율의 변화에 따른 해빙 1% 해빙농도의 변화는 북극 해빙 표면 온도를 3.5K까지 상승시킬 수 있다고 하였다. 따라서 북극 리드를 탐지하고 변화를 모니터링 하는 것은 북극 전체의 에너지 수지를 평가하고 대기와 해양사이의 물리량 교환을 파악하는데 중요하다고 할 수 있다.

북극 전체의 리드 탐지는 현장관측 자료를 활용하기보다 주로 위성을 활용하여 효율적으로 리드를 탐지하였다. 1990년도 초반부터 AVHRR(Advanced Very High Resolution Radiometer), DMSP(Defense Meteorological Satellite Program) 위성을 활용하여 리드를 탐지하여 왔다. 2000년도 이후부터는 MODIS(Moderate Resolution Imaging Spectroradiometer)와 AMSR-E(Advanced Microwave Scanning Radiometer for EOS)위성이 주로 활용되었다. Chase and Holyer, 1990에서는 처음으로 linear mixture analysis를 Geosat 고도계에 적용하여 해빙의 종류와 농도를 추정하였다. Geosat 고도계는 상대적으로 낮은 공간해상도와 작은 개수의 range bin으로 인해 작은 크기의 리드를 탐지하는 것은 쉽지 않다.

본 과제에서는 Geosat보다 더 진보된 레이더 고도계인 CryoSat-2에 linear mixture analysis

를 적용하여 리드 탐지를 위한 waveform mixture algorithm을 개발하였고, 2011-2016년 1-5 / 10-12월의 북극 전역에 대한 월별 리드 비율을 산출하였다. CryoSat-2의 beam behavior 변수와 후방산란계수를 사용하는 이전 임계값 기반의 리드 탐지와는 달리 L1b 자료의 waveform을 바로 사용하기 때문에 CryoSat-2 baseline 업데이트에 영향을 받지 않고 지속적으로 리드를 탐지할 수 있다는 장점이 있다.

가. CryoSat-2

CryoSat-2는 SIRAL을 탑재하고 2010년 9월에 ESA(European Space Agency)에서 극지 환경 변화를 위해 발사한 위성이다. 현재 극지 환경을 전문적으로 관측할 목적을 가진 유일한 위성이다. CryoSat-2의 주요 센서인 SIRAL의 중심 주파수는 13.575GHz (Ku-band)이며 bandwidth는 320MHz 이다. CryoSat-2는 SIRAL 센서를 활용하여 지난 고도계 위성인 Geosat이나 Jason 보다 작은 리드를 효율적인 에너지 사용으로 탐지할 수 있다 (Wingham 등 2006). 본 연구에서는 CryoSat-2 baseline C SAR(Synthetic Aperture Radar) 모드와 SIN(SAR Interferometric) 모드를 사용하였으며 각각 256개와 1024의 range bin을 보유하고 있다 (Scagliola, 2014).

CryoSat-2는 높은 PRF(Pulse Repetition Frequency, 18.181KHz)로 64개의 버스트 레이더 펄스를 지표로 발사한다. 이때 위성의 움직임으로 인해 도플러 빔(Doppler beam)이 형성 된다. 각 도플러 빔에서 256개의 waveform이 겹치게 되는데 이를 beam stacking이라 한다. 겹쳐있는 Speckle noise와 thermal noise를 줄이기 위해 256개의 waveform을 평균하여 하나의 waveform으로 만든다. 다음 그림은 리드와 해빙의 CryoSat-2 L1b waveform의 예시이다. Waveform의 시작 부분이 조금씩 다르기 때문에 leading edge 내의 signal 파워의 1%를 시작점으로 하였다.




그림 3.1.1 대표적인 리드와 해빙의 CryoSat-2 L1b waveform.

나. 해빙 edge 자료

EUMETSAT(European organization for the exploitation of METeorological SATellites) OSISAF(Ocean and Sea Ice Satellite Application Facility)에서 제공하는 해빙 edge 자료를 사용하여 전 북극 월별 리드 비율 맵을 마스킹 하였다. 해빙 edge 산출물은 SSMIS(Special Sensor Microwave Imager/Sounder) 위성의 19GHz와 91GHz의 polarization ratio와 37GHz와 19GHz의 gradient ratio를 사용하여 개발 되었다.

다. 해빙 edge 자료

본 연구에서 산출된 전 북극 월별 리드 비율 맵과 기존 연구의 전 북극 월별 리드 비율 맵을 비교하였다. Rohrs and Kaleschke (2012)는 AMSR-E 자료를 활용하여 얇은 해빙 농도를 산출한다. 얇은 해빙 농도가 50% 넘으면 리드라 간주 하고 일일 얇은 해빙 농도자료를 평균하여 월별 리드 비율 맵을 만들었다. Wernecke and Kaleschke (2015)는 약 99.5km의 공간 해상도로 월별 리드 비율 맵을 만들었다. Willmes and Heinemann (2016)은 일일 리드 맵을 육상, 구름, 해빙, 리드, 리드-artifact의 카테고리 나누어 산출했다. 카테고리 중에서 리드 클래스만 고려하여 일일 리드맵을 평균하여 월별 리드 비율 맵을 산출했다. 본 연구에서는 모든 산출물이 공통되는 시간인 2011년 1-3월만을 비교에 사용하였다.

2. Waveform mixture algorithm을 개발하기 위한 방법

가. Waveform mixture algorithm

원격탐사에서 endmember는 순수한 물, 식생, 나지 픽셀과 같은 지상에서 분광학적으로 순수한 픽셀을 말한다. Endmember는 linear mixture analysis를 수행하는데 있어 필수적인 요소이다. Linear mixture analysis는 픽셀 내에서 지상 물체의 분광학적 특성이 선형적으로 합성되어 있다는 것을 가정한다(Keshava and Mustard, 2002). Linear mixture analysis는 spectral mixture 문제를 해결하는데 탁월한 성능을 보여왔다(Foody and cox, 1994; Dengsheng 등, 2003; Changshan, 2004; Iordache 등, 2011). Linear mixture analysis는 endmember를 기반으로 하여 혼합된 픽셀의 abundance를 산출한다. 고도계의 footprint 내에는 리드와 해빙이 혼합되어 존재하기 때문에 linear mixture analysis를 고도계의 waveform에 적절하게 적용할 수 있다. 본 연구에서는 linear mixture analysis를 CryoSat-2 L1b waveform에 적용하여 waveform mixture algorithm을 개발하였다. 다음 그림의 (a)는 waveform mixture algorithm에서 사용된 리드 endmember이고 (b)는 해빙 endmember 이다. Waveform mixture algorithm의 성공적인 구동을 위해서는 적절한 endmember의 선택이 필수적이다.

기본적인 waveform mixture model의 구조는 아래 식과 같다.

$$Y_p = \sum_{k=1}^K a_{ik} E_k + r_k$$

수식 3.1.1.

w a v e f o r m
m i x t u r e m o d e l

여기서 $Y_p = \{Y_1, Y_1, Y_1, Y_1 \dots Y_k\}$ 는 waveform vector 이고 k는 waveform의 range bin의 개수이다. a_{ik} 는 abundance 비율로서 리드와 해빙 endmember에 따른 비율을 표현한다. E_k 는 endmember vector이다. r_k 는 un-modeled residual 이다. abundance는 un-modeled residual을 최소화 시키는 최소자승법을 수행함으로써 얻을 수 있다.

Chase and Holyer (1990)은 linear mixture analysis를 고도계의 waveform에 수행하는데 있어 2가지 문제점을 제시했다. 첫 번째는 waveform의 footprint내에는 리드와 해빙이 선형적으로 혼합되어 있지 않을 수도 있다는 것이다. CryoSat-2는 리드의 specular 반사에 더 민감하게 반응하기 때문에 footprint 내에 리드와 해빙이 공존하게 된다면 리드로 과대탐지 할 경향이 있다. 두 번째는 Chase and Holyer (1990)이 사용했던 Geosat은 waveform이 레이더 빔이 footprint 중심으로 편향 되어 있었다. 이는 linear mixture analysis를 waveform에 적용하는데 에러의 원인이 될 수 있다. 그러나 CryoSat-2 L1b waveform은 200개 이상의 waveform이 다양한 입사각을 가지고 평균되어 만들어지기 때문에 다음과 같은 문제를 해결 할 수 있다.

나. Endmember의 선택

Endmember의 선택은 waveform mixture algorithm을 수행하는데 필수적인 요소이다. 2011-2016년 1-5월, 10-12월 총 48개월 동안 각 월마다 48개의 CryoSat-2 orbit 파일들의 endmember를 추출하기 위하여 선정하였다. 리드와 해빙의 endmember 후보 waveform은 Lee 등 (2016)에서 개발된 DT(Decision Trees) 기반 리드 탐지 기법을 참고하여 선택하였다. DT는 원격탐사의 분류 문제를 해결할 때 효율적으로 사용되어온 방법이다(Kim 등, 2015; Torbick and Corbiere, 2015; Amani 등, 2017; Tadesse 등, 2017). 주관적인 endmember의 선택을 피하기 위해서 DT에 의해 선정된 리드와 해빙의 후보 waveform 중에서 N-FINDR 알고리즘을 사용하여 각각 리드와 해빙 endmember를 선정하였다. N-FINDR는 대표적인 endmember를 자동적으로 선정해주는 알고리즘으로 endmember를 추출할 때 가장 많이 사용되는 알고리즘 중 하나이다(Winter, 1999; Zortea and Plaza, 2009; Erturk and Plaza, 2015; Ji 등, 2015; Chi 등, 2016). DT에 의해 선정된 리드와 해빙의 waveform 개수는 각각 8,501, 420,858개 이다.




그림 3.1.2 리드와 해빙의 endmember 추출을 위해 사용된 2011-2016년 1-5월, 10-12월 동안의 48개 CryoSat-2 orbit 파일들.

Waveform mixture algorithm 기반 리드의 분류는 3, 5, 10월의 250m 해상도의 MODIS 영상으로 평가되었다. 모든 월의 MODIS 영상을 사용하여 리드 분류를 평가해야 하지만 극야와 MODIS와 CryoSat-2의 시간차이(30분)를 고려해야했기 때문에 4개의 비교만 수행하였다.

Waveform mixture algorithm의 모델은 각각 리드와 해빙의 abundance를 CryoSat-2 along-track 포인트에 따라 산출한다. 리드가 있는 곳에는 리드의 abundance가 높고 해빙의 abundance가 낮으면 해빙위에서는 그 반대이다. 리드와 해빙의 abundance를 리드와 해빙의 이분법으로 만들기 위해서는 최적의 임계값을 설정하는 것이 중요하다. 자동 calibration을 통해 리드와 해빙의 구분할 수 있는 최적의 임계값을 산출하였다. 자동 calibration을 수행하기 위해서 2014년 4월 17일, 2015년 5월 25일, 2015년 10월 10일, 2016년 3월 27일의 MODIS 영상을 통해 리드와 해빙의 기준자료를 육안으로 선정하였다. 여기서 waveform mixture algorithm이 탐지할 수 있는 리드의 크기를 언급할 필요가 있다. 최적의 임계값을 산출하기 위한 calibration 과정에서 MODIS 250m 해상도 영상을 사용하기 때문에 최소 250m 또는 그 이상의 리드를 waveform mixture algorithm이 탐지 할 수 있다. MODIS 영상에서는 250m 이하의 리드를 보기 힘들며 이것이 리드를 탐지하는데 있어 불확실성이 될 수 있다.

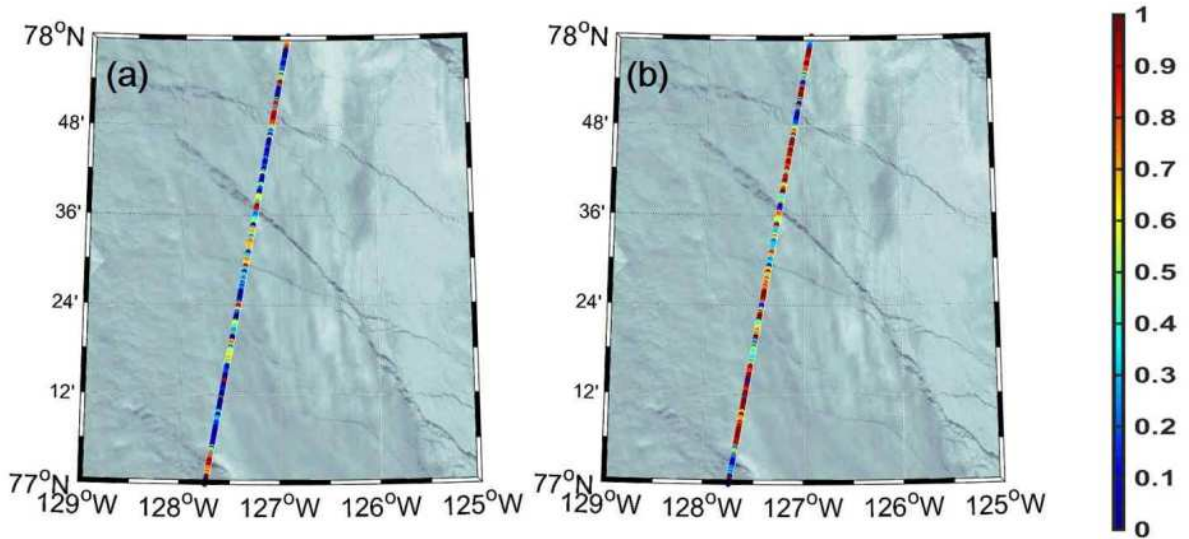


그림 3.1.3 2015년 10월 10일 waveform mixture algorithm에서 산출한 리드와 해빙의 abundance (a) 리드 abundance, (b) 해빙 abundance.

다. 10x10km 격자의 sensitivity 계산

전 북극 월별 북극 리드비율 산출은 10km 격자 내에 CryoSat-2의 관측수와 리드의 관측수의 비율로 산출된다. 극 쪽으로 갈수록 CryoSat-2의 관측 개수가 많고 북극 해안가로 갈수록 CryoSat-2의 관측 개수가 적어진다. 격자에 따라 CryoSat-2의 관측수가 다르기 때문에 격자의 민감도 테스트를 수행하였다. 10x10km 격자 내의 리드와 해빙 관측수의 30%를 임의로 50번 바꾸어 표준편차를 계산하여 민감도를 계산하였다. 높은 표준편차 값일수록 리드와 해빙 개수의 변화에 따라 더 민감하다는 것을 보여준다. 표준편차가 0인 지점은 리드가 발생하지 않은 지역이다.

3. 연구 결과

가. 리드 분류 결과

그림은 리드와 해빙을 대표하는 waveform으로 N-FINDR 알고리즘에 의해 선정되었다. 리드의 waveform은 specular 반사에 의해 좁고 curve와 함께 빔 파워가 강하게 나타난다. 해빙은 리드보다 거친 표면으로 인해 waveform의 분포가 리드 waveform 보다 넓다.

자동 calibration을 통한 리드와 해빙의 abundance 비율은 리드 abundance 0.84, 해빙 abundance 0.57로 나타났다. 다음 그림에는 waveform mixture algorithm의 리드 분류 결과와 임계값을 사용한 CryoSat-2 기반 리드 탐지 리드 분류 결과(Laxon 등 2013; Rose, 2013; Lee 등 2016)를 비교하였다. 기존에 임계값을 사용한 리드 분류 방법은 beam behavior 변수들과 후방산란계수를 입력 값으로 사용하기 때문에 baseline C 자료를 사용하기 위해 각 변수들을 baseline C에 맞게 변환했다.

MODIS 영상을 활용하여 4가지 리드 분류 결과를 평가·비교하였다. 아래 그림과 같이 리드 분류 결과에서 빨간 점이 리드를 의미하고 파란 점이 해빙의 의미한다. 객관적인 비교를 위해 각각 방법마다 정량적인 평가가 수행되었다. Lee 등 (2016)의 DT가 overall accuracy 95.19%로 가장 높았고 그 다음으로 waveform mixture algorithm이 95%, Rose (2013)이 93.26%, Laxon 등 2013이 91.70%를 기록했다. Waveform mixture algorithm의 리드 user's accuracy는 DT의 리드 user's accuracy보다 낮는데 이는 waveform mixture algorithm이 해빙을 리드로 오탐지했다는 것을 알 수 있다. Waveform mixture algorithm은 전반적으로 DT와 비슷한 성능으로 리드를 탐지하였다. Waveform mixture algorithm을 수행하기 위한 endmember를 선정할 때 DT를 활용하여 리드와 해빙 waveform을 선정하였기 때문에 waveform mixture algorithm과 DT의 결과는 비슷한 것이 당연하다고 볼 수 있다. Waveform mixture algorithm을 해빙 두께를 산출하는데 필요한 리드 탐지에 충분히 사용가능 할 것으로 보인다.



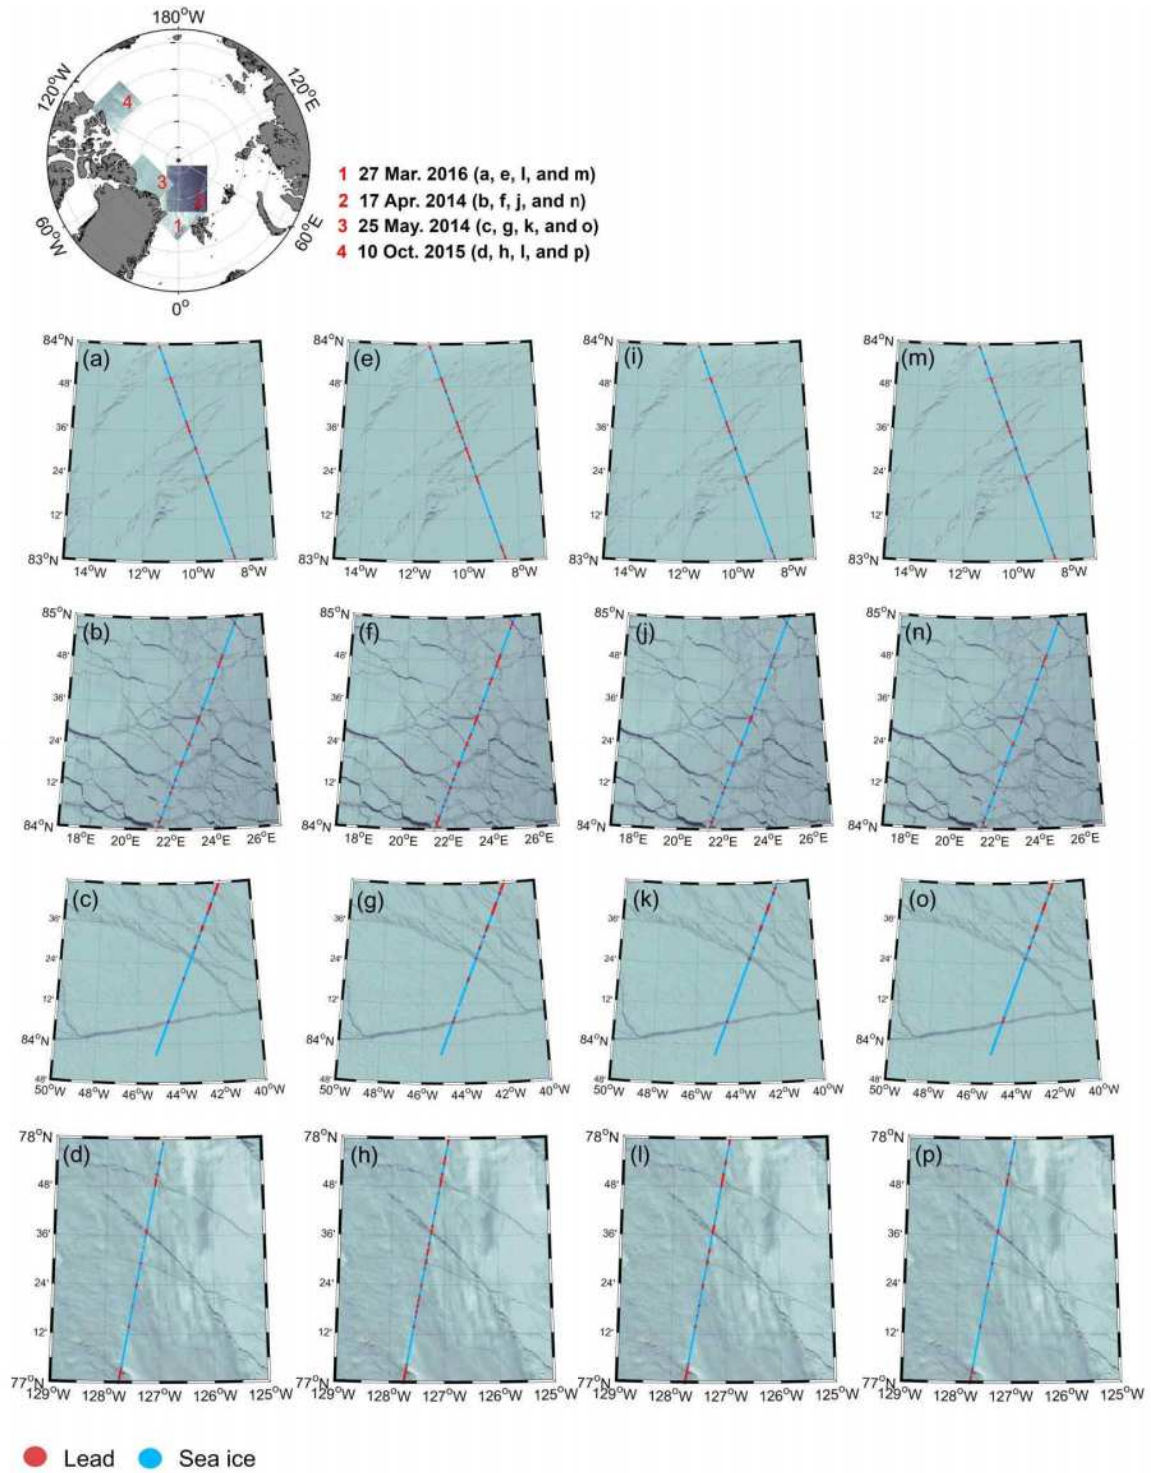
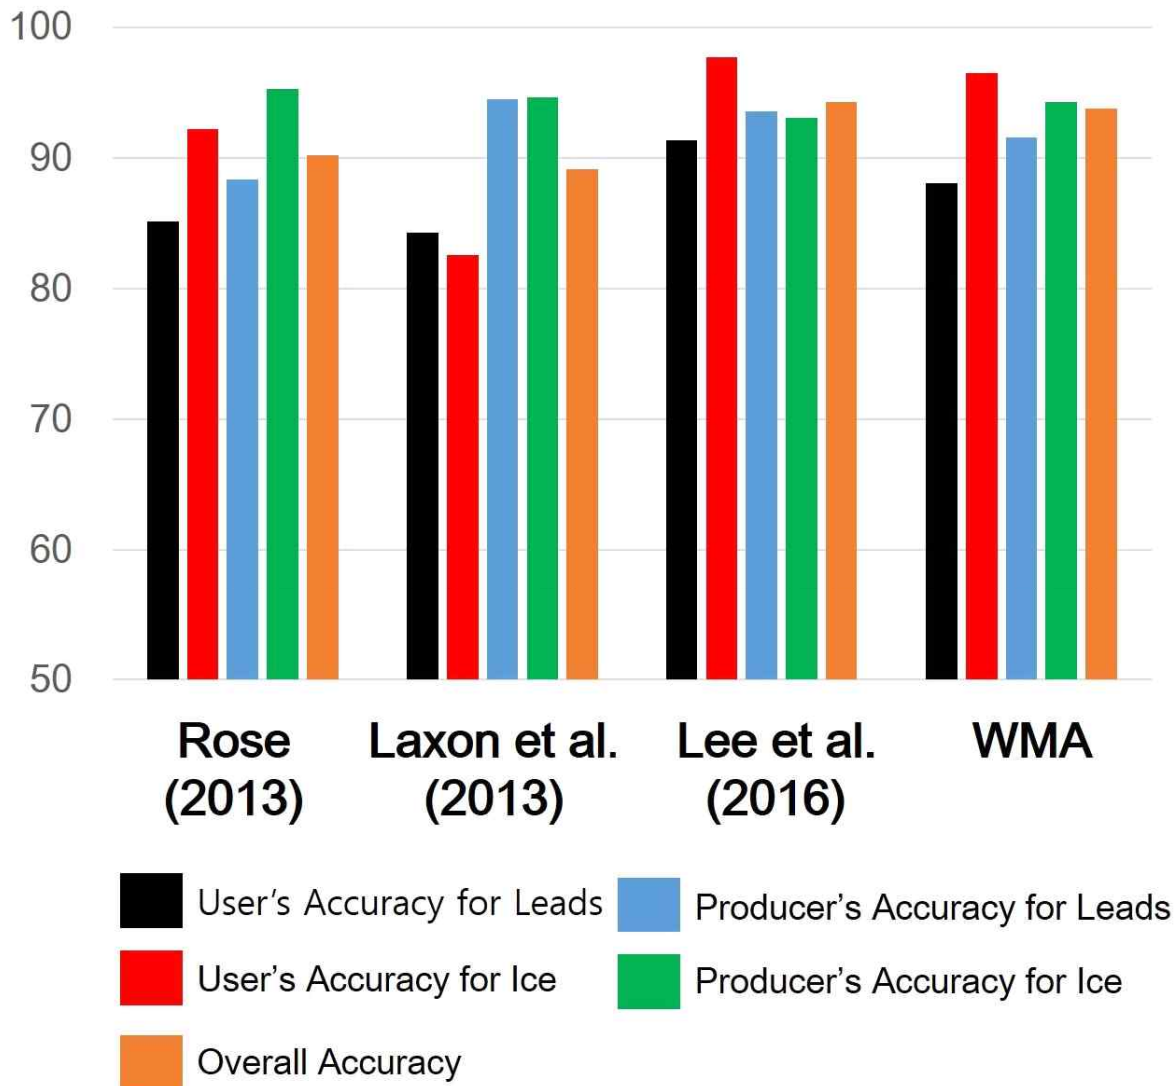


그림 3.1.4 리드 분류 결과: (a)-(d) Rose (2013)의 리드 분류 결과, (e)-(h) Laxon 등 (2013)의 리드 분류 결과, (i)-(l) Lee 등 (2016)의 리드 분류 결과, (m)-(p) waveform mixture algorithm의 리드 분류 결과.



*Unit: Percentage (%)

그림 3.15 리드 분류 결과의 정량적 비교.

나. 전 북극 월별 리드 비율 맵의 공간분포

2011-2016년 1-5월, 10-12월의 전 북극 월별 리드 비율 맵을 10km의 격자로 산출하였다. 적절한 격자크기를 결정하기 위해 다양한 크기의 격자들(10, 50, 100km)을 테스트 해보았으나, 격자 내의 리드와 해빙의 관측 개수와 같은 공간분포의 변동이 두드러지게 나타나지 않아, 보다 상세한 공간분포의 묘사가 가능 한 10km의 격자로 최종 산출하였다. 월별 리드 비율 맵에서 전반적으로 share zone과 해빙이 빠져나가는 해양 쪽에서 리드 비율이 높았다. 특히 봄철(3-5월) 버포트 해양 쪽에서 항상 높은 리드 비율이 나타난다. 10월부터 3월 까지 결빙 시즌으로 리드의 비율이 감소하고 4월 이후로는 해빙이 녹는 시즌으로 리드 비율이 증가한다. 리드 비율의 계절 변동성은 해빙 두께의 계절 변동성과 일치하는 경향을 보인다.

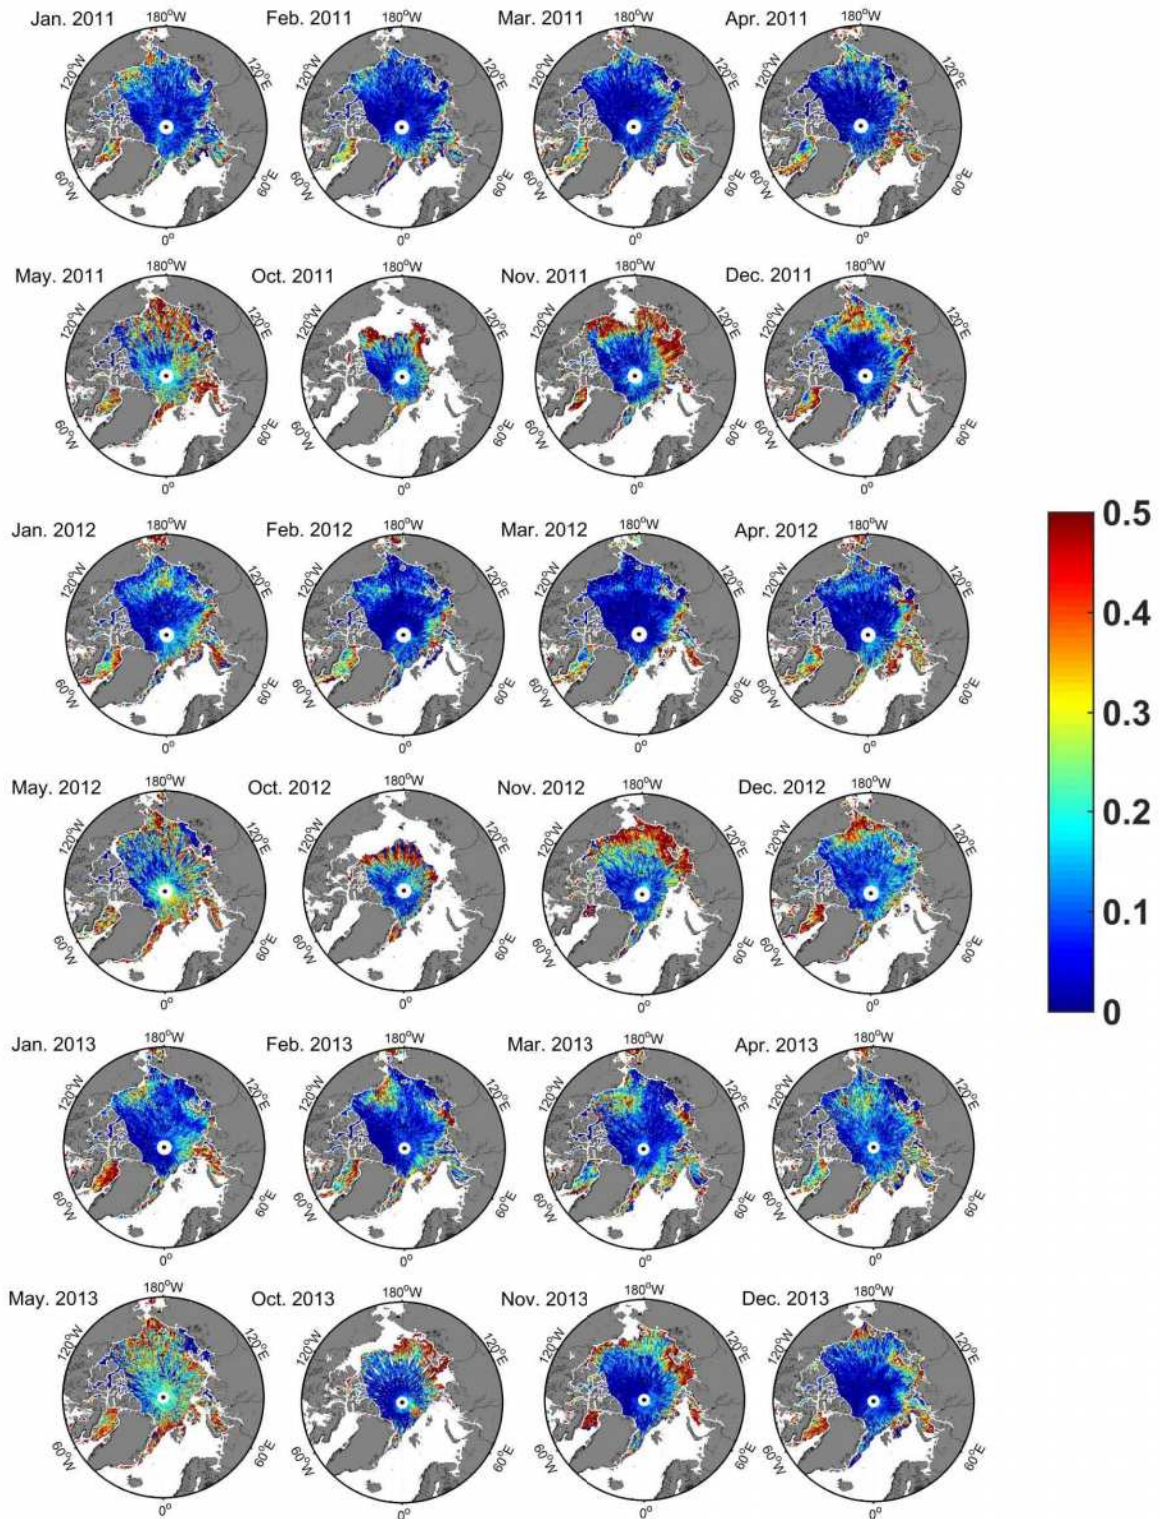


그림 3.1.6 2011-2013년 1-5월, 10-12월의 waveform mixture algorithm으로 산출된 전 북극 월별 리드 비율.

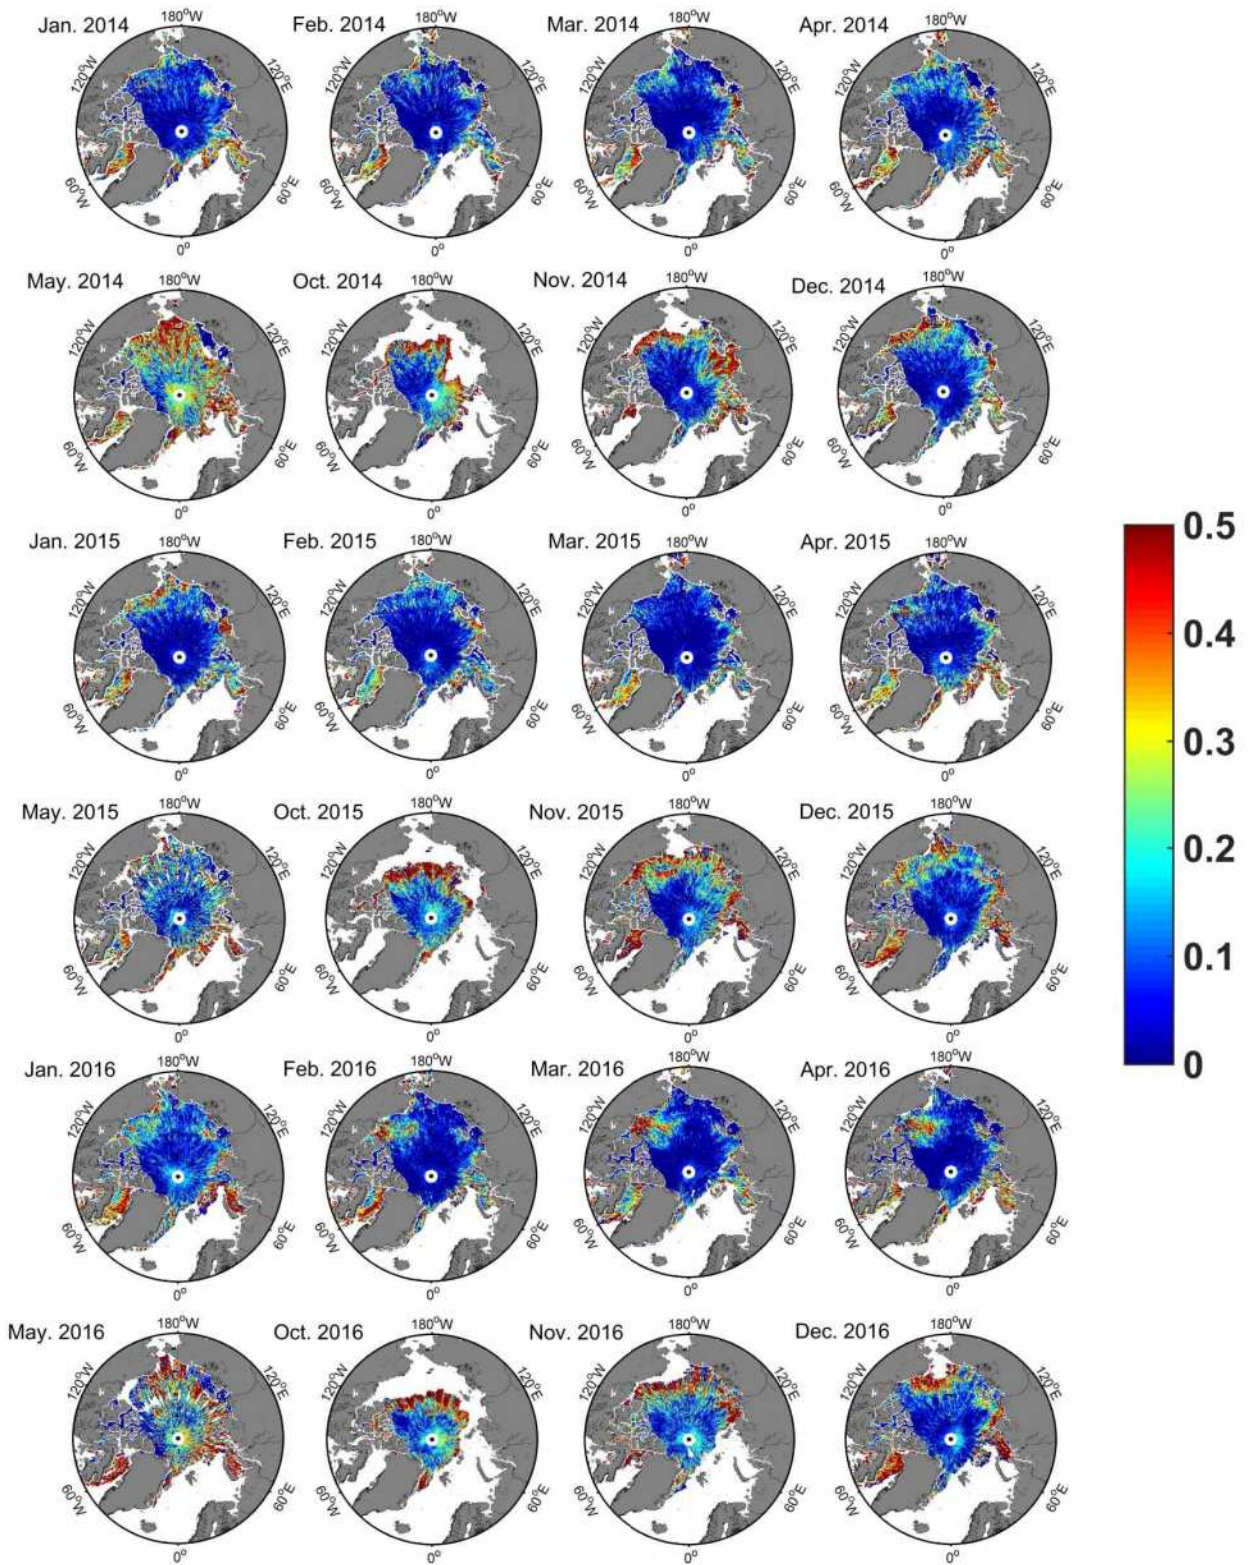
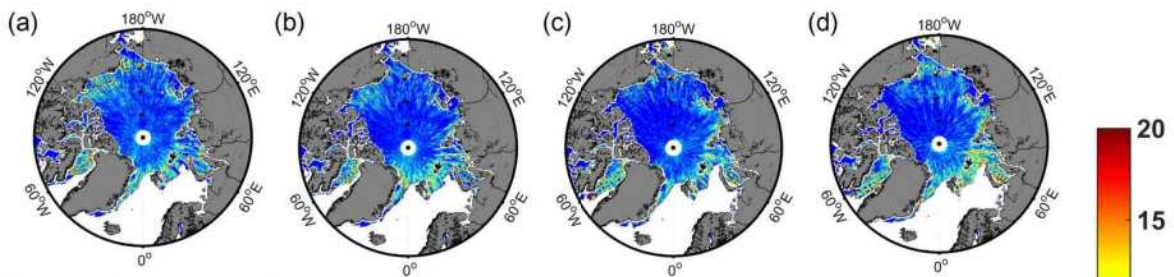


그림 3.1.7 2014-2016년 1-5월, 10-12월의 waveform mixture algorithm으로 산출된 전 북극 월별 리드 비율.

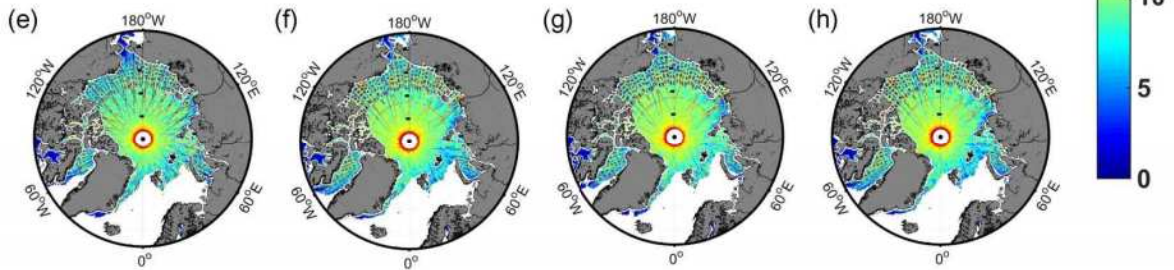
다. 10x10km 격자 민감도 분석 결과

CryoSat-2의 관측 개수는 극 방향으로 갈수록 많아지고 해안선 방향으로 갈수록 작아진다. CryoSat-2의 관측 개수가 작은 해안선 방향에서는 월별 리드 비율을 계산할 때 불확실성과 민감도가 커진다. 2011년 1-3월의 리드와 해빙의 관측 개수가 다음 그림에 나와 있다. 북극해 해안선 근처에서는 리드비율의 표준편차가 크고 북극해 중심 부분에서는 리드비율의 표준편차가 작게 나타난다. 동 시베리아해와 동 랩타프 해에서는 리드의 관측이 없었기 때문에 표준편차 또한 0으로 산출 되었다. 고도계로 계산한 월별 리드비율은 위와 같이 CryoSat-2의 개수에 따라 민감하게 반응한다.

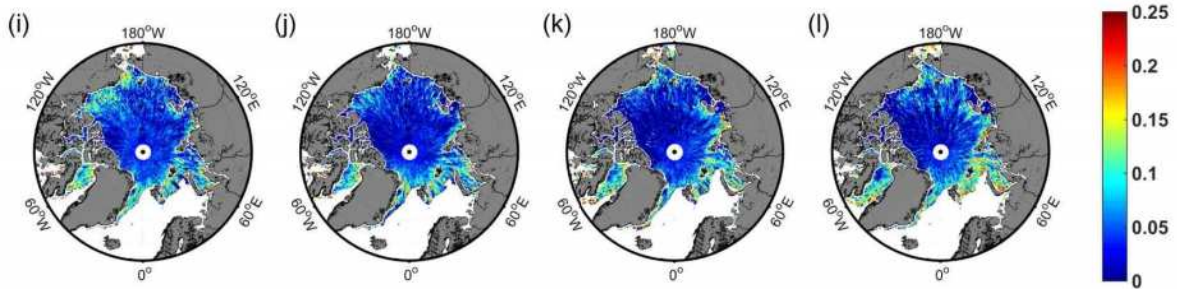
Number of lead observations



Number of ice observations



Standard deviation



January 2011

February 2011

March 2011

April 2011

그림 3.1.8 (a-d) 리드의 관측 개수, (e-h) 해빙의 관측 개수, (i-l) 표준편차, 민감도 분석 결과.

4. 토론

가. 리드 분류 결과의 비교

Waveform mixture algorithm의 리드 탐지 결과는 DT와 비슷하였기 때문에 SSHA(Sea Surface height Anomaly)를 산출할 때 사용 가능하다. 기존의 임계값 기반의 리드 탐지 방법은 baseline이 업데이트 될 때마다 임계값을 조정해야한다. CryoSat-2 baseline이 업데이트 되면 beam behavior 변수들과 후방산란계수가 바뀌기 때문이다. Waveform mixture algorithm은 CryoSat-2 L1b waveform을 직접 사용하기 때문에 baseline의 업데이트에 영향을 적게 받는다. 이것은 waveform mixture algorithm의 강점이 될 수 있다.

반면 waveform mixture algorithm을 재결빙된 리드에 적용할 때는 해빙으로 분류 할 수도 있다. 아래 그림 MODIS 영상의 어두운 부분(84.26°N, 43°W)을 보면 명확하게 리드 인 것을 알 수 있다. 재결빙된 리드는 FYI와 비슷한 경향이 있기 때문에 waveform mixture algorithm으로는 재결빙된 리드를 해빙으로 오분류할 수도 있다. SSHA를 반영하면 이러한 불확실성을 경감 될 수 있을 것으로 보인다.

나. 월별 리드 비율 맵의 비교

4가지 월별 리드 비율의 장단점이 비교 평가 되었다(Rohrs and Kaleschke, 2012; Wernecke and Kaleschke, 2015; Willmes and Heinemann, 2015). 기본적으로 장면 기반의 리드 맵(MODIS과 AMSR-E)과 고도계 기반의 리드 맵(CryoSat-2)으로 나뉘 볼 수 있고 각각 다른 특징을 가지고 있다. 장면 기반의 리드 맵은 지표의 다른 특징에 민감하고 리드의 선형적인 특징과 폴리냐를 잘 표현한다. AMSR-E 기반의 리드 맵은 3km이상의 큰 리드만을 탐지할 수 있다. 고도계 기반의 리드 맵은 2011년 1월 최저해에 높은 리드비율을 보이지만, 장면 기반의 리드 맵에는 같은 기간에 낮은 리드비율을 보인다. 이시기에 리드의 길고 선형적인 모형인 아니라 부서지거나 떨어져나간 해빙들이 많기 때문에 고도계 기반 알고리즘은 해빙 사이의 해양도 리드로 탐지하였지만 장면 기반 알고리즘은 리드라 판단하지 않아 리드비율이 낮았다. MODIS IST 기반의 리드 맵은 이 지역에 해빙과 해양의 온도가 혼합되어 온도가 낮게 나타남으로써 리드라 탐지하지 못하였고 AMSR-E는 footprint 내에 해빙의 시그널이 더 우세하여 리드로 탐지 못한 것으로 추정 된다.

고도계 기반의 리드 맵은 해안선 주변에는 CryoSat-2 개수가 작아 불확실성이 존재함에도 불구하고 전반적인 리드비율의 높고 낮음은 잘 표현하였다. Wernecke and Kaleschke (2015)의 리드 탐지 알고리즘은 리드의 false 분류를 줄이고자 하는 방향으로 개발되었기 때문에 waveform mixture algorithm에 비해 보수적으로 리드를 탐지했다. 그 결과 월별 리드 맵에서도 전반적으로 waveform mixture algorithm의 리드 비율이 Wernecke and Kaleschke (2015)보

다 높게 나타났다. Wernecke and Kaleschke (2015)는 waveform mixture algorithm 보다는 격자의 크기가 큰 99.5km 이다. 따라서 월별 리드 비율을 계산할 때 waveform mixture algorithm 보다는 불확실성이 작게 나타나는 경향이 있다.

월별 리드 비율 맵의 선택은 사용자의 관심사에 따라 다를 수 있다. 장면 기반의 리드 맵은 해안선 주변의 폴리나와 전형적으로 선형적인 리드의 분포를 잘 보이는 반면 CryoSat-2 기반의 리드 맵은 선형적인 리드의 특성은 잘 관측하지 못하지만 깨어지거나 부서진 해빙 사이의 틈을 잘 관측할 수 있는 장점이 있다.




그림 3.1.9 2011년 1-3월 리드 비율 맵의 비교. (a-c) Rohrs and Kaleschke (2011)의 AMSR-E 기반 리드 비율 맵, (d-h) Willmes and Heinemann (2015)의 MODIS 기반 리드 비율 맵, (g-i) Wernecke and Kaleschke (2015)의 CryoSat-2 기반 리드 비율 맵, (j-i) waveform mixture algorithm을 사용한 CryoSat-2 기반의 리드 비율 맵.

다. 리드 다이내믹스

북극 해빙의 다이내믹스는 바람, 위도, 해류에 의해 주로 좌우된다(Kwok and Untersteiner, 2011). 북극 해류 순환은 해빙 상태의 변화에 기여한다. 다음 그림에서 그린란드 북동쪽 부분은 북극의 주요 해류인 버포트 gyre와 Polar transport drift에 의해 항상 해빙이 수렴하기 때문에 리드 비율이 항상 낮다(Kwok 2015). Kwok 등 (2013)에서는 버포트 gyre와 polar transport

drift가 1982년부터 2009년까지 증가하면서 다년생 해빙의 비율을 낮게 만들었다고 분석 하였다. 하지만 2011-2016년, 6년 동안은 선형적인 리드 비율의 증가 보다는 연간 리드 비율의 변화가 큰 것으로 나타났다. 이를 증명하기 위해서는 좀 더 장기간의 리드 비율 자료가 필요하다.

리드 비율의 연간 변화는 대기의 이상 현상과 깊은 관련이 있다. 2013년과 2014년의 봄 사이에 버포트 해 주변 리드 비율이 감소하였는데 이것은 해빙 두께의 증가와 관련이 깊다(Tilling 등 2015; Lee 등, 2016). Tilling 등 (2015)는 2013년 여름에 상대적으로 차가운 대기가 있었기 때문에 해빙의 두께가 2014년 봄에 증가했다고 보고했다. 일반적으로 11월부터 3월까지의 해빙이 동결되는 시기이나 2016년 1월에는 오히려 리드 비율이 증가했다. Kim 등 (2017)과 Ricker 등 (2017)은 이 시기에 해빙의 성장이 느려진 이유를 규모가 큰 저기압이 대서양 북쪽에서 발생하면서 중위도에 있는 열과 습도를 북쪽으로 이동시켰기 때문이라고 설명하였다.




그림 3.1.10 봄(3-5월), 가을(10-11월), 겨울(12,1,2월)의 월별 리드비율의 평균.

5. 결론

본 연구에서는 waveform mixture algorithm가 CryoSat-2 L1b waveform에 적용되어 리드를 탐지하였다. 리드와 해빙의 waveform이 waveform mixture algorithm이 수행하는데 필수적인 endmember로 사용되었다. Endmember N-FINDR 알고리즘에 의해 수많은 후보

endmember waveform 중에서 선정되었다. 리드를 탐지하기 위한 임계값의 최적화는 250m 공간해상도의 MODIS 영상을 사용하여 수행되었다. Waveform mixture algorithm의 리드 탐지 결과는 DT의 리드탐지 결과와 성능이 비슷하였으며 기존의 리드 탐지 알고리즘 보다는 더 나은 성능을 보였다. 따라서 waveform mixture algorithm은 해빙 두께를 추정하는 알고리즘에도 충분히 사용될 수 있을 것으로 판단된다. 월별 리드 비율 맵을 통해 최근 해빙의 연간 변동이 심하다는 것을 보여주었다. 장면 기반의 리드맵과 고도계 기반의 리드맵은 기본적으로 다른 특성을 보여주었지만 전반적인 리드 비율의 분포는 비슷하였다. 리드 비율맵은 최근 연구결과와 일치하는 것을 보여주었다.

Waveform mixture algorithm은 기계학습을 포함한 기존의 임계값 기반의 리드 탐지 기법에 비해 CryoSat-2 baseline 업데이트에 영향을 적게 받는다. 향후 고도계 미션에도 waveform mixture algorithm을 적용하여 리드 탐지를 탐지할 수 있을 것으로 보인다.



제 2 절 북극 해빙농도 단기 예측 알고리즘 개발

연구 내용	연구 결과
해빙 농도에 영향을 미치는 대기 및 해양 변수 도출	최근 5년 동안 수행된 북극 해빙 농도 예측에 대한 선행 연구 및 문헌조사를 통하여 해빙 농도에 영향을 미치는 대기/해양 변수를 분석하여, 변수를 도출하였음
변수와 해빙농도의 상관관계 분석	각 변수와 해빙농도의 상관관계를 분석(Pearson's correlation analysis)하여 모델 구축을 위한 변수를 도출하였음
랜덤포레스트 기법을 활용한 변수별 상대적 중요도 파악	랜덤 포레스트 기법의 변수 중요도 분석을 통한 변수별 상대적 중요도를 비교하였음
기계학습 기법을 활용한 해빙농도 예측 모델 개발	기계학습 기법 중 하나인 랜덤 포레스트 기법을 활용한 6~9월의 one-month 해빙농도 예측 모델 개발
딥러닝 기법을 활용한 해빙농도 예측 모델 개발	딥러닝 기법 중 하나인 CNN 기법을 활용한 6~9월의 one-month 해빙농도 예측 모델 개발
기계학습 기반 모델 및 딥러닝 기반 모델의 비교 및 분석	개발한 두 모델의 예측결과 비교 및 분석을 통한 최종 예측 모델 제안

1. 해빙 농도에 영향을 미치는 대기 및 해양 변수 도출

가. 국내·외 해빙 농도 예측 선행 연구

본 연구는 최근 5년 동안 수행된 북극 해빙 농도 예측에 대한 선행연구 및 문헌조사를 통하여 해빙 농도에 영향을 미치는 대기/해양 변수를 분석하였고(표 1), 각 변수와 해빙농도의 상관관계를 분석(Pearson's correlation analysis)하여 모델 구축을 위한 변수를 도출하였다.

기존 해빙 관련 parameter의 예측 연구는 주로 수치모델링과 통계기법에 의거한 연구가 주로 이루어지고 있는 것으로 나타났다 (Guemas et al., 2014; Chi and Kim, 2017). 또한, 대부분의 통계기법 기반의 선행연구는 해빙과 해양 및 기후적 요소와의 관계를 규명하는 방향으로 진행되어 왔다 (Guemas et al., 2014). Wang et al. (2016)은 vector autoregressive (VAR) 기법을 활용하여 여름(5-9월) 해빙농도의 interseasonal variability를 규명하였다. VAR 기법은 해양 및 대기 분야의 변수를 활용하지 않고 과거의 해빙 관측자료만을 활용하여 예측하는 모델이며, 30일 예측 기준 약 17%의 RMSE의 예측성을 보였다. Yuan et al. (2016)은 Linear Markov model 기법을 활용하여 중·장기 북극 해빙 농도 예측 모델을 개발하였음. 해빙농도(SIC), 기상 관련 재분석자료(SAT, 300-hPa height, and u and v at the 300-hPa level) 및 SST를 활용하여 북극 해빙 농도 변화와의 관계를 분석하였으며, 최종적으로 SIC, SAT, SST와 11개의 MEOF modes 변수를 이용하여 1-12개월 예측 모델을 개발하였다. Chi and Kim (2017)은 시계열 분석(time series analysis)에

널리 활용되는 딥러닝 기법 중 하나인 LSTM (long and short-term memory) 기법을 활용하여 단기/장기 해빙 농도 예측 모델을 개발하였음. SIC만을 활용하여 미래 SIC를 예측하는 모델을 개발하였으며, melting season에 대한 예측정확도가 상대적으로 낮은 것으로 나타났다. Comeau et al. (2018)은 KAF (kernel analog forecasting) 기법을 활용하여 지난 800년간의 해빙의 area and volume anomalies를 분석하고 단기/장기 해빙 농도 anomaly 예측 모델을 개발하였다. SIC, SST 및 SLP 변수를 활용하였으며, 다양한 kernel로부터 얻어진 weights를 앙상블하는 KAF 기법을 활용하여 보다 정교한 모델을 제안하며, 12개의 지역에 대한 분석을 수행하였다.

표 3.2.1 해빙 농도 추정과 관련된 최근 연구 동향

study	method	variables	temporal/spatial resolution	results
Wang et al. (2016)	vector autoregressive (VAR) model	target: SIC estimators: past SIC	daily (1979-2012), 225km x 225km	RMSE of 30-days SIC prediction = 17%
Yuan et al. (2016)	Linear Markov model	target: SIC estimators: SIC, SST, SAT, and 11 MEOF modes	monthly (1979-2012), 2° x 0.5°	RMSE of 2-months SIE prediction = 0.41
Chi and Kim (2017)	LSTM (long and short term memory)	target: SIC estimator: SIC only	monthly (1978-2015), 25km x 25km	average RMSE of monthly prediction = 8.89%
Comeau et al. (2018)	KAF (kernel analog forecasting)	target: SIC anomalies estimators: SIC, SST, and SLP	monthly (800 years), no mention regarding spatial resolution	NRMSE of one-month SIC anomaly prediction = over 0.5

나. 변수와 해빙농도의 상관관계 분석

선행연구 및 문헌조사를 통해 도출한 북극 해빙 농도에 영향을 줄 것으로 기대되는 대기/해양 변수 9종을 선정하여, 2002-2017년 melting season(6-9월)에 대하여 한 달 뒤 해빙 농도와 상관성을 분석하였다 (Pearson's correlation analysis). 9개의 변수는 각각 sea ice concentration (SIC), forecast albedo (FAL), 2-meter temperature (T2m), sea surface temperature (SST), mean sea level pressure (MSL), 10-meter u and v wind vector (u10 and v10), total cloud cover (TCC), ice surface temperature (IST) 으로 선정하였다.

변수들의 상관성 분석 결과, 그림과 같이 SIC, FAL, SST, u10, IST는 다음 달의 북극 해빙 농도와 양의 상관관계를 가지는 반면, T2m, v10, TCC는 음의 상관관계를 가지는 것으로 나타났다. 또한, MSL의 경우, melting season이 진행됨에 따라 양의 상관관계에서 음의상관관계로 변화하는 양상을 보였다. 본 연구에서는 평균 절대 상관계수가 상대적으로 낮은 TCC 및 상관관계가 시간에 따라 변하는 MSL 변수를 제외한 나머지 7개의 대기/해양 변수를 활용하여 one-month prediction 모델을 구축하였다.

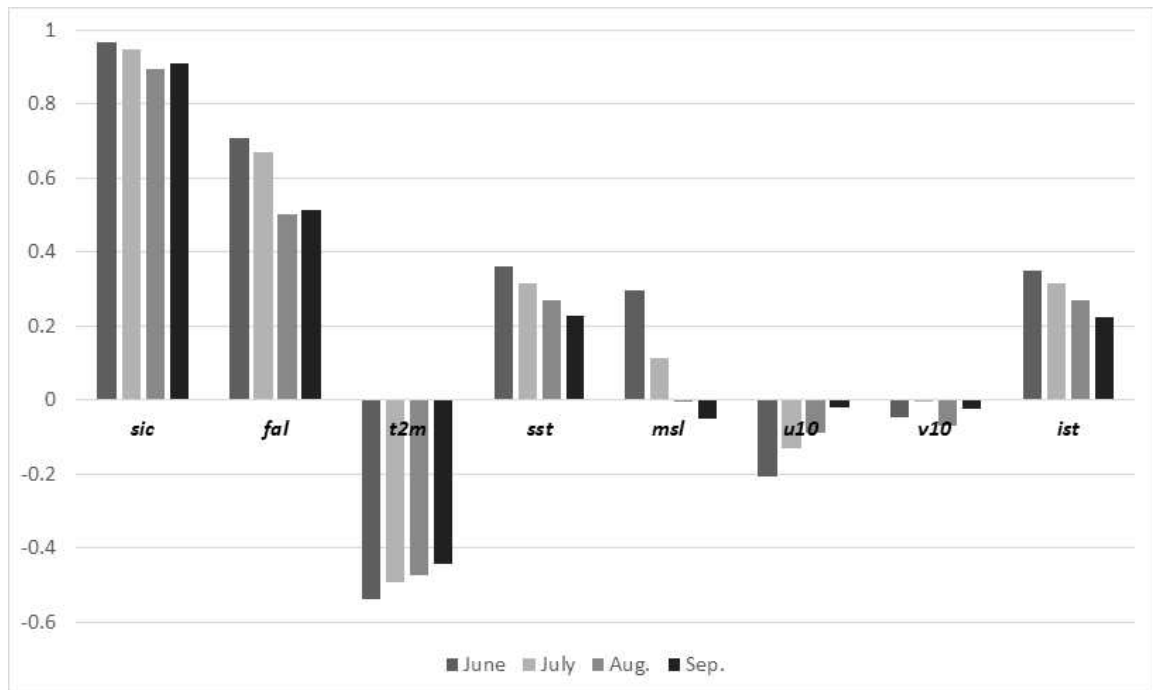


그림 3.2.1 Pearson's correlation coefficient between SIC and one-month past variables on melting season (June - Sep.) during 2002-2017

다. 랜덤포레스트 기법을 활용한 변수별 상대적 중요도 파악

RF 모델의 MSE(mean squared error) 기반의 변수 중요도(variable importance) 분석 결과, 한 달 전의 SST와 v10이 다음 달의 해빙 농도를 예측하는 데에 상대적으로 중요한 역할을 하는 것으로 나타났고, 그 뒤로 SIC, u10, FAL, T2m, IST 순으로 나타났으며, FAL, T2m, IST는 큰 차이 없이 비슷한 상대적 중요도를 갖는 것으로 나타났다. 본 연구에서는 u10 및 v10 중에서 상대적으로 중요하게 나타난 v10과 T2m 및 IST 중에서 상대적으로 중요하게 나타난 T2m의 변수를 활용하였다. 따라서 최종적으로 다음과 같이 총 8종의 변수를 선정하였다: SIC one-year before (sic_1y), SIC one-month before (sic_1m), SIC anomaly one-year before (ano_1y), SIC anomaly one-month before (ano_1m), sea surface temperature (SST), 2-meter air temperature (T2m), forecast albedo (FAL), and the amount of v-wind (v-wind).




그림 3.2.2 relative variable importance based on MSE using Random Forests

2. 모델 자료와 다중위성자료의 융합과 다양한 통계기법 및 기계학습을 이용한 해빙 농도 예측모델 개발

가. 데이터 구축 및 전처리

앞서 도출한 해빙 농도에 영향을 미치는 8종의 해빙 및 대기·해양 변수를 기계학습 및 딥러닝 기법을 활용하여 해빙의 one-month prediction 모델을 개발하였다. 훈련자료는 1988년부터 2017년 30년 사이의 월별 데이터를 활용하였으며, 월 해빙 농도 예측 결과를 비교하여 정확도를 검증하였다. 현재 월평균 자료로부터 다음 달 해빙 농도를 추정하는 one-month prediction 모델을 구축하였으며, 12개월 각각에 대한 총 12개의 월별 예측 모델을 개발하였다. hindcast 기법을 활용하여 훈련/검증 하였다. 예를 들어, 2000년의 월별 예측모델을 훈련하기 위하여 1988-1999년의 자료가 활용되며, 2017년을 위해서는 1988-2016년의 자료가 활용되었다. 대기/해양 변수는 해빙 농도변수를 포함하여 총 8가지의 변수를 활용하였으며(표 2), 월평균(monthly mean)하여 25km 극지 스테레오투영(Polar stereographic projection) 변환을 통해 모델을 구축하였다. 마지막으로, 단순 anomaly persistence forecast 모델을 baseline 모델로 비교하였는데, 이는 단순 연간 선형모델에 대하여 anomaly 예측 결과를 더해주는 모델로 구축하였다.

표 3.2.2 variables descriptions for SIC prediction model

variable	source	temporal resolution	spatial resolution
SIC one-year before (sic_1y)	NSIDC	Daily	25km
SIC one-month before (sic_1m)	NSIDC	Daily	25km
SIC anomaly one-year before (ano_1y)	NSIDC	Daily	25km
SIC anomaly one-month before (ano_1m)	NSIDC	Daily	25km
Sea surface temperature one-month before (SST)	NOAA OISST ver.2	Daily	0.25°
2-meter air temperature one-month before (T2m)	ECMWF ERA Interim	Monthly	0.125°
forecast albedo one-month before (FAL)	ECMWF ERA Interim	Monthly	0.125°
the amount of v-wind one-month before (v-wind)	ECMWF ERA Interim	Monthly	0.125°

나. 기계학습 및 딥러닝 기법을 활용한 해빙농도 예측 모델 개발

기계학습 기법으로는 회귀분석에 자주 사용되는 앙상블 기법중 하나인 랜덤포레스트(Random Forests) 기법을 사용하였으며, 딥러닝 기법으로는 변수들의 공간적인 패턴을 고려하는 인공 신경망 기법중 하나인 CNN(Convolutional Neural Networks) 기법을 사용하였다. 또한, 랜덤포레스트 모델은 Matlab R2018의 TreeBagger 함수를 사용하였으며, 트리의 수는 50개로 지정하였다. CNN 모델은 Python 3.6의 텐서플로(tensorflow)에서 지원하는 Keras conv2d 모듈을 활용하였으며, 총 3개의 convolutional layers, 2개의 max pooling layers, 1층의 fully connected layer로 구성된 CNN 모델을 구축하였다. batch size는 1024, epoch은 100, window size는 11x11로 구성하였으며, ReLU 활성화 함수와 Adam 최적화 함수를 적용하였다.

정량적인 비교를 위하여 본 연구에서는 다음과 같이 총 다섯 종류의 통계기법을 활용하였다. mean absolute error (MAE, 수식 3.2.1), anomaly correlation coefficient (ACC, 수식 3.2.2), root mean square error (RMSE, 수식 3.2.3), normalized root mean square error (nRMSE, 수식 3.2.4), and Nash-Sutcliffe efficiency (NSE, 수식 3.2.5)

$$MAE = \text{mean}(|\text{predictedSIC} - \text{actualSIC}|)$$

수식 3.2.1 MAE equation

$$ACC = \frac{(\text{mean}(\sum(\text{predictedSIC} - (\text{predictedSIC})))(\text{actualSIC} - (\text{actualSIC})))}{(\sqrt{(\text{mean}(\sum(\text{predictedSIC} - \text{predictedSIC})^2)}\sqrt{(\text{mean}(\sum(\text{actualSIC} - \text{actualSIC})^2)})}$$

수식 3.2.2 ACC equation

$$RMSE = \sqrt{\text{mean}(\text{predictedSIC} - \text{actualSIC})^2}$$

수식 3.2.3 RMSE equation

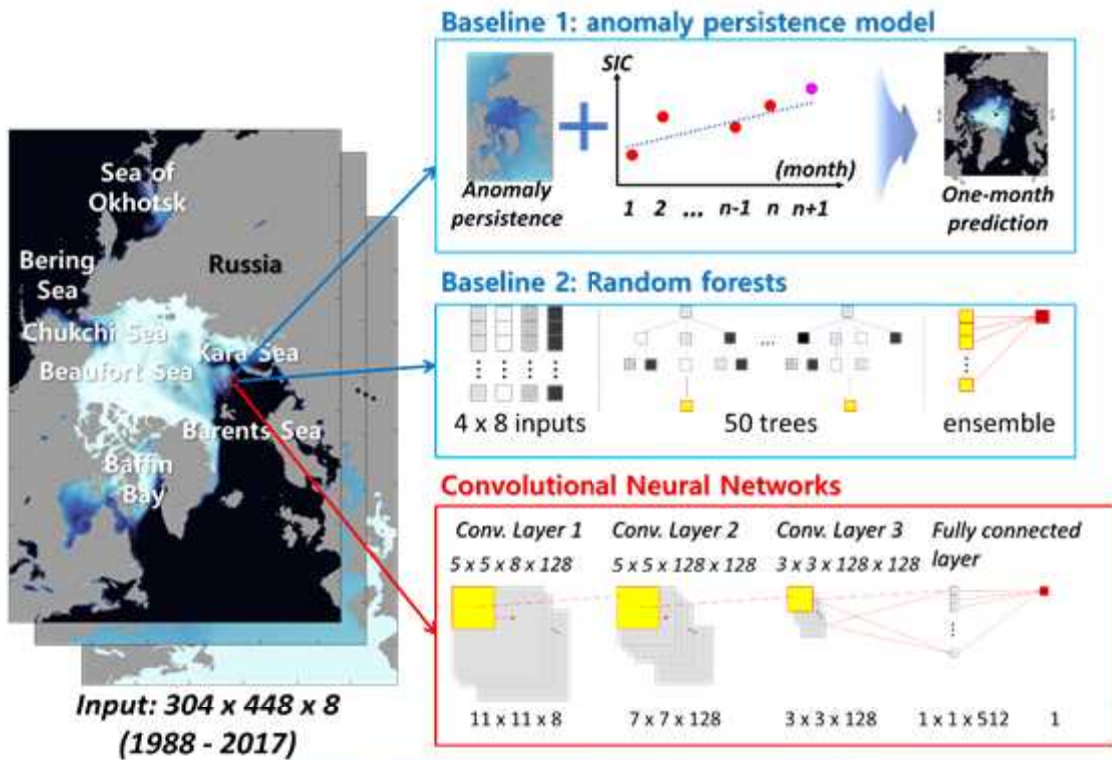
$$nRMSE = RMSE / \text{std}(\text{actualSIC})$$

수식 3.2.4 nRMSE equation


$$NSE = 1 - (\sum(\text{actualSIC} - \text{predictedSIC})^2) / (\sum(\text{actualSIC} - \text{mean}(\text{actualSIC}))^2)$$

수식 3.2.5 NSE equation






Prediction accuracy
Comparison of prediction accuracy and spatio-temporal analysis



Variable sensitivity
Examination of variable sensitivity of both models



Extreme cases
Analysis of extreme cases: September 2007 and 2012



Prediction accuracy and detailed comparison

그림 3.2.3 해빙 농도 예측 연구 흐름도

3. 기계학습 기반 모델 및 딥러닝 기반 모델의 비교 및 분석

1988-2017 평균 예측 오차의 경우, baseline으로 활용된 anomaly persistence model이 평균 예측 RMSE가 10.54로 나타났고, RF 기반 모델이 6.61%, CNN기반 모델의 경우, 5.76%로 나타나 CNN 기반의 모델이 예측력이 더 뛰어난 것으로 나타났다. 이 외 MAE, ACC, nRMSE, NSE등의 모든 지표에 대하여 CNN 기법을 활용한 모델이 가장 뛰어난 예측력을 보였다. 또한, 낮은 해빙농도 구간 (0-40%)의 예측력 또한 CNN 기반의 모델이 가장 높은 예측력을 보여주

어, 북극 중심부분 뿐만 아니라 극 가장자리 부분에 대한 모의력도 상대적으로 좋은 성능을 보이는 것으로 나타났다.

표 3.2.3 해빙 농도 예측 모델 간 성능 비교

		MAE	ACC	RMSE	nRMSE	NSE
All range of SICs (0-100%)	Persistence	4.31%	0.95	10.54%	29.17%	0.89
	RF	2.45%	0.98	6.61%	18.64%	0.96
	CNN	2.28%	0.98	5.76%	16.15%	0.97
Low SICs (0-40%)	Persistence	2.94%	0.54	8.94%	24.62%	0.81
	RF	2.38%	0.96	7.23%	19.87%	0.90
	CNN	2.13%	0.96	6.18%	16.87%	0.93

단순 통계수치 뿐만이 아니라, 지도를 활용하여 공간적으로 이 오차들이 어떻게 분포하는지에 대한 분석을 수행하였다. 그 결과, 공간적인 오차 또한 anomaly persistence prediction model과 RF모델에 비하여 CNN모델이 가장 낮은 오차를 보이고 있으며, melting / freezing season과 관계 없이 해빙 가장자리 영역에 대한 예측력이 좋은 것으로 나타났다. 특히, Kara Sea부터 Barents Sea 까지의 영역에서 꾸준한 해빙의 감소가 보이고 있는데, 이는 따뜻하고 염도가 높은 해수가 꾸준히 유입되기 때문인 것으로 판단된다 (Schauer et al., 2002; Årthun et al., 2012; Kim et al., 2018).

극지연구소

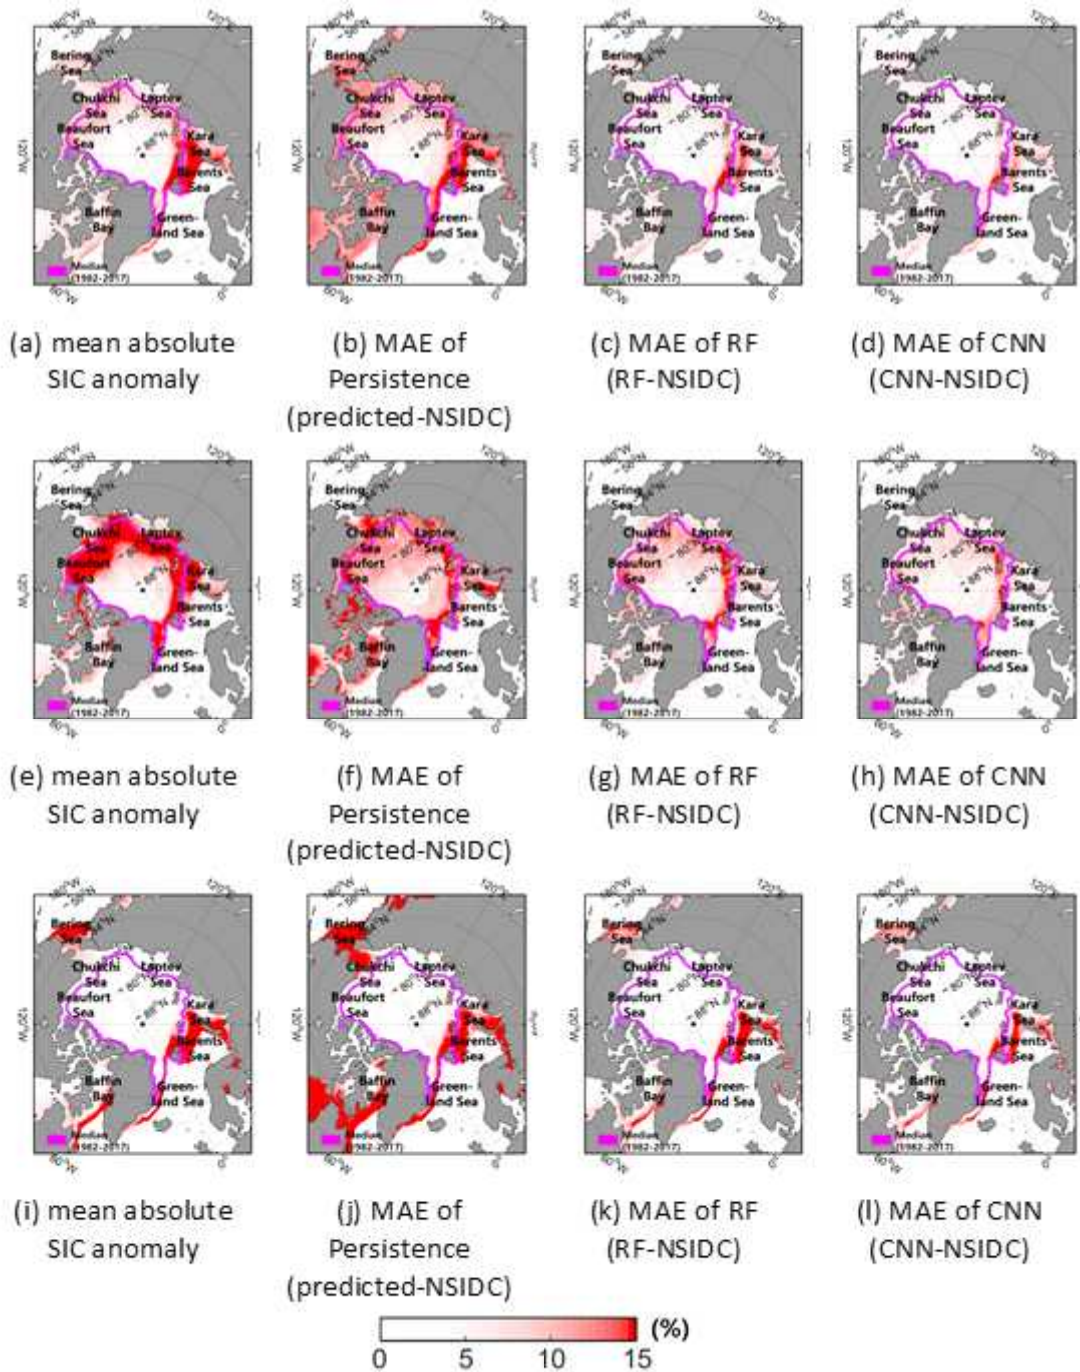


그림 3.2.4 comparison among mean absolute SIC anomaly and MAE for persistence, RF, and CNN models in annual (a-d); melting (e-f); and freezing season (i-l)

다음 그림은 2000-2017 년의 melting season (6월 - 9월)에 대한 서로 다른 세가지 예측 모델의 예측 결과 및 NSIDC SIC의 분포를 보여준다. anomaly persistence prediction model은 모든 범위의 SIC에 대해서 낮은 예측력을 보여주었다. 또한 이 모델은 melting season에 SIC가 높을수록 과대평가하는 경향을 보였다. 이는 지구 온난화로 인한 해빙의 추세를 잘 파악하

지 못하는 것으로 판단된다. 반면, RF 및 CNN 모델은 경계 SIC 값 (10 % 미만 및 90 % 초과 SIC)에 대해 비교적 약한 예측력을 보여주었다. 특히 RF 모델은 SIC를 거의 0과 100 %로 예측하는 데 취약성을 보였다. 낮은 SIC (5 % 미만)의 경우 두 모델 모두 과대평가 하는 경향이 보였다. 전반적으로 CNN 모델이 RF보다 더 나은 예측 결과를 보여 주는 것으로 나타났다 (CNN : 평균 오류 4.84 % 및 표준 편차 7.65 %; RF : 평균 오류 5.92 % 및 표준 편차 9.77 %). 반면 SIC가 높은 경우 (95 % 이상) 두 모델 모두 과소평가 하는 경향이 보였다. RF 모델은 오류 -4.62%와 표준 편차 4.57%를 보여 주었고, CNN은 각각 -4.17 %와 4.14 %를 나타내어 상대적으로 나은 예측력을 보여주었다. 결과적으로 동일한 훈련 샘플을 통해 CNN이 더 낮거나 높은 해빙 농도에 대한 예측력이 높은 것으로 나타났으며, 이는 RF보다 CNN의 학습 능력이 크기 때문일 수 있을 것으로 판단된다 (Wang et al., 2017).

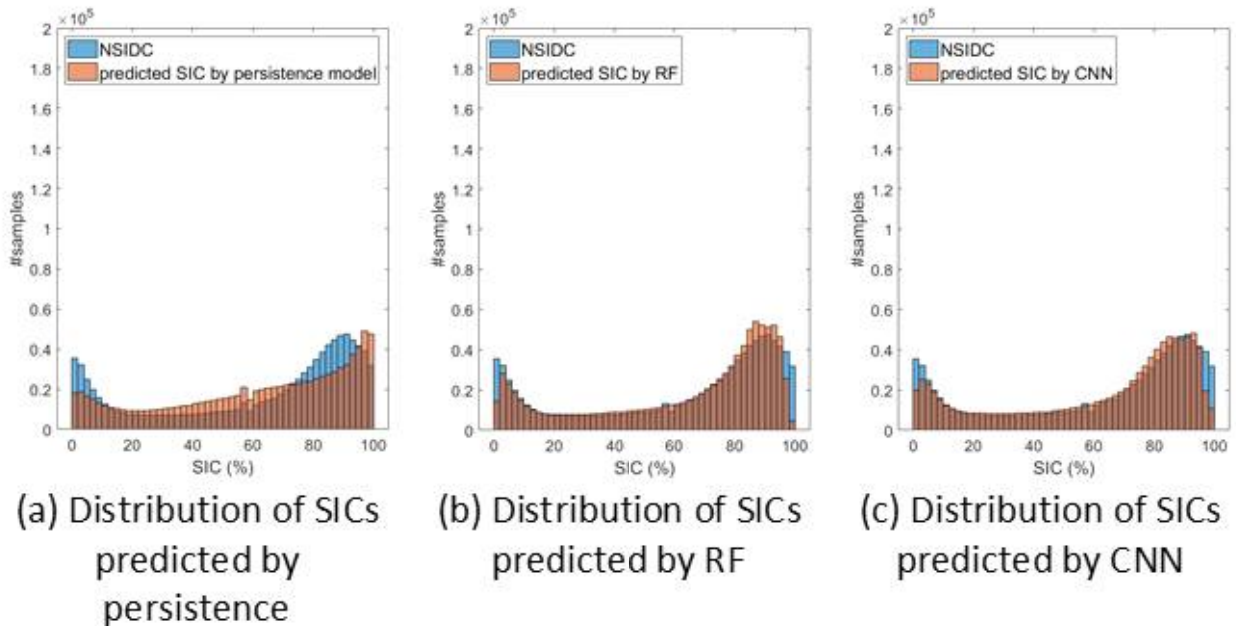


그림 3.2.5 histograms of SICs based on NSIDC (blue) and three prediction models (red) in melting season

다음 그림은 2000-2017년 평균 RF 및 CNN 모델에 대한 월별 예측 정확도 (RMSE 및 nRMSE)를 나타낸다. RF 모델은 모든 기간에서 CNN 모델보다 낮은 예측 정확도를 보였다. CNN 모델의 예측 정확도는 freezing season (12월 - 3월; 6.13%)보다 melting season (6월 - 9월; 5.41%)에서 더 높게 나타났다. 그러나 RMSE는 데이터의 범위에 의한 영향이 크기 때문에, 해석에 주의가 필요하다. 예를 들면, RMSE가 전반적으로 melting season에 낮게 나타났다 (Chi and Kim, 2017). 이에 본 연구에서는 nRMSE도 함께 비교하였는데, 비교 결과 nRMSE는 RMSE와 반대의 패턴을 보여주었다. 표준 편차를 사용하여 정규화 된 RMSE는 월

별 SIC의 상이한 분포를 고려하여 예측 정확도를 표시 할 수 있기 때문이다. CNN 모델의 nRMSE 분석 결과, melting season (6월 - 9월; 19.09%)과 freezing season (12월 - 3월; 14.08%)에서 RMSE를 활용한 분석과 반대되는 패턴이 관측되었다. 이는 최근 수년간 북극 해빙의 예상치 못한 감소로 인하여 melting season의 SIC 예측이 어려워짐을 뜻한다 (Stroeve et al., 2007; Chi and Kim, 2017).

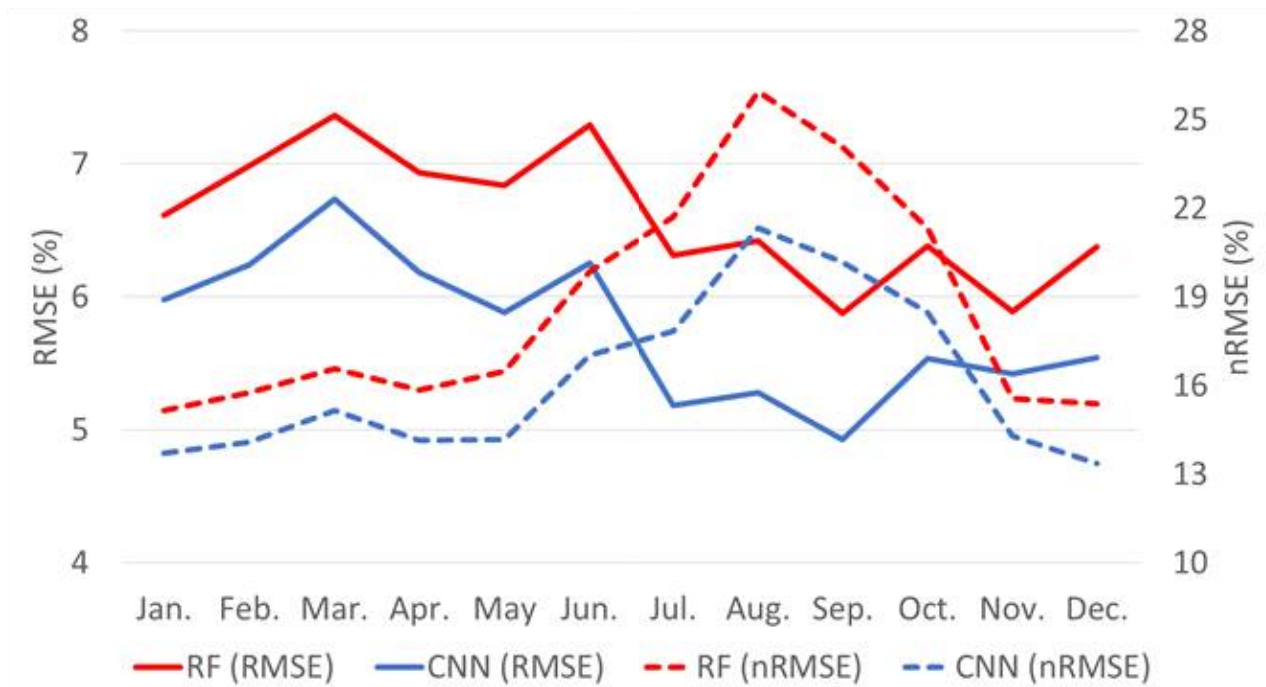


그림 3.2.6 monthly prediction accuracies between RF and CNN models

앞의 분석 결과의 연장으로, CNN 모델의 예측 정확도의 연간 트렌드를 분석하였다. 이는 freezing season (12월 - 3월; nRMSE 14.08%) 및 melting season (6월 - 9월; nRMSE 19.09%)에 대하여 반대되는 추세가 나타났는데, melting season의 nRMSE는 최근 몇 년 동안 (2000-2017) 증가 추세를 보였다. 따뜻한 대기 온도 (Hassol, 2004; Zhang et al., 2007), 얇은 해빙 (Maslanik et al., 2007), 높은 해수면 온도 (Steele et al., 2008)를 포함한 북극 환경의 변화가 최근 기후변화와 더불어 심화되었기 때문에, melting season에 대한 해빙 농도 변화 예측을 더욱 어렵게 만든 것으로 판단된다. 예를 들어, 북극 해빙 범위는 예상치 못한 따뜻한 대기 환경, 일사량의 변화, 여름철 대형 사이클론의 발생과 같은 다양한 원인으로 인해 북극 해빙은 2007년 여름과 2012년 여름에 걸쳐 두 번의 최소 면적을 보인 적이 있다 (Kauker et al., 2009; Kay et al., 2008; Parkinson and Comiso, 2012; Zhang et al., 2013).

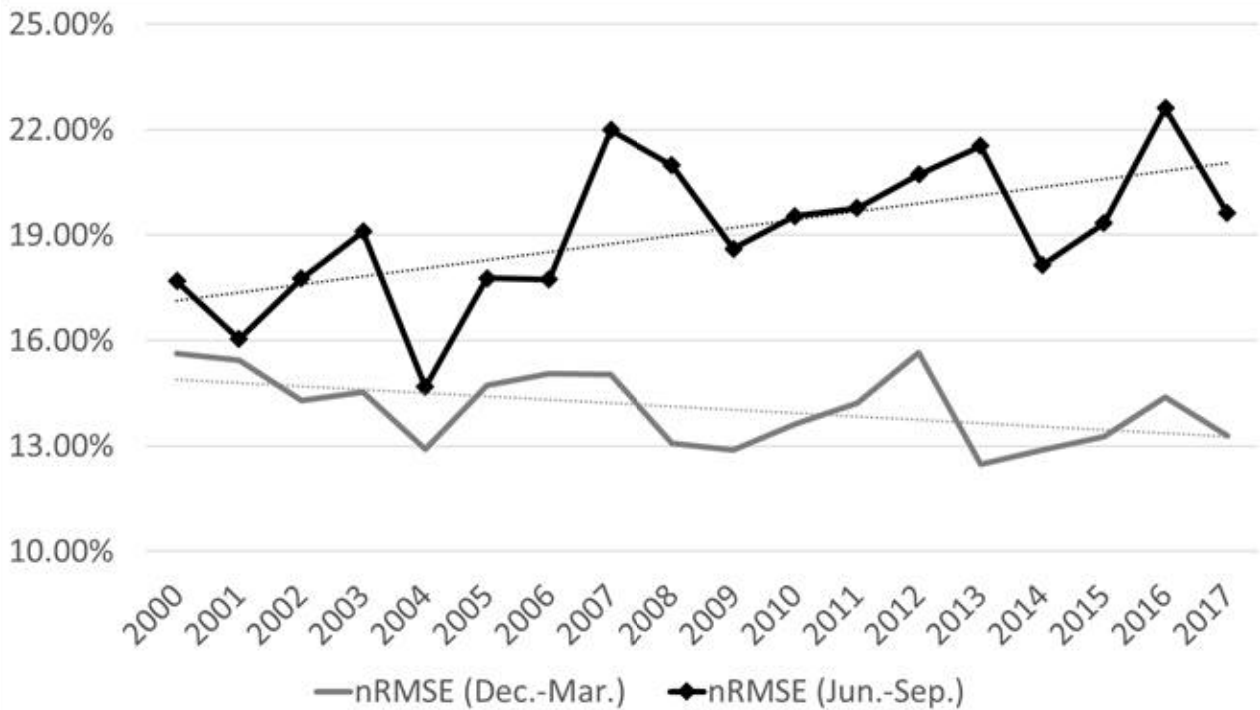


그림 3.2.7 annual changes of prediction accuracy of CNN model

본 연구는 또한 해빙 면적이 최소가 되었던 이상 현상에 대한 모의력을 비교하기 위하여, 2007년 및 2012년 9월의 RF 및 CNN 모델에 의해 예측된 SIC 및 실제 SIC 예측 결과를 비교하였다. 해빙 면적에서 예측치 못한 감소가 있었음에도 불구하고 CNN 모델은 2007년 9월과 2012년에 상대적으로 좋은 예측 결과를 보여주었다 (RMSE 5.00% 및 4.71%, nRMSE 21.93% 및 23.95%).

2007년 9월의 경우, 여름 동안 보퍼트 해 - 척치 해 - 랩테브 해를 통해 큰 해빙의 감소가 발생했다. RF와 CNN 모델 모두 척치 해와 랩테브 해에서 SIC의 과대 추정치를 보여 주었다. 이는 두 모델이 훈련을 통해 해당 지역의 해빙의 급격한 속도를 효과적으로 학습할 수 없었음을 보여준다. 이와 유사하게, 2012년 9월의 RF 및 CNN 모델을 기반으로 한 예측 모델 또한 예측의 한계가 나타났다. 2012년 여름에는 보퍼트 해 - 랩테브 해 - 카라 해에서 해빙이 크게 감소한 것을 확인할 수 있으며, RF 및 CNN 모델 모두 베런츠 해와 카라 해 사이의 지역에서 SIC의 과대 추정을 보였다. 이는 여름철 대서양에서 따뜻한 해수가 유입되어 해당 지역의 해빙이 빠르게 감소했기 때문일 수 있으며 (Schauer et al., 2002; Årthun et al., 2012; Kim et al., 2018), 두 모델 모두 예측 오류가 주로 SIC 이상이 높은 지역 (즉, 훈련 표본 크기가 작은 한계 얼음 영역)에서 발견되었다는 점을 미루어 보아, 훈련자료의 불균형에 의한 예측모형의 한계인 것으로 판단된다. 그럼에도 불구하고, RF기반의 모델보다 CNN 기반의 모델이 정량적 및 공간적으로 잘 모의하는 것으로 나타났다.

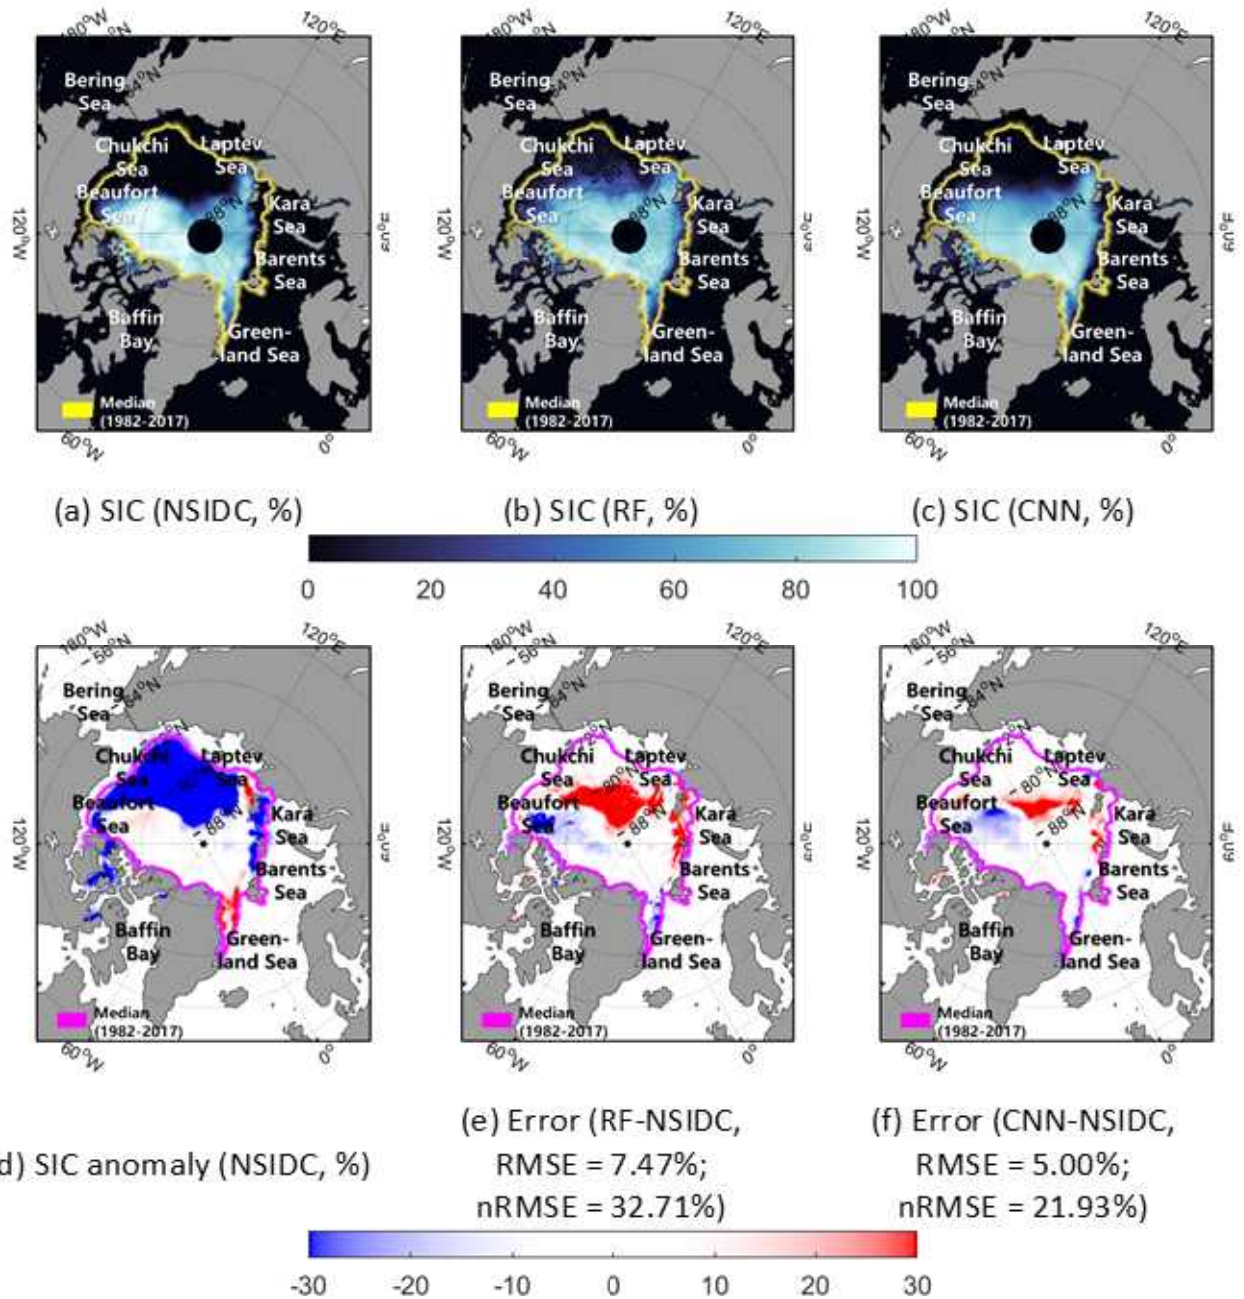


그림 3.2.8 SICs prediction results in September 2007

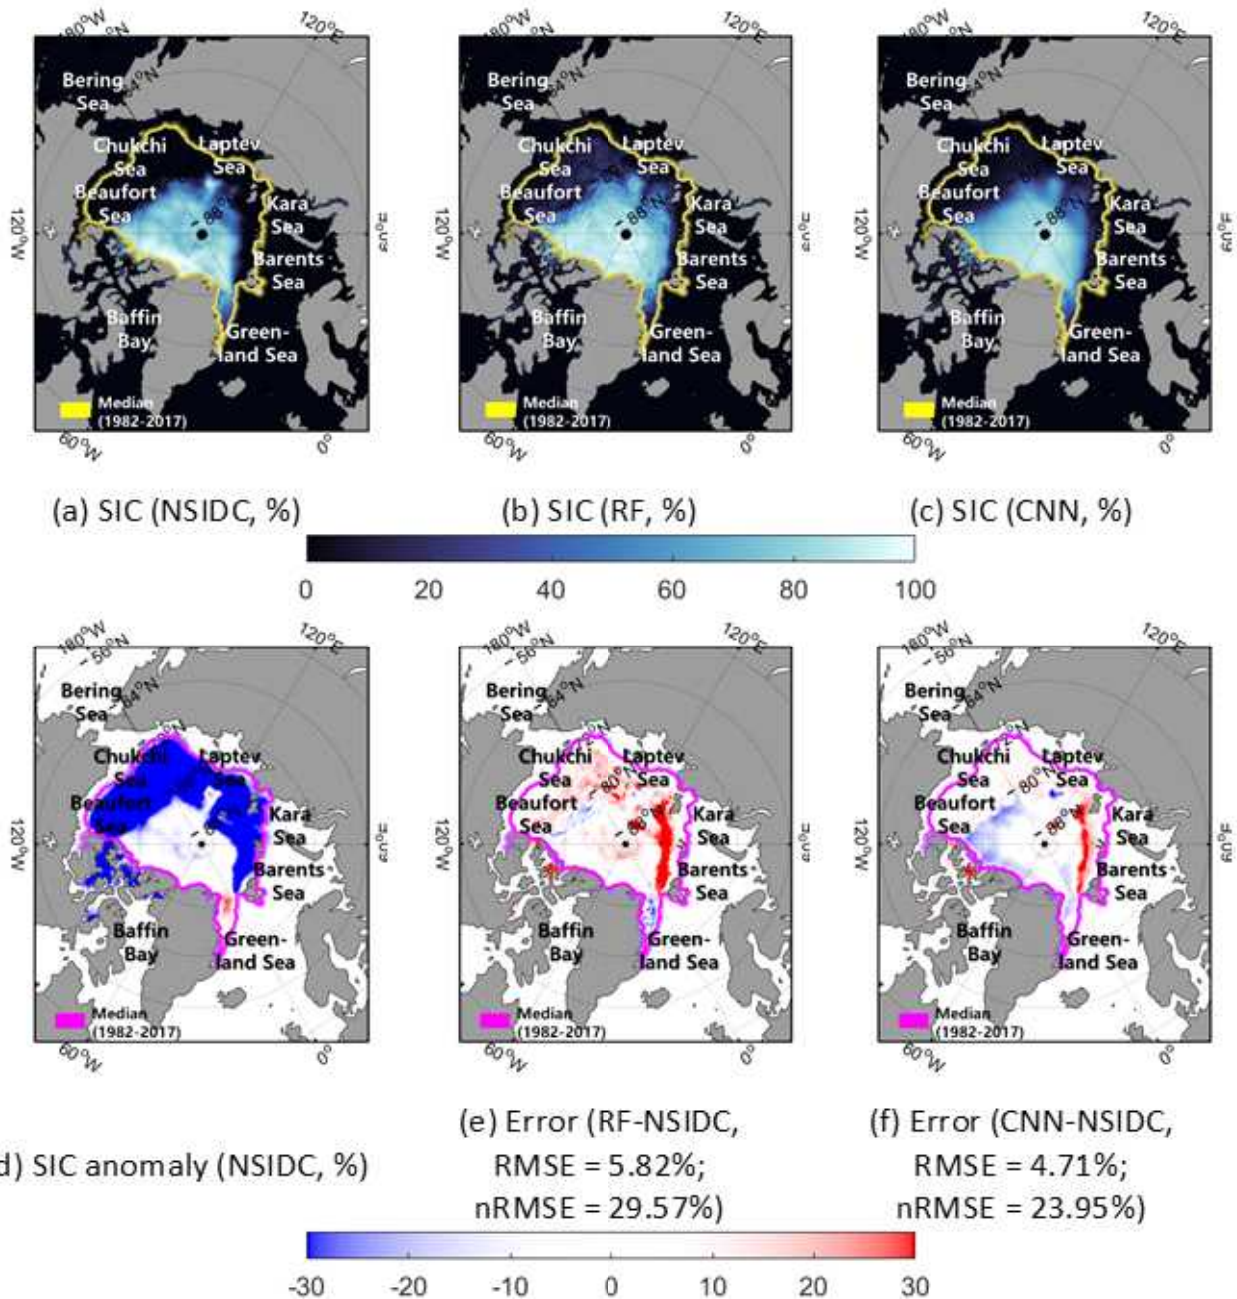


그림 3.2.9 SICs prediction results in September 2012

4. 결론 및 논의사항

본 연구는 딥러닝 기법중 하나인 CNN 기법을 활용하여 one-month SIC prediction 모델을 개발하였다. CNN 모델은 타 기법에 비하여 보다 나은 예측 성능을 보여주었으며 (MAE 2.28 %, ACC 0.98, RMSE 5.76 %, nRMSE 16.15 % 및 NSE 0.97), 해빙의 농도가 낮은 가장자리 지역에 대한 상대적으로 높은 예측력을 보였다. 지구 온난화로 인한 해빙 면적의 감소가 지속되고 있는 현재 상황에서 CNN 모델의 예측력 또한 melting season에서 모의력이 점점 감소하고 있는 것으로 나타났으며, 2007년 및 2012년 해빙 최소면적의 경우에 대한 추가적인 모의력을 분석하였다.

몇 가지 한계점 또한 존재하는데, 본 연구의 모델은 long-term effect를 고려하지 못한다는 한계가 있다. 2007년 및 2012년의 해빙 면적 최소의 경우, 여름철의 비정상적인 따뜻한 대기조건 뿐만이 아니라 지속적으로 따뜻했던 겨울과 봄철 기후로 인한 이유 또한 존재한다. 특히 이들은 해빙 가장자리의 변화에 영향을 많이 미쳤다 (Devasthale et al., 2013). 또한, 해빙의 두께 또한 해빙 변화를 예측하는데에 있어 중요한 요소로 작용한다 (Stroeve et al., 2008; Chevallier et al., 2013; Zhang et al., 2013). 하지만, 현재 활용 가능한 해빙 두께 산출물의 가용성이 제한되어 있기 때문에, 해빙의 두께를 고려하지 못하였다. 마지막 한계점은 딥러닝 모델의 해석의 한계점을 들 수 있다. 잘 알려진 대로, CNN 기법의 convolution 레이어 간의 복잡하고 비선형적인 연산으로 인하여 해석에 어려움이 있다 (Koh et al., 2017; Guidotti et al., 2018). 최근의 딥러닝 연구는 heat map 혹은 occlusion map 등의 기법을 활용하여 시각화 기반의 해석을 시도하고 있는 실정이다 (Brahimi et al., 2017; Trigueros et al., 2018). 그러나 본 연구에서는 변수 사이의 비선형적인 관계에 대한 명확한 해석을 제공하지 못했다는 데에 한계점이 존재한다.



제 3 절 2016년 11월 해빙 최소면적에 대한 원인 규명

연구 내용	연구 결과
기후, 해양 재분석 자료를 활용한 2016년 해빙 최소면적 원인 파악	MERRA-2 대기 온도, 대기압, 바람장 자료를 활용하여 2016년 8-10월의 온도 이상치를 확인하였음
각종 기후 변수들을 활용한 2016년 11월 해빙 최소 면적과 원격 상관관계 파악	AD(Arctic Dipole), EA/WR(East-Atlantic-West Russia), NAO(North Atlantic Oscillation), PNA(Pacific/North America), SCA(Scandinavian)과 대기온도와 대기압과의 상관관계를 가지는 것으로 확인하였음

1. 기후, 해양 재분석 자료를 활용한 2016년 해빙 최소면적 원인 파악 및 원격 상관관계 파악

가. 기후, 해양 재분석 자료를 활용한 2016년 해빙 최소면적 원인 파악

2016년 11월 경, 해빙 면적(sea ice extent)이 최소면적을 기록하는 것으로 나타났다. 이에 대한 원인 분석을 위하여 여러 재분석자료 및 기후 변수를 활용하여 상관관계를 분석하고자 하였으며, MERRA-2 대기온도, 대기압, 바람장 자료를 활용하여 2016년 8-10월의 온도 이상치(anomaly)를 확인하였다.

극지연구소

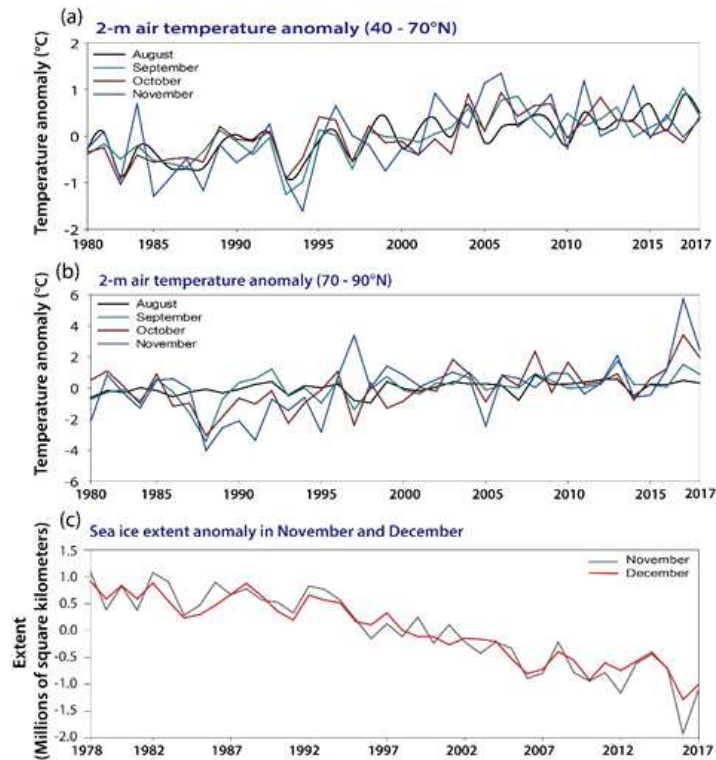


그림 3.3.1 Anomalies of 2-m air temperature (Aug.-Nov.) and sea ice extent (Nov.-Dec.) on Arctic region

나. 각종 기후 변수들을 활용한 2016년 11월 해빙 최소 면적과 원격 상관관계 파악

AD(Arctic Dipole), EA/WR(East-Atlantic-West Russia), NAO(North Atlantic Oscillation), PNA(Pacific/North America), SCA(SCandinavian)이 북극 대기온도와 대기압과의 유의미한 원격 상관관계(teleconnection)를 가지는 것으로 확인하였다. 추가적인 분석이 필요한 상황이지만, AD, NAO와 같은 기후 변수와 해빙면적의 원격상관성을 확인하였고, 특히, 북극 지역의 대기온도와 대기압사이의 유의미한 원격 상관관계를 밝혀냈다는 데에 의미가 있다고 판단된다.

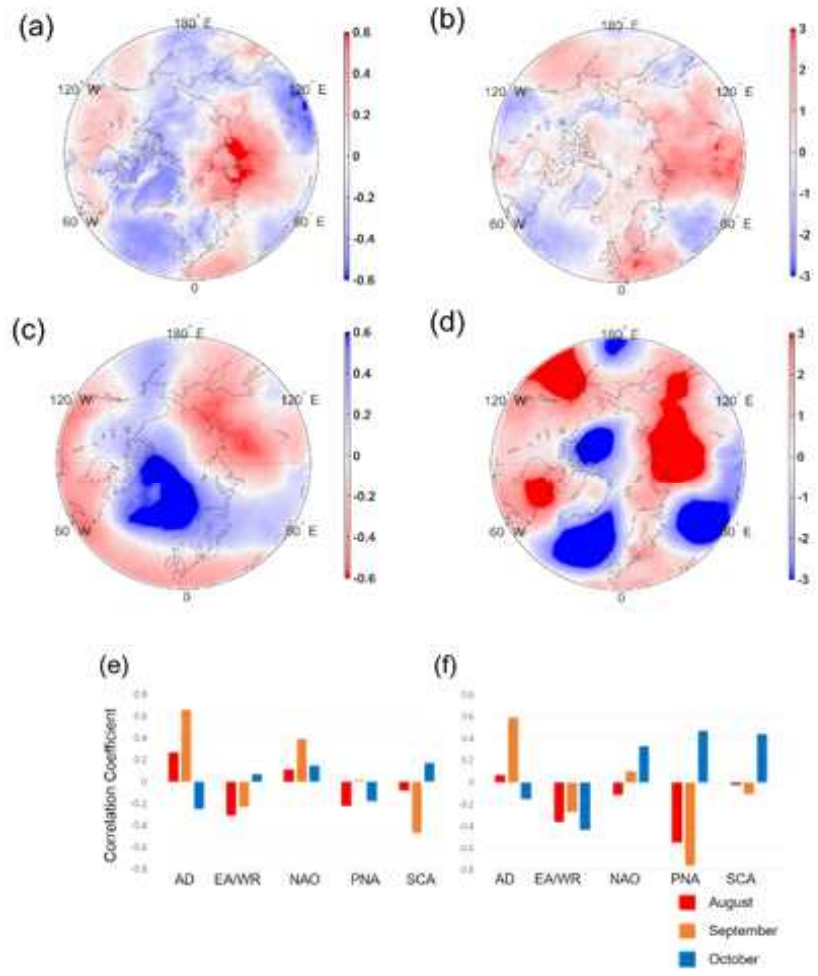


그림 3.3.2 teleconnection between atmosphere and SIE

제 4 절 Passive microwave 위성 자료 융합을 통한 초년생 해빙 두께 추정

연구 내용	연구 결과
주파수, 주파수 비율과 기계학습을 활용한 해빙 두께 추정 모델 개발	AMSR2 및 SMOS 주파수별 밝기온도 자료를 활용한 얇은 해빙 두께 추정 모델 개발 해빙 농도, Radio-Frequency Interference (RFI) 등 다른 변수 활용
CryoSat-2 해빙두께 자료와 융합을 통한 하이브리드 북극 해빙 두께 추정	CryoSat-2, SMOS, CS2-SMOS 해빙두께 자료와 비교를 통한 모델 검증 및 개선
현장자료와 비교검증을 통한 알고리즘 개선	Operation IceBridge 해빙 두께 관측자료와의 비교를 통한 모델 검증 및 개선

1. 주파수, 주파수 비율과 기계학습을 활용한 초년생 해빙 두께 추정 모델 개발

가. 연구 목적 및 배경

해빙은 바다의 표면에서 바다와 대기 사이의 단열재 역할을 하는데 이 때 열 전도율은 해빙의 두께에 반비례하며, 부분적 해빙의 열전도율은 겨울철의 두꺼운 해빙에 비해 수십배에서 수백배가량 높은 것으로 알려져 있다. 초년생 해빙은 두께가 30cm ~ 2m 사이이며 봄과 여름철에 녹고 1년 이상 지속되지 않기 때문에 계절에 따라 그 농도와 두께 변화 폭이 크며, 해빙이 대기/해양에 미치는 영향을 파악하기 위해서 초년생 해빙 두께 변화에 대한 보다 정확한 추정이 필요한 실정이다. 하지만, 현재까지의 관련 선행 연구의 경우, passive microwave의 주파수, 주파수 비율과 초년생 해빙의 관계를 통해 단순 선형 모델을 개발하는 데에 그치고 있다. 따라서 본 연구에서는 기계학습 기법을 활용하여 보다 정확한 해빙 두께 추정을 위한 알고리즘을 개발하였다.

본 연구의 목적은 passive microwave 위성영상을 융합하여 초년빙 (first year ice)의 해빙두께를 추정하는 알고리즘을 개발하는 것으로, passive microwave의 다양한 주파수로부터 얻어진 자료를 활용하여 현장자료와의 비교 및 검증을 통한 개선된 알고리즘을 제안하였다. 초년빙은 두께가 30cm~2m 사이로 다년빙에 비해 얇으며, 1년 이상 존재하지 않기 때문에 계절의 영향을 크게 받는다. 또한 대기/해양과 큰 연관을 가지기 때문에, 초년빙 두께 변화를 보다 정확하게 관찰하고자 하였다. Passive microwave 위성의 여러 주파수를 조합하여 기계학습 기법 적용하여 초년생 해빙 두께를 추정하고, 더 나아가 CryoSat-2와 같은 위성 관측자료를 융합하여 초년생 해빙의 두께를 추정하는 모델을 구축하였다.




그림 3.4.1 Example error characteristic of SMOS and CryoSat ice thickness retrieval from SMOS (Algorithm II*) and CryoSat2 (AWI-retracked) with uncertainties from data products (Kaleschke et al. 2015)

나. 국내·외 연구 동향

Cryosat-2 등 altimeter를 활용한 해빙두께 추정 알고리즘은 hydrostatic balance equation을 기준으로 산정하고 있으며, 1m 이상의 두꺼운 해빙에서는 비교적 잘 추정하지만, 얇은 해빙에 대한 정확도가 상대적으로 낮은 실정이다 (“relative uncertainties associated with this method are large over thin 5 ice regimes”). Passive microwave를 이용한 해빙 두께 연구는 아직 제한적이며, 눈이 쌓여 있지 않은 dry sea ice에 대한 sub-meter 급의 penetration depth를 가지는 L-band (1.4GHz, SMOS and SMAP)를 적극 활용하고 있다. 하지만, 여전히 외적인 요인 (snow depth, salinity, sea ice concentration)과 센서 산출물의 불확실성 요인 (Radio-Frequency Interference (RFI), incidence angle)으로 인하여 두께 추정의 한계가 존재한다. 50cm 이하의 thin sea ice의 경우, 해빙이 조각나기 쉬워, 한 grid 내에서 해빙농도가 100%가 되기 어려우며, 빈 공간 (sea water)으로 인한 반사도 차이가 발생하기 쉬우며, 이러한 이유 때문에 coarse spatial resolution (10km)에서 추정하기가 더욱 어려울 것으로 판단된다. 또한, 얇은 해빙의 경우 young ice일 확률이 높으며, 기존 모델에서 가정하고 있는 dry ice와 특성이 많이 달라지기 때문에 (salinity, water content, melt pond, ...), 파장대 및 편광 별 물리적 반

사특성이 그대로 반영되지 않는 경향이 있다.

최근에는 passive microwave를 활용하여 해빙 위의 snow depth를 추정하는 연구가 활발히 진행되고 있다. MODIS thermal band를 활용한 thin sea ice thickness 추정 연구가 꾸준히 이루어지고 있는데, 융합을 통하여 접근이 가능 할 것으로 기대된다. Heat budget을 고려한 개념으로 ice surface temperature를 기준으로 추정하고 있으며, 최근에는 다양한 기후인자나 수치 모델을 활용한 보다 복잡한 알고리즘을 사용하고 있다.

대표적으로 Huntemann et al. (2014)는 SMOS 이용 50cm 이하 thin sea ice thickness retrieval algorithm을 개발하였다. sea ice growth 모델을 통해 얻은 SIT 자료를 활용하여 훈련 / 알고리즘을 개발하였으며, MODIS SIT 산출물 및 EM bird 관측 자료를 활용하여 검증하였다.




그림 3.4.2 Scatter plot of EM bird and SMOS SIT retrieval (Huntemann et al., 2014)

Ricker et al. (2017)은 Cryosat-2 (1m이상)와 SMOS (1m 이하)를 융합한 해빙두께 모델을 개발하였다. 평균 해빙 두께가 높은 지역에 대해서는 단순 CS2모델이 더 잘 모의하나, daily SMOS 와의 융합을 통하여 weekly product 제공이 가능해졌다는 면에서 많은 기여를 하였다. Barents Sea 지역에서의 Airborne thickness data (AEM data)와 CS2SMOS 자료와의 비교를 통해 약 0.7m의 RMSD 수준의 정확도를 확보하였으며, thin ice에 대한 CS2 산출물의 활용도를 확장하였다.

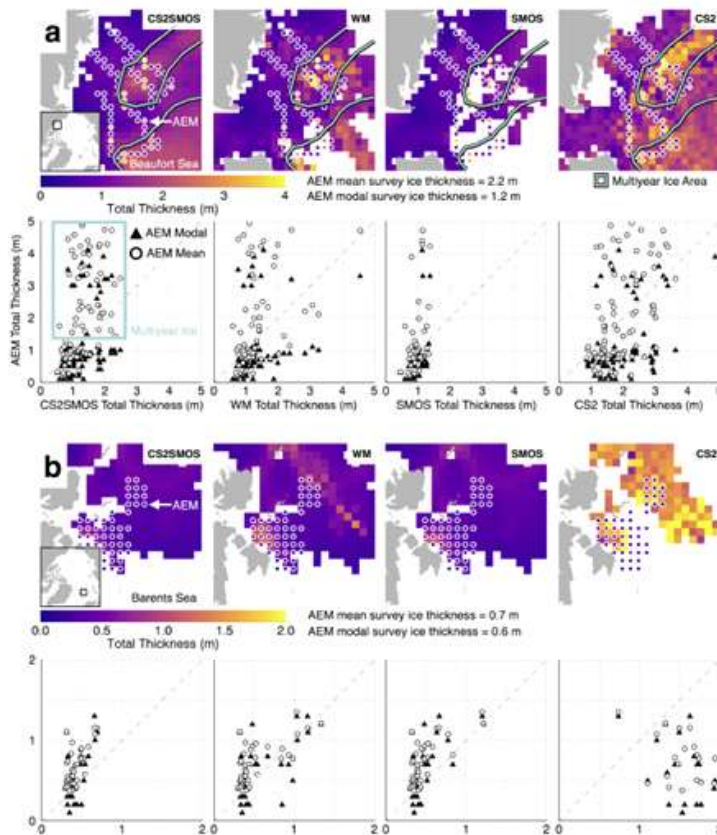


그림 3.4.3 scatter plot of AEM in situ and CS2SMOS SIT (Ricker et al., 2017)

극지연구소

Pařilea et al. (2019)는 SMAP과 SMOS를 결합한 thin sea ice thickness 추정 알고리즘 개발하였다. SMAP 밝기온도 관측자료를 SMOS 밝기온도 관측자료에 fitting 하여 spatial/temporal coverage를 높인 50cm 두께 이하의 thin SIT 추정 모델을 제안하였으며, SMAP의 고정된 incidence angle에 대하여 SMOS incidence angle 40-50도 사이의 자료를 변환하였다. 두 관측 자료의 융합을 통하여 다음과 같이 크게 네 가지 improvement가 있었다. (1) 두 위성의 융합 활용을 통한 북극 해빙 두께 산출물의 시간.공간적 해상도의 상승, (2) 두 위성의 융합 활용을 통한 RFI 필터링 기법의 전반적인 개선, (3) SMOS와 SMAP 밝기온도 관측자료의 intercalibration 결과의 RMSD가 기존의 fitting에 비하여 약 30% 수준의 개선, (4) 해빙 두께 산출물의 전반적인 신뢰도의 개선. 하지만, 이 산출물 또한 100%의 해빙농도를 가정하여 두께를 산출하기 때문에, 해빙 농도가 낮은 지역에 대해서는 정확도를 보증하지 못한다는 한계점이 존재한다. 특히, 선박을 이용한 현장 관측자료인 ASPeCT 해빙 두께 관측 자료와의 비교를 하였을 때, 과추정(overestimation)하는 경향이 보이는데, 이는 앞서 지적한 한계점으로 인하여 해빙 농도가 충분하지 못한 얇은 해빙에 대한 두께 모의가 제대로 이루어지지 못한다

는 결과를 보여준다.




그림 3.4.4 Comparison of ASPeCT-based ice thickness and the SMOS-SMAP retrieval (Patilea et al., 2019)

2. 현장 자료

해빙 두께의 reference로 활용할 수 있는 현장자료의 경우, 아래와 같이 크게 세 종류의 현장 관측 자료가 있다.

첫 번째로, NASA에서 운용하는 IceBridge (The IceBridge L4 Sea Ice Freeboard, Snow Depth, and Thickness (IDCSI4) product) 자료가 있다. 이는 2009년 03월부터 2018년 04월 까지 매년 3-4월에 측정하고 있으며, 약 40m마다 포인트 단위의 측정자료를 제공한다. 측정에 활용되는 장비는 Airborne Topographic Mapper (ATM), Snow Radar, Digital Mapping System (DMS), and KT19 pyrometer 등이 활용되고 있으며, freeboard 및 snow depth 측정값을 활용하여 간접적으로 해빙 두께를 추정하고 있다.

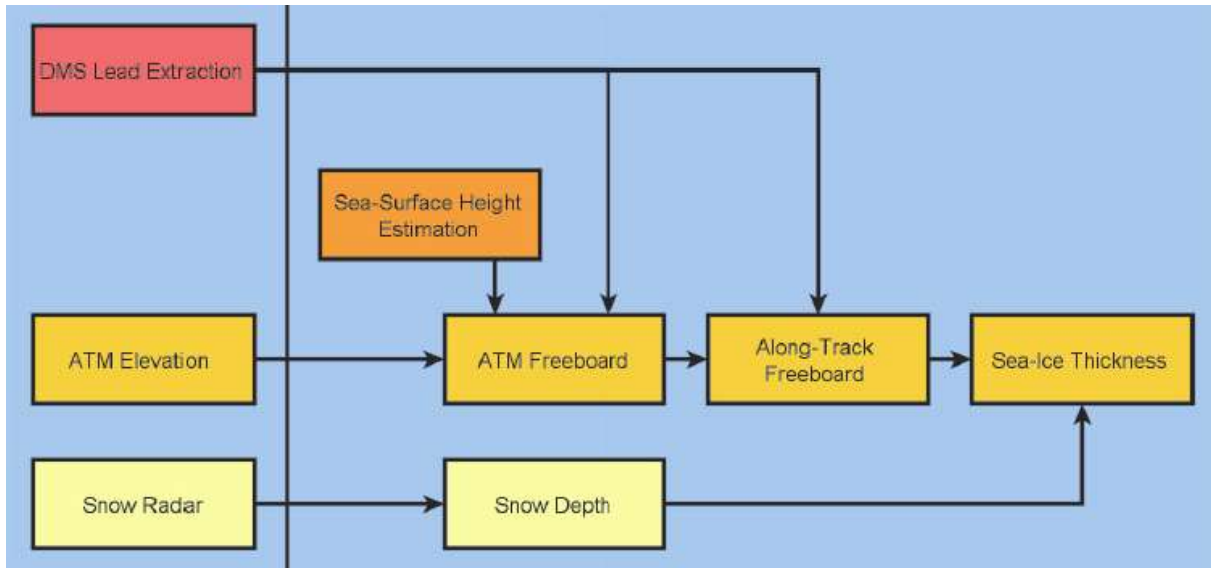


그림 3.4.5 a brief diagram of the IceBridge L4 products

이때, 간단한 hydrostatic balance model 이용하여 간접적으로 두께를 추정하고 있으며, 활용되는 각 상수 값은 고정되어있다 (free board 높이와 snow depth 및 밀도자료 활용).

$$h_i = \frac{\rho_w}{\rho_w - \rho_i} fb_{adj} - \frac{\rho_w - \rho_s}{\rho_w - \rho_i} h_s$$

수식 3.4.1 hydrostatic balance equation

IceBridge 자료의 경우, 아래 표와 같이 관측자료를 제공하고 있으며, 각 산출 값에 대한 불확실성 데이터 또한 같이 활용할 수 있다. 이 값을 활용한 quality control (QC)가 가능하며, 해빙 두께 산출물을 활용하기 이전에 신뢰할 수 있는 자료를 선별하여 분석에 활용할 수 있다.

표 3.4.1 Parameter lists for the IceBridge data

Parameter	Description	Units
Lat	Latitude	Degrees
Lon	Longitude	Degrees
Thickness	Sea ice thickness	Meters
thickness_unc	Sea ice thickness uncertainty	Meters
mean_fb	Mean freeboard from the combined ATM and DMS data set	Meters
ATM_fb	Mean freeboard from the ATM data set only (may be biased due to the loss of data over thin ice and water)	Meters
fb_unc	Freeboard uncertainty	Meters
snow_depth	Snow depth	Meters
snow_depth_unc	Snow depth uncertainty	Meters
n_atm	Number of ATM measurements used	n/a

pcnt_ow	Percentage of open water detected in the DMS imagery over the 40 m area	n/a
pcnt_thin_ice	Percentage of grease ice and/or nilas detected in the DMS imagery over the 40 m area	n/a
pcnt_grey_ice	Percentage of non-snow-covered grey ice detected in the DMS imagery over the 40 m area	n/a
corr_elev	Surface elevation after the removal of mean sea surface, atmospheric pressure, and tidal corrections	Meters
elev	Mean ATM elevation	Meters
date	Date of measurement in YYYYMMDD format	n/a
elapsed	Elapsed time from the start of the day in UTC	Seconds
atmos_corr	Atmospheric pressure loading term	Meters
mss	Mean sea surface	Meters
ellip_corr	Conversion factor between the WGS-84 and Topex/Poseidon ellipsoids	Meters
tidal_corr	Sum of the ocean, load, and earth tides	Meters
ocean_tide_corr_part	Ocean tide for the surface elevation	Meters
load_tide_corr_part	Load tide for the surface elevation	Meters
earth_tide_corr_part	Solid earth tide for the surface elevation	Meters
ssh	Local interpolated sea surface height	Meters
n_ssh	Number of ATM measurements used to determine the nearest sea surface height estimate	n/a
ssh_sd	Standard deviation of ATM elevations used to determine the nearest sea surface height estimate	Meters
ssh_diff	Difference between the centroids of the final and initial Gaussian fits to the nearest sea surface height	Meters
ssh_elapsed	Elapsed time since the last sea surface height data point was encountered	Seconds
ssh_tp_dist	Distance to the nearest sea surface height tie point	Meters
surface_roughness	Standard deviation of the ATM elevation points in the 40 m grid	Meters
ATM_file_name	Name of the ATM file which the surface elevation measurements were from	n/a
Tx	Mean transmit signal strength (40 m resolution) of the ATM data	Relative
Rx	Mean received signal strength (40 m resolution) of the ATM data	Relative
KT19_surf	Surface temperature from the KT-19 instrument	Celsius
KT19_int	Internal temperature of the KT-19 instrument	Celsius
low_en_corr	Correction added to the ATM elevation data for low signal strength	Meters
sa_int_elev	Height of radar derived snow-air interface relative to the WGS-84 ellipsoid	Meters

si_int_elev	Height of radar derived snow-ice interface relative to the WGS-84 ellipsoid	Meters
my_ice_flag	Flag for ice type, 0: first year ice, 1: multi-year ice	n/a

두 번째로, IMB Buoy 자료를 활용할 수 있다. 부이 자료의 경우, 2005 - 2016년 사이 관측된 각 부이별 관측 자료를 활용할 수 있다 (2017-2019년 관측자료는 QA/QC중). 4시간 단위로 측정 자료를 제공하고 있다. 총 4가지 종류의 부이를 운영중이며, 측정항목의 차이는 없다. 측정 항목은 Meteorological data, mass balance data, temperature data, metadata 로 구분할 수 있다. Meteorological data는 air temperature (°C) and air pressure (mbar)를 제공하며, Mass balance data는 snow depth, ice thickness, top of ice position, and bottom of ice position (all in meters)를 제공하며, Temperature data는 air, ice and ocean temperature profile data (°C) from thermistor string(s)를 제공한다. 마지막 Metadata의 경우는 information about the individual buoy, its deployment, operation, and a summary of the mass balance statistics, including total ice growth/melt, total snow accumulation/ ablation, and dates of melt/freeze onset during each full growth or melt season that the buoy operated에 대한 정보를 제공한다. 하지만, 부이의 특성 상, 아래 그림에 나와 있듯 얇은 해빙 상에는 설치·운영하기 어려운 실정이며, 때문에 first year ice 혹은 thin sea ice에 대한 관측이 어렵다는 한계가 있다.




그림 3.4.6 IMB buoy diagram (source: <http://imb-crrel-dartmouth.org/imb/>)




그림 3.4.7 IMB installation (source: <http://imb-crrel-dartmouth.org/imb/>)

세 번째로는 Ice Watch Arctic Shipborne Sea Ice Standardization Tool (ASSIST) Data가 있다. 홈페이지(<https://icewatch.met.no/about>)에서 모든 자료를 획득/활용할 수 있으며, 해빙 관측선에서 육안측정을 기반으로 관찰이 이루어지는 특징이 있다. 이는 북반구에서 운용되고 있는 모든 선박에서 기록된 시각 기반 해빙 관측 자료를 모두 관장하고 있으며, 노르웨이 기상 연구소, 알래스카 페어뱅크스 대학교, 국제 북극 연구센터, 알래스카 지리 정보 네트워크에 의하여 자료가 관리되고 있다. ASSIST system을 사용하는 모든 국제 선박의 Ice Watcher들은 Ice Watch 프로그램에 관측자료 (해빙 농도, 해빙 두께, 해빙의 상태, 표면의 거칠기 등)를 실시간으로 보고할 수 있으며, 데이터베이스에 업로드 요청할 수 있다. 하지만, 육안 관측에 의존하는 자료의 특성 상, 연속된 해빙 두께가 아닌, 10cm 단위의 이산적인 분포를 보이며, 이 또한 정확한 수치를 기대하기 어렵다는 단점이 있다.

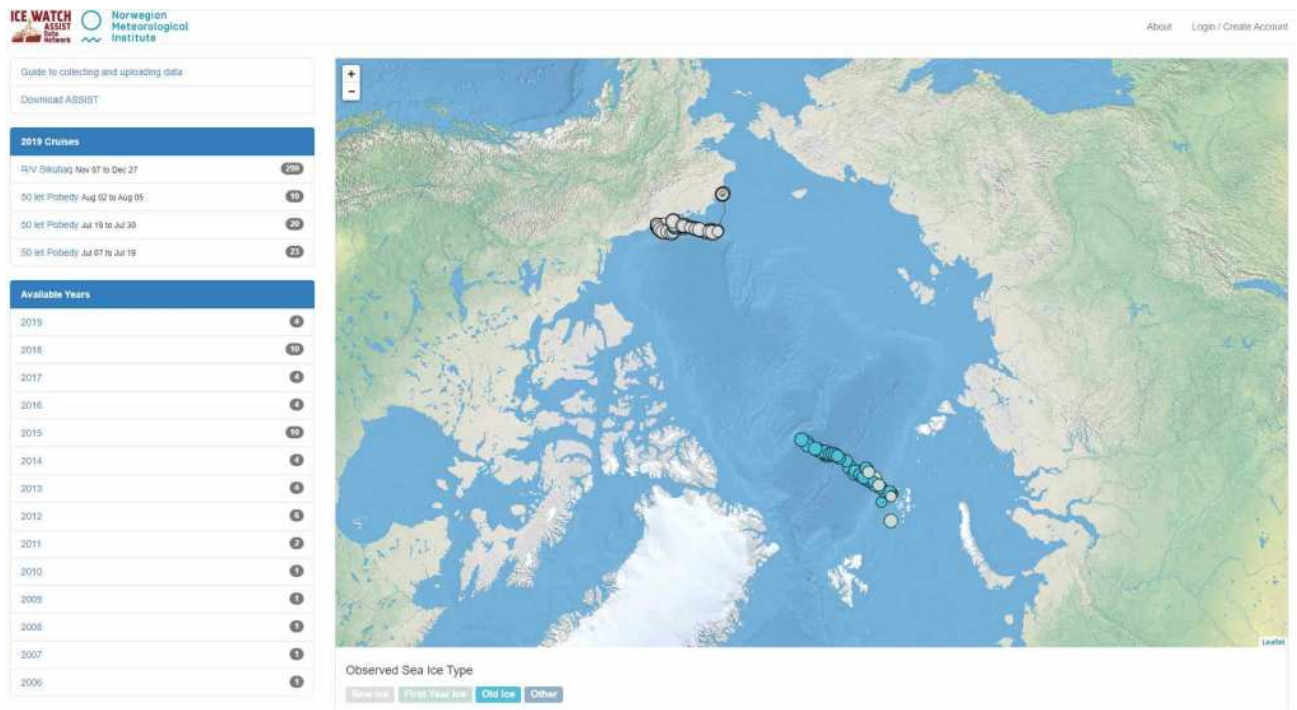


그림 3.4.8 Ice Watch 자료 공유 사이트 화면 및 자료 분포도 (source: <https://icewatch.met.no/>)

세 종류의 데이터는 아래 표와 같이 정리할 수 있다. 앞서 언급 하였듯이, IceBridge 자료를 제외한 두 자료는 thin sea ice 관측자료 활용에 한계가 있는 실정이다. 따라서 본 연구에서는 IceBridge 관측 자료를 바탕으로 thin sea ice (first year ice가 포함된) 의 두께 추정 모델을 개발하였다.

IceBridge 관측자료의 QC를 위하여 본 연구에서는 NASA에서 제공하는 guideline을 따라 (1) Freeboard의 불확실성이 10cm 이하, (2) Thickness의 불확실성이 1m 이하인 경우에 대하여만 신뢰할 수 있는 관측자료로 판단, 분석에 활용하였다.

표 3.4.2 available data sources for sea ice thickness

	Source	Coverage	Spatial res.	Temporal res.	Variables
In-situ	IceBridge	2016-	Points	40 min.	Ice type, snow depth, SIT
In-situ	Buoy (IMB)	2000-	Points	Hourly	Ice type, SIT, temp., pressure
In-situ	Shipborne (IceWatch)	2002-	Points	Hourly	Ice type, SIC, SIT, snow thickness, melt pond, algae...

3. 주파수, 주파수 비율과 기계학습을 활용한 해빙 두께 추정 모델 개발

본 연구는 최근 5년 동안 수행된 북극 해빙 농도 예측에 대한 선행연구 및 문헌조사를 통하여 해빙 농도에 영향을 미치는 passive microwave 관련 변수를 분석하였다. 아래 표는 passive microwave를 이용한 해빙 두께 분석에 활용할 수 있을 것으로 기대되는 위성자료 및 변수 리스트이며, AMSR2, SSMIS-F18, SMOS, SMAP으로부터 얻어지는 밝기온도 자료를 활용할 수 있을 것으로 기대된다.

표 3.4.3 available satellite data for SIT estimation

data type	Source	Coverage	Spatial res.	Temporal res.	Variables
BT	AMSR2	2012.07 -	3.125 - 10km	Daily	6.93, 7.3, 10.65, 18.7, 23.8, 36.5, 89.0 GHz H/V
BT	SSMIS F18	2012.07 -	3.125 - 25km	Daily	18.7, 23.8, 36.5, 89.0 GHz H/V
BT	SMOS L3	2012.07-	12.5km	Daily	1.4 GHz avg, RFI, uncertainty
BT	SMAP L3	2015.03-	9km	Daily	1.4GHz H/V
SIC	AMSR2	2012.07-	3.125km	Daily	Sea ice concentration
Ice type	OSI-SAF	2012.07-	12.5km	Daily	Sea ice type (FYI / MYI / ambiguous)

기존 passive microwave 활용 해빙 두께 추정 연구의 경우, 6, 37, 89 GHz (vertical pol.), gradient ratio (7/19 and 19/ 37, vertical pol.), 및 1.4 GHz (L-band) 변수를 널리 활용 하고 있는 것으로 나타났다. 본 연구에서는 AMSR2 및 SMOS와 SMAP 관측자료로부터 측정할 수 있는 변수들로 구축하였으며, 3-km grid로 변환하여 분석하였다. 아래 표와 같이 총 7개의 변수를 활용하였으며, penetration depth가 가장 큰 L-band의 기준에 맞추어, 1.0 m 이하의 얇은 해빙에 대한 두께 추정 모델을 개발하였다. 북극 전역에 대한 분석을 수행하였으며 (180°W - 180°E / 50°N - 90°N), SMAP 자료를 활용할 수 있는 2015년부터 2019년까지 제공되고 있는 모든 자료를 활용하였다.

표 3.4.4 input variables for thin SIT estimation

variables	source	temp. res.	spa. res.
1)AMSR-2 BT (GR18-36 and GR 7-18, v-pol)	JAXA, AMSR L1R	Daily	3.125 km

2) SMOS BT (average of H and V-pol) and RFI	ICDC, SMOS L3C	Daily	12.5 km
3) SMAP BT (1.4 GHz, H and V-pol) and surface temperature	NSIDC, SMAP L3C	Daily	9 km

2015-2019 IceBridge 관측자료의 경우, 3.125 km의 grid에 맞추어 매칭하였을 때 전체 관측 자료는 아래 좌측 그림에 나와있는 바와 같이, 0 - 8m의 다양한 분포를 보여주고 있다. 하지만, 본 연구에서는 0.8m 이하의 두께를 가지는 얇은 해빙에 대하여 초점을 맞추기 위하여 이들 중 1.0 m 이하의 자료만 따로 추려내었다. 이 과정에서 많은 관측자료의 손실이 있었으며, 결과적으로 총 2,255개의 샘플이 확보되었다.

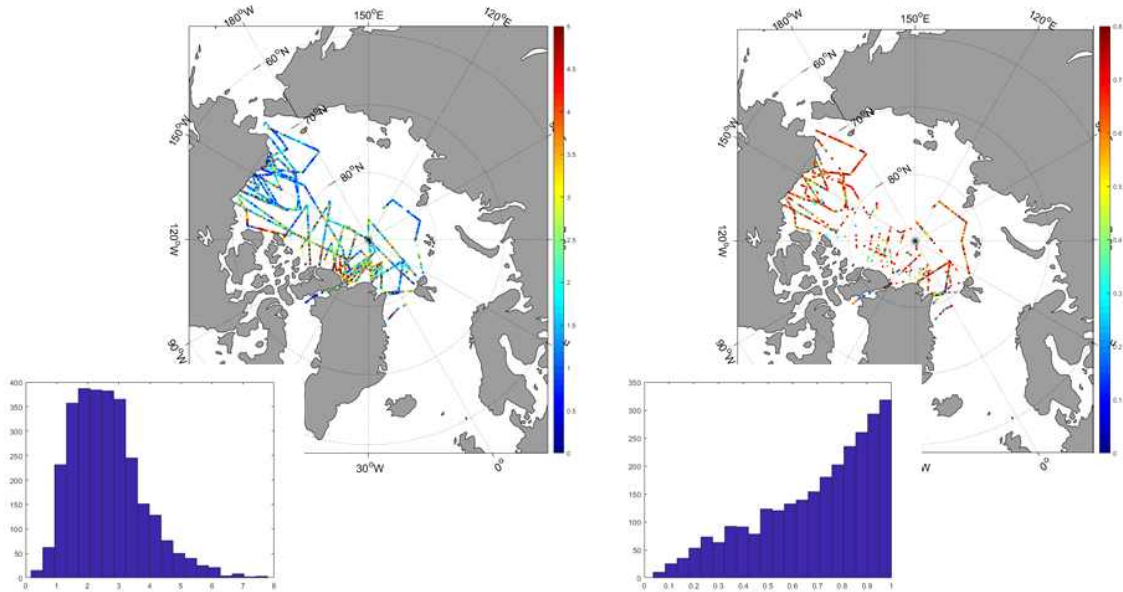


그림 3.4.9 IceBridge data distribution and histogram (left: overall, right: thin ice with 3.125 km-mean, 2015-2019)

본 연구에서는 이들 관측자료를 활용하여 랜덤포레스트 모델을 구축하였고, 트리의 개수는 50개로 설정하였다. 또한, 이때 균질하지 못한 두께 관측자료의 밸런스를 맞추어주기 위하여 오버샘플링(oversampling) 기법을 활용하였다. 적은 수의 샘플로 인한 얇은 해빙 두께 추정 훈련의 어려움이 예상되기 때문에, 10%의 랜덤 편차를 적용한 샘플을 추가 생성하여 모델의 훈련에 활용하였다. 기존 2,255개의 샘플에서 총 3,650개의 샘플로 확장하였으며, 훈련시에만 활용하여 얇은 두께 추정에 대한 약점을 보완하고자 하였다.




그림 3.4.10 original SIT dataset (left) and the dataset after oversampling (right)

본 연구는 oversampling을 적용하지 않은 자료와 적용한 자료를 활용하여 예측 모델의 변화를 비교하였다. 검증은 leave-one-out 형태로 진행하였으며, 아래 그림과 같이 오버샘플링 적용 이후 예측 모델의 개선이 이루어진 것으로 확인되었다. 기존의 unbalance한 샘플로 훈련을 진행하였을 경우, 50cm 이하의 보다 얇은 해빙에 대한 모의력이 상대적으로 떨어지는 반면, oversampling을 통하여 자료의 균형을 맞추어 준 후, 얇은 해빙에 대한 모의력이 많이 늘어난 것으로 나타났다.



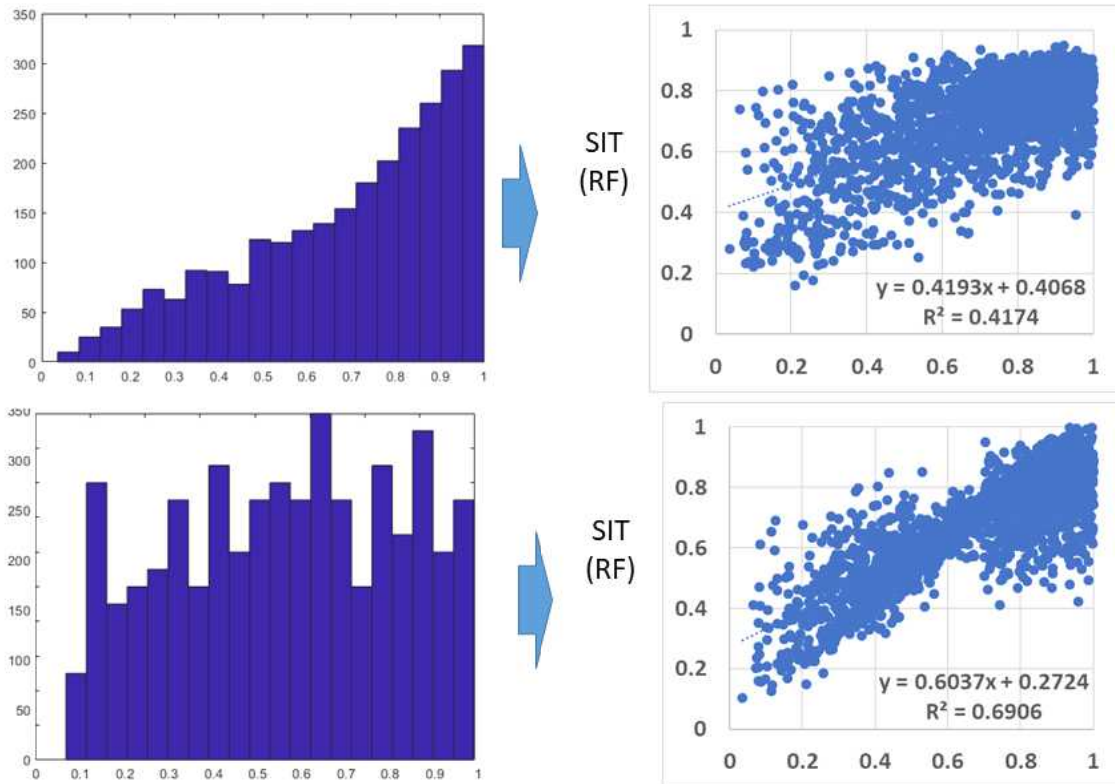


그림 3.4.11 RF-based SIT estimation models (upper: before oversampling; lower: after oversampling)

4. 타 해빙 두께 산출물과의 비교

기존 산출물로써 제공되고 있는 CryoSat-2 (CS2), SMOS, CS2-SMOS 해빙 두께와의 비교·분석을 통한 모델 검증 및 개선을 수행하였다. 세 종류의 산출물 모두 12.5 ~ 25km의 공간 해상도로 freezing season에 대해서만 제공을 하고 있으며, 본 연구 또한 IceBridge에서 제공하는 3-4월의 자료만을 활용하고 있어, 모델의 결과를 상호 비교·분석하기에 용이하다고 판단하였다. 본 연구에서 활용한 입력자료를 모두 12.5km의 공간해상도로 맞추어 모델링 하였으며, 그 결과를 가지고 다른 세 모델과 1.0m 이하의 얇은 해빙 자료에 대한 정확도를 비교하였다.

얇은 해빙에 대하여 IceBridge 해빙두께 관측자료와 CS2, SMOS, CS2-SMOS 해빙 두께 산출물을 상호비교한 결과, RMSE 기준 CS2 (0.16m), SMOS (0.19m), CS2-SMOS SIT (0.18m)으로, 얇은 해빙에 대하여 상대적으로 모의력이 낮은 것으로 나타났으며, 이들과 비교하여 RF 기반의 모델이 약 0.13m의 높은 정확도를 나타내었다.

표 3.4.5 model accuracy comparison with thin sea ice from IceBridge

	CS2	CS2SMOS	SMOS	RF model
RMSE (cm)	16.66	19.29	17.96	12.92

5. 결론 및 한계점

본 연구에서 개발한 RF 기반의 얇은 해빙 두께 추정 모델의 경우, 기존 산출물 대비 상대적으로 높은 모의력을 보이는 것으로 나타났다. AMSR2, SMOS, SMAP에서 관측되는 자료를 활용하여 모델을 구축하였으며, 오버샘플링을 통하여 IceBridge 관측자료의 얇은 해빙에 대한 자료의 불균질(unbalancing) 문제를 완화하였다.

하지만, IceBridge 관측자료 또한 3-4월에만 자료가 집중되어있고, 공간적으로도 북극 전지역에 대한 자료가 확보되어있지 않다는 한계점이 존재한다. 따라서, 보다 많은 현장자료를 활용한 보완이 필요할 것으로 판단되며, 추후 EM 실측자료를 더 확보하여 모델을 보완해야할 필요가 있을 것으로 보인다.



제 5 절 Sentinel-1 SAR와 ARTIST 해빙 농도를 이용한 북극 해빙 농도 상세화

연구 내용	연구 결과
해빙 농도에 영향을 미치는 인자 파악 및 고해상도 위성 및 모델 인자 추출	Sentinel-1의 HH, HV 및 입사각과 AMSR2 밝기온도를 이용하여 해빙 농도를 모의하여 중요도가 높은 인자 파악
다양한 통계기법 및 기계학습을 활용한 해빙 농도 상세화	랜덤 포레스트 및 신경망을 이용한 해빙 농도 상세화 모델 개발 및 비교
계절별 인자 중요도 파악 및 상세화 알고리즘 개발 및 최적화	계절별로 변수 중요도를 비교 분석

북극 지역은 온실 효과와 해빙 사이의 강한 긍정적인 피드백으로 기후 변화에 크게 기여한다(Aagaard와 Carmack, 1989). 열전달에 대한 긍정적인 피드백은 물에 비해 해빙의 알베도가 높기 때문에 발생한다. 해빙농도(SIC)는 해빙의 분포를 나타낼 수 있는 해당 면적의 해빙으로 덮인 면적의 일부분으로 정의된다. 수동 마이크로미터파센서, 가시 영상, 열 적외선 및 SAR를 포함한 여러 유형의 위성이 북극 지역에서 SIC를 추정하는 데 사용되었다.

수동 마이크로파센서는 1979년부터 날씨가 구름의 유무에 관계없이 북극권 상공에서 매일 해빙 농도를 제공하는 데 이용되고 있다. Scanning Multichannel Microwave Radiometer (SSMR), Special Sensor Microwave/Imager (SSM/I), Special Sensor Microwave Imager/Sounders (SSMIS), Advanced Microwave Scanning Radiometer - Earth Observing System (AMSR-E), Advanced Microwave Scanning Radiometer - 2 (AMSR2)와 같은 여러 위성이 매일 해빙 농도를 추정하는데 사용되었다. 이에 따라 NASA Team (NT), Bootstrap(BT), Ocean and Sea Ice Satellite Application Facility (OSI-SAF), Arctic Radiation and Turbulence Interaction Study (ARTIST) 해빙 농도 알고리즘(Cavalieri 등, 1984; Comiso, 1986; Comiso 등, 1997; Spreen 등, 2008) 등 여러 수동 마이크로미터파센서 기반 알고리즘이 개발되었다. 이러한 수동 마이크로미터파센서 기반 알고리즘은 북극 전체에 대해 3.125-25km의 공간 분해능을 제공한다. 이 중 ARTIST 해빙 농도는 수동 마이크로파센서 기반 해빙 농도 중 해상도가 가장 높은 AMSR2 89GHz를 사용해 3.125km 격자 분해능으로 SIC를 제공한다 (Beitsch et al., 2014). 고주파 채널을 이요한 해빙 농도는 대기 영향에 민감하지만 공간 분해능이 높다는 장점을 가진다 (AMSR-E의 경우 6.25km, AMSR2의 경우 3.125km).

NASA Team 알고리즘은 3개의 SSM/I 채널 (19.4GHz 수평 및 수직 편광 및 37GHz 수직 편광)을 사용하며, 1) 편광 및 스펙트럼 경사 비율 계산, 2) 알려진 영역에 대한 tie-point를 이용한 초년빙 및 다년빙 농도 추정, 3) 기상 영향에 의한 바다 위의 비정상적인 SIC 값을

제거하기 위한 기상 필터 사용의 단계로 이루어져 있다 (Cavalieri, 1994; Cavalieri 외, 1996; Gloersen 와 Cavalieri, 1986; Swift 와 Cavalieri, 1985). NATA Team 알고리즘은 널리 사용되지만, 눈과 초년빙 얼음에 의해 해빙 농도 값을 과소평가하는 경우가 많다 (Andersen 외, 2007). NT 알고리즘은 고주파 채널(SSM/I의 경우 85GHz, AMSR의 경우 89GHz)을 사용하여 NT2 알고리즘을 개발하기 위해 확장되었으며, 이를 통해 개방된 바다에 대한 대기 효과를 조사할 수 있었다(Markus and Cavalieri, 2009, 2000). NASA Team 이외에 널리 쓰이는 알고리즘은 SSMR 자료 (Comiso, 1986)를 위해 개발된 Bootstrap으로, SSM/I, AMSR2와 같은 새로운 수동 마이크로파센서 (Choi 와 Noki, 2015; Comiso, 1995)에 적용되어 성능이 향상되었다. Bootstrap 알고리즘은 통합된 얼음 영역(해빙 농도가 100%에 가까운 곳)과 얼음이 없는 영역(해빙 농도가 0%인 곳)의 두 가지 표면 유형이 있다고 가정한다. 다채널 위성 자료에서 밝기 온도의 고유 군집 분포를 이용하며, 얇은 얼음과 편광에 대한 증화 효과에 덜 민감하기 때문에 계절적으로 안정된 경향이 있다 (Andersen 외, 2007; Comiso, 1995, 1986). Svendsen 외 (1987)은 SSM/I의 85GHz 채널의 높은 공간 분해능을 활용할 것을 제안했다. 이는 나중에 Kaleschke 외 (2001)에 의해 확장되었다. ARTIST 해빙 농도 알고리즘은 Svendsen 외 (1987)가 제안한 고주파 채널 (SSM/I의 경우 85GHz, AMSR의 경우 89GHz)의 해빙 농도 모델을 저주파 채널 (19, 22, SSM/I의 경우 37GHz, SSM/I의 경우 18, 23, AMSR의 경우 37GHz)에서 파생된 해양 마스킹 자료와 결합한다(Kern 외, 2003; Spreen 외, 2008).

MODIS나 VIIRS와 같은 광학 및 열적외선 위성도 해빙 농도를 추정하는 데 사용되었다. 구름 아래에서는 사용할 수 없음에도 불구하고, 광학 위성 센서는 수동 마이크로파센서보다 더 높은 공간 해상도를 제공할 수 있다. Drüe 와 Heinemann (2004)은 수온과 해빙의 표면온도 사이의 비율을 계산하여 MODIS Terra 위성을 이용한 1km의 해빙 농도 알고리즘을 개발했다. Ahn 외 (2014)은 MODIS 자료에서 월별 바다와 얼음 사이의 비율에 가중치를 적용하여 AMSR2 10km SIC를 1km로 상세화했다. 2011년에 VIIRS 위성의 발사 이후, VIIRS에서 해빙 농도를 추정하기 위한 여러 연구도 실시되었다. MODIS 또는 VIIRS에서 SIC를 직접 추정한 것 외에도 고해상도 광학 센서는 수동형 마이크로미터파센서 기반 해빙 농도에 대한 참조 자료로 사용되었다. Chi 외 (2019)은 수동 마이크로파센서 기반 Bootstrap 및 ARTIST 해빙 농도보다 더 정확한 해빙 농도를 얻기 위해 MODIS를 사용했다. 500m 해상도의 MODIS 기반 해빙 농도를 얻기 위해 스펙트럼 혼합물 분석(Spectral mixture analysis; SMA)과 인공 신경망을 사용하였다. 높은 공간 해상도의 이점이 크더라도, 구름 아래에서 해빙 농도를 추출할 수 없는 것은 특히 구름이 많이 낀 북극 여름 동안 해빙 농도를 모니터링하는데 있어서 광학 센서의 치명적인 한계점이다.

SAR는 높은 공간 분해능과 기상 조건의 독립성을 모두 갖춘 극지방 모니터링에 널리 사용

되어 왔다 (Dierking, 2013, 2009; Han 외, 2017; Han 및 Kim, 2018; Karvonen, 2014; Scheuchl 외, 2004). 최근 SAR 기반 해빙 농도 추정에 대한 대부분의 연구는 인공 신경망(Cooke and Scott, 2019; Karvonen, 2017; Wang 외, 2017, 2016), 서포트 벡터 머신(Huiying 외, 2014), 랜덤 포레스트(Han 외, 2017; Han 및 Kim, 2018)를 포함한 기계학습 기반 접근법을 이용하였다. 기계학습 기반 해빙 농도 추정에 대한 연구의 대부분은 훈련 데이터로 해빙 차트를 사용했다. 해빙 차트의 해빙 농도는 매우 넓은 영역에 대해서 이산적인 값을 가지기 때문에 연속값인 해빙 농도를 훈련하는 데 적합하지 않다. 또한 해빙 차트는 각 나라의 기관별로 제공되므로 광범위한 북극 지역에서 전반적으로 이용하기 어렵다. 대부분의 연구는 훈련 자료로 해빙 차트의 해빙 농도를 사용했지만, 최근 Cooke 및 Scott (2019년)은 수동 마이크로파센서 기반 해빙 농도를 훈련 자료로 사용하였다. 해빙 차트 대신 수동 마이크로파센서 기반 해빙 농도를 이용한다면 해빙 차트의 한계점인 수동 생성, 주관적 해석 반영, 낮은 시간 해상도 (1주일) 문제를 완화할 수 있다.

본 연구의 목적은 SAR를 이용하여 수동 마이크로파센서 기반의 해빙 농도를 상세화 하는 것이다. SAR를 기반으로 한 해빙 농도 추출과 관련된 이전 연구를 확장하기 위해 본 연구는 해빙 차트의 해빙 농도 대신 수동 마이크로파센서 기반 해빙 농도를 학습 자료로 이용할 수 있는가에 초점을 맞춰서 연구를 수행하였다.

1. 연구에 사용된 자료

(가) Sentinel-1 SAR

Sentinel-1은 유럽우주국(ESA)의 코페르니쿠스 프로그램 위성 중 하나이다. Sentinel-1은 같은 궤도면을 공유하는 두 개의 위성인 Sentinel-1A (S1A)와 Sentinel-1B (S1B)로 구성되어 있다. 각 위성의 궤도는 12일 반복 주기를 가지며 사이클당 175개의 궤도를 완성한다. S1A와 S1B의 조합은 상승 궤도 및 하강 궤도를 모두 고려할 때 3일의 재방문 시간을 가진다. ESA는 Sentinel 위성을 쉽게 사용할 수 있도록 SNAP(Sentinel Application Platform)를 제공한다. SNAP은 방사선 보정, 반점 노이즈 감소, 리샘플링 및 모자이크를 포함한 Sentinel-1 툴박스 (S1TBX)를 통해 기본적인 전처리 기능을 제공한다. Sentinel-1 및 SNAP에 대한 자세한 정보는 ESA Sentinel-1 사용자 가이드 (<https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar>) 및 ESA Science Toolbox 플랫폼(STEP; <https://step.esa.int/main/toolboxes/snap>)에서 확인할 수 있다. 본 연구에서는 Sentinel-1의 extra-wide 모드를 이용하였고 이는 40m의 공강 해상도를 가진다. Extra-wide 모드에서는 HH와 HV 편광 정보를 제공한다. 따라서 본 연구에서는 2018년 1월부터 9월까지의 HH, HV 및 입사각을 입력 자료로 이용하였으며, 예시는 아래 그림과 같다.




그림 3.5.1 Sentinel-1 HH, HV, 입사각의 예시

(나) Sentinel-2 자료

Sentinel-2는 두 개의 트윈 센서로 구성된다. Sentinel-2A와 2B. 데이터가 클라우드 영역에 대해 불가능하더라도 Sentinel-2는 북극 지역에 높은 해상도(10m, 20m, 60m)의 다중 스펙트럼 영상을 제공할 수 있다. 본 연구에서는 Sentinel-2의 가시적 영상과 분해능 60m의 열 영상을 사용하여 하향 조정된 SIC를 검증하였다.

(다) ARTIST 해빙 농도 자료

학습 자료를 제공하기 위해 ARTIST 해빙 농도를 사용했다. ARTIST 해빙 농도는 89GHz 채널의 편광 차이를 얼음과 물의 타이 포인트에 맞춘다. ARTIST 알고리즘에서는 AMSR-E 센서의 저주파 채널을 기반으로 한 기상 필터를 적용한다. 이러한 기상 필터는 SAR 영상, 광학 데이터 또는 선박 관측치와 같은 다른 데이터 출처와 시각적으로 비교했을 때 볼 수 있듯이 mixed ice zone에서 해빙 농도가 현저하게 감소하는 경우가 많다. ARTIST 해빙 농도는 다른 수동 마이크로파센서 기반 알고리즘에 버금가는 오류를 갖고 있으며, 다른 수동 마이크로파센서 기반 해빙 농도에 비해 공간 분해능이 높기 (AMSR-E의 밝기 온도를 사용할 경우 6.25km, AMSR2의 밝기 온도를 사용할 경우 3.25km) 때문에 선택되었다.




그림 3.5.2 본 연구에서 사용된 ARTIST 해빙 농도

극지연구소

2. 자료 및 연구 방법

Sentinel-1 영상은 SNAP 소프트웨어에 내장된 Sentinel-1 Toolbox를 사용하여 처리되었다. 열 노이즈 처리가 HH와 HV 모두에 대해 적용되었다. 방사선량 보정을 수행하여 HH와 HV를 시그마 naught로 변환하였다. 노이즈 제거와 계산량을 줄이기 위해 500m 해상도로 이미지를 리샘플링했다. 리샘플링된 500m SAR 영상은 다시 한 번 ARTIST 해빙 농도의 그리드에 맞춰 3,125m로 변환되어 샘플을 수집했다. 카라 해에 대하여 총 500개의 영상 중 400개는 학습용으로 이용하였고 100개는 검증용으로 이용하여 분리된 영상에 대해 샘플을 추출하였다. 본 연구에서는 공간적인 분포는 고려하지 않은 픽셀끼리의 비교만을 통해 샘플을 구축하였다.




그림 3.5.3 본 연구의 연구 지역 (좌) 및 Sentinel-1 HH 영상의 예시 (우)

구축된 샘플을 이용하여 인공 신경망 기반 해빙 농도 상세화 모델을 만들었다. 먼저 ARTIST 해빙 농도의 해상도인 3.125km 격자에 맞춰서 모델을 학습하였다. 그 이후에 학습된 모델에 500m 해상도의 Sentinel-1 영상을 적용하여 최종적으로 500m 해상도의 해빙 농도를 산출하였다. 본 연구의 전반적인 흐름도는 아래 그림과 같다.

극지연구소

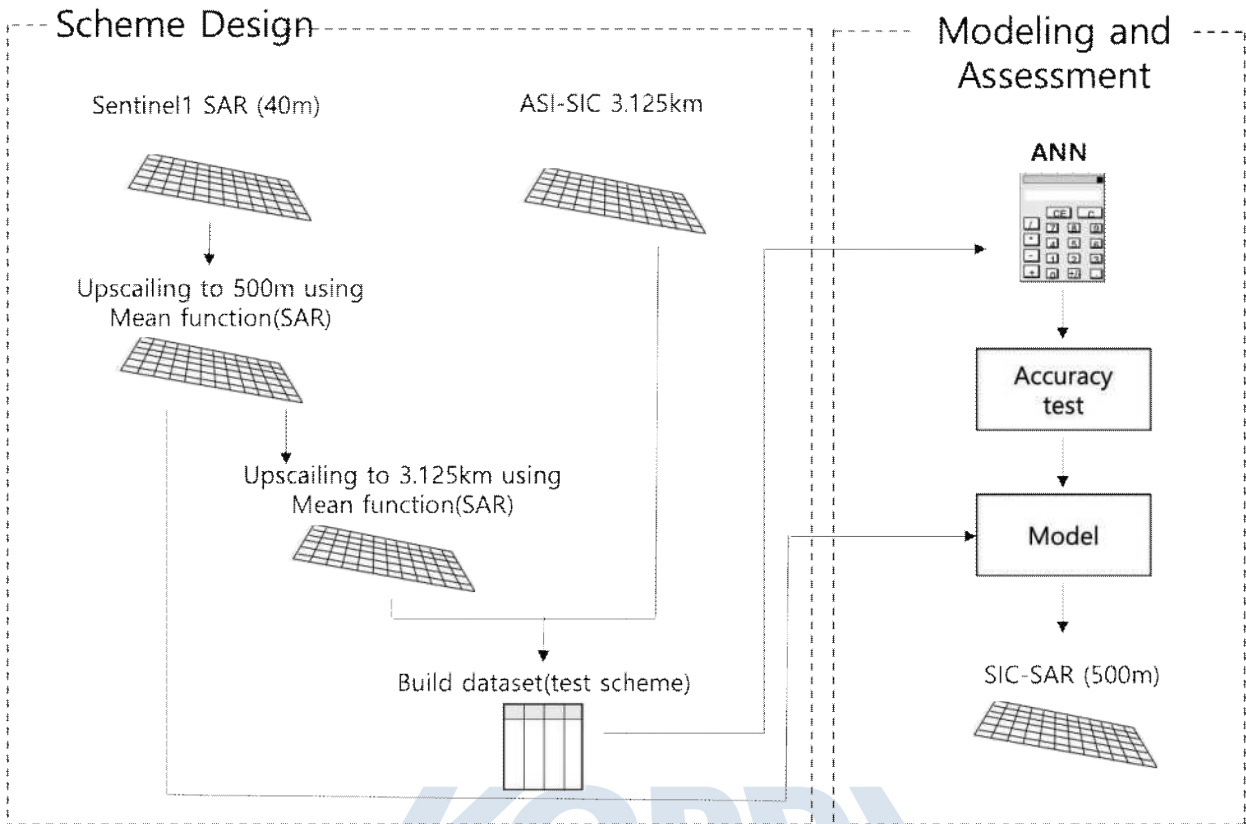
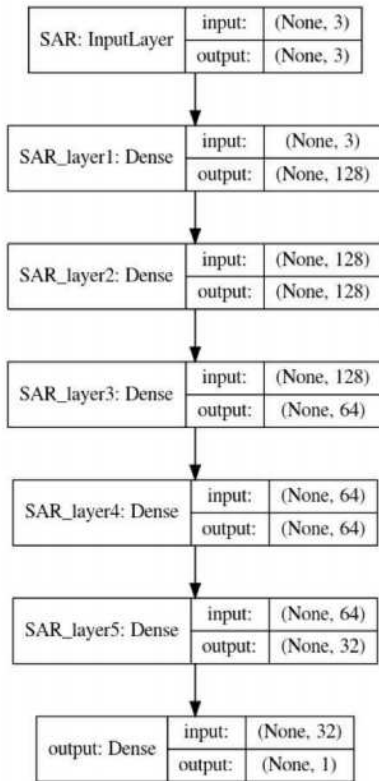


그림 3.5.4 본 연구의 모식도

인공 신경망의 구조는 모델 결과에 영향을 미치며, 일반적으로는 깊은 구조의 신경망이 좋은 결과를 나타낸다고 알려져있다. 하지만 모든 경우에 대해 단순히 깊은 구조의 신경망이 향상된 결과를 보장하는 것은 아니며, 자료의 특성 및 효율을 고려하여 구조를 결정해야 한다. 본 연구에서는 여러 번의 시험을 거쳐서 5개의 은닉층을 가진 신경망을 이용하였다. 총 샘플 개수는 4,144,059개이며, 학습 시간은 Nvidia사의 GTX 1080Ti 그래픽 가속 카드를 이용하여 약 1시간 정도가 소요되었다. 본 연구에서 이용한 인공 신경망의 구조는 아래 그림과 같다.



- Artificial Neural Network
- Input layer: Sentinel-1 inputs (HH, HV, incidence angle)
- Hidden layers : 128-128-64-64-32 nodes
- Output layer : 1 output of constant value
- # of samples : 4,144,059

그림 3.5.5 본 연구에서 쓰인 인공 신경망의 구조

3. 연구 결과

(가) 정량적인 검증

학습에 이용하지 않은 별도의 100개 영상에서 추출한 샘플을 이용하여 학습 모델의 성능을 평가하였다. 검증 결과 평균 제곱근 오차 (RMSE)는 16.38%가 나왔으며, 상관 계수 (R)은 0.74를 기록하였다. 해빙 농도의 범위가 0부터 100%인 것을 감안하면 RMSE의 크기는 비교적 큰 것으로 판단된다. 추정된 모델의 분포와 실제 ARTIST 해빙 농도의 분포를 확인하기 위해 산포도 그림을 분석하였다. 아래 그림에서 볼 수 있듯이, 전반적인 영역에 걸쳐 산포도가 넓게 분포되어 있다. 이에 대한 원인은 크게 세 가지로 추정할 수 있는데, 첫 번째로는 Sentinel-1 SAR의 노이즈가 큰 오차를 초래했을 가능성과 두 번째로는 불균형한 학습 자료의 분포, 그리고 마지막으로 공간적인 요소가 고려되지 않은 하나의 픽셀을 이용했기 때문으로 보인다. 이에 대한 대안으로는 단순히 HH, HV, 입사각 이외에도 GLCM과 같은 주변 픽셀의 공간 분석에 쓰이는 변수를 추가하는 것과, 고해상도 및 저해상도 해빙 농도에 치우친 샘플을 히스토그램 기반으로 보정하여 균형있게 학습하는 것을 제시할 수 있다.




그림 3.5.6 SAR를 통해 예측한 해빙 농도와 ARTIST 해빙 농도의 산포도

(나) 정성적인 검증

정량적인 검증 이후에 저해상도 (3125m) 기반으로 생성된 모델에 고해상도 (500m) SAR 자료를 이용하여 상세화된 해빙 농도를 추출하였다. 아래 그림들은 상세화된 해빙 농도를 나타내며, 정성적 검증에 사용된 영상들은 학습 자료와 처음부터 분리되었다. 아래 영상들에서 확인할 수 있듯이, 상세화된 해빙 농도는 고해상도 SAR의 패턴을 잘 반영하는 것을 확인할 수 있다. 특히 바다와 해빙의 경계인 marginal ice zone에 대하여 ARTIST 해빙 농도가 상세한 정보를 줄 수 없는 것에 비하여 SAR를 이용하여 상세화된 해빙 농도는 리드 및 바다와 해빙 사이의 상세한 정보를 제공한다. 저해상도 추정 결과 (SAR-SIC 3125m) ARTIST 해빙 농도를 비교하였을 때는 전반적으로 절대적인 값의 차이가 있으며, 이는 앞서 언급한 정량적인 분석에서 크게 나타났던 RMSE의 원인이 되는 것으로 분석된다. 본 연구에서는 ARTIST 해빙 농도를 학습 자료로 이용하였지만, SAR를 이용하여 추정한 해빙 농도는 SAR의 정보를 반영하기 때문에 ARTIST 해빙 농도와 전반적인 값의 차이를 보인다. 하지만 전반적인 분포는 저해상도 추정 결과와 ARTIST 해빙 농도가 비슷한 패턴을 보이며, 더욱 상세한 분석을 통해서도 고해상도 광학 위성을 통한 분석이 필요할 것으로 보인다.

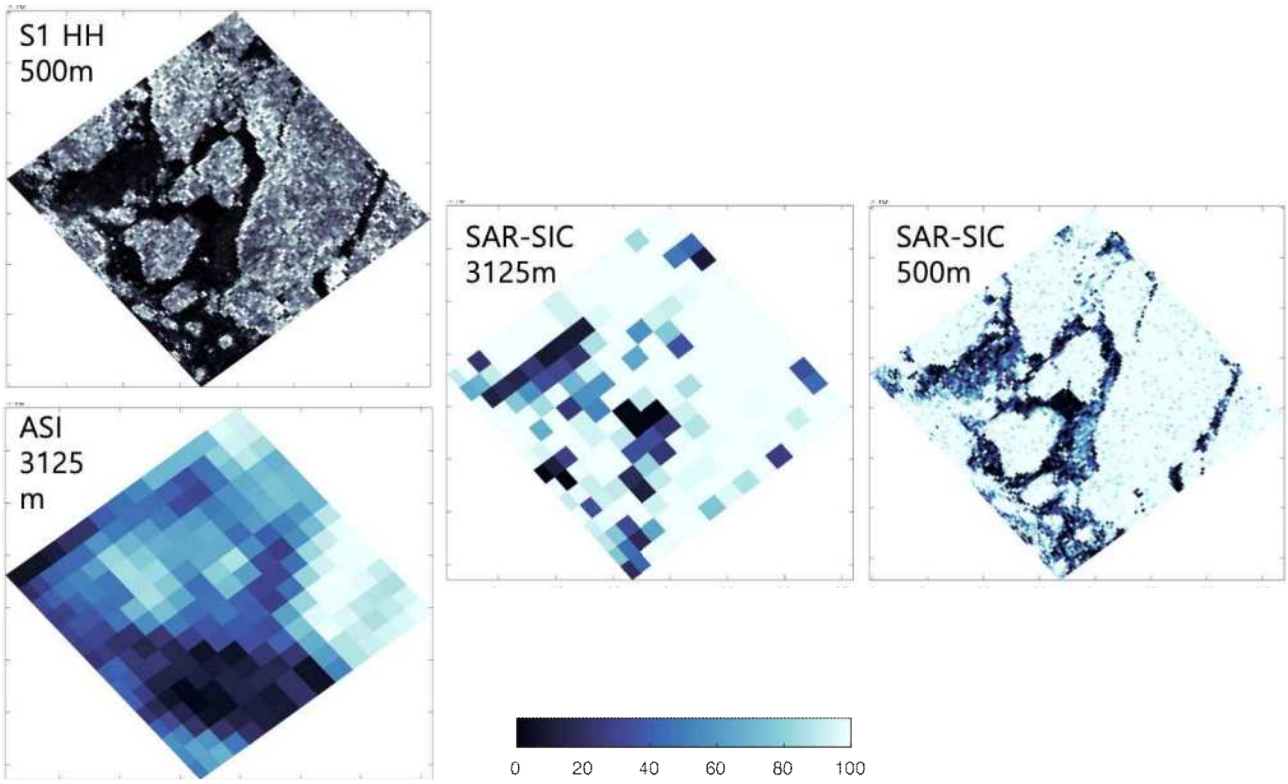


그림 3.5.7 ARTIST 해빙 농도와 본 연구에서 추정된 저해상도 및 고해상도 해빙 농도의 비교

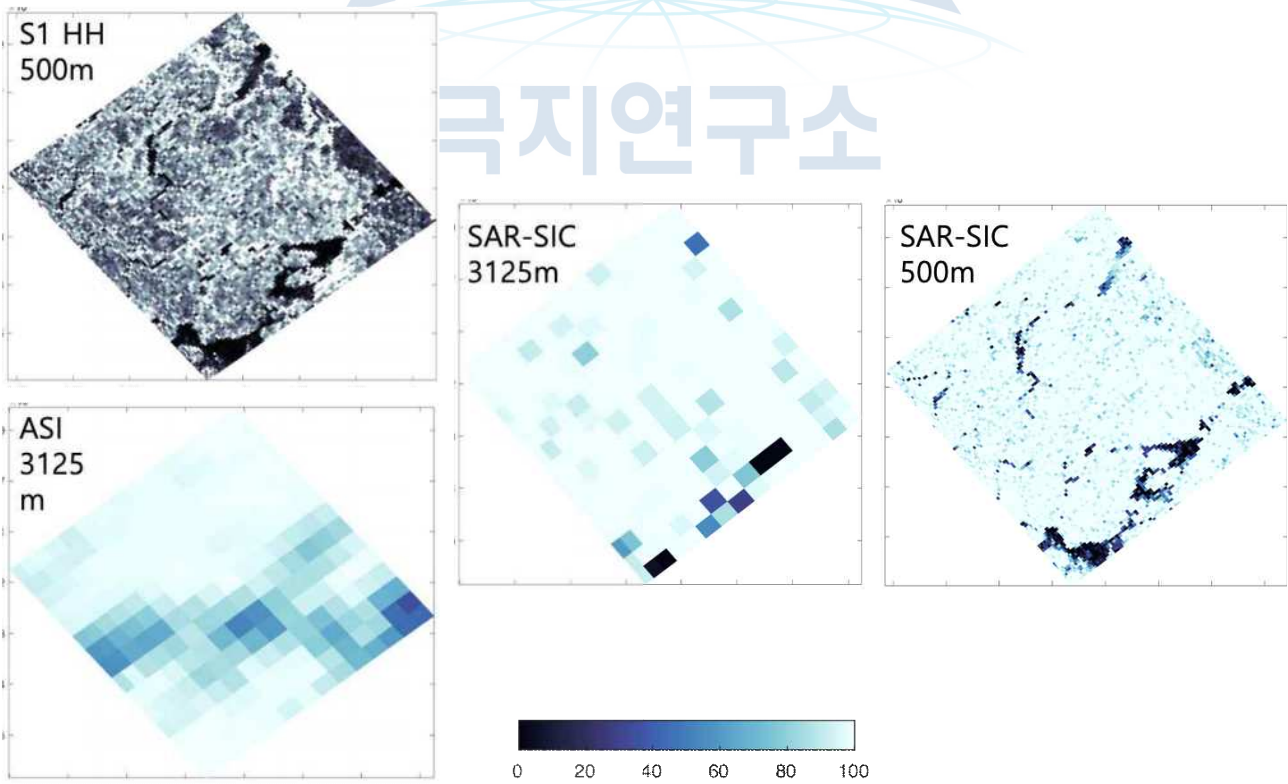


그림 3.5.8 ARTIST 해빙 농도와 본 연구에서 추정된 저해상도 및 고해상도 해빙 농도의 비교




그림 3.5.9 ARTIST 해빙 농도와 본 연구에서 추정된 저해상도 및 고해상도 해빙 농도의 비교

4. 토론

ARTIST 해빙 농도와 저해상도 SAR 영상을 이용하여 구축한 인공 신경망 모델은 16.38%의 RMSE와 0.74의 상관 계수를 보였다. 학습의 오차는 아직 개선의 여지가 필요한 것으로 판단되며, 이를 개선하기 위해서는 전처리 및 학습 샘플 추출 단계에서 Sentinel-1 SAR의 노이즈를 줄이는 것이 관건으로 보인다. 또한 본 연구에서는 해당 픽셀의 정보만 이용하였으며 주변 정보를 이용하지 않았는데, 공간적인 분포를 적용하면 노이즈 감소와 함께 추가적인 정보를 제공하여 정확도를 향상시킬 수 있을 것으로 제시된다. 공간적인 분포 이용에는 SAR에서 전통적으로 사용되는 GLCM 방법을 이용하거나, 인공 신경망에서 공간 분포 이용에 주로 사용되는 Convolutional Neural Network (CNN)을 이용할 수 있을 것으로 보인다. 또한 해빙 농도가 전반적으로 고해상도에 밀집되어있는만큼, 학습 단계에서 고해상도에 지나치게 치중된 샘플이 아니라 모든 해빙 농도 영역에 대해 골고루 분포된 자료를 이용한다면 정확도의 개선을 기대할 수 있을 것으로 보인다.

정성적인 분석에서는 추출된 고해상도 SAR 기반 해빙 농도가 Sentinel-1 SAR의 분포를 잘 반영하는 것으로 분석되며, 이는 ARTIST 해빙 농도 혹은 저해상도 SAR 기반 해빙 농도가 반영하지 못하는 정보를 반영하는 것을 확인하였다. ARTIST 해빙 농도와 저해상도 해빙 농도를 비교하였을 때 전반적인 해빙 농도 크기의 차이를 확인할 수 있었으며, 이는 비교적 큰 RMSE

의 원인으로 판단된다. 비록 본 연구에서 학습 자료를 ARTIST 해빙 농도를 이용하였으므로 최대한 ARTIST 해빙 농도를 모사하는 것이 이상적이지만, 그와 동시에 ARTIST 해빙 농도가 반영하지 못하는 고해상도 정보를 Sentinel-1 SAR를 통해 나타낼 수 있는 가능성을 확인할 수 있었다. 따라서 단순히 RMSE를 낮추는 것 이외에 추가적인 분석이 필요할 것으로 보이며, 추가적인 검증 자료인 고해상도 광학자료 및 해빙 차트 등을 함께 이용한다면 보다 고도화된 검증을 할 수 있을 것으로 보인다.

5. 결론

본 연구에서는 Sentinel-1 SAR와 ARTIST 해빙 농도를 이용하여 상세화된 해빙 농도를 생성하였다. 기존 연구에서는 해빙 차트를 기계학습 모델의 학습 자료로 이용한 것과는 달리, 본 연구에서는 수동 마이크로파센서 기반의 해빙 농도인 ARTIST 해빙 농도를 학습 자료로 이용하였다. 해빙 차트에서 제공하는 해빙 농도는 주관성, 이산적인 분포 및 상세하지 못한 정보, 그리고 북극 전역이 아닌 특정 지역에서만 제공하기 때문에 학습 자료로 이용하기에는 한계가 있다고 판단되었다. 카라 해에 대해 2018년 1월부터 9월에 걸쳐 총 500 장의 Sentinel-1 SAR 영상을 이용하였으며, 그 중 400장은 모델 학습에 이용하고 100장은 검증에 이용하였다.

정량적인 검증에서는 RMSE가 16.38%를 보였으며 상관계수는 0.74를 나타냈다. 전반적인 해빙 농도 차이는 비교적 크게 나타났으며, 이는 수동 마이크로파센서 기반인 ARTIST 해빙 농도와 SAR 기반으로 추정된 해빙 농도의 특성 때문으로 보인다. SAR 기반 해빙 농도에서는 수동 마이크로파센서의 낮은 해상도에서 제공하지 않는 상세한 정보를 제공하며, 특히 물과 해빙 사이의 marginal ice zone에 대하여 차이를 보인다. 정량적인 분석을 통해서 본 연구에서 수행한 상세화된 해빙 농도는 입력 자료인 고해상도 Sentinel-1 SAR의 분포를 잘 반영하는 것으로 확인되었으며, ARTIST 해빙 농도에 비해 상세한 결과를 제공한다. 정성적인 분석을 통해 본 연구의 가능성을 확인하였으며, 보다 상세한 검증 및 분석을 위해서는 추가적으로 고해상도 광학 이미지와 해빙 농도 차트와의 비교도 필요할 것으로 보인다.

정리하자면 본 연구에서는 기존 연구와는 다르게 해빙 차트가 아닌 수동 패시브마이크로파센서 기반의 해빙 농도를 기계학습 모델의 학습 자료로 이용하였으며, 그 결과 상세화된 해빙 농도는 SAR가 제공하는 고해상도 정보를 잘 반영하는 것으로 판단된다. 본 연구에서는 기초적인 접근을 통한 상세화 연구를 진행하였으며 그 결과 SAR를 이용한 해빙 농도 상세화의 가능성을 확인할 수 있었다. 본 연구를 토대로 공간 정보 및 고도화된 딥러닝 기법을 이용한다면 더욱 향상된 결과를 나타낼 수 있을 것으로 기대된다. 또한 본 연구에서는 해빙 차트의 해빙 농도 대신 수동 마이크로파센서 기반의 해빙 농도를 이용하였으므로, 특정 지역이 아닌 북극 전역에 대한 빙 농도 샘플을 추출할 수 있을 것으로 보인다. 이를 통해 기존의 연구들이 특정

지역에서만 연구를 수행했던 것과는 차별적으로 북극 전역에 대한 학습 및 검증을 수행할 수 있는 것을 의미하며, 최종적으로 북극 전역에 대한 해빙 농도 상세화 모델을 구축할 수 있음을 시사한다.



제 4 장 연구개발 목표 달성도 및 대외기여도

제 1 절 연구개발목표의 달성도

본 연구는 2017년 1월 1일 부터 2019년 12월 31일 까지 크게 네 가지 연구를 수행하였다. 먼저, 북극 해빙 프리보드 및 해빙 두께 추정 알고리즘 개발 및 월별 리드 비율 산출을 위하여 해빙 프리보드 및 두께 추정알고리즘을 개발하고 월별 북극 리드 비율 산출 알고리즘을 개발하였다.

2차년도에는 북극 해빙 농도 단기 예측 알고리즘을 개발 하였다. 해빙 농도에 영향을 미치는 인자의 중요도 파악 및 위성 기반 인자 추출 및 개선 방법을 제안하였고, 모델 자료와 다중 위성자료의 융합과 다양한 통계기법 및 기계학습을 이용한 월 해빙 농도 예측 모델을 개발하였다. 또한, melting / freezing season을 구분하여 해빙 농도의 전반적인 변화 및 예측력을 모의하였다.

3차년도에는 Passive microwave 위성의 융합을 통하여 얇은 해빙 두께를 추정하는 모델을 제안하였다. 주파수, 주파수 비율과 기계학습을 활용한 초년생 해빙 두께 추정 모델 개발하였으며, IceBridge 관측자료 기반의 현장자료와 비교를 통하여 알고리즘을 검증하였다. 또한, CryoSat-2, CryoSat2-SMOS, SMOS에서 산출되는 해빙 두께 자료와의 정량적인 비교·분석을 통하여 모델의 정확도를 분석하였다. 또한, 해빙 농도 상세화 알고리즘을 개발하였다. 해빙 농도에 영향을 미치는 인자 파악 및 고해상도 위성 및 모델 인자를 추출 하고, 다양한 통계 기법 및 기계학습을 활용하여 해빙 농도를 상세화하는 알고리즘을 개발하였다.

표 4.1.1 연구 개발 목표 진행도

수행 내용		수행월											
		1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월
북극 해빙 프리보드 및 해빙 두께 추정 알고리즘 개발 및 월별 리드 비율 산출	여름을 제외한 월별 해빙 프리보드 및 두께 추정												
	월별 북극 리드 비율 산출												
북극 해빙 농도 단기 예측 알고리즘 개발	해빙 농도에 영향을 미치는 인자의 중요도 파악												
	통계기법 및 기계학습을 이용한 해빙 농도 예측 모델 개발												
해빙 농도 상세화 알고리즘 개발	해빙 농도에 영향을 미치는 고해상도 위성 및 모델 인자 추출												
	통계기법 및 기계학습을 활용한 해빙 농도 상세화												
Passive microwave 위성자료 융합을 통한 초년생 해빙 두께 추정	주파수, 주파수 비율과 기계학습을 활용한 초년생 해빙 두께 추정 모델 개발												
	현장자료와 비교 검증을 통한 알고리즘 개선												

제 2 절 관련 분야에의 기여도

1. 학술적 파급효과

우리나라에 극지연구와 위성자료의 활용도를 높임으로써 위성강국으로 발돋움하는데 일조하였다. 본 연구에서 개발한 공간모델과 연구결과는 국제적인 극지 연구 분야의 기초자료로써 활용될 것으로 예상된다. 우리나라에는 아직 극지연구 인력이 부족한 편이고 특히 원격탐사 전문가가는 더더욱 부족한 실정이며, 본 연구 과제를 통해 극지 원격탐사 분야 연구 인력을 양성함으로써 극지연구의 발전가능성을 제고하였다.

기존의 임계값 기반의 CryoSat-2 리드 탐지 기법의 한계를 극복한 waveform mixture algorithm을 개발하였다. 2020년까지 연장된 CryoSat-2 미션에 waveform mixture algorithm을 적용하여 연속적으로 리드를 탐지할 수 있고 향후 발사될 고도계 미션에도 waveform mixture algorithm을 적용할 수 있을 것으로 기대된다. Waveform mixture algorithm은 CryoSat-2 baseline의 업데이트에 영향을 받지 않기 때문에 국제적인 활용이 예상된다.

또한, 북극 해빙의 변화에 대한 보다 다각적인 분석이 가능할 것으로 기대된다. 특히, 해빙의 두께와 상세화된 해빙 농도 분포 자료를 융합·활용한다면 해빙의 부피에 대한 개념으로 접근할 수 있게 되며, 이를 통하여 해빙 면적이 아닌 북극 해빙의 총 부피의 변화에 대한 분석이 가능할 것으로 기대된다.

뿐만 아니라, 기존 통계기법 및 수치해석 기법을 통해 산출된 기법에 비하여 기계학습 및 딥러닝 기법을 활용하였을 경우, 보다 높은 수준의 결과를 얻을 수 있는 것을 확인하였으며, 추후 북극 해빙 분야 연구에 적극적으로 활용한다면 국제적으로 신뢰할 수 있는 위성 원격탐사 산출물을 제공하는데 기여할 수 있을 것으로 기대된다.

2. 경제적 파급효과

북극 해빙의 공간적 분포를 예측하는 위성기반 모델을 개발함으로써 다양한 응용분야에 중요한 정보를 제공할 수 있다. 해빙의 리드 탐지 기법 및 리드 비율 지도를 활용하여 해빙의 분포를 파악할 수 있으며, 이를 활용하여 해빙조사 및 연구단 파견의 계획을 세우는 데에 의사결정 지표로써 활용할 수 있을 것으로 기대된다.

해빙 농도 예측 모델을 활용하여 여름철 북극 항로를 결정하는데 활용할 수 있으며, 이로 인한 사회·경제적 손실을 감소할 수 있을 것으로 기대된다. 또한, 해빙 농도 변화에 영향을 미치는 해양·대기 변수를 활용하여 해빙의 변화를 보다 상세하게 예측할 수 있으며, 상세화 알고리즘과 융합을 통하여 해빙분야 현장 조사 계획 수립에 보다 유용하게 활용할 수 있을 것으로 기대된다.

제 5 장 연구개발결과의 활용계획

앞서 파급효과에서 언급하였듯이, 본 연구 결과의 활용을 통하여 북극 해빙의 변화에 대한 보다 다각적인 분석이 가능할 것으로 기대된다. 해빙의 두께와 농도 분포 자료를 융합·활용한다면 기존에 한계점으로 지적되고 있던 해빙 면적에 대한 접근이 아닌, 북극 해빙의 부피의 변화에 대한 분석이 가능할 것으로 기대된다.

또한, CryoSat-2의 활용도를 더욱 증진시키기 위한 기초자료로서 활용이 가능할 것으로 기대된다. ICESat-2 위성 관측자료와의 융합·활용하여 북극 해빙의 lead 및 melt pond가 해빙의 변화에 미치는 영향을 분석하여 해빙의 변화를 예측하는 연구가 진행 될 수 있을 것으로 기대된다. 해빙의 리드 및 너비 추정 알고리즘 개발을 하기 위한 참고자료로 활용 할 수 있을 것이며, lead fraction의 공간분포를 분석할 수 있는 기반으로 참고할 수 있다.

ICESat-2의 경우, 초당 10,000개의 레이저 펄스를 사용하여 지표면의 높이를 측정하며, 특히 북극을 비롯한 빙권의 감시에 특화되어 있다. land ice height, sea ice freeboard, sea ice elevation, land/water vegetation elevation, inland water elevation, ocean elevation, backscatter profiles 와 같은 다양한 산출물을 제공하고 있으며, backscatter profiles 자료를 활용한다면 이 외에 더욱 다양한 해빙의 특성을 분석하는데 활용할 수 있을 것이다.

뿐만 아니라 ICESat-2는 약 17m의 footprint를 가지고 있으며, 약 300m X 1000m의 footprint를 가지는 CryoSat-2와 비교하여 보다 심도 있고 향상된 빙권의 분석이 가능할 것으로 기대된다. 현재까지 위성을 활용한 북극 해빙의 lead 및 melt pond에 대한 구체적인 분석이 제대로 이루어지지 못하고 있는 실정이며, 특히 lead의 너비(lead width)나 melt pond의 면적 등에 대한 산출물이 제공되지 않고 있기 때문에, 본 과업에서 제시한 북극 해빙의 lead 탐지 및 lead fraction 지도를 활용한 개발에 주요 참고자료로 활용할 수 있을 것이다.

또한 Sentinel 시리즈와 같은 고해상도 광학 위성자료를 활용하여 lead와 melt pond 샘플을 구축하고 광학 특성 분석에 활용 할 수 있을 것으로 기대되는데, 이를 위한 참고자료로 또한 CryoSat-2 및 IceSat-2 자료가 참고자료로 활용될 수 있을 것이다.

본 연구에서 분석한 ECMWF나 MERRA-2와 같은 재분석자료를 활용한 북극 해빙 농도 및 면적에 영향을 미치는 요인으로 참고할 수 있으며, 이 뿐만 아니라 Arctic Oscillation (AO), 북극 dipole index 등을 활용한 기상인자들과 북극 lead 및 melt pond fraction의 상관관계를 분석 할 수 있다.

기계학습 및 딥러닝 기법을 활용하였을 경우, 기존 통계기법 및 수치해석 기법을 통해 산출된 기법에 비하여 높은 수준의 결과를 얻을 수 있는 것을 확인하였으며, 추후 북극 해빙 분야 연구에 적극적으로 활용한다면 보다 수준높은 위성 원격탐사 산출물을 제공하는데에 기여할 수 있을 것으로 기대된다.

제 6 장 연구개발과정에서 수집한 해외과학기술정보

1. North-American CryoSat-2 science meeting (이상균 연구원)

2017년 3월 20일부터 24일 까지 캐나다 Banff에서 열린 North-American CryoSat-2 science meeting에 참여하여 연구의 최신 트렌드와 향후 동향을 파악하였다. 학회에서 본 현재 해빙연구에서 주요 이슈는 고도계 기반의 해빙 두께를 추정할 때 필요한 정확한 눈(snow)의 두께를 추정하는 것이다. 해빙 freeboard에서 두께를 전환할 때 눈의 두께정보가 필수적인데 전 북극의 눈 정보는 여전히 Warren (1999)에서 개발된 눈의 정보를 사용하고 있다. 따라서 해빙 두께 또한 많은 불확실성을 가지게 된다. 하지만 아직까지도 위성을 활용하여 전 북극 눈의 두께 정보를 추정하는 것은 쉽지 않고 항공 자료, 모델, 통계 기법을 이용해서 눈의 정보를 추정하고 있었다. 앞으로 위성을 활용한 전 북극 눈의 두께 정보의 추출이 필요할 것으로 보인다.

ICESat-2(Ice Cloud Elevation Satellite-2)는 ICESat-1의 후속 위성으로 2018년 발사를 앞두고 있다. 이에 따라 현재 ICESat-2의 calibration과 validation 상황에 대한 발표가 있었다. ICESat-2는 CryoSat-2와 달리 레이저 고도계를 사용함으로써 눈을 관통할 수 없다. ICESat-2가 CryoSat-2와 함께 사용할 경우 시너지 효과를 발휘할 것으로 예상되는데 예를 들면 CryoSat-2의 레이더 빔이 눈을 얼마나 관통하는지 파악할 수 있다. 추후 ICESat-2와 CryoSat-2의 활발한 융합 연구가 예상되며, 본 연구진도 적극 활용할 수 있을 것으로 기대된다.

2. IBRV ARAON Arctic Cruise ARA10B (August 3-27, 2019, 김영준 연구원)

2019년 8월 3일부터 27일까지 진행된 하계 아라온 북극탐사 (ARA10B)에 참여하여 북극 해빙 및 북극해의 현장조사를 보조하였다. 북극 척치해/베링해/동시베리아해 해빙관측, 해양환경·생태계 모니터링, 대기 환경 탐사를 위한 탐사계획에서 2항차에 참여하였다. 베링, 척치해 및 동시베리아해 주변 총 34개 조사 정점에서 해양 생물 및 대기 관측 수행을 보조하였으며, 해빙 캠프(sea ice camp)에 참여하여 척치 보더랜드 2개 정점에서 3D laser scanner 이용 해빙 표면 거칠기 및 적설 관측, UAV를 활용한 해빙 지형 관측, 수중 드론을 활용한 해빙 아래 환경 분석, Ice core의 깊이별 염분 측정, melt pond 조사, ice tracker 설치 등을 보조하며 현장의 상황을 직접 경험하고 현장자료의 획득 과정을 직접 체험하였고 기술정보와 데이터 등을 확보하였다.

특히, 해빙캠프의 경우, 독일, 영국, 크로아티아, 프랑스의 연구팀과 함께 국제 공동 해빙 연구를 수행하는 기회를 얻었으며, 현장자료를 취득하기 위한 watch 과정과 연구진들의 소통 및 의사결정 과정을 몸소 체험할 수 있었다. 9개국(한국, 미국, 러시아, 크로아티아, 영국, 프랑스, 인도, 중국, 독일) 8개 연구기관, 9개 대학교, 4개 업체에서 총 75명(연구원 39명, 헬리콥터운영팀 3명, 북극곰감시원 2명, 선의 1명, 해군 참관 1명, 해빙항해사 2명, 아라온 승조원 29명)의

다국적 연구팀으로 구성된 현장조사 경험을 통하여 해빙에 대한 이해도가 높아졌음은 물론, 해빙 면적이 전년 대비 대폭 감소한 2019년 여름의 해빙 현장 자료를 이용하여 추가적인 연구수행이 가능할 것으로 기대된다.



그림 6.1 IBRV ARAON Arctic Cruise ARA10B 참가 사진

극지연구소

제 7 장 참고문헌

- Aagaard, K., Carmack, E.C., 1989. The role of sea ice and other fresh water in the Arctic circulation. *J. Geophys. Res. Ocean.* 94, 14485 - 14498.
- All About Glaciers, National Snow and Ice Data Center. <https://nsidc.org/cryosphere/glaciers>. Accessed 10 November 2018.
- Andersen, S., Tonboe, R., Kaleschke, L., Heygster, G., Pedersen, L.T., 2007. Intercomparison of passive microwave sea ice concentration retrievals over the high-concentration Arctic sea ice. *J. Geophys. Res. Ocean.* 112.
- Archer, K. J., and Kimes, R. V.: Empirical characterization of random forest variable importance measures. *Comput. Stat. Data. An.*, 52(4), 2249-2260, doi:10.1016/j.csda.2007.08.015. 2008.
- Årthun, M., Eldevik, T., Smedsrud, L. H., Skagseth, Ø. and Ingvaldsen, R. B.: Quantifying the Influence of Atlantic Heat on Barents Sea Ice Variability and Retreat, *J. Clim.*, 25(13), 4736 - 4743, doi:10.1175/JCLI-D-11-00466.1, 2012.
- Baker, 2013. Joint Polar Satellite System (JPSS) Operational Algorithm Description (OAD) Document for VIIRS Sea Ice Concentration (SIC) Intermediate Product (IP) Software. Rev. B, 474 - 00094, 26 pp., NASA Goddard Space Flight Center, Greenbelt, Md.
- Baldwin, D., Tschudi, M., Pacifici, F., Liu, Y., 2017. Validation of Suomi-NPP VIIRS sea ice concentration with very high-resolution satellite and airborne camera imagery. *ISPRS J. Photogramm. Remote Sens.* 130, 122 - 138.
- Beitsch, A., Kaleschke, L., Kern, S., 2014. Investigating high-resolution AMSR2 sea ice concentrations during the February 2013 fracture event in the Beaufort Sea. *Remote Sens.* 6, 3841 - 3856.
- Bröhan, D., and Kaleschke, L.: A Nine-Year Climatology of Arctic Sea Ice Lead Orientation and Frequency from AMSR-E, *Remote Sensing*, 6, 1451, 2014.
- Cavalieri, D. J. and Parkinson, C. L.: Arctic sea ice variability and trends, 1979 - 2010, *The Cryosphere*, 6, 881-889, doi.org/10.5194/tc-6-881-2012, 2012.
- Cavalieri, D. J., C. L. Parkinson, P. Gloersen, and H. J. Zwally: Sea Ice Concentrations from Nimbus-7 SMMR and DMSP SSM/I-SSMIS Passive Microwave Data, Version 1., Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center, <https://doi.org/10.5067/8GQ8LZQVL0VL>. 2018.
- Cavalieri, D.J., 1994. A microwave technique for mapping thin sea ice. *J. Geophys. Res.*

- Ocean. 99, 12561 - 12572.
- Cavalieri, D.J., Gloersen, P., Campbell, W.J., 1984. Determination of sea ice parameters with the Nimbus 7 SMMR. *J. Geophys. Res. Atmos.* 89, 5355 - 5369.
- Cavalieri, D.J., Parkinson, C.L., Gloersen, P., Zwally, H.J., 1996. Sea ice concentrations from Nimbus-7 SMMR and DMSP SSM/I-SSMIS passive microwave data. Boulder, Color. USA NASA DAAC Natl. Snow Ice Data Cent. 25.
- Chase, J. R., and Holyer, R. J.: Estimation of sea ice type and concentration by linear unmixing of Geosat altimeter waveforms, *Journal of Geophysical Research: Oceans*, 95, 18015-18025, 10.1029/JC095iC10p18015, 1990.
- Chen, K., Wang, J., Chen, L.-C., Gao, H., Xu, W. and Nevatia, R.: Abc-cnn: An attention based convolutional neural network for visual question answering, *arXiv Prepr. arXiv1511.05960*, 2015.
- Chi, J. and Kim, H.: Prediction of Arctic Sea Ice Concentration Using a Fully Data Driven Deep Neural Network, *Remote Sens.*, 9(12), 1305, doi:10.3390/rs9121305, 2017.
- Chi, J., Kim, H., Lee, S., Crawford, M.M., 2019. Deep learning based retrieval algorithm for Arctic sea ice concentration from AMSR2 passive microwave and MODIS optical data. *Remote Sens. Environ.* 231, 111204.
- Chi, J., Kim, H.-C., and Kang, S.-H.: Machine learning-based temporal mixture analysis of hypertemporal Antarctic sea ice data, *Remote Sensing Letters*, 7, 190-199, 10.1080/2150704X.2015.1121300, 2016.
- Cho, K., Naoki, K., 2015. Advantages of AMSR2 for monitoring sea ice from space, in: *Asian Conference on Remote Sensing*, Manila, Philippines.
- Chouzenoux, E., Legendre, M., Moussaoui, S., and Idier, J.: Fast Constrained Least Squares Spectral Unmixing Using Primal-Dual Interior-Point Optimization, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, 59-69, 10.1109/JSTARS.2013.2266732, 2014.
- Chu, C., Chen, C., Nolte, L. P. and Zheng, G.: Fully automatic cephalometric x-ray landmark detection using random forest regression and sparse shape composition, *Submitt. to Autom. Cephalometric X-ray Landmark Detect. Chall.*, 2014.
- Cohen, J., Screen, J. A., Furtado, J. C., Barlow, M., Whittleston, D., Coumou, D., Francis, J., Dethloff, K., Entekhabi, D., Overland, J. and others: Recent Arctic amplification and extreme mid-latitude weather, *Nat. Geosci.*, 7(9), 627, doi:10.1038/ngeo2234, 2014.
- Comeau, D., Giannakis, D., Zhao, Z. and Majda, A. J.: Predicting regional and pan-Arctic

- sea ice anomalies with kernel analog forecasting, *Clim. Dyn.*, 52(9 - 10), 5507 - 5525, doi:10.1007/s00382-018-4459-x, 2019.
- Comiso, J. C.: Abrupt decline in the Arctic winter sea ice cover, *Geophys. Res. Lett.*, 33(18), doi:10.1029/2006GL027341, 2006.
- Comiso, J.C., 1986. Characteristics of Arctic winter sea ice from satellite multispectral microwave observations. *J. Geophys. Res. Ocean.* 91, 975 - 994.
- Comiso, J.C., 1995. SSM/I sea ice concentrations using the bootstrap algorithm. National Aeronautics and Space Administration, Goddard Space Flight Center~...
- Comiso, J.C., Cavalieri, D.J., Parkinson, C.L., Gloersen, P., 1997. Passive microwave algorithms for sea ice concentration: A comparison of two techniques. *Remote Sens. Environ.* 60, 357 - 384.
- Cooke, C.L. V, Scott, K.A., 2019. Estimating Sea Ice Concentration From SAR: Training Convolutional Neural Networks With Passive Microwave Data. *IEEE Trans. Geosci. Remote Sens.*
- Crane, R. G.: Seasonal variations of sea ice extent in the Davis Strait-Labrador Sea area and relationships with synoptic-scale atmospheric circulation, *Arctic*, 434 - 447, doi:10.14430/arctic2671, 1978.
- Deser, C. and Teng, H.: Evolution of Arctic sea ice concentration trends and the role of atmospheric circulation forcing, 1979--2007, *Geophys. Res. Lett.*, 35(2), doi:10.1029/2007GL032023, 2008.
- Deser, C., Tomas, R. A. and Peng, S.: The transient atmospheric circulation response to North Atlantic SST and sea ice anomalies, *J. Clim.*, 20(18), 4751 - 4767, doi:doi.org/10.1175/JCLI4278.1, 2007.
- Devasthale, A., Sedlar, J., Koenigk, T. and Fetzer, E. J.: The thermodynamic state of the Arctic atmosphere observed by AIRS: comparisons during the record minimum sea ice extents of 2007 and 2012, *Atmos. Chem. Phys.*, 13(15), 7441 - 7450, doi:10.5194/acp-13-7441-2013, 2013.
- Dierking, W., 2009. Mapping of different sea ice regimes using images from Sentinel-1 and ALOS synthetic aperture radar. *Ieee Trans. Geosci. Remote Sens.* 48, 1045 - 1058.
- Dierking, W., 2013. Sea ice monitoring by synthetic aperture radar. *Oceanography* 26, 100 - 111.
- Dokken, T. M. and Jansen, E.: Rapid changes in the mechanism of ocean convection during the last glacial period, *Nature*, 401(6752), 458, doi:10.1038/46753, 1999.

- Doney, S. C., Ruckelshaus, M., Emmett Duffy, J., Barry, J. P., Chan, F., English, C. A., Galindo, H. M., Grebmeier, J. M., Hollowed, A. B., Knowlton, N. and others: Climate change impacts on marine ecosystems, *Ann. Rev. Mar. Sci.*, 4, 11 - 37, doi:10.1146/annurev-marine-041911-111611, 2012.
- Drobot, S. D., Maslanik, J. A. and Fowler, C.: A long range forecast of Arctic summer sea ice minimum extent., *Geophys. Res. Lett.*, 33(10), doi: 10.1029/2006GL026216, 2006.
- Drobot, S.: Long-range statistical forecasting of ice severity in the Beaufort - Chukchi Sea., *Weather Forecast*, 18(6), 1161-1176., doi: 10.1175/1520-0434(2003)018<1161:lsfois>2.0.co;2, 2003.
- Drüe, C., Heinemann, G., 2004. High-resolution maps of the sea-ice concentration from MODIS satellite data. *Geophys. Res. Lett.* 31.
- Emery, W. J., Fowler, C. W. and Maslanik, J. A.: Satellite-derived maps of Arctic and Antarctic sea ice motion: 1988 to 1994, *Geophys. Res. Lett.*, 24(8), 897 - 900, doi:10.1029/97gl00755, 1997.
- Ertürk, A., and Plaza, A.: Informative Change Detection by Unmixing for Hyperspectral Images, *IEEE Geoscience and Remote Sensing Letters*, 12, 1252-1256, 10.1109/LGRS.2015.2390973, 2015.
- Forkuor, G., Dimobe, K., Serme, I. and Tondoh, J. E.: Landsat-8 vs. Sentinel-2: examining the added value of sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso, *GIScience Remote Sens.*, 55(3), 331 - 354, doi:10.1080/15481603.2017.1370169, 2018.
- Francis, J. A. and Vavrus, S. J.: Evidence for a wavier jet stream in response to rapid Arctic warming, *Environ. Res. Lett.*, 10(1), 14005, doi:10.1088/1748-9326/10/1/014005, 2015.
- Ghimire, B., Rogan, J. and Miller, J.: Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic, *Remote Sens. Lett.*, 1(1), 45 - 54, doi:10.1080/01431160903252327, 2010.
- Gignac, C., Bernier, M., Chokmani, K., Poulin, J., 2017. IceMap250 – Automatic 250 m sea ice extent mapping using MODIS data. *Remote Sens.* 9, 70.
- Gloersen, P., Cavalieri, D.J., 1986. Reduction of weather effects in the calculation of sea ice concentration from microwave radiances. *J. Geophys. Res. Ocean.* 91, 3913 - 3919.
- Grumbine, R. W.: Virtual floe ice drift forecast model intercomparison, *Weather Forecast.*, 13(3), 886 - 890, doi:10.1175/1520-0434(1998)013<0886:VFIDFM>2.0.CO;2, 1998.
- Guemas, V., Blanchard-Wrigglesworth, E., Chevallier, M., Day, J. J., Déqué, M.,

- Doblas-Reyes, F. J., Fučkar, N. S., Germe, A., Hawkins, E., Keeley, S. and others: A review on Arctic sea-ice predictability and prediction on seasonal to decadal time-scales, *Q. J. R. Meteorol. Soc.*, 142(695), 546 - 561, doi:10.1002/qj.2401, 2016.
- Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F. and Pedreschi, D.: A survey of methods for explaining black box models, *ACM Comput. Surv.*, 51(5), 93, doi:10.1145/3236009, 2018.
- Guo, Z. and Du, S.: Mining parameter information for building extraction and change detection with very high-resolution imagery and GIS data, *GIScience Remote Sens.*, 54(1), 38 - 63, doi:10.1080/15481603.2016.1250328, 2017.
- Han, H., Hong, S.-H., Kim, H., Chae, T.-B., Choi, H.-J., 2017. A study of the feasibility of using KOMPSAT-5 SAR data to map sea ice in the Chukchi Sea in late summer. *Remote Sens. Lett.* 8, 468 - 477.
- Han, H., Kim, H., 2018. Evaluation of summer passive microwave sea ice concentrations in the Chukchi Sea based on KOMPSAT-5 SAR and numerical weather prediction data. *Remote Sens. Environ.* 209, 343 - 362.
- Hassol, S.: Impacts of a warming Arctic-Arctic climate impact assessment, Cambridge University Press., 2004.
- Holland, M. M. and Stroeve, J.: Changing seasonal sea ice predictor relationships in a changing Arctic climate, *Geophys. Res. Lett.*, 38(18), doi:10.1029/2011gl049303, 2011.
- Hong, D.-B., Yang, C.-S., 2018. Automatic discrimination approach of sea ice in the Arctic Ocean using Sentinel-1 Extra Wide Swath dual-polarized SAR data. *Int. J. Remote Sens.* 39, 4469 - 4483.
- <http://www.nature.com/articles/srep40051#supplementary-information>,2017.
- <http://www.nature.com/ngeo/journal/v8/n8/abs/ngeo2489.html#supplementary-information>,2015.
- Huiying, L., Huadong, G., Lu, Z., 2014. Sea ice classification using dual polarization SAR data, in: *IOP Conference Series: Earth and Environmental Science*. p. 12115.
- Iordache, M. D., Bioucas-Dias, J. M., and Plaza, A.: Sparse Unmixing of Hyperspectral Data, *IEEE Transactions on Geoscience and Remote Sensing*, 49, 2014-2039, 10.1109/TGRS.2010.2098413, 2011.
- Janout, M. A., Aksenov, Y., Hölemann, J. A., Rabe, B., Schauer, U., Polyakov, I. V., Bacon, S., Coward, A. C., Karcher, M., Lenn, Y.-D., Kassens, H., and Timokhov, L.: Kara Sea freshwater transport through Vilkitsky Strait: Variability, forcing, and further pathways toward the western Arctic Ocean from a model and observations, *Journal of Geophysical*

- Research: Oceans, 120, 4925–4944, 10.1002/2014JC010635, 2015.
- Ji, L., Geng, X., Sun, K., Zhao, Y., and Gong, P.: Modified N-FINDR endmember extraction algorithm for remote-sensing imagery, *International Journal of Remote Sensing*, 36, 2148–2162, 10.1080/01431161.2015.1034895, 2015.
- Johannessen, O. M., Bengtsson, L., Miles, M. W., Kuzmina, S. I., Semenov, V. A., Alekseev, G. V., Nagurnyi, A. P., Zakharov, V. F., Bobylev, L. P., Pettersson, L. H. and others: Arctic climate change: observed and modelled temperature and sea-ice variability, *Tellus A Dyn. Meteorol. Oceanogr.*, 56(4), 328 - 341, doi:10.3402/tellusa.v56i5.14599, 2004.
- Kaleschke, L., Lüpkes, C., Vihma, T., Haarpaintner, J., Bochert, A., Hartmann, J., Heygster, G., 2001. SSM/I sea ice remote sensing for mesoscale ocean-atmosphere interaction analysis. *Can. J. Remote Sens.* 27, 526 - 537.
- Kang, D., Im, J., Lee, M. I., and Quackenbush, L. J.: The MODIS ice surface temperature product as an indicator of sea ice minimum over the Arctic Ocean. *Remote Sens. Environ.*, 152, 99–108., doi.org/10.1016/j.rse.2014.05.012, 2014.
- Karvonen, J., 2014. A sea ice concentration estimation algorithm utilizing radiometer and SAR data. *Cryosph.* 8, 1639 - 1650.
- Karvonen, J., 2017. Baltic sea ice concentration estimation using Sentinel-1 SAR and AMSR2 microwave radiometer data. *IEEE Trans. Geosci. Remote Sens.* 55, 2871 - 2883.
- Karvonen, J., Simila, M., Makynen, M., 2005. Open water detection from Baltic Sea ice Radarsat-1 SAR imagery. *IEEE Geosci. Remote Sens. Lett.* 2, 275 - 279.
- Kauker, F., Kaminski, T., Karcher, M., Giering, R., Gerdes, R. and Voßbeck, M.: Adjoint analysis of the 2007 all time Arctic sea-ice minimum, *Geophys. Res. Lett.*, 36(3), doi:10.1029/2008g1036323, 2009.
- Kay, J. E., L'Ecuyer, T., Gettelman, A., Stephens, G. and O'Dell, C.: The contribution of cloud and radiation anomalies to the 2007 Arctic sea ice extent minimum, *Geophys. Res. Lett.*, 35(8), doi:10.1029/2008g1033451, 2008.
- Kern, S., Kaleschke, L., Clausi, D.A., 2003. A comparison of two 85-GHz SSM/I ice concentration algorithms with AVHRR and ERS-2 SAR imagery. *IEEE Trans. Geosci. Remote Sens.* 41, 2294 - 2306.
- Kern, S., Rösel, A., Pedersen, L. T., Ivanova, N., Saldo, R. and Tonboe, R. T.: The impact of melt ponds on summertime microwave brightness temperatures and sea-ice concentrations, *Cryosph.*, 10(5), 2217 - 2239, doi:10.5194/tc-10-2217-2016, 2016.
- Keshava, N., and Mustard, J. F.: Spectral unmixing, *IEEE Signal Processing Magazine*, 19,

44-57, 10.1109/79.974727, 2002.

- Key, J., Stone, R., Maslanik, J., and Ellefsen, E.: The detectability of sea-ice leads in satellite data as a function of atmospheric conditions and measurement scale, *Annals of Glaciology*, 17, 227-232, 10.3198/1993AoG17-1-227-232, 1993.
- Key, J.R., Mahoney, R., Liu, Y., Romanov, P., Tschudi, M., Appel, I., Maslanik, J., Baldwin, D., Wang, X., Meade, P., 2013. Snow and ice products from Suomi NPP VIIRS. *J. Geophys. Res. Atmos.* 118, 12 - 816.
- Kildegaard Rose, S., Forsberg, R., and Toudal Pedersen, L.: Measurements of sea ice by satellite and airborne altimetry, *DMIDMI*,
- Kim, B.-M., Hong, J.-Y., Jun, S.-Y., Zhang, X., Kwon, H., Kim, S.-J., Kim, J.-H., Kim, S.-W., and Kim, H.-K.: Major cause of unprecedented Arctic warming in January 2016: Critical role of an Atlantic windstorm, *Scientific Reports*, 7, 40051, 10.1038/srep40051
- Kim, J., Kim, K., Cho, J., Kang, Y., Yoon, H.-J. and Lee, Y.-W.: Satellite-Based Prediction of Arctic Sea Ice Concentration Using a Deep Neural Network with Multi-Model Ensemble, *Remote Sens.*, 11(1), 19, doi:10.3390/rs11010019, 2019.
- Kim, M., Lee, J., Han, D., Shin, M., Im, J., Lee, J., Quackenbush, L., Gu, Z.: Convolutional neural network-based land cover classification using 2-D spectral reflectance curve graphs with multi-temporal satellite imagery. *IEEE J. of Selected Topics in Applied Earth Obs. and Remote Sens.*, 11, 4604-4617, 2018.
- Koh, P. W. and Liang, P.: Understanding black-box predictions via influence functions, in *Proceedings of the 34th International Conference on Machine Learning-Volume 70*, pp. 1885 - 1894., 2017.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E.: Imagenet classification with deep convolutional neural networks, in *Advances in neural information processing systems*, pp. 1097 - 1105., 2012.
- Kurtz, N. T., Galin, N., and Studinger, M.: An improved CryoSat-2 sea ice freeboard retrieval algorithm through the use of waveform fitting, *The Cryosphere*, 8, 1217-1237, 10.5194/tc-8-1217-2014, 2014.
- Kwok, R., Spreen, G., and Pang, S.: Arctic sea ice circulation and drift speed: Decadal trends and ocean currents, *Journal of Geophysical Research: Oceans*, 118, 2408-2425, 10.1002/jgrc.20191, 2013.
- Kwok, R.: Sea ice convergence along the Arctic coasts of Greenland and the Canadian Arctic Archipelago: Variability and extremes (1992 - 2014), *Geophysical Research Letters*,

- 42, 7598–7605, 10.1002/2015GL065462, 2015.
- Lai, S., Xu, L., Liu, K. and Zhao, J.: Recurrent convolutional neural networks for text classification, in Twenty-ninth AAAI conference on artificial intelligence., 2015.
- Laxon, S. W., Giles, K. A., Ridout, A. L., Wingham, D. J., Willatt, R., Cullen, R., Kwok, R., Schweiger, A., Zhang, J., Haas, C., Hendricks, S., Krishfield, R., Kurtz, N., Farrell, S., and Davidson, M.: CryoSat-2 estimates of Arctic sea ice thickness and volume, *Geophysical Research Letters*, 40, 732–737, 10.1002/grl.50193, 2013.
- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P.: Gradient-based learning applied to document recognition, *Proc. IEEE*, 86(11), 2278 - 2324, 1998.
- Ledley, T. S.: A coupled energy balance climate-sea ice model: Impact of sea ice and leads on climate, *J. Geophys. Res. Atmos.*, 93(D12), 15919 - 15932, doi:10.1029/jd093id12p15919, 1988.
- Lee, H., Grosse, R., Ranganath, R. and Ng, A. Y.: Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations, in *Proceedings of the 26th annual international conference on machine learning*, pp. 609 - 616., 2009.
- Lee, S., Im, J., Kim, J., Kim, M., Shin, M., Kim, H.-c., and Quackenbush, L.: Arctic Sea Ice Thickness Estimation from CryoSat-2 Satellite Data Using Machine Learning-Based Lead Detection, *Remote Sensing*, 8, 698, 2016.
- Lindsay, R. W., and Rothrock, D. A.: Arctic sea ice leads from advanced very high resolution radiometer images, *Journal of Geophysical Research: Oceans*, 100, 4533–4544, 10.1029/94JC02393, 1995.
- Lindsay, R. W., Zhang, J., Schweiger, A. J., and Steele, M. A.: Seasonal predictions of ice extent in the Arctic Ocean., *J. Geophys. Res.-Oceans.*, 113(C2), doi:10.1029/2007JC004259, 2008.
- Liu, T., Abd-Elrahman, A., Jon, M. and Wilhelm, V. L.: Comparing Fully Convolutional Networks, Random Forest, Support Vector Machine, and Patch-based Deep Convolutional Neural Networks for Object-based Wetland Mapping using Images from small Unmanned Aircraft System, *GIScience Remote Sens.*, (just-accepted), doi:10.1080/15481603.2018.1426091, 2018.
- Liu, Y., Key, J., Mahoney, R., 2016. Sea and freshwater ice concentration from VIIRS on Suomi NPP and the future JPSS satellites. *Remote Sens.* 8, 523.
- Luo, Y., Trishchenko, A.P., Khlopenkov, K. V, 2008. Developing clear-sky, cloud and cloud shadow mask for producing clear-sky composites at 250-meter spatial resolution for the

- seven MODIS land bands over Canada and North America. *Remote Sens. Environ.* 112, 4167 - 4185.
- Lüpkes, C., Vihma, T., Birnbaum, G., and Wacker, U.: Influence of leads in sea ice on the temperature of the atmospheric boundary layer during polar night, *Geophysical Research Letters*, 35, n/a-n/a, 10.1029/2007GL032461, 2008.
- Mahajan, S., Zhang, R. and Delworth, T. L.: Impact of the Atlantic meridional overturning circulation (AMOC) on Arctic surface air temperature and sea ice variability, *J. Clim.*, 24(24), 6573 - 6581, doi:10.1175/2011jcli4002.1, 2011.
- Marcq, S., and Weiss, J.: Influence of sea ice lead-width distribution on turbulent heat transfer between the ocean and the atmosphere, *The Cryosphere*, 6, 143-156, 10.5194/tc-6-143-2012, 2012.
- Markus, T., Cavalieri, D.J., 2000. An enhancement of the NASA Team sea ice algorithm. *IEEE Trans. Geosci. Remote Sens.* 38, 1387 - 1398.
- Markus, T., Cavalieri, D.J., 2009. The AMSR-E NT2 sea ice concentration algorithm: Its basis and implementation. *J. Remote Sens. Soc. Japan* 29, 216 - 225.
- Maslanik, J. A., Fowler, C., Stroeve, J., Drobot, S., Zwally, J., Yi, D. and Emery, W.: A younger, thinner Arctic ice cover: Increased potential for rapid, extensive sea-ice loss, *Geophys. Res. Lett.*, 34(24), doi:10.1029/2007gl032043, 2007.
- Maykut, G. A.: Large-scale heat exchange and ice production in the central Arctic, *Journal of Geophysical Research: Oceans*, 87, 7971-7984, 10.1029/JC087iC10p07971, 1982.
- Melia, N., Haines, K. and Hawkins, E.: Sea ice decline and 21st century trans-Arctic shipping routes, *Geophys. Res. Lett.*, 43(18), 9720 - 9728, doi:10.1002/2016gl069315, 2016.
- Moriyas, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., and Veith, T. L. : Model evaluation guidelines for systematic quantification of accuracy in watershed simulations, *T. ASABE.*, 50(3), 885-900, doi: 10.13031/2013.23153, 2007.
- Mutanga, O., Adam, E. and Cho, M. A.: High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm, *Int. J. Appl. Earth Obs. Geoinf.*, 18, 399 - 406, doi:10.1016/j.jag.2012.03.012, 2012.
- Nash, J. E., and Sutcliffe, J. V. : River flow forecasting through conceptual models part I— A discussion of principles, *J. Hydrol.*, 10(3), 282-290, doi : 10.1016/0022-1694(70)90255-6, 1970.
- Open University: *Ocean Circulation (Second Edition)*, Second Edi., Butterworth-Heinemann, Oxford., 2001.

- Overland, J. E., Francis, J. A., Hanna, E., and Wang, M.: The recent shift in early summer Arctic atmospheric circulation, *Geophysical Research Letters*, 39, n/a-n/a, 10.1029/2012GL053268, 2012.
- Parkinson, C. L. and Comiso, J. C.: On the 2012 record low Arctic sea ice cover: Combined impact of preconditioning and an August storm, *Geophys. Res. Lett.*, 40(7), 1356 - 1361, doi:10.1002/grl.50349, 2013.
- Parkinson, C. L., and Cavalieri, D. J.: A 21 year record of Arctic sea-ice extents and their regional, seasonal and monthly variability and trends, *Ann. Glaciol.*, 34, 441-446, doi.org/10.3189/172756402781817725, 2002.
- Prasad, S., Zakharov, I., McGuire, P., Power, D. and Richard, M.: Estimation of sea ice parameters from sea ice model with assimilated ice concentration and SST, *Cryosph.*, 12(12), 3949 - 3965, doi:10.5194/tc-2018-112, 2018.
- Preller, R. H. and Posey, P. G.: The polar ice prediction system—a sea ice forecasting system., 1989.
- Rayner, N. A. A., Parker, D. E., Horton, E. B., Folland, C. K., Alexander, L. V, Rowell, D. P., Kent, E. C. and Kaplan, A.: Global analyses of sea surface temperature, sea ice, and night marine air temperature since the late nineteenth century, *J. Geophys. Res. Atmos.*, 108(D14), doi:10.1029/2002jd002670, 2003.
- Ren, S., He, K., Girshick, R. and Sun, J.: Faster r-cnn: Towards real-time object detection with region proposal networks, in *Advances in neural information processing systems*, pp. 91 - 99., 2015.
- Richardson, H. J., Hill, D. J., Denesiuk, D. R. and Fraser, L. H.: A comparison of geographic datasets and field measurements to model soil carbon using random forests and stepwise regressions (British Columbia, Canada), *GIScience Remote Sens.*, 54(4), 573 - 591, doi:10.1080/15481603.2017.1302181, 2017.
- Ricker, R., Hendricks, S., Girard-Arduin, F., Kaleschke, L., Lique, C., Tian-Kunze, X., Nicolaus, M., and Krumpen, T.: Satellite-observed drop of Arctic sea-ice growth in winter 2015-2016, *Geophysical Research Letters*, n/a-n/a, 10.1002/2016GL072244, 2017.
- Ricker, R., Hendricks, S., Helm, V., Skourup, H., and Davidson, M.: Sensitivity of CryoSat-2 Arctic sea-ice freeboard and thickness on radar-waveform interpretation, *The Cryosphere*, 8, 1607-1622, 10.5194/tc-8-1607-2014, 2014.
- Rodner, E., Simon, M., Fisher, R. B. and Denzler, J.: Fine-grained recognition in the noisy wild: Sensitivity analysis of convolutional neural networks approaches, *arXiv Prepr.*

arXiv1610.06756, 2016.

- Röhrs, J., and Kaleschke, L.: An algorithm to detect sea ice leads by using AMSR-E passive microwave imagery, *The Cryosphere*, 6, 343-352, 10.5194/tc-6-343-2012, 2012.
- Schauer, U., Loeng, H., Rudels, B., Ozhigin, V. K., and Dieck, W.: Atlantic water flow through the Barents and Kara Seas. *Deep Sea Research Part I: Oceanographic Research Papers*, 49(12), 2281-2298, doi.org/10.1016/s0967-0637(02)00125-5, 2002.
- Scheuchl, B., Flett, D., Caves, R., Cumming, I., 2004. Potential of RADARSAT-2 data for operational sea ice monitoring. *Can. J. Remote Sens.* 30, 448 - 461.
- Schweiger, A. J. and Zhang, J.: Accuracy of short-term sea ice drift forecasts using a coupled ice-ocean model, *J. Geophys. Res. Ocean.*, 120(12), 7827 - 7841, doi:10.1016/s0967-0637(02)00125-5, 2015.
- Schweiger, A. J., Zhang, J., Lindsay, R. W. and Steele, M.: Did unusually sunny skies help drive the record sea ice minimum of 2007?, *Geophys. Res. Lett.*, 35(10), doi:doi.org/10.1029/2008gl033463, 2008.
- Screen, J. A. and Simmonds, I.: The central role of diminishing sea ice in recent Arctic temperature amplification, *Nature*, 464(7293), 1334, doi:10.1038/nature09051, 2010.
- Screen, J. A., Simmonds, I., Deser, C. and Tomas, R.: The atmospheric response to three decades of observed Arctic sea ice loss, *J. Clim.*, 26(4), 1230 - 1248, doi:10.1175/jcli-d-12-00063.1, 2013.
- Shimada, K., Kamoshida, T., Itoh, M., Nishino, S., Carmack, E., McLaughlin, F., Zimmermann, S. and Proshutinsky, A.: Pacific Ocean inflow: Influence on catastrophic reduction of sea ice cover in the Arctic Ocean, *Geophys. Res. Lett.*, 33(8), doi:10.1029/2005g1025624, 2006.
- Sonobe, R., Yamaya, Y., Tani, H., Wang, X., Kobayashi, N. and Mochizuki, K.: Assessing the suitability of data from Sentinel-1A and 2A for crop classification, *GIScience Remote Sens.*, 54(6), 918 - 938, doi:10.1080/15481603.2017.1351149, 2017.
- Spall, M. A.: Circulation and water mass transformation in a model of the Chukchi Sea, *Journal of Geophysical Research: Oceans*, 112, n/a-n/a, 10.1029/2005JC003364, 2007.
- Spreen, G., Kaleschke, L., Heygster, G., 2008. Sea ice remote sensing using AMSR-E 89-GHz channels. *J. Geophys. Res. Ocean.* 113.
- Steele, M., Ermold, W. and Zhang, J.: Arctic Ocean surface warming trends over the past 100 years, *Geophys. Res. Lett.*, 35(2), doi:10.1029/2007gl031651, 2008.
- Strobl, C., Boulesteix, A. L., Zeileis, A., and Hothorn, T.: Bias in random forest variable

- importance measures: Illustrations, sources and a solution. *BMC bioinformatics*, 8(1), 25., doi :10.1186/1471-2105-8-25, 2007.
- Stroeve, J. C., Serreze, M. C., Holland, M. M., Kay, J. E., Malanik, J. and Barrett, A. P.: The Arctic's rapidly shrinking sea ice cover: a research synthesis, *Clim. Change*, 110(3 - 4), 1005 - 1027, doi:10.1007/s10584-011-0101-1, 2012.
- Stroeve, J., Hamilton, L. C., Bitz, C. M. and Blanchard-Wrigglesworth, E.: Predicting September sea ice: Ensemble skill of the SEARCH sea ice outlook 2008--2013, *Geophys. Res. Lett.*, 41(7), 2411 - 2418, doi:10.1002/2014gl059388, 2014.
- Stroeve, J., Holland, M. M., Meier, W., Scambos, T. and Serreze, M.: Arctic sea ice decline: Faster than forecast, *Geophys. Res. Lett.*, 34(9), doi.org/10.1029/2007GL029703, 2007.
- Stroeve, J., Serreze, M., Drobot, S., Gearheard, S., Holland, M., Maslanik, J., Meier, W., and Scambos, T.: Arctic sea ice extent plummets in 2007. *Eos, Transactions American Geophysical Union*, 89(2), 13-14, doi.org/10.1029/2008eo020001, 2008.
- Svendsen, E., Matzler, C., Grenfell, T.C., 1987. A model for retrieving total sea ice concentration from a spaceborne dual-polarized passive microwave instrument operating near 90 GHz. *Int. J. Remote Sens.* 8, 1479 - 1487.
- Swift, C.T., Cavalieri, D.J., 1985. Passive microwave remote sensing for sea ice research. *Eos, Trans. Am. Geophys. Union* 66, 1210 - 1212.
- Tieleman, T. and Hinton, G.: Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude, *COURSERA Neural networks Mach. Learn.*, 4(2), 26 - 31, 2012.
- Tietsche, S., Notz, D., Jungclaus, J. H. and Marotzke, J.: Recovery mechanisms of Arctic summer sea ice, *Geophys. Res. Lett.*, 38(2), doi:10.1029/2010gl045698, 2011.
- Tilling, R. L., Ridout, A., Shepherd, A., and Wingham, D. J.: Increased Arctic sea ice volume after anomalously low melting in 2013, *Nature Geosci*, 8, 643-646, 10.1038/ngeo2489
- Timmermann, R., Danilov, S., Schröter, J., Böning, C., Sidorenko, D. and Rollenhagen, K.: Ocean circulation and sea ice distribution in a finite element global sea ice--ocean model, *Ocean Model.*, 27(3 - 4), 114 - 129, doi:10.1016/j.ocemod.2008.10.009, 2009.
- Trigueros, D. S., Meng, L., and Hartnett, M.: Enhancing convolutional neural networks for face recognition with occlusion maps and batch triplet loss, *Image Vision Comput.*, 79, 99-108, doi.org/10.1016/j.imavis.2018.09.011, 2018.
- Trishchenko, A.P., Luo, Y., Khlopenkov, K. V., 2006. A method for downscaling MODIS

- land channels to 250-m spatial resolution using adaptive regression and normalization, in: Remote Sensing for Environmental Monitoring, GIS Applications, and Geology VI. p. 636607.
- Wang, L., Scott, K. A., Xu, L. and Clausi, D. A.: Sea ice concentration estimation during melt from dual-pol SAR scenes using deep convolutional neural networks: A case study, *IEEE Trans. Geosci. Remote Sens.*, 54(8), 4524 - 4533, doi:10.1109/tgrs.2016.2543660, 2016.
- Wang, L., Scott, K. and Clausi, D.: Sea ice concentration estimation during freeze-up from SAR imagery using a convolutional neural network, *Remote Sens.*, 9(5), 408, doi:10.3390/rs9050408, 2017.
- Wang, L., Scott, K., Clausi, D., 2017. Sea ice concentration estimation during freeze-up from SAR imagery using a convolutional neural network. *Remote Sens.* 9, 408. <https://doi.org/10.3390/rs9050408>
- Wang, L., Scott, K.A., Xu, L., Clausi, D.A., 2016. Sea ice concentration estimation during melt from dual-pol SAR scenes using deep convolutional neural networks: A case study. *IEEE Trans. Geosci. Remote Sens.* 54, 4524 - 4533. <https://doi.org/10.1109/tgrs.2016.2543660>
- Wang, L., Yuan, X., Ting, M., and Li, C.: Predicting summer Arctic sea ice concentration intraseasonal variability using a vector autoregressive model., *J. Climate.*, 29(4), 1529-1543., doi: 10.1175/JCLI-D-15-0313.1, 2016.
- Weingartner, T., Aagaard, K., Woodgate, R., Danielson, S., Sasaki, Y., and Cavalieri, D.: Circulation on the north central Chukchi Sea shelf, *Deep Sea Research Part II: Topical Studies in Oceanography*, 52, 3150-3174, <http://doi.org/10.1016/j.dsr2.2005.10.015>, 2005.
- Wernecke, A., and Kaleschke, L.: Lead detection in Arctic sea ice from CryoSat-2: quality assessment, lead area fraction and width distribution, *The Cryosphere*, 9, 1955-1968, 10.5194/tc-9-1955-2015, 2015.
- Willmes, S., and Heinemann, G.: Sea-Ice Wintertime Lead Frequencies and Regional Characteristics in the Arctic, 2003 - 2015, *Remote Sensing*, 8, 4, 2016.
- Wingham, D. J., Francis, C. R., Baker, S., Bouzinac, C., Brockley, D., Cullen, R., de Chateau-Thierry, P., Laxon, S. W., Mallow, U., Mavrocordatos, C., Phalippou, L., Ratier, G., Rey, L., Rostan, F., Viau, P., and Wallis, D. W.: CryoSat: A mission to determine the fluctuations in Earth's land and marine ice fields, *Advances in Space Research*, 37, 841-871, <http://dx.doi.org/10.1016/j.asr.2005.07.027>, 2006.
- Winter, M. E.: N-FINDR: an algorithm for fast autonomous spectral end-member

- determination in hyperspectral data, 1999, 266–275,
- Woodgate, R. A., Aagaard, K., and Weingartner, T. J.: Interannual changes in the Bering Strait fluxes of volume, heat and freshwater between 1991 and 2004, *Geophysical Research Letters*, 33, n/a–n/a, 10.1029/2006GL026931, 2006.
- Woodgate, R. A., Weingartner, T., and Lindsay, R.: The 2007 Bering Strait oceanic heat flux and anomalous Arctic sea-ice retreat, *Geophysical Research Letters*, 37, n/a–n/a, 10.1029/2009GL041621, 2010.
- Yoo, C., Han, D., Im, J., Bechtel, B.: Comparison between convolutional neural networks and random forest for local climate zone classification in mega urban areas using Landsat images. *ISPRS J. Photogramm. Remote Sens.*, 157, 155–170, 2019.
- Yoo, C., Im, J., Park, S. and Quackenbush, L. J.: Estimation of daily maximum and minimum air temperatures in urban landscapes using MODIS time series satellite data, *ISPRS J. Photogramm. Remote Sens.*, 137, 149 - 162, doi:10.1016/j.isprsjprs.2018.01.018, 2018.
- Yu, L., Zhong, S., Winkler, J. A., Zhou, M., Lenschow, D. H., Li, B., Wang, X. and Yang, Q.: Possible connections of the opposite trends in Arctic and Antarctic sea-ice cover, *Sci. Rep.*, 7, 45804, doi:10.1038/srep45804, 2017.
- Yuan, X., Chen, D., Li, C., Wang, L. and Wang, W.: Arctic sea ice seasonal prediction by a linear Markov model, *J. Clim.*, 29(22), 8151 - 8173, doi:10.1175/jcli-d-15-0858.1, 2016.
- Zakharova, E. A., Fleury, S., Guerreiro, K., Willmes, S., Rémy, F., Kouraev, A. V., and Heinemann, G.: Sea Ice Leads Detection Using SARAL/AltiKa Altimeter, *Marine Geodesy*, 38, 522–533, 10.1080/01490419.2015.1019655, 2015.
- Zakhvatkina, N., Smirnov, V., Bychkova, I., 2019. Satellite SAR Data-based Sea Ice Classification: An Overview. *Geosciences* 9, 152.
- Zhang, E., Liu, L., and Huang, L.: Automatically delineating the calving front of Jakobshavn Isbræ from multi-temporal TerraSAR-X images: a deep learning approach, *The Cryosphere Discuss.*, doi.org/10.5194/tc-2019-14, in review, 2019.
- Zhang, J., Lindsay, R., Schweiger, A. and Steele, M.: The impact of an intense summer cyclone on 2012 Arctic sea ice retreat, *Geophys. Res. Lett.*, 40(4), 720 - 726, doi:10.1002/grl.50190, 2013.
- Zorteza, M., and Plaza, A.: A Quantitative and Comparative Analysis of Different Implementations of N-FINDR: A Fast Endmember Extraction Algorithm, *IEEE Geoscience and Remote Sensing Letters*, 6, 787–791, 10.1109/LGRS.2009.2025520, 2009.

Zygmuntowska, M., Khvorostovsky, K., Helm, V., and Sandven, S.: Waveform classification of airborne synthetic aperture radar altimeter over Arctic sea ice, *The Cryosphere*, 7, 1315-1324, 10.5194/tc-7-1315-2013, 2013.

