

Letter

북극 해빙표면온도 산출을 위한 Automated Machine Learning과 Deep Neural Network의 적용성 평가

박성우 ^{ID 1)} · 성노훈 ^{ID 2)} · 심수영 ^{ID 3)} · 정대성 ^{ID 3)} ·
우종호 ^{ID 4)} · 김나연 ^{ID 1)} · 김홍희 ⁵⁾ · 한경수 ^{ID 6)*}

Applicability Evaluation of Automated Machine Learning and Deep Neural Networks for Arctic Sea Ice Surface Temperature Estimation

Sungwoo Park ^{ID 1)} · Noh-Hun Seong ^{ID 2)} · Suyoung Sim ^{ID 3)} · Daeseong Jung ^{ID 3)} ·
Jongho Woo ^{ID 4)} · Nayeon Kim ^{ID 1)} · Honghee Kim ⁵⁾ · Kyung-Soo Han ^{ID 6)*}

Abstract: This study utilized automated machine learning (AutoML) to calculate Arctic ice surface temperature (IST). AutoML-derived IST exhibited a strong correlation coefficient (R) of 0.97 and a root mean squared error (RMSE) of 2.51K. Comparative analysis with deep neural network (DNN) models revealed that AutoML IST demonstrated good accuracy, particularly when compared to Moderate Resolution Imaging Spectroradiometer (MODIS) IST and ice mass balance (IMB) buoy IST. These findings underscore the effectiveness of AutoML in enhancing IST estimation accuracy under challenging polar conditions.

Keywords: Arctic, Automated machine learning, Ice surface temperature

요약: 본 연구는 북극의 해빙표면온도(ice surface temperature, IST)를 자동화된 기계 학습(automated machine learning, AutoML) 기반으로 산출하였다. AutoML 기반 IST는 상관관계(correlation coefficient, R) 0.97, 평균 제곱

Received November 24, 2023; Revised November 28, 2023; Accepted December 2, 2023; Published online December 31, 2023

¹⁾ 부경대학교 지구환경시스템과학부 공간정보시스템공학전공 석사과정생(Master Student, Major of Spatial Information Engineering, Division of Earth Environmental Science, Pukyong National University, Busan, Republic of Korea)

²⁾ 부경대학교 지오메틱연구소 전임연구원(Researcher, Geomatics Research Institute, Pukyong National University, Busan, Republic of Korea)

³⁾ 부경대학교 지구환경시스템과학부 공간정보시스템공학전공 박사수료생(PhD Candidate, Major of Spatial Information Engineering, Division of Earth Environmental Science, Pukyong National University, Busan, Republic of Korea)

⁴⁾ 부경대학교 지구환경시스템과학부 공간정보시스템공학전공 석/박사통합과정생(Combined MS/PhD Student, Major of Spatial Information Engineering, Division of Earth Environmental Science, Pukyong National University, Busan, Republic of Korea)

⁵⁾ 아이해이트플라잉버그스(주) 연구원(Researcher, Ihateflyingbugs Inc., Seoul, Republic of Korea)

⁶⁾ 부경대학교 지구환경시스템과학부 공간정보시스템공학전공 교수(Professor, Major of Spatial Information Engineering, Division of Earth Environmental Science, Pukyong National University, Busan, Republic of Korea)

* Corresponding author: Kyung-Soo Han (kyung-soo.han@pknu.ac.kr)

Copyright © 2023 by The Korean Society of Remote Sensing. This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<https://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

근 오차(root mean squared error, RMSE) 2.51K로 산출되었다. 심층신경망(deep neural network, DNN) 모델과 비교하여 AutoML IST는 Moderate Resolution Imaging Spectroradiometer (MODIS) IST 및 ice mass balance (IMB) buoy IST와의 검증 결과에서 좋은 정확도를 보인다. 이는 어려운 극지방 조건에서 IST 추정 정확도를 향상시키는 AutoML의 효과를 강조한다.

주요어: 북극, 자동화된 기계 학습, 해빙표면온도

1. 서론

해빙표면온도(ice surface temperature, IST)는 북극 기후의 변화를 평가하는 가장 기본적인 변수로 사용된다 (Chapman and Walsh, 2007). IST는 해빙의 표면과 대기 간의 열과 수분의 교환을 제어하는 surface energy budget 변화를 통합하며(Liu et al., 2018), 북극의 잠열 및 복사 강제력 계산에 필수적인 입력변수이다(Key and Hafefliger, 1992). 따라서 극지방 기후 시스템 이해를 위해서 지속적인 IST의 시·공간 모니터링은 필수적이다(Sim et al., 2022).

극지방의 춥고 혹독한 지리적 조건으로 인한 제한적인 현장 측정으로 인해 IST를 사용하는 다양한 연구에서 위성자료를 활용하고 있다. 현재 극궤도 위성 Terra/Aqua에 탑재된 Moderate-Resolution Imaging Spectroradiometer (MODIS)에서 산출하는 IST는 split window 기법을 사용하여, 11–12 μm 파장의 밝기온도 차이를 활용하여 산출된다(Hall et al., 2001). 하지만 Riggs and Hall (2015)에 의하면 MODIS IST 알고리즘은 구름을 식별하는 과정에서 해빙을 구름으로 식별하는 오류를 가지고 있다. 이러한 문제를 해결하기 위해 기존 알고리즘 개선(Liu et al., 2018), 자료동화(Karagali et al., 2022) 등 다양한 연구가 진행되고 있다. Sim et al. (2022)의 연구에서는 대기와 해빙 간 열교환에 관련된 입력변수들을 사용한 deep neural network (DNN) 모델을 구축하여 북극 IST를 산출하고, 극야 및 구름 영역에서의 결측 문제를 해결하였다.

현재 sea surface temperature, land surface temperature 등 표면온도 산출과 관련하여 DNN 뿐만 아니라 다양한 AI를 활용한 많은 연구가 진행되고 있다(Zhao et al., 2019; Alerskans et al., 2022). AI 기반의 연구는 모델 선택 및 하이퍼파라미터(hyperparameter) 최적화와 같은 과정에서 복잡성이 발생함에 따라 많은 시간이 소요된다. 따라서 본 연구에서는 IST의 정확도를 향상시키기 위

해 automated machine learning (AutoML) 기술을 활용하였으며, 이를 통해 자동화된 프로세스로 모델 선택과 하이퍼파라미터 조정을 통해 IST를 산출하였다. DNN, AutoML 기반으로 산출된 IST는 기존 위성기반 IST 및 buoy 자료와 검증을 수행하였다.

2. 연구자료 및 방법

공간적 범위는 북극의 해빙지역($30.98^{\circ}\text{--}90^{\circ}\text{N}$, $0^{\circ}\text{--}360^{\circ}\text{S}$)이며, 시간적 범위는 2016년 1월부터 12월 31일까지 1년을 연구기간으로 설정하였다. 심층 신경망이라 불리는 DNN은 입력 층과 출력 층 사이에 여러 개의 은닉 층들로 이루어진 인공 신경망이며, 신경망의 설계 및 훈련에 초점을 맞춘 특정 접근 방식이다. AutoML은 데이터 전처리, 기계 학습 pipeline을 탐색하고 최적화를 진행함으로써 사용자의 개입의 필요성을 줄이는 것을 목표로 하는 모델이다.

Sim et al. (2022)의 DNN IST와 본 연구의 AutoML IST를 비교하기 위해 DNN IST 입력자료(Table 1)와 동일하게 연구를 진행하였다. 또한 산출된 IST의 정확성을 평가하기 위해 MODIS IST 및 Cold Regions Research and Engineering Laboratory에서 개발된 ice mass balance (IMB) buoy 자료와 비교를 진행하였다(Richter-Menge et al., 2006).

DNN에서 설정한 하이퍼파라미터는 Table 2와 같으며, AutoML은 자체적으로 하이퍼파라미터 조정을 수행한다. AutoML에서 모든 변수는 모델 자체적으로 Z-score 정규화를 적용하였다. 또한 cross validation을 5회 수행하였으며, 평가지표로 root mean squared error (RMSE)를 사용하여 최종적으로 K-nearest neighbor (KNN)가 선정되었다.

Table 1. Model input variables

Variable	Source	Spatial resolution	Temporal resolution
Ice surface temperature	MODIS/Terra	4 km	Daily
Sea ice concentration (SIC)	OISST	0.25°	Daily
2 m temperature (Ta)	ERA5 reanalysis data	0.25°	Daily
Total column water vapor (TCWV)	ERA5 reanalysis data	0.25°	Daily
Solar zenith angle (SZA)	Geometric data	0.25°	Daily
Local solar noon angle (LSN)	Geometric data	0.25°	Daily
Latitude	Geometric data	0.25°	Daily

Table 2. Selected hyperparameters in DNN

Hyperparameter	Layer	Node	Batch size	Epoch	Loss function
Setting value	32	128,128,128	32	100	Mean squared error

3. 연구결과

비교 및 검증을 수행하기 위해 선형관계의 강도와 방향을 측정할 수 있는 correlation coefficient (R), 예측 값과 관측 값 사이의 평균 오차 크기를 측정한 RMSE, 예측 값이 관측 값에서 얼마나 벗어나는지 %로 나타낸 relative root mean squared error (rRMSE), 모델이 일정한 방향으로 실제 값에서 벗어나는 경향을 반영하는 Bias를 평가지표로 사용하였다.

3.1. MODIS IST와 비교 결과

모델 기반 IST의 정확도를 평가하기 위해 테스트 데이터를 이용하여 예측한 값과 참값으로 둔 MODIS IST

를 비교하였다(Fig. 1). AutoML IST, DNN IST 각각 R (0.97, 0.96), RMSE (2.51K, 2.98K), rRMSE (0.97%, 1.15%), Bias (0.001K, -0.629K)로 나타난다. 결과를 살펴보면 AutoML과 DNN에서 예측한 IST에서 매우 높은 선형 관계와 허용 가능한 오차범위를 나타내며 통계적으로 유의미한 결과로 해석 가능하며, AutoML IST가 DNN IST에 비해 RMSE가 0.47K, rRMSE가 0.18% 낮게 나타난다.

3.2. IMB Buoy IST와 검증

본 연구에서 AI 기반 IST 산출물이 가지는 정확도 평가를 위해 MODIS IST 비교 방법과 동일하게 IMB buoy IST와 검증하였다. Fig. 2는 AutoML과 DNN을 각각 비

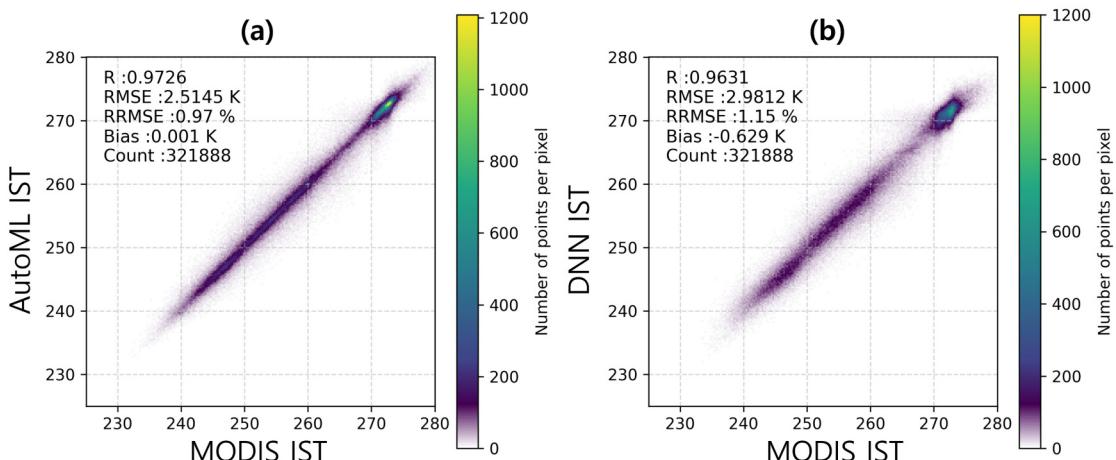


Fig. 1. Validation of estimated IST using AutoML and DNN through MODIS IST. (a) Comparison of AutoML IST and MODIS IST. (b) Comparison of DNN IST and MODIS IST.

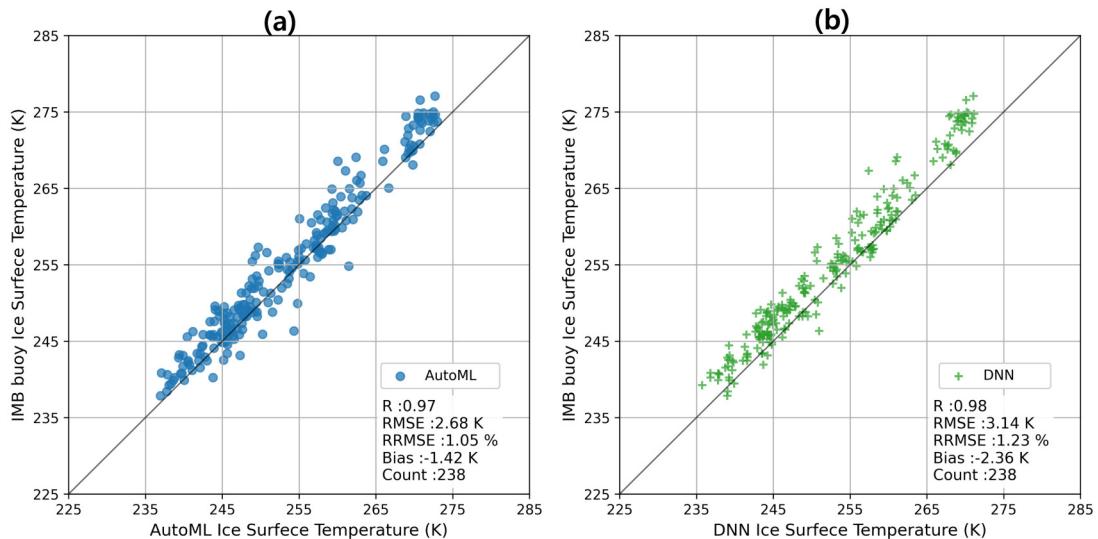


Fig. 2. Validation of estimated IST using AutoML and DNN through IMB buoy IST. (a) Comparison of AutoML IST and IMB buoy IST. (b) Comparison of DNN IST and IMB buoy IST.

교한 산포도이며, R (0.97, 0.98), RMSE (2.68K, 3.14K), rRMSE (1.05%, 1.23%), Bias (-1.42K, -2.36K)로 나타난다. 각각의 모델에서 예측된 IST는 R이 1에 가까운 높은 선형관계를 가지며, 유의미한 결과로 해석할 수 있다. 또한 AutoML IST가 DNN IST에 비해 RMSE가 0.46, rRMSE가 0.18%, Bias는 0.94K 낮은 결과를 보인다. MODIS IST는 1-3K의 정확도로 산출되고 있는데, AutoML IST는 MODIS와 비슷한 정확도로 IST를 예측하였다.

buoy IST와 비교한 결과 또한 AutoML IST에서 RMSE, rRMSE, Bias가 낮게 나타나며, MODIS IST와 유사한 정확도로 산출되었다.

본 연구에서는 IST를 AutoML과 DNN을 사용하여 산출 및 비교를 진행한 것에 의의가 있다. AutoML IST에서 MODIS와 IMB buoy와 비교한 결과가 DNN IST 보다 정확도가 높으나, DNN IST 또한 허용 가능한 오차 범위로 나타났다. 따라서 AutoML과 DNN을 활용하여 IST를 산출에 적용할 수 있다고 판단하였다.

4. 요약 및 결론

본 연구는 북극 기후 연구에 중요한 필수적인 입력 변수로 사용되는 위성기반 IST의 시·공간 연속성을 확보하기 위해 기계 학습 기반의 AutoML을 활용하여 IST 산출을 진행하였다. AutoML과 DNN 모델이 IST 산출 적용 가능성을 평가하기 위해 동일한 입력변수를 통해 동일한 방법으로 비교 및 평가를 진행하였다.

MODIS IST와 비교한 결과를 살펴보면, 각각의 모델에서 산출한 IST가 MODIS IST와 비교하여 R에서 1에 가까운 선형적인 관계와 함께 AutoML IST에서 RMSE, rRMSE, Bias가 DNN IST에 비해 낮게 나타난다. IMB

사사

이 논문은 2023년도 정부(과학기술정보통신부)의 지원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1A2C2010976).

Conflict of Interest

No potential conflict of interest relevant to this article was reported.

- | Reference | |
|--|--|
| Alerskans, E., Zinck, A. S. P., Nielsen-Englyst, P., and Høyer, J. L., 2022. Exploring machine learning techniques to retrieve sea surface temperatures from passive microwave measurements. <i>Remote Sensing of Environment</i> , 281, 113220. https://doi.org/10.1016/j.rse.2022.113220 | <i>Atmospheres</i> , 97(D5), 5885–5893. https://doi.org/10.1029/92JD00348 |
| Chapman, W. L., and Walsh, J. E., 2007. Simulations of Arctic temperature and pressure by global coupled models. <i>Journal of Climate</i> , 20(4), 609–632. https://doi.org/10.1175/JCLI4026.1 | Liu, Y., Dworak, R., and Key, J., 2018. Ice surface temperature retrieval from a single satellite imager band. <i>Remote Sensing</i> , 10(12), 1909. https://doi.org/10.3390/rs10121909 |
| Hall, D. K., Riggs, G. A., Salomonson, V. V., Barton, J. S., Casey, K., Chien, J. Y. L. et al., 2001. <i>Algorithm theoretical basis document (ATBD) for the MODIS snow and sea ice-mapping algorithms</i> . National Aeronautics and Space Administration, Goddard Space Flight Center. https://eospso.gsfc.nasa.gov/sites/default/files/atbd/atbd_mod10.pdf | Richter-Menge, J. A., Perovich, D. K., Elder, B. C., Claffey, K., Rigor, I., and Ortmeyer, M., 2006. Ice mass-balance buoys: A tool for measuring and attributing changes in the thickness of the Arctic sea-ice cover. <i>Annals of Glaciology</i> , 44, 205–210. https://doi.org/10.3189/172756406781811727 |
| Karagali, I., Barfod Suhr, M., Mottram, R., Nielsen-Englyst, P., Dybkjær, G., Ghent, D., and Høyer, J. L., 2022. A new Level 4 multi-sensor ice surface temperature product for the Greenland Ice Sheet. <i>The Cryosphere</i> , 16(9), 3703–3721. https://doi.org/10.5194/tc-16-3703-2022 | Riggs, G. A., and Hall, D. K., 2015. MODIS sea ice products user guide to collection 6.1. Available online: https://nsidc.org/sites/default/files/mod29_c61_userguide.pdf (accessed on Nov. 24, 2023). |
| Key, J., and Haefliger, M., 1992. Arctic ice surface temperature retrieval from AVHRR thermal channels. <i>Journal of Geophysical Research</i> : | Sim, S., Lee, E., Seo, M., Seong, N. H., Jeong, D., Woo, J., and Han, K. S., 2022. Deep neural network-based spatial gap-filling of MODIS ice surface temperatures over the Arctic using satellite and reanalysis data. <i>Remote Sensing Letters</i> , 13(12), 1213–1221. https://doi.org/10.1080/2150704X.2022.2138620 |
| | Zhao, W., Duan, S. B., Li, A., and Yin, G., 2019. A practical method for reducing terrain effect on land surface temperature using random forest regression. <i>Remote Sensing of Environment</i> , 221, 635–649. https://doi.org/10.1016/j.rse.2018.12.008 |