

## 계절내-계절 기후예측의 딥러닝 기반 후보정을 위한 입력자료 전처리 기법 평가

정유란<sup>1\*</sup>, 이진영<sup>2</sup>, 김미애<sup>1</sup>, 손수진<sup>1</sup>

<sup>1</sup>에이팩기후센터 기후사업본부 예측기술과, <sup>2</sup>에이팩기후센터 기후사업본부  
(2023년 04월 14일 접수; 2023년 06월 07일 수정; 2023년 06월 09일 수락)

### Investigating Data Preprocessing Algorithms of a Deep Learning Postprocessing Model for the Improvement of Sub-Seasonal to Seasonal Climate Predictions

Uran Chung<sup>1\*</sup>, Jinyoung Rhee<sup>2</sup>, Miae Kim<sup>1</sup>, Soo-Jin Sohn<sup>1</sup>

<sup>1</sup>Prediction Research Department, Climate Services and Research Division, APEC Climate Center,  
Busan, Republic of Korea

<sup>2</sup>Climate Services and Research Division, APEC Climate Center, Busan, Republic of Korea

(Received April 14, 2023; Revised June 07, 2023; Accepted June 09, 2023)

#### ABSTRACT

This study explores the effectiveness of various data preprocessing algorithms for improving subseasonal to seasonal (S2S) climate predictions from six climate forecast models and their Multi-Model Ensemble (MME) using a deep learning-based postprocessing model. A pipeline of data transformation algorithms was constructed to convert raw S2S prediction data into the training data processed with several statistical distribution. A dimensionality reduction algorithm for selecting features through rankings of correlation coefficients between the observed and the input data. The training model in the study was designed with TimeDistributed wrapper applied to all convolutional layers of U-Net: The TimeDistributed wrapper allows a U-Net convolutional layer to be directly applied to 5-dimensional time series data while maintaining the time axis of data, but every input should be at least 3D in U-Net. We found that Robust and Standard transformation algorithms are most suitable for improving S2S predictions. The dimensionality reduction based on feature selections did not significantly improve predictions of daily precipitation for six climate models and even worsened predictions of daily maximum and minimum temperatures. While deep learning-based postprocessing was also improved MME S2S precipitation predictions, it did not have a significant effect on temperature predictions, particularly for the lead time of weeks 1 and 2. Further research is needed to develop an optimal deep learning model for improving S2S temperature predictions by testing various models and parameters.

**Key words:** Sub-seasonal to seasonal predictions, Deep learning, U-Net, Feature engineering, Multi-model ensemble



\* Corresponding Author : Uran Chung  
(uchung@apcc21.org)

## I. 서 론

최근 기후예측 개선을 위한 딥러닝 모델의 개발 및 적용 연구가 증가하고 있다. 특히 단기(예, 1~3일)와 계절(예, 3~6개월) 시간 규모에 대한 연구가 활발한데, 각각의 시간 규모에서 수치모델 내 매개변수 모수화 및 자료동화, 장기 기후예측 모델 결과의 후보정(post-processing)에 대한 연구가 이루어지고 있다(Rasp and Lerch 2018; Schultz *et al.*, 2021). 일기 예보에서 물리 정보 및 신경망(neural network)을 결합한 후보정 기법을 전지구 영역으로 확장하여 강수량 예측성을 개선한 연구가 있으며(Bihlo and Popovych 2022), U-Net을 통해 중국의 여름 강수 예측성을 획기적으로 개선한 Deng *et al.*(2023)의 연구도 주목할 만 하다. 반면, 계절 내-계절(Sub-seasonal to seasonal, S2S) 시간 규모의 기후예측은 여전히 도전적인 시간 규모로 여겨지는데, 이는 장기 예측과 비교하면 알려진 예측력 원천(source of predictability)이 적고, 단기 예측과 비교하면 긴 선행시간(lead-time)으로 인해 예측 인자와의 비선형성이 증가하여 역학 모델을 통한 획기적 개선이 어렵기 때문이다(Vitart and Robertson 2018). S2S 기후예측 개선을 위해 역학 모델 결과의 통계적 후보정은 효과적인 방안이 될 수 있는데(e.g., Li *et al.*, 2021; Specq and Batte, 2020), 아직 머신러닝 또는 딥러닝 활용 연구는 드문 실정이다.

S2S 기후예측 개선을 위한 머신러닝 및 딥러닝 활용 연구가 적은 이유는 S2S 기후예측 입력자료의 전처리 기법, S2S 시간 규모 예측에 적용 가능한 딥러닝 모델이나 기술에 대한 연구 부족 등에서 찾을 수 있다. 또한, 단기나 계절 기후 예측모델 결과 자료와 달리, S2S 기후 예측모델 결과 자료는 예측자료 생산 시작일의 차이로 인해 달라지는 예측 빈도(forecast frequency), 예측 선행시간 및 기간(forecast range) 등에 대한 예측 정보 제공 기관 간의 합의된 표준이 없어 기관별로 자료의 포맷이 매우 상이하다. 이는 일반적인 사용자가 S2S 예측자료를 다루거나 후보정하는 것에 하나의 제약 요인이 되고 있다. 예를 들어, S2S 기후 예측의 대표적 두 모델인 ECMWF (European Centre for Medium-Range Weather Forecasts)와 GloSea5 (Global Seasonal forecast system version 5)의 기후변수 출력 산출물은 각 16개와 13개이며, 기후변수별로 시간 해상도가 다르다. 예측자료 생산 시작일을 기준으로 최고 및 최저기

온은 6시간 단위로 제공되고 그 외 기후변수는 일별 단위로 제공되는데 이것 또한 어떤 변수는 전일부터 제공되고 다른 변수는 익일부터(예, 시작일 다음 날) 제공되는 등, 변수 및 저장 시간 규모, 배열 형태 등이 상이하고 복잡하여 전체 자료를 바로 처리해서 활용하기 어렵다.

S2S 기후예측을 머신러닝이나 딥러닝으로 후보정하기 위해 필요한 입력자료에 대한 전처리 기법이나 특성 공학(feature engineering) 등의 기초 연구도 부족한 실정이다. 원시자료의 특성에 따라 자료의 분포나 극치를 조정하는 전처리 과정이나 목표 변수의 예측을 위해서 활용되는 입력 기후변수의 조합 및 구성은 딥러닝의 학습 과정에 중요한 영향을 미친다(Meyer *et al.*, 2018). 예를 들어, 예측 목표 변수와 무관하거나 중복된 입력 변수를 사용하는 경우 학습 알고리즘을 산만하게 하여 학습 성능을 저하시킬 수 있다. 자료 전처리를 위해 0과 1 혹은 -1에서 1사이의 값으로 자료 범위로 변형시키는 정규화 알고리즘이나(Gerritsma, 2020; Ha *et al.*, 2016; Kim *et al.*, 2022; Singh *et al.*, 2021; Son *et al.*, 2021; Xiao *et al.*, 2019; Zhang *et al.*, 2020), 각 기후변수의 평균을 빼고 표준편차로 나누는 표준화 알고리즘이 많이 사용되는데(Hong *et al.*, 2021), 그 밖의 알고리즘에 대한 검토를 통해 S2S 기후예측에 적합한 전처리 방법을 조사할 필요가 있다.

본 연구에서는 6개 개별 S2S 기후 예측모델 및 이들의 다중모델앙상블(Multi-Model Ensemble, MME)의 주별 최고 및 최저기온, 강수 예측 성능을 살펴보고, 딥러닝 기반의 기후예측에 대한 다양한 전처리 알고리즘 적용이 예측성 개선에 기여하는 바를 평가하였다. 특히, 예측 선행시간 1주를 벗어나면 예측 성능이 급격히 떨어지는 역학 모델의 한계인 2-4주 선행 예측 개선에 초점을 맞추었다. 자료 전처리 과정은 다음 2가지 관점에서 적합도를 평가하였다. 첫째, S2S 기후예측 입력 자료에 다양한 변환 알고리즘(예, 표준화 혹은 이산화 등)을 적용하여, 여러 변환 방법에 따른 훈련기간 내 훈련 효과를 비교하였다. 둘째, 선택된 변환 방법을 적용한 훈련자료로부터 목표 기후변수 예측에 중요한 영향을 미치는 기후변수(딥러닝 모델의 입력 피치)를 선별하였다. 훈련을 위해 사용한 변수 선택에 따른 예측 성능 차이를 분석함으로써, 훈련자료의 차원 감소 효과 및 목표 기후변수를 위한 특성 정보를 파악하고자 하였다.

## II. 재료 및 방법

### 2.1. 훈련자료 구축

#### 2.1.1. 계절내-계절 개별 기후모델 기반 훈련자료

본 연구에서는 S2S 기후예측 데이터베이스 내 6개 개별 기후모델의 과거 재현 예측(Hindcast) 자료를 활용하였다. 6개 개별 기후모델은 일반적으로 예측성이 가장 우수하다고 평가되는 ECMWF (European Centre for Medium-Range Weather Forecasts, de Andrade *et al.*, 2019; ECMWF, 2020; Vitart and Robertson, 2018) 부터 GloSea5 (Global Seasonal forecast system version 5, (Scaife *et al.*, 2014; Maclachlan *et al.*, 2015), ECCC (Meteorological Service of Canada), NCEP (National Centers for Environmental Prediction), CMA (China Meteorological Administration)와 UKMO (United Kingdom Met Office)로 구성된다(Table 1). 6개 개별 기후모델의 과거 재현 예측 버전은 2018년 말까지 생성된 것이며 기후변수는 최고기온(TMAX; Maximum air temperature at 2m), 최저기온(TMIN, Minimum air temperature at 2m), 평균온도(T2M, 2 meter air temperature), 평균해면기압(MSLP, Mean Sea Level Pressure), 강수(PREC, Precipitation), 해수면온도(SST, Sea surface temperature), 상향장파복사(OLR, Outgoing Longwave Radiation), 50, 200, 850hPa 동서방향 및 남북방향 풍속(U50, U200, U850, V50, V200, V850; U and V component of wind), 500hPa 연직 풍속(W500, Vertical velocity), 850hPa 비습(Q850, Specific humidity), 200 and 500hPa 지위고도(Z200, Z500; Geo-

potential height)이다. S2S 데이터베이스 내 2018년 버전에서 GloSea5(해수면온도, 상향장파복사, 850hPa 비습)와 UKMO(평균해면기압)에는 누락 변수가 있는데, 누락 변수는 무시된 상태에서 훈련자료를 구축하였다. 또한, S2S 데이터베이스 내 기후변수의 시간 해상도는 일반적으로 일별(daily) 자료로 저장되는데 최고 및 최저 기온만 예외적으로 6시간 간격으로 제공되어 이 경우 일별 자료로 단순 평균한 후 활용하였다. 공간 해상도는 전지구 공간 규모(global spatial scale)에서 1.5° 간격의 위도 121개 격자 및 경도 240개의 격자로 구성된다.

S2S 기후예측 데이터베이스 내 개별 기후모델의 과거 재현 예측 자료에서 앙상블 멤버 수(Hindcast Ensemble size), 예측 기간(Hindcast length), 예측 빈도(Hindcast frequency), 예측 선행기간(Time range) 등은 모델 간 상이하다(Table 1). 개별 기후모델의 각 앙상블은 제어 적분(control run) 결과와 섭동 적분(perturbation run) 결과로 구성되는데, 학습할 기후모델의 기후변수 개수가 증가하면 이 전체 앙상블의 크기도 증가한다. 예를 들면, ECMWF는 총 16개의 기후변수를 가지는데, 각각의 변수는 1개의 제어 적분과 10개의 섭동 적분 결과를 가지므로 전체 앙상블 멤버를 활용할 경우 훈련자료를 위한 입력변수의 규모는 총 176개(11 ensemble runs × 16 variables)로 증가하게 된다. 앙상블 크기의 증가는 합성곱 신경망(Convolutional Neural Network, CNN) 네트워크의 계산 속도를 지연시킬 수 있으므로, 본 연구에서는 전체 앙상블 분포 대신 앙상블 평균을 사용하였다. 이 외에도 전체 도메인 격자(121 × 240)와 예측 기간 및 생산 주기(20년 × 46일 × 52주)가 추가되어

**Table 1.** Brief description of six individual climate models and their MME for hindcast dataset used in this study

	Acronyms of S2S climate prediction system	Global producing center	Hindcast ensemble size	Hindcast length	Hindcast frequency	Time range (day)
Climate model	GloSea5	Seoul	3	1991-2010	4/month (1,9,17,25)	0-59
	UKMO	Exeter	7	1993-2015	4/month (1,9,17,25)	0-59
	CMA	Beijing	4	1994-2014	daily	0-59
	ECMWF	ECMWF	11	Past 20 years	2/week (Mon, Thu)	0-45
	NCEP	Washington	4	1999-2010	Daily	0-43
	ECCC	Montreal	4	1998-2014	Weekly (Thu)	0-32
Ensemble	MME	-	-	1995-2014	Weekly	0-29

구성되면, 이는 자료를 읽고 계산하는 속도 지연 등의 어려움이 발생할 수 있어 훈련자료의 변수, 기간, 주기 및 도메인 등에 대한 적절한 설정이 필요하다. Table 1에서, CMA와 NCEP의 예측 빈도(Hindcast frequency)는 매일로, NCEP을 예로 들면, 전체 도메인 격자로 구축될 경우 NCEP의 훈련자료는 20년 × 44일 × 365일 × 121 × 240으로 매우 커지게 된다. 따라서, 예측 빈도의 기준을 월 4회로 맞추기 위해, CMA와 NCEP 및 주 2회(화, 목)인 ECMWF의 예측 빈도를 목요일에 생산되는 ECCO에 맞추었다.

**2.1.2. 다중모델앙상블 기반 훈련자료**

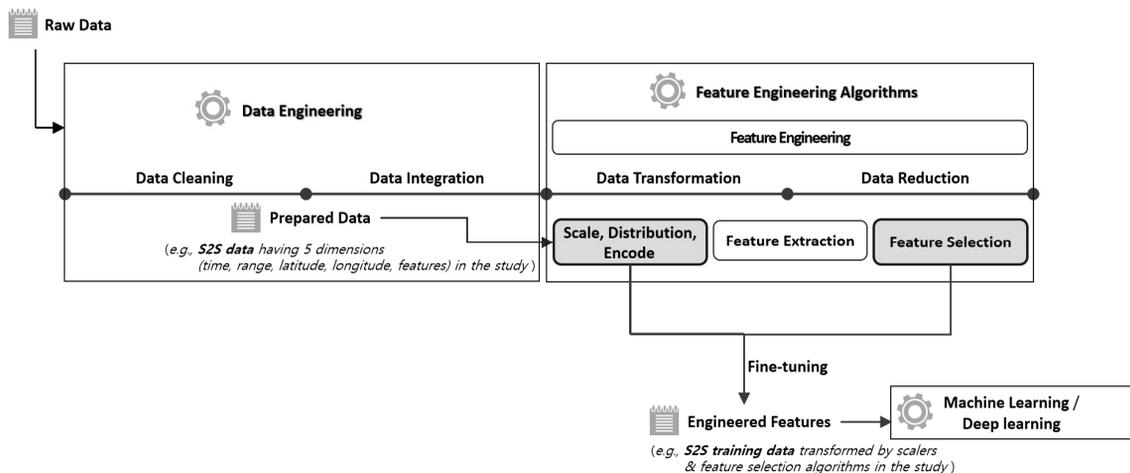
본 연구에서는 6개 개별 기후모델의 S2S 기후예측 자료를 바로 사용하여 훈련자료를 구축하는 것과 별도로, 6개 기후모델 전부를 결합(단순 평균)하여 다중모델앙상블(Multi-Model Ensemble, MME) 예측자료를 구성하였다. 개별 기후모델들의 과거 재현 예측 기간이 공통으로 포함되는 범위는 1999년에서 2010년의 12년으로, MME의 훈련 기간으로 설정하기에는 다소 짧다. 따라서, MME의 훈련 기간은 공통 기간 이전의 4년은 NCEP을 제외하고 이후의 4년은 GloSea5를 제외하더라도, 충분한 자료 기간을 확보하기 위해서 나머지 4개 개별 기후모델이 모두 배치될 수 있는 기간으로 1995년에서 2014년의 20년으로 선정하였다. MME의 예측 빈도는 ECCO의 예측 빈도에 맞추었으며, MME의 예측 선행기간(time range)은 30일로 설정하였다.

**2.1.3. 관측자료**

훈련에 사용될 참값(레이블), 즉 관측자료는 ECMWF에서 제공하는 재분석 자료 ERA5 (ECMWF Reanalysis version 5, <https://www.ecmwf.int/en/forecasts/dataset/ecmwf-reanalysis-v5>)의 일 최고기온 및 최저기온, 강수 자료를 이용하였다. 관측자료 구축에 필요한 모든 설정은 구축된 개별 기후모델의 S2S 및 MME 훈련자료와 동일하게 구성되었다.

**2.2. 전처리: 자료 변환 및 차원 감소**

전처리(preprocessing)는 입력자료를 훈련 모델이 이해할 수 있는 형태로 변환하거나 자료의 품질을 개선하는 일련의 과정으로, 특성 공학(feature engineering)이라고도 한다(Fig. 1). 전처리를 통해 자료는 여러 형태를 거치는데, 우선 원시자료(raw data)는 초기에 수집된 자료로, 분석이나 머신러닝 혹은 딥러닝 학습 용도로 전혀 처리가 되지 않은 자료이다. 정제자료(prepared data)는 결측 값 및 품질 검증(Data Engineering) 등의 처리를 거쳐 학습을 위한 자료로 만들어진 자료를 의미한다. 예를 들면, 개별 S2S 기후모델 예측 자료의 서로 다른 변수, 앙상블, 예측 기간, 빈도를 통일하고 자료 공백 등의 결함을 매워 훈련 모델이 요구하는 배열(예, 4차원 혹은 5차원 배열)로 구축된 입력자료(예, Fig. 1에서 S2S data)를 의미한다. 공학 기법이 적용된 자료(engineered feature 혹은 engineered data)는 자료 스케일링(Scaling)과 자료 변환 등의 특성 공학(feature



**Fig. 1.** A schematic diagram of data preprocessing process. The gray boxes indicate techniques among the preprocessing used in this study.

engineering) 방법들을 거쳐 재가공 된 자료이다. 예를 들어, 평균해면기압이나 연직풍속 등의 변수는 값의 범위(또는 분포)가 상이한데, 머신러닝 혹은 딥러닝 알고리즘은 대체적으로 매우 다양한 범위의 숫자형 데이터를 이용하여 학습시키는 경우 올바른 성능을 보여주지 못하는 경우가 많다. 따라서 이러한 스케일의 차(혹은 분포)가 큰 자료를 0에서 1 사이로 변환시키는 등의 방법이 있고 범주형 자료의 경우 0 혹은 1과 같은 값으로 변환(data transformation)시키는 과정이 필요한데, 이런 변환을 거친 자료를 공학 기법이 적용된 자료, 즉 훈련자료가 된다. 또한, 훈련 모델에 제공하는 입력 변수(feature)를 특성이라고도 하는데, 정제자료에는 모델을 훈련 및 예측하는데 전혀 관련이 없는 잉여 정보 혹은 잡음(noise) 등이 포함되어 있을 수 있다. 관련 없는 정보를 걸러내는 기법 중에 특성 선택(feature selection) 혹은 특성 추출(feature extraction) 알고리즘이 있는데, 이런 특성 공학을 통해 변환된 자료도 훈련자료(예, Fig. 1에서 S2S training data)이다. 자료 변환과 별개로 자료를 변형 및 축소시킨(data reduction) 후 전체 자료를 학습(training) 및 평가용(validation or test)으로 분할하는(split) 등의 과정도 전처리에 해당된다.

### 2.2.1 변환 알고리즘

기후변수 값 간 서로 다른 범위를 통일하기 위해 본 연구에서는 최고 및 최저값 간 차이로부터 자료 범위를 변형하는 MaxAbs 및 MinMax 알고리즘(Eq. 1 and 2), 평균을 빼고 표준편차로 나누는 Standard (Eq. 3), 사분 범위 혹은 분위수로부터 변환하는 Robust 및 Quantile 알고리즘(Eq. 4 and 5)을 선택하여 비교하였다.

$$\frac{x}{\max(|x|)} \quad (\text{Eq. 1})$$

$$\frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (\text{Eq. 2})$$

MaxAbs와 MinMax 알고리즘의 특징은 기본적으로 자료의 범위가 0과 1 사이가 되도록 변환해 주는데, 특히 MaxAbs는 음수가 있을 경우 -1에서 1 사이로 변환된다(Eq. 1 and 2).

$$\frac{x_i - \text{mean}(x)}{\text{sd}(x)} \quad (\text{Eq. 3})$$

Standard 알고리즘은 자료의 표준편차(sd)가 1이고 평균(mean)이 제거되어 0을 중심으로 분포가 만들어진다(Eq. 3).

$$\frac{x_i - \text{median}(x)}{Q_3(x) - Q_1(x)} \quad (\text{Eq. 4})$$

Robust 알고리즘은 중위값(median)을 0으로, 사분 범위(Q<sub>3</sub>-Q<sub>1</sub>)가 1이 되도록 변환한다(Eq. 4).

$$G^{-1}(F(x)) \quad (\text{Eq. 5})$$

Quantile 알고리즘은 분위수(G<sup>-1</sup>)와 누적분포함수(Cumulative Distribution Function, F(x)) 계산을 통해 정규 분포로 바꿔준다(Eq. 5).

### 2.2.2. 특성 선택

훈련자료에서 잉여 정보가 많으면 학습 모델의 훈련 프로세스가 느려질 수 있으며, 학습 모델의 구조가 산만해지거나 모델이 제대로 학습되지 않아서 예측성이 저하될 수 있다. 특성 선택은 중요한 변수를 선택적으로 사용하여 훈련 모델이 자료를 보다 쉽게 해석할 수 있도록 하고 훈련 시간을 단축하고 과적합(over-fitting)을 줄여줄 수 있다. 특성 선택 알고리즘에는 필터 방법(filter method), 랩퍼 방법(wrapper method), 임베드 방법(embedded method) 등이 있으며, 본 연구에서는 통계 분석을 바탕으로 특성을 선택하는 필터 방법을 사용하였다. Scikit-learn 라이브러리에서 제공하는 SelectKBest 모듈을 이용하여 목표 변수와의 상관계수를 계산하여 입력 변수의 순위를 결정하고 가장 점수가 높은 k개의 입력 변수를 최종 선택한다. 본 연구에서 구축된 가용 S2S 훈련자료의 입력 변수는 16개의 기후변수로 구성되었는데, 이 중 예측을 위한 목표 변수와의 상관계수 상위 8개 변수로 이루어진 새로운 훈련자료를 구축하였다. 여기에 임의로 몇 개의 변수를 더하거나 감하여 기후변수를 10개 이상 선택한 훈련자료와 기후변수를 7개 이하 선택된 훈련자료로 구성된 두개의 그룹을 더하여 입력 피처 조합이 다른 총 4개 훈련자료 그룹(기존 16개 기후변수를 가진 훈련자료, 10~15개 기후변수를 가진 훈련자료, 8개 기후변수를 가진 훈련자료 및 7개 이하 기후변수를 가진 훈련자료)으로 구축하였다.

### 2.3. 훈련 모델 및 훈련 환경

#### 2.3.1. 훈련 모델

U-Net 모델은 의학 영상 이미지 일부를 픽셀 단위로 분류 및 강조하여 이미지에서 개체 혹은 경계를 뚜렷하게 찾는 이미지 분할(segmentation)을 목적으로 개발된 모델이지만 최근에는 다양한 분야, 특히 기상과학 분야에서 널리 사용되고 있다(Weng and Zhu 2021; Weyn *et al.*, 2021). 따라서, 본 연구의 훈련 모델도 기후 분야의 딥러닝 연구에서 널리 사용되는 U-Net 모델을 활용하였다. U-Net 모델은 이미지의 전반적인 특징 정보를 얻기 위한 수축 형태(contracting path)의 네트워크와 정확한 지역화를 위한 팽창 형태(expanding path)의 네트워크를 U자형의 대칭 형태로 가지는데, 본 연구에서는 기본 U-Net의 합성곱 레이어(convolution layer)마다 TimeDistributed wrapper를 추가하여 5차원 입력 자료(예, samples, time, latitude, longitude, variables)의 연속적인 시계열 특성을 모델이 활용할 수 있도록 수정하였다(Fig. 2).

#### 2.3.2. 훈련 환경 및 연구 지역

MME 과거 재현 예측 기간 전체(1995~2014년)를 기반하여 80%인 1995년부터 2010년까지는 훈련 자료, 나머지 20%인 2011년부터 2014년까지는 테스트 자료로 설정하였다. K-겹 교차검증(k-fold cross-validation)은 활용할 자료가 제한적일 때 훈련과 검증자료를 효율적으로 활용할 수 있다는 장점이 있다. 또한, 파이썬은 쪼개기(numpy split) 및 섞기(shuffle) 등을 통해 자료를 효과적으로 이용할 수 있는데, 훈련자료 중에서 4겹(4-fold)으로 쪼개어 일부 자료를 검증으로 활용하였다. 단, 이때 시계열 자료가 섞이지 않도록 셔플은 사용하지 않았다. 원자료는 전지구에 대해 가용하지만 본 연구에서는 연산 속도뿐 만 아니라 동아시아 기후예측 관련 중관규모순환(대기 순환 패턴)이 고려될 수 있도록 딥러닝 훈련 모델에 입력될 때의 입력 및 출력 도메인을 경도 52°E~160°E, 위도 50°S~58°N의 동아시아 지역(1.5°로 72 × 72개 격자)으로 설정하였다(Fig. 3). 딥러닝 훈련 모델은 케라스(Keras) 및 텐서플로우(TensorFlow) 프레임워크를 사용하여 구축하였으며, 훈련 모델의 최적화를 위한 손실함수(loss function)는 평균절

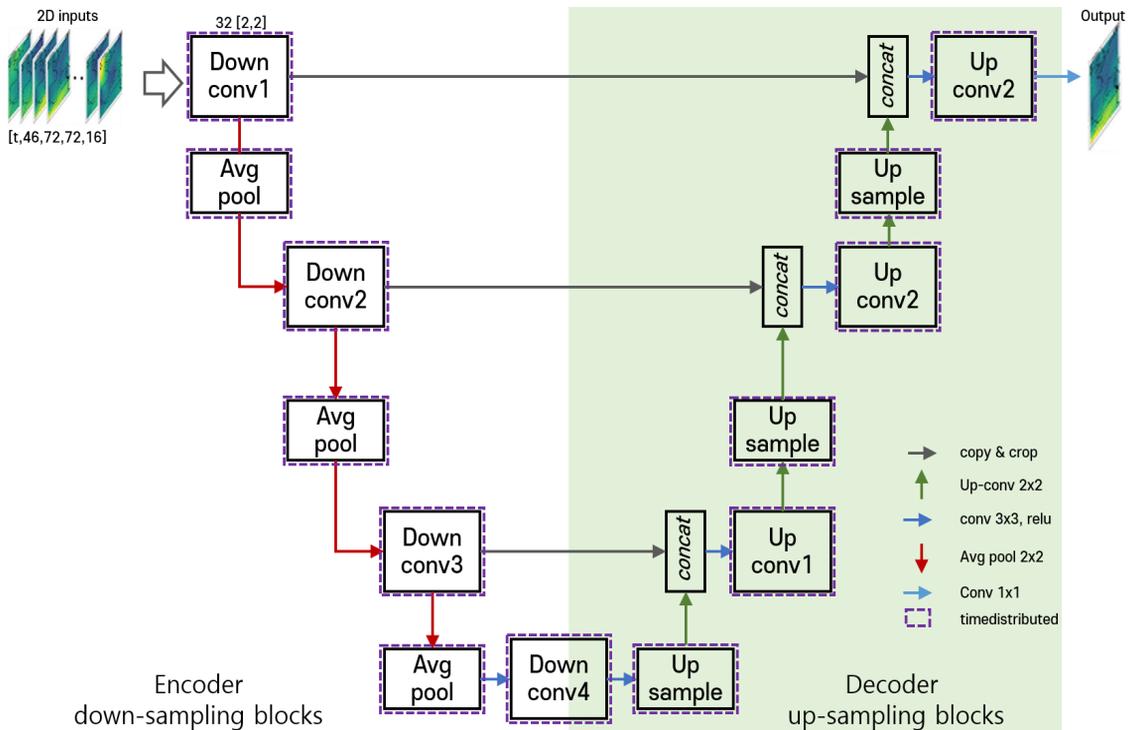
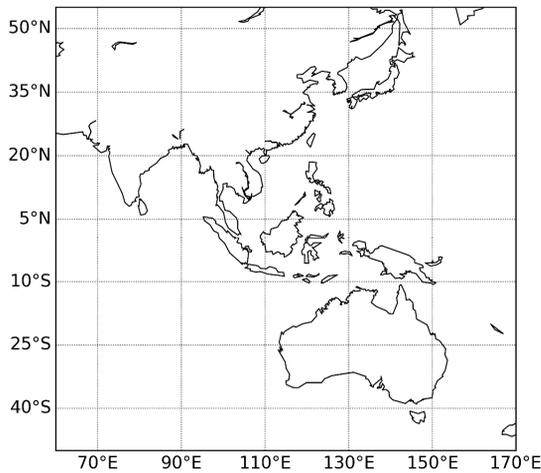


Fig. 2. Structure of U-Net wrapped by TimeDistributed layer in this study (Source of U-Net architecture from Ronneberger *et al.*, 2015 and U-net Wikipedia).



**Fig. 3.** The geographical domain of the constructed training data of S2S in this study.

대오차(Mean Square Error, MSE), 측정함수(metrics)로는 모델이 얼마나 잘 재현했는가를 평가하기 위한 코사인 유사도(cosine similarity)(He *et al.*, 2020)와 평균 평방근오차(Root Mean Square Error, RMSE)를 이용하였다. 최적의 딥러닝 모델 구현을 위해 학습률(learning rate)이나 배치 크기(batch size), 훈련 반복 횟수(epoch), 가중치 초기화 방법(optimizer) 등 선형적 지식을 기반으로 모델을 설정하는 값을 초매개변수(Hyperparameter)라고 하며, 본 연구에서 설정한 초매개변수의 기능과 설정값을 Table 2에 설명하였다. 특히 손실함수를 최소화하면서 적용 모델의 매개변수를 갱신하기 위한 최적화 함수(optimizer)는 최근 가장 성능이 좋다고 알려진 아담(Adam)을 사용하였다(Kingma and Ba, 2017).

**2.4. 공간적 예측 평가 지표**

예측 결과의 공간적 예측 정확성 및 변동성은 편차

공간상관계수(anomaly spatial Pattern Correlation Coefficient, PCC) (Lang *et al.*, 2020; Wang *et al.*, 2020)로 계산할 수 있다(Eq. 6).

$$PCC_j = \frac{\sum_{i=1}^N \Delta x_{i,j} \Delta y_{i,j}}{\sqrt{\sum_{i=1}^N \Delta x_{i,j}^2} \sqrt{\sum_{i=1}^N \Delta y_{i,j}^2}} \quad (\text{Eq. 6})$$

여기서,  $j$ 는 예측 선행기간이고  $I$ 는 격자이다.  $\Delta x_{i,j}$ 와  $\Delta y_{i,j}$ 은 격자  $I$ 에서 선행 예측기간  $j$ 의 평균 아노말리(anomaly)이다.  $N$ 은 연구지역 전체 격자 개수이다.

딥러닝 훈련 모델을 전혀 적용하지 않은 S2S 예측자료의 PCC와 비교하여, 5개 변환 알고리즘 및 차원 감소에 따른 예측 결과의 PCC의 개선 정도(예, 양 혹은 음의 값)를 쉽게 이해하기 위해 평가 지수(PCC)에 대한 개선 비율(improvement ratio)을 기술 점수(skill score)로 정의하고 평가하였다(Eq. 7, Liu *et al.*, 2021; Sadeghi *et al.*, 2020).

$$\text{Skill score} = \frac{PCC_{pred} - PCC_{raw}}{PCC_{raw}} \quad (\text{Eq. 7})$$

여기서,  $PCC_{pred}$ 는 훈련 모델에 의해 후보정된 목표변수의 예측 성능을 평가한 지수(훈련 후 평가된 PCC)이고,  $PCC_{raw}$ 는 훈련 모델에 입력하기 전, 즉 학습되지 않은 목표변수의 원시자료 예측 성능을 평가한 지수(훈련 전 평가된 PCC)이다.

**III. 결과 및 고찰**

**3.1. 훈련 모델의 학습 성능**

개별 기후모델의 일 최고, 최저기온과 강수 S2S 예측 훈련자료(1998~2014년)를 이용하여 딥러닝 훈련

**Table 2.** Explanation of hyperparameters used in this study and its values

Hyper-parameter	Function	Value in the study
Optimizer	helps to know how to change weights and learning rate of neural network to reduce the losses (e.g., Adam, SGD, RMSProp, Adagrad etc.)	Adam
Learning rate	controls how much to change the model in response to the estimated error each time the model weights are updated	0.005
Batch size	the number of samples to work through before updating the internal model parameters	80
Epoch	the number times that the learning algorithm will work through the entire training dataset	50

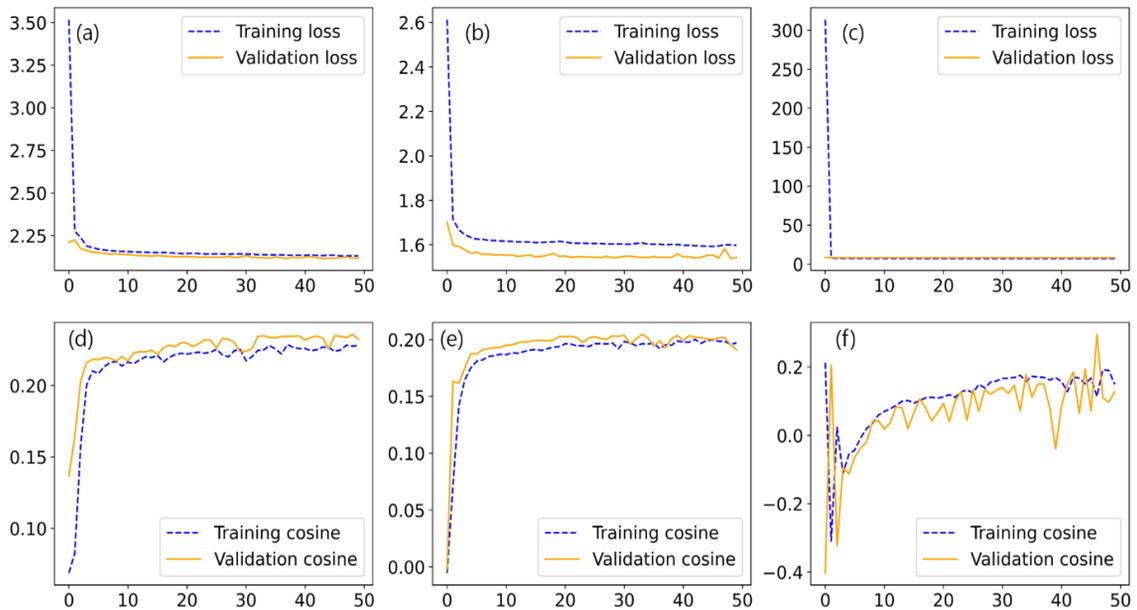
모델을 최적화하였다. ECMWF에 대해 훈련 과정 동안 K-겹 교차검증을 통해 계산된 손실함수(loss) 및 측정 함수(metrics) 변화를 살펴보았다(Fig. 4).

Fig. 4에서 위의 3개 그래프는(a, b, and c) 각각 최고 및 최저기온 및 강수량에 대한 손실함수로 계산된 MSE이고, 아래 3개 그래프는(d, e, and f) 측정함수로 재현 혹은 유사 정도를 계산한 코사인 유사도이다. 그 그래프에서 파란색 점선은 훈련 결과, 오렌지색 실선은 검증 결과를 의미한다. 일 최고 및 최저기온, 강수의 훈련 손실과 검증 손실은 대체로 균일하였는데, 일 최고기온의 훈련 및 검증 손실(Fig. 4a and d)과 강수의 훈련 및 검증 손실(Fig. 4c and f)은 차이가 거의 없고, 일 최저기온의 경우 검증 손실이 훈련 손실보다 더 작았다(Fig. 4b and e). 세 목표 변수일 최고 및 최저기온, 강수) 모두에서 훈련 손실과 검증 손실이 거의 유사한 결과를 보여줌으로써, 훈련 기간에 대한 모델의 자료 의존성이 크지 않으며 모델이 안정적으로 구축된 것을 확인할 수 있다. 일 최고 및 최저기온의 코사인 유사도는 빠르게 증가하여 Epoch 5부터 0.2 이상의 값으로

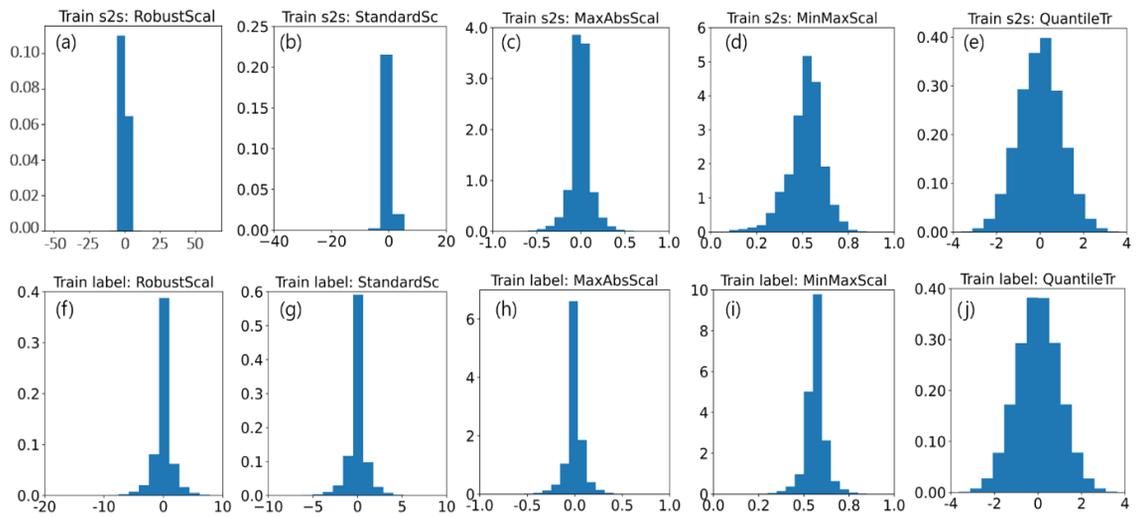
유지되면서 훈련과 검증 코사인 유사도가 대체로 균일하게 나타났고, 검증 코사인 유사도는 훈련보다 미세하게 높았다. 일 강수의 훈련 코사인 유사도는 Epoch 5 이전에서 불안정하다가 그 이후 0.1 이상의 값으로 비교적 균일하게 수렴한다. 검증의 경우 Epoch 10 이후에도 다소 불안정하게 변동하는 양상을 보인다. 즉, 성능의 수렴 과정에서 목표 변수 간 변동 양상에는 다소 차이가 보이지만, 학습과 검증 간 성능의 범위가 크게 다르지 않음을 알 수 있다. 결과적으로 학습과 검증에 대한 오차와 성능에는 목표 변수 간 약간의 차이가 보이지만, 학습 및 검증 모두에서 유사한 오차와 성능을 보임으로써 모델이 안정적으로 구축된 것을 알 수 있다.

### 3.2. 변환 알고리즘 적용에 대한 예측 성능 평가

본 연구에서 비교한 5개 자료 변환 알고리즘에 의해 변환된 ECMWF 훈련자료의 최고기온에 대한 히스토그램을 살펴보았다(Fig. 5). Fig. 5의 위 그림들은 변환 알고리즘에 의해 변환 된 ECMWF의 분포(Fig. 5a to e)이고, Fig. 5의 아래 그림들은 이 연구에서 참값으로



**Fig. 4.** Performance of the U-Net, trained and optimized in k-fold cross validation, by S2S daily anomaly of maximum and minimum air temperature, and daily precipitation during training period. (a), (b), and (c) explain training and validation MSE (Mean Square Error) calculated as loss of S2S daily anomaly of maximum and minimum air temperature and precipitation, respectively; (d), (e), and (f) indicate training and validation cosine similarity calculated as evaluation metric of S2S daily anomaly of maximum and minimum air temperature and precipitation, respectively. The blue dotted line represents the training loss and the orange solid line explains the validation loss.



**Fig. 5.** Histograms of daily maximum air temperature training data of ECMWF S2S (top) and ERA5 (bottom) converted by the five data transformation algorithms; (a) and (f) transformed by Robust algorithm, (b) and (g) by Standard, (c) and (h) by MaxAbs, (d) and (i) by MinMax, (e) and (j) by Quantile.

사용하고 있는 ERA5의 변환된 분포(Fig. 5f to j)이다. 각각의 알고리즘을 통해 변환된 S2S 훈련자료 히스토그램은 참값과 유사한 분포를 보였다.

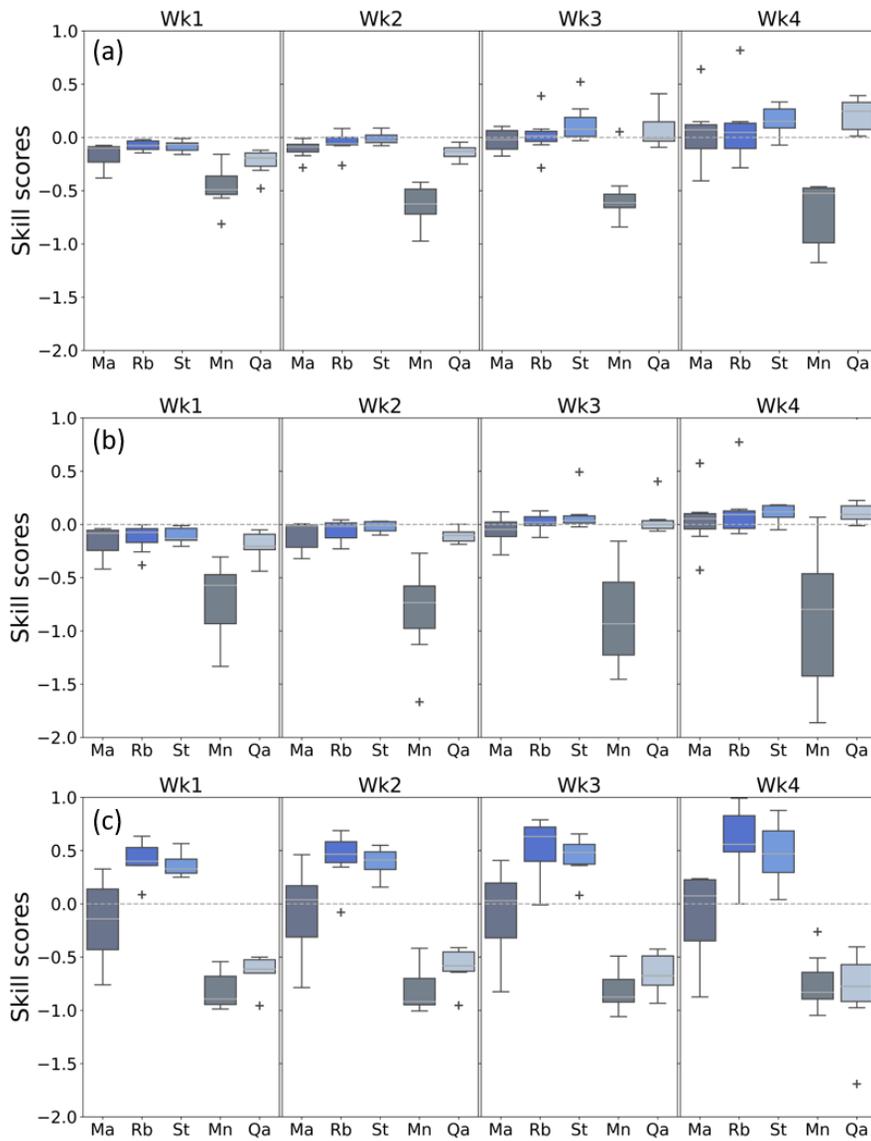
S2S 예측 결과는 일별로 주어지나, 주별로 활용되는 경우가 많으므로 예측 성능은 선행시간을 주별로 나누어 (1~4주)로 살펴보았다. 예를 들어, Table 1에서 ECMWF의 예측 선행시간(time range)은 0~45일로 46일인데, 46일을 7일 간격으로 나누면 총 6주가 된다. 그러나, 본 연구에서 ECCO와 MME의 예측 선행시간이 30~32일로 4주이므로 4주까지 비교하였다. Fig. 6은 각 변환 알고리즘에 대한 주별 PCC 개선 결과를 보여준다. 훈련 모델이 적용되지 않은 기준선(회색 점선)을 0으로 하여, 5개의 자료 변환 알고리즘(MaxAbs; Ma, Robust; Rb, Standard; St, MinMax; Mn, and Quantile; Qa)에 의해 변환된 6개 기후모델 및 MME의 훈련자료로 학습한 모델에서 예측된 결과를 기반으로 주별 PCC의 개선 비율인 상대적 기술 점수(skill score)를 상자수염도(boxplot)로 나타내었다. 기술 점수의 값이 0이면 훈련 모델이 적용되지 않은 PCC와 성능이 같아 성능 향상이나 감소가 없는 경우이며(Fig. 6의 회색 점선), 양의 값이면 훈련 모델이 적용되지 않은 PCC보다 성능 향상, 음의 값이면 성능이 감소한 것을 의미한다.

일 최고 및 최저기온의 1~2주 선행 예측에서, 변환된 훈련자료에 따라 PCC 기술 점수는 회색 점선 아래에 있다가, 3~4주 선행 예측에서는 MinMax를 제외하

고 회색 점선보다 높아지기 시작하였다(Fig. 6a and b). 이것은 후보정되지 않은 S2S 기후예측은 선행시간이 길어질수록 그 성능이 감소하며 특히 3주부터는 예측 성능이 급격히 떨어지는 것으로 알려져 있는데(Vitart and Robertson, 2018; Wang and Robertson, 2019; Mariotti *et al.*, 2018), 자료의 특징과 분포가 적절히 반영된 변환 알고리즘을 적용하고 딥러닝 훈련 모델을 통해 학습을 수행하면 역학 모델에서 예측 성능이 급격히 감소하는 선행시간의 예측 성능을 보정할 수 있음을 알 수 있다.

강수의 경우, 1주 선행시간부터 변환 알고리즘 간의 PCC 기술 점수 차이가 뚜렷하게 나타났다(Fig. 6c). MinMax와 Quantile 알고리즘에 따른 훈련자료의 PCC 기술 점수를 제외하고, MaxAbs, Robust 및 Standard의 PCC 기술 점수는 회색 점선 위에 있다. 특히 Robust와 Standard 알고리즘으로 변환된 훈련자료의 PCC 기술 점수는 1주에서 4주까지 모두 회색 점선보다 높은 수준을 유지하였다. 원시자료인 S2S 기후예측에서 강수는 기온보다 예측 성능이 상대적으로 더 떨어지는데 (Moron and Robertson, 2020; Li *et al.*, 2019), 적절한 자료 변환 알고리즘 적용 및 딥러닝 훈련 모델을 통한 후보정성이 1주 선행시간부터 그 효과를 나타낸 것으로 보인다.

세 개의 목표 기후변수에서 MinMax의 기술 점수가 모두 저조했는데, MinMax는 특정 분포(정규 혹은 가



**Fig. 6.** Comparisons of skill scores on PCC (spatial Pattern Correlation Coefficient) from U-Net model predictions on the training data of six climate models and MME (daily maximum air temperature: (a), daily minimum air temperature: (b), and daily precipitation: (c)). The five data transformation algorithms (MaxAbs: Ma, Robust: Rb, Standard: St, MinMax: Mn, and Quantile: Qu) are compared along with PCC before training (gray dotted). The symbol of the cross represents outlier.

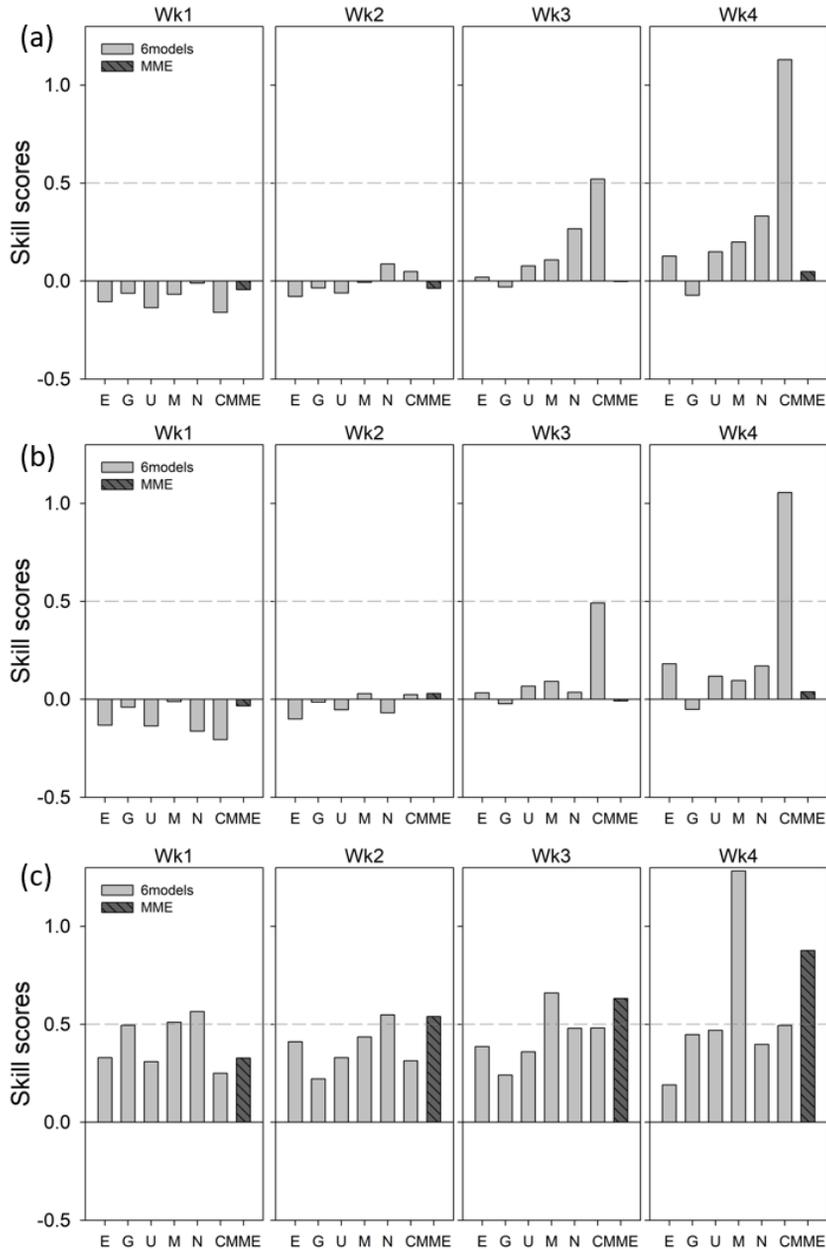
우시안을 가정하지 않고 자료의 범위를 변환하는 알고리즘이다. 그러나, S2S 기후 예측자료는 특정 분포로 설명 가능한 자료이기 때문에 MinMax가 본 연구의 S2S 기후 예측자료의 변환으로 적합하지 않아 기술 점수가 저조한 것으로 판단된다. 또한, Quantile은 일정한 개수로 나눈 구간으로 분포를 파악하는 알고리즘으로

기온과 같은 연속적인 자료에 적합하지만, 강수와 같이 불연속적인 자료에는 적용하기 어려운 변환 알고리즘으로 보인다. Robust와 Standard의 기술 점수 패턴이 기온 및 강수에서 비슷한 이유는 유사 알고리즘에서 비롯된 것으로 생각되는데, Standard를 예로 들면, Eq. 3과 4에서 median은 mean으로, 사분범위는 표준편차로

대체될 수 있는 유사 기법 때문인 것으로 보인다.

Fig. 7은 Standard 알고리즘으로 변환된 일 최고 및 최저기온과 강수 훈련자료의 PCC 기술 점수를 기후 모

델별로 비교한 것이다. 강수에서 Standard의 기술 점수가 Robust보다 낮지만, 기온의 경우 3~4주에서 Standard의 기술 점수가 높아지기 때문에(Fig. 6), 딥러닝 혼

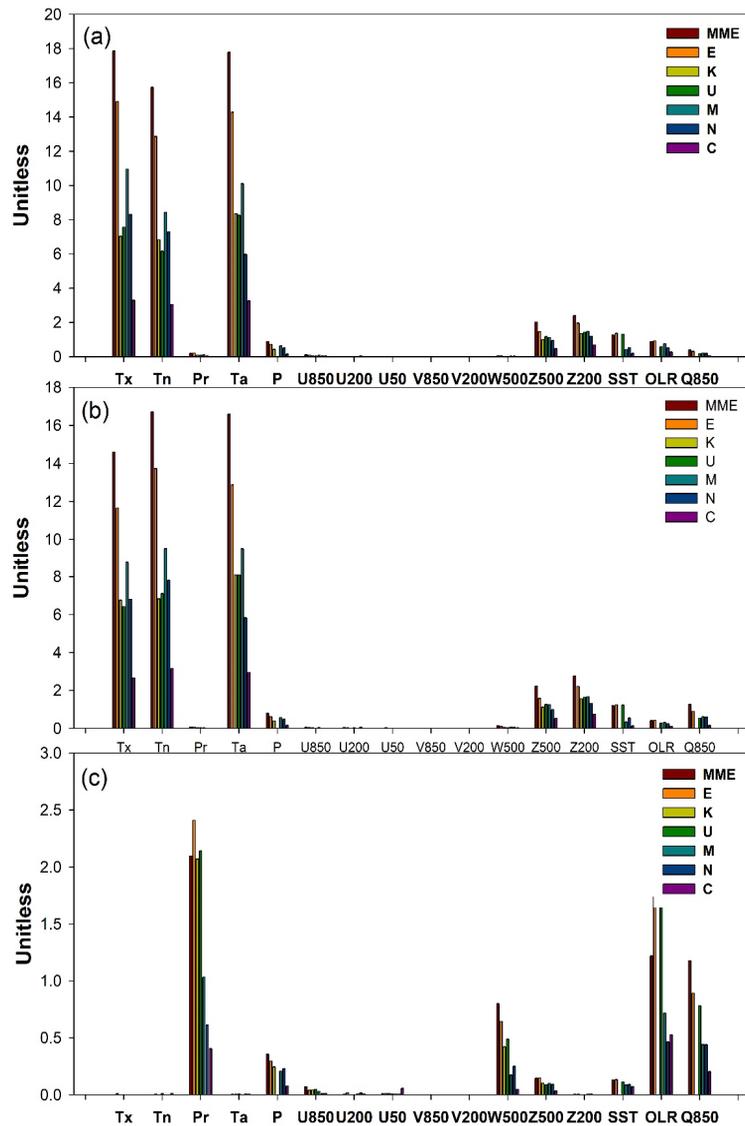


**Fig. 7.** Comparisons of skill scores on PCC (spatial Pattern Correlation Coefficient) of (a) maximum and (b) minimum air temperature, and (c) precipitation of S2S prediction of six climate models (solid bars in light) and MME (hatched bar in dark gray), postprocessed by the U-Net model with the Standard transformation algorithm for lead times of week 1 to 4. X-axis indicates six climate models (E: ECMWF, G: Seoul, U: UKMO, M: ECCC, N: NCEP, and C: CMA) and MME (Refer Table 1).

런 모델 기반 후보정을 통해 S2S 3-4주 예측성을 높이는 본 연구의 목표에 따라 Standard 변환 알고리즘을 적용한 결과를 비교하였다.

일 최고 및 최저기온의 경우 1~2주 선행 예측에서 6개 개별 기후모델과 MME의 PCC 기술 점수는 낮거나 음의 값으로 나타났대(Fig. 7a and 7b). 이것은 딥러닝 학습 모델을 통한 훈련이 S2S 일 최고 및 최저기온

개선에 기여하지 못했음을 의미한다. 그러나 ECMWF, UKMO 및 ECCC의 3~4주 선행시간에서는 기술 점수가 높아졌다. 특히 훈련 모델 적용 전의 S2S 기후예측의 예측성이 상대적으로 낮게 나타났던 개별 기후모델 (예, NCEP 혹은 CMA)의 기술 점수가 높아졌는데, 이것은 이 모델들에서 학습 모델이 적용되지 않은 PCC가 매우 낮아 딥러닝 학습을 통한 PCC와의 차이가 상대적

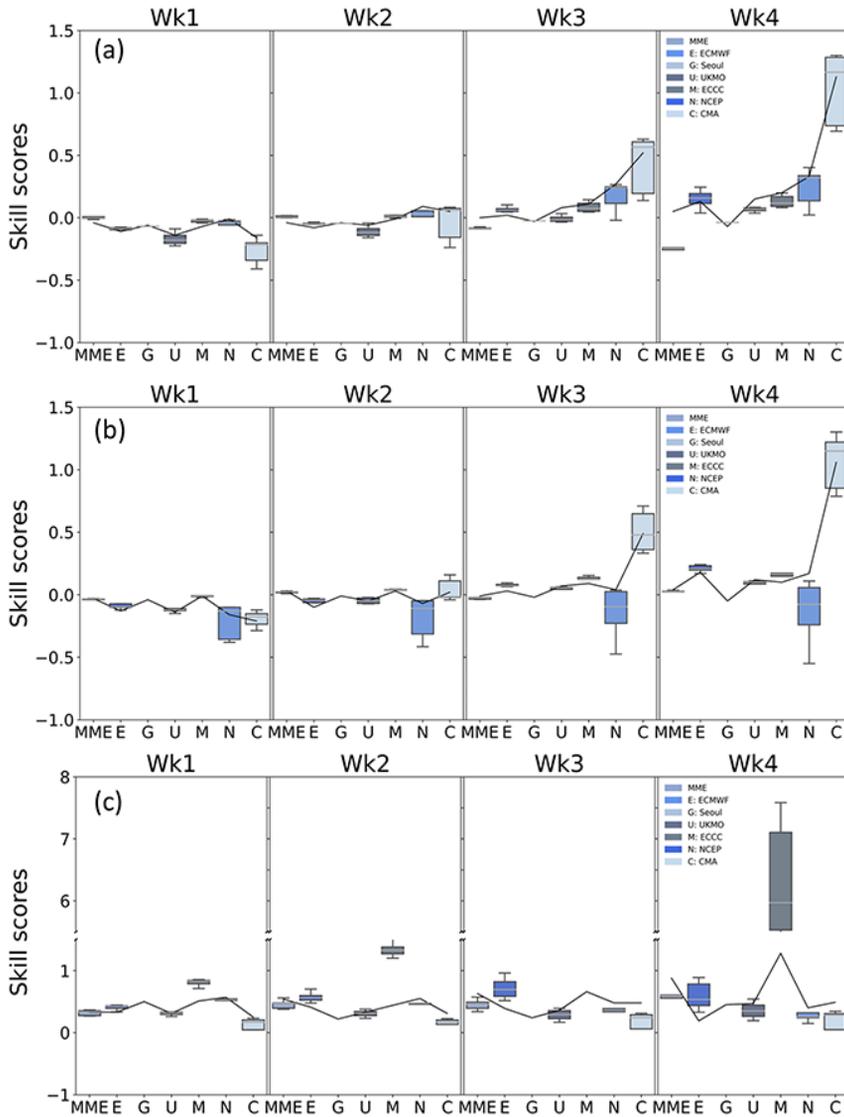


**Fig. 8.** Degree of association (unitless) of list of climate variables, from individual S2S models and MME being used in training process, with targeted variables, i.e. (a) maximum and (b) minimum air temperature, and (c) precipitation, being predicted. The abbreviations in the label are the six climate models names (E: ECMWF, G: Seoul, U: UKMO, M: ECCC, N: NCEP, and C: CMA) and MME (Refer Table 1).

으로 커졌기 때문에 기술 점수 차가 극대화된 것으로 판단된다.

강수의 경우, 예측 선행 1주에서 4주까지 모든 기후모델 및 MME의 PCC 기술 점수는 양의 값으로 나타났다 (Fig. 7c). ECCCG가 4주 예측 선행에서 매우 큰 기술 점수

를 보였는데, 이것 역시 학습 모델을 적용하지 않았을 때의 낮은 PCC와 자료 변환 및 학습 모델을 통해 후보 정된 결과의 PCC 차가 컸기 때문인 것으로 보인다. 또한, MME 일 최고 및 최저기온보다 MME 강수에서 기술 점수 향상이 크게 나타났는데, 이것은 원시 예측 성

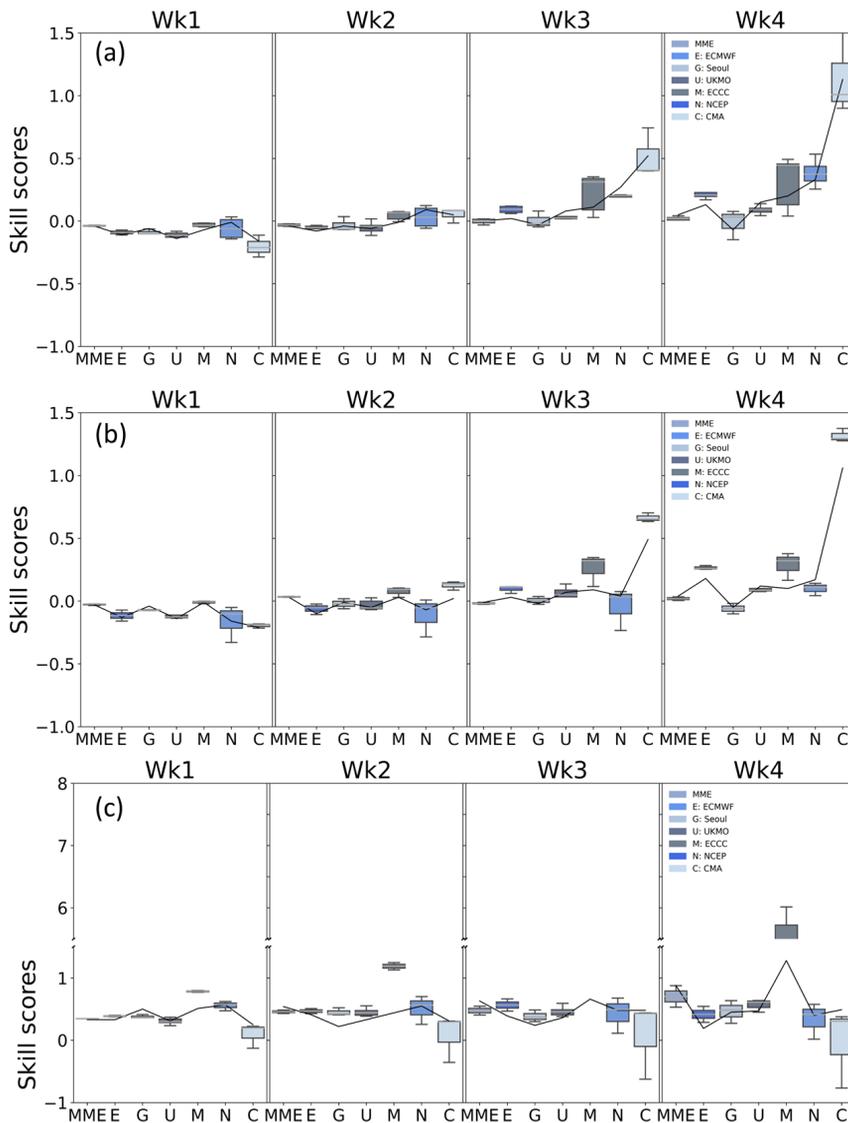


**Fig. 9.** Comparisons of skill scores on PCC (spatial Pattern Correlation Coefficient) of new training data composed of variables with a correlation rank of 10 or higher (Var10) from the training data transformed by the Standard transformation algorithm (daily maximum temperature: (a), daily minimum temperature: (b), and daily precipitation: (c)). The abbreviations on X-axis are the climate model names, such as the legend. The black solid line represents the skill score of PCC calculated from the results of training and prediction using the training data composed of all available climate variables (16 or 13) without considering correlation.

능이 상대적으로 낮은 강수량의 경우 MME를 하더라도 그 예측 성능이 제한되어 후보정이 반드시 필요함을 시사한다고 할 수 있다. 따라서, S2S 강수 예측 성능은 MME 기법 및 적합한 변환 알고리즘이 결합된 딥러닝 훈련으로 성공적으로 개선할 수 있음을 확인하였다.

### 3.3. 특성 선택 알고리즘 적용에 대한 예측 성능 평가

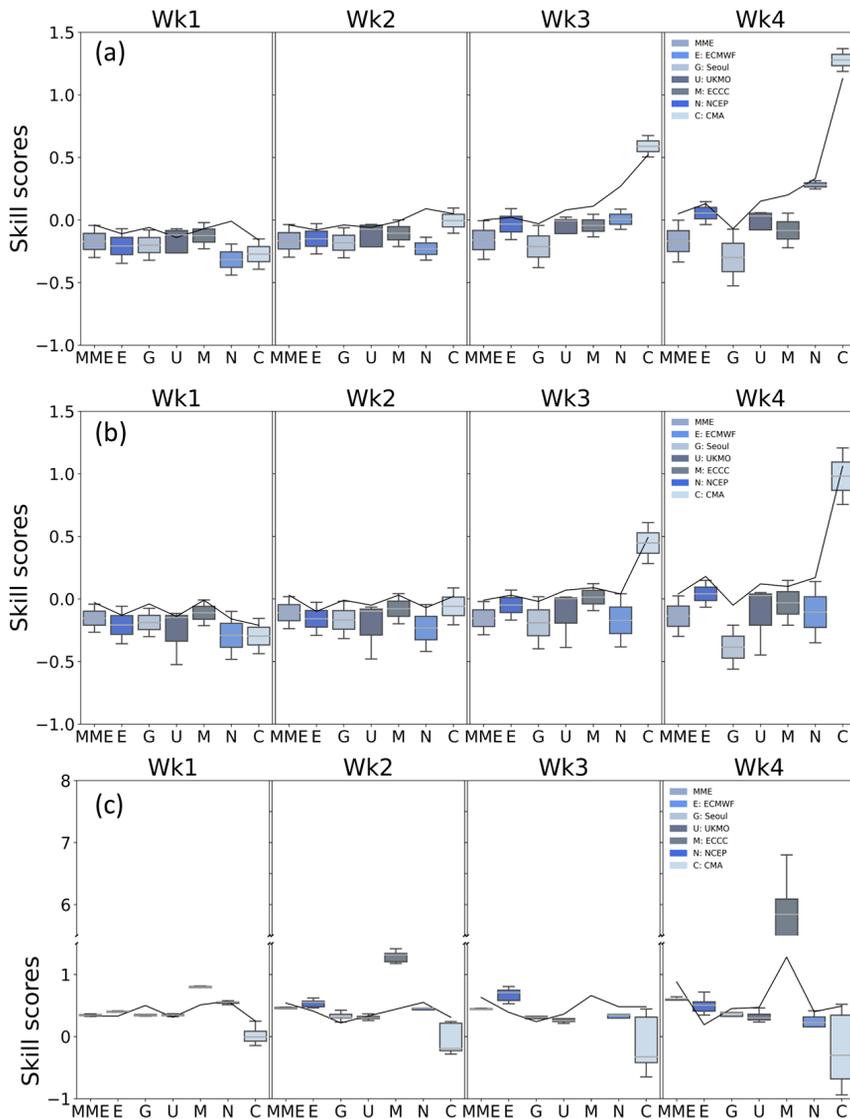
Standard 알고리즘으로부터 변환된 개별 기후모델 및 MME 기반 S2S 훈련자료와 ERA5의 훈련자료로부터 일 최고 및 최저기온, 강수 예측에 영향을 미치는



**Fig. 10.** Comparisons of skill scores on PCC (spatial Pattern Correlation Coefficient) of new training data composed of variables with a correlation rank of 8 climate variables (Var8) from the training data transformed by the Standard transformation algorithm (daily maximum temperature: (a), daily minimum temperature: (b), and daily precipitation: (c)). The abbreviations of the X-axis are the climate model names such as the legend. The black solid line represents the skill score of PCC calculated from the results of training and prediction using the training data composed of all available climate variables (16 or 13) without considering correlation.

변수들의 상관관계를 계산하였다(Fig. 8). 공통적으로 덩러닝 훈련 모델을 기반으로 예측 개선을 목표로 하는 기후변수(최고 및 최저기온, 강수)를 후보정하는 것이므로 목표 기후변수와 동일한 입력 변수들이 관련성이 가장 높은 변수로 확인되었다. 이 외에 해면기압(P),

200 및 500hPa의 지위고도(Z200, Z500), 해수면온도(SST)와 장파복사(OLR), 850hPa의 비습도(Q850)가 일 최고 및 최저기온 예측에 큰 영향을 미치는 변수들로 나타났다. S2S 일 최저기온에서는 Q850이 OLR보다 더 중요한 변수로 나타난 반면, 일 최고기온에서는



**Fig. 11.** Comparisons of skill scores on PCC (spatial Pattern Correlation Coefficient) of new training data composed of variables with a correlation rank of 7 or less climate variables (Var7) from the training data transformed by the Standard transformation algorithm (daily maximum temperature: (a), daily minimum temperature: (b), and daily precipitation: (c)). The abbreviations of the X-axis are the climate model names such as the legend. The black solid line represents the skill score of PCC calculated from the results of training and prediction using the training data composed of all available climate variables (16 or 13) without considering correlation.

반대로 OLR이 Q850보다 더 중요하게 나타났는데, 이는 최고기온이 하루 중 한낮에 나타나며 이때 상향장파복사의 강도가 큰 영향이 반영된 것으로 판단된다. 강수 예측의 경우 대기의 따뜻하고 찬 경향을 나타내는 기온 변수들은 영향이 거의 없는 것으로 나타났으며, 마찬가지로 강수(Pr)와 관련성이 가장 높고 이 외에 850hPa의 비습도(Q850), 상향장파복사(OLR), 500hPa에서의 연직풍속(W500) 및 해면기압(P) 순으로 관련성이 높은 것으로 나타났다.

Standard 알고리즘으로부터 변환된 개별 기후모델 및 MME 기반 S2S 훈련자료를 상관성 순위 7위까지 선택된 변수로 구성된 훈련자료를 Var7, 순위 8위까지 선택된 변수로 이루어진 훈련자료를 Var8, 순위 10위까지에서 선택된 변수로 만들어진 훈련자료를 Var10으로 명명하였고, 이러한 상관성을 고려하지 않고 가용 가능한 전체 기후변수(16개 혹은 13개)로 구성된 기준 훈련자료(검정 실선인 기준선)까지 총 4개 훈련자료 그룹을 준비하였다. 이들을 각각 학습 모델에서 훈련 및 예측한 결과로부터 계산한 PCC 기술 점수를 평가하였다(Fig. 9 to 11).

일 최고 및 최저기온의 경우, Var10과 Var8에서 6개 기후 모델 및 MME의 PCC 기술 점수는 1~2주 예측 선행에서 기준선(전체 기후변수 16개 혹은 13개로 구성된 기준 훈련자료의 PCC 기술 점수)과 차이가 나지 않았고, 3~4주 예측 선행에서도 ECMWF, ECCC 및 CMA가 기준선보다 다소 높아진 것을 제외하고, 대부분의 기술 점수가 기준선과 차이가 나지 않아, 특성 선택을 통한 S2S 일 최고 및 최저기온의 1~2주 예측 선행이 개선되지 않았다(Fig. 9a, and b, and Fig. 10a, and b). 더욱이, Var7일 때 PCC 기술 점수는 기준선보다 낮아지고 불확실성(boxplot depth)도 커짐으로써(Fig. 11a and b), 일정 수준까지의 특성 정보 감소는 오히려 예측성을 저하시킬 수 있는 것으로 판단된다. 이는 애초에 역학 모델 내 변수간 상관성이 아주 크지 않음지라도 후보정 과정에서 학습 정보의 원천으로 활용될 수도 있음을 시사한다. 즉, 기온의 경우 기온 자체의 특성을 가진 변수가 상대적으로 상관성이 크고, 다른 순환장 변수들은 상관성이 작아 이를 기반으로 가용 변수를 지나치게 제한하면, 기온 이외의 다른 변수들이 제외되어 기온을 기온만으로 중복 학습하는 것과 유사하게 될 수 있다. 다시 말해, 다른 순환장 변수로부터 얻을 수 있는 유의미한 정보 소실을 야기할 수 있기 때문에 기온 훈련자료에 대해 특성 공학을 적용할 때 주의할 필

요가 있을 것으로 판단된다.

강수의 경우, Var10에서 ECMWF와 ECCC의 기술 점수가 기준선보다 높았고(Fig. 9c), 특히 Var8에서 CMA를 제외한 대부분 기후모델의 기술 점수가 기준선보다 높았다(Fig. 10c). Var7의 경우, 불확실성이 증가하기는 했지만 전반적으로 Var10 및 Var8과 유사하였다(Fig. 11c). 이는 특성 선택에 의한 훈련자료의 차원 변화, 즉 상관성이 작은 변수 정보를 제거해서 훈련자료의 특성 정보를 줄여주는 것이 예측 성능 변화에 크게 영향을 미치지 않는 것을 나타낸다. 강수의 경우 훈련 모델에 의한 훈련 과정에서 순환장 변수에 의한 영향이 기온의 경우와 비교해서 상대적으로 작아 보이는데, 강수와 관련성이 높은 변수인 강수(Pr), 상향장파복사(OLR), 850hPa의 비습도(Q850)는 서로(변수) 간의 관련성이 상이하지만 강수 예측에 영향을 미치는 인자로 일관되게 포함되면서 큰 역할을 했기 때문으로 보인다.

#### IV. 결 론

계절내-계절(Subseasonal to seasonal, S2S) 시간 규모의 기후예측 후보정을 위한 딥러닝 훈련 모델의 성능을 개선하기 위하여 다양한 전처리 기법의 학습 개선 효과를 평가하였다. 후보정을 위한 대상 자료로는 6개 개별 기후모델의 S2S 훈련자료 뿐만 아니라, 여러 기후 모델을 함께 고려하여 예측 신뢰성을 증가시킬 수 있는 다중모델앙상블(Multi-Model Ensemble, MME) 기법을 통해 MME S2S 훈련자료를 활용하였다. 전처리 기법 적용의 효과를 평가하기 위해 최고 및 최저 차이를 이용하는 MinMax 및 MaxAbs 알고리즘, 표준편차를 이용하는 Standard 및 분위수를 통해 변형하는 Robust와 Quantile 알고리즘으로 구성된 입력 자료 변환 파이프라인을 구축하여 그 성능을 비교하였다. 또한, 변환된 훈련자료와 예측 목표 변수와의 상관관계를 이용해 훈련자료의 입력 차원을 줄여주는 특성 선택 알고리즘의 효과를 살펴보았다. 본 연구에서 학습 모델인 U-Net 모델에 TimeDistributed wrapper를 모든 합성곱(convolutional layer) 층에 적용하였다.

전처리된 6개 개별 기후모델 및 MME 기반 일 최고 및 최저기온과 강수 S2S 훈련자료에 대해 훈련 전과 후의 PCC 개선 비율인 기술 점수를 비교한 결과, 일 강수의 경우 Standard 및 Robust 알고리즘으로 처리했을 때 예측 선행시간 전체인 1~4주에서 예측 성능이

개선되었다. 일 최고 및 최저기온의 경우는 원시 예측 성능이 일 강수보다 높음에도 불구하고 예측 성능 개선이 예측 선행시간 3~4주에서 나타나서, 원시 예측 성능이 높은 경우에도 후보정을 통한 개선이 가능함을 보여주었다. 목표 변수가 강수인 경우 S2S 예측자료의 변수들 가운데 자기 상관을 제외하면 W500, OLR 및 Q850과 관련성이 높았으며, 목표 변수가 기온인 경우에는 동중 계열의 기온 변수(예, T2M, SST)들을 제외하면 Z200 및 Z500과 같은 대기의 두께와 관련성이 높았다. 그러나, 특성 선택을 통한 입력 변수 감소는 일 강수 예측 성능에 영향을 미치지 않는 것으로 나타났다. 반면, 일 최고 및 최저기온의 경우 입력 변수가 7개 이하인 경우에는 오히려 예측 성능이 낮아졌다. 이는 목표 변수와 관련성이 높은 동중 계열의 변수만을 활용하고 다른 변수를 제외했기 때문에 모델이 제대로 학습이 되지 않는 것으로 여겨진다. S2S 기온 예측 성능 개선을 위해서는 다른 딥러닝 훈련 모델을 적용하는 등 강수와 다른 접근이 필요할 것으로 판단된다. 후속 연구에서는 인위적으로 변수를 제한하는 훈련자료의 정제(tuning)보다는 적절한 자료 변환 알고리즘 적용, 훈련 과정에서 유의미한 정보를 탐색할 수 있는 다양한 딥러닝 훈련 모델 구축 및 파라미터 조정, 훈련 모델 최적화 및 민감도 분석 등을 통해 S2S 기후 예측 성능을 향상할 수 있는 연구가 필요하다.

## 적 요

본 연구에서는 계절내-계절(Subseasonal to seasonal, S2S) 기후예측의 주별 예측 성능을 개선하기 위해서 딥러닝 기반의 후보정(post processing) 기술을 개발하였다. 그 첫 단계로, 일 최고, 최저기온과 일 강수를 목표 변수로, 자료의 특성과 분포에 적합한 자료 변환 및 특성 공학 기법을 규명하고자 하였다. 먼저, 6개 개별 기후모델의 S2S 예측 자료를 딥러닝 모델에 입력하기 위한 훈련자료로 변환하고, 이로부터 다중모델앙상블(Multi-Model Ensemble, MME) 기반 훈련자료를 구축하였다. 참값(label)으로는 ECMWF의 ERA5 재분석 자료를 사용하였다. 자료 변환 알고리즘은 최고 및 최저 차이를 계산하여 입력자료의 범위를 변형시키는 MinMax 및 MaxAbs 변환, 표준편차를 이용하는 Standard 변환 및 분위수를 지정하여 변형하는 Robust와 Quantile 변환으로 구성된 전처리 파이프라인을 구축하였으며, 변환된 훈련자료와 예측 변수와의 상관관

계를 계산하여 순위에 따라 훈련자료의 특성을 선택하는 특성 선택 기법을 추가하였다. 본 연구는 U-Net 모델에 TimeDistributed wrapper를 모든 합성곱 층(convolutional layer)에 적용하여 활용하였다. 5개 알고리즘으로부터 변환된 6개 개별 기후모델 및 MME S2S 훈련자료(일 최고 및 최저기온, 강수)에 훈련 모델을 적용한 결과와 훈련 모델을 적용하지 않은 결과를 ERA5와의 공간상관계수(spatial Pattern Correlation Coefficient)를 계산하고 그 개선율인 기술 점수(skill score)를 평가한 결과, 일 강수의 PCC 기술 점수는 Standard 및 Robust 변환으로 처리된 것에서 전체 예측 선행(1~4주)에 대해 모두 높았고, 일 최고 및 최저기온에서는 예측 선행시간 3~4주에서만 높게 나타났다. 또한, 일 강수에서 특성 선택에 따른 훈련자료의 차원 감소가 예측 성능 변화에 영향을 미치지 않는 것으로 나타났다. 일 최고 및 최저기온의 경우에는 특성 선택에 의한 훈련자료의 특성 정보 감소가 오히려 예측 성능을 저하시킬 수 있는 것으로 확인되었으며, 원시자료에서 예측성이 높은 1~2주 기온 예측 개선을 위한 적합한 전처리 변환 알고리즘이나 특성 선택을 찾을 수 없었다. 후속 연구에서는 원시 예측 성능이 강수에 비해 높으나 딥러닝 훈련 모델에 의한 후보정 효과가 미미한 예측 선행 1~2주 기온 예측의 저조 원인에 대해 탐색하고, 다양한 딥러닝 훈련 모델로의 적용 및 초매개변수 조정 등 학습 과정의 최적화를 통해 S2S 기후 예측 성능을 개선하고자 한다.

## 감사의 글

본 연구는 APCC의 지원을 통해 수행되었습니다. 아울러, 본 연구는 S2S 데이터베이스로부터 APCC 기후센터 내 구축된 데이터 인벤토리를 활용하였습니다. 지속적으로 해당 기후예측 자료를 수집하고 갱신해 주신 연구원님께 감사드립니다.

## REFERENCES

- de Andrade, F. M., Caio A. S. Coelho, and Iracema F. A. Cavalcanti, 2019: Global precipitation hindcast quality assessment of the Subseasonal to Seasonal (S2S) prediction project models. *Climate Dynamics* **52**, 5451-5475. <https://doi.org/10.1007/s00382-018-4457-z>
- Bihlo, A., and R. O. Popovych, 2022: Physics-

- informed neural networks for the shallow-water equations on the sphere. *Journal of Computational Physics* **456**, 111024. <https://doi.org/10.1016/j.jcp.2022.111024>
- Deng, Q., P. Lu, S. Zhao, and N. Yuan, 2023: U-Net: A deep-learning method for improving summer precipitation forecasts in China. *Atmospheric and Oceanic Science Letter* **100322**. <https://doi.org/10.1016/j.aosl.2022.100322>
- ECMWF, 2020: Retrieved from. <https://doi.org/https://www.ecmwf.int/>.
- Gerritsma, A., 2020: Super-resolution neural networks: A strategy to downscale model output data. Wageningen University, 1-35. <https://edepot.wur.nl/541825>
- Ha, J.-H., Y. H. Lee, and Y.-H. Kim, 2016: Forecasting the Precipitation of the Next Day Using Deep Learning. *Journal of The Korean Institute of Intelligent System* **26**, 93-98. <https://doi.org/10.5391/jkiis.2016.26.2.093>
- He, S., X. Li, T. DelSole, P. Ravikumar, and A. Banerjee, 2020: Sub-Seasonal Climate Forecasting via Machine Learning: Challenges, *Analysis*, and Advances. *CoRR*, abs/2006.0.
- Hong S., J. H. Kim, D. S. Choi, and K. Baek, 2021: Development of Surface Weather Forecast Model by using LSTM Machine Learning Method. *Atmosphere Korean Meteorological Society* **31**, 73-83. <https://doi.org/10.14191/Atmos.2021.31.1.073>
- Kim, T., N. Ho, D. Kim, and S.-Y. Yun, 2022: Benchmark Dataset for Precipitation Forecasting by Post-Processing the Numerical Weather Prediction. <https://doi.org/10.48550/ARXIV.2206.15241>
- Kingma, D. P., and J. Ba, 2017: Adam: A Method for Stochastic Optimization.
- Lang, Y., L. Luo, A. Ye, and Q. Duan, 2020: Do CFSv2 seasonal forecasts help improve the forecast of meteorological drought over Mainland China? *Water (Switzerland)* **12**. 1-14, <https://doi.org/10.3390/w12072010>
- Li, W., J. Chen, L. Li, H. Chen, B. Liu, C.-Y. Xu, and X. Li, 2019: Evaluation and Bias Correction of S2S Precipitation for Hydrological Extremes. *Journal of Hydrometeorology* **20**. 1887-1906.
- Li, Yanzhong, D. Tian, and H. Medina, 2021: Multimodel Subseasonal Precipitation Forecasts over the Contiguous United States: Skill Assessment and Statistical Postprocessing. *Journal of Hydrometeorology* **22**, 10. 2581-2600, <https://doi.org/10.1175/JHM-D-21-0029.1>
- Liu, Y., L. Bogaardt, J. Attema, and W. Hazeleger, 2021: Extended-range arctic sea ice forecast with convolutional long short-Term memory networks. *Monthly Weather Review* **149**, 1673-1693. <https://doi.org/10.1175/MWR-D-20-0113.1>
- Maclachlan, C., and Coauthors, 2015: Global Seasonal forecast system version 5 (GloSea5): A high-resolution seasonal forecast system. *Quarterly Journal of Royal Meteorology Society* **141**. 1072-1084, <https://doi.org/10.1002/qj.2396>
- Mariotti, A., P. M. Ruti, and M. Rixen, 2018: Progress in subseasonal to seasonal prediction through a joint weather and climate community effort. *Npj Climate and Atmospheric Science* **1**, 4. <https://doi.org/10.1038/s41612-018-0014-z>
- Meyer, H., C. Reudenbach, T. Hengl, M. katurji, and T. Nauss, 2018: Improving performance of spatio-temporal learning models using forward feature selection and target-oriented validation. *Environmental Modelling & Software* **101**, 1-9. <https://doi.org/10.1016/j.envsoft.2017.12.001>
- Moron, V., and A. W. Robertson, 2020: Tropical rainfall subseasonal-to-seasonal predictability types. *npj Climate and Atmospheric Science* **3**, 4. <https://doi.org/10.1038/s41612-020-0107-3>
- Rasp, S., and S. Lerch, 2018: Neural Networks for Postprocessing Ensemble Weather Forecasts. *Monthly Weather Review* **146**, 3885-3900. <https://doi.org/10.1175/MWR-D-18-0187.1>
- Ronneberger, O., P. Fischer, and T. Brox, 2015: U-Net: Convolutional Networks for Biomedical Image Segmentation. *Climate Dynamic* **60**, 1-29. <https://doi.org/10.1007/s00382-022-06343-9>
- Sadeghi, M., P. Nguyen, K. Hsu, and S. Sorooshian, 2020: Improving near real-time precipitation estimation using a U-Net convolutional neural network and geographical information. *Environmental Modelling & Software* **134**. <https://doi.org/10.1016/j.envsoft.2020.104856>
- Scaife, A. A., and Coauthors, 2014: Skillful long-range prediction of European and North American winters. *Geophysical Research Letters* **41**, 2514-2519. <https://doi.org/10.1002/2014GL05963>
- Schultz, M. G., C. Betancourt, B. Gong, F. Kleinert, M. Langguth, L. H. Leufen, A. Mozaffari, and S. Stadler, 2021: Can deep learning beat numerical weather prediction? *Philosophical Transactions of the Royal Society A, Mathematical Physical, and Engineering Sciences* **379**. <https://doi.org/10.1098/rsta.2020.0097>
- Singh, M., B. Kumar, S. Rao, S. S. Gill, R. Chattopadhyay, R. S. Nanjundiah, and D. Niyogi,

- 2021: Deep learning for improved global precipitation in numerical weather prediction systems. **5**.
- Son, H., S. Kim, H. Yeon, Y. Kim, Y. Jang, and S. E. Kim, 2021: Visual analysis of spatiotemporal data predictions with deep learning models. *Applied Sciences* **11**. <https://doi.org/10.3390/app11135853>
- Specq, D., and L. Batte, 2020: Improving subseasonal precipitation forecasts through a statistical-dynamical approach: application to the southwest tropical Pacific. *Climate Dynamics* **55**, 1913-1927. <https://doi.org/10.1007/s00382-020-05355-7>
- Vitart, F., and A. W. Robertson, 2018: The sub-seasonal to seasonal prediction project (S2S) and the prediction of extreme events. *npj Climate and Atmospheric Science* **1**, 3. <https://doi.org/10.1038/s41612-018-0013-0>
- Wang, L., and A. W. Robertson, 2019: Week 3-4 predictability over the United States assessed from two operational ensemble prediction systems. *Climate Dynamics* **52**, 5861-5875. <https://doi.org/10.1007/s00382-018-4484-9>
- Wang, Y., H. L. Ren, F. Zhou, J. X. Fu, Q. L. Chen, J. Wu, W. H. Jie, and P. Q. Zhang, 2020: Multi-model ensemble sub-seasonal forecasting of precipitation over the Maritime Continent in Boreal Summer. *Atmosphere (Basel)*, **11**, 157-172. <https://doi.org/10.3390/atmos11050515>
- Weng, W., and X. Zhu, 2021: INet: Convolutional Networks for Biomedical Image Segmentation. *IEEE Access*, **9**, 16591-16603. <https://doi.org/10.1109/ACCESS.2021.3053408>
- Weyn, J. A., D. R. Durran, R. Caruana, and N. Cresswell-Clay, 2021: Sub-Seasonal Forecasting With a Large Ensemble of Deep-Learning Weather Prediction Models. *Journal of Advances in Modeling Earth Systems* **13**. <https://doi.org/10.1029/2021MS002502>
- Xiao, C., and Coauthors, 2019: A spatiotemporal deep learning model for sea surface temperature field prediction using time-series satellite data. *Environmental Modelling & Software* **120**, 104502. <https://doi.org/10.1016/j.envsoft.2019.104502>
- Zhang, C. J., J. Zeng, H. Y. Wang, L. M. Ma, and H. Chu, 2020: Correction model for rainfall forecasts using the LSTM with multiple meteorological factors. *Meteorological Applications* **27**, 1-15. <https://doi.org/10.1002/met.1852>