

다중모델 기반 계절내 예측 활용 가이드라인 개발
**Development of guidelines for using subseasonal
forecast based on multi-models**

**김가영¹, 김해정¹, 오지현¹, 유태우¹, 이윤영¹, 정여민¹,
정유란¹, 정유림¹, 함수련¹, 윤순조²**
기후사업본부 예측기술과¹, 기후분석과²

2019.12.

APEC기후센터

평문 초록

본 과제는 최근 각광받고 있는 계절내 규모(2주~2개월) 예측의 현재를 진단하고, 개선을 통한 미래의 가능성을 점치기 위해 기획되었으며, 그 결과로 계절내 예측의 평가/보정/활용에 대한 다양한 분석과 기술 개발이 이루어졌다. 우선, 기상청에서 현업으로 사용되고 있는 한영 공동계절예측 시스템인 GloSea5의 계절내 3-4주 예측의 성능을 종합적으로 평가하고, 구조적 오차를 파악하고자 하였다. 개별 검증 정보만으로는 실제 수준을 파악할 수 없기 때문에 타 기관 모형과 정량적인 비교가 가능하도록 메트릭을 고안하였고, 그 결과 GloSea5는 전반적인 성능에 있어 세계 최고 모형인 ECMWF 보다 다소 뒤처지나 동아시아 기온 예측에 있어서는 우위에 있음을 알 수 있었다. 또한, 기후값 계산 방식 변경에 따른 동아시아 예측성 개선 가능성을 확인하였다. GloSea5 지표온도 및 강수 예측장의 계통적 오차의 증분 특징을 살펴보기 위해 선행 시간 2주, 4주, 6주, 8주의 여름철 온도 및 강수의 오차 분포를 분석하였다. 적도 태평양에서 나타나는 강수의 오차는 서태평양을 중심으로 상대적으로 강한 대류와 연관이 있으며, 이는 결국 지표 열속의 오차와도 연결된다. 이러한 계절내 예측의 오차는 결국 계절 규모의 해양의 오차와도 직접적으로 영향을 미치고 있음을 알 수 있다. 또한, GloSea5의 동아시아 기후 모의 특성을 살펴보기 위해 기후 변동성들의 재현성 평가를 통해 오차 특성을 살펴보았다.

다양한 알고리즘의 개발, 컴퓨팅 기술의 발달, 방대한 데이터의 축적에 따라 최근 각광받고 있는 딥러닝 기술은 기후 예측 분야에서도 그 적용 가능성이 기대되고 있다. 본 연구에서는 기계학습 및 심층학습을 이용하여 계절내 예측 자료의 후처리를 통한 한반도 영역의 최고 및 최저기온 그리고 강수의 예측성 향상 가능성을 알아보고자 하였다. 그 결과, GloSea5와 ECMWF의 최고/최저기온, 강수량 3개 변수에 대해 딥러닝 기술을 적용했을 때 평방근제곱근오차 (Root Mean Square Error, RMSE)가 획기적으로 감소 (최고/최저기온 17% 이상, 강수 50% 이상)함을 확인하였다. 또한 선행주수별 분석에서는 3-4주를 포함한 전체 기간의 RMSE가 개선되었다. 딥러닝 뿐만 아니라 회귀 분석, 경험 직교 함수 등 고전 통계 방법을 활용한 모형 보정 기법 개발 역시 그 잠재성이 무한하다. 한반도 극한 기온 사상의 선행 인자인 동아시아의 기온에 대해서 모형 회귀장을 관측 회귀장으로 치환하는 방식을 적용했을 때, 선행 3주 주평균 예측에 대한 상관계수 값이 기존 예측 대비 19.4% 개선되는 효과를 확인할 수 있었다.

다소 성능이 낮고 복잡한 계절내 예측의 단점을 극복하기 위해서는 정보 가공을 통한 활용성 증대가 필요하다. 다양한 기후 모드 위상 등의 조건에 대한 성능 민감도에 기반한 동아시아 겨울 선행 3주 기온 예측 성능 추정 가이드라인을 개발하였고, 이는 성능에 대한 불확실성을 줄임으로써 매뉴얼 예보에의 활용이 기대된다. APCC는 인도양에서부터 태평양을 아우르는 아시아 지역을 일정한 주기로 움직이는 구름대에 대한 정보를 2013년부터 지속적으로 제공해 오고 있으나, 매일 하나의 값으로만 도출되어 전문적인 지식이 없다면 실제 구름대의 위치나 그 영향에 대한 공간 분포를 추정하는데 어려움이 따른다. 그래서 이 연구에서는 값을 공간장으로 변환하는 기법을 개발하였고 개발된 공간 정보는 실제 구름대의 변동과 지역적 영향을 아주 잘 표현하였다. 특히 건기보다는 우기에 구름대의 변동과 지역적 영향을 잘 나타내었다.

개발된 기법은 예측에도 적용할 수 있었고 생산된 구름대 예측 정보는 아시아 지역에 있어서 적어도 2-3주까지는 신뢰할만한 정보임을 확인하였다.

Executive Summary

This project performed a series of analysis and technique development in the verification, correction, and application of dynamic model output, thereby it aimed to diagnose the current status of subseasonal prediction and to estimate its potential for future growth.

Firstly, the basic performance of the subseasonal prediction was evaluated using an ensemble hindcast runs for 20 years (1991-2010) produced by the KMA GloSea5 model. The KMA GloSea5 model is a global prediction system for the subseasonal-to-seasonal time scale, based on the fully-coupled atmosphere, land, ocean, and sea-ice model. Overall climatology representation and real-time deterministic forecast skill of KMA prediction were verified relative to those of three other organizations (ECMWF, ECCC, and NCEP) for three variables and three regions. As expected, the general prediction skill of the GloSea5 model was worse than ECMWF, while it outperformed all three models in predicting East Asia temperature. In addition, real-time forecast skill, particularly for East Asia, could be increased when replacing the reforecast sample merging method to calculate climatology. In order to examine the forecast fidelity and reproducibility of the system, this study focused on three important aspects: systematic biases of hindcast climatology, error diagnostics related to precipitation, and prediction skill of major climate variability. The results indicate 1) the overestimated precipitation over the western Pacific, 2) precipitation errors related to the enhanced convection processes leading to decreased incoming surface heat fluxes by clouds. As a consequence, SST can be decreased by cloud-radiation processes as well as ocean mixing processes, thereby possibly affecting ENSO prediction. This study also included the evaluation and the identification of systematic biases in the global prediction model and focused on the prediction skill of East Asian summer and winter monsoon with its interaction between tropics or arctic climate, which are major drivers of weather and climate variability in East Asia.

Secondly, post-correction techniques of climate forecast using either deep learning or classical statistical methods (e.g. regression and empirical orthogonal functions) have the potential to improve S2S forecasting skills. Deep learning technology, which has recently been spotlighted, is expected to be applied in the area of climate forecasting with the development of various algorithms, computing power, and the accumulation of big data. We investigated if deep learning can improve the prediction accuracy of S2S forecast data in the Korean Peninsula. After applying the Long Short Term Memory algorithm to GloSea5 and ECMWF S2S models, the overall root-mean-square errors across the entire lead times were dramatically decreased for maximum temperature (> 17%), minimum temperature (> 17%), and precipitation (> 50%). This algorithm also decreased seasonality in S2S models, leading to stable climate forecasting throughout a year. In addition, conventional regression analysis and empirical

orthogonal function improved the 2m temperature (T2m) prediction skill of three week ahead during boreal winter over the East Asia by 19.4% relative to that of the original SCM MME.

Lastly, the techniques to improve the usability of subseasonal prediction data were developed. East Asia winter temperature is highly related to extratropical atmospheric variabilities (East Asia Winter Monsoon (EAWM), Siberian High (SH), and Arctic Oscillation (AO)), but these relationships are not always properly simulated in individual climate models and even in the Multi-Model Ensemble. Despite of poor skill in predicting climate indices, it is shown that employing those relationships has the potential to estimate the real-time forecast skill of EA T2m three weeks ahead. APCC has provided the Boreal Summer Intra-Seasonal Oscillation (BSISO) index since 2013. However, this index type information is not easy to understand what it means, so it is necessary to provide client-friendly information that could be intuitively recognized. Among three methodologies developed to transform the BSISO index into the atmospheric circulation field (BSISO impact), the composite analysis based methodology were selected because it reasonably accounted for total atmospheric intraseasonal variability. This method was superior to the other two methods in respect to all phase, season, variable, and region. The BSISO impact anomaly based on the selected method accounted for more than 30% of total variability over the Asia monsoon area and described up to 60% of total variability over the Indian and the Northwest Pacific Ocean, a source of mid-latitude climate prediction. The BSISO impact has a seasonal characteristic, which well represents atmospheric status in a wet season rather than a dry season for major monsoon areas such as Southwest monsoon, Western North Pacific monsoon, Meiyu, and Changma. Especially, the Southwest monsoon onset is a good target to exploit the BSISO impact field. The selected methodology is also highly applicable to the forecast of BSISO impact anomaly by using the BSISO index forecast. The BSISO impact forecast from the ECMWF model is more skillful than those from the other models in simulating the observed BSISO impact anomaly. For example, it provided reliable results for up to 2-3 weeks for the Asia monsoon region. Consequently, we developed a method to reconstruct BSISO related atmospheric circulation field and its local impact from index type information and this method can be applied to not only monitoring but also forecasting BSISO impact. The BSISO impact information has the potential to represent the monsoonal variability in the Asia monsoon region.

국문 요약

이 과제는 최근 수요 및 관심도가 증대되고 있는 계절내 규모 예측에 대한 평가, 보정, 활용을 위한 각종 기법 및 가이드라인을 개발하는데 그 목적이 있다.

첫 번째 목적은, 기상청에서 현업으로 사용되고 있는 한영 공동계절예측 시스템인 GloSea5의 계절내 예측에 대한 객관적 성능 평가와 모형 구조적 오차 진단이다. 지역별, 계절별, 선행 시간별로 타 기관 모형 혹은 이전 해 대한 상대적인 기후값 재현성, 실시간 예측 성능을 평가하는 체계를 구축하였고, 2018년 한 해 동안의 1-4주 선행시간에 대한 GloSea5 주평균 결정론적 검증 결과를 제시하였다. GloSea5 성능은 ECCO, NCEP과는 대체로 유사하지만 ECMWF에 비해서는 현저히 떨어지고, 2018/19년에 비해 2017/18년 겨울의 성능이 좀 더 좋았다. 전반적으로 동아시아 기온 예측성은 지위고도장에 비해서 떨어져 기온 예보 개선을 위한 노력이 필요함을 확인할 수 있다. 또한, GloSea5 과거 재현 자료 기후값을 계산하는 방식에 따른 성능 민감도를 평가하였다. 그 결과, 선행 시간을 일치시키는 방식보다 예측 날짜를 일치시키는 방식으로 기후값을 생산했을 때 동아시아의 예측 성능이 개선됨을 확인하였다. GloSea5 지표 온도 및 강수 예측장의 계통적 오차의 증분 특징을 살펴보기 위해 선행시간 2주, 4주, 6주, 8주의 여름철 (JJA) 온도 및 강수의 오차 분포를 분석하였다. ERA-Interim 재분석 자료와의 차이로 나타낸 지표 온도의 오차는 선행시간 2주의 결과에서 이미 특징적인 오차 분포가 뚜렷하게 나타난다. 다만, 적도 동태평양에서 나타나는 음의 오차는 선행시간이 길어질수록 더욱 크게 나타나며 적도 서태평양에서 나타나는 양의 오차는 선행시간이 길어질수록 더욱 약하게 나타난다. 한편, 적도 중앙 태평양의 강수 오차는 대부분 선행시간 1주에서 가장 크게 나타나고 있다. 강수의 양의 오차와 연관하여, 서태평양을 중심으로 상대적으로 강한 대류가 존재하며 줄어든 태양복사 지표도달 및 잠열로 인한 냉각 효과로 인해 음의 지표 열속 오차가 뚜렷하다. 이로 인해 선행시간이 긴 계절 규모에서 해양 연직 온도의 음의 오차가 뚜렷하며, 동태평양을 중심으로 얇은 혼합층으로 인한 해수면 냉각을 가져올 수 있다. 이는 ENSO 예측성에도 영향을 줄 수 있는 오차라고 생각되어 추후 해양 오차 성장 특성에 대해 더 연구될 필요가 있다. 한편, GloSea5의 동아시아 겨울 몬순 모의의 오차 특성을 살펴보기 위해 동아시아 겨울철 (DJF) 기후와 ENSO의 원격상관 재현성 평가를 위해 1991년-2000년(전반기, 1P)과 2001년-2010년(후반기, 2P) 두 기간으로 나누어서 분석하였다. ENSO와 동아시아 겨울 몬순과의 상관관계가 전반기에는 0.5이상의 높은 음의 상관을 보이고 있었지만, 후반기에는 0.4정도의 양의 상관으로 변화한 것이 특징이다. 동아시아 겨울 몬순 인덱스의 후반기의 낮은 성능의 패턴과 ENSO와의 상관관계의 모의 성능은 동일하게 나타나고 있으며, 이는 몬순 인덱스를 계산할 때 사용되는 상층 동서 바람의 예측 성능과도 크게 관련이 있다. 또한, 최근 ENSO의 특징이 동태평양 중심 (EP)에서 중태평양 중심 (CP)으로 변하고 있는 것과도 연관이 있을 것으로 보여 더 자세한 분석이 요구된다.

두 번째 목적은, 낮은 수준의 계절내 예측 성능 개선을 위한 모형 후보정 기법 개발이다. 딥러닝 기술은 다양한 알고리즘의 개발, 컴퓨팅 기술의 발달, 갈수록 방대해지는 데이터의 축

적에 따라 다양한 분야에서 복잡한 문제들을 해결하는데 널리 적용되고 있다. 딥러닝 기술은 기후 예측 분야에서도 예측 확률을 높여줄 수 있는 기술로 인식되고 있지만, 매우 복잡한 역학적 데이터로 구성된 기후 패턴을 예측하는 일은 방대한 데이터 축적 및 계산 집약적인 과정이기 때문에 이 분야에 대한 딥러닝 기술의 적용은 아직 초기 단계에 있다. 그러나 딥러닝 기술이 최근 강수량 등의 예측에 대한 성능 개선이 확인되면서, 기후예측 분야에서도 예측 성능개선 가능성을 보여주는 기술로 발전하고 있다. 본 연구에서는 딥러닝의 알고리즘 중 하나인 장단기기억기술(Long Short Term Memory, LSTM)을 이용하여 S2S 예측 자료의 후처리를 통한 한반도 영역의 세 개 예측 변수(최고 및 최저기온, 강수)의 예측성 향상 가능성을 알아보고자 하였다. 딥러닝 모델을 구축하기 위한 입력 자료로 지표면 평균 온도(T2M), 최고 온도(TMAX), 최저 온도(TMIN), 850 hPa 기압면에서의 동서, 남북방향 바람(U850, V850), 해면기압(MSLP), 강수(PREC) 등 ECMWF와 GloSea5 S2S 예측 결과에서 제공하는 변수 전체를 이용하였으며, 재분석 자료인 ERA-Interim 자료를 관측값으로 설정하여 딥러닝 모델을 구축하였다. 그 결과, 전체 예측 선행시간에 대한 세 기후 변수의 과거예측과 관측치간의 평방근제곱근오차(Root Mean Square Error)가 획기적으로 감소 (최고/최저기온 17% 이상, 강수 50% 이상)하였고, 선행주수별 예측에서도 전 기간에 걸쳐 RMSE가 비슷한 폭으로 개선되었다. 따라서, 딥러닝 기술이 S2S 예측 성능을 효과적으로 향상시킬 수 있음을 확인할 수 있었다. 신기술인 딥러닝뿐만 아니라 고전적인 회귀 분석, 경험적 직교 함수 기법을 활용하여 한반도 극한 기온 사상의 선행 인자인 동아시아 겨울 기온의 예측성 개선을 위한 통계적 보정 기술을 개발하였다. 이를 위해 동아시아 겨울 기온의 변동 모드, 동아시아 겨울 몬순, 태평양 제트 스트림, 시베리아 고기압, 극진동 등 다양한 기수 모드들이 예측 특성을 진단하고, 관련 동아시아 기온 반응장이 관측과 얼마나 상이한지 비교하였다. 기온 변동 모드와 동아시아 지역 평균 기온 지수에 대한 회귀장 치환 기법 적용한 결과 기존 SCM MME 대비 최대 19.4%의 ACC 성능 개선을 확인하였다.

세 번째 목표는, 계절내 예측의 낮은 성능과 복잡한 자료 구조로 인해 저조한 이용율을 극복하기 위한 예보 활용 가이드라인 개발이다. 앞서 살펴본 계절내 모형의 주평균 예측은 그 성능이 낮을 뿐만 아니라 샘플 간의 성능 격차가 매우 크다. 만약 실시간 예측 정보가 성능에 대한 추정치와 함께 제공된다면 매뉴얼 예보에서 활용성이 극대화 될 수 있을 것이다. 과거 샘플 자료 분석을 통해, 동아시아 겨울 선행 3주차 기온 예보 성능이 기후 모드, 선행 초기 성능, 예측 안정도 조건에 민감하게 반응함을 확인하였다. 뚜렷한 성능 격차가 나타나는 8개의 기후 변동 모드 교차 조건을 파악하였고, 선행 1주와 3주차 성능의 선형성, 예보 안정도에 비례하는 예측 특성 등이 확인됐다. 이를 바탕으로 실시간 예측의 성능을 3분위 카테고리에 대한 확률로 추정하는 결정트리에 관한 가이드라인을 개발하였다. 추후 실시간 예측에 대한 적용성 평가에 기반한 최적화 작업 이후, 현업 활용이 기대된다. 또한, 지수 형태로 제공되던 여름철 계절내 정보를 좀 더 직관적으로 인지할 수 있게 아시아 몬순 지역에 대한 대기 순환장(영향장)으로 만들고자하였다. 이를 위해서 지수를 공간장으로 변환시킬 기법들을 개발하였고 이 중 전체 대기 변동을 가장 적절하게 설명할 수 있는 하나의 기법을 선택하였다. 선택된 기법은 월별, 위상별, 강도별, 변수별, 지역별로도 다른 기법보다 우수함을 확인하였다. 선택된 기법을 적용한 영향장은 아시아 몬순 지역 전반에 대해서 전체 변동의 30% 이상을 설명할 수 있고 중위도 기후 예측의 원천이 될 수 있는 인도양 및 북서태평양 지역의 변동에 있어선 최대 60% 이상을 설명할 수 있었다. 선택된 기법으로 만들어진 영향장은 여름철 6개월 중 인도, 중국, 북서태평

양, 한반도 등 주요 몬순 지역마다 각각 몬순성 우기가 활발한 월에 대기 상황을 더 잘 설명하는 계절적 특성을 가지고 있어 건기에 비해 우기에 대한 활용도가 높음을 알 수 있었다. 그 중 인도 몬순에 대해서는 최근 10년 중 6번의 몬순 시작에 여름철 계절내 진동(Boreal Summer Intraseasonal Oscillation, BSISO)이 직접적인 기여를 하여 우기에 대한 BSISO 영향장의 활용 가능성을 보였다. 선정된 기법은 여름철 계절내 진동 예측 지수를 활용한다면 영향장 예보에도 적용이 가능함을 확인하였다. 특히 ECMWF의 BSISO 영향장 예보는 다른 모델의 그것에 비해 관측의 BSISO 영향장을 모의하는 능력이 더 뛰어나 아시아 몬순 지역에 있어서 적어도 2-3주까지는 신뢰할만한 BSISO 영향 정보를 제공할 수 있음을 확인하였다. 결과적으로 이 연구에서는 지수 정보에서는 유추하기 힘들었던 아시아 몬순 영역에서의 지역적인 여름철 계절내 변동을 영향장이라는 공간 정보를 통해 직관적으로 확인할 수 있는 방안을 고안하였다. 그리고 이 정보는 모니터링뿐만 아니라 예보에도 적용할 수 있어서 여름철 계절내 변동의 활동과 그 지역적 영향을 살펴보는 데 있어서 유용하게 쓰일 수 있다.

목차

평문 초록	i
Executive Summary	iii
국문 요약	v
목차	viii
표 차례	x
그림 차례	xi
1. 서론	1
2. 방법 및 자료	4
가. 자료	4
(1) 계절내 모형 자료	4
(2) 관측 자료	6
나. 방법론	6
(1) 딥러닝 기법	6
(2) BSISO 영향장 분석 기법	11
다. 기후 지수들	13
3. 결과	16
가. 계절내 모형 예측성 평가 및 오차 진단	16
(1) GloSea5 예측성능 비교 및 평가 매트릭스 개발	16
(2) GloSea5 구조적 오차 진단	37
나. 계절내 모형 예측 보정 기술 개발	58
(1) 딥러닝을 활용한 한반도 최저·최고 기온 및 강수 예측 보정 기술 개발	58
(2) 겨울철 동아시아 기온 예측 보정 기술 개발	67
다. 계절내 예측 정보 활용 가이드라인 개발	97
(1) 겨울철 동아시아 주평균 기온 예측 성능 추정 가이드라인 개발	97
(2) 다중모델 기반 BSISO 영향분석 기술 개발	101
4. 요약 및 결론	118
사사	123
References	124
부록 A. KMA 계절내 예측성능 비교·평가 매트릭 자동화 시스템 운영매뉴얼	130

부록 B. 계절내 예측모델의 기후값 재현성능(RMSE-PCC).....	141
부록 C.	142
부록 D.	151
부록 E. 동아시아 겨울 기온 선행3주 예측의 성능 추정을 위한 가이드라인.....	169
부록 F. 몬순 시작일 정의와 평가 기법.....	174
부록 G. 위상별 BSISO 영향장 비교 검증.....	177

표 차례

Table	page
1. Description of subseasonal forecast models.	5
2. Description of BSISO forecast models.	6
3. Summary of input and label data for S2S-deep learning.	11
4. Methodology for BSISO impact analysis.	13
5. EASM indices used in this study.	14
6. EAWM indices used in this study. * indicates normalized value.	15
7. Weekly RMSE before and after LSTM learning.	65
8. Four ways to reconstruct model' s T2M anomaly field over EA for 3 weeks lead time. ...	94

그림 차례

Figure	page
1. Model configuration of KMA-GloSea5.	4
2. Single-layer perceptron and multi-layer perceptron (Source: Lee, 2018).	7
3. (A) The repeating Recurrent Neural Networks.	8
4. The repeating module in a standard RNN contains a single layer (Source: http://colah.github.io/posts/2015-08-Understanding-LSTMs/).	9
5. The repeating module in an LSTM contains four interacting layers (Source: http://colah.github.io/posts/2015-08-Understanding-LSTMs/).	10
6. SVM classification algorithm (source: https://en.wikipedia.org/wiki/Support-vector_machine). ..	10
7. Conceptual diagram for BSISO impact analysis.	12
8. The structure diagram of GloSea5 Verification Framework.	17
9. An example of climatology smoothing method.	19
10. An example of calculating 1-lead week for climatology from (a) 3-models, (b) target based KMA, and (c) lead based KMA.	20
11. Scatter diagram of annual RMSE and PCC of (a) T2M, (b) PREC, and (c) Z500 for ECCC (orange), ECMWF (blue), NCEP (green), target based KMA (purple), and lead based KMA (yellow) for 1- to 4-lead week over Globe (solid line) and East Asia (dashed line).	21
12. Annual and seasonal averaged relative RMSE difference of climatology of T2M over East Asia and Globe of ECCC, ECMWF, and NCEP with target based KMA.	23
13. Same as Figure 12, except for PREC.	24
14. Same as Figure 12, except for Z500.	25
15. ACC of Global (a) T2M, (b) PREC, and (c) Z500 for 4 lead weeks of ECCC, ECMWF, NCEP, target based KMA, and lead based KMA.	26
16. ACC of East Asian (a) T2M, (b) PREC, and (c) Z500 for 4 lead weeks of ECCC, ECMWF, NCEP, target based KMA, and lead based KMA.	27
17. Annual and seasonal averaged relative ACC difference between target and lead based KMA of 2018 real-time forecast of (a) T2M, (b) PREC, and (c) Z500 over East Asia and Globe.	28
18. Scatter plot of day difference and 1-lead week ACC of (Left) T2M for MAM over globe	

(left) and PREC for JJA over East Asia (right) of target based KMA (blue) and lead based KMA (red).	29
19. Scatter plot of day difference and 2-lead (left) and 4-lead (right) week ACC of Z500 for SON in East Asia of target based KMA (blue) and lead based KMA (red).	30
20. Scatter plot of day difference and (a) 2-lead and (b) 4-lead week ACC of Z500 for JJA in East Asia of target based KMA (blue) and lead based KMA (red).	30
21. Annual and seasonal averaged relative ACC difference of 2018 real-time forecast of T2M over East Asia and Globe of (a) ECCC, (b) ECMWF, and (c) NCEP with target based KMA.	32
22. Annual and seasonal averaged relative ACC difference of 2018 real-time forecast of Z500 over East Asia and Globe of (a) ECCC, (b) ECMWF, and (c) NCEP with target based KMA.	34
23. Annual and seasonal averaged relative ACC difference between 2017 and 2018 real-time forecast of (a) T2M, (b) PREC, (c) and Z500 over East Asia and Globe of target based KMA.	36
24. Monthly averaged lead week pattern correlation coefficient (PCC) for (a)Z500, (b)U200, (c)Z200.	38
25. Horizontal distribution of 500hPa geopotential height for 10 March 1991 from (a) ERA interim reanalysis data and (b) GloSea5 initialized 9 March 1991 (1-day lead time).	38
26. Temporal correlation coefficient (TCC) of the 2m temperature between ERA interim reanalysis data and GloSea5 hindcast with (a)-(d)1-4 week lead for DJF.	39
27. Temporal correlation coefficient (TCC) of the precipitation between ERA interim reanalysis data and GloSea5 hindcast with (a)-(d)1-4 week lead for DJF.	40
28. Spatial distribution of surface temperature biases (model minus ERA interim reanalysis) of (a)-(d)2-8 week lead for 1991-2010 JJA.	41
29. Spatial distribution of averaged surface precipitation biases (model minus GPCP observation) of (a)-(d)2-8 week lead for 1997-2010 JJA.	42
30. Ratio of large-scale precipitation and convective precipitation from total precipitation.	43
31. Spatial distribution of 200hPa potential velocity and divergent wind biases (model minus ERA interim reanalysis) of (a)-(d)2-8 week lead for 1991-2010 JJA.	44
32. Magnitude of Hadley circulation. Zonal mean velocity potential at (a) 850hPa and (b) 200hPa from ERA-Interim reanalysis and GloSea5 2 (pink), 4 (green), 6 (red), and 8 (red)	

week lead.	44
33. Surface biases distribution of (a) net longwave radiation fluxes, (b) latent heat fluxes, (c) net shortwave radiation fluxes, and (d) net heat fluxes.	45
34. Difference distribution of vertical subsurface ocean temperature averaged 10N-10S between GODAS and GloSea5 with lead (a) 1 month, and (b) 3 month.	46
35. Difference distribution of 20D isothermal depth between GODAS and GloSea5 with lead (a) 1 month, and (b) 3 month.	46
36. Spatial distribution of winter SST (Nino3.4) and following spring SST (NTA region).	47
37. Time series of EASM Index calculated by ERA-Interim.	48
38. Time series of winter Nino3.4 index (black), spring NTA SST (red), and spring NTA SST with removed ENSO effect (blue).	49
39. Scatter plots of winter Nino 3.4 SST versus EASM index.	49
40. Spatial distributions of summer UV850 and PREC regressed winter Nino3.4 for same/opposite sign.	50
41. Surface temperature (shaded) and 200hPa wind (vector) regressed on the Nino 3.4 index from GloSea5 (a), (c) with lead 1 week, and (b), (d) with lead 3 week.	52
42. Surface precipitation (shaded) and 850hPa wind (vector) regressed on the Nino 3.4 index from GloSea5 (a), (c) with lead 1 week, and (b), (d) with lead 3 week.	52
43. (a) Correlation coefficient between Nino 3.4 index and East Asia monsoon index from ERA interim and GloSea5 with lead 1-4 week.	53
44. Surface temperature (shaded) and sea level pressure (contour) regressed onto the EOF 2nd PC from (a) ERA-Interim, (b) GloSea5 with lead 1 week, and (c) GloSea5 with lead 2 week.	54
45. (a) Correlation coefficient of arctic oscillation (AO) between from ERA interim and GloSea5 with lead 1-4 week.	55
46. The linear trends in surface temperature during DJF for the periods 2000-2009 from the ERA-Interim and GloSea5 with lead 1, 3 week.	56
47. Leading modes governing detrended winter sea level pressure from ERA-Interim (black solid), and GloSea5 with lead 1 (blue), 3 (red) week.	56
48. Surface temperature (shaded) and Sea level pressure (contour) regressed onto the EOF 1st PC from (a) ERA-Interim, (b) GloSea5 with lead 1 week, and (c) GloSea5 with lead 2 week.	57

49. Proposed structure 1 of deep learning.	58
50. Proposed structure 2 of deep learning.	59
51. Proposed structure 3 of deep learning.	59
52. Overall prediction performance before and after LSTM measured by RMSE.	61
53. Comparison of performance (RMSE) among machine learning algorithms.	63
54. Comparison of daily performance (RMSE) across entire forecast lead time.	64
55. Weekly RMSE before and after applying LSTM algorithms to ECMWF and GloSea5.	65
56. Seasonality of S2S-Deep learning prediction (entire forecast lead time).	66
57. Seasonality of S2S-Deep learning prediction (week 3 forecast)	66
58. (a) scatter of RMSE and ACC of weekly mean T2M over East Asia for 11 winter seasons and (closed circles in (b)) overall skill variation with 1 to 4 weeks lead times.	67
59. long term mean of weekly (a) ACC and (b) RMSE variation of weekly mean T2M over East Asia.	68
60. (a-b) spatial pattern of two leading EOF modes of T2M over East Asia (100.5° E~145.5° E, 30° N-60° N) derived from the observation and scatter of the observed and predicted PC time series corresponding to (c) 1st and (d) 2nd mode for lead times out to 4 weeks.	69
61. Power spectrum of (black dashed line) the observed and (color solid lines) the predicted PC time series corresponding to (a) 1st and (b) 2nd EOF mode of T2M over East Asia. ...	70
62. Observed (left) U200 and (right) MSLP patterns regressed onto the observed (upper) 1st and (right) 2nd PC time series. Contours display observed winter mean climatology.	71
63. (a) TCC of DJF weekly SHI between models (individual models and MME) and the observation from lead week 1 to 4.	72
64. Schematic diagram of weekly slope prediction.	73
65. Observed (a) winter mean (DJF) MSLP for 1999-2010(the domain for Siberian High is indicated with a green rectangle), (b) weekly climatology (dot) and slope for 4-week (solid line) SHI, and (c) 2m temperature anomalies regressed onto weekly SHI.	74
66. Observed SHI (asterisk) and 4-week slope of SHI (solid line), (b) 2m temperature anomalies averaged over EA, and (c) SHI (colored dot) and 4-week slope of SHI (solid line) in 2001.	75
67. Slope of SHI (a) predicted by MME and (b) climatology for 4 weeks from each initial date from 1999/2010 to 2009/2010 (hPa/week).	76

68. (a) Correlation of SHI slope between the MME and the observation (left bar) compared to the correlation of SHI slope between the climatology and the observation (right bar).	77
69. Number of occurrence of (a) positive slope and (b) negative slope of SHI for the observation, climatology, and MME for DJF from 1999/2000 to 2009/2010.	78
70. Boxplot of weekly slope of SHI for negative and positive cases, respectively (left) and weekly slope of the observed temperature at 2m over East Asia corresponding to positive and negative slope of SHI (right).	79
71. Composite of 2m temperature tendency (°C/week) for positive (a) and negative (b) cases of observed SHI slope and positive (c) and negative (d) case of SHI slope predicted by MME.	80
72. (a) DJF mean of weekly EAWMI TCC between models (individual model and MME) and the observation from lead week 1 to 4 (b) Correlation of weekly EAWMI between the observation and S2S MME.	81
73. (a) DJF mean EAWM indices for the period 1981-2010. Two dotted lines indicate ± 0.5 std dev, dash-dot lines indicate ± 1.0 std dev (b) 2m temperature anomalies averaged over East Asia for strong, neutral, weak East Asian monsoon years.	82
74. (Left) Pattern correlation between the seasonal mean and weekly mean temperature at 2m over East Asia (right) Year mean of pattern correlation (black), pattern correlation between the observed and predicted 2m temperature at lead week 3 (red) and 4 (yellow).	83
75. Wavelet power spectrum of (a) the observed and (b-e) MME weekly EAJS (U200 averaged over 27.5° -37.5° N, 130° -160° E) for DJF from 1999/2000 to 2009/2010.	85
76. Meridional location of the EAJS core for (a) the observation and (b-e) MME at lead week 1 through 4.	86
77. Averaged zonal wind speed and core location (black dot) of the observed EAJS during (a) north-located, (b)normal, and (c) south-located weeks.	87
78. Composite difference of 2m temperature and Z500 between EAJS north-located and normal years (a,b) south-located and normal years (c,d).	88
79. (a) Number of weeks for EAJS north-located (red), normal (blue), and south-located (yellow) in the observation and MME at different lead weeks.	89
80. observed and predicted MSLP patterns regressed onto corresponding AO indices.	90
81. Inter-model comparison: TCC and RMSE skill of predicted AO index for 4 lead weeks. ...	91

82. Standard deviation of AO indices for (a) 11 years at every week and (b) 12 weeks every year.	92
83. Correlation coefficients among 8 indices, those are T2M anomaly average over EA, PC time series of two EOF modes of T2M anomalies over EA, four EAWM indices, and AO index, for (bottomleft) the observation and (topright) the model.	93
84. ACC of (white bar) original and (colored bars) four different ways reconstructed T2M over EA for 3 weeks lead time. One-leave-out cross-validation is applied.	95
85. EA T2M ACC distribution of 132 samples (12 weeks for 11 winter seasons) for (light yellow) original MME and (light green) reconstructed by REG_EOF+REG_EATa.	96
86. T2M anomalies of (a) observation (b) original MME and (c) reconstruction from REG_EOF+REG_EATa for Jan 16-22, 2002.	97
87. Box-whisker of ACC for BN, NN and AN groups at different 4 lead weeks.	99
88. mean ACC of 9 categories based on two different indices' tercile criteria for lead week (top) 3 and (bottom) 4.	100
89. (a) scatter plot and (b) box-whisker plot between simulated PC1 persistency and EA T2M skill for lead time of 3 weeks from 132 samples (12 weeks for 11 winter seasons).	101
90. Skill comparison of BSISO impact for Outgoing Longwave Radiation over Asia-monsoon region for M1 (left), M2 (middle) and M3 (right).	102
91. Skill comparison of BSISO impact for multi variable over Asia-monsoon region for M1 (left), M2 (middle) and M3 (right).	103
92. Monthly skill comparison of BSISO impact for OLR and zonal wind at 850hPa over Asia-monsoon region for M1 (bottom), M2 (middle) and M3 (top).	104
93. Phase dependency of anomaly correlation and fractional variance for BSISO impact.	105
94. Regional robustness of anomaly correlation for BSISO impact.	106
95. Phase preference of BSISO impact field based on M1.	108
96. Regional and seasonal preference of BSISO impact anomaly based on M1.	109
97. Month representing maximum fractional variance of BSISO impact anomaly for outgoing longwave radiation.	110
98. Monsoon onset date for Taiwan Mei-Yu and Southwest monsoon during the recent 10 years.	112
99. Tendency diagram of monsoon onset for Taiwan Mei-Yu and Southwest monsoon during the recent 10 years.	112

100. Skill comparison of BSISO impact forecast for WEEK1 in respect of Outgoing Longwave Radiation over Asia-monsoon region. 114

102. Anomaly correlation coefficient of BSISO impact forecast from ECMWF for WEEK1, WEEK2 and WEEK3 and each month. 115

103. Scatter plot of forecast skills for multi-variables from multi models. Each model(variable) is distinguished by color(marker). 116

1. 서론

계절내 예측기술 향상을 위한 연구들이 국제적으로 활발히 수행되고 있으며, 관련 연구를 수행하기 위해 생산되는 예측 데이터의 양이 방대하다. 그러나 이를 생산한 기후 모형 별 계절내 예측 시스템 프로토콜이 상이함에 따라 이에 대한 대등한 평가가 매우 어려운 실정이고, 자료처리 기법과 예측정확도 평가 기법이 표준화되어 있는 단기예측정보나 계절예측정보와는 달리 계절내 예측정보의 경우 표준화된 평가 및 예측 기법이 존재하지 않는다. 또한, 단기예보나 장기예보에 비해 아직 그 예측기술이 그 초기단계에 지나지 않고 있다. 계절내 예측은 기상(weather)과 기후(climate) 사이에 위치하여 초기장의 영향이 거의 사라지는 구간이기 때문에 계절내 예측 모형의 예측성능은 매든-줄리안 진동(Madden-Julian Oscillation, MJO)와 같은 계절내 시간 규모의 주요 변동모드 예측을 제외하고는 기온과 강수 같은 기본 변수들의 예측에 있어 2주 이상의 예측 목표에 미치지 못한다. 특히, 한반도를 비롯한 동아시아 지역 강수와 기온의 계절내 예측성능은 다른 지역에 비해 현저히 떨어진다. 하지만, 이음새 없는 기상예보를 위한 계절내 예측자료의 중요성에 대한 인식이 증가함에 따라 다양한 섹터들로부터 정보 제공에 대한 요구가 실제로 빈번하게 이루어지고 있다. 이러한 배경 하에, 계절내 모형의 모의 특성 및 성능을 객관적으로 평가하고, 그를 바탕으로 예측 개선을 위한 기술을 개발하며, 마지막으로 계절내 예측 자료 가공을 통해 활용 가이드라인을 제안하는데에 이 과제의 목적이 있다.

전지구 기후 모형(Global Climate Models; GCMs)은 계절내 예측에서 계절 예측에 이르기까지 기본적으로 사용되고 있는 필수적인 존재이다. 이에 전세계 현업 기관들내에서 기후예측모형은 중장기 예측 성능 향상을 목표로 끊임없이 발전해 오고 있다. 한국 기상청에서도 1999년부터 대기대순환 모형에 근거한 장기예보 생산체계를 구축하고 역학적 방법에 의한 장기 예측 자료를 생산하였다. 국립기상과학원에서도 2000년대에 들어서 기후예측모형을 구축, 역학적 방법에 의한 장기예측자료를 생산하였다. 최근에는 한국 기상청과 국립기상과학원은 계절규모에서 한영 공동 기후예측시스템을 정착하고 현업으로 이용하기 위해 영국 기상청과 협력해왔고, 그 결과 2010년부터 영국 기상청의 전지구 대기-해양-해빙 결합모형(HadGEM3)을 기반으로 한 계절예측 시스템 Global Seasonal Forecasting System version 4(GloSea4)를 도입하고 구축하였다. 또한, 기상청은 향상된 계절 예보를 위해 2014년부터 GloSea4에서 모델 물리과정과 수평분해능을 개선한 고해상도 기후모형인 GloSea5(GloSea version 5)를 현업에 도입하였다.

한영 공동계절예측시스템 현업운영을 위해 GloSea5를 구축하면서, 국내에서도 GloSea5의 예측 성능 평가 및 검증을 다양하게 진행하고 있다. 하지만, 계절내규모에서의 성능 및 특성에 대한 연구는 아직 많지 않다. 따라서 이 연구에서는 기상청-GloSea5 계절내 기후값 및 실시간 예측에 대한 성능 정보를 타 기관 모형과의 비교를 통해 객관적으로 제시하고, 동아시아 예측 성능 향상을 위해 동아시아 몬순과 관련된 다양한 기후변동성과의 상관성 및 재현성의 오차에 대해 조사해보고자 한다. 또한, 계절내예측 규모에 해당하는 3-4주의 예측 성능의 특성을 알아보고, 이러한 결과를 통해 과거재현기후에서의 구조적 오차에 대해 파악하여 예측장을 해석할 때 도움이 되고자 한다. 또한 추후 모델의 개선 방향 제시에 필요한 정보를 제공하고자 한다.

전 세계적으로 11개 기후 예측 기관이 계절내 예측에 대한 정보 공유 및 이해를 위해

Subseasonal-to-Seasonal (S2S) 프로젝트에 참여하고 있으며, 각 기관에서 생산된 S2S 예측 자료는 유럽 중기 기상 예보 센터(European Centre for Medium-Range Weather Forecasts, ECMWF)와 중국 기상청(China Meteorological Administration, CMA) 데이터 포털을 통해 사용자들에게 제공되고 있다. S2S 자료가 다양한 분야에서 유용하게 사용될 수 있음에도 불구하고, 일기 예보나 중장기 예보에 비해 예측성이 현저하게 낮다는 단점 때문에 (Brunet et al., 2010; WMO, 2012; Robertson et al., 2015) 활용이 잘 되지 않고 있는 실정이다. 따라서 S2S 예측 정보의 활용성을 증대시키기 위해서는 계절내 예측 모델 자체의 성능을 개선하거나, 예측결과를 보정하는 기술 개발이 필요하다.

최근 들어 새로운 알고리즘의 개발과 방대해지는 데이터의 축적에 따라 다양한 분야에서 복잡한 문제들을 해결하는데 딥러닝 기술이 널리 적용되고 있다. 이는 데이터의 복잡한 내부 구조를 알고리즘이 스스로 학습하고 패턴을 찾을 수 있어 기존에 해결하기 힘들었던 문제들을 해결할 수 있기 때문이다. 그러나 기후 예측의 경우, 매우 복잡한 역학적 데이터로 구성된 패턴을 예측하는 일이 데이터 및 계산 집약적인 과정이기 때문에 이 분야에 대한 머신러닝/딥러닝 기술의 적용은 아직 초기 단계에 있다. 최근 연구에서, 이러한 기술이 강수량 등의 예측 성능 개선에 사용될 수 있음을 보여주었다(Hernandez et al., 2016). 예를 들어, 관측 자료에 다양한 통계적 기법뿐만 아니라 기계학습인 다층퍼셉트론(Multi-layer Perceptron, 이하 MLP), 지도 선형기계학습(Support Vector Machine, 이하 SVM) 및 극한 기계학습(Extreme learning Machine, 이하 ELM)을 적용하여 다음 날의 기온을 예측하는 방법을 제시하였다(Abdel-Aal et al., 1995; A. Paniagua-Tineo et al., 2011). 또한, E.G. Ortiz-Garcia et al.(2012)와 Ramesh et al.(2014)은 종관기상관측 자료에 다양한 기계학습 기법을 통해 다음 6시간 및 7일 동안의 기온을 예측하였다. Xingjian et al. (2015)은 강수의 현재 예보를 시공간적(spatiotemporal)으로 연속하는 문제로 인식하여 레이더 관측 이미지를 이용하여 미래 12시간까지 강수 예측을 수행하였다. 예측 모델을 구축하기 위하여 일반적인 장단기기억(Long Short-Term Memory, LSTM) 기법의 내부에 Convolution 기법을 적용한 ConvLSTM을 제안하였으며, 다른 기법들에 비해 우수한 성능을 보여주는 결과를 도출하였다. Nair et al. (2018)은 artificial neural network 기법을 이용하여 GCMs으로부터 생산된 자료의 예측성을 향상시키는 연구를 수행한 바 있으며 인도 지역에 대해 몬순 기간의 강수량 연 변동(year to year variations)의 예측성을 향상시킬 수 있음을 보인 바 있다. 또한 GCM의 모수화 프레임에 신경망(Neural networks) 기법을 통해 훈련시켜 GCM의 예측력을 향상시키는데 심층학습을 적용하였다(Scher et al., 2018; Dueben & Bauer, 2018). 이와 같이 기후변수의 예측 정확성을 향상시키기 위해 많은 연구가 수행되었으나 대부분의 연구가 기상 관측자료의 단기 예보 및 계절 규모 예보 관점에서 이루어졌고, S2S 시간 규모에서의 강수 혹은 기온 예측성 향상에 관한 연구는 거의 이루어져 있지 않다.

신기술인 딥러닝 기법뿐만 아니라 기존 모형자료 보정 (Model Output Statistics, MOS) 분야에 방대하게 활용되고 있는 회귀 분석, 경험적 직교 함수 등 고전 통계 기법 역시 계절내 규모 예측 개선을 위한 적용이 기대된다. 한반도 겨울 한파 현상의 선행 인자로 알려진 동아시아 겨울 기온의 경우 선행 3주차에서도 그 성능이 저조한데, 북반구 대기 변동 모드들과 역학적 관련성이 잘 알려져 있어 경험적 대규모 순환장 관련성에 기반한 통계적 보정을 통한 성능 개선을 기대할 수 있겠다. 따라서 이 연구에서는 기계학습 및 심층학습을 이용하여 S2S 예측 자료의 후처리를 통한 한반도 영역의 S2S 예측 자료의 예측성 향상 가능성을 알아보고자 한다. 또

한, 동아시아 겨울 기온 주평균 예측 개선을 위한 고전 통계 기반 보정 기법의 적용 가능성을 확인하고자 한다. 특히, 1~2주보다는 3~4주 시간 규모의 예측 자료에 대한 예측 성능 오차가 큰 것으로 알려진 S2S 예측 자료에 이러한 보정 기법을 적용하면, 3~4주 예측 오차 감소와 더불어 신뢰도 높은 S2S 예측 자료를 제공할 수 있을 것으로 예상된다.

한편, 예측 정보 가공을 통한 활용성 증대는 기후 서비스의 성공 조건으로서, 계절내 규모 역시 그 예외는 아니다. 계절내 규모 변동성은 매우 크고, 따라서 예측 성능 역시 불확실성이 매우 크다. 계절 예측의 경우, 장기 해양 강제력 조건에 따라 그 예측성에 대한 대략적인 예상이 가능하고 이를 활용해 매뉴얼 예보를 수정하게 된다. 계절내 규모에서도, 실시간으로 역학 모형 성능 범위를 추정하여 그 신뢰도를 점칠 수 있다면, 매뉴얼 예보 개선의 기회의 창이 될 것이라 기대된다. 또한, APCC는 MJO와 더불어 계절내 시간 규모에서 주요한 예측인자로 간주되는 여름철 계절내진동 (Boreal Summer Intraseasonal Oscillation: BSISO) 예측을 2013년부터 서비스 해오고 있고, 좀 더 쉽게 BSISO를 이해할 수 있는 방안에 대한 국내/외 실무진들의 수요가 지속적으로 있어 왔다. 따라서 아시아 몬순지역의 다양한 기상현상에 대한 BSISO의 영향 분석을 더 강화하고 콘텐츠를 고도화하여 수요에 대응하는 것이 필요하며, 지속적인 예측성 평가와 예보 향상 기법 개발을 통해 더 나은 BSISO 예측 정보를 제공할 수 있는 방안을 제시해야 한다. 이 연구에서는 동아시아 겨울 기온 실시간 예측성 추정 가이드라인과 BSISO 영향장 분석 및 몬순 시작 시점 추정 등을 위한 BSISO 활용 가이드라인을 제안하고자 한다.

이 보고서의 2장은 과제에서 사용된 자료 및 방법론, 그리고 여러 가지 기후 모드들의 정의를 서술하겠다. 3장은 계절내 예측에 대한 (a) 객관적 평가, (b) 후보정 기술 개발, (c) 활용 가이드라인에 걸친 다양한 세부 주제 연구 결과를 포함한다. 첫 번째로 기상청 계절내 예측 모형 KMA-GloSea5의 실시간 예측성 평가와 동아시아 겨울/여름 몬순 시스템, 해양 및 대류 활동과 관련한 모형 오차 분석 결과를 제시하겠다. 두 번째로 딥러닝 적용을 통한 한반도 기온/강수 보정 기술, 고전 회귀 분석법 기반의 동아시아 겨울 기온 보정 기술을 제안하겠다. 마지막으로 동아시아 겨울 기온 실시간 예측성 추정 가이드라인과 BSISO 영향장 분석 및 몬순 시작 시점 추정 등을 위한 BSISO 활용 가이드라인을 제안하겠다. 4장은 연구 결과를 요약하고 향후 과제 성과를 확장을 위한 시사점을 제시한다.

2. 방법 및 자료

가. 자료

(1) 계절내 모형 자료

(가) KMA-GloSea5 예측 자료

우리나라 기상청은 2010년 영국 기상청(Met Office)과 대기-해양 결합 모형을 이용한 계절 예측시스템의 공동구축 및 운영에 관한 협정을 체결하여 단기간 날씨부터 계절내 및 계절 예측, 기후 예측을 포함하는 포괄적인 계절예측시스템인 Global Seasonal Forecasting System version 5 (GloSea5) (MacLachlan et al. 2015) 을 도입하였고, 2014년부터 현재까지 현업 계절예측에 활용 중이다. 영국 기상청 기후 모델인 HadGEM3 (Hadley Centre Global Environment Model version 3) 에 기초하여 구축된 GloSea5는 Met Office의 Unified Model (UM) 대기 모델 (Global Atmosphere model; Walters et al., 2017) 과 Nucleus for European Modeling of the Ocean (NEMO) (Madec, 2008) 해양모델, Los Alamos sea ice model (CICE) (Rae et al., 2015) 해빙 모델, Joint UK Land Environment Simulator (JULES) (Walters et al., 2017) 지면 모델로 구성되며, 지면-대기-해양 플럭스 교환을 위해 OASIS 커플러로 결합되어 있다 (Kim et al., 2018). GloSea5의 대기모델 수평격자 해상도는 N216으로 위도 0.56° 와 경도 0.83° 이며 (약 ~60km), 연직으로 85개의 층을 가지고 있다. 해양모델의 수평 및 수직 해상도는 각각 $0.25^\circ \times 0.25^\circ$ 와 75층이며, 대기-해양 플럭스는 3시간 간격으로 교환 된다 (Figure 1). 특히, 계절내 예측을 위한 GloSea5 과거모의 (Hindcast) 실험은 1991년부터 2010년까지 총 20년 동안 매달 1일, 9일 17일, 25일 ECMWF의 ERA-Interim 자료를 초기장으로 이용하여, 3개 앙상블 멤버의 60일 적분으로 수행된다. 이 연구는 GloSea5 계절내 시간 규모 분석을 위해 Hindcast version 2017과 version 2018을 사용하여 기본적인 검증을 수행하였다.

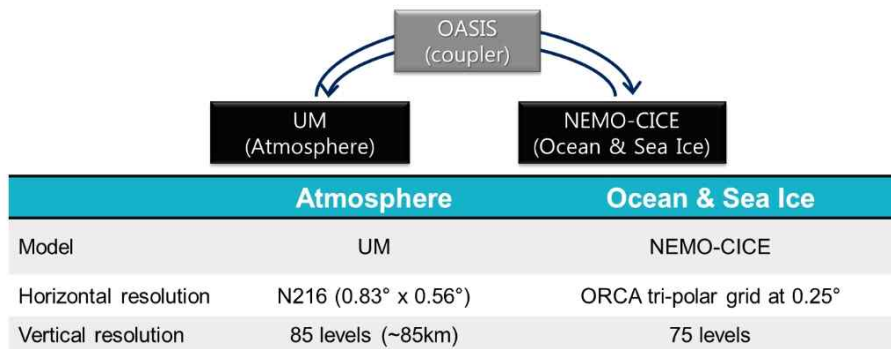


Figure 1. Model configuration of KMA-GloSea5.

(나) S2S 모형 예측 자료

계절내 예측자료는 S2S prediction project database (Vitart et al., 2017)에서 수집하여 준

실시간으로 제공하고 있는 자료를 활용하였다. 현재 총 11개의 모형이 S2S prediction project를 위해 자료를 제공하고 있으며 본 연구에서는 그 중 네 모형(ECCC, ECMWF, KMA, NCEP)의 자료를 활용하여 연구를 수행하였다. 이중 세 모형(ECCC, ECMWF, NCEP)은 예측날짜와 동일한 날짜에 과거재현자료를 제공하고 있으며, 세 모형 모두 매주 동일한 요일(목요일)에 예측을 수행한다. 반면, KMA의 모형은 과거재현자료를 한달에 4회 고정된 날짜(1일, 9일, 17일, 25일)에 제공하고 있으며, 예측자료는 매일 생산되지만 앙상블 멤버의 수가 4개로 적어서 확률예측 계산 등을 위해서는 일주일 정도의 예측결과를 합쳐서 사용할 필요가 있다. 이처럼 각 모형들은 저마다의 예측 스케줄과 전산 자원에 따라 모형의 특성이 매우 상이하며 (Table 1), 그에 따라 각 모형 간 비교를 위해서는 동일한 기준을 정하여 자료를 표준화할 필요가 있다. 따라서 기본적으로 자료수집 시 용이한 비교 분석을 위해 예측자료의 수평 해상도를 모두 1.5° 로 고정하였으며, 시간 해상도는 24시간으로 하였다.

Table 1. Description of subseasonal forecast models.

Center	Time Range	Resolution	Ens. Size	Fcst. Frequency	Refcst Period	Refcst Ens. Size	Refcst. Frequency
ECCC	32 days	0.45x0.45, L40	21	weekly	1998-2017	4	weekly
ECMWF	46 days	Tco639/319 L91	51	2/week	past 20 years	11	2/week
KMA	60 days	T216 L85	4	daily	1991-2010	3	4/month
NCEP	44 days	T126 L64	16	daily	1999-2010	4	daily

(다) BSISO 모형 예측 자료

APCC BSISO 예보에 사용되고 있는 모형은 총 5개로 각 모형의 특성은 Table 2와 같다. 실시간 BSISO 지수 예보를 위해 CWB는 2015년부터 나머지 4개 모형은 2013년부터 5월에서 10월 동안 꾸준히 예측자료를 제공해오고 있다. 이에 본 연구에서 사용한 모형 자료의 공통 기간은 2015년부터 2018년까지 4년 동안의 5월에서 10월이고 각 예보의 20일까지의 리드타임을 활용하였다.

Table 2. Description of BSIISO forecast models.

Institute	Model	Ensemble Size	Forecast Period (day)	Updated frequency	Resolution
NCEP	CFS	4	40	Once a day	T126 L64
	GFS	1	16	Once a day	T574, T190 L64
BOM	POAMA	33	40	Twice per week	T47 L17
ECMWF	ECMWF	51	32	Twice per week	T639, T319 L62
Taiwan CWB	CWB	6	40	Every 5 days	T116 L30

(2) 관측 자료

이 연구에서 모형의 예측성을 평가하기 위한 비교대상으로 ECMWF의 일별 ERA-Interim 재분석자료(Dee et al., 2011)의 기온, 강수, 500hPa 지위고도를 사용하였다. 관측자료는 모형과 동일한 격자인 $1.5^{\circ} \times 1.5^{\circ}$ 로 내삽한 후 일별 자료를 주 평균하였다. 일별 BSIISO 지수를 계산하기 위해서는, 1981년부터 2018년까지 NCEP/NCAR 재분석 자료 (Kalnay 등, 1996)를 사용하고 합성장 분석 등 다양한 분석을 수행하였다.

나. 방법론

(1) 딥러닝 기법

딥러닝 (Deep learning)의 수많은 세부 알고리즘들이 빠른 속도로 개발되고, 여러 알고리즘이 함께 사용되어 문제를 해결하는 경우가 많아지고 있기 때문에, 검증된 라이브러리/모듈을 제공하여 딥러닝 개발자가 편리하게 응용 프로그램을 효율적으로 개발할 수 있도록 한다. 이렇게 제공되는 상위 프로그램 패키지를 딥러닝 프레임워크 (deep learning framework)라고 한다. 본 연구에서는 S2S 예측 데이터의 딥러닝 학습을 통한 예측 성능 향상을 위해 Apache에서 개발된 MXNET 프레임워크를 사용하였다. MXNET은 오픈소스 딥러닝 프레임워크로 imperative/symbolic 모델 지원, 다중 CPU/GPU 지원, 단순한 CPU/GPU 모델 변환, 서버~모바일을 아우르는 다양한 하드웨어 플랫폼 지원, 분산학습 지원 등 다양한 특징들을 지닌다. 최근에는 뛰어난 성능 덕에 아마존의 공식 딥러닝 프레임워크로 채택되기도 하였다. 머신러닝 기법간 비교는 scikit-learn, Pandas, NumPy 및 Matplotlib이 설치된 Python SciPy 환경에서 수행하였다.

세부 딥러닝 알고리즘으로는 장단기기억기술 (long short term memory; LSTM)이 채택되었고, 다층퍼셉트론(multilayer perceptron; MLP), 순환신경망 (recurrent neural network; RNN), 지도선형 기계학습 (support vector machine; SVM)도 추가로 사용되어 LSTM의 예측 결과와 비

교하였다.

딥러닝은 여러 개의 은닉층 (hidden layer, 입력층과 출력층 사이의 중간층)를 가진 인공 신경망을 사용하는 기계 학습 (machine learning)의 일종으로, 컴퓨터가 대규모의 데이터로부터 자체적으로 결과에 영향을 끼치는 주요 선형/비선형 패턴을 학습하여 모델을 구축하고, 새로운 데이터에 대해 예측을 수행하는 기법이다. 이 중 가장 기본적인 형태의 딥러닝 모델은 MLP로, 단층퍼셉트론 (Single-layer Perceptron, SLP)과 MLP는 입력층 (Input layer), 은닉층 (Hidden layer), 출력층 (Output layer), 가중치 (Weight), 편향 (Bias)으로 구성되어 있다는 부분에서는 동일하나 Figure 2과 같이 은닉층의 개수가 2개 이상인 경우를 MLP라고 한다. 학습 모델을 구축하기 위하여 입력층에는 학습을 시키고자 하는 데이터를 배치하고, 은닉층에 위치하고 있는 가중치와 편향의 값을 조정하여 최종적으로 출력하고자 하는 결과에 가장 적합한 값을 출력하도록 반복학습을 수행하게 된다. MLP는 단층 perceptron의 단점으로 지적되어온 비선형 모델 학습이 불가능함을 은닉층의 개수를 늘리고, 각 층 neuron의 입출력을 비선형으로 가능하게 함으로서 학습 능력을 크게 향상시켰다. MLP는 은닉층의 개수가 증가할수록 더욱 다양하고 심화된 학습이 가능해지게 된다. Perceptron의 특징은 은닉층의 활성화 함수가 -1에서 1사이의 값을 반환한다는 것인데 그로 인하여 비선형적 함수식을 표현하기 위해서는 입력 데이터를 정규화 해 줄 필요가 있다. 표준화된 입력 변수는 가중치를 곱하고 편향을 더한 후 활성화 함수로 보내지며 대표적인 활성화 함수는 계단함수 (Hard limiter), 시그모이드 (Sigmoid) 함수, ReLU 함수 등이 있다. 활성화 함수를 통과한 값은 그 다음 은닉층으로 보내지며 다시 가중치를 곱하고 편향을 더한 후 다시 활성화 함수를 통과 한 후 출력층으로 보내지게 된다. 이후 출력된 값과 대상값의 차이를 최소화 할 수 있는 방향으로 학습이 반복되는 오차역 전파 알고리즘을 통해 학습이 수행된다.




Figure 2. Single-layer perceptron and multi-layer perceptron (Source: Lee, 2018).

MLP의 경우 뉴럴 네트워크가 입력층, N개의 은닉층, 출력층의 단일 방향으로 연결된 feed-forward neural network이다. 이 형태의 네트워크에서는 입력 데이터가 모든 노드를 한번씩만 지나가며 개별 입력 데이터가 독립적인 관계로 간주되어 학습이 진행된다. 하지만, 시계열이나 문장과 같은 데이터 간의 순서에 중요한 정보가 포함되어 있거나 입력 자료 간에 상관관계가 있는 자료들의 경우, 이런 관계가 무시되고 데이터의 조각들이 독립적으로 학습되는 단점이 있다. Recurrent neural network (RNN)는 이 단점을 극복하는 딥러닝 모델로 주목받아왔다. 이것은 RNN이 은닉층에서 나온 output이 다시 같은 은닉층 뉴런의 input 자료로 들어가도록 연결되어서, 데이터 간의 순서를 학습과정에서 고려할 수 있는 특징을 가지고 있기 때문이다. Figure 3의 A는 은닉층을 가진 RNN을 표현한 것이고, Figure 3의 B는 이 RNN을 시간축으로 펼쳐 설명한 것이다. 은닉층의 출력이 다시 은닉층에 입력되는 구조로 되어 있어서 Recurrent Neural Networks로 불린다. 과거의 정보는 은닉층에 계속 저장되며, 새로운 입력 자료에 의해 업데이트가 된다. 즉, RNN은 은닉층에서 자신의 기억을 update한다. 업데이트가 되면서 output도 하나씩 나오게 되므로, 오차를 계산할 수 있게 되고, 이 오차를 최소화하는 방향으로 업데이트가 된다. 이런 특징 때문에, RNN은 sequence data를 다루는데 강력함을 발휘한다. 예를 들어, 문장 학습의 경우, 문장의 구성 요소인 개별 단어 뿐 아니라 단어 간의 순서를 통해 단어의 여러 의미 중 정확한 의미를 찾아내고, 문장 전체의 맥락을 이해할 수 있게 된다. 따라서 신문 기사, 음성 언어, 신호 감지 장치에 의해 수집된 시계열 데이터, 주식 시장 차트, 유전자 서열 등 구성 요소간의 서열이 중요한 대규모 데이터를 처리하는데 RNN이 자주 이용된다.

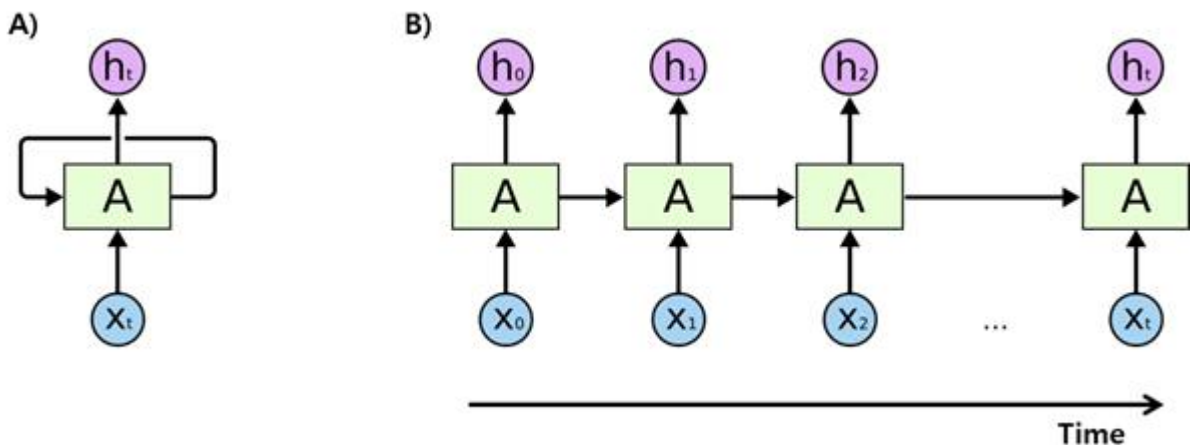


Figure 3. (A) The repeating Recurrent Neural Networks. (B) An unrolled recurrent neural network an time axis. (Source: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>)

이러한 장점에도 불구하고, RNN의 경우 짧은 서열 데이터에서만 강력한 효과를 발휘한다는 실질적인 문제가 존재한다. 이것은 각 뉴런에서 학습된 데이터가 가공된 후의 상태로 다음 은닉층 뉴런으로 전달되기 때문에 입력자료의 길이가 길어지고 은닉층 개수가 길어질수록 이

전의 정보가 충분히 뒤로 전달되지 못하게 되기 때문이다. 이로 인해 초기 서열의 정보가 학습 과정에서 잊혀지는 단점이 생기게 된다 (장기 의존성 문제, the problem of long-term dependency). 이런 문제를 해결한 것이 LSTM 알고리즘이다. LSTM 알고리즘은 RNN의 일종으로, Figure 4의 단일 레이어를 가지는 표준 RNN의 기본 신경세포 구조에 4개의 게이트를 사용하였다 (Figure 5). LSTM은 은닉층의 기억세포에 상호작용하는 입력 게이트, 망각 게이트, 출력 게이트라는 요소를 활용하였다. 게이트들은 선택적으로 정보들이 흘러 들어갈 수 있도록 만드는 장치를 의미한다. 각 게이트에서 계산된 시그모이드 함수를 이용해 기억을 지우거나 유지해 가며 서열 데이터의 먼 위치에 있는 요소들이 연결될 수 있도록 한다. 시그모이드 레이어 (sigmoid layer)는 0 혹은 1의 값을 출력하며, 각 구성 요소가 영향을 주게 될지를 결정해 주는 역할을 한다. 0 값을 가지게 되면 해당 구성 요소가 미래의 결과에 아무런 영향을 주지 않게 되고 1 값을 가지게 되면 해당 구성 요소가 확실히 미래의 예측 결과에 영향을 주도록 데이터가 흘러가게 한다. 그리고, 셀 스테이트를 보호하고 컨트롤하기 위해서 세 가지 게이트들을 이용하고 있는데, forget gate layer에서는 어떤 정보를 버릴지를 선택하는 역할이고, input gate layer에서는 어떤 값을 업데이트할 지를 결정하게 된다. 마지막으로 tanh layer에서는 셀 스테이트에 더해질 수 있는 새로운 후보 값을 만들어 낸다. 어떤 값을 출력할지 결정하는 시그모이드 레이어와 셀 스테이트의 값이 tanh 함수를 거쳐서 -1과 1 사이의 값으로 출력되면, 시그모이드 레이어에서 얻은 값과 tanh 함수를 거쳐 얻은 값을 곱해서 출력하는 과정이 표준적인 LSTM 방식이다. 이렇게 구성된 신경세포들이 하나의 컨베이어 벨트처럼 전체 체인을 통과하는데, 이 구조를 통해서 앞쪽의 정보가 큰 변함 없이 계속 다음 단계에 전달이 되게 함으로써 최적의 결과를 얻도록 하는 혁신적인 방법을 통해 장기 의존성 문제를 해결하였다. 이를 토대로 초반부 정보가 후반부 정보와 밀접한 관련이 있는 특징을 가지는 데이터 (예: 여러 절로 이루어진 긴 문장, 중장기 예보)에서 LSTM이 MLP나 RNN 등 다른 딥러닝 기법과 비교해 더 나은 성능을 가질 것으로 기대할 수 있다.




Figure 4. The repeating module in a standard RNN contains a single layer (Source: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>).




Figure 5. The repeating module in an LSTM contains four interacting layers (Source: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>).

SVM은 주어진 샘플 그룹에 대해 분류 작업 (classification) 규칙을 찾아내는 머신러닝 분야의 대표적인 이진 분류를 위한 기법이다. SVM의 핵심은 n 차원의 데이터 공간에서 커널 (kernel) 함수 정의를 통해 최적의 선형 혹은 비선형 분할선(decision boundary)을 결정하는 것이다 (Figure 6). 본 연구에서는 다항식 커널(kernel) 함수를 통해 분할선 (decision boundary)을 결정하였다.




Figure 6. SVM classification algorithm (source: https://en.wikipedia.org/wiki/Support-vector_machine).

딥러닝의 input 데이터로는 대한민국 기상청 S2S 자료인 GloSea5와 여러 예측기관에서 나오는 S2S 자료들 중 가장 예측성이 우수하다고 알려진 ECMWF의 S2S 모델이, label 데이터로는 ERA-Interim 재분석 데이터가 사용되었다. ECMWF 모델은 일주일에 2번씩 향후 46일에 대해 전 지구 예보를 생산하고 있다 (Table 3). 이 모델은 1개의 control run과 10개의 perturbation run, 총 11개의 앙상블 멤버를 과거 20년에 걸쳐 생성하여 과거예측 자료를 생성한다. GloSea5 모델도 과거 20년치의 과거예측 자료를 생산하지만, ECMWF의 46일치가 아닌 60일치의 일별 예측 자료를 생성하고, 예측 연도도 1991-2010으로 ECMWF의 1998-2017년도와

차이가 있다. 또 다른 차이점은 GloSea5가 1개의 control run과 2개의 perturbation run만을 생성한다는 것인데, 딥러닝 학습 측면에서 ECMWF의 11개 앙상블 데이터에 비해 샘플의 수가 크게 적어지기 때문에 학습의 신뢰성이 저하된다는 단점으로 작용할 수 있다. ERA-Interim 자료는 1990년부터 2018년까지 일단위로 생성되어, ECMWF와 GloSea5와 겹치는 시기의 자료를 추출하여 레이블 데이터로 사용하였다.

Table 3. Summary of input and label data for S2S-deep learning.

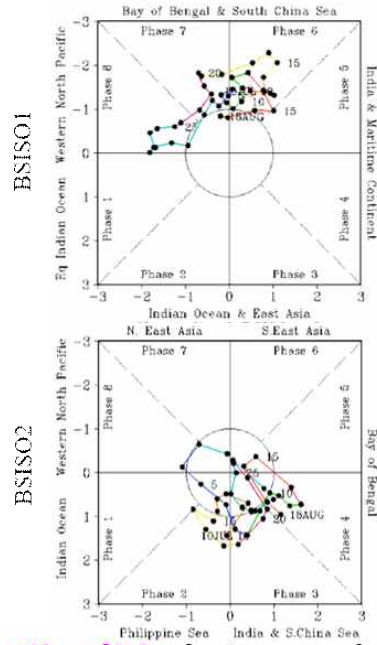
	Observed	Forecast	
	ERA-Interim	ECMWF	GloSea5
Period	1990-2018	1998-2017	1991-2010
Time scale	daily	daily	daily
Time range	-	46 days	60 days
DL input	current S2S release (variables X days)		
DL output	Tmax, Tmin, Precipitation (daily)		

딥러닝을 통한 S2S 예측성능 향상을 위해 ECMWF와 GloSea5 S2S 데이터 각각에 대해 학습을 진행하였다. Input 데이터로 각 S2S 배포 데이터 (변수 X forecast days의 2차원 배열)를 하나의 표본 데이터로, 20년 X 앙상블 개수를 표본 데이터 집단으로 간주하여 학습하였다. 딥러닝의 결과는 최고기온 (Tmax), 최저기온 (Tmin), 강수량 (Precipitation) 3개 변수별로 forecast day별 값을 가진 1차원 배열이 나오도록 하였다. 레이블 데이터는 ERA-Interim에서 학습 데이터 날짜에 해당하는 output 변수를 추출하였다. 학습 성능의 기준으로는 회귀 분석의 대표 m 성능 척도인 Root Mean Square Error (RMSE)를 사용하였다.

(2) BSISO 영향장 분석 기법

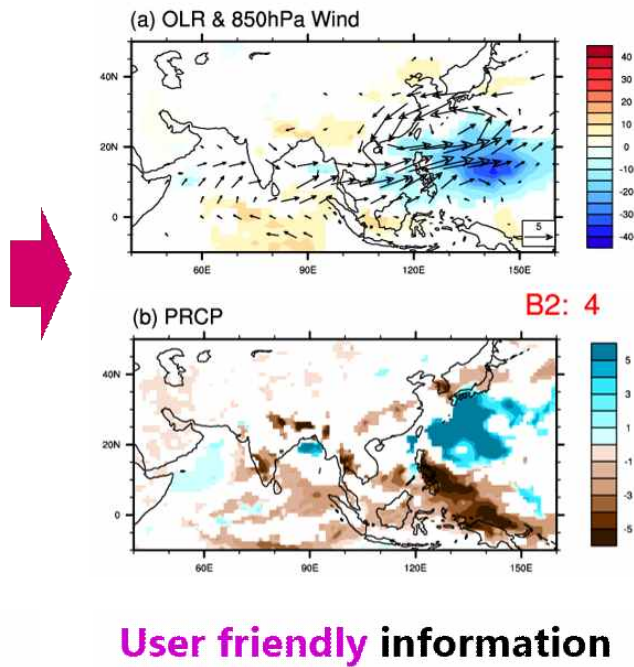
현재 BSISO 서비스 콘텐츠는 위상도에 기반 한 지수 정보 제공이 주를 이루고 있어, 아시아 몬순 지역에서 변동하고 있는 BSISO의 상태나 그에 따른 지역적인 영향을 알기 위해서는 사용자가 스스로 본인의 지식에 기반 하여 지수 정보를 2차원 혹은 좀 더 고차원적인 공간 정보(e.g. 아시아 몬순 지역의 기온, 강수 아노말리)로 이미지를 연상하거나 분석해야 하는 어려움이 있다. 따라서 BSISO 정보를 좀 더 직관적으로 인지할 수 있는 정보가 요구되어왔고 지수 형태로 제공되어오던 BSISO 정보를 공간장으로 변환하는 기술을 개발하였다(Figure 7). 좌측은 기존에 제공되던 BSISO 지수 정보이고 우측은 개발된 기법을 적용하여 만들어진 BSISO 대기 영향장 정보이다.

Forecast/Monitoring on Main Driver



Illegible information

Forecast/Monitoring on its Atmospheric Response



User friendly information

Figure 7. Conceptual diagram for BSISO impact analysis.

(가) 합성장 분석 기반 기법 (M1)

BSISO 영향장을 추정하기 위한 방법으로 합성장 분석을 활용하였다. 먼저 1981년부터 2018년 동안 관측된 기후 변수들을 사용하여 BSISO 지수 1과 2의 위상과 크기 각각에 대해 매 월 합성장 분석을 수행하였다. 이때 BSISO 지수는 그 크기가 1.0보다 큰 경우일 때만을 사용함으로써 BSISO가 강할 때의 대기 반응만을 고려하였다.

BSISO 영향장은 예측된 혹은 관측된 BSISO 지수와 관측에서의 관계(합성장)를 결합하는데 이는 BSISO 지수의 크기와 위상에 의존한다(Table 4). BSISO1과 BSISO2에서 각각 추정된 영향장들은 각 지수가 설명할 수 있는 변동량(variance)의 비율로써 합산된다. 이 기법은 다양한 변수들에 대한 영향장을 생산 할 수 있는 장점이 있다.

(나) 회귀분석 기반 기법 (M2)

BSISO 영향장을 추정하기 위한 또 다른 방법으로 회귀 분석을 활용하였다. 1981년부터 2018년 동안 관측된 기후 변수들과 BSISO 지수의 곱으로 계산하였고 자세한 수식은 Table 4에서 확인할 수 있다. 이 기법 역시 다양한 변수들에 대한 영향장을 생산할 수 있는 장점이 있으나 BSISO 활동이 강하지 않을 때의 대기 상태도 함께 고려될 수 있다.

(다) EOF 분석 기반 기법 (M3)

BSISO 지수는 EOF 분석을 통해 정의되었다. 따라서 Table 4에서 제시한 것처럼 EOF 분석 시 도출되는 공간 벡터와 시간 계수의 결합을 통해 1981년부터 2018년 동안의 BSISO의 공간 모습을 재구성 할 수 있었다. 이 기법은 BSISO 지수를 정의할 시 사용된 OLR과 850hPa의 동서류에 대해서만 재구성 할 수 있다는 단점이 있다.

Table 4. Methodology for BSISO impact analysis

Methodology	Formula
Composite based methodology (M1)	$\begin{aligned} & \text{Composite map(phase)} \times \text{BSISO1} \times 0.62 \\ & + \\ & \text{Composite map(phase)} \times \text{BSISO2} \times 0.38 \end{aligned}$
Regression based methodology (M2)	$\begin{aligned} & \text{Regression map of anomaly onto BSISO1-1} \times \text{BSISO1-1} \\ & + \\ & \text{Regression map of anomaly onto BSISO1-2} \times \text{BSISO1-2} \\ & + \\ & \text{Regression map of anomaly onto BSISO2-1} \times \text{BSISO2-1} \\ & + \\ & \text{Regression map of anomaly onto BSISO2-2} \times \text{BSISO2-2} \end{aligned}$
EOF based methodology (M3)	$\begin{aligned} & \text{EOF1} \times \text{BSISO1-1} + \text{EOF2} \times \text{BSISO1-2} \\ & + \\ & \text{EOF3} \times \text{BSISO2-1} + \text{EOF4} \times \text{BSISO2-2} \end{aligned}$

다. 기후 지수들

이 과제는 계절내 예측 모형이 구현하는 다양한 북반구 대기 변동과 열대 대류를 진단하기 위해 기존의 다양한 기후 지수들을 활용하였다.

동아시아 지역은 연중 강수량이 여름철에 집중되는 몬순(monsoon) 현상이 뚜렷하며, 이러한 동아시아 여름몬순의 가장 두드러진 특징은 북서태평양 아열대지역 고기압성 흐름의 계절적 변화와 열대 태평양과 인도양에 대한 대류 활동으로 나타난다 (Wang et al., 2004). 특히, 북서태평양 몬순(Western North Pacific Monsoon, WNPM)은 우리나라를 포함한 중국과 일본의 여름 강수량과 기온에 상당한 영향을 주는 것으로 알려져 있으며, 이 연구에서 동아시아 여름 몬순 (East Asia Summer Monsoon, EASM) 분석에 주된 지수로 활용하였다. 그리고 동아시아 여름몬순과 뚜렷한 상관성을 가지는 북서태평양 아열대 고기압(Western North Pacific Subtropical High, WNPSH) 지수를 활용하였다. 또한, 인도 몬순의 특징을 나타내는 지수 (Indian Monsoon,

IM; Webster and Yang, WY) 는 서태평양 대류 활동에 관여된 동아시아 여름몬순에 영향을 미치므로 동아시아 여름몬순 분석을 위한 지수로 선정하였다. 이 연구에서는 동아시아 여름몬순의 특징을 반영한 4개 지수를 계절내 예측 분석에 활용하였고, Table 5에 제시된 지수들은 계절내 예측 시간 규모의 분석을 위해 선행 주수에 따른 여름철(June-July-August, JJA) 평균 자료로 산출되었다.

Table 5. EASM indices used in this study.

Index	Definition	Reference
IM	850hPa zonal wind (U850hPa), gradient (5° -15° N,40° -80° E)-(20° -30° N,70° -90° E)	Wang et al. (2001)
WNPM	850hPa zonal wind (U850hPa), gradient (5° -15° N,100° -130° E)-(20° -30° N,110° -140° E)	Wang et al. (2001)
WNPSH	850hPa geopotential height (H850hPa), area average (15° -25° N,115° -150° E)	Wang and Zhang (2002)
WY	200hPa/850hPa zonal wind (U200hPa, U850hPa), gradient U850(EQ-20° N,40° -110° E)-U200(EQ-20° N,40° -110° E)	Webster and Yang (1992)

동아시아 겨울몬순의 4가지 주요 특징으로 동아시아 서쪽의 시베리아 고기압과 동아시아 동쪽에 위치한 알루산 저기압, 동아시아 하층 남북방향의 바람, 동아시아 중층의 기압골, 그리고 상층 제트 기류를 꼽을 수 있다 (Chan and Li, 2004; Jhun and Lee, 2004). 특히 시베리아 고기압의 경우, 그 강도의 계절내 변동이 동아시아 겨울철 기온에 상당한 영향을 끼치는 것으로 알려져 있다. 이 연구에서 시베리아 고기압 영역을 40° -65° N, 80° -120° E로 정의하였다 (Panagiotopoulos et al. 2005) (Figure 65(a)).

다양한 동아시아 겨울몬순 지수가 개발되어 왔으나, 이 연구에서는 앞서 언급한 겨울몬순의 4가지 주요 특징을 각각 반영한 4개의 지수를 택하여 계절내 예측에 활용코자 한다 (Table 6). Table 6에 나열된 지수들은 동아시아 겨울몬순의 경년변동성을 분석하기 위해 주로 월 평균 자료를 바탕으로 활용되어 왔으나 이 연구에서는 주 평균 예측 평가를 위해 각 지수의 정의 방법을 주 평균 자료에도 적용하였다.

Table 6. EAWM indices used in this study. * indicates normalized value.

Index	Definition	Reference
WangC_P	Sea Level Pressure (SLP)* gradient $(2 \times \text{SLP}^*1 - \text{SLP}^*2 - \text{SLP}^*3) / 2$ SLP*1: normalized area-averaged SLP over Siberia (40° -60° N, 70° -120° E) SLP*2: the North Pacific (30° -50° N, 140° E-170° W) SLP*3: the Maritime Continent (20° S-10° N, 110° -160° E)	Wang and Chen (2014)
Wang_P	SLP* gradient $(40^\circ - 70^\circ \text{ N}, 110^\circ \text{ E}) - (40^\circ - 70^\circ \text{ N}, 160^\circ \text{ E})$	Wang et al. (2009)
Wang_Z	PC1 of 500hPa geopotential height (Z500hPa)*, $(25^\circ - 50^\circ \text{ N}, 100^\circ - 180^\circ \text{ E})$	Wang et al. (2009)
Li_U	200hPa zonal wind (U200hPa), gradient $\{[(30^\circ - 35^\circ \text{ N}, 90^\circ - 160^\circ \text{ E}) - (50^\circ - 60^\circ \text{ N}, 70^\circ - 170^\circ \text{ E})] + [(30^\circ - 35^\circ \text{ N}, 90^\circ - 160^\circ \text{ E}) - (5^\circ \text{ S} - 10^\circ \text{ N}, 90^\circ - 160^\circ \text{ E})]\} / 2$	Li and Yang (2010)

극진동 (Arctic Oscillation, AO) 모드는 20° N 이상 북반구 해수면 평균 기압 (MSLP) 아노말리에 대하여 경험직교함수 (Empirical Orthogonal Function, 이하 EOF)를 적용 시 얻어지는 선도 모드로 정의하고, 이 패턴에 MSLP 아노말리장을 투영시켜서 관측과 모형에 대한 극진동 지수를 얻는다. 또한, 통상적으로 사용하는 EOF 모드를 통해 정의되는 AO 지수와 함께, 북위 35N, 65N의 정규화된 동서 평균된 지표 기압의 차이(를 사용해 계산되는 Li and Wang (2003)을 추가적으로 오차 분석에 사용하였다.

본 연구에서 사용한 BSISO 지수는 2013년에 개발된 Lee et al. (2013)의 기법을 사용하였다. 이 기법은 BSISO의 위상, 강도, 구조 등을 실시간으로 지수화 할 수 있어 BSISO의 활동을 모니터링하고 예측하기에 용이하다는 장점이 있다. 이 기법은 BSISO를 30-60일 주기의 BSISO1 지수와 10-30일 주기의 BSISO2 지수로 나누어 표현하는데 BSISO1은 아시아몬순 지역에서 나타나는 전형적인 계절내 북진 모드를 나타내고 BSISO2는 아시아 몬순의 발달과 연관된 남북 진동 모드를 나타낸다. 두 개의 모드로 나누어서 현상을 살펴보는 것은 각각 중 어느 모드의 영향이 현재 BSISO 활동에서 더 우세한지를 판단하기는 쉬울 수 있다. 그러나 실제 대기는 두 모드가 결합되어 움직이므로 양자 간의 합에 의해 대류 활동에 시너지를 만드는 지역과 그렇지 아니한 지역을 확인하여 지역적인 영향을 살펴보는 데는 한계가 따른다.

3. 결과

이 과제에서 수행된 계절내 시간 규모 역학 예측에 대한 평가/보정/활용 등 전방위 세부 연구 주제들을 기본 목적에 따라 “모형 예측성 평가 및 오차 진단”, “모형 예측 보정 기술 개발”, “예측 정보 활용 가이드라인 개발” 로 구분하여 서술하였다.

가. 계절내 모형 예측성 평가 및 오차 진단

(1) GloSea5 예측성능 비교 및 평가 매트릭스 개발

(가) 기상청-GloSea5 성능 평가 프레임

① 결정론적 성능 평가 프레임

이음새 없는 기상예보를 위한 계절내 예측자료의 중요성에 대한 인식이 증가함에 따라 계절내 예측에 대한 이해를 높이고 예측성능 향상을 위해 다양한 국제 연구들이 수행되고 있다. 그러나 기관별로 생산되는 계절내 예측 데이터의 양은 매우 방대할 뿐만 아니라 기후모델별 계절내 예측 시스템 프로토콜이 상이하다(예, 선행시간, 수평해상도, 앙상블 수, 예측주기, hindcast 기간 등). 따라서 모델별 대등한 평가가 어렵고, 단기예측이나 장기예측과는 달리 표준화된 자료처리 기법과 예측 정확도 평가 기법이 존재하지 않는 실정이다.

APCC에서는 WMO의 S2S prediction project database(Vitart et al., 2017)로부터 다양한 예측모델에서 생산된 계절내 예측자료를 주기적으로 다운로드 받은 후 데이터베이스화 하고 있다. 2018년에는 APCC에서 계절내 예측 분야에 핵심기술을 확보하고 국제적인 흐름에 참여하기 위한 역량 강화의 시작단계로 계절내 예측의 현 주소를 객관적으로 평가하기 위해 수집한 예측자료 중 목요일에 실시간 예측과 과거재현예측을 하는 3개 모델(ECCC, ECMWF, NCEP)을 우선적으로 선정하여 계절내 예측 성능을 분석한 바 있다(문자연 등, 2018). 이를 기반으로 상대적인 관점에서의 기상청 현업 기후예측모델인 GloSea5(Global Seasonal Forecasting Model Version 5, 이하 KMA로 표현) 예측성능 비교/평가를 위해 다음과 같은 3가지로 매트릭스를 개발하였고(Figure 8), 이를 위한 준자동화 시스템을 구축하였다(부록 A).

- 기후값 처방 방안에 따른 상대적 기후값 재현성능 또는 실시간 예측성능 비교/평가
- 타 모델 대비 KMA의 비교우위
- 전년 대비 상대적 기후값 재현성능 또는 실시간 예측성능 개선 여부

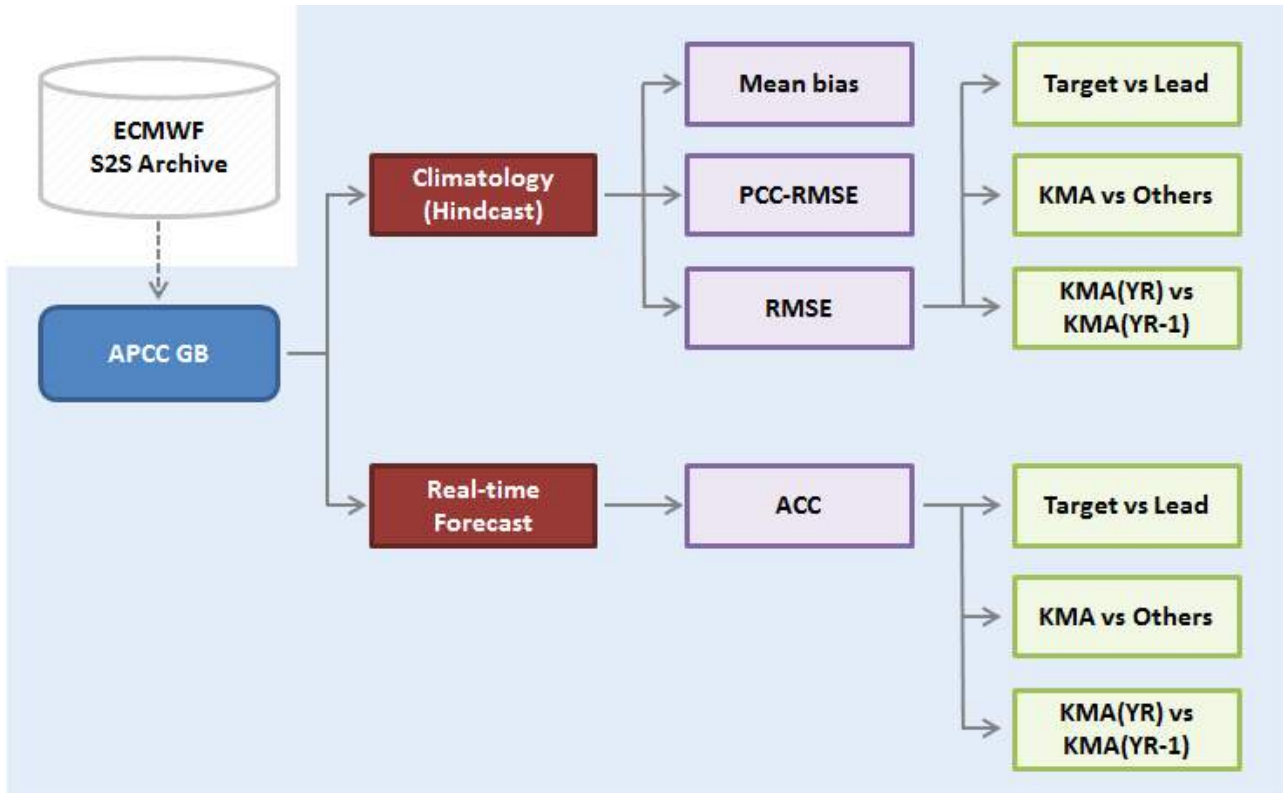


Figure 8. The structure diagram of GloSea5 Verification Framework.

이 보고서에서는 결정론적 예측에 대한 비교/검증을 수행하였다. 기후값 검증에는 mean bias, PCC, RMSE를 실시간 예측의 검증에는 ACC를 적용하였고 각 검증기법에 대한 설명은 아래와 같다.

○ Mean bias

Mean bias는 예측자료와 관측자료의 편차에 대한 시간평균이며 아래와 같이 나타낸다.

$$Mean\ Bias = \frac{1}{n} \sum_{i=1}^n (F - O)$$

○ PCC (Pattern Correlation Coefficient)/ ACC (Anomaly Correlation Coefficient)

PCC는 주로 예측공간분포가 관측과 얼마나 유사한가를 -1부터 1 사이의 값으로 나타내는 지수로, 두 공간분포에서 동일한 위치에 있는 값 간의 상관계수이다. 1에 가까울수록 두 패턴이 비슷함을 나타낸다. ACC는 PCC의 특별한 경우로, 관측과 예측에서 각각 기후값을 제거하여 계산한 상관계수이고 아래와 같이 계산한다.

$$ACC = \frac{\sum_{i=1}^n w_i (f_i - \bar{f})(o_i - \bar{o})}{\sqrt{\sum_{i=1}^n w_i (f_i - \bar{f})^2 \sum_{i=1}^n w_i (o_i - \bar{o})^2}}$$

$$w_i = \cos \phi_i$$

여기서 n 은 샘플수를 ϕ_i 는 위도를 의미하고, $f_i, \bar{f}, o_i, \bar{o}$ 는 각각 예측값, 예측자료의 기후값, 관측값, 관측자료의 기후값을 나타낸다.

○ RMSE (Root Mean Square Error)

RMSE는 모델이 예측한 값과 관측값 사이의 오차를 나타내어 예보의 정확성을 살펴보는 척도로 사용되며, 아래 식과 같이 예측값이 관측값으로부터 갖는 오차를 제공하여 평균한 평균 제공오차의 제곱근으로 계산된다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (F - O)^2}{n}}$$

② 선행시간 혹은 예측시점에 따른 기후값 처방 방안

문자연 등(2018)은 계절내 예측에 있어서 기후값은 선행시간이 길어짐에 따라 성능이 감소하지만 모델별, 지역별 격차가 크고, 모델의 경년변동은 관측에 비해 작고 선행시간이 길어짐에 따라 감소하는 경향이 뚜렷하다고 제시하였다. 이 때 기후값은 각 모델별로 예측 시작날짜와 동일한 날짜(월, 일)에 해당하는 과거재현자료의 공통기간(1999-2010년)에 대한 평균으로 구한 바 있다. 그러나 올해 연구과제에서는 모델별로 예측 시작날짜와 동일한 날짜뿐만 아니라 일주일 전, 후의 날짜까지 총 3개의 과거재현자료를 평균하였는데 이는 1) 기후값을 계산할 때 사용되는 샘플수를 늘려서 안정적인 결과를 낼 수 있을 뿐만 아니라 2) 특히 계절이 바뀌어 기온이 급변하는 시기에도 편향된 예측결과가 나오지 않는다는 장점이 있기 때문이다(이우섭 등, 2017). 2017년 12월 21일에 생성된 예측자료에 대한 기후장을 생성할 경우를 예를 들어 살펴볼 것이다. ECCO, ECMWF, NCEP(이하 3개 모델로 표현)은 매주 목요일에 실시간 예측자료와 과거재현자료를 생산하므로, 실시간 예측자료가 생산되는 날짜와 동일한 12월 21일의 과거예측자료와 일주일 전/후인 12월 14일과 12월 28일의 과거예측자료에서 첫 일주일(월요일-금요일)을 평균하였다. 이와 마찬가지로 2017년 12월 28일의 기후값은 12월 21일, 12월 28일, 다음 해 1월 4일의 과거예측자료를 평균하여 생성하였다(Figure 9). 예측 아노말리는 이렇게 구해진 각 모델별 기후값을 해당날짜의 예측자료에서 뺀 값으로 구하였다.



Figure 9. An example of climatology smoothing method.

이 연구의 목적은 KMA와 타 기관 모델 또는 전년 예측대비의 상대적인 우위를 살펴보는 것이므로, 동일한 조건을 만들기 위해 KMA 역시 3개 모델과 같은 방법으로 기후값을 구해야 할 것이다. 그러나 KMA의 예측자료 생산 스케줄은 3개 모델과는 다르게 과거예측자료의 경우 매 달 1, 9, 17, 25일에, 실시간 자료는 매일 생산하므로 3개 모델 기후값과 완벽하게 동일한 방법으로 동일하게 계산할 수 없다. 따라서 KMA의 기후값을 계산하기 위한 다른 방법이 필요하고, 다음과 같은 두 가지 방법을 제안하였다.

○ 예측시점에 따른 기후값 처방 방법(Target based KMA)

예측시점은 3개 모델에서 기후값을 계산하기 위해 사용된 과거예측자료의 예측날짜를 의미하는데, 예측일과 동일한 날짜를 포함한 1주일 전/후의 날짜이다. 예를 들어, 2018년 2월 15일 예측자료의 1주차 기후값을 구하기 위해서 3개 모델에서는 2월 12일부터 3월 4일까지의 과거재현자료가 필요하다. 3개 모델에서는 각 과거예측자료의 첫 번째 월-일요일을 가져오는데 2월 8일 과거예측자료에서 2월 12일~18일을, 2월 15일 과거예측자료에서 2월 19~25일을, 2월 22일 과거예측자료에서 2월 26일~3월 4일 날짜를 택한 후 평균한 값이 1주치의 기후값이 된다(Figure 10(a)). 그러나 KMA는 일주일 간격의 과거예측자료가 없기 때문에 예측시점과 가장 가까운 3개의 과거예측자료인 2월 9일, 2월 17일, 2월 25일로부터 각각 2월 12~18일, 2월 19~25일, 2월 26일~3월 4일을 가져온 후 평균한 값이 1주차 기후값이 된다(Figure 10(b)). 이렇게 4주차까지의 기후값을 계산할 수 있다.

○ 선행시간에 따른 기후값 처방 방법(Lead based KMA)

3개 모델의 기후값 처방 시에 과거재현자료로부터 월-일요일을 각각 평균하게 되는데, 이는 1주차부터 4주차까지 선행시간 5-11일, 12-18일, 19-25일, 26-32일에 해당한다. 따라서 KMA 기후값 처방시에 선행시간의 관점에서 기후값을 계산하는 방법 또한 생각해 볼 수 있다. 앞서 예를 든 2018년 2월 15일 예측자료의 경우에 1주차 기후값은 KMA 과거예측자료 2월 9일, 2월 17일, 2월 25일로부터 선행시간 5-11일인 2월 13~19일, 2월 21~27일, 3월 1일~7일에 해당하는

값을 평균하여 생산할 수 있고(Figure 10(c)), 이 방법 역시 4주차 기후값까지 생산가능하다.

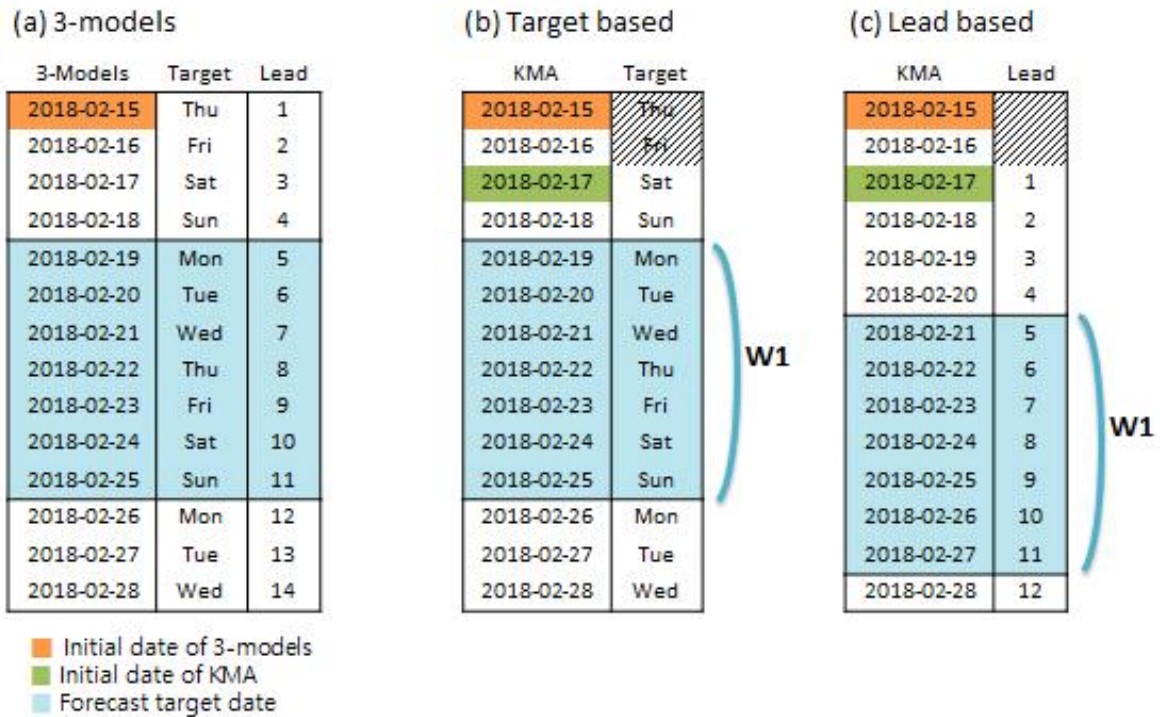


Figure 10. An example of calculating 1-lead week for climatology from (a) 3-models, (b) target based KMA, and (c) lead based KMA.

(나) 기후값 재현성 평가

모델의 실시간 예측성능을 살펴보기에 앞서 정의한 모델별 기후값의 재현성능 먼저 평가해보고자 한다. IPCC 4차 평가보고서 8장에 따르면 기후모의에 대한 평가는 모델의 해양의 계통오차 등이 가져오는 열 흡수량과 점증기후반응의 불확실성 때문에 필요하다고 언급한 바 있다(Randall et al, 2007). Figure 11의 가로축은 2018년 연평균 기후값의 RMSE, 세로축은 PCC를 나타낸 것으로, 모델별, 지역별(전구 및 동아시아) 1주 선행시간(색칠된 동그라미)에서 시작하여 4주까지의 변화를 변수별로 보여준다. 예상한 바와 같이 전반적으로 변수는 지역과는 상관없이 모델들의 기후값 재현성능이 떨어져 선행시간이 지남에 따라 RMSE는 높아지고 PCC는 낮아진다. 모델의 전구 재현능력을 살펴보면 ECMWF가 가장 우위에 있는 것으로 판단된다. 특히 강수의 경우 ECMWF는 선행시간이 증가함에도 불구하고 RMSE와 PCC의 변화가 다른 모델에 비해 거의 없다. KMA의 기후값 재현능력은 기후값 처방 방법에 따른 성능 차이가 거의 차이가 없고, ECCC나 NCEP에 비해 성능이 좋다. KMA의 동아시아 기온 기후값 재현능력은 다른 3개 모델에 비해 월등히 좋다는 점은 두드러지는 특징 중 하나이다. KMA는 동아시아 강수의 경우 ECCC와 NCEP에 비해 기후값을 잘 재현하고, 동아시아 500hPa 지위고도의 경우는 NCEP보다는 관측과 더 유사한 기후값을 생산했다고 볼 수 있다. 계절별 기후값에 대한 RMSE-PCC 관점의 재현성능은 부록 B를 참고하면 된다.

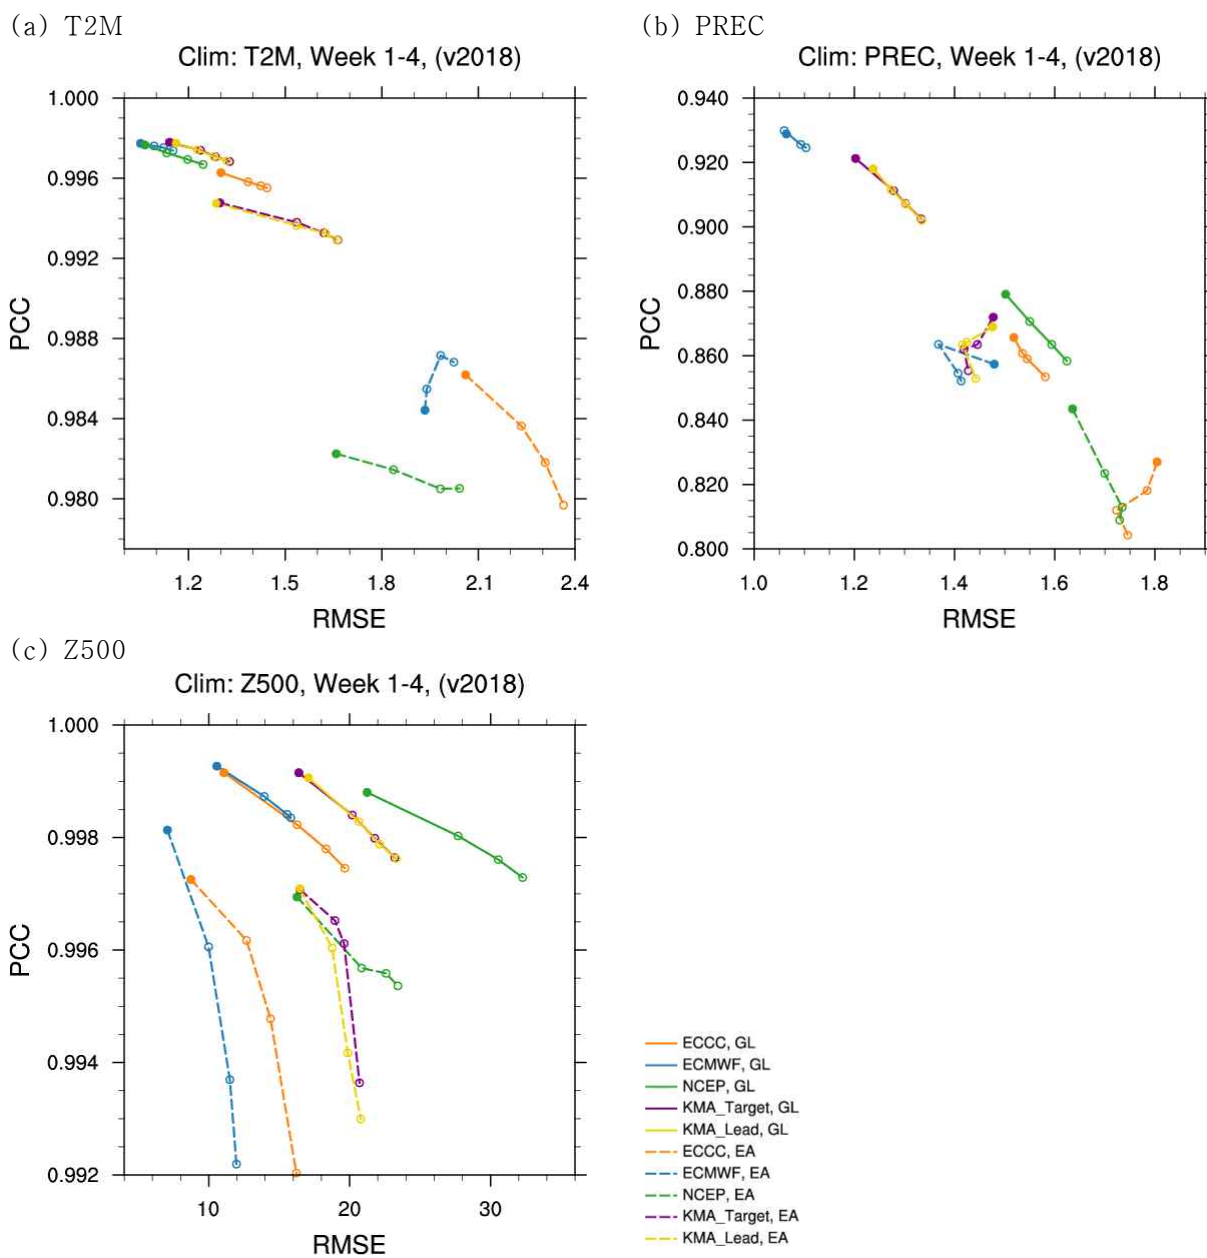


Figure 11. Scatter diagram of annual RMSE and PCC of (a) T2M, (b) PREC, and (c) Z500 for ECCC (orange), ECMWF (blue), NCEP (green), target based KMA (purple), and lead based KMA (yellow) for 1- to 4-lead week over Globe (solid line) and East Asia (dashed line). Closed circle indicates 1-lead week.

앞서 언급한 대로, 이 연구의 목적은 KMA 모델의 다른 모델과 비교하여 상대적으로 KMA의 기후값은 얼마나 잘 재현되는지를 알아보는 것이다. 여기서는 재현성을 공간적 오차의 관점에서 바라보기 위해 KMA와 다른 모델의 기후값 RMSE의 상대적 차이에 대한 연평균 및 계절평균을 Figures 12-14에 나타내었다. 여기서 KMA의 기후값은 예측시점을 기준으로 하여 계산되었다. 변수별, 모델별로 가로축은 계절(연평균, 봄/여름/가을/겨울평균)을 세로축은 지역(전구, 동아시아) 평균을 나타낸다. 위쪽 삼각형에서부터 반시계방향으로 진행되면서 선행시간이

증가하며 위, 왼쪽, 아래, 오른쪽 삼각형은 각각 1, 2, 3, 4주 선행시간을 의미한다. 여기서 RMSE의 상대적인 차이는 아래 수식으로 계산하고, 양의 값을 가질 때는 타 모델에 비해 KMA의 재현능력이 좋고 음의 값이면 KMA의 상대적인 재현능력이 나쁨을 의미한다.

$$Relative\ diff\ of\ RMSE(\%) = \frac{RMSE_{other} - RMSE_{KMA}}{RMSE_{KMA}} \times 100$$

또한 상대적인 RMSE 차이가 신뢰할만한 값인지 확인하기 위해 상대적 RMSE 차이가 극값의 범주에 속하였는지를 판단하였다. 변수별/지역별/선행시간별로 3개 모델 전체에 대한 상대적 RMSE 차이의 상/하위 25 퍼센타일값을 각각 구한 후 둘 중 큰 절대값을 기준으로 삼고 상대적 RMSE 차이가 -1*기준값보다 작거나 기준값보다 클 때 신뢰할만한 차이가 있는 것으로 정의하였다. 전체적으로 KMA 기후값 재현성능은 1주부터 4주 선행시간까지 같은 경향성이 유지되는 특징이 있다. 기온과 강수의 재현성능은 4주 선행시간까지 ECCC와 NCEP보다 좋고 ECMWF보다는 나쁜 경향이 있다. 그러나 동아시아 기온의 경우는 ECMWF를 포함한 3개 모델보다 KMA가 기후값을 더 잘 재현하는 특징이 있다. 500hPa 지위고도의 기후값 재현성은 ECCC와 ECMWF가 KMA에 비해 좋은데, 특히 ECMWF의 경우는 전반적으로 신뢰할만한 수준의 차이를 보인다. 반면에 NCEP의 500hPa 지위고도 기후값은 KMA보다 재현성능이 좋지 않고 전구 500hPa 지위고도의 경우는 KMA와의 차이가 더 커진다.

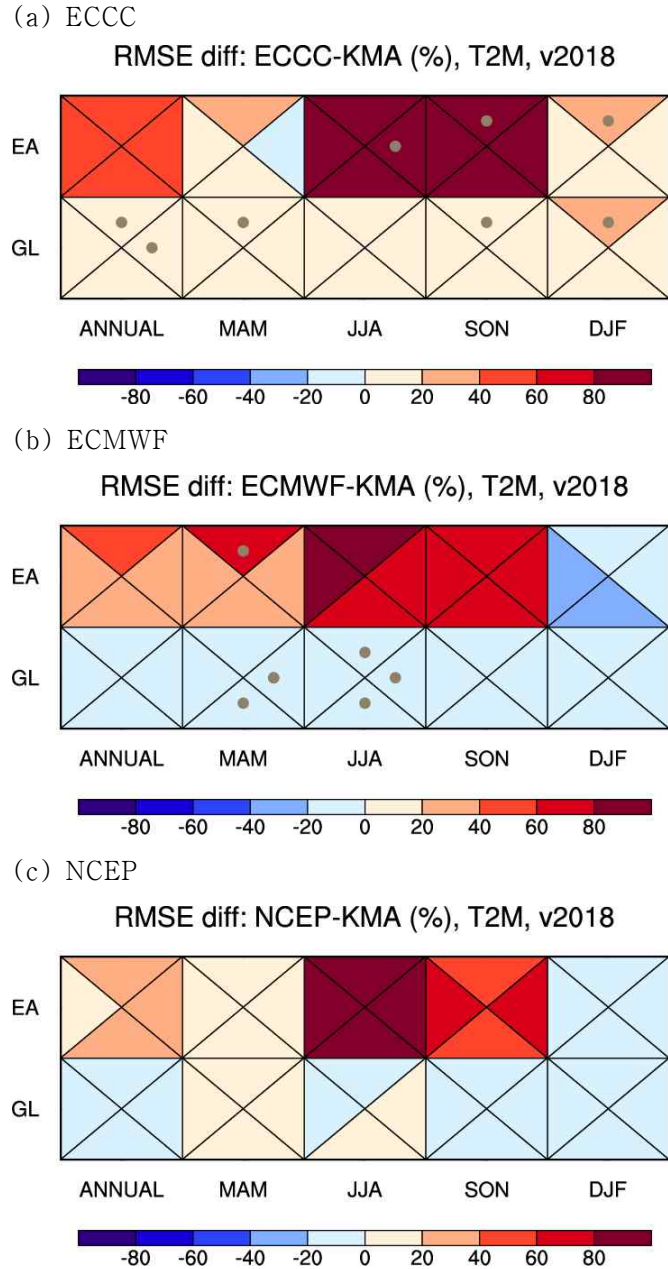



Figure 12. Annual and seasonal averaged relative RMSE difference of climatology of T2M over East Asia and Globe of ECCC, ECMWF, and NCEP with target based KMA. The top, left, bottom and right triangles represent for 1-lead, 2-lead, 3-lead and 4-lead week, respectively. Gray dot indicates that relative difference is significantly large.

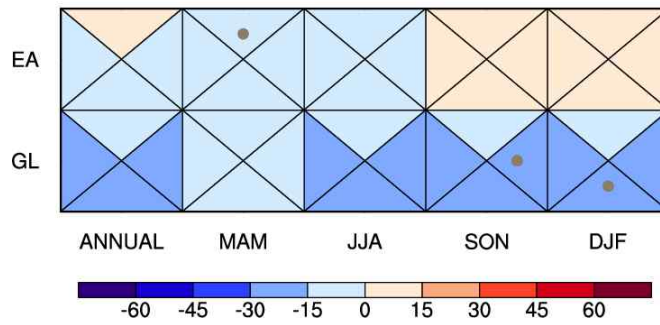
(a) ECCC

RMSE diff: ECCC-KMA (%), PREC, v2018



(b) ECMWF

RMSE diff: ECMWF-KMA (%), PREC, v2018



(c) NCEP

RMSE diff: NCEP-KMA (%), PREC, v2018

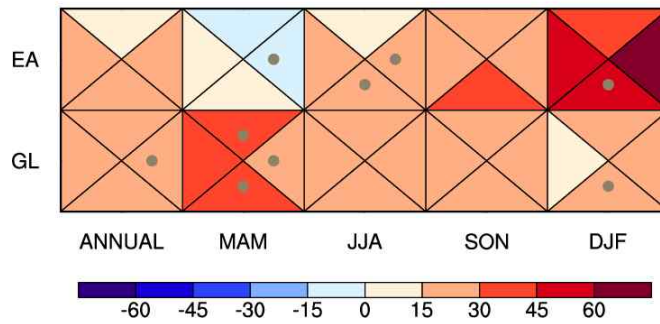


Figure 13. Same as Figure 12, except for PREC.

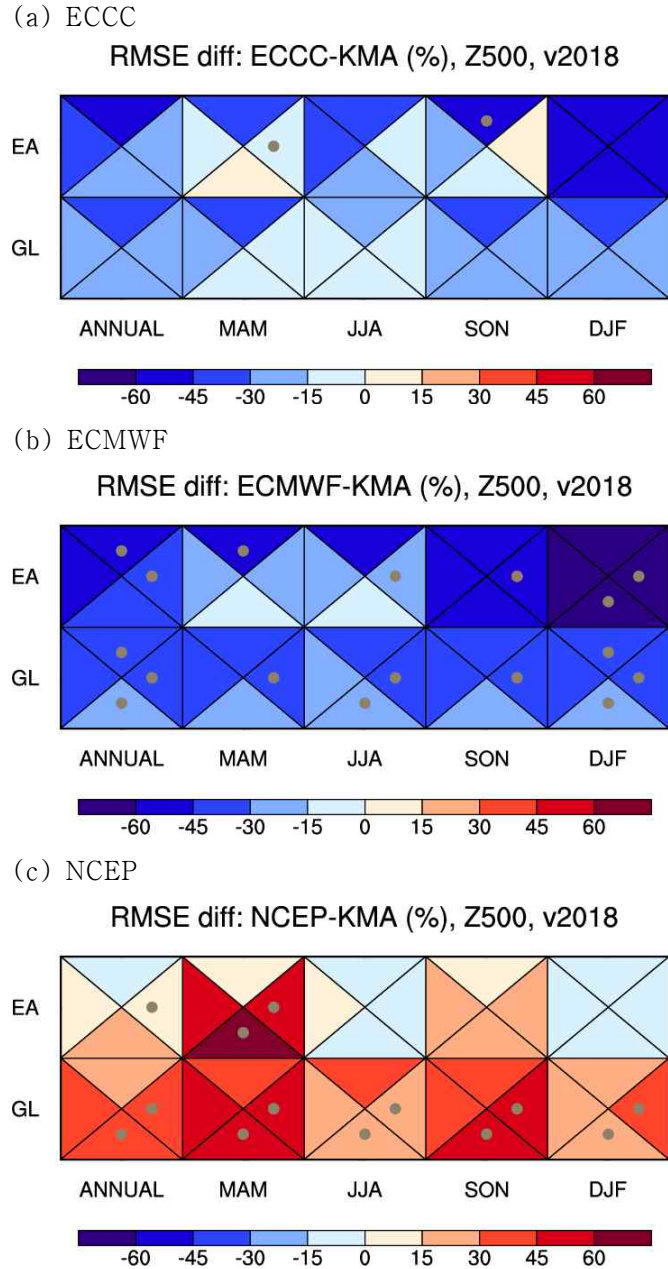


Figure 14. Same as Figure 12, except for Z500.

(다) 2018 실시간 예측성 평가

2018년 실시간 주평균 예측에 대해서 5개 예측자료(ECCC, ECMWF, NCEP, target based KMA, lead based KMA)에 대한 변수별 결정론적 예측능력을 살펴보고자 한다. Figure 15에서는 3개 변수의 전구 예측성능을 4주간 누적하여 보여준다. 4주 누적된 예측성능 중에서 1주차 예측자료나 변수에 상관없이 가장 큰 비율을 차지한다. 변수별 특징을 살펴보면 누적 예측성능은 기온, 500hPa 지위고도, 강수 순으로 떨어진다. 모델 중 ECMWF는 상대적으로 높은 예측성이 4주까지 유지되는데, 기온에 대한 누적예측성능이 다른 두 변수보다 높고 특히 강수에 대한 예측성은 NCEP에 비해 약 2배 가까운 누적예측성능 값을 가진다. 1주 선행시간에서 500hPa

지위고도의 예측성능은 모든 모델에서 다른 변수에 비해 높으나, 선행시간이 진행됨에 따라 급격한 예측성능의 저하를 보인다. 1주 선행시간에서 비슷한 수준의 예측능력을 보인 기온과 비교해보기 위해 ECMWF를 예를 들어 살펴보면, 1주 선행시간에서 기온은 0.76, 500hPa 지위고도는 0.82로 500hPa 지위고도의 예측성능이 약간 우수하나 500hPa 지위고도의 예측성능은 기온에 비해 급격하게 줄어들어 4주 선행시간일 때는 기온이 0.24, 500hPa 지위고도가 0.14이다. KMA의 기후값 처방방법에 따른 전구 누적 예측성능의 차이는 거의 없고 ECMWF에는 미치지 못하나 대부분 ECCC와 NCEP에 비해서는 좋은 것으로 판단된다.

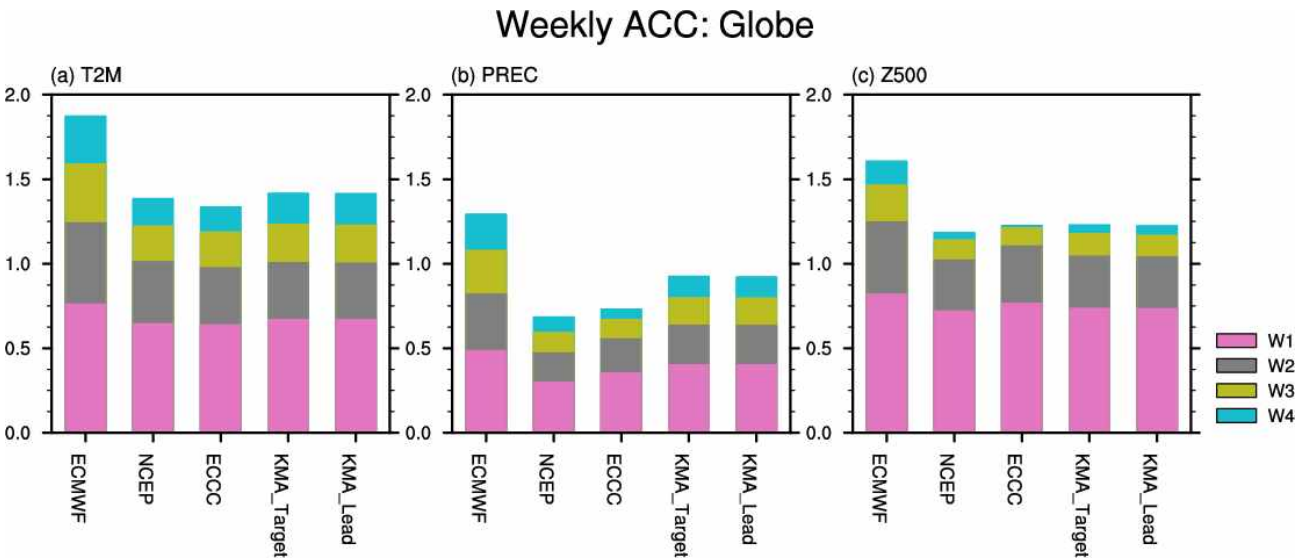


Figure 15. ACC of Global (a) T2M, (b) PREC, and (c) Z500 for 4 lead weeks of ECCC, ECMWF, NCEP, target based KMA, and lead based KMA.

Figure 16에는 동아시아의 4주 누적 예측성능을 나타내었다. 동아시아 역시 변수와는 상관 없이 ECMWF의 예측성능이 우수하다. 변수별로 비교해보면 전구와는 다르게 500hPa 지위고도의 예측성능이 더 우수하나 강수의 예측성능은 전구보다 더 낮다. 5개 예측자료 중 ECCC는 유일하게 3-4주 선행시간의 동아시아 기온과 500hPa 지위고도의 예측성능이 타 모델에 비해 확연하게 떨어지므로 기온과 지위고도의 3-4주 예측이 힘들다고 할 수 있고, 4주 누적 예측성능 역시 가장 낮다. 반면 강수에서는 NCEP이나 KMA보다 우월한 예측성능을 보이는 것이 특징적이다. KMA는 모든 변수에서 기후값 처방방법에 따라 전구에서 보다는 약간의 성능 차이를 보이는데 예측시점에 따른 방법이 선행시간에 따른 방법에 비해 예측이 조금 더 우수하지만 통계적인 차이는 없고 NCEP과 비슷한 수준의 예측성능을 보인다.

Weekly ACC: E.Asia

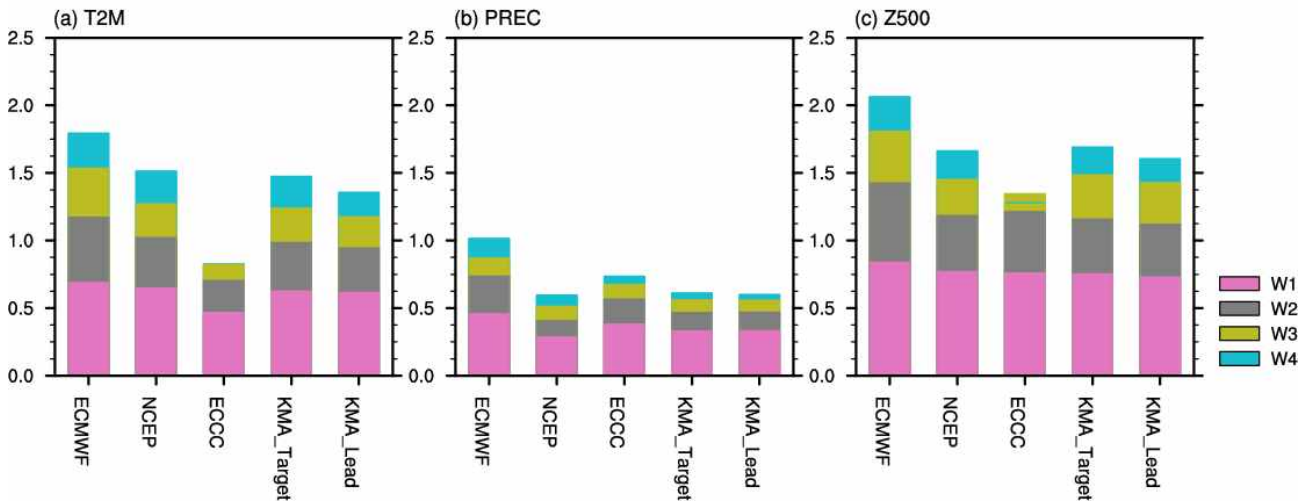


Figure 16. ACC of East Asian (a) T2M, (b) PREC, and (c) Z500 for 4 lead weeks of ECCO, ECMWF, NCEP, target based KMA, and lead based KMA.

① 기후값 처방에 따른 예측 성능 민감도

2018년 KMA의 실시간 예측성능을 기후값 처방에 따라 상대적으로 비교한 결과를 Figure 17에 제시하였다. 아래 수식에서 알 수 있듯이 빨간색 계열은 예측시점을 기준으로 기후값을 처방한 실시간 예측성능이 더 좋음을, 파란색 계열은 반대로 선행시간 기준으로 기후값을 처방한 예측성능이 더 우수함 보여준다. 전반적으로 예측시점을 기준으로 기후값을 처방한 예측장에서, 그리고 전구보다 동아시아에서 더 좋은 예측성능이 보인다. 특히 동아시아 기온의 경우 예측시점을 기준으로 기후값을 처방하면 선행시간이 길어질수록 예측성능의 차이가 더 커진다. 또 하나의 특징은 가을철에는 전반적으로 예측시점과 선행시간 기후값 처방 방법 간의 예측성능 차이가 다른 계절에 비해 뚜렷하다는 점이다.

$$Relative\ diff\ of\ ACC(\%) = \frac{ACC_{Target} - ACC_{Lead}}{ACC_{Target}} \times 100$$

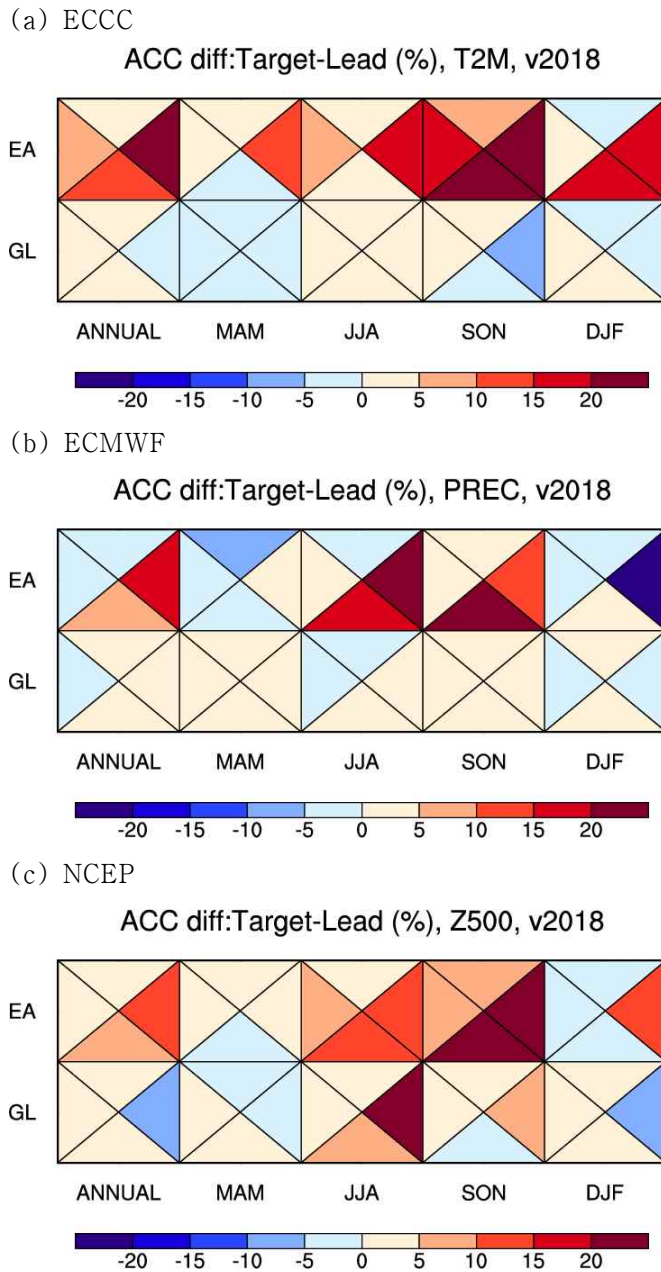


Figure 17. Annual and seasonal averaged relative ACC difference between target and lead based KMA of 2018 real-time forecast of (a) T2M, (b) PREC, and (c) Z500 over East Asia and Globe. The top, left, bottom and right triangles represent for 1-lead, 2-lead, 3-lead and 4-lead week, respectively.

기후값 처방 방법에 따른 예측성능 차이를 보기 위해 실시간 예측 시작날짜로부터 예측 시작시점간의 차이의 합과 예측성능간의 관계를 살펴보았다. 여기서 가로축은 실시간 예측 시작날짜로부터 첫 예측시점 날짜의 차이에 대한 합으로, 예를 들어 2018년 3월 29일 목요일에 대한 실시간 예측 시작날짜는 그 다음주 월요일인 2018년 4월 2일이고, KMA 모델의 첫 예측 시작날짜인 2018년 3월 25일, 4월 1일, 4월 9일에 대한 예측시작날짜는 각각 2019년 3월 26일,

4월 2일, 4월 9일로, 실시간 예측 시작날짜로부터의 차이는 -7일, 0일, 7일로 이들의 합은 0이다. 이런 식으로 모든 2018년 예측에 대해 선행주수별로 제시하였다. Figure 18에는 봄철 전구 기온과 동아시아 여름철 강수의 1주 선행시간에 대한 예측시점 및 선행시간 기준 기후값을 이용한 예측성능과 날짜 차이(절대값)에 대한 관계를 나타내었다. 날짜 차이가 커질수록 예측성능이 떨어지는 자명한 결과가 보이는데, 1주 선행시간에서는 선행시간 기준 예측성능이 예측시점 기준 예측성능의 날짜 차이에 대한 민감도가 더 크다. 그러나 전반적으로 본다면 겨울에서 여름으로 계절이 바뀌는 봄철일 때 여름보다 더 민감한 예측성능을 보임을 알 수 있다.

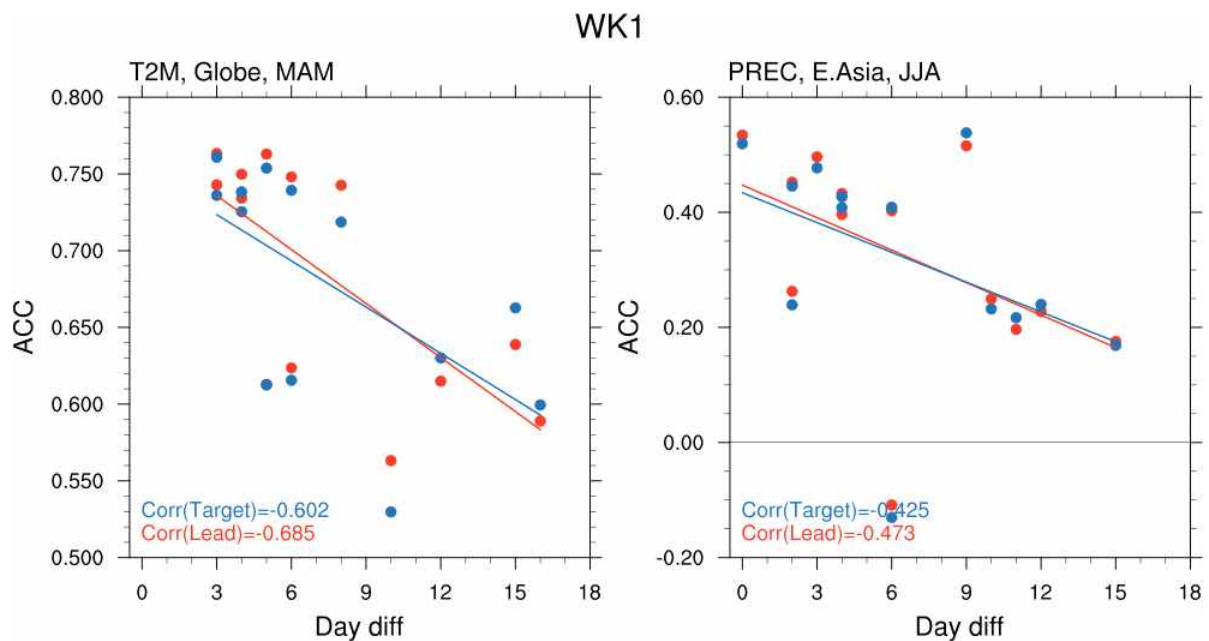


Figure 18. Scatter plot of day difference and 1-lead week ACC of (Left) T2M for MAM over globe (left) and PREC for JJA over East Asia (right) of target based KMA (blue) and lead based KMA (red). The solid line indicates correlation between day difference and ACC.

그렇다면 계절이 바뀌는 시기에 날짜 차이에 대한 예측성능의 민감도는 선행시간에 따라 어떻게 달라지는지 알아보기 위해 가을철 동아시아 500hPa 지위고도에 대한 2주 및 4주 선행시간의 민감도를 살펴보았다(Figure 19). 2주 선행시간에서도 역시 날짜차이에 대한 선행시간 기준 예측성능이 예측시점 기준 예측성능에 비해 민감하긴 하나, 상관계수가 예측시점 기준으로는 -0.145, 선행시간 기준으로는 -0.188로 전반적으로 날짜 차이에 대한 민감도 자체는 크지 않다고 볼 수 있다. 4주 선행시간에서도 역시 선행시간 기준 예측성능이 예측시점 기준 예측성능에 비해 큰 상관계수를 보임으로써 조금 더 민감하게 반응하나, 2주차와 비교했을 때 예측시점 기준 -0.669, 선행시간 기준 -0.757의 상관계수를 보이며 전반적인 민감도는 더 커진다. 결론적으로 선행시간에 따라 예측성능이 저하되는 것 보다 계절적인 변화에 따라서 예측성능이 더 크게 변할 수 있음을 알 수 있다. 그러나 항상 날짜 차이가 커짐에 따라 예측성능이 줄어드는 것은 아니다. 여름철 동아시아 500hPa 지위고도의 경우에는 날짜 차이가 커짐에도 불구하고 예측성능이 이제까지와는 다르게 커지는데(Figure 20) 여기에 대해서는 향후 연구가 필요한

부분이라고 생각된다.

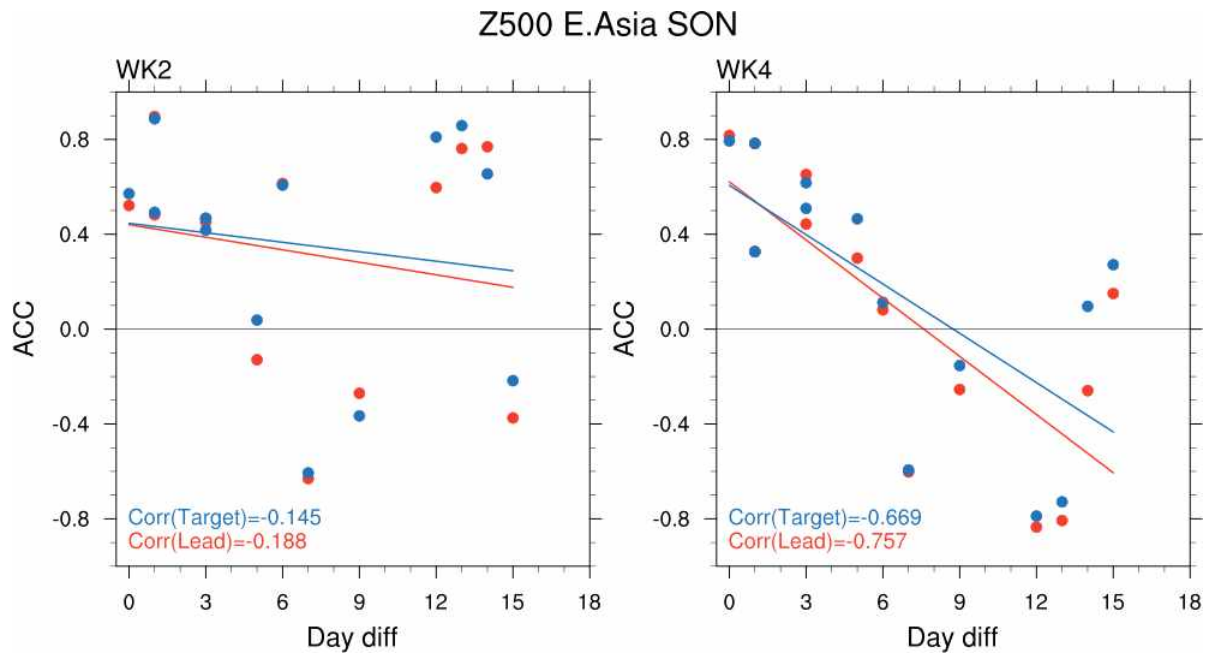


Figure 19. Scatter plot of day difference and 2-lead (left) and 4-lead (right) week ACC of Z500 for SON in East Asia of target based KMA (blue) and lead based KMA (red). The solid line indicates correlation between day difference and ACC.




Figure 20. Scatter plot of day difference and (a) 2-lead and (b) 4-lead week ACC of Z500 for JJA in East Asia of target based KMA (blue) and lead based KMA (red). The solid line indicates correlation between day difference and ACC.

② 타 모형대비 비교 우위

2018년 KMA 실시간 예측자료의 예측성능을 타 모델과 비교하여 제시하였다. 여기서 기후 값은 예측시점을 기준으로 생산하였다. KMA의 기온 예측은 ECCC에 비해 전반적으로 우수한 하고 전구 예측보다는 동아시아 기온 예측성능이 더 뛰어나다. 계절별로 나누어 살펴보면 봄철과 여름철 기온을 잘 예측하는데, 3-4주로 갈수록 예측성능간의 차이가 더 커진다 (Figure 21(a)). ECMWF는 KMA에 비해 좋은 예측성능을 보이는데, 동아시아 가을철 기온의 예측에서는 3주를 제외하고 KMA의 예측성능이 더 좋으며 특히 4주 선행시간에서는 신뢰할만한 차이를 보인다(Figure 21(b)). NCEP과는 뚜렷한 성능차이가 나타나지는 않았으나, 전반적으로 동아시아 보다는 전구 기온에 있어서 KMA가 NCEP보다 나은 예측성능을 보여준다(Figure 21(c)).

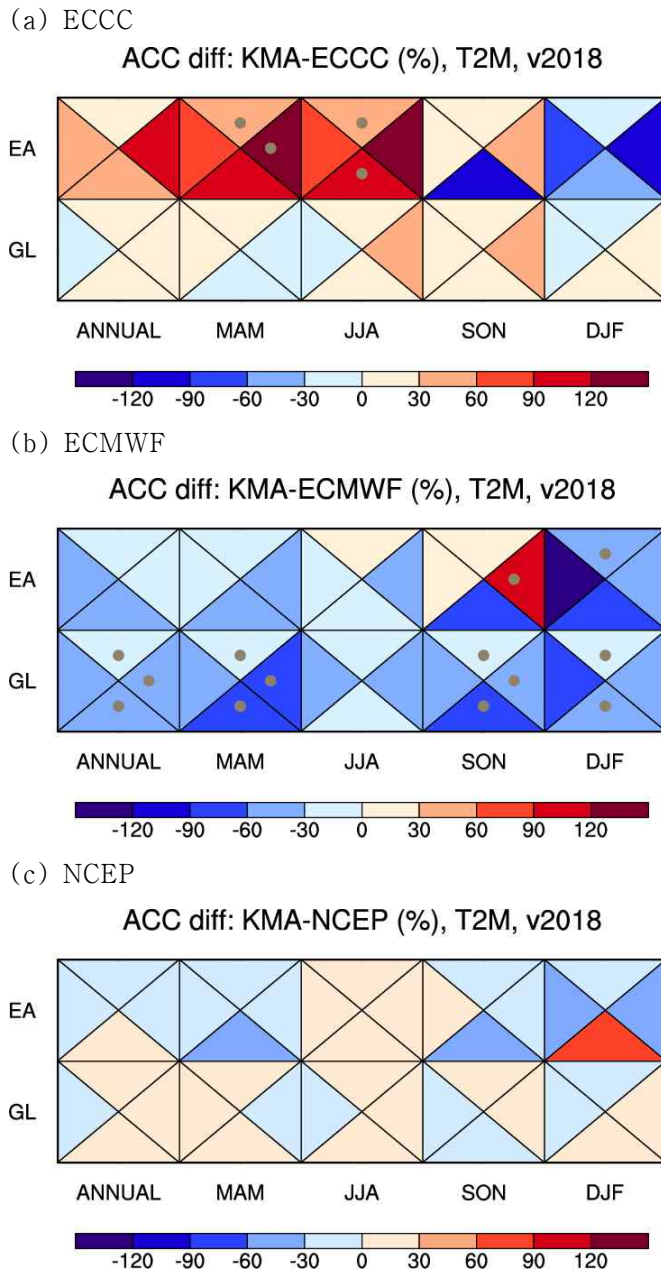


Figure 21. Annual and seasonal averaged relative ACC difference of 2018 real-time forecast of T2M over East Asia and Globe of (a) ECCC, (b) ECMWF, and (c) NCEP with target based KMA. The top, left, bottom and right triangles represent for 1-lead, 2-lead, 3-lead and 4-lead week, respectively. Gray dot indicates that relative difference is significantly large.

Figure 22에는 500hPa 지위고도에 대한 타 모델 대비 KMA의 상대적 예측성능을 제시하였다. ECCC에 비하여 KMA는 선행시간이 지남에 따라 3-4주에서 예측성능이 점차적으로 우위에 있게 되는 특징을 보인다. ECMWF의 예측성능은 전체적으로 KMA보다 우위에 있으나, 가을철 동아시아 500hPa 지위고도의 예측성능은 특히 3-4주일 때 KMA가 ECMWF보다 예측성능이 좋다. 또한 KMA와 NCEP의 기온 예측성능은 큰 차이가 없었던 반면, 500hPa 지위고도의 4주 선행시간에 대한 KMA의 예측성능이 상대적으로 NCEP에 비해 우수한 경향이 있다.

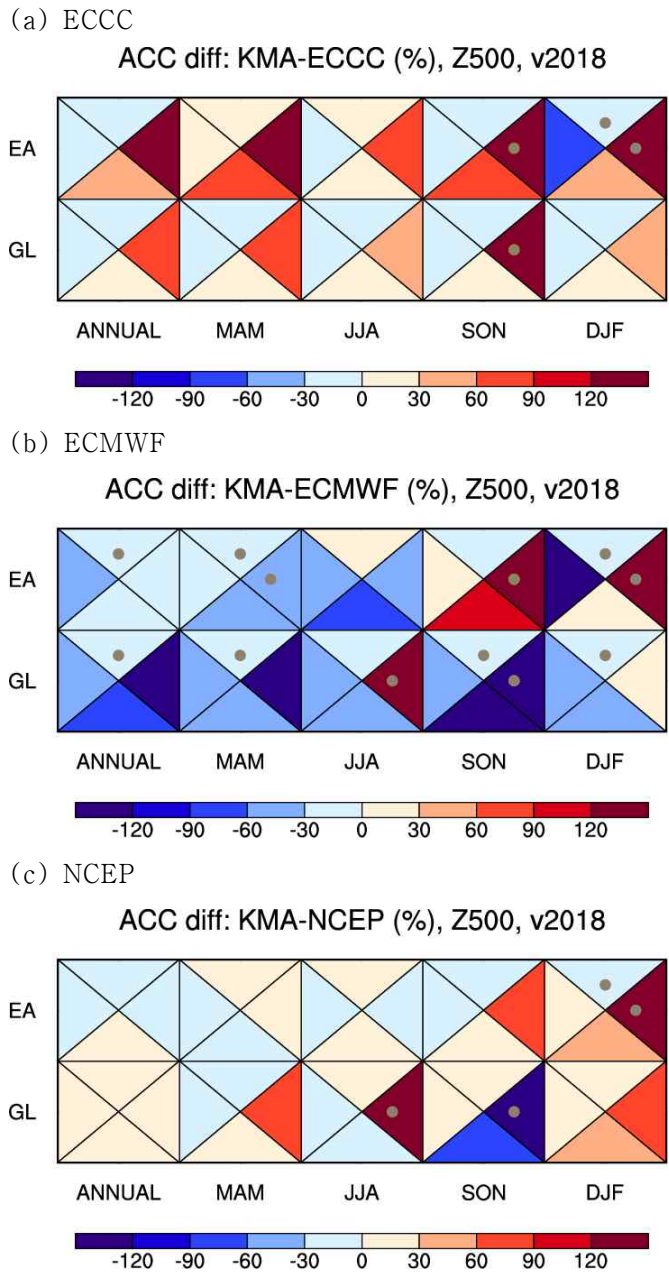


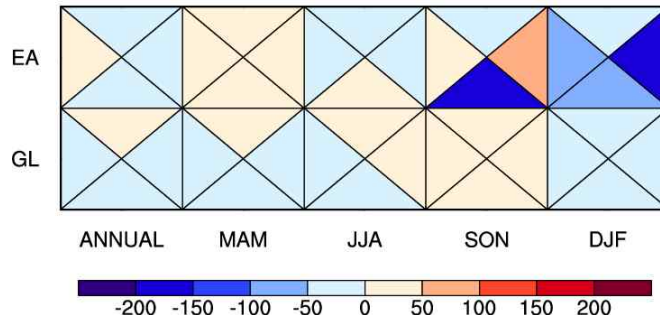
Figure 22. Annual and seasonal averaged relative ACC difference of 2018 real-time forecast of Z500 over East Asia and Globe of (a) ECCC, (b) ECMWF, and (c) NCEP with target based KMA. The top, left, bottom and right triangles represent for 1-lead, 2-lead, 3-lead and 4-lead week, respectively. Gray dot indicates that relative difference is significantly large.

③ 2017년 대비 예측성 개선 여부

KMA의 2018년 실시간 예측성능을 2017년의 예측성능과 비교하여 얼마나 개선되었는지 Figure 23에 나타내었다. 대체적으로 2017년과 2018년 예측성능은 크게 차이하지 않는다. 그럼에도 불구하고 몇 가지 살펴보면, 2017년 겨울철 기온 예측성능은 전구와 동아시아에서 모두 2018년에 비해 우수하고 이러한 특성이 선행시간 4주까지 이어진다. 또한 겨울철 전구 강수의 경우 3-4주 선행시간에서 2017년의 예측성능이 더 좋아지는 특징을 보인다. 선행연구에서 계절 내 예측의 주별 예측성능은 선행시간이 증가할수록 전구와 동아시아 등에서 적분 초기시점의 ENSO에 영향을 받고 전구 강수의 경우에는 ENSO에 대한 의존도가 점차 커짐을 제시한 바 있는데(문자연 등, 2018; 김가영 등, 2019), 2017년 겨울에는 약한 라니냐(CPC의 2017년 겨울철 ONI지수 참조: http://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php)가 지속되었기 때문에 2018년 보다 2017년 겨울철 전구/동아시아 기온과 전구 강수의 예측성능이 좋은 이유 중 하나로 판단해볼 수 있다.

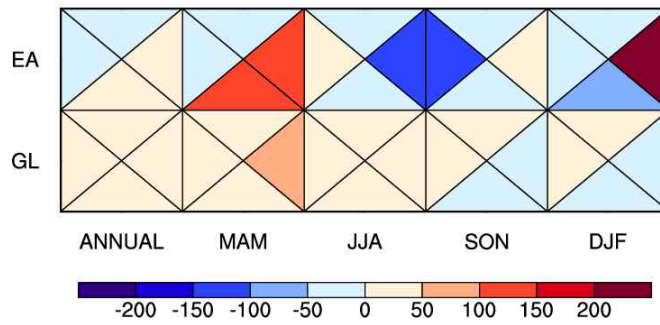
(a) ECCC

ACC diff: v2018-v2017 (%), T2M



(b) ECMWF

ACC diff: v2018-v2017 (%), PREC



(c) NCEP

ACC diff: v2018-v2017 (%), Z500




Figure 23. Annual and seasonal averaged relative ACC difference between 2017 and 2018 real-time forecast of (a) T2M, (b) PREC, (c) and Z500 over East Asia and Globe of target based KMA. The top, left, bottom and right triangles represent for 1-lead, 2-lead, 3-lead and 4-lead week, respectively.

(2) GloSea5 구조적 오차 진단

(가) 과거재현기후의 오차 진단

① 계통적 오차 특성

기본적인 예측 성능을 위해 주요 예측 변수들에 대해 월별 평균된 공간 상관 계수를 통해 검증하였다. 그 중 상층 변수 일부에 대한 검증 결과를 Figure 24에 나타내었다. 대부분의 계절에서 공통적으로 선행시간 3주의 결과에서 약 0.5 전후의 상관계수를 보이는 것을 알 수 있다. 그러나 NWP범위에 해당하는 선행시간 1주에서도 현저히 떨어지는 예측성능을 보이는 결과가 나타나는 것을 알 수 있다. 이러한 결과를 보다 자세히 살펴보기 위해 낮은 예측성능을 보이는 사례들 중 1991년 3월 9일 초기장을 사용한 결과의 선행시간 1일의 결과를 ERA-Interim 재분석 자료와 비교하여 Figure 25에 나타내었다. 재분석자료와 비교하였을 때, GloSea5의 결과에서는 중위도 지역을 중심으로 비정상적으로 낮은 값이 분포하고 있음을 알 수 있으며, 이는 일정 값 이상이 되었을 때 나타나는 패턴을 보이고 있어 (U200, Z200 동일하게 나타남) 모델 그 자체의 문제가 아닌 결과값 후처리 혹은 변환과정에서 나타나는 현상으로 판단된다. 또한, 사용된 결과가 현재까지 WMO S2S 웹페이지에 공유되고 있음에 주의해야 한다. 본 연구에서는 Hindcast version 2017과 동일한 설정으로 구성된 version 2018의 상하층 바람장, 지위고도장, 기온, 강수 등의 결과를 사용하기로 한다.

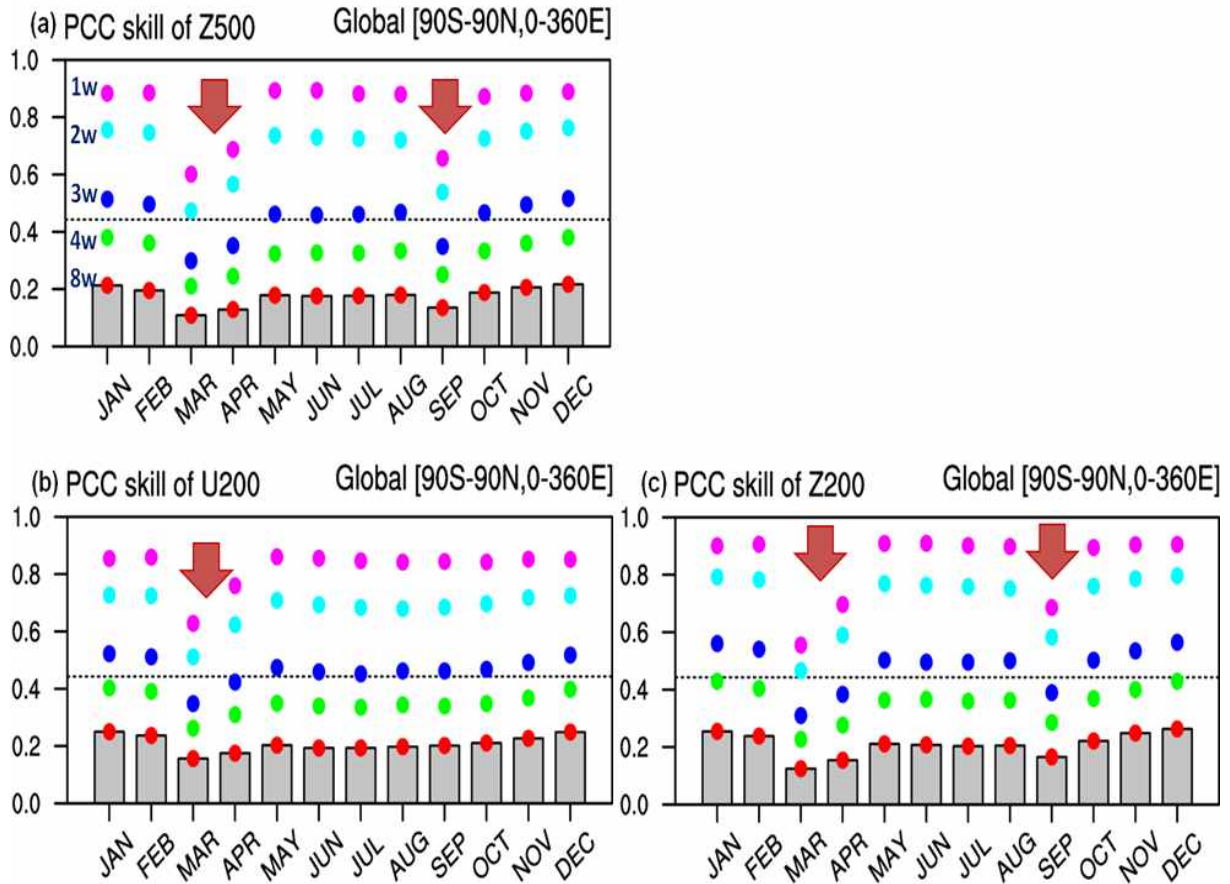


Figure 24. Monthly averaged lead week pattern correlation coefficient (PCC) for (a)Z500, (b)U200, (c)Z200. Dashed line is for 95% significant level. Pink, sky-blue, deep-blue, green, and red dot mean 1, 2, 3, 4, and 8 week lead time, respectively.

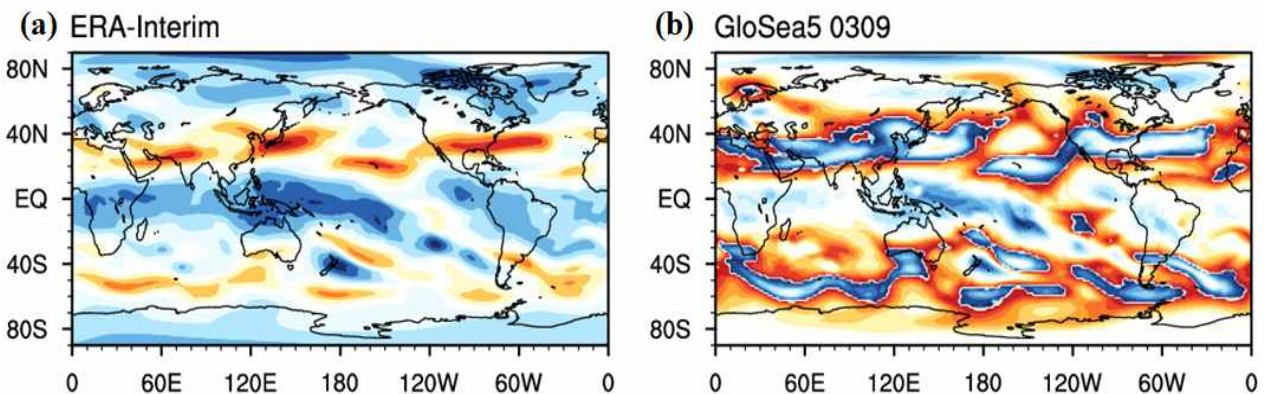


Figure 25. Horizontal distribution of 500hPa geopotential height for 10 March 1991 from (a) ERA interim reanalysis data and (b) GloSea5 initialized 9 March 1991 (1-day lead time).

Hindcast v2018의 기본적인 예측 성능 진단을 위해 지표 온도 및 강수의 주별 선행시간의

시간상관계수 분포를 Figure 26과 Figure 27에 각각 나타내었다. 주별 지표 온도의 예측성능을 살펴보면 선행시간 4주까지 0.6이상의 높은 시간상관계수를 보이고 있음을 알 수 있다. 선행시간 3-4주에서는 극지역 및 Maritime Continent 지역 일부, 대륙 지역을 중심으로 상관계수가 다소 낮아진다. 지표 온도와는 달리 강수의 주별 평균 시간 상관 계수의 분포는 적도 태평양 강수대를 제외하고 매우 낮게 나타나고 있다. 이는 대부분의 기후 예측 모형에서 나타나는 특징이다. 선행시간 1주에는 대부분의 지역에서 높은 상관 계수를 보이지만, 선행시간이 길어질수록 상관 계수는 급격히 감소한다. 특히 선행 시간 3-4주에 육지지역 및 중위도, 극지역 대부분에서 상관계수는 0에 가깝게 낮다. 하지만, 적도 태평양 및 대서양 인도양 일부까지 높은 상관계수를 유지하고 있다.

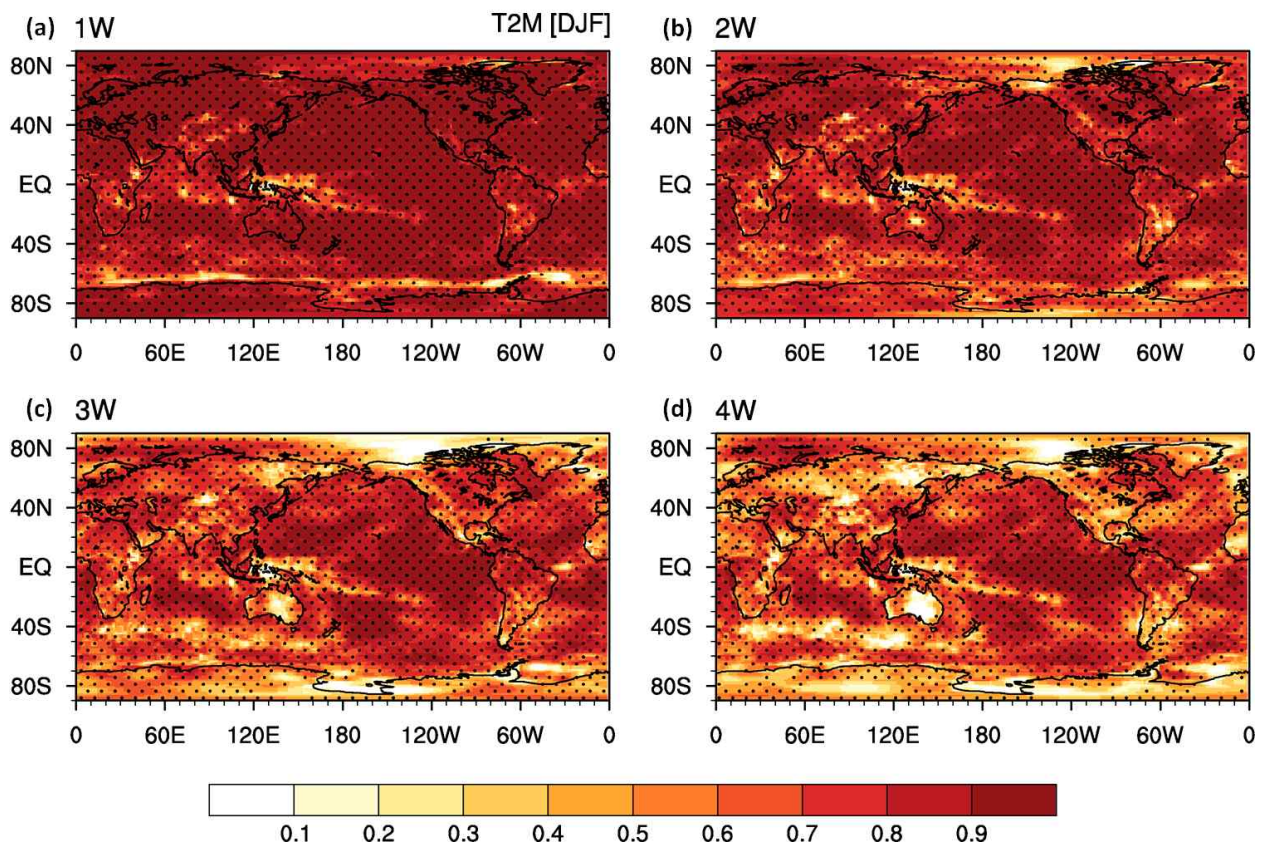


Figure 26. Temporal correlation coefficient (TCC) of the 2m temperature between ERA interim reanalysis data and GloSea5 hindcast with (a)-(d)1-4 week lead for DJF. Dots in (a)-(d) indicates the area statistically significant at the 95% level.

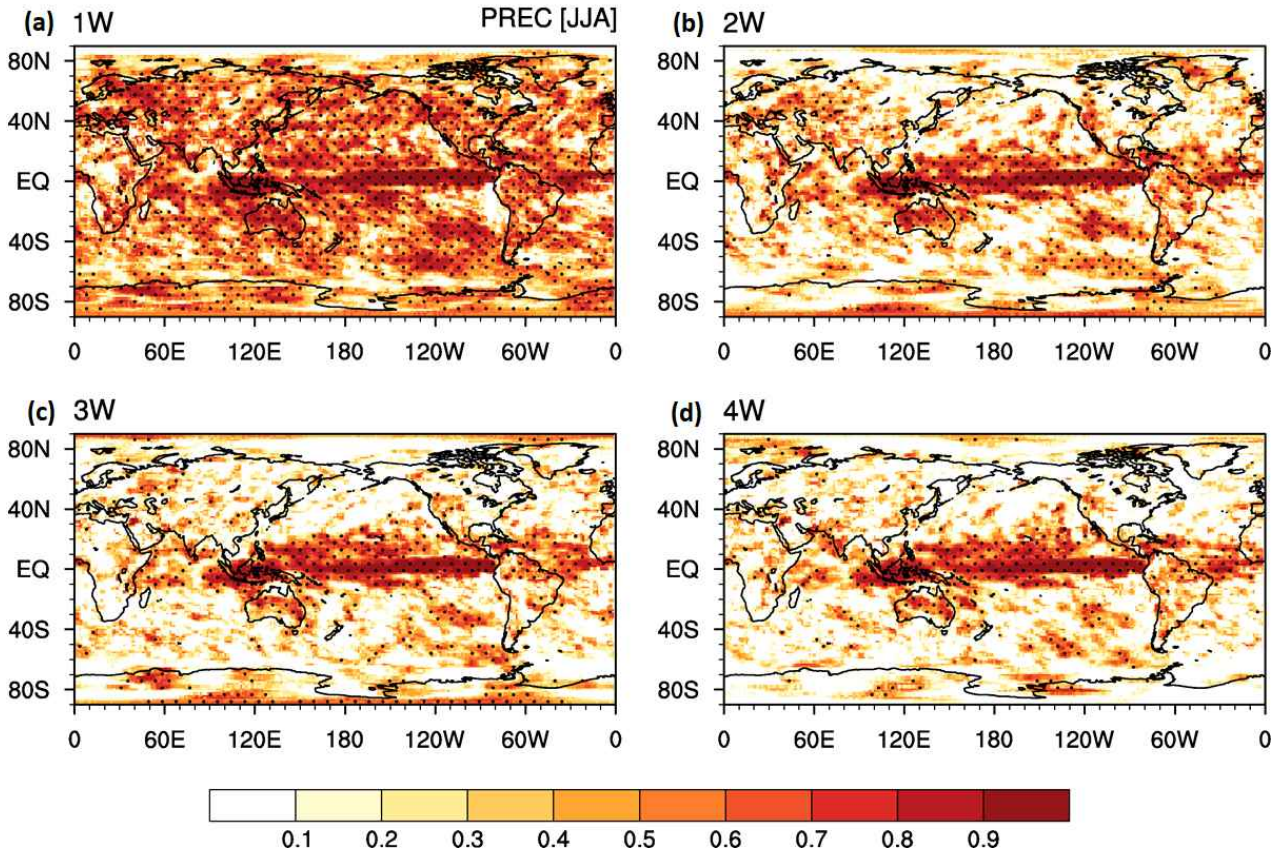


Figure 27. Temporal correlation coefficient (TCC) of the precipitation between ERA interim reanalysis data and GloSea5 hindcast with (a)-(d)1-4 week lead for DJF. Dots in (a)-(d) indicates the area statistically significant at the 95% level.

GloSea5 지표온도 및 강수 예측장의 계통적 오차의 증분 특징을 살펴보기 위해 선행시간 2주, 4주, 6주, 8주의 여름철 (JJA) 온도 및 강수의 오차 분포를 Figure 28와 Figure 29에 나타내었다. ERA-Interim 재분석 자료와의 차이로 나타난 지표온도의 오차는 선행시간 2주의 결과에서 이미 특징적인 오차 분포가 뚜렷하게 나타난다. 선행시간 2주의 지표온도의 오차를 살펴보면, 적도 태평양 강수대를 중심으로 양의 오차가 약하게 나타나고 있으며, 유라시아 일부 및 북미 대부분 지역, 북남미 지역으로 강한 양의 오차가 나타난다. 반면, 양 극지역과 대륙 일부 지역, 한반도를 비롯한 북태평양에 걸쳐 음의 오차가 뚜렷하게 나타나고 있다. 또한 적도 태평양 일부에서 음의 오차가 약하게 나타난다. 이러한 오차 분포는 선행시간에 관계없이 유사하게 나타나고 있다. 다만, 적도 동태평양에서 나타나는 음의 오차는 선행시간이 길어질수록 더욱 크게 나타나며 적도 서태평양에서 나타나는 양의 오차는 선행시간이 길어질수록 더욱 약하게 나타난다. 이러한 특징은 강수의 오차 증가와도 크게 관련이 있다고 할 수 있다.

강수의 오차를 살펴보면, 선행시간 2주의 결과에서부터 뚜렷하게 양의 오차가 확인된다. 적도 태평양의 ITCZ의 강수대를 따라 상당한 양의 오차가 나타나고 동태평양 강수대 위쪽 일부와 인도차이나 반도에서 한반도, 북서태평양 일부에서 약한 음의 오차가 나타난다. 선행시간에 따라 오차의 증가가 어떻게 나타나는지를 살펴보기 위해 선행시간 2주, 4주, 6주, 8주의 강수의 오차 분포를 선행시간별로 살펴보면, 선행시간 2주는 인도양을 비롯한 서태평양에 이르기

까지 양의 강수 오차가 나타남을 확인할 수 있다. 선행시간이 4주 이상으로 증가하면서 서태평양 양 강수 오차는 점점 증가하고 있음을 알 수 있다. 그에 비해 적도 중앙 태평양의 강수 오차는 대부분 선행시간 1주에서 가장 크게 나타나고 있다.

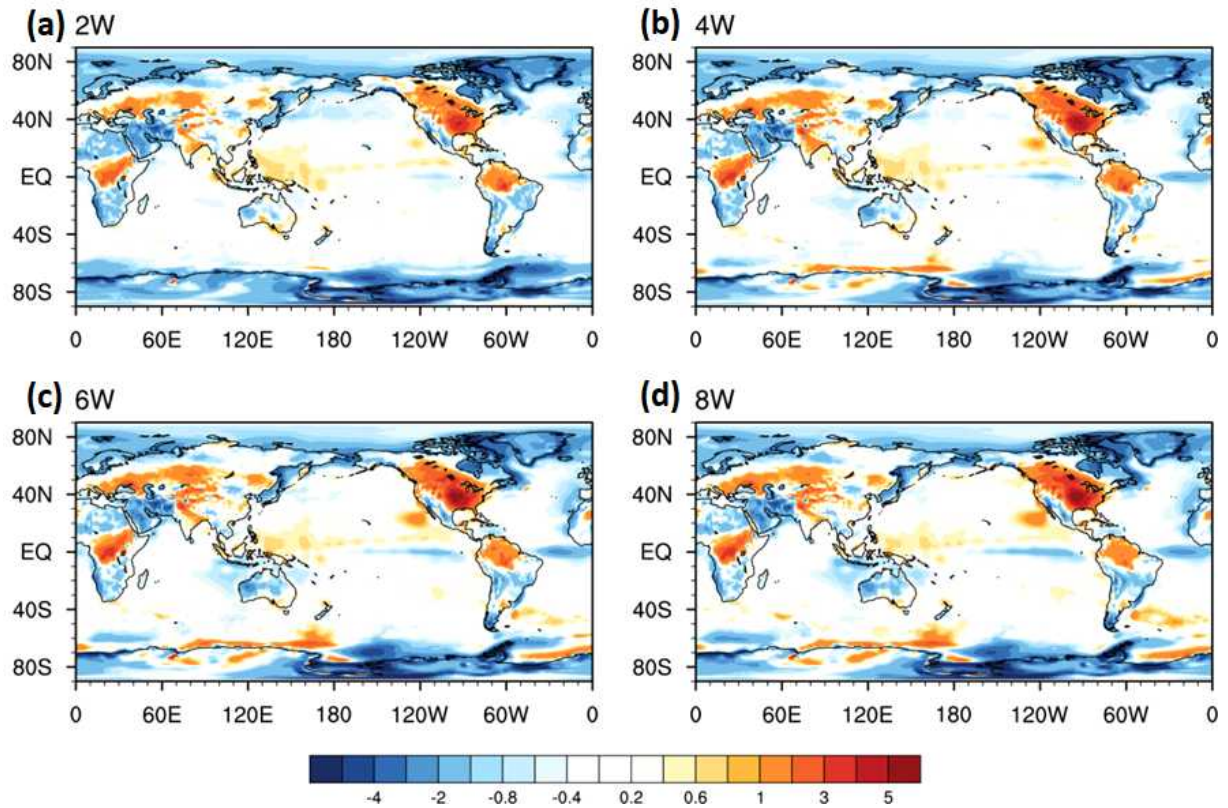


Figure 28. Spatial distribution of surface temperature biases (model minus ERA interim reanalysis) of (a)-(d)2-8 week lead for 1991-2010 JJA.

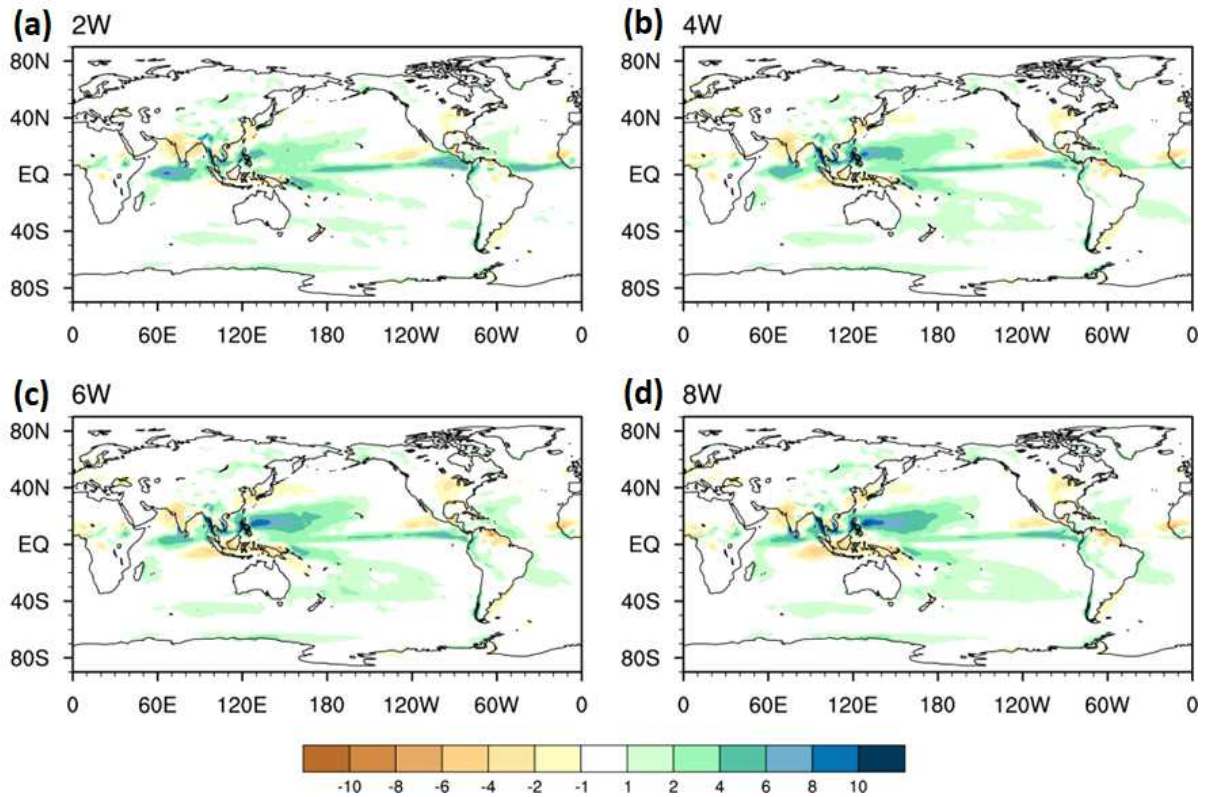


Figure 29. Spatial distribution of averaged surface precipitation biases (model minus GPCP observation) of (a)-(d)2-8 week lead for 1997-2010 JJA.

② 강수와 관련된 오차 특성

강수의 오차 특성을 확인하기 위해 미세물리과정에 의한 강수와 적은 모수화 과정에 의한 강수의 비율을 Figure 30에 나타내었다. 그림에서 알 수 있듯이 적도에서 중위도 대부분의 지역까지도 적게는 70%, 많게는 90% 이상의 비율로 적은 모수화 과정에 의한 강수로 이루어져 있다. 또한, 중위도에서 고위도로 갈수록 미세물리과정에 의한 강수가 늘어난다. 또한 그림에서 실선으로 나타나는 양의 강수 오차 (5mm/day)이상의 지역은 가장 푸른색으로 나타나는 적은 모수화 과정 90% 이상의 지역임을 알 수 있다. 즉, 대부분의 오차를 설명하는 적도 태평양의 양의 오차는 대류과정에 의한 강수에 의해 발생한다고 생각할 수 있다.

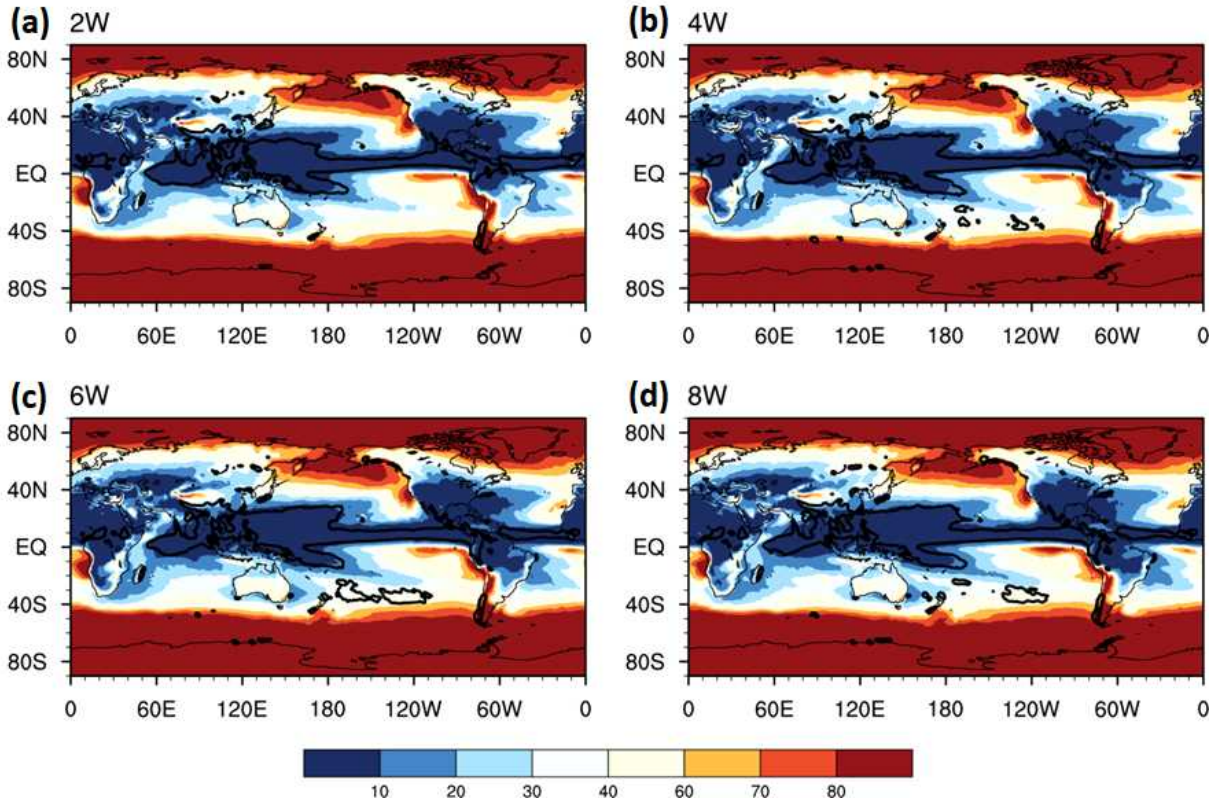


Figure 30. Ratio of large-scale precipitation and convective precipitation from total precipitation. Red (Blue) indicates that large-scale (convective) precipitation is dominant. Bold black line means precipitation biases (over 5mm/day).

이러한 강수의 오차는 대기 순환장과 크게 연관이 있다. Figure 31에서 선행시간 2-8주의 결과로부터 계산된 상층 연직 순환장의 오차를 확인할 수 있다. 적도지역의 대류 및 강수 오차와 관련하여 적도 서태평양 및 인도양 지역에서 관측보다 강한 상층 발산 (하층 수렴)을 보이고 있으며, 그와 반대로 북동태평양을 기준으로 상층 수렴 (하층 발산)을 보이고 있다. 이러한 패턴은 선행시간이 길어질수록 더욱 강하게 나타나고 있다. 적도지역의 강한 강수 및 대류로 인한 에너지는 해들리 순환에 의해 중위도 지역으로 전파된다. 동서 평균된 하층 및 상층 순환장으로 해들리 순환의 강도를 나타내었다 (Figure 32). 예상할 수 있듯이, 강한 대류로 인해 관측대비 강한 해들리 순환의 강도를 보이고 있다. 이는 선행시간 2주에서 이미 대부분의 오차를 가지고 있으며, 선행시간이 길어질수록 다소 증가하는 추세를 보인다. 또한, 강수는 복사과정 및 지표 열속과도 서로 연관되어 있다.

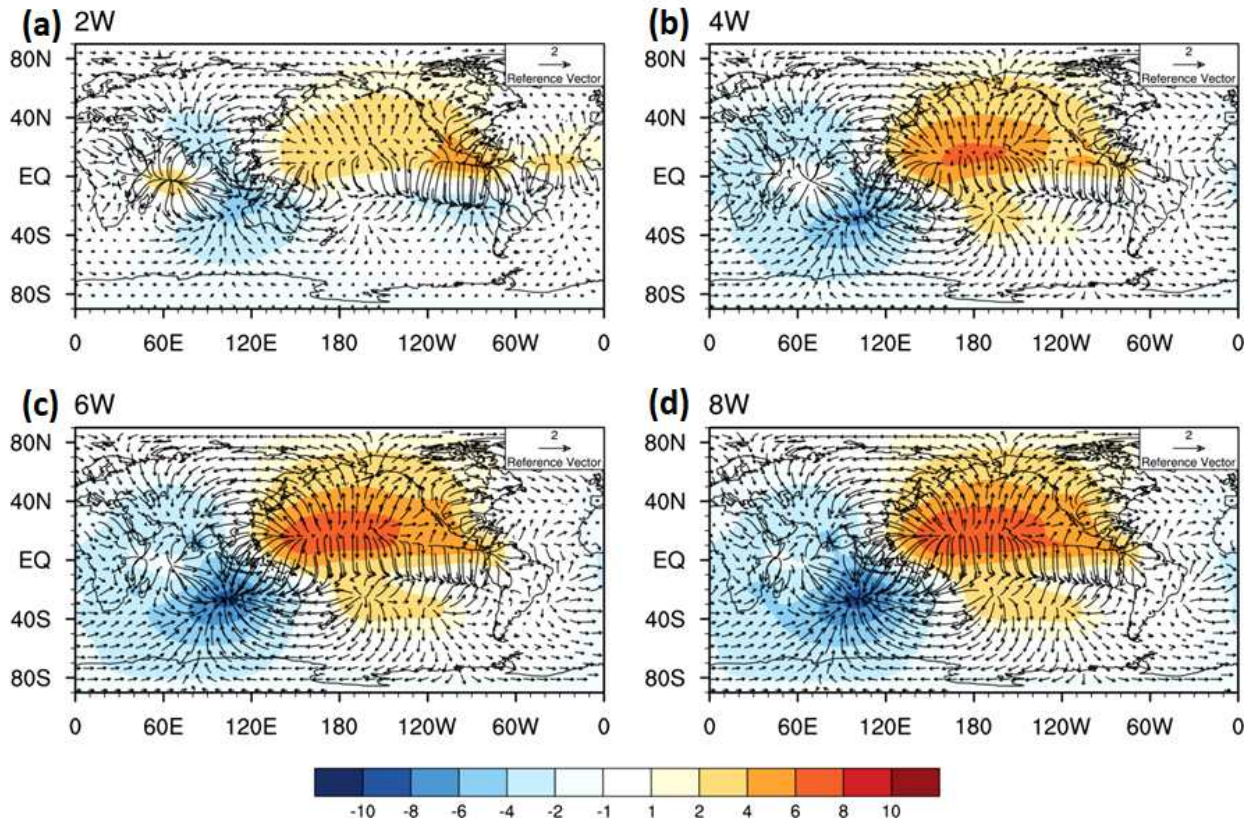


Figure 31. Spatial distribution of 200hPa potential velocity and divergent wind biases (model minus ERA interim reanalysis) of (a)-(d) 2-8 week lead for 1991-2010 JJA. Negative values mean upper-level divergence (low-level convergence). Unit is -10^6 .




Figure 32. Magnitude of Hadley circulation. Zonal mean velocity potential at (a) 850hPa and (b) 200hPa from ERA-Interim reanalysis and GloSea5 2 (pink), 4 (green), 6 (red), and 8 (red) week lead.

Figure 33에서 ISCCP 관측 자료 및 재분석 자료와 GloSea5 선행시간 4주로부터 계산된 복사속 및 지표 열속의 오차의 분포를 나타내었다. 상대적으로 강수가 많은 지역, 특히 적도 강수대에서는 적운형 구름이 생성되기 때문에 이로 인해 태양복사의 지표 도달이 어려워진다. 또한 지표 입사량이 줄어들어 지표 온도의 하강이 나타나고 이로 인해 강수가 줄어드는 상호작용이 존재한다. 이러한 강수-복사 상호작용이 많은 기후 모델에서는 정확하게 모의되지 못하고 있는 것으로 알려져 있다. 대기-해양 결합모델에서 이러한 오차가 줄어든다고 밝혀져 있지만, 여전히 많은 오차를 가지고 있다. Figure 33에서 나타나듯이, GloSea5의 양의 강수 오차는 적도지역에서 음의 지표 복사를 가져오며, 또한 많은 강수로 인해 발생하는 잠열 냉각에 의해 지표 열속의 경우는 과도한 음의 오차를 나타내고 있다. 다만, 지표 온도의 경우 미미하지만 양의 오차가 나타나고 있어 (보이지 않음) 이러한 불일치 현상에 대해서는 조금 더 자세한 분석이 필요하다고 할 수 있다.

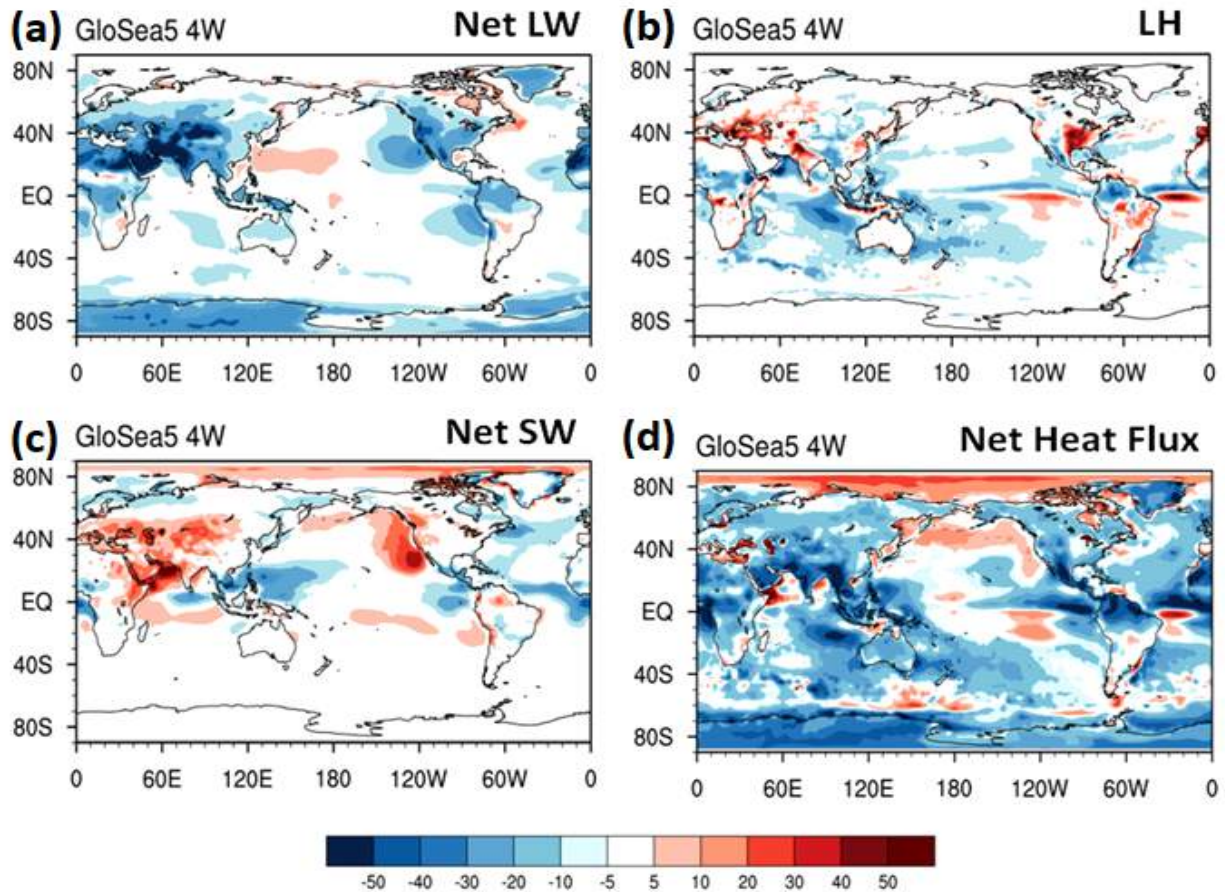


Figure 33. Surface biases distribution of (a) net longwave radiation fluxes, (b) latent heat fluxes, (c) net shortwave radiation fluxes, and (d) net heat fluxes. Positive(Negative) values mean surface heating (cooling) compared to ERA-Interim and GloSea5 with lead 4 week.

날씨에서 계절내 규모에서 나타나는 오차들이 계절 규모, 특히 계절 예측에 크게 영향을 주는 해양에는 어떻게 나타나는지 살펴보기 위해 적도 지역의 해양 연직 온도에 대해 Figure 34에 나타내었다. 선행시간 1개월, 3개월에서 계산된 남위/북위 10도 지역의 해양 연직온도의

오차 분포를 보면, 기본적으로 혼합층에서의 음의 오차가 두드러진다. 이는 대기의 강한 강수에 의해 태양복사의 도달이 상대적으로 적게 나타나기 때문이라고 생각할 수 있다. 선행시간이 길어질수록 표층온도의 음의 오차는 더욱 강하게 나타나고 있으며, 인도양 및 대서양에서도 음의 오차가 뚜렷하게 나타나고 있다.

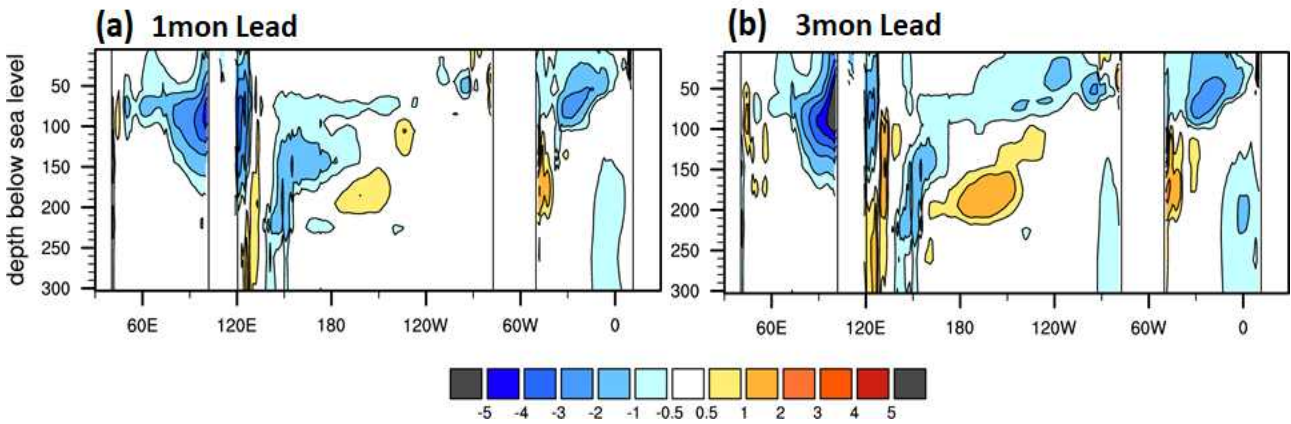


Figure 34. Difference distribution of vertical subsurface ocean temperature averaged 10N-10S between GODAS and GloSea5 with lead (a) 1 month, and (b) 3 month.

혼합층의 깊이로 판단할 수 있는 20도 등온선 깊이의 오차를 GODAS와 비교하여 Figure 35에 나타내었다. 20도 등온선 깊이의 오차를 살펴보면, 적도 일부 지역에서는 깊게 나타나지만 대부분의 지역에서 얇게 나타나고 있음을 확인할 수 있다. 이러한 연직 온도의 음의 오차는 선행시간이 길어질수록, 특히 동태평양에서 더욱 크게 나타나 이와 연관된 ENSO의 예측 성능 저하에 관심을 가질 필요가 있다. 해양 오차와 관련된 자세한 분석이 추후 더 진행될 예정이다.

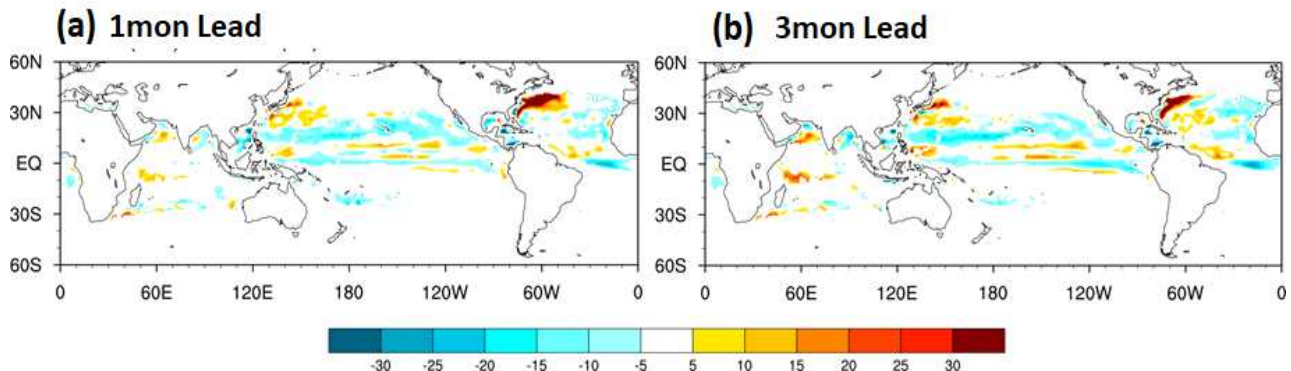


Figure 35. Difference distribution of 20D isothermal depth between GODAS and GloSea5 with lead (a) 1 month, and (b) 3 month.

(나) 동아시아 기후 모의 재현성 평가

GloSea5의 동아시아 기후 모의의 오차 특성을 살펴보기 위해 가장 영향을 뚜렷하게 미치는 기후 요소들의 재현성 평가를 살펴보았다. 특히 동아시아 여름과 겨울에 가장 크게 영향을 미치는 변동성인 동아시아 여름과 겨울 몬순의 재현성 평가를 통해 각각의 오차의 특성에 대해 살펴보았다. 이러한 특성을 통해 GloSea5 계절내 예측장 해석에 도움이 되고자 한다.

① 동아시아 여름과 관련된 오차 특성

전구 기후 모델에서 가장 큰 역할을 하는 기후변동성은 단연 ENSO라고 할 수 있다. 또한 ENSO는 저위도에서 중위도로 연결되는 원격상관 또한 잘 알려져 있다. 최근 Chen et al. (2018) 연구 결과는 동태평양과 열대대서양 (North Tropical Atlantic, NTA) 의 해수면 온도 (Sea Surface Temperature, SST) 변동성과 동아시아 여름몬순 (East Asia Summer Monsoon, EASM) 의 연관성을 제시하였고, 그에 따라 동아시아 여름몬순의 예측 가능성을 시사하였다. GloSea5 모델의 계절내예측 선행시간 1-4주에 따른 재현성을 ERA-Interim 재분석자료와 비교·평가하고 GloSea5 모델을 활용한 동아시아 여름몬순 예측 가능성을 Hindcast 결과를 통해 확인하고자 한다.

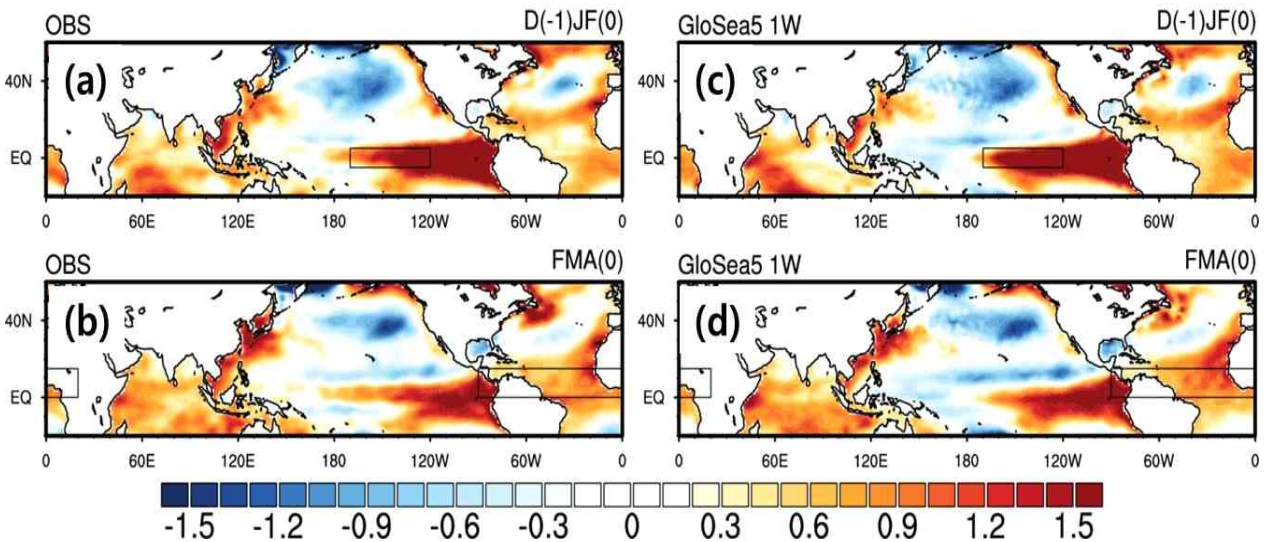


Figure 36. Spatial distribution of winter SST (Nino3.4) and following spring SST (NTA region).




Figure 37. Time series of EASM Index calculated by ERA-Interim.

선행연구는 겨울철(D(-1)JF(0) 동태평양과 봄철(FMA(0)) 열대대서양의 SST (선형추세 제거 아노말리, Detrend Anomaly)의 징후(sign)가 동일한 경우, 동아시아 여름몬순과 유의한 양의 상관관계를 보인다고 밝혔다. Figure 36은 1998년 재분석자료의 겨울철(Figure 36a)과 봄철(Figure 36b)의 SST이며, 상자 표시된 겨울철 동태평양 SST와 봄철 열대 대서양 SST의 아노말리가 동일한 sign으로 확인된다. 이러한 공간분포는 GloSea5 계절내예측 선행시간 1주의 결과 (Figure 36c, d) 에서 매우 유사하게 나타나는 것을 확인하였다. 또한 Figure 37에서 해당 연도의 EASM의 강도가 뚜렷하게 높게 나타나 겨울철과 봄철 열대 SST와 여름철 동아시아 몬순의 관련성을 추론할 수 있다.

분석을 위해 겨울철 동태평양의 SST가 봄철 열대대서양에 미치는 영향을 제거하였다. 그 결과, Figure 38에 나타난 것과 같이, 겨울철 동태평양과 유의한 상관관계가 제거된 봄철 열대 대서양 SST (NTA_r FMA) 자료를 분석에 활용하였다 (0.5*표준편차 이상인 경우 연구에 사용하였다). 겨울철 동태평양과 봄철 열대대서양의 SST 아노말리가 동일한 sign을 나타내는 Same sign (1994, 1998, 2001, 2005, 2009, 2010) 과 반대 sign을 보이는 Opposite sign (1992, 1995, 1996, 1997, 2000, 2003, 2004, 2007, 2008) 으로 분류하였다.




Figure 38. Time series of winter Nino3.4 index (black), spring NTA SST (red), and spring NTA SST with removed ENSO effect (blue).

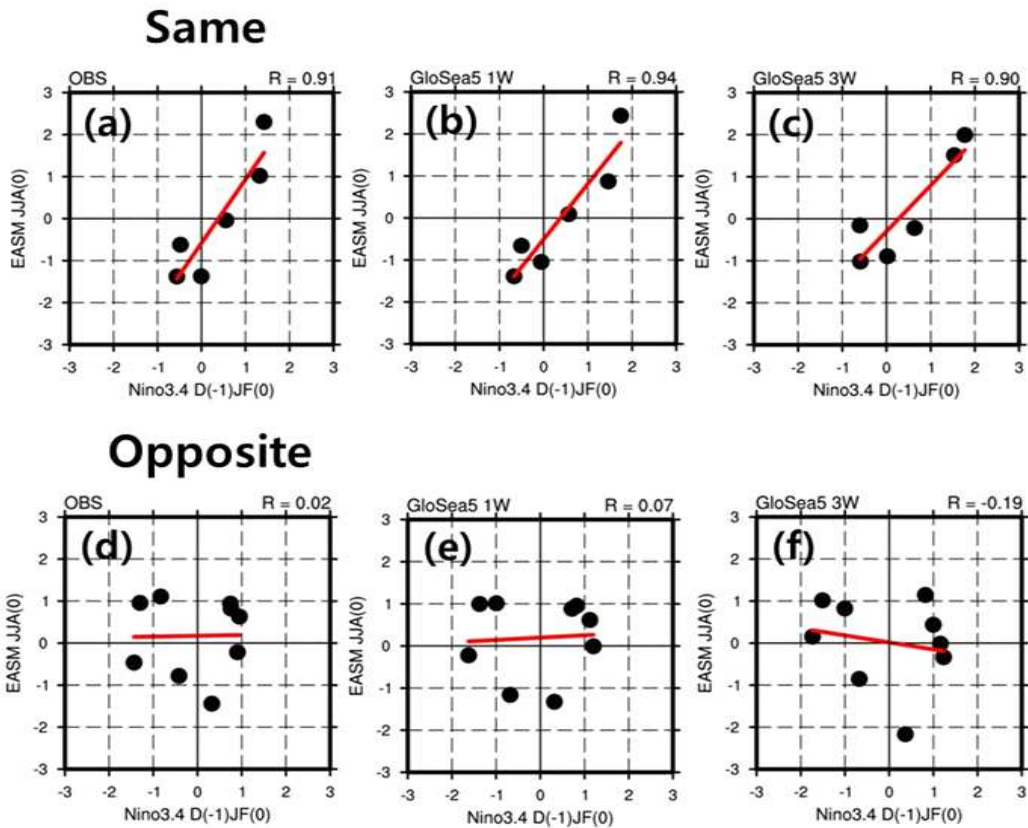


Figure 39. Scatter plots of winter Nino 3.4 SST versus EASM index.

Figure 39은 Same/Opposite sign에 따른 겨울철 ENSO(Nino3.4)와 여름철 동아시아 여름몬순의 상관성을 제시하는 산점도이며, 재분석자료 결과(Figure 39a, d)와 GloSea5 모델의 선행시간 1주 (Figure 39b, e), 3주 (Figure 39c, f)의 결과를 나타낸다. Same sign인 경우, 겨울철 ENSO와 여름철 동아시아 여름몬순의 상관성이 매우 뚜렷하게 나타났고, 이러한 특징은 선행시

간 3주까지 예측성능이 유지되었다. Opposite sign의 경우 겨울철 ENSO와 여름철 동아시아 여름몬순의 상관성이 유의하지 않은 결과를 보였다.

Figure 40은 겨울철 동태평양 SST와 여름철 강수와 하층 바람 성분의 회귀장 (regression map) 으로 재분석자료 결과 (Figure 40a, d)와 GloSea5 선행시간 1주 (Figure 40b, e), 3주 (Figure 40c, f)의 결과를 제시한다. Same sign인 경우, 재분석자료의 강수 및 하층 바람장에서 북서태평양 지역의 고기압성 흐름이 발달하여 동아시아에 습윤한 공기가 유입되는 패턴이 형성되었다. 이러한 특징이 GloSea5 모델의 선행시간 3주까지 모의되는 것을 확인하였다. 반면 Opposite sign의 경우, 동아시아 여름몬순에 영향을 미치는 패턴은 재분석자료와 GloSea5 모델에서 나타나지 않았다. 이러한 결과를 바탕으로, 겨울철 동태평양과 봄철 열대대서양의 SST와 동아시아 여름몬순의 상관성을 파악하였고, GloSea5 계절내예측 결과의 겨울·봄철 SST 예측성능이 유지될 때, 동아시아 여름몬순 예측에 도움이 될 수 있음이 추론된다.

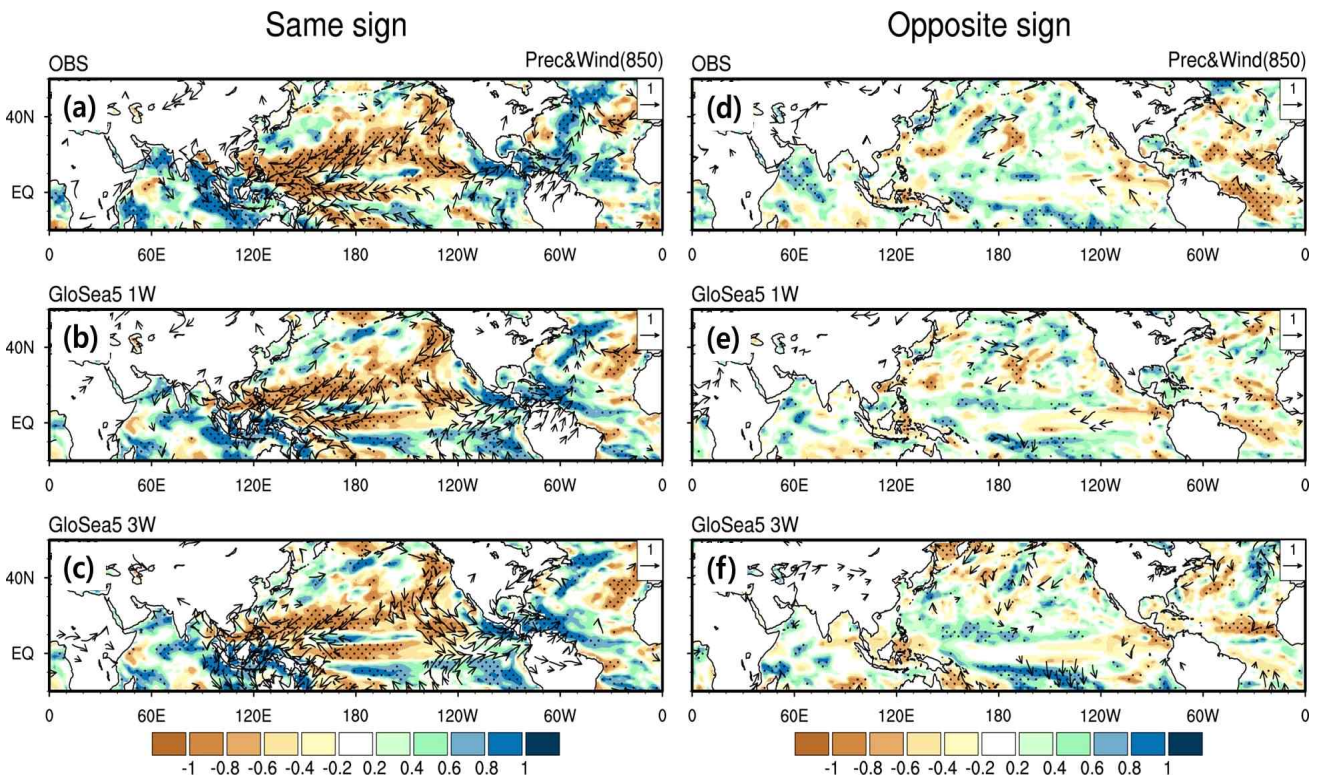


Figure 40. Spatial distributions of summer UV850 and PREC regressed winter Nino3.4 for same/opposite sign.

② 동아시아 겨울과 관련된 오차 특성

㉞ 열대기후

동아시아 겨울철 (DJF) 기후와 ENSO의 원격상관 재현성 평가를 위해 1991년-2000년(전반기, 1P)과 2001년-2010년(후반기, 2P) 두 기간으로 나누어서 예측 선행기간 1주, 3주로부터 계산된 Nino3.4지수에서 회귀된 겨울철 지표 기온, 강수, 상하층 바람장을 Figure 41, 42에 나타

내었다. 선행시간 1주의 결과는 재분석자료에서 보이는 회귀장을 매우 잘 모의하고 있기 때문에, 1주와 3주의 결과를 비교하여 분석하였다. 분석기간 전반기와 후반기의 결과를 비교해보면, 3주에서는 Nino3.4지수에 회귀된 적도 지역 지표기온은 동태평양에서 중태평양쪽으로 그 중심이 이동한 것을 알 수 있다. 또한, 선행시간 1주의 결과에서 전반기 상층 바람장이 서태평양 중심으로 큰 순환장을 이루고 남중국쪽에서 한반도 일본까지 작은 순환장을 보이고 있는 것과 달리 후반기에서는 적도지역 바람장이 중태평양 방향으로 이동되고 중위도 북태평양에서도 반시계방향의 순환장을 나타내고 있으며 동아시아에서 보이던 바람장은 다소 약화된 것이 특징이다. 이러한 특징을 선행시간 3주의 결과에서도 잘 모의하고 있다. 하지만, 전반기에서는 선행시간 1주의 결과와 다르게 3주의 결과에서는 북태평양 중앙에서 동쪽에 이르는 반시계방향의 순환장이 강화되어 나타나고 있다. 후반기에서는 적도태평양 및 북태평양의 순환장은 매우 잘 모의하고 있지만, 북서태평양의 동아시아 몬순과 관련된 반시계방향의 순환장을 약하게 모의하고 있는 것이 특징이다.

Figure 42는 Nino3.4지수에 회귀된 강수와 하층 바람장을 선행시간 1주와 3주에 대해 나타내었다. 선행시간 1주의 결과를 살펴보면, 전반기에는 해수면 온도와 관련하여 적도 태평양을 중심으로 강한 양의 강수가 나타나며 서태평양을 중심으로 음의 강수를 보이고 있다. 로컬 헤들리 순환과 연계되어 동아시아 지역에도 양의 강수가 나타나고 있다. 후반기에는 해수면 온도의 중심이 서쪽으로 이동됨에 따라 양의 강수 역시 서쪽으로 치우쳐져 나타나고 있으며, 전반기와 비교하여 음의 강수 영역은 다소 약하게 나타난다. 이와 연관되어 동아시아의 양의 강수 역시 약하게 나타나고 있음을 알 수 있다. 선행 시간 3주의 결과를 보면, 1주와 비교하여 볼 때 전반기의 강수 영역 및 하층 순환장은 매우 잘 유지되고 있음을 알 수 있다. 하지만 후반기에 들어 양의 강수대가 다소 약하게 나타나고 있음을 확인할 수 있다.

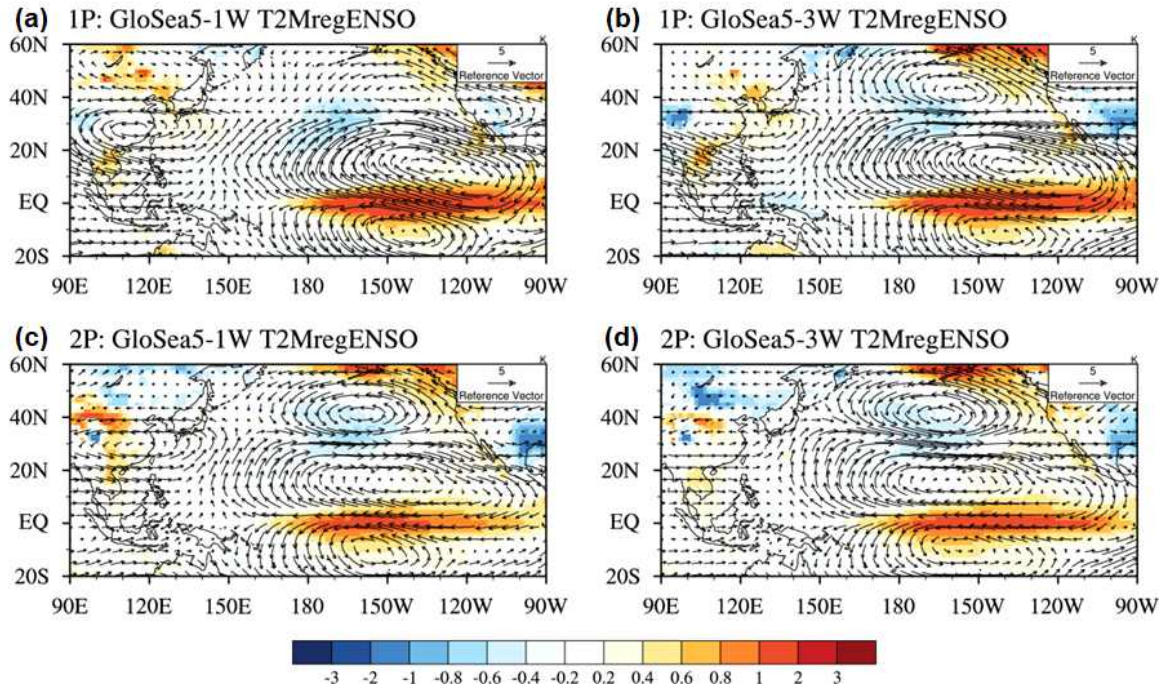


Figure 41. Surface temperature (shaded) and 200hPa wind (vector) regressed on the Nino 3.4 index from GloSea5 (a), (c) with lead 1 week, and (b), (d) with lead 3 week. (a), (b) 1P is averaged for 1991-1999, (c), (d) 2P is for averaged for 2001-2009.

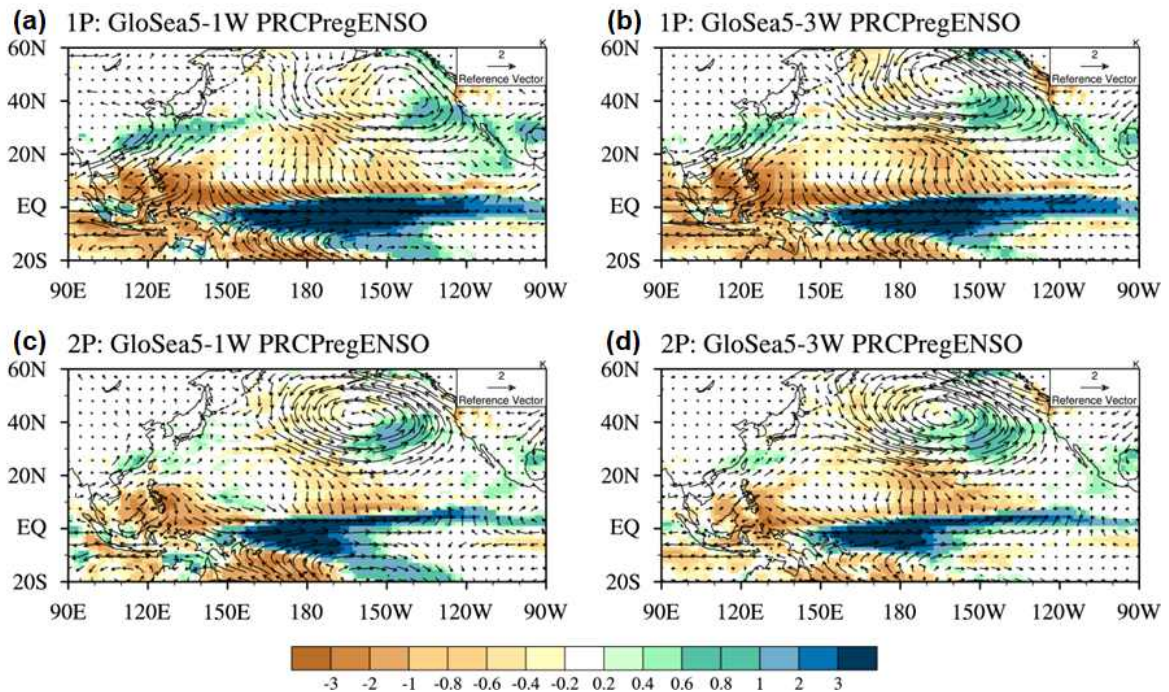


Figure 42. Surface precipitation (shaded) and 850hPa wind (vector) regressed on the Nino 3.4 index from GloSea5 (a), (c) with lead 1 week, and (b), (d) with lead 3 week. (a), (b) 1P is averaged for 1991-1999, (c), (d) 2P is for averaged for 2000-2009.

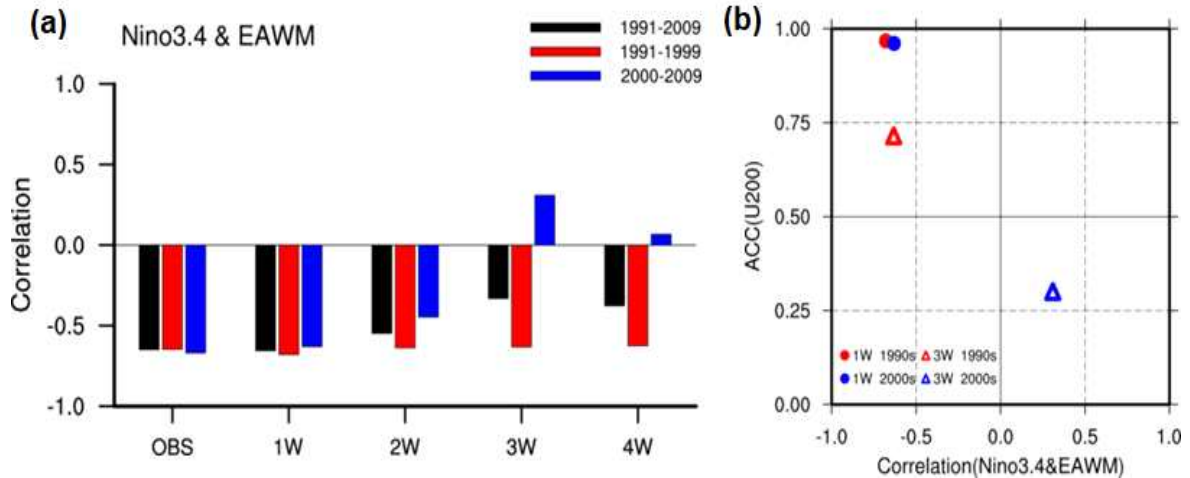


Figure 43. (a) Correlation coefficient between Nino 3.4 index and East Asia monsoon index from ERA interim and GloSea5 with lead 1-4 week. (b) Anomaly correlation coefficient of 200hPa zonal wind over East Asia with relationship of Nino 3.4 and EAWM index. Red bar is averaged for 1991-1999, blue bar is for averaged for 2000-2009.

동아시아 겨울몬순과 ENSO와의 상관관계를 상층 동서바람의 동아시아 지역의 아노말리 상관계수와 함께 Figure 43에서 확인할 수 있다. 상층 동서바람은 선행시간 1주에서 높은 예측 성능을 보이고 있지만 선행시간 3주의 결과는 후반기의 결과가 전반기의 결과보다 상당히 낮게 나타나고 있다. 특히 ENSO와 동아시아 겨울몬순과의 상관관계가 전반기에는 0.5이상의 높은 음의 상관을 보이고 있었지만, 후반기에는 0.4정도의 양의 상관으로 변화한 것이 특징이다. 동아시아 겨울 몬순 인덱스의 후반기의 낮은 성능의 패턴과 ENSO와의 상관관계의 모의 성능은 동일하게 나타나고 있으며, 이는 몬순 인덱스를 계산할 때 사용되는 상층 동서 바람의 예측 성능과도 크게 관련이 있다. 또한, 최근 ENSO의 특징이 동태평양 중심 (EP)에서 중태평양 중심 (CP)으로 변하고 있는 것과는 무관하지 않을 것이다. 실제로 강수의 중심이 전반기보다 후반기에 서쪽으로 이동하였고 (Figure 43), 이로 인해 동아시아에 미치는 영향이 달라졌을 거라고 예상할 수 있다. 이와 관련한 자세한 분석이 추가적으로 더 필요할 것이다. 또한, 동아시아 겨울몬순에 크게 영향을 주는 기후 변동성으로는 시베리아 고기압 및 북극의 영향을 생각할 수 있기 때문에 다음 장에서 그에 대해 더 논의해 보고자 한다.

㉔ 북극진동

동아시아 겨울철 기온에 크게 영향을 미치는 변동성을 알아보기 위해 북반구 겨울철 지표 온도의 EOF 분석을 수행하였다. EOF 두 번째 모드의 PC에 회귀된 기온 및 기압은 전형적인 북극진동의 패턴을 나타내고 있다 (Figure 44). 재분석 자료에서 나타난 것을 살펴보면, 북극지역을 중심으로 강한 음의 기압패턴을 가지는 dipole 기압 구조를 확인할 수 있으며, 유라시아에서 우리나라에 이르기까지 양의 기온 패턴을 보이고 있다. 이러한 특징을 선행시간 1주에서는 매우 잘 모의하고 있음을 확인할 수 있다. 하지만, 3주 선행시간에서는 기온 및 기압의 패

턴은 잘 모의하지만 그 강도가 약해짐을 알 수 있다. 아무리 완벽한 역학 모형이라도 대기가 가지고 있는 혼돈적 특성에 의해 일기 예측은 2주를 넘을 수 없는 Lorenz (1963)의 특징을 고려해 보았을 때, 3주 선행시간에서 이 정도의 예측 성능을 보이는 것은 매우 고무적이라 할 수 있다.

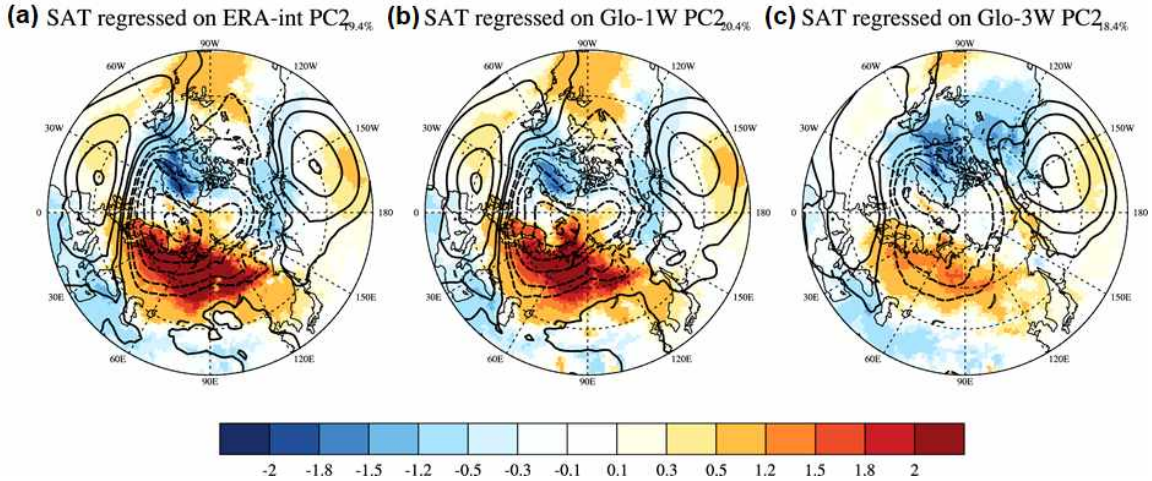


Figure 44. Surface temperature (shaded) and sea level pressure (contour) regressed onto the EOF 2nd PC from (a) ERA-Interim, (b) GloSea5 with lead 1 week, and (c) GloSea5 with lead 2 week.

이러한 결과를 자세히 분석해 보기 위해 AO 지수의 예측성능을 1991년-2000년(전반기)과 2001년-2010년(후반기)로 나누어서 Figure 45a에 나타내었다. 본 연구에서는 EOF를 이용한 통계적 방법으로 정의된 AO 지수 대신 Li and Wang (2003)이 고안한 AO 지수를 사용하였다. 이 지수는 북반구 지표기압으로 계산하며, 중위도 순환장의 변동성을 잘 나타낸다고 알려져 있다. 그림 45b에서 검은 선으로 표시된 상관관계를 보면 선행시간 2주까지 0.9이상의 높은 예측성능을 보이다가 선행시간 3주에서 4주로 갈수록 급격히 떨어지는 것을 확인할 수 있다. 흥미로운 점은 빨간 선으로 나타난 90년대의 예측성능은 선행시간 4주에서 반대 상관계수를 보이는 반면, 파란 선으로 나타난 00년대의 예측성능은 선행시간 4주까지도 0.7정도의 높은 값을 유지한다는 점이다.

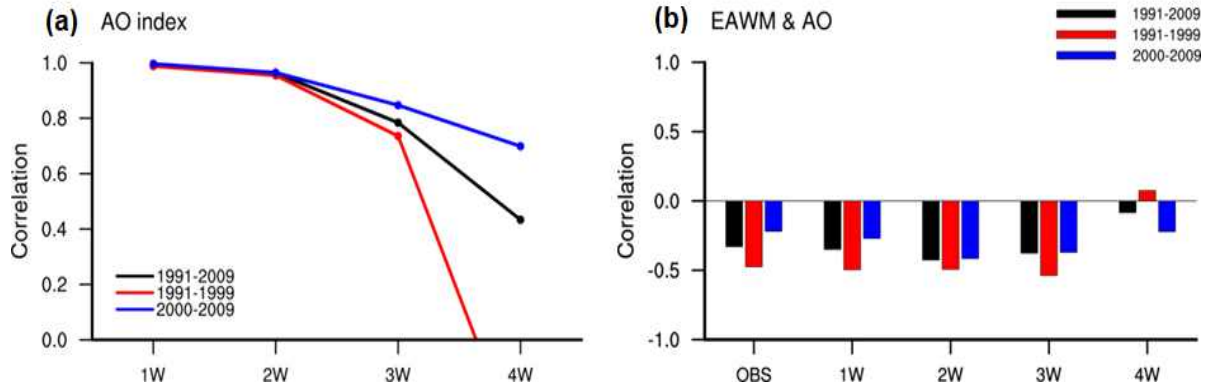


Figure 45. (a) Correlation coefficient of arctic oscillation (AO) between from ERA interim and GloSea5 with lead 1-4 week. (b) Relationship of AO and EAWM index from ERA interim and GloSea5 with lead 1-4 week. Red line (bar) is averaged for 1991-1999, blue line (bar) is for averaged for 2000-2009.

겨울철 기온예측에 AO 지수 및 동아시아 몬순 지수가 많이 사용된다는 점을 고려하여 두 지수의 상관관계를 전반기와 후반기로 나누어서 Figure 45에 나타내었다. Li et al. (2014)에 따르면, 1970년대 후반 이후로 동아시아 겨울 몬순과 AO의 음의 상관성이 뚜렷하게 나타난다. 하지만, Kang and Lee (2017)에서 동아시아 겨울 몬순과 AO의 음의 상관성이 1990년대 후반이후로 약해짐을 밝힌 바 있다. Figure 45b에서 관측에서 나타나는 상관관계를 보면, 본 연구에서도 1990년대보다 2000년대에서 동아시아 겨울 몬순과 AO의 상관관계가 약해지는 것을 확인할 수 있다. GloSea5에서 모의된 몬순과 AO의 관계를 보면, 선행시간 3주차까지도 관측에서 보이는 상관관계를 잘 모의하고 있음을 알 수 있다. 하지만, 선행시간 4주에서는 1990년대의 강한 음의 상관관계를 전혀 모의하지 못함을 확인할 수 있다. 다만, 2000년대 이후의 약한 음의 상관관계는 잘 모의하고 있다. 이러한 사실을 바탕으로 GloSea5의 3-4주의 계절내 혹은 계절 예측의 AO 모의를 통해 동아시아 겨울철 기후 변동을 예측하는 것은 큰 도움이 되리라 판단된다. 다만, 통상적으로 사용하는 EOF 모드를 통해 정의되는 AO 지수보다 Li and Wang (2003)이 고안한 AO 지수를 사용했을 때 더 유의미한 결과가 나왔음을 주의해야 한다.

㉔ 빙권

최근 들어 북극지역의 기후 변동이 중위도에 주는 영향에 대한 많은 연구들이 논의되고 있다 (Kug et al. 2015; Mori et al. 2014). 관측 자료를 이용한 여러 연구에서 알려져 있듯이 중위도와 북극에서의 온도 트렌드는 1990년대 후반을 기점으로 정반대의 패턴을 보인다. 이러한 특징을 GloSea5가 잘 모의하고 있는지를 확인하기 위해 1991년-2000년(전반기)과 2001년-2010년(후반기)의 북극-중위도의 온도 트렌드를 분석하였다. 재분석자료와 GloSea5의 선행시간 1주, 3주에서 모의된 후반기의 온도 트렌드를 Figure 46에 나타내었다. 재분석 자료에서 나타나는 북극 온난 트렌드와 유라시아에 걸쳐 나타나는 한랭 트렌드는 NWP기간인 선행시간 1주에서 잘 모의되고 있는 것을 알 수 있다. 선행시간 3주에서도 북극 온난 트렌드는 매우 잘 모의되고 있으나 유라시아의 한랭 트렌드가 다소 약하게 나타나고 있다. 특히 이러한 Warm Arctic Cold

Continent (WACC) 패턴은 최근 연구에서도 논쟁이 계속되고 있는 점은 유의해야 하며, 대부분의 CMIP 모델에서 모의하지 못하는 것으로 알려져 있다는 점을 고려해야 한다 (Kug et al. 2015). 최근 연구 프로젝트를 통해 여러 모델을 사용해 모의 특징 및 원인에 대해 조사되고 있어, 앞으로도 관심을 가지고 계속 연구해 볼 필요가 있음을 제안한다.

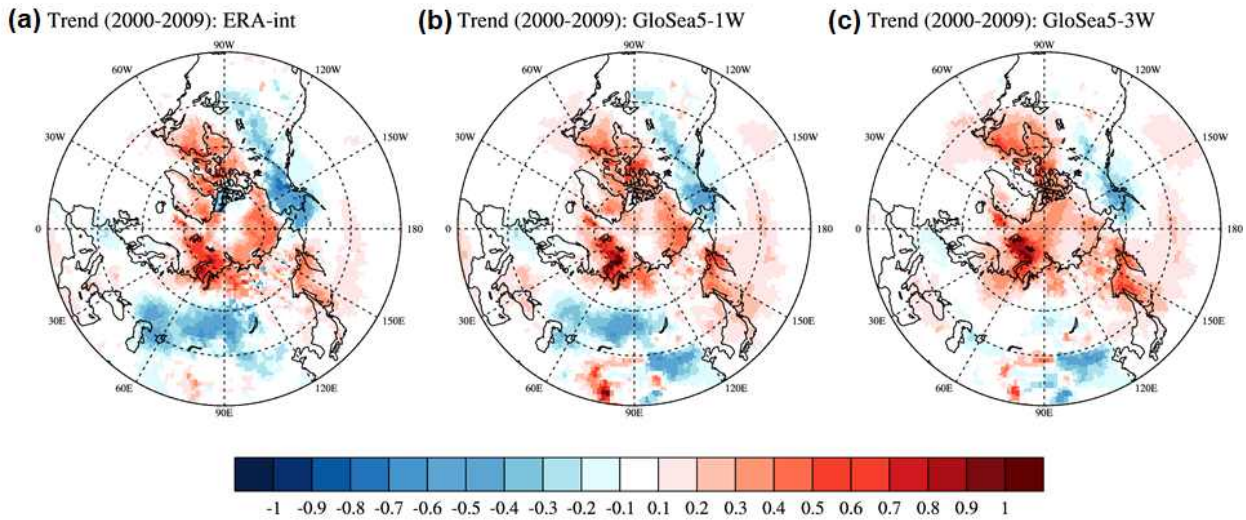


Figure 46. The linear trends in surface temperature during DJF for the periods 2000-2009 from the ERA-Interim and GloSea5 with lead 1, 3 week.




Figure 47. Leading modes governing detrended winter sea level pressure from ERA-Interim (black solid), and GloSea5 with lead 1 (blue), 3 (red) week. Black dashed line indicates Siberian high index.

동아시아 겨울 기후에 크게 영향을 미치는 요소 중 하나는 시베리아 고기압의 확장 및 축소라고 할 수 있다. 트렌드를 제거한 동아시아 지표기압의 EOF의 첫 번째 모드의 PC 시계열

을 시베리아 고기압 지수와 함께 Figure 47에 나타내었다. 재분석 자료와 선행시간 1주에서 나타나는 지표기압의 첫 번째 EOF 모드와 시베리아 고기압 지수의 시계열 변동 패턴이 매우 유사하게 나타나는 것을 알 수 있다. 다만, 선행시간 3주에서 모의되는 시계열 변동은 재분석자료와 매우 다르게 보이고 있어, 계절내 예측에서 지표기압의 오차가 매우 큼을 확인할 수 있다. Figure 47로부터 회귀된 지표기온 및 기압의 분포를 Figure 48에서 확인할 수 있다. 재분석 자료에서 나타나는 회귀 분포는 전형적인 시베리아 고기압의 확장 패턴이다. 양의 지표기압 패턴이 유라시아에서 나타나며 한반도 쪽으로 기압골이 발달하고 이로 인한 대륙에 찬 기온이 분포하고 있다. 예상할 수 있듯이, 선행시간 3주에서 회귀된 지표기압은 재분석자료에서 보인 패턴을 거의 보이지 않고 있으며, 이로 인해 유라시아 대륙에서도 차가운 온도가 매우 약하게 나타나고 있다. 이러한 결과를 바탕으로 볼 때, GloSea5로부터 모의된 계절내 예측에서 EOF 분석을 통해 시베리아 고기압의 확장 및 축소에 대한 예측 결과를 예상할 경우 많은 오차가 포함되어 있음에 주의하여 분석해야 한다.

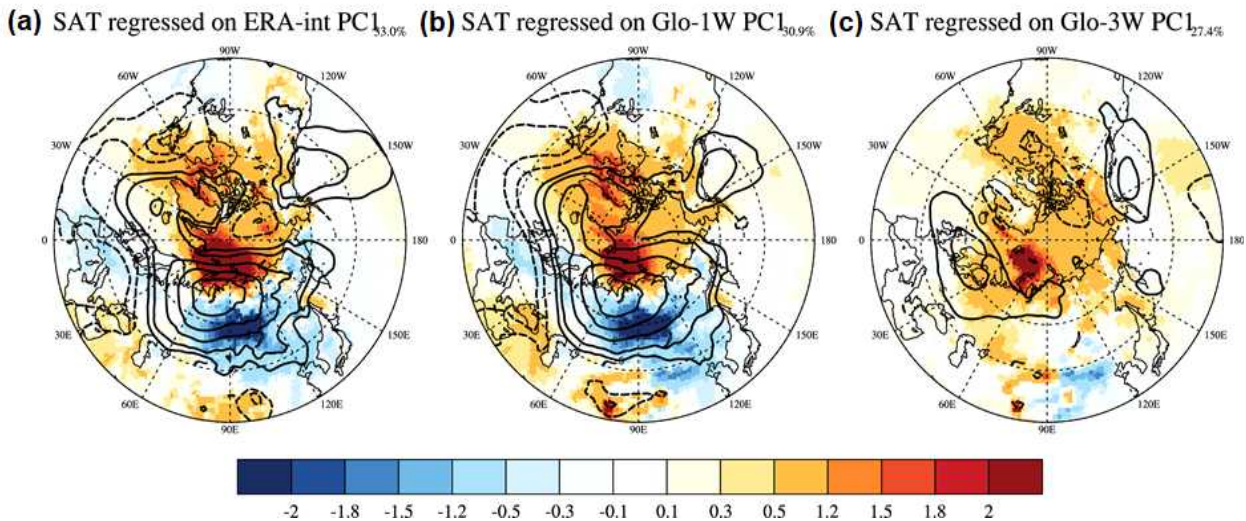


Figure 48. Surface temperature (shaded) and Sea level pressure (contour) regressed onto the EOF 1st PC from (a) ERA-Interim, (b) GloSea5 with lead 1 week, and (c) GloSea5 with lead 2 week.

나. 계절내 모형 예측 보정 기술 개발

(1) 딥러닝을 활용한 한반도 최저·최고 기온 및 강수량 예측 보정 기술 개발

(가) 딥러닝 자료 입출력 구조 구축

딥러닝 입력 구조로 아래와 같은 세가지 방안이 고려되었다 (Figure 49-51). 입력 구조 1은 특정일에 release 되는 ECMWF 혹은 GloSea5 S2S예측 데이터의 2차원 배열 (variables X forecast days)을 한 개의 샘플로 구성하고, 전체 샘플 집단은 20년 X 앙상블 개수 (3 for GloSea5, 11 for ECMWF)로 구축하였다. Output으로는 최고기온, 최저기온, 강수량 3변수 각각에 대해 forecast day에 해당하는 길이를 가진 1차원 배열이 나오도록 하였다. 전체 데이터를 무작위로 10등분하여 10-fold cross-validation으로 학습하며 과최적화를 방지하였다. 이 방식으로 딥러닝 입력자료를 구축하면 매년 특정 시기의 기후 요인이 유사하다는 가정 하에 일년에 배포되는 48 혹은 52개의 S2S 예측 데이터별로 특화된 딥러닝 모델을 구축하여 기후 변수의 계절성을 고려할 수 있다는 장점이 있다. 입력 구조 2는 선행 주수별로 입력자료를 정의하여 딥러닝 학습을 진행하였다. 예를 들어, 1월 4일 예측 자료에서 7일 동안의 자료를 읽고, 다음 7일에 대해서는 1월 11일 예측 자료의 첫번째 7일 동안의 자료를 읽고, 역시 다음 7일은 1월 18일의 예측 자료 첫번째 7일을 읽었다. 입력 구조 3은 배포일 X forecast day의 2차원 배열에 앙상블 자료들을 각 샘플로 하였고, output은 배포일별 관측치로 하였다.

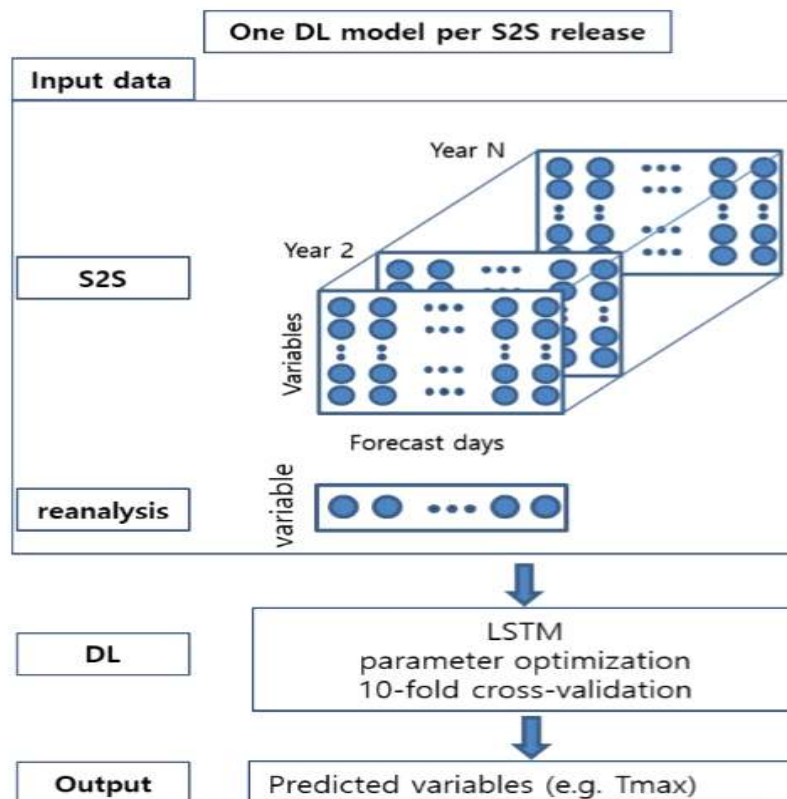


Figure 49. Proposed structure 1 of deep learning.




Figure 50. Proposed structure 2 of deep learning.

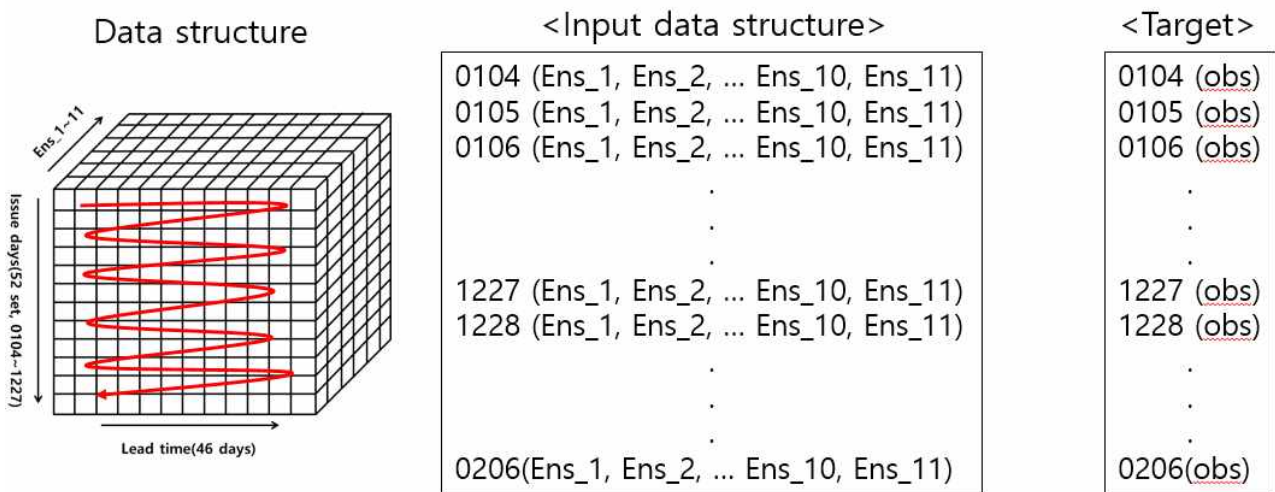


Figure 51. Proposed structure 3 of deep learning.

위 3가지 입력 구조 중, 기후변수간의 상호작용을 고려할 수 있고, feature engineering을 통한 변수의 가감이 가능하며, 배포 시기별 딥러닝 모델을 구축할 수 있고, 새로 생성되는 S2S 자료의 즉각적인 개선이 가능하도록 디자인된 입력 구조 1 (Figure 49)을 채택하여 딥러닝 학습을 진행하였다.

(나) 딥러닝 모델 훈련 및 예측

본 연구에서는 입력된 시계열 기후자료를 자동으로 학습하고, vanishing gradient problem 을 해결할 수 있으며, 다차원 데이터의 입출력을 지원하는 LSTM을 채택하였다. LSTM의 활성화 함수와 은닉층 (hidden layer) 노드 개수의 산정이 필요하다. 먼저 단일층을 구성하고 활성화 함수로 tanh 함수와 ReLU 함수 두 개의 모델을 구성한 후, 은닉층 노드의 개수를 10개씩 증가시켜 학습 손실이 가장 작게 나타나는 활성화 함수와 노드의 개수를 획득하였다. 그 결과 은닉층의 노드가 200개 이며 활성화 함수가 ReLU일 때 가장 우수한 학습 결과를 보여주었다. 또한 최근 딥러닝 응용 기술에서 우수한 성능으로 광범위하게 채택되고 있는 확률론적 기울기 확장 알고리즘으로 Adam 최적화 알고리즘 (optimizer)을 사용하였으며, 이 알고리즘의 기본 설정과 은닉층의 깊이(dense)는 100개로 구성하였다. 출력 단위의 경우, 기온은 degree Celsius로 강수량은 mm로 입력 기후 자료와 동일한 단위로 출력된다. 예측 모델에서 오류 메트릭스의 경우 평방근제곱근오차 (Root Mean Square Error, 이하 RMSE)가 더 일반적이어서 채택하였지만 평균절대오차 (Mean Absolute Error, 이하 MAE)도 채택하였다. 그래서 예측 모델의 성능 지표는 7일 동안의 각각 리드 타임에 대한 RMSE와 MAE이다. RNN은 위 LSTM과 다른 구조로 구성되는데, 200개의 노드를 가진 100개의 은닉층 대신에 훈련하는 동안 학습되는 가중치를 가진 기억 장치와 매개 변수로 구성하였다. 이때 기억 장치는 현재 시간 (t)을 감안하여 시퀀스 (t+1)에서 다음 번에 값을 예측하고자 하는 경우, 현재 시간 (t)은 물론, 이전 두 시간 (t-1, t-2)을 입력 변수로 사용할 수 있다. 최적화 알고리즘과 오류 메트릭스는 동일하게 설정하였다. 선형SVM은 가장 기본적인 형태로 ϵ 항을 최소화하는 β_j 값의 조합을 찾는 선형최소제곱법 (Ordinary Least Squares, 이하 OLS)라는 알고리즘을 채택하였다. 피어슨 상관계수 (Pearson correlation coefficient)를 계산하여 피쳐들 (features)을 선택하였는데, 이때 0.6보다 작은 것들은 제거하였다. 또한 단계적 회귀 분석 (step-wise regression)에서 후진제거법 (backward elimination)을 사용하여 예측 변수 (features)의 유의성에 대한 상호 작용의 영향을 테스트함으로써 통계적 유의성을 평가하여 예측 모델을 구성하였다.

학습 및 검증을 위해서는 ECMWF의 입력 자료 경우 1998년 1월 4일부터 2017년 1월 3일까지 총 20년 동안의 일별 (daily) 자료 중 75% (1998년 1월 4일 ~ 2013년 1월 3일)를 학습에, 25% (2013년 1월 4일 ~ 2017년 1월 3일)를 검증에 활용하였다. GloSea5의 경우 1991년 1월 1일부터 2010년 12월 21일까지 총 20년 동안의 자료 중 마찬가지로 75% (1991년 1월 1일 ~ 2005년 12월 31일)를 학습에, 25% (2006년 1월 1일 ~ 2010년 12월 31일)를 검증에 이용하였다. 또한, 학습 모델 구축을 위해 훈련 자료로 사용된 ERA-Interim자료의 기간도 ECMWF와 GloSea5의 재현 기간을 포함할 수 있도록 1991년 1월부터 2017년 12월까지 이용하였다.

딥러닝을 포함한 기계학습 분야에서 항상 주의해야 할 점이 과적합 (overfitting)이다. 과적합 문제를 방지하는 방법에는 데이터 자체의 양을 늘리는 방법과 알고리즘적으로 해결하는 방법이 있다. 데이터의 양이 많아지면, 학습 과정에서 training/test의 크기가 커지면서 데이터의 다양한 측면을 다루면서 정확한 특징을 파악해서 보다 정확한 모델을 만들 수 있게 된다. 알고리즘 내에서 해결하는 방법 중 하나는 feature reduction이나 feature engineering을 통해 불필

요한 입력변수를 제거해 알고리즘이 효율적으로 학습을 하도록 하는 것이다. 하지만 이 방법은 개별 변수들의 특징과 상호작용에 대한 깊은 이해가 있어야 해석이 가능하기 때문에 별도의 연구가 필요하다. 또다른 알고리즘 내의 해결 방법으로는 dropout이 있다. 이는 딥러닝 신경세포 중 일부를 배제하며 학습을 진행함으로써, 신경망 세포들이 서로 동조하며 과적합으로 가는 것을 차단한다. 본 연구에서는 dropout ratio를 0.2로 설정하여 딥러닝 과적합을 방지하고자 하였다. 매해 S2S 데이터의 양이 증가하면 적은 데이터에 의한 과적합 문제도 해결될 것으로 기대된다.

(다) 딥러닝을 통한 계절내 기후예측 성능의 개선 평가

LSTM 딥러닝 기술을 이용해 GloSea5와 ECMWF 두 가지 S2S 예측 모델의 오류 (RMSE)가 크게 개선됨을 확인하였다 (Figure 52). 최고기온 (Tmax)의 경우, GloSea5 모델에서 0.2746이었던 RMSE가 0.0957로 (오차 감소: 0.1789), ECMWF 모델에서 0.2859의 RMSE가 0.0929로 (오차 감소: 0.193) 크게 감소하였다. 최저기온 (Tmin) 또한 GloSea5 모델에서 0.2741이었던 RMSE가 0.0957로 (오차 감소: 0.1784), ECMWF 모델에서 0.2818의 RMSE가 0.0937로 (오차 감소: 0.1881) 감소하여, 두 예측 모델에서 유사한 정도의 오차 감소를 보였다. 강수량 (Prec)의 경우 GloSea5 모델에서 0.5851이었던 RMSE가 0.0505로 (오차 감소: 0.5346), ECMWF 모델에서 0.5888의 RMSE가 0.0491로 (오차 감소: 0.5397) 상당폭의 예측 오차 감소를 보였다. GloSea5와 ECMWF 모델간에는 원자료와 딥러닝 적용 후 예측 성능에서는 전체적으로 큰 차이를 보이지는 않았다.

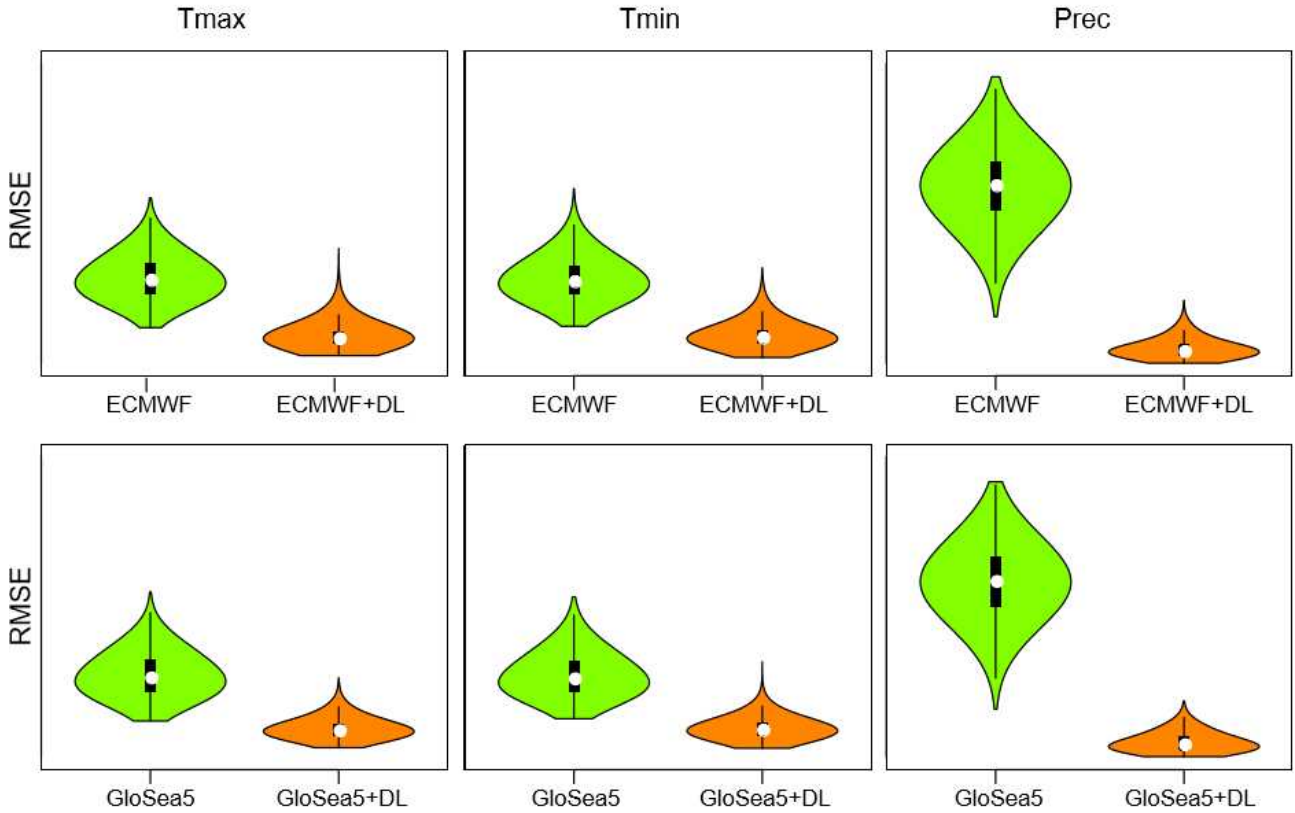


Figure 52. Overall prediction performance before and after LSTM measured by RMSE.

Correlation coefficient (CC)의 경우에도 GloSea5와 ECMWF 두 가지 S2S 모델에서 예측 성능이 다소 개선됨을 확인하였다 (부록 D Supplementary Figure 1). 최고기온 (Tmax)의 경우, GloSea5 모델에서 0.4709이었던 CC가 0.5602로, ECMWF 모델에서는 0.3942의 0.4984로 상승하였다. 최저기온 (Tmin) 또한 GloSea5 모델에서 0.5201이었던 CC가 0.5921로, ECMWF 모델에서 0.4401의 CC가 0.5196로 두 예측 모델에서 상관계수의 상승을 보였다. 강수량 (Prec)의 경우 또한 GloSea5 모델에서 0.0039이었던 CC가 0.0888로, ECMWF 모델에서 0.0039의 CC가 0.1227로 증가하였다. LSTM 학습을 통해 S2S 모델에 상관없이 계절내 예측 자료의 RMSE 및 CC 예측성 개선 효과가 높음을 확인하였다.

(라) 다른 머신러닝 기법간 예측성능 개선 비교

본 연구에서 사용한 LSTM 방법은 다른 머신러닝/딥러닝 기법에 비해, 시계열 자료 예측에서 이론적으로 뛰어나다고 알려져 있다. 이를 확인하기 위해 같은 데이터셋에 대해 대표적인 머신러닝 방법인 support vector machine (SVM)과 LSTM보다 한 세대 이전 딥러닝 방법인 recurrent neural network (RNN)을 적용하였다 (Figure 53, 부록 D Supplementary Figure 2). SVM의 경우 GloSea5와 ECMWF 두 모델에서 실제 최고/최저온도의 오차가 0.1~0.3도 가량 소폭 감소되었고, 강수량의 경우에도 6.5~10.3mm 정도로 오차가 감소되었다. RNN의 경우 최고/최저기온예측에서 S2S원자료나 SVM보다 0.4~2.8도의 훨씬 뛰어난 오차 감소를 보였다. GloSea5

모델의 경우, RNN을 통해 보정된 최고온도는 LSTM보다도 뛰어난 2.4도의 오차를 보여, ERA-Interim 재분석 자료와 가장 유사한 성능을 보여주었다. 다만, 강수량의 경우 S2S 원자료에 비해 5mm 가량 감소하긴 했지만, SVM보다는 떨어지는 성능을 보였다. LSTM의 경우 거의 모든 모델, 예측변수에서 다른 방법에 비해 RMSE를 크게 줄여줄어, 가장 안정적인 성능을 보여주었다. 이는 시계열 자료의 장기 의존성 문제를 해결하는 LSTM의 특징이 S2S 예측에서도 큰 효과를 발휘함을 나타낸다.




Figure 53. Comparison of performance (RMSE) among machine learning algorithms.

(마) 선행 시간 전체의 day-to-day 변동성 분석

예측 기간 전체에 걸친 딥러닝의 예측 성능 향상을 확인하기 위해 S2S 데이터의 배포일, 격자 전체 데이터에 대해 ERA-Interim 재분석 자료와의 RMSE 및 CC를 계산하여, LSTM 보정 이후의 계산 결과와 비교하였다 (Figure 54 and 부록 D Supplementary Figure 3). ECMWF와 GloSea5 두 모델 모두 딥러닝을 통해 보정된 결과가 크게 향상되었다. ECMWF의 경우 최고기온이 1도, 최저기온이 1.9도, 강수량은 9.8mm 가량 오차가 크게 감소했다. GloSea5의 경우 최고기온이 2.1도, 최저기온이 2.2도, 강수량이 14.5mm 감소되어 더욱 RMSE 개선폭이 컸다.




Figure 54. Comparison of daily performance (RMSE) across entire forecast lead time.

(바) 선행 주수별 주평균 예측의 year-to-year 변동성

계절내 예측 모델의 예측률이 시간이 지남에 따라 크게 감소된다고 알려져 있다. 딥러닝에 의해 이 문제가 해결될 수 있는지 알아보기 위해, ECMWF와 GloSea5 두 모델의 최고/최저기온, 강수량 3개 변수에 대해 주별 예측 오차를 RMSE로 계산하였다 (Figure 55, Table 6, and 부록 D Supplementary Figure 4). 다른 결과와 마찬가지로, 딥러닝을 통해 두 모델, 세 예측 변수 모두 안정적으로 오차가 크게 감소하였고, 강수량 예측에서 오차 감소폭이 더 크게 나타났다. ECMWF의 경우 예측변수에 관계없이 긴 선행주수에서 더 큰 폭으로 RMSE가 개선되었다. 예를 들어, 최저기온의 경우 1주 선행 예측에서 1도의 오차 감소폭이 5주 선행 예측에서 2.2도로 오차가 더욱 크게 감소되었다. GloSea5의 경우 선행주수에 따른 개선폭은 미비했으나, ECMWF에 비해 컸던 원자료의 RMSE가 더욱 큰 폭으로 감소하였다. 예를 들어, ECMWF 최고기온의 1주 선행 예측은 딥러닝을 통해 0.4도의 오차가 감소했지만, GloSea5의 경우 같은 변수/선행 시간 예측에서 1.9도의 오차가 감소하였다. 따라서 예측성능 개선이 힘든 것으로 알려진 S2S 원자료를 딥러닝을 통해 선행 주별 예측 오차가 크게 개선됨을 알 수 있었다.

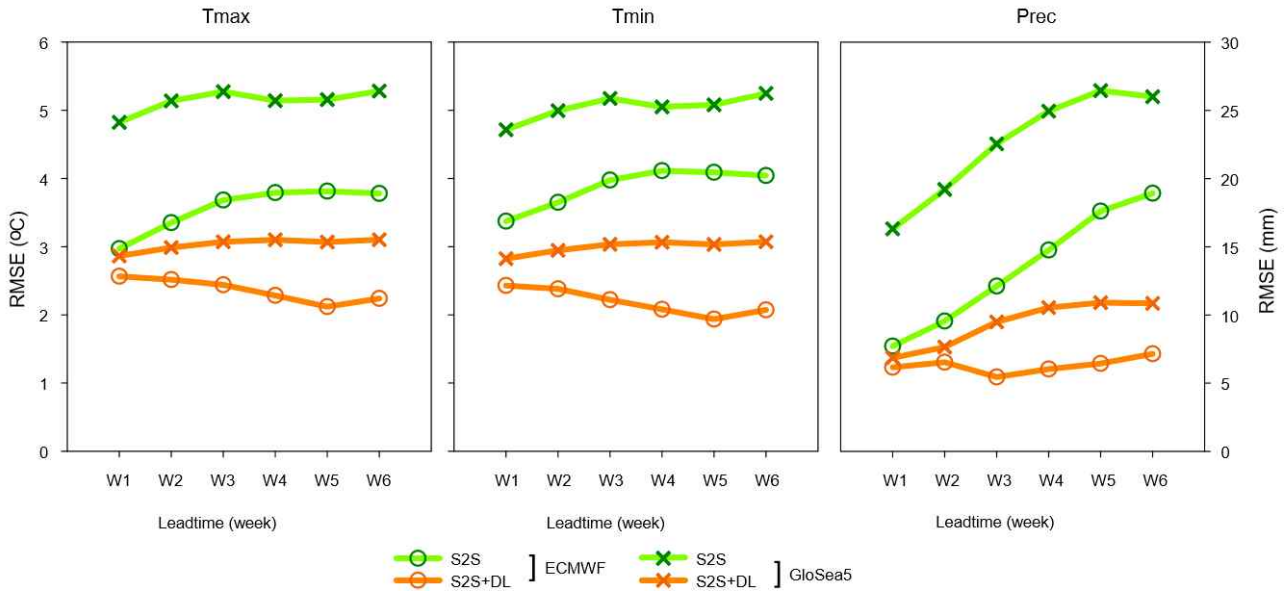


Figure 55. Weekly RMSE before and after applying LSTM algorithms to ECMWF and GloSea5.

Table 7. Weekly RMSE before and after LSTM learning

RMSE	GloSea5						ECMWF					
	Tmax(°C)		Tmin(°C)		Prec(mm)		Tmax(°C)		Tmin(°C)		Prec(mm)	
	S2S	S2S+DL	S2S	S2S+DL	S2S	S2S+DL	S2S	S2S+DL	S2S	S2S+DL	S2S	S2S+DL
W1	4.8	2.9	4.7	2.8	16.3	6.9	3.0	2.6	3.4	2.4	7.7	6.2
W2	5.1	3.0	5.0	2.9	19.2	7.7	3.4	2.5	3.6	2.4	9.6	6.5
W3	5.3	3.1	5.2	3.0	22.6	9.5	3.7	2.4	4.0	2.2	12.1	5.5
W4	5.1	3.1	5.1	3.1	24.9	10.5	3.8	2.3	4.1	2.1	14.8	6.0
W5	5.2	3.1	5.1	3.0	26.5	10.9	3.8	2.1	4.1	1.9	17.6	6.4
W6	5.3	3.1	5.2	3.1	26.0	10.9	3.8	2.2	4.0	2.1	18.9	7.2

(사) 초기 시점에 따른 개선 민감도 분석

계절내 예측은 예측 시작 시점에 따라 오차가 달라진다고 알려져 있다. Figure 56과 Figure 57에서 보듯이 S2S 원자료 (초록색 선)의 경우 전체 선행 시간 혹은 3주차의 오차 계절성이 뚜렷함을 볼 수 있다. 예를 들어 최고/최저기온의 경우 겨울과 초여름철에 생산되는 계절내 예측 데이터가 다른 계절에 비해 약 20% 큰 RMSE를 보였다. 강수량의 경우 가을철에 생산된 계절내 예측 데이터의 RMSE가 다른 계절에 비해 컸다. 본 연구에서 구축된 딥러닝 모델의 경우, S2S 데이터의 배포일별로 학습 모델이 구축되기 때문에, S2S 예측의 계절성을 감소시킬 수 있는 장점이 있다. LSTM을 이용한 학습 결과, S2S 모델과 예측 변수의 종류에 관계 없이 모든 데이터 생산 시점에 걸쳐 RMSE가 큰 폭으로 개선되었다 (주황색 선). 특히 오차가 큰 계절에서 RMSE 개선폭이 두드러져, 딥러닝이 S2S 예측 성능의 개선에 강력한 효과를 발휘함을 보여주었다.




Figure 56. Seasonality of S2S-Deep learning prediction (entire forecast lead time)

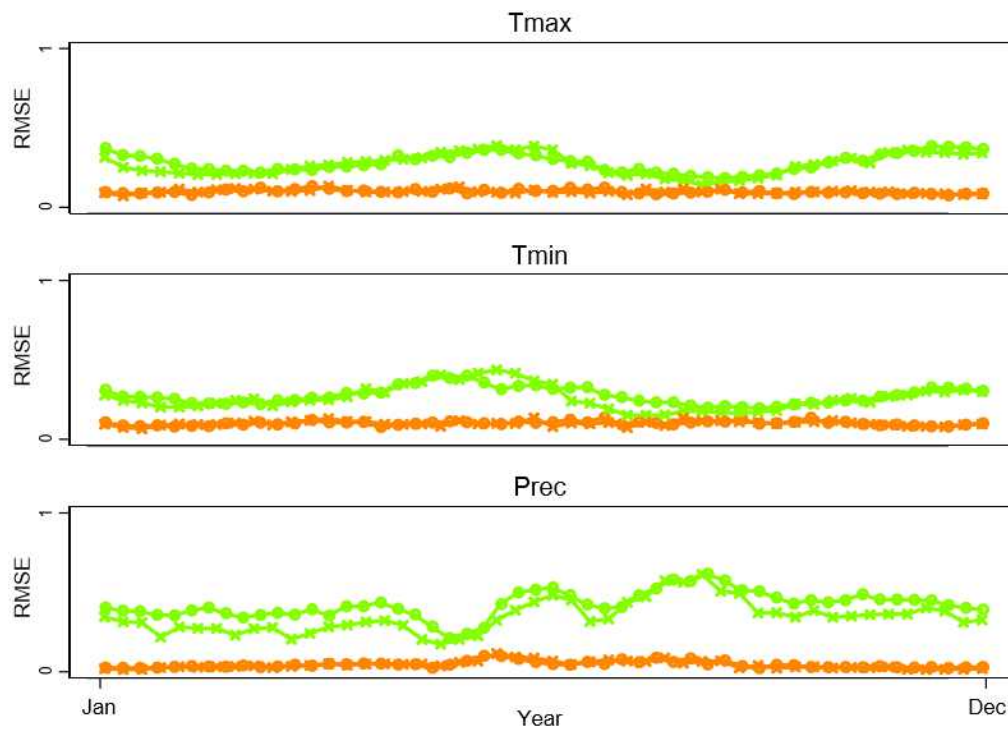


Figure 57. Seasonality of S2S-Deep learning prediction (week 3 forecast)

(2) 겨울철 동아시아 기온 예측 보정 기술 개발

(가) 동아시아 겨울 기온과 관련된 대기 변동 모드의 예측성 평가

① 동아시아 주평균 기온 예측성 평가

겨울철 한파/난파 등 극한 기상 현상이 빈번한 동아시아 영역에서 계절내 예측 개선을 위한 노력은 지속적으로 이루어지고 있다. 2018년 계절내 MME 과제에서는, 다중 모형 앙상블(MME) 기법을 적용한다고 하더라도 중위도 대륙에 위치한 동아시아의 예측성, 특히 하층 기온 예측성은 열대나 다른 해양을 낀 지역들에 비해 현저히 떨어짐을 확인하였다. 동아시아 주평균 2m 기온(T2m) 단순 평균법(Simple Composite Method, 이하 SCM) MME 예측의 ACC와 RMSE의 분포는 이 두 메트릭 사이의 역의 관계를 대략적으로 보여준다(Figure 58). 선행 주수가 길 때, 검증값의 분포가 매우 넓게 나타나는데 반해, 1주 선행 예보 검증값들은 상대적으로 좌상향으로 좁게 모여 있다. 각 선행 주수별 평균 성능을 살펴보면, 선행 시간이 길어질수록 ACC는 급격히 떨어지고 RMSE는 급격히 증가하는 양상을 보이지만, 과거의 상태가 지속될 거라는 persistent 예보에 비해서는 역학 예측 MME 성능이 현저히 높음을 알 수 있다(Figure 58b).

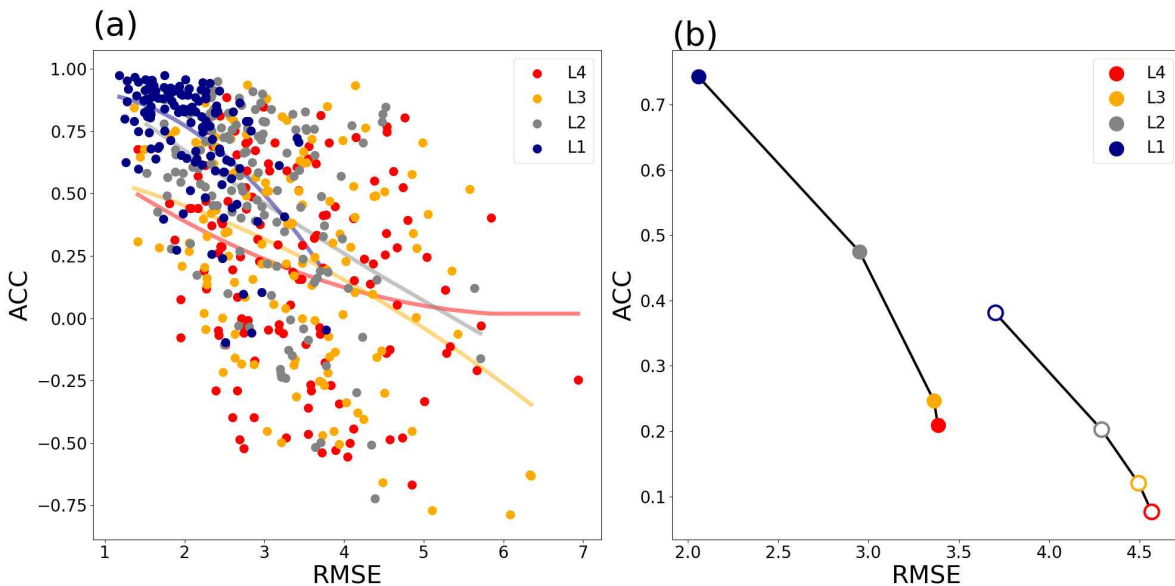


Figure 58. (a) scatter of RMSE and ACC of weekly mean T2M over East Asia for 11 winter seasons and (closed circles in (b)) overall skill variation with 1 to 4 weeks lead times. Open circles in (b) represent the persistent forecast skill.

동아시아 T2m 예측성능은 유의한 수준의 계절 변동을 보인다(Figure 59). ACC의 경우, 겨울철 성능이 여름철에 비해 근소하게 높게 나타났고, 그 차이는 선행 주수가 길수록 크다. RMSE의 경우 계절성이 매우 뚜렷한데, 겨울에는 오차가 매우 크고, 여름철은 상대적으로 매우 작다. 이는 지표 기온의 분산의 계절성과 일관된다. 중위도 대륙의 기온의 시간 변동성은 겨울

철에 매우 크고, 여름철에는 매우 작다. 또한 국지적 한파/난파가 빈번하고 비정상적으로 발생하는 겨울은 넓은 영역에 걸쳐 나타나는 여름에 비해 공간적인 변동성도 현저히 크다. 따라서 겨울철 기온 예측의 오차가 크게 나타나게 된다. 이러한 계절성은 선행 주수에 대해 일관되나, 역시나 긴 선행시간에서 그 격차가 크게 벌어진다.

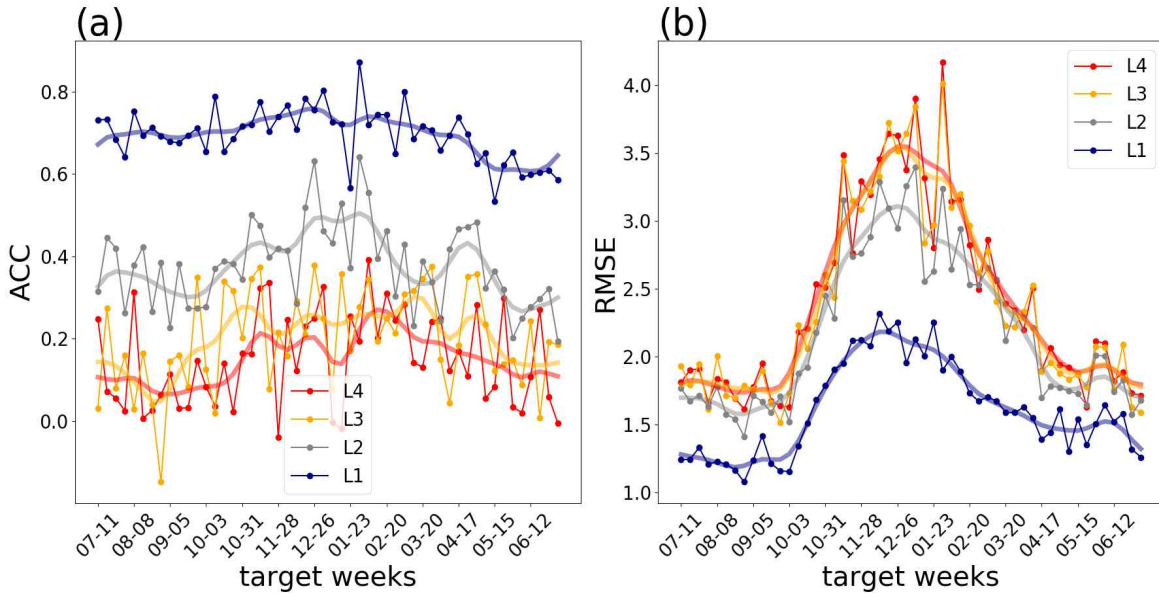


Figure 59. long term mean of weekly (a) ACC and (b) RMSE variation of weekly mean T2M over East Asia.

② 동아시아 주평균 기온의 주요 변동 패턴

동아시아 지역 기온 변동성을 확인하기 위하여 주평균 T2m 아노말리에 EOF 분석법을 적용한 결과는 Figure 60ab과 같다. 이 과제에서는 동아시아 영역을 다소 좁게 100.5° E~145.5° E, 30° N~60° N로 정의하였다. 첫 번째 모드의 공간 패턴은 전체 영역이 동시에 변동하는 pulsing 형태이고, 두 번째 모드는 남북방향의 쌍극자 형태이다. 각 모드에 대하여 아노말리장을 투영하는 방식으로 지수를 생산하고, 관측 지수와 SCM 예측 지수의 분포와 시간 상관 계수를 계산하였다 (Figure 60bc). 첫 번째 모드에 비해 두 번째 모드의 성능이 근소한 차이로 떨어지는데, 이는 변동성을 설명하는 정도가 적기 때문이고, 이러한 예측성 감소 경향은 고차 모드로 갈수록 매우 뚜렷하게 나타난다. 선행 주수별로 살펴보면, 1주 선행 예측은 매우 정확하나, 계절내 예보로서 주로 활용이 기대되는 3-4주 선행 예측의 성능은 두 모드 모두 현저히 떨어짐을 알 수 있다.

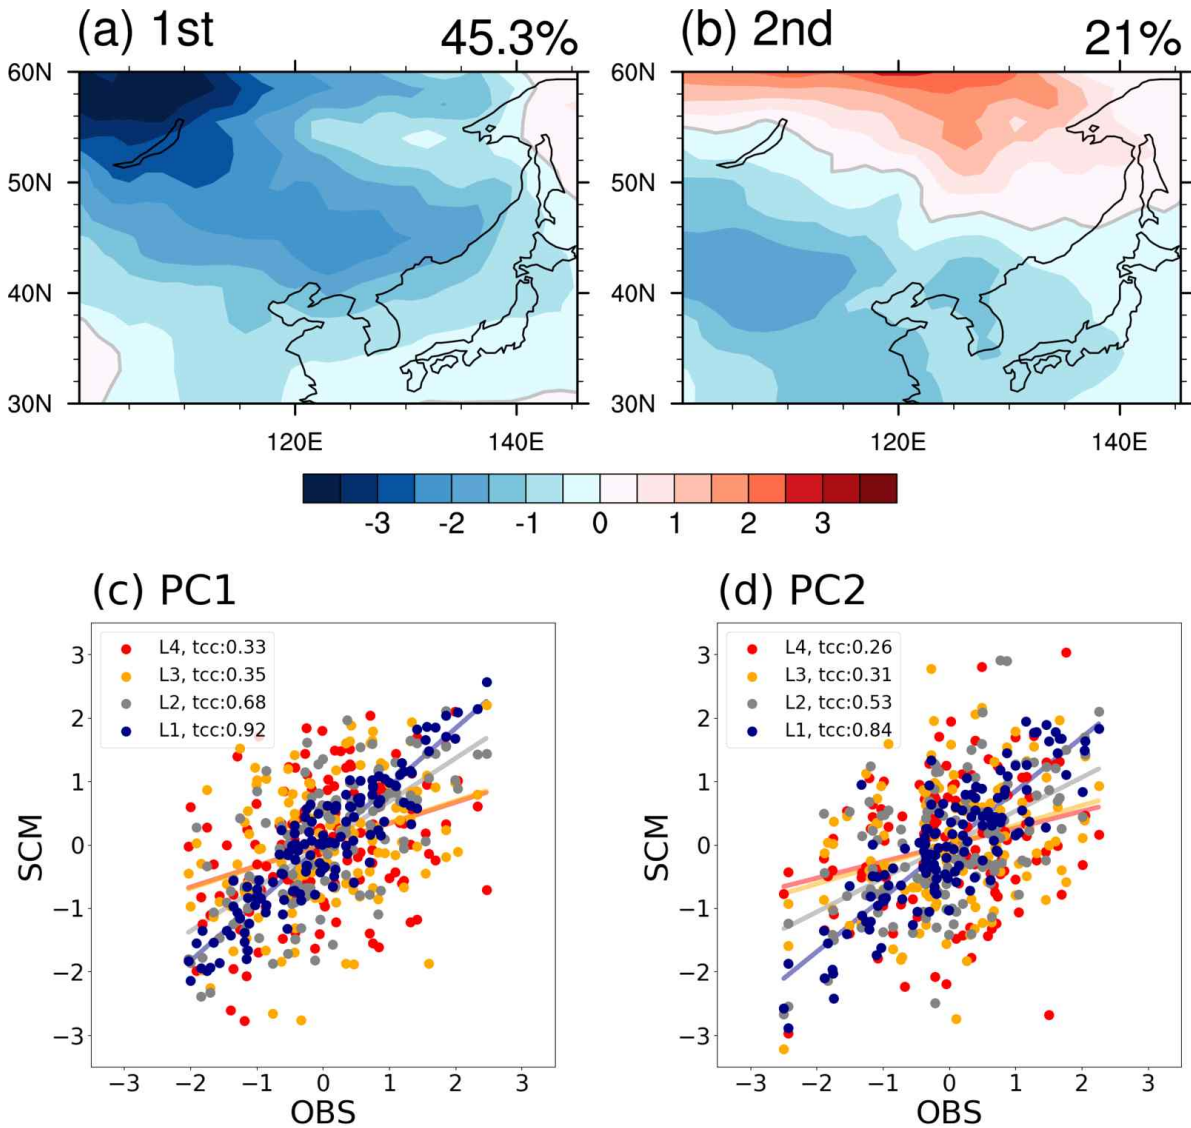


Figure 60. (a-b) spatial pattern of two leading EOF modes of T2M over East Asia (100.5° E- 145.5° E, 30° N- 60° N) derived from the observation and scatter of the observed and predicted PC time series corresponding to (c) 1st and (d) 2nd mode for lead times out to 4 weeks.

동아시아 기온 변동 모드 지수에 대한 스펙트럼 분석 결과는 Figure 61와 같다. 넓은 영역에서 pulsing 형태로 나타나는 첫 번째 모드의 경우 1년 이상의 장주기 변동성분의 파워가 크게 나타나는데 반해, 공간 규모가 작은 두 번째 모드의 경우 1년 미만의 단주기 변동성분의 파워가 상대적으로 크다. 이는 자연계 현상의 시·공간 규모의 일관성을 보여주는 단적인 예이다. SCM 예측의 경우, 파워스펙트럼 분포를 대략적으로는 잘 재현하고 있으나 시간 규모에 따른 파워의 상대적인 크기는 선행시간이 길어질수록 오차를 보인다 (Figure 61c). 관측의 경우, 첫 번째 모드는 1년 이상의 장주기 파워와 1년 미만의 단주기 파워가 서로 비슷하고, 두 번째 모드는 1년 미만의 단주기 파워가 더 크다. 이러한 파워의 상대적인 크기는 1주 선행 예측에서는 매우 정확하게 나타난다. 하지만, 선행 주수가 증가할수록 첫 번째 모드의 1년 미만의 단주기 파워가 증가하고, 반대로 두 번째 모드의 1년 이상 장주기 파워가 증가함으로써 3-4주에서는 그 상대성이 역전되어 나타난다. 이는 모형 예측에서 시·공간 규모의 일관성이 깨지고, 예

너지 분포가 어그러지는 현상으로, 앞서 언급한 고차 모드로 갈수록 지수 예측성이 떨어지는 것과는 일관된다.

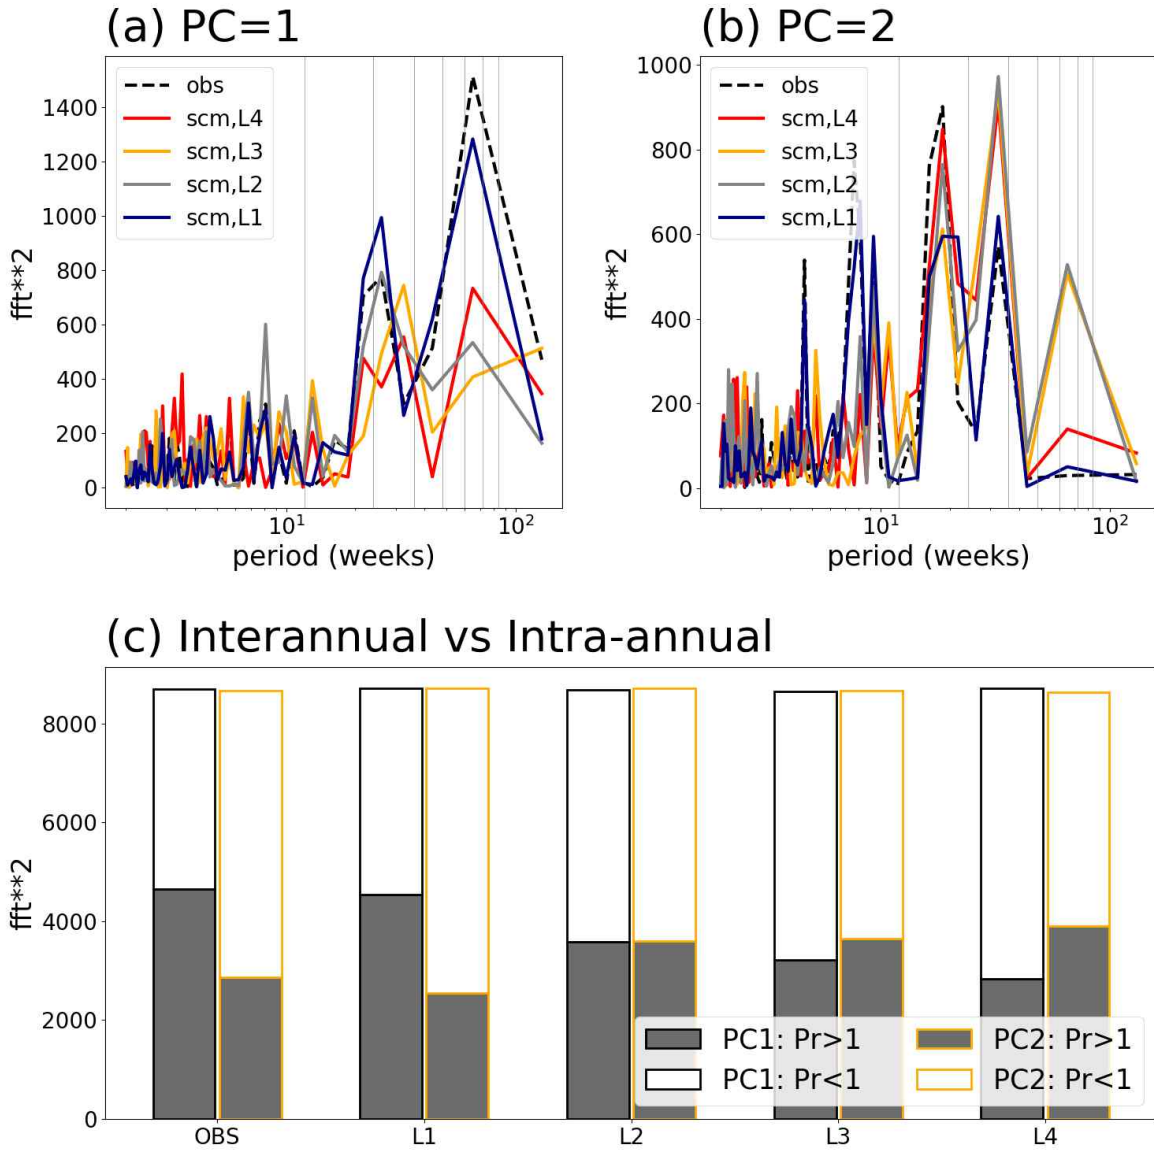


Figure 61. Power spectrum of (black dashed line) the observed and (color solid lines) the predicted PC time series corresponding to (a) 1st and (b) 2nd EOF mode of T2M over East Asia. (c) integrated power spectrum for (dimgray bar) interannual and (white bar) intra-annual time periods for (black boundary) PC1 and (orange boundary) PC2.

동아시아 기온 변동 모드에 대한 전지구 반응성을 확인하기 위해서, 두 모드 지수에 대한 상층 동서 바람장 (U200)과 해수면 기압장 (MSLP) 회귀장을 그려 보았다 (Figure 62). 첫 번째 모드의 경우, 태평양 제트의 풍상측에의 강화 및 북상, 대서양 제트의 풍하측에서의 남하, 시베리아 고기압 강화와 관련하여 나타남을 확인할 수 있다. 두 번째 모드의 경우, 태평양 제트의

강화 및 위도 방향 범위 축소, 대서양 제트 풍하측 축소, 시베리아 고기압과 알류시안 저기압 비대칭 강화 등으로 나타난다. 시베리아 고기압의 확장 및 해양 저기압과 대치되는 회귀장 패턴은 동아시아 겨울 주평균 기온 변동성이 동아시아 겨울 몬순 시스템과 연관되어 있음을 시사한다. 또한, 극지역과 주변 중위도 지역이 뚜렷이 대비되는 MSLP 회귀장 패턴으로부터 동아시아 겨울 주평균 기온 변동성이 극진동 현상과도 유의하게 연관되어 있음을 예상할 수 있다.

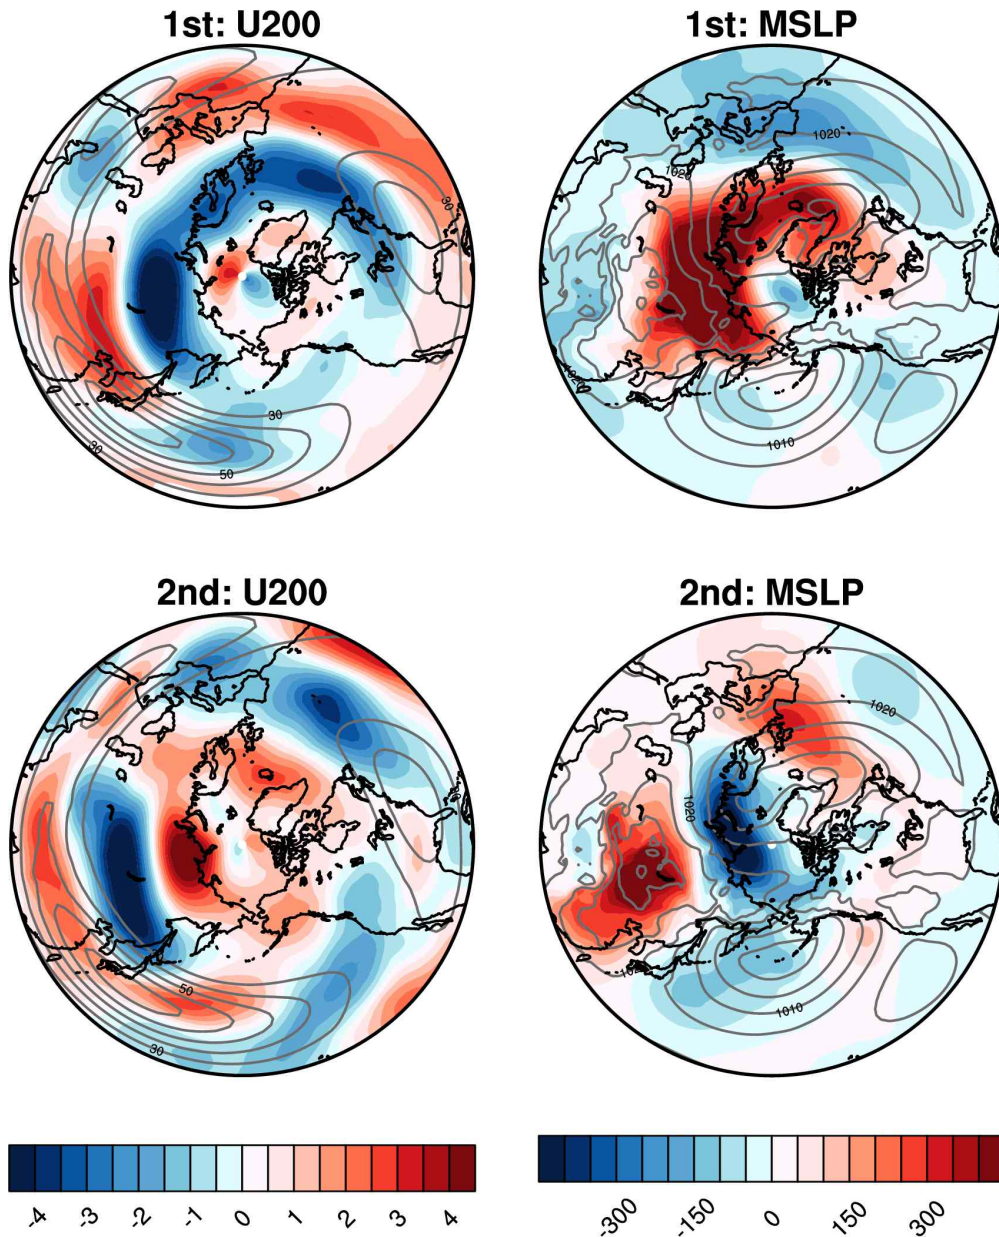


Figure 62. Observed (left) U200 and (right) MSLP patterns regressed onto the observed (upper) 1st and (right) 2nd PC time series. Contours display observed winter mean climatology.

③ 대기 변동 모드들의 예측성 평가

앞서 동아시아 겨울 주평균 기온 변동과 관련된 것으로 파악된 다양한 기후 모드들에 대한 모형 예측 특성 분석 및 성능 평가, 그리고 기후 변동 모드들간의 관련성에 대한 모형 재현성에 대한 결과를 제시하겠다.

㉞ 시베리아 고기압

시베리아 고기압의 강도를 나타내기 위해 시베리아 고기압의 영역에 대하여 평균된 MSLP 값을 지수로 사용하는데, Figure 63(a)는 관측 시베리아 고기압 지수와 1주부터 4주전 예측된 개별모형, 그리고 MME의 상관계수를 나타낸 것이다. 선행시간이 증가함에 따라 상관계수가 급격히 감소하는 것을 확인할 수 있으며, 각 주 별 상관계수의 값도 큰 변동을 보인다. 전반적으로 개별모형에 비해 MME가 상관계수의 값이 가장 크거나 두 번째로 큰 값을 보이고는 있으나, MME에 의해 예측된 시베리아 고기압 영역의 MSLP도 관측과 통계적으로 유의한 상관관계는 예측 선행 2주전까지만 나타난다 (Figure 65(b)). 따라서 비록 MME에 의해 예측된 시베리아 고기압의 예측성이 개별모형에 비해 우위를 차지한다 할지라도 이 예측정보를 직접 활용하기에는 여전히 한계가 있다.

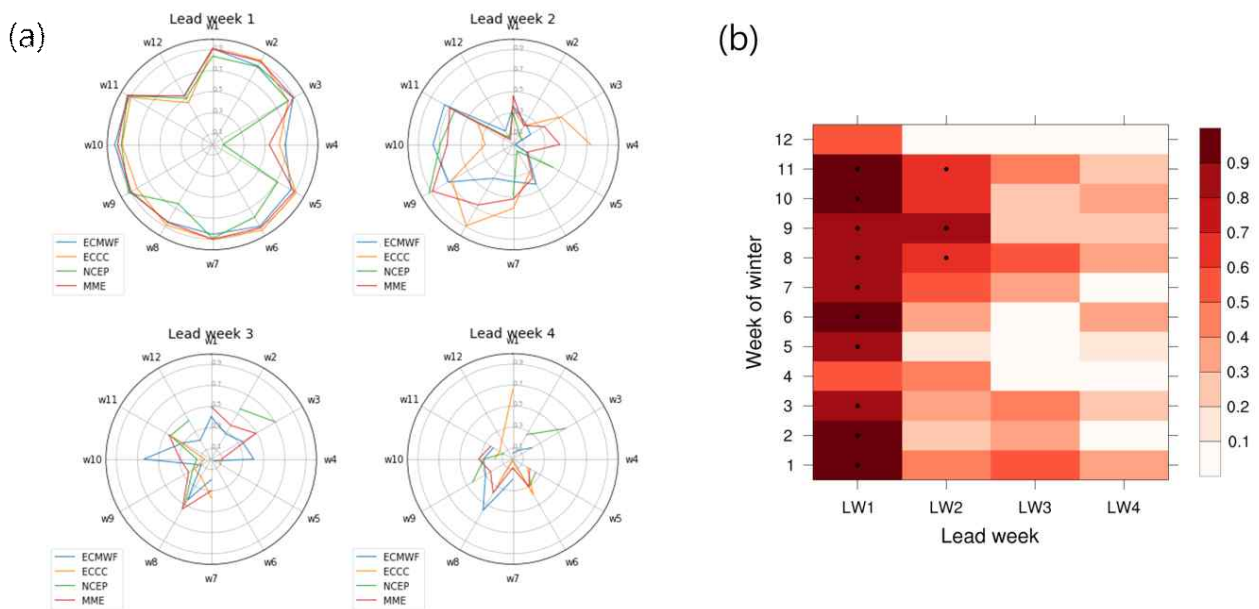


Figure 63. (a) TCC of DJF weekly SHI between models (individual models and MME) and the observation from lead week 1 to 4. (b) Correlation of weekly SHI between the observation and S2S MME. Dots indicate value greater than 95 % confidence level. Week1 (W1) indicates first week of the winter from December through February.

이에 본 연구에서는 시베리아 고기압 영역에 대해 평균된 MSLP의 겨울철 계절내 변화경향 예측을 통해 동아시아 지역의 기온 변화를 예측하는 기법을 제안하고자 한다. 즉, Figure

64과 같이 MME예측 초기시점으로부터 4주까지 예측된 값을 활용하여 도출된 시베리아 고기압의 주별 증감을 나타내는 기울기 정보를 통하여 시베리아 고기압 강도의 발달과 쇠퇴를 예측하게 된다. 이를 바탕으로 동아시아 영역의 향후 4주 기온의 변화 경향을 예측할 수 있다.

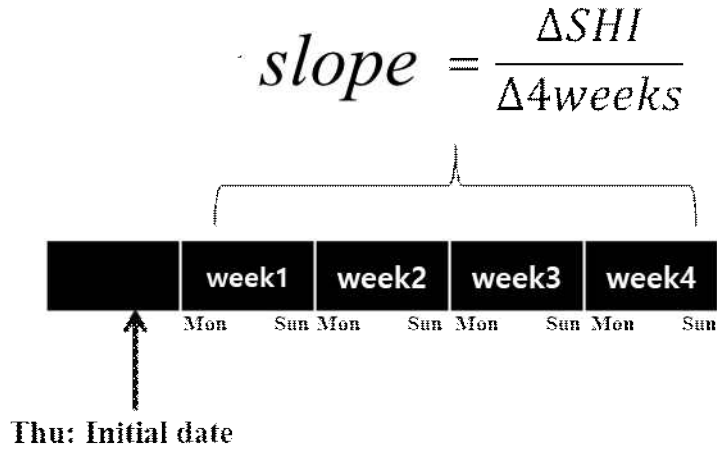


Figure 64. Schematic diagram of weekly slope prediction.

기후학적으로 시베리아 고기압의 강도는 Figure 65(b)와 같이 12월부터 1월초까지 증가하는 추세를 보이다가 1월초부터 점차 감소하는 경향을 보인다. 시베리아 고기압 강도의 증가는 한반도, 중국 북부, 그리고 일본을 포함한 동아시아 영역에 통계적으로 유의미한 기온 하강을 가져온다 (Figure 65(c)).

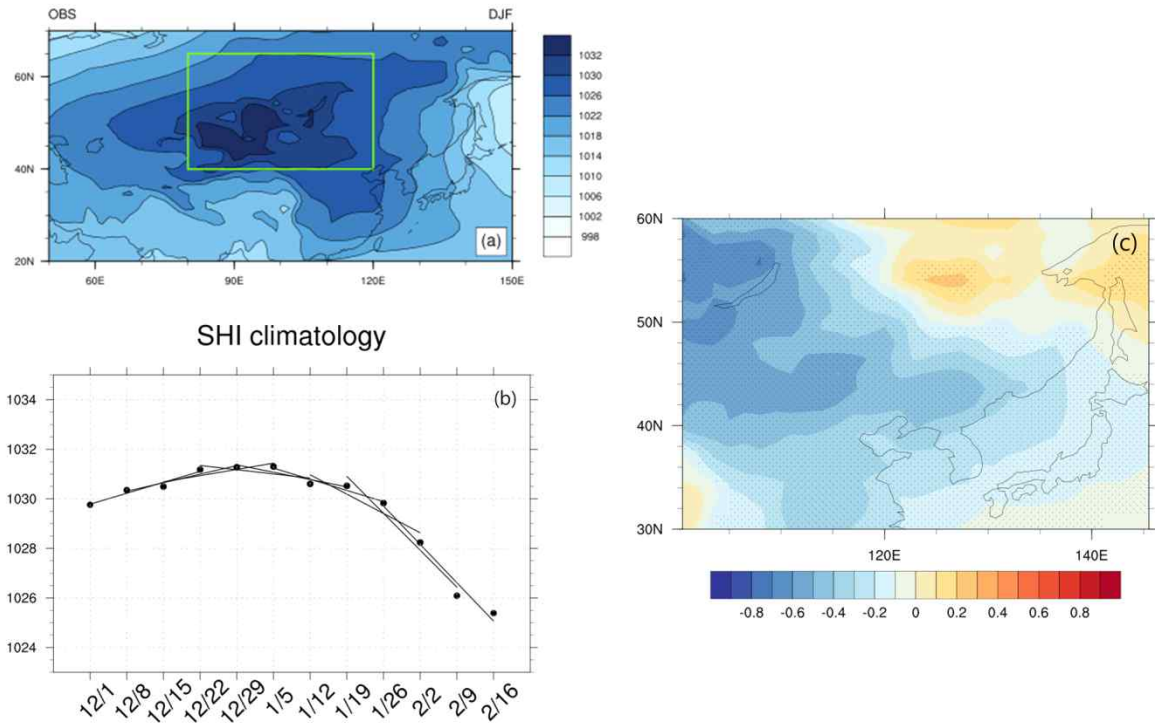


Figure 65. Observed (a) winter mean (DJF) MSLP for 1999-2010(the domain for Siberian High is indicated with a green rectangle), (b) weekly climatology (dot) and slope for 4-week (solid line) SHI, and (c) 2m temperature anomalies regressed onto weekly SHI. Values exceeding 90% confidence level are dotted.

Figure 66은 본 연구에서 제안된 방법론을 2001년 사례에 적용하여 나타낸 것이다. 2001년의 경우, 시베리아 고기압의 강도는 12월에 감소하는 추세를 보이다가 1월 초부터 중순까지 증가 후, 1월 후반에 들어 다시 감소하는 경향을 나타낸다 (Figure 66(a)). 이 때 동아시아 기온의 변화 경향을 살펴보면 시베리아 고기압 강도가 감소하는 12월에 증가하는 경향을, 시베리아 고기압 강도가 증가하는 1월 초 中반에 감소하는 경향을 보이고 있다 (Figure 66(b)). Figure 66 (c)는 2001년 시베리아 고기압 강도 변화경향의 MME 예측을 나타낸 것이다. 같은 색으로 표시된 각각의 동그라미 기호는 같은 시작일로부터 예측된 값을 의미한다. 이렇게 예측일로부터 4주후까지 예측된 값을 바탕으로 도출된 각각의 기울기를 역시 같은 색으로 표현되었다. 2001년의 경우, 기울기의 크기에 있어서 관측과 다소 큰 차이가 존재하나, 기울기의 부호가 대체로 관측과 일치하는 것을 확인할 수 있다.

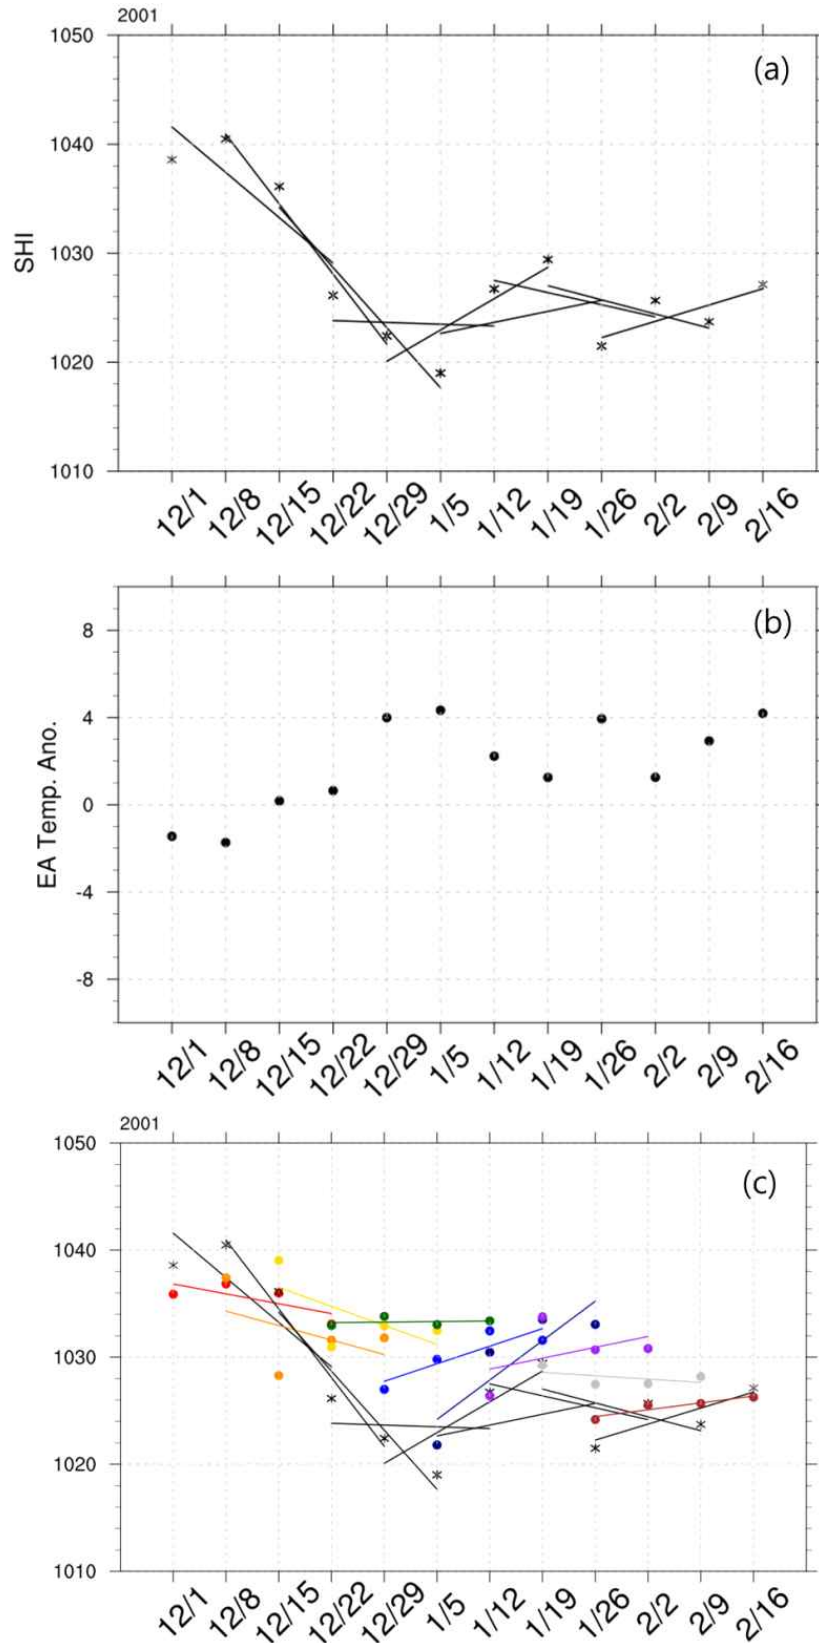


Figure 66. Observed SHI (asterisk) and 4-week slope of SHI (solid line), (b) 2m temperature anomalies averaged over EA, and (c) SHI (colored dot) and 4-week slope of SHI (solid line) in 2001. Markers and lines in same color denote those are predicted by MME at the same initial date.

Figure 67(a)는 1999/2000-2009/2010 DJF 겨울철 시베리아 고기압 강도의 계절내 변화를 나타내는 기울기의 관측값과 예측값을 나타낸 것이며, Figure 67(b)는 관측의 기후값과 해당 연도의 관측기울기 값을 나타낸 것이다. 관측값의 경우, 삼각형의 상하 방향은 기울기의 부호를, 삼각형의 크기는 강도를 각각 나타낸다. 이 중, 동그라미가 쳐있는 기호는 관측과 일치하거나 혹은 비슷 범위에 든 예측 값을 의미한다. 기후값에 의존한 예측의 경우 관측과 일치하는 경우는 전체 99회 중 21회로 약 21 퍼센트의 적중율을 보이지만, 관측과 계절내 예측이 일치하는 경우는 31회, 약 31 퍼센트로 기후값에 기반한 예측에 비해 개선된 적중율을 보인다.

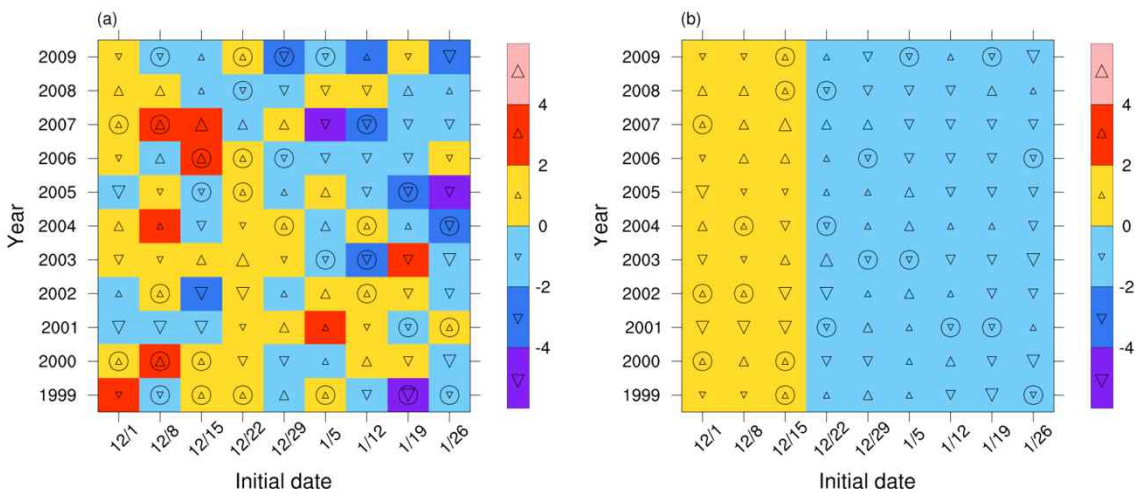


Figure 67. Slope of SHI (a) predicted by MME and (b) climatology for 4 weeks from each initial date from 1999/2010 to 2009/2010 (hPa/week). Observed slope (▽: positive slope, △: negative slope) is overlaid. Circle denotes that the prediction is consistent with the observation.

시베리아 고기압 강도의 계절내 기울기의 관측과 MME 예측의 상관계수는 0.5보다 큰 값으로 기후값과 관측값이 약 0.3정도의 상관계수를 보인 것 보다 크고 (Figure 68(a)), 관측과 MME 예측간의 RMSE 또한 관측과 기후값의 RMSE보다 작은 값을 보임으로써 (Figure 68(b)) 기후값에 준하여 시베리아 고기압 강도의 계절내 변화경향을 예측하는 것보다 MME 예측 결과가 더 우수한 것을 알 수 있다.




Figure 68. (a) Correlation of SHI slope between the MME and the observation (left bar) compared to the correlation of SHI slope between the climatology and the observation (right bar). (b) RMSE of MME SHI slope and climatology SHI slope with respect to the observation.

한편, 양의 기울기와 음의 기울기를 나타내는 빈도수를 관측, MME 예측, 기후값에 대해 살펴보면, 1999/2000-2009/2010년 DJF 동안 양의 기울기 빈도수: 음의 기울기 빈도수가 각각 44:55, 49:50, 33:66으로 나타났다 (Figure 69).




Figure 69. Number of occurrence of (a) positive slope and (b) negative slope of SHI for the observation, climatology, and MME for DJF from 1999/2000 to 2009/2010.

이처럼 시베리아 고기압 강도의 계절내 변화를 나타내는 기울기의 예측에 있어서 기후값에 근거한 예측에 비해 MME 예측이 우수한 것으로 나타났다. 다만, Figure 70(a)와 같이 관측에 비해 계절내 예측에 의한 기울기 값의 범위가 다소 작은 경향을 보인다.

Figure 70(b)는 시베리아 고기압 강도의 계절내 변화에 따른 동아시아 영역에 대해 평균된 기온 변화 경향의 상자-수염 그래프이다. 시베리아 고기압 강도의 기울기가 양의 값을 가질 때 동아시아 영역의 기온이 감소하고, 시베리아 고기압 강도의 기울기가 음의 값을 가질 때 동아시아 영역의 기온이 증가하는 경향을 관측과 예측에서 모두 확인할 수 있다.




Figure 70. Boxplot of weekly slope of SHI for negative and positive cases, respectively (left) and weekly slope of the observed temperature at 2m over East Asia corresponding to positive and negative slope of SHI (right).

Figure 71은 관측과 예측에서 시베리아 고기압 강도의 기울기가 각각 양의 값과 음의 값을 가질 때 동아시아 영역에서 2m 온도 기울기 합성장을 나타낸 것이다. 합성장의 패턴이 앞서 Figure 65(c)에서 보인 기온 아노말리를 시베리아 고기압 지수에 회귀시킨 결과와 유사한 것을 확인할 수 있다. 즉, 시베리아 고기압의 강도가 증가할 때, 한반도, 중국 북부, 일본을 포함한 동아시아 영역에서 온도의 감소 경향이 나타나고 (Figure 71(a)) 시베리아 고기압의 강도가 감소할 때는 그 반대 경향이 나타난다 (Figure 71(b)). 계절내 예측에 의한 시베리아 고기압 강도 기울기의 부호에 따라 관측 온도 변화 경향을 합성한 결과, 관측에 비해 그 변화 경향이 작다 (Figure 71(c),(d)).

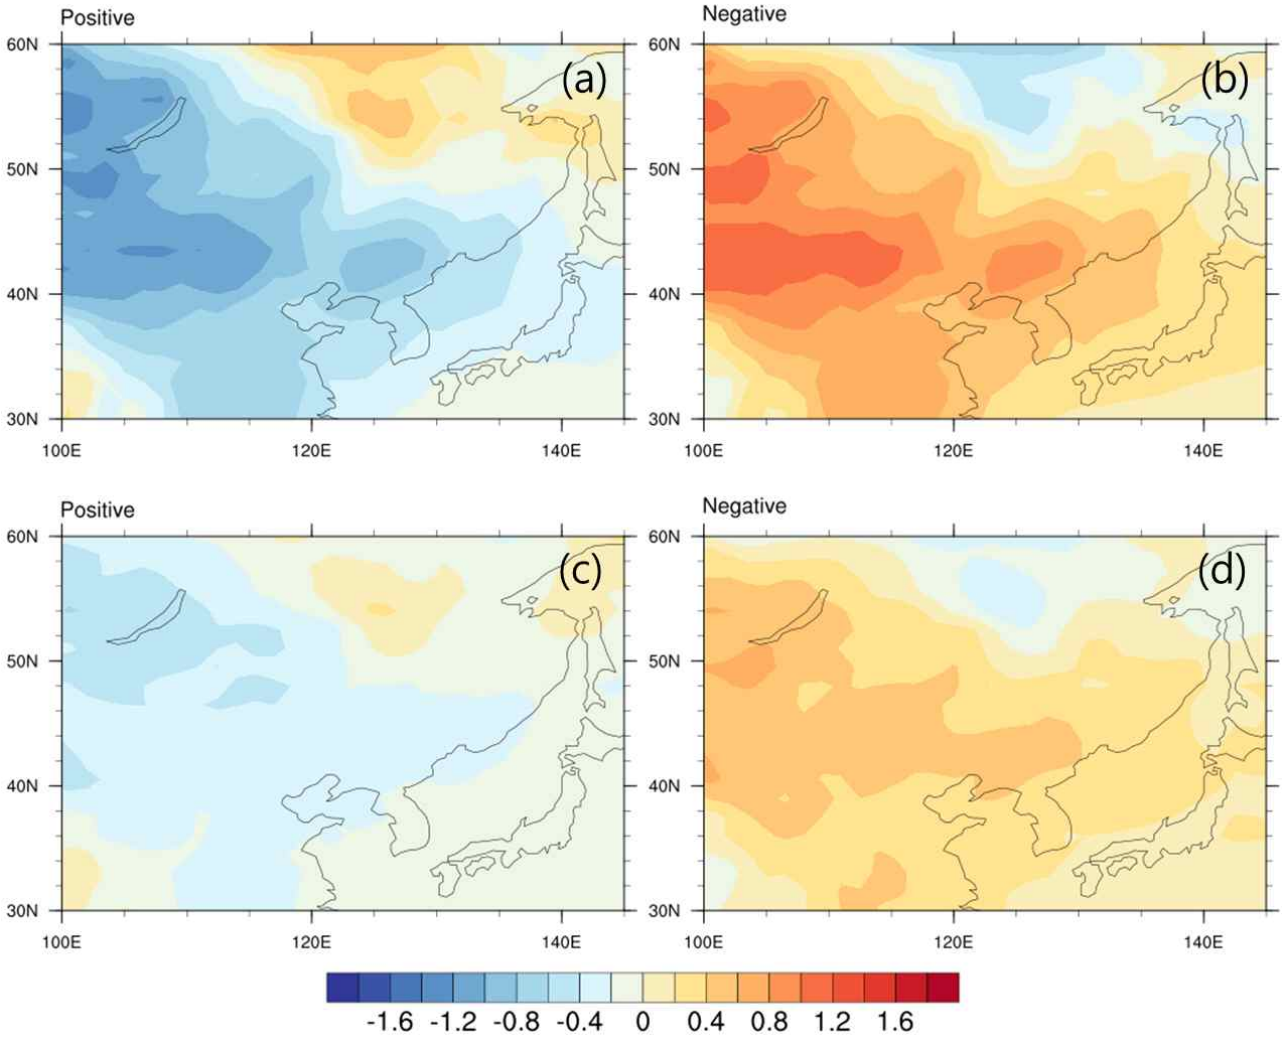


Figure 71. Composite of 2m temperature tendency ($^{\circ}\text{C}/\text{week}$) for positive (a) and negative (b) cases of observed SHI slope and positive (c) and negative (d) case of SHI slope predicted by MME.

㉔ 동아시아 겨울몬순과 태평양 제트

동아시아 겨울철 날씨 및 기후는 동아시아 겨울 몬순의 영향을 크게 받는다. 본 연구에서는 Table 6에 나열된 4가지 타입의 동아시아 겨울 몬순지수의 계절내 예측성을 평가해보고 계절내 시간규모에서 이들 지수의 활용 방안에 대해 논의해보고자 한다.

Figure 72(a)는 관측자료를 바탕으로 한 동아시아 겨울 몬순 지수와 개별 모델 및 MME에 의해 예측된 겨울몬순 지수의 상관계수를 선행시간 별로 비교한 것이다. 4개의 지수 모두 선행시간이 증가함에 따라 예측과 관측간의 상관관계가 급격히 줄어드는 것을 확인할 수 있다. 동아시아 겨울몬순 지수 예측에 있어서도 MME 예측 성능이 각 개별모형의 성능과 비교하였을 때 상대적으로 우수하다. 4개의 동아시아 겨울 몬순 지수 중, Li and Yang (2010)이 제안한 200 hPa 수평바람장의 경도를 바탕으로 한 Li_U 지수의 예측성능이 개별모형과 MME 모두에서 우수한 것으로 나타났다. Figure 72(b)에서도 MME를 통해 예측된 4개의 동아시아 몬순 지수 각

각의 예측성을 비교하였을 때, 상층 바람 강도에 기반한 Li_U가 예측선행 3-4주전에도 통계적으로 유의미한 상관관계를 보이는 것으로 나타났다.

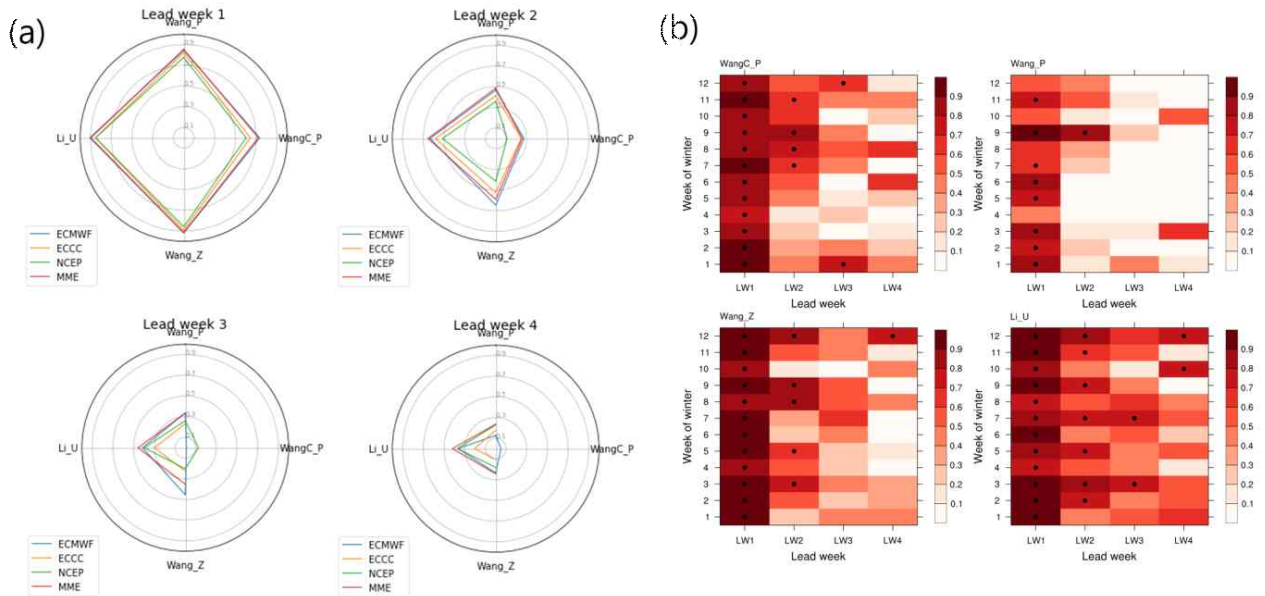


Figure 72. (a) DJF mean of weekly EAWMI TCC between models (individual model and MME) and the observation from lead week 1 to 4 (b) Correlation of weekly EAWMI between the observation and S2S MME. Dots indicate value greater than 95 % confidence level.

겨울몬순이 계절내 예측의 성능에 어떠한 영향을 미치는지 알아보기 위하여 4개의 동아시아 몬순 지수에 기반하여 분석 기간인 1999/2000-2009/2010년 겨울철의 몬순 타입을 강도에 따라 구분하였다 (Figure 73). Figure 73(a)와 같이, 1981/1982-2009/2010년을 기준으로 하여, 정규화된 4개의 동아시아 겨울 몬순 지수의 DJF 평균값 중 2개 이상이 1.0 표준편차 이상의 값을 가지면 강한 겨울 몬순해, -1.0 표준편차 이하의 값을 가지면 약한 겨울 몬순해로 정의하여 구분하였다. 이와 같은 방법으로 각 해 별 몬순 타입은 Figure 73(b)와 같이 구분될 수 있다. 1999/00, 2000/01, 2004/05, 2005/2006은 강한 겨울 몬순해로 구분되고 이때 동아시아 겨울철 평균 기온은 음의 편차를 나타내는 반면, 2006/07, 2008/09는 약한 겨울 몬순 해로서 이 시기 동아시아 겨울철 평균 기온은 양의 편차를 나타내는 것을 확인할 수 있다. 약한 몬순 해, 혹은 강한 몬순 해로 구분되지 못한 나머지 해의 경우 몬순 강도에 따른 동아시아 겨울철 평균 기온의 뚜렷한 패턴을 확인하기 쉽지 않다.

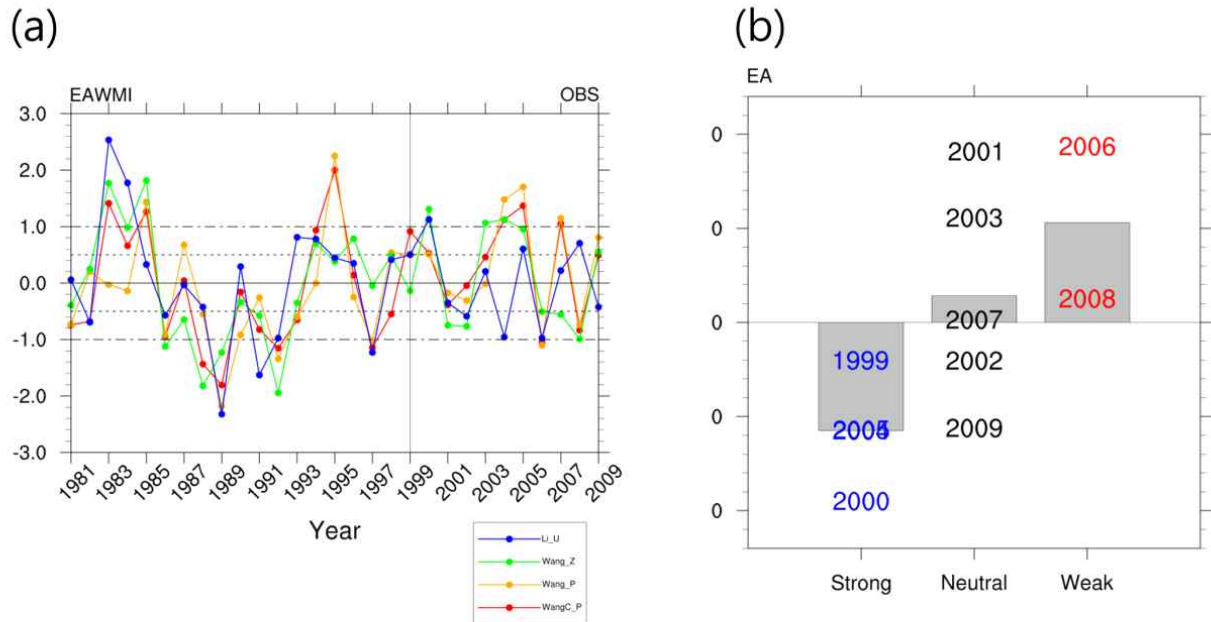


Figure 73. (a) DJF mean EAWM indices for the period 1981-2010. Two dotted lines indicate ± 0.5 std dev, dash-dot lines indicate ± 1.0 std dev (b) 2m temperature anomalies averaged over East Asia for strong, neutral, weak East Asian monsoon years. Bar indicates mean temperature anomalies over East Asia for each category of EAWM.

비록 동아시아 겨울 몬순에도 계절내 변동 성분이 존재하기는 하나 (not shown) 경년변동 성분이 두드러지기 때문에 동아시아 겨울 몬순의 강도가 동아시아 기온의 계절내 예측성능에 미치는 영향이 존재하는지 알아보려고 한다. Figure 74의 좌측그림은 동아시아의 매해 겨울철 (DJF) 평균기온 패턴과 각 해의 주별 (총 12주) 평균기온 패턴의 공간 상관관계를 나타낸 것이다. 상관계수 값이 양으로 클수록 동아시아 영역의 주별 기온 패턴이 계절평균으로부터 크게 벗어나지 않음을 의미한다. Figure 74우측의 점정 막대그래프는 각 해의 주별 공간상관계수의 평균값을 나타낸다. 2000년과 2006년에 특히 상관계수가 0.6에 육박하거나 그 이상의 값을 갖는다. 이와 더불어 주황색과 빨강색 막대그래프는 각각 3, 4주 선행 시점에 MME에 의해 예측된 동아시아 기온 분포와 관측 기온과의 공간상관계수를 나타낸 것이다. 앞서 보였듯이, 3, 4주 예측 선행시점에서의 MME 예측과 관측기온과의 공간상관계수는 매우 낮다. 하지만 2000년과 2006년은 다른 해에 비해 3주 예측 선행시점에서 관측과의 공간 상관계수 값이 높은 것을 확인할 수 있다. 2000년과 2006년은 가장 강했던 몬순과 가장 약했던 몬순 해로 각각 분류되었다 (Figure 73(b)). 현재 계절내 예측 자료의 가용한 과거 재현자료의 기간이 짧은 관계로 몬순의 강도가 강할수록 계절내 예측의 예측 성능이 나아지는지에 대한 보다 일반적인 결론을 도출하는데 무리가 있으나, 추후 보다 더 심도 깊은 상세한 연구가 수행될 필요가 있다.

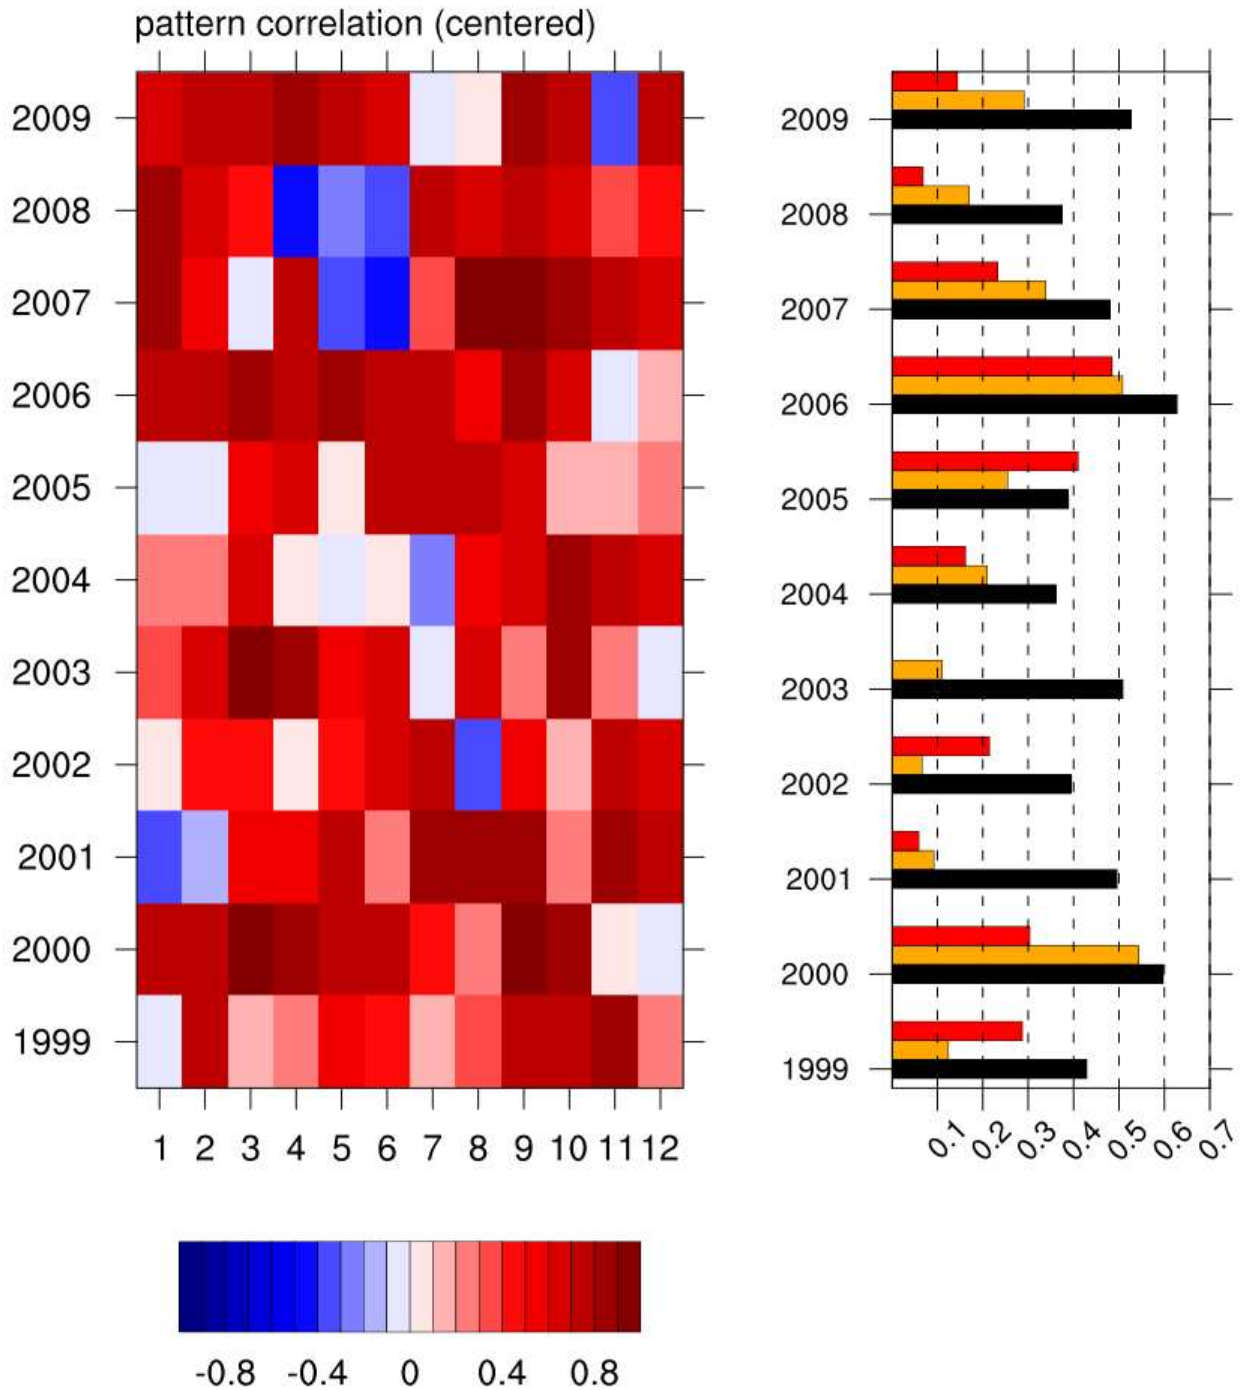


Figure 74. (Left) Pattern correlation between the seasonal mean and weekly mean temperature at 2m over East Asia (right) Year mean of pattern correlation (black), pattern correlation between the observed and predicted 2m temperature at lead week 3 (red) and 4 (yellow).

앞서 비교한 네 개의 동아시아 겨울 몬순 지수 중 3-4주 예측선행 시점에도 상대적으로 우수한 예측 성능을 보였던 Li_U 지수의 경우 동아시아 겨울철 상층 제트의 특성을 반영한 지수로서, 지수의 값이 클수록 동아시아 상공의 제트가 강해지는 것을 의미한다. 동아시아 제트는 다양한 시간규모에 걸쳐 동아시아 겨울의 날씨와 기후에 영향을 주는 주요한 현상 중 하나

로 알려져 있다 (Yang et al.,2002). 동아시아 제트의 계절 및 경년 변동 특성에 대한 다양한 연구가 지금까지 활발하게 이루어진 것에 비해 동아시아 제트의 계절내 변동 특성에 대한 연구는 드물다. 본 연구에서는 동아시아 제트의 계절내 변동성과 이와 관련한 MME 예측성에 대해 분석해보고자 한다.

Figure 75는 동아시아 제트의 주별 관측 및 MME 예측 자료의 웨이블릿 파워 스펙트럼을 나타낸다. Figure 75(a)에서 볼 수 있듯이, 동아시아 제트에도 4-8주 사이의 주기를 갖는 계절내 변동 성분이 존재한다. 특히 1999/00, 2005/06, 2009/10에서 유의미한 계절내 성분이 나타난다. 예측장의 경우, 계절내변동 성분이 존재하긴 하나 예측 선행시간이 길어질수록 장주기 성분의 파워가 증가하는 경향을 보인다.

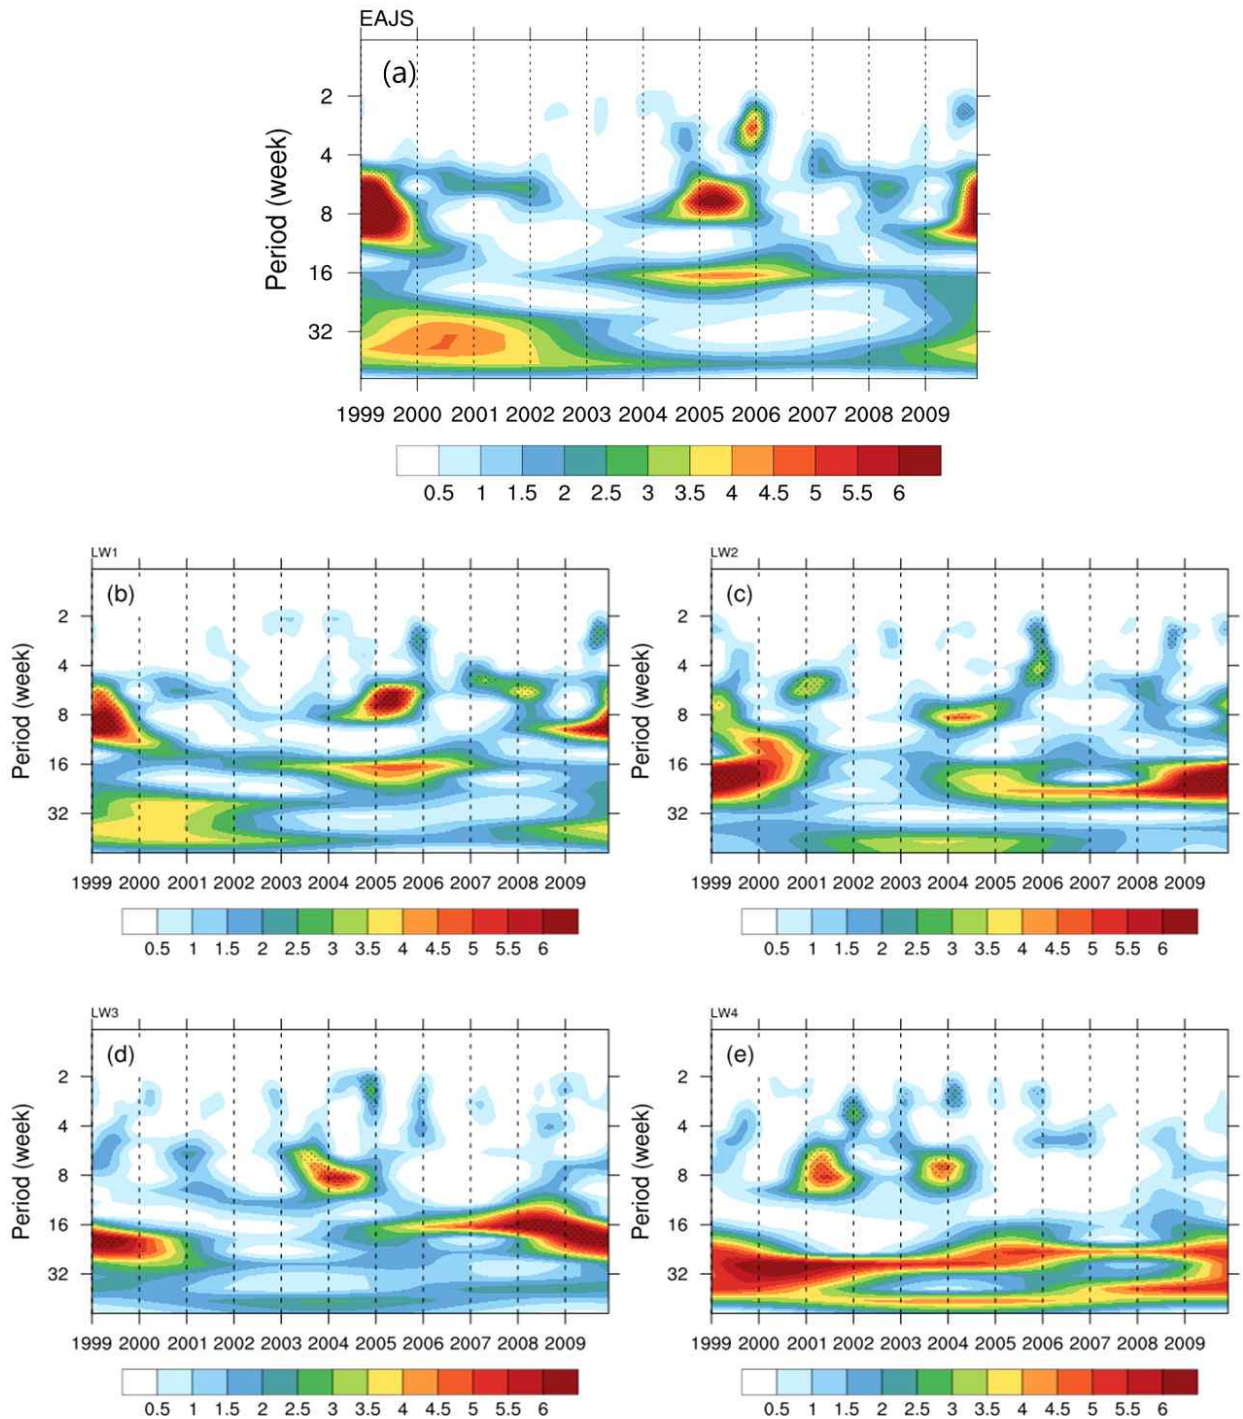


Figure 75. Wavelet power spectrum of (a) the observed and (b-e) MME weekly EAJS (U200 averaged over 27.5° - 37.5° N, 130° - 160° E) for DJF from 1999/2000 to 2009/2010.

Figure 76(a)는 주 별 관측자료에 나타난 동아시아 제트 코어 위치의 위도를 나타낸 것이다. 관측에 따르면 동아시아 제트의 코어는 40° N 보다 북쪽에 위치하거나 30° N 보다 남쪽으로 위치하는 등 코어 위치의 주 별 남북방향 변동이 큰 편이다. 그러나 MME 예측의 경우, 예측 진행시간이 길어질수록 제트코어 위치의 남북방향 변동폭이 눈에 띄게 줄어든다 (Figure 76 (b-e)).

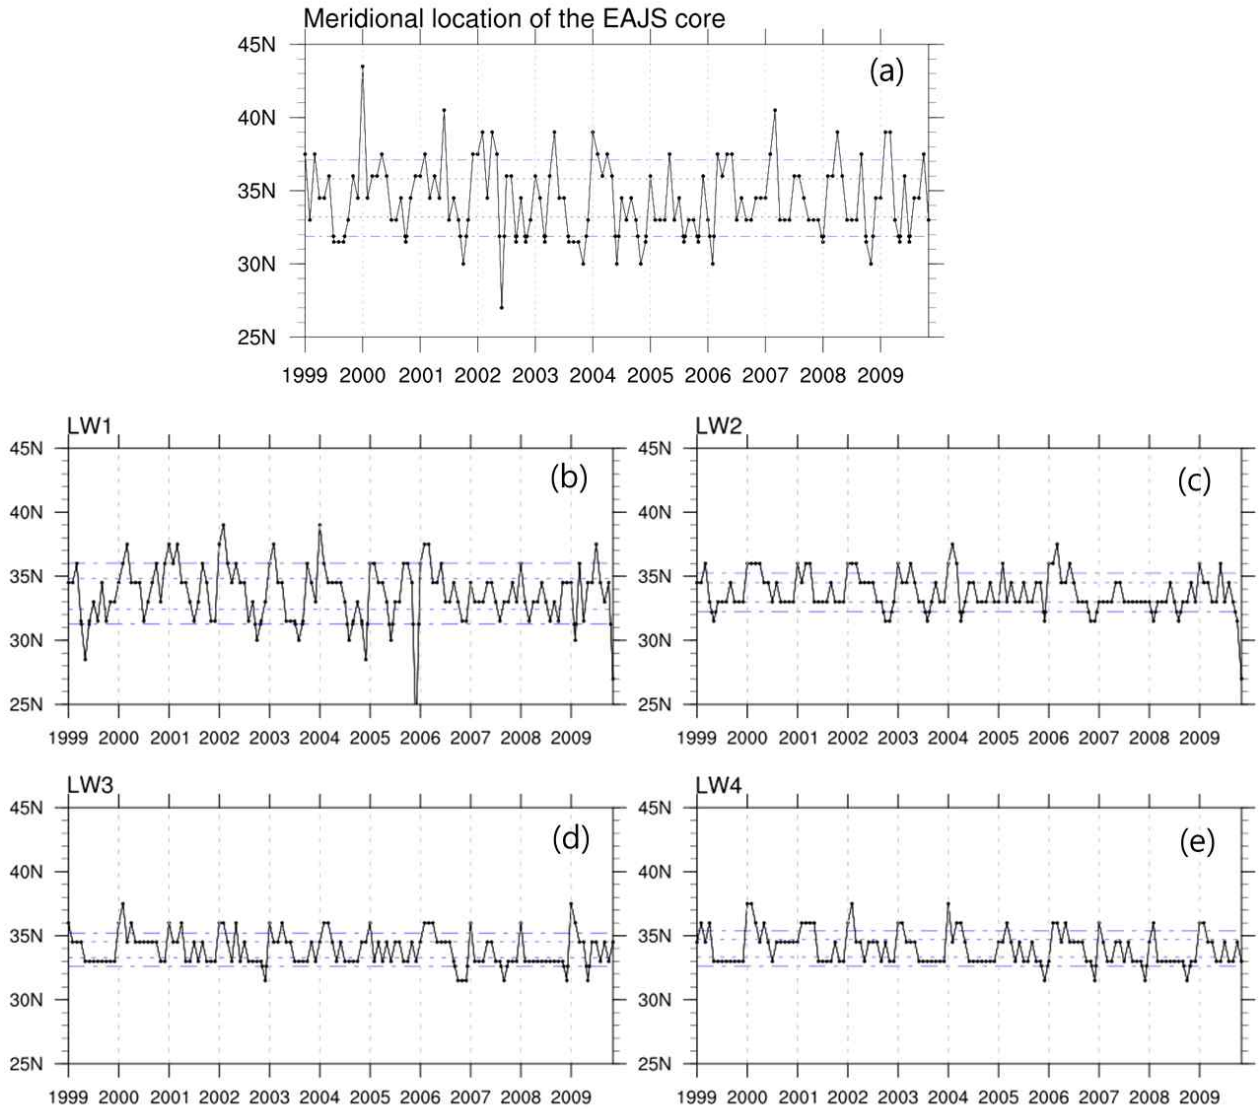


Figure 76. Meridional location of the EAJS core for (a) the observation and (b-e) MME at lead week 1 through 4. Dotted line indicates ± 0.5 standard deviation and dot-dash line indicates ± 1 standard deviation.

관측에서 나타난 동아시아 제트 코어의 겨울철 각 주별 남북방향 위치에 따라 동아시아 제트를 구분하면 Figure 77과 같다. Figure 77(a)의 경우 제트 코어의 위도가 1 표준편차 이상인 주만 택하여 합성한 것이며, Figure 77(c)의 경우는 제트 코어의 위도가 -1 표준편차이하인 주만 택하여 합성한 것이다. 제트 코어의 위도가 $-0.5 \sim 0.5$ 표준편차에 해당할 경우 Figure 77(b)와 같이 나타난다. 코어의 위도가 보통의 경우 34.5°N 인데 반하여, 코어가 북쪽에 위치한 경우 중심 코어의 평균 위도는 37.5°N , 남쪽에 위치한 경우 평균 위도는 31.5°N 이다. 코어의 위도에 상관없이 중심 풍속은 70 m/sec 이상의 값을 보인다. 동아시아 겨울철 동안 제트코어가 북상한 경우, 보통인 경우, 남하한 경우는 각각 26회, 26회, 24회로 비교적 균등한 비율로 나타났다.

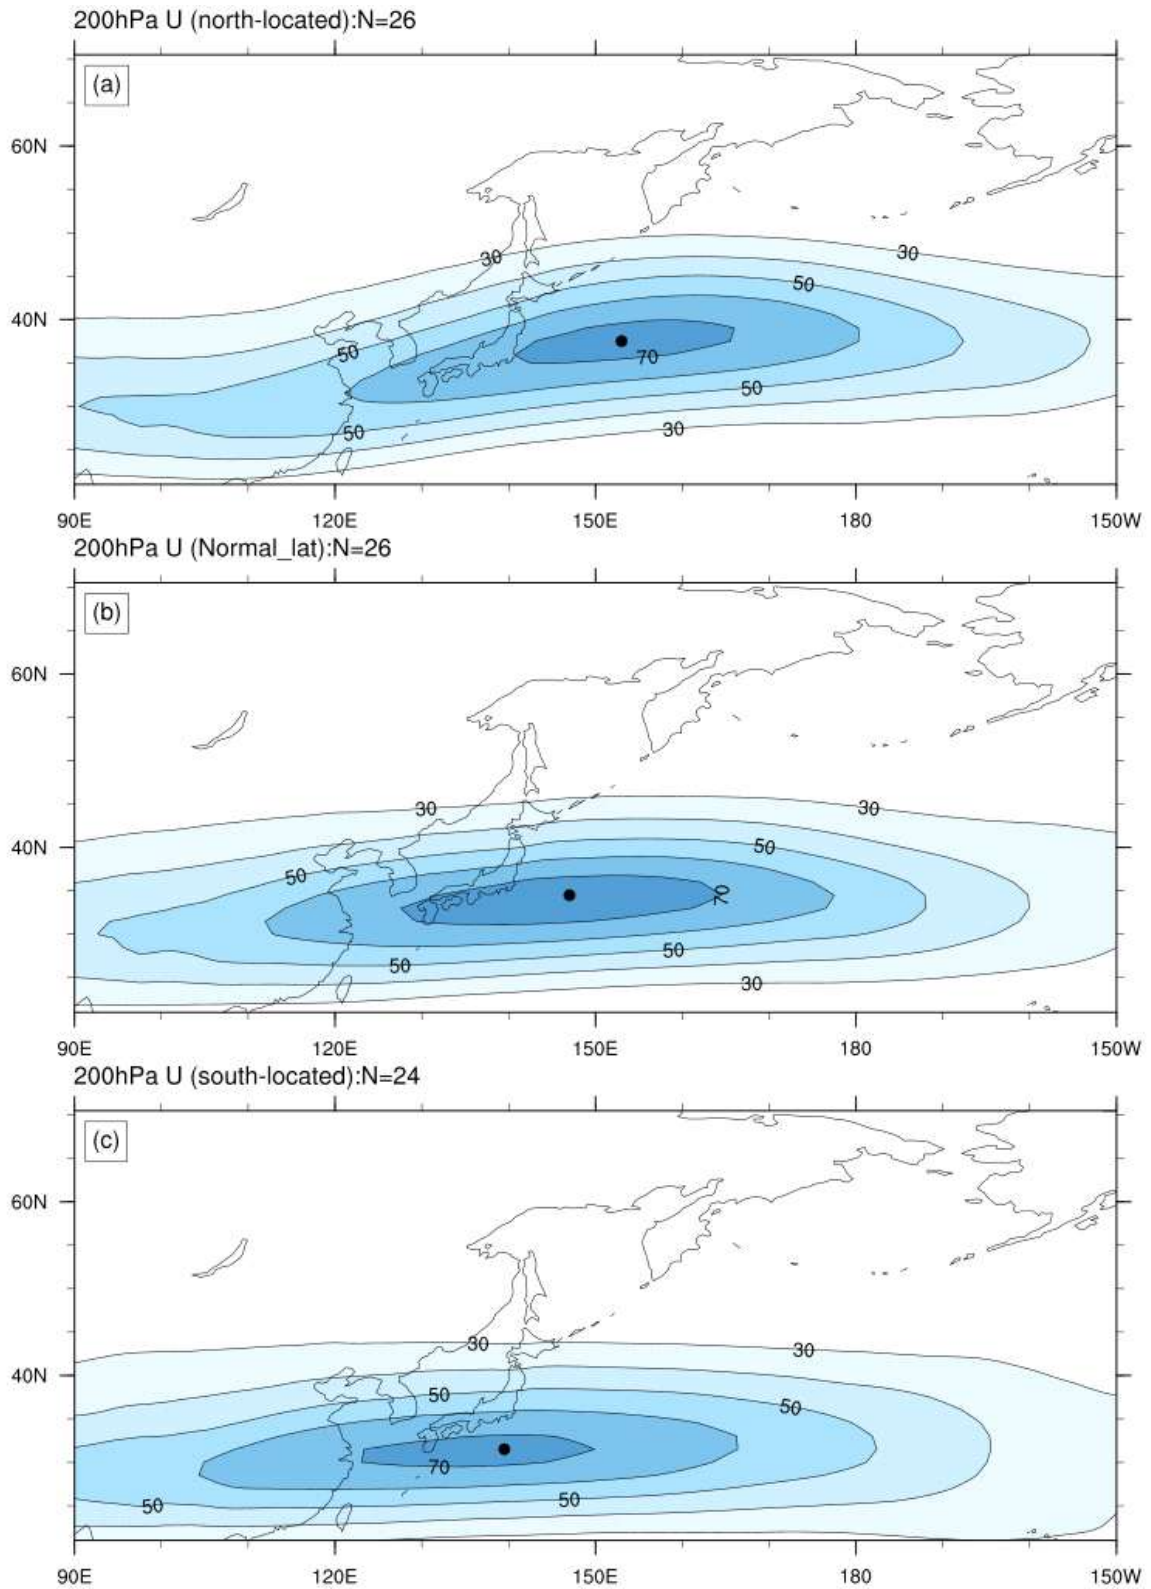


Figure 77. Averaged zonal wind speed and core location (black dot) of the observed EAJS during (a) north-located, (b)normal, and (c) south-located weeks.

동아시아 제트의 위치에 따른 동아시아 겨울철 기온을 알아보기 위해 동아시아 제트가 각각 북상 및 남하 했을 때와 보통의 위치에 있을 때의 동아시아 겨울철 기온의 차이를 살펴보았다 (Figure 78). 동아시아 제트가 북상했을 때는 보통 해 보다 한반도를 비롯한 북중국, 몽골 지역의 양의 기온 편차가 나타나고 (Figure 78(a)) 동아시아 제트가 남하했을 때는 한반도에 음의 기온 편차가 나타난다 (Figure 78(c)). 이때 상층 기압 패턴을 살펴보면 동아시아 제트가 북상했을 때, 한반도는 고기압 중심부에 위치하는 반면 (Figure 78(b)), 동아시아 제트가 남하했을 때는 한반도 북동쪽에 고기압, 북서쪽에 저기압이 위치하면서 북풍이 한반도 쪽으로 유입되기 좋은 환경이 된다(Figure 78(d)).

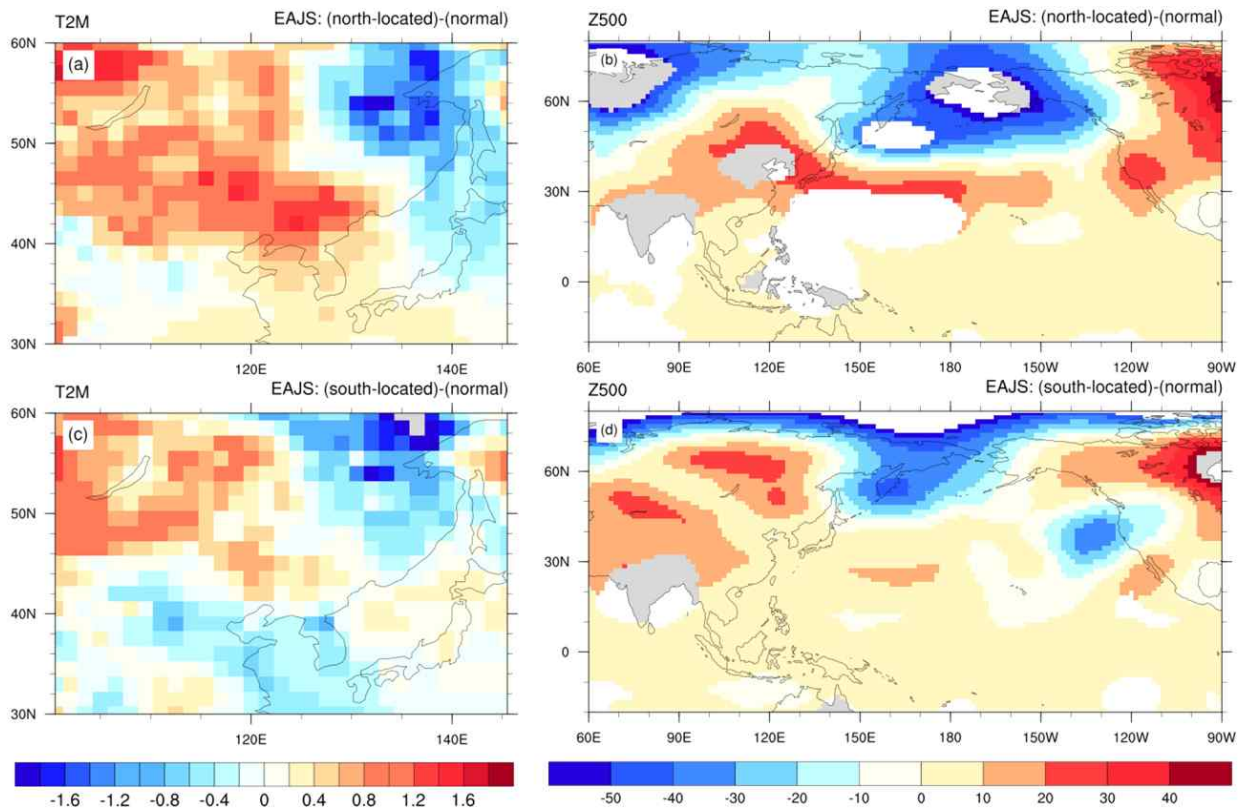


Figure 78. Composite difference of 2m temperature and Z500 between EAJS north-located and normal years (a,b) south-located and normal years (c,d). Values confident at 90% level are plotted.

관측의 경우, 동아시아 제트 코어 남북방향의 위치가 비교적 균등한 횡수로 분포하는데 비해 MME 예측에서는 제트 코어가 남북 방향으로 크게 벗어나 위치하는 경우가 보통해에 비해 적다 (Figure 79(a)). 다만 한가지 흥미로운 점은 제트 코어가 북쪽에 위치하는 경우가 남쪽에 위치하는 경우보다 많은 횡수를 차지하는 경향을 보이는데, 이런 점이 MME 계절내 기온 예측의 오차와 관련이 있을 것으로 추정된다. 관측에서 나타난 제트 코어의 위치에 따라 동아시아 지역 MME 기온 예측과 관측 패턴의 ACC 평균을 비교해 본 결과, 관측에서 제트코어가 북상하였을 때 선행 1주-4주 모두 관측과 MME 기온 예측의 패턴이 다른 두 경우보다 더 비슷한

값을 보이는 것으로 나타났다 (Figure 79(b)). 동아시아 기온이 높을 때 MME 예측성능이 좋아지는 경향을 보이는 것과 관련이 있을 것으로 추측된다.

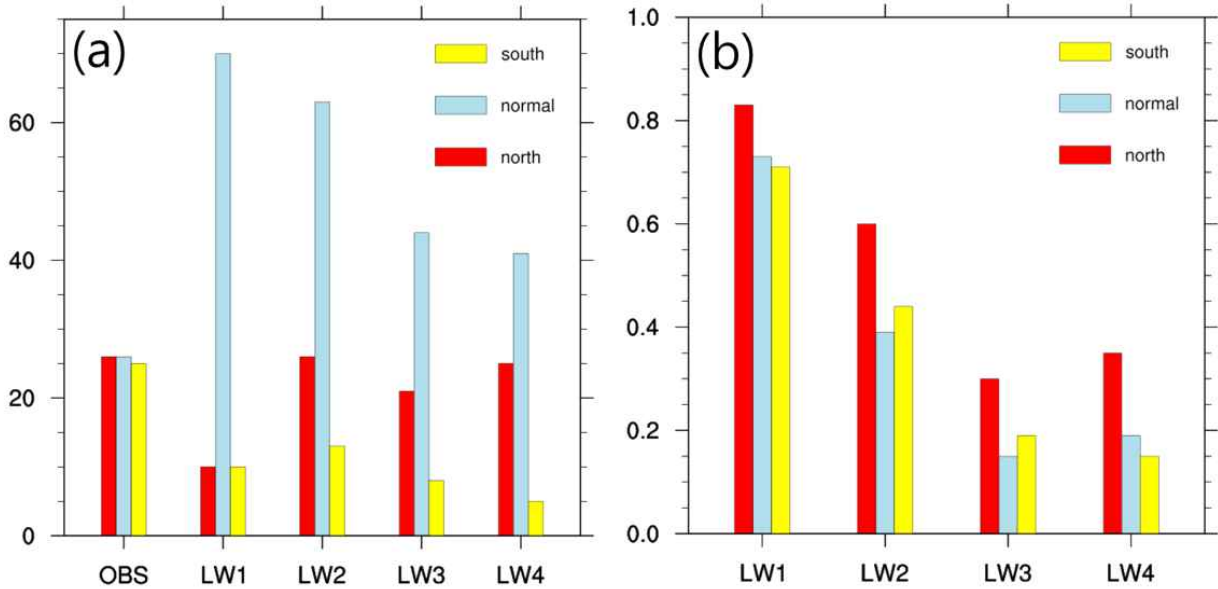


Figure 79. (a) Number of weeks for EAJS north-located (red), normal (blue), and south-located (yellow) in the observation and MME at different lead weeks.(b) ACC at different lead week of T2m over EA averaged for the weeks of north-located (red), normal (blue), and south-located (yellow) EAJS in the observation.

㉔ 극진동

EOF 선도모드에 나타난 극진동 (Arctic Oscillation) 은 북극 지역의 저기압과 그 주변 두 대양 즉, 북태평양과 북대서양에서의 두 고기압 아노말리의 형태를 갖고, 두 고기압의 상대적 크기는 대서양에서 강하다. 극진동 공간 패턴에 대한 관측과 모형간의 객관적 비교를 위해, 각각에서 극진동 지수에 대한 MSLP 회귀장을 구해 보았다 (Figure 80). 선행 1주 회귀장은 관측 회귀장과 공간상관계수 0.98로서 거의 유사하지만, 선행 시간이 증가할수록 회귀장의 절대적 강도도 줄어들고 공간상관계수도 감소한다. 특히 태평양 고기압이 강해지면서 두 대양간의 상대적 크기가 역전되어 나타나는데, 이를 통해 기후 모형내 극진동 모드와 관련된 대양간 에너지 분포가 관측의 그것과 다름을 확인할 수 있다.

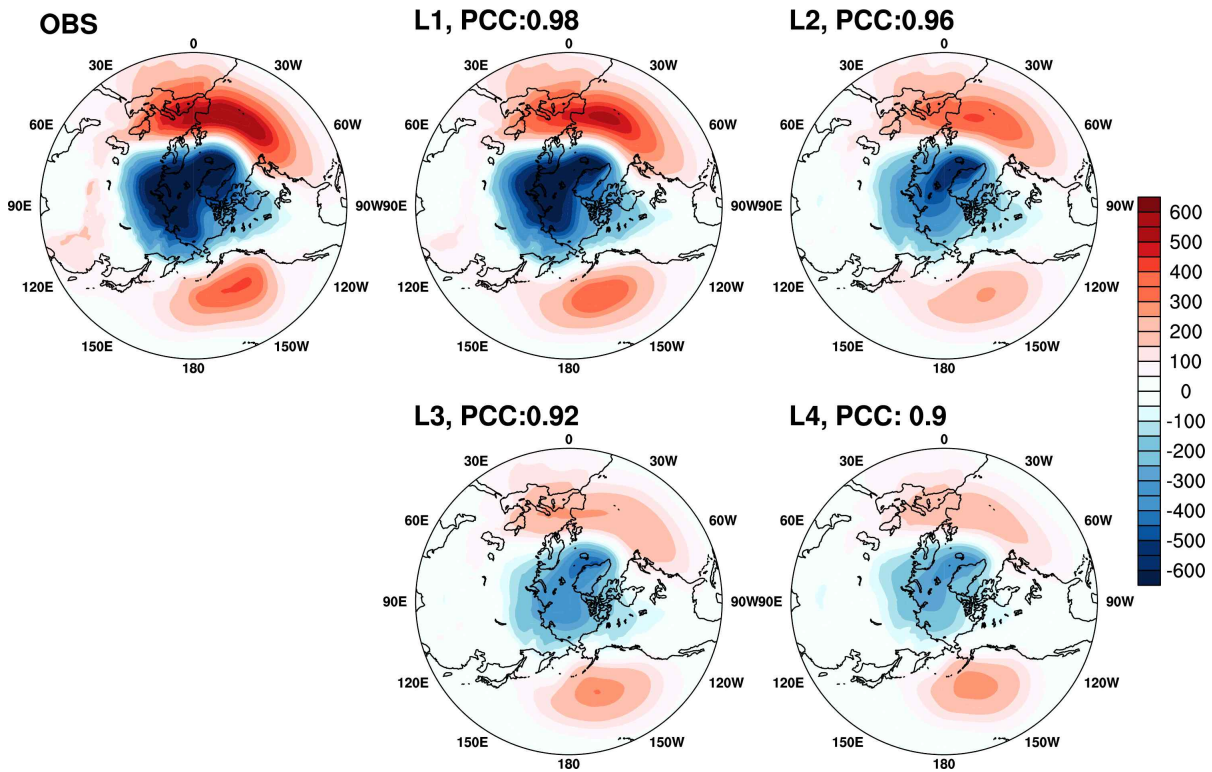


Figure 80. observed and predicted MSLP patterns regressed onto corresponding AO indices. The unit is Pa.

1-4주 선행 시간에 대한 극진동 지수의 예측성을 시간상관계수 (TCC) 와 RMSE 검증값을 이용하여 ECMWF, ECCC, NCEP 세 개별 모형과 그들의 SCM에 대해 비교해 보았다 (Figure 8 1). 예상할 수 있듯이, ECMWF 모형의 극진동 지수 예측 스킬이 다른 두 모형에 비해 높게 나타난다. 다른 두 모형을 비교하면, 비접합 모형인 ECCC의 성능이 선행 1-2주에서는 더 높지만 선행 시간이 증가할수록 급격히 떨어져 오히려 3-4주에서는 NCEP의 성능이 더 높게 나타난다. 3주에서는 세 모형간의 성능차가 매우 미비하고, 4주에서는 ECCC의 성능이 다른 두 모형에 비해 유독 떨어지는 양상을 보인다. SCM MME의 경우, 1-2주에서는 ECMWF 성능과 크게 다르지 않아 효과가 미비하지만, 계절내 규모에서 가장 활용성이 기대되는 3-4주에서는 개별 모형을 크게 상회하는 성능을 보여 그 효과를 확인할 수 있다. 특히 4주차 MME 성능의 3주차 ECMWF 성능을 넘어서 그 효과가 가장 크게 나타난다.




Figure 81. Inter-model comparison: TCC and RMSE skill of predicted AO index for 4 lead weeks.

극진동 지수의 변동폭을 확인하기 위해, 겨울철 매주 각 초기 시작일에 대한 11년 동안의 표준편차와 매해 겨울내 표준편차를 계산해 보았다 (Figure 82). 관측의 경우, 12월 하순에 큰 표준편차를, 앞 뒤로 12월 상순, 1월 상순에 상대적으로 작은 표준편차를 나타낸다. 이러한 표준편차 경향은 선행 1주차에서는 매우 유사하게 나타낸다. 하지만, 선행 주수가 길어질수록 표준편차 경향성도 같은 시간만큼 밀려서 나타나는 경향이 있고, 특히 4주차에서는 관측과 완전히 상이한 변동 경향을 나타낸다. 주평균 극진동 지수의 겨울내 변동폭은 매년 다른데, 2006/07년, 2000/01에는 상대적으로 크고, 2005/06년과 2002/03년 겨울에 작게 나타났다. 선행 1주차의 경우, 이러한 경년성분을 전반적으로 잘 나타내는 것으로 보이나, 선행 2주차 이후에는 관측과 상이한 특성을 나타낸다. 흥미로운 점은 모든 선행 주수에서 일관되게 2002/03년 겨울의 극진동 지수 변동성이 가장 작게 나타난 것이다. 이 해는 엘니뇨로 기록된 해로서, 과거 통계에 따르면 북반구 겨울철에 엘니뇨가 발생하면 동아시아가 전반적으로 따뜻해지는 경향을 보여 왔다. 모형 내에서 대기 현상은 열대 해양 강제력에 의해 대부분 결정되고 다른 중위도/고위도 역학 과정은 제대로 모의되지 않는다. 따라서, 모형은 2002/03년 겨울을 큰 변동 없는 온화한 겨울로 예측했을 것이고, 이와 연관되어 극진동 지수 변동성도 역시 작게 나타난 것으로 예상해 볼 수 있다.




Figure 82. Standard deviation of AO indices for (a) 11 years at every week and (b) 12 weeks every year.

㉔ 대기 변동 모드들 관련성에 대한 재현성 평가

앞서, 동아시아 겨울 기온 변동 모드, 그리고 이와 관련된 다양한 기후 모드들의 시간 변동 특성 및 예측성을 파악해 보았다. 각 변동 지수들 간의 관련성 및 그 재현성에 관한 분석은 모형 예측 후보정의 인자 선정 및 활용 가이드라인 개발을 위한 기초 정보로 활용될 수 있기에 그 의미가 크다고 할 수 있다. 동아시아 지역 평균 기온 아노말리, 2개의 동아시아 겨울 기온 변동 모드, 동아시아 겨울 몬순, 시베리아 고기압, 극진동 현상이 서로 얼마나 연관되어 있는지, 다른 말로 얼마나 독립적인지를 확인하기 위해 각 지수들의 시간상관계수를 계산해 보았다 (Figure 83). 첫 번째 기온 변동 모드는 (극성을 음수로 정의했기 때문에) 동아시아 지역 평균 기온 아노말리아와 거의 반대로 움직이는 것을 확인할 수 있다. 동아시아 평균 기온 아노말리는 시베리아 고기압 지수, 그리고 동아시아 몬순 지수 특히 WangC_P와 매우 유의한 음의 상관성을 보인다. 그리고 앞서 회귀장 분석에서 제시했듯이, 첫 번째 기온 변동 모드는 극진동 지수와 유의한 음의 상관성을, 두 번째 기온 변동 모드는 3개의 동아시아 겨울 몬순 지수와 통계적으로 유의한 양의 상관성을 보인다. 관측에서의 기후 변동간의 상관성 (대각선 아래) 은 SCM 예측 (대각선 위) 에서 일부는 적절히 재현되고 있는 것으로 보이나, 그렇지 않은 부분도 많다. 몬순 지수들간의 뚜렷한 상관성은 선행 시간에 관계없이 제대로 나타나지만, 동아시아 지역 평균 기온 아노말리와 동아시아 몬순 지수, 시베리아 고기압 지수와의 상관성은 더 이상 유의하지 않다. 동아시아 지역 평균 기온 아노말리와 두 번째 기온 변동모드와의 상관성은 관측에서는 유의하지 않지만 2-4주 선행 예측에서는 유의하게 나타난다. 하지만, 첫 번째 기온 변동모드와 극진동 지수와의 관련성은 관측 모형 둘 다에서 유의하게 나타남을 확인할 수 있다.

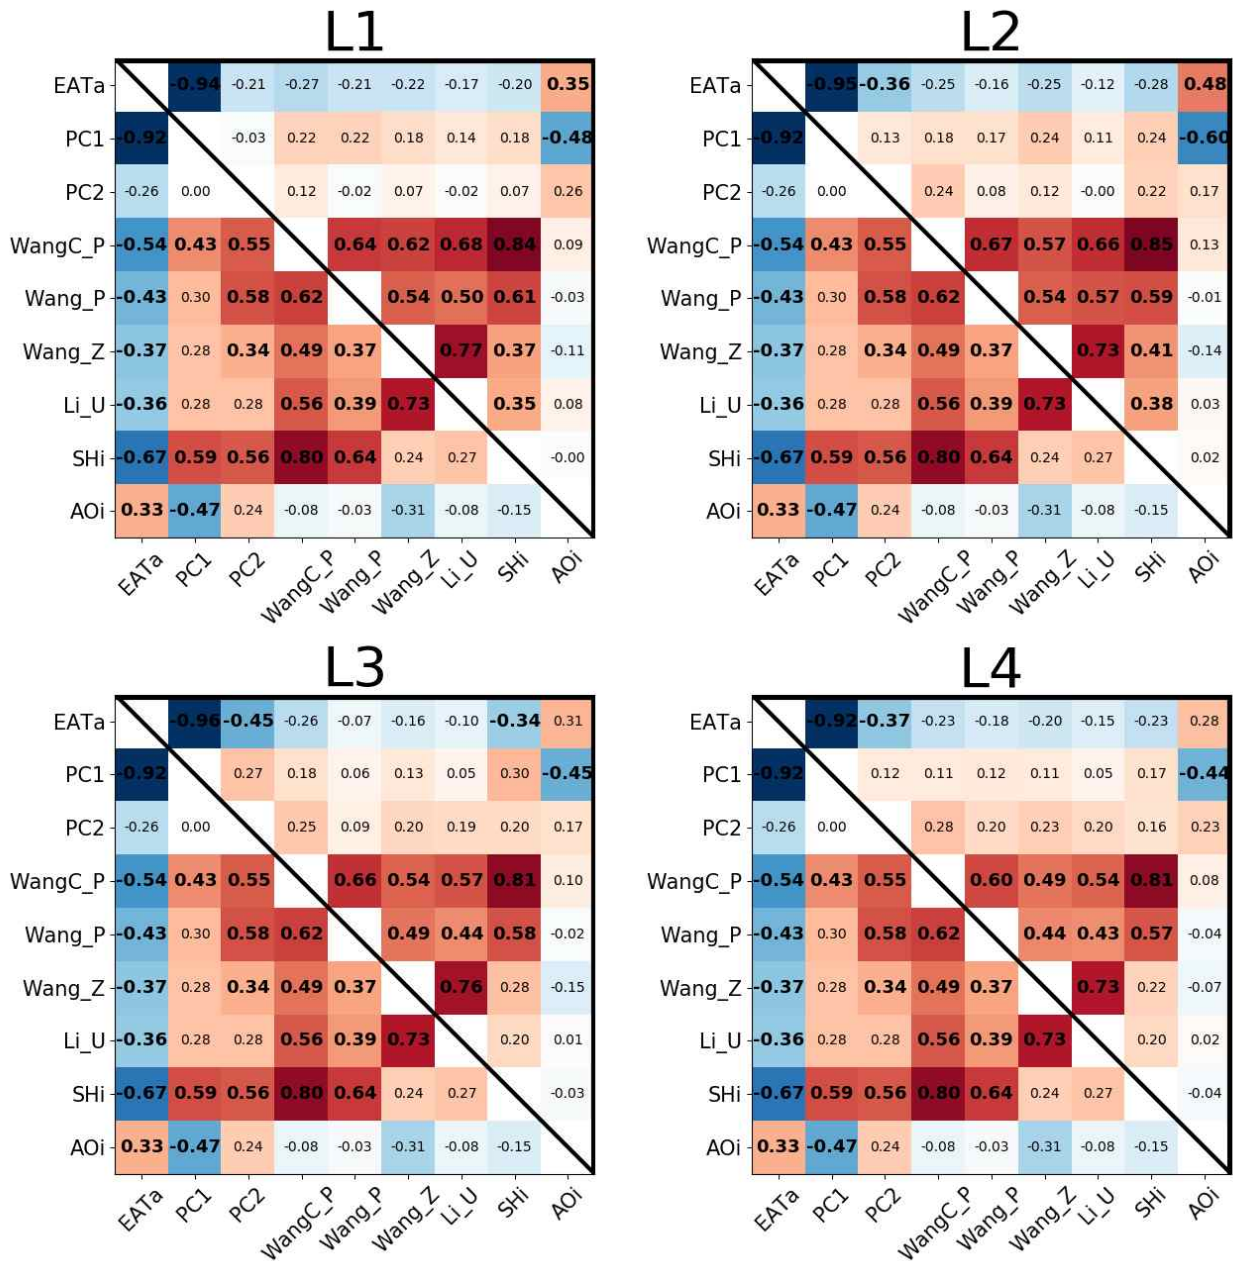


Figure 83. Correlation coefficients among 8 indices, those are T2M anomaly average over EA, PC time series of two EOF modes of T2M anomalies over EA, four EAWM indices, and AO index, for (bottomleft) the observation and (topright) the model.

(나) 회귀장 치환을 활용한 동아시아 겨울 3주차 기온 예측 보정

앞서 언급한대로, 계절내 규모 모형에서 동아시아 겨울 기온장의 예측성은 상당히 낮다. 특히 단기 예보 기간보다 조금 길고 응용분야 예측 정보로서의 수요가 큰 선행 3주차부터 그 예보 성능이 급격하게 떨어진다. 이를 극복하기 위한 방안으로, 본 과제에서는 지역에 특화된 통계적 후보정 기법을 검토하였고 그 실효성에 대한 평가를 수행하였다. 앞서 동아시아 기온장 변동 모드 뿐만 아니라 그와 관련된 다양한 기후 모드들에 대한 다양한 분석을 수행하였고, 과거 관측 그리고 과거 모형에서 유의미한 통계적 관련성을 파악하였다. 이를 바탕으로 Table 8

의 네 가지 보정 기법을 적용해 그 성능을 확인하였다. 앞서, 동아시아 변동 모드의 지수 예측성 평가에서 고차원 모드일수록 예측성이 떨어짐을 언급한 바 있다. 이러한 결과를 바탕으로 모형에서 고차원 모드들을 제거할 때 오히려 관측과의 오차가 감소할 수도 있겠다는 추정을 할 수 있었고, 이것이 첫 번째 EOF 기반의 후 보정 기법이다. 두 번째 (REG_EATa) 는 동아시아 지역 평균 기온과 관련된 모형 회귀장을 관측에 해당하는 값으로 치환하여 기온장을 재구성하는 방법이다. 세 번째 (REG_EOF) 는 첫 번째 방법을 좀 더 발전시킨 것으로 각 EOF 모드 지수에 대한 모형 회귀장을 관측 회귀장으로 치환하여 기온장을 재구성하는 방법이다. 네 번째 (REG_EOF+REG_EATa) 는 세 번째 방법에 두 번째 방법을 통합시킨 것으로 각각의 변동 모드들 뿐만 아니라 전체 지역 평균에 대한 모형 회귀장을 순차적으로 치환하여 기온장을 재구성하는 방법이다. 자세한 과정은 아래 표에 적시하였다.

Table 8. Four ways to reconstruct model's T2M anomaly field over EA for 3 weeks lead time.

Method	Formula	Description
EOF	for t=j, $\sum_{i=1}^{32} \text{EOF}_i * \text{PC}_i$	T2M anomaly field reconstruction is based on only first 32 EOFs without higher (from 33) EOFs.
REG_EATa	for t=j, $\text{Model T2Ma} - \left(\frac{\text{Model T2Ma}}{\text{EATa}} * \text{EATa} \right) + \left(\frac{\text{Observed T2MOa}}{\text{EATa}} * \text{EATa} \right)$	From model T2M anomaly (T2Ma) field, subtracting the projected field onto T2Ma regression with respect to model's East Asia averaged temperature anomalies (EATa) then adding the projected field onto observed T2M anomaly (T2MOa) regression with respect to EATa
REG_EOF	for t=j, $\text{Model T2Ma} - \sum_{i=1}^{34} \left(\frac{\text{Model T2Ma}}{\text{PC}_i} * \text{PC}_i \right) + \sum_{i=1}^{34} \left(\frac{\text{Observed T2MOa}}{\text{PC}_i} * \text{PC}_i \right)$	From model T2Ma field, subtracting the projected field onto T2Ma regression with respect to PC then adding the projected field onto T2MOa regression with respect to PC sequentially for each of first 34 EOFs.
REG_EOF + REG_EATa	for t=j, $\text{Model T2Ma} - \sum_{i=1}^{34} \left(\frac{\text{Model T2Ma}}{\text{PC}_i} * \text{PC}_i \right) + \sum_{i=1}^{34} \left(\frac{\text{Observed T2MOa}}{\text{PC}_i} * \text{PC}_i \right) - \left(\frac{\text{Model T2Ma}}{\text{EATa}} * \text{EATa} \right) + \left(\frac{\text{Observed T2MOa}}{\text{EATa}} * \text{EATa} \right)$	The procedure of REG_EOF is followed by the procedure of REG_EATa.

각각의 후보정 기법을 hindcast 자료에 적용하였을 때, 기존 동아시아 주평균 기온 SCM MME 대비 성능이 얼마만큼 개선되었는지를 ACC 값으로 확인하였다 (Figure 84). 이 때, 성능 과대평가를 방지하기 위하여, 모든 방법에 대해 leave-one-out test를 적용해 분리된 자료로부터 얻어진 결과들을 평가하였다. 기존의 SCM MME 성능은 ACC 0.25 정도로 대략 관측의 6-7%만을 설명하고 있다. 네 가지 후보정 기법을 적용했을 때, 기존 대 2.9, 6.5, 16.2, 그리고 19.4%의 개선율을 보여서 마지막 방법, 즉 개별 EOF에 대한 회귀장과 전체 동아시아 평균 기온에 대한 회귀장을 모두 치환하여 재구성하는 방법 (REG_EOF+REG_EATa)의 성능이 가장 많이 개선되었음을 확인할 수 있다. 19.4%라는 숫자가 매우 커 보이지만, 안타깝게도 실제 절대값에서 ACC 0.3, 즉 관측 변동성의 10%만을 재현하고 있음을 의미한다. 그럼에도 불구하고, 동아시아 기온에 대해 매우 나쁜 성능을 보이는 역학 예측 모형을 보조하기 위한 수단으로서 본 과제 결과의 가능성을 확인할 수 있었다.




Figure 84. ACC of (white bar) original and (colored bars) four different ways reconstructed T2M over EA for 3 weeks lead time. One-leave-out cross-validation is applied.

최대 개선을 보이는 REG_EOF+REG_EATa 방법을 적용한 132개의 각 예측장에 대해서 기존 성능과 후보정 이후 성능의 히스토그램을 그려보았다 (Figure 85). 푸른 계열이 후보정 이후

의 성능 분포로서 노란 계열의 기존 성능 분포에 비해 오른쪽으로 다소 치우치게 나타나, 전반적으로 성능 개선이 이루어졌음을 확인할 수 있다. 특히 -0.7, -0.2, 그리고 0.3 주변 구간의 도수가 감소하는 대신, 0.7 주변 구간의 도수가 확실히 증가하였다. 하지만, 모든 경우에 대해, 이러한 통계 후보정 방법이 성능을 개선시키는 것은 아니기에, 일부 구간에서는 도수가 감소하는 것으로 나타나기도 한다.




Figure 85. EA T2M ACC distribution of 132 samples (12 weeks for 11 winter seasons) for (light yellow) original MME and (light green) reconstructed by REG_EOF+REG_EATa.

Figure 86은 실제로 REG_EOF+REG_EATa 후보정 기법을 적용하여 관측과 유사한 기온장을 얻은 사례이다. 2002년 1월 16-22일 동아시아 주평균 기온은 시베리아와 중국 동부 그리고 한반도까지 온화한데 반해 극동 러시아 일부와 일본 북부 지역에서 추운 분포를 보였다 (Figure 86a). 하지만, 안타깝게도 기후 모형은 선행 3주 때 이 시점의 동아시아 지역 전반에서 기온이 평년보다 낮을 것을 예보하였다 (Figure 86b). 실제로 기후 모형은 좁은 영역에서 소규모로 나타나는 기온 급상승/하강의 패턴을 제대로 모의하지 못하는 것이 잘 알려져 있다. 이 경우에 후보정 기법을 적용하면, 시베리아에서부터 장출하는 온난한 기류와 동쪽 해양의 차가운 기류의 대비 패턴을 제대로 나타낸다 (Figure 86c). 이는, 개발된 기법에 대한 안정화와 최적화가 이루어진다면, 대규모 순환장에 대한 과거 통계적 관련성을 활용한 예측장 수정 방법이 향후 역학 예보 개선에 적용될 수 있음을 시사한다.

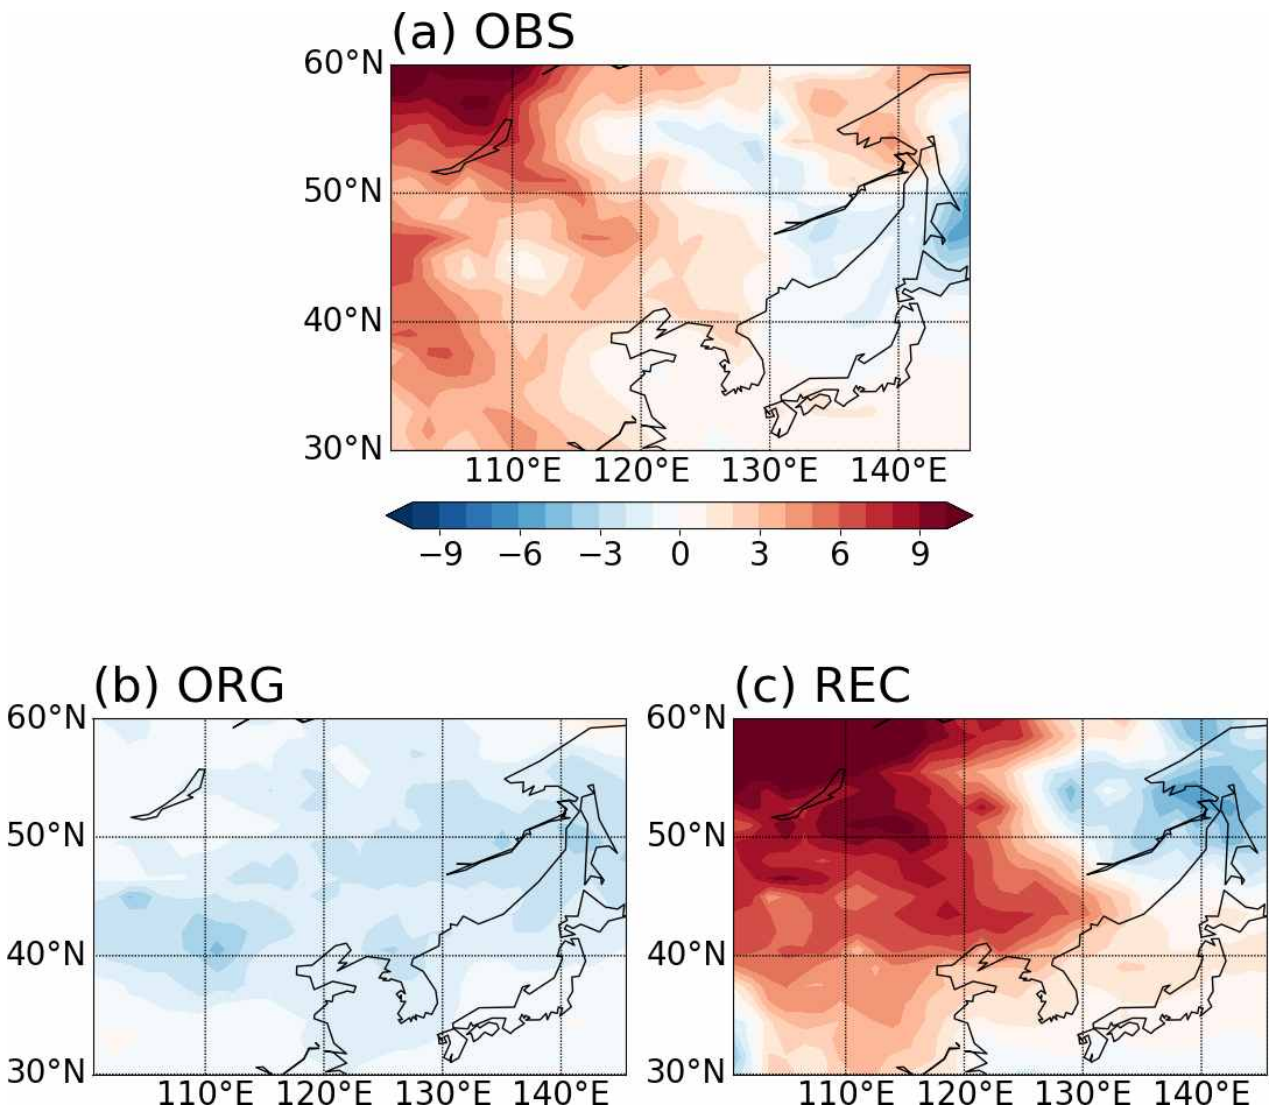


Figure 86. T2M anomalies of (a) observation (b) original MME and (c) reconstruction from REG_EOF+REG_EATa for Jan 16-22, 2002.

다. 계절내 예측 정보 활용 가이드라인 개발

(1) 겨울철 동아시아 주평균 기온 예측 성능 추정 가이드라인 개발

기후 예측 서비스는 미래의 대기 상태뿐만 아니라 그 불확실성에 대한 정보 역시 제공함으로써 예측 정보에 대한 사용자의 의사 결정을 돕는 역할을 수행할 것이 기대한다. 현재 대부분의 현업 기관 및 기후 센터들의 예보는 과거 재현 자료의 성능 검증표나 혹은 최근 예측 성능 평균값을 그 근거로 제시하고 있다. 하지만, 과거 재현 성능이나 최근 성능의 평균은 해당 예측 시스템의 전반적인 성능을 나타내는 값으로서 매 실시간 예측에 대한 성능의 범위를 좁혀주지는 못한다. 계절내 예측, 특히 동아시아 겨울 기온 주평균 3주차 예측의 경우 앞서 언급했듯이 예측성이 매우 낮고 그 범위도 넓다. 따라서 매 주 예보를 내보내는 시점에 그 성능의 추정치도 함께 제공할 수 있다면, 사용자들의 사용성이 좀 더 높아질 수 있겠다. 앞서 동아시아

아 겨울 기온 주별 변동과 관련된 다양한 기후 모드들을 예측 특성 및 그 성능을 파악하였고, 이러한 정보를 좀 더 가공하여 실시간 예측 성능 추정을 위한 아래 세 가지의 조건들을 도출할 수 있었다.

(가) 동아시아 겨울 기온 예측력의 지속 특성

계절내 모형의 성능은 일반적으로 선행 1주에서 매우 높고, 선행 시간이 길어짐에 따라 급격히 감소하고 그 폭이 커지는 특징이 있다. 또한, 매 주 예측 자료 평가 경험에서 초기 예측 성능이 긴 선행시간에도 일정 정도 유지되는 특성을 확인할 수 있었다. 단기 예보 기간보다 조금 길면서 활용성 측면에서 수요가 높은 예보 3-4주차의 성능이 초기 선행 1주차 성능을 따르는지 여부를 파악하고자 각 예보들을 선행 1주 성능을 기준으로 Above Normal (AN), Near Normal (NN), Below Normal (BN)의 삼분위로 구분하고, 각 카테고리 예보들의 매 선행 주수 성능을 박스-휘스커 그래프로 분석해 보았다 (Figure 87). 선행 1주의 경우 정의에 따라 완벽히 3분위로 나뉘고, 대부분의 예보들이 높은 성능을 보여 AN과 NN의 범위가 매우 좁고 BN 영역이 매우 넓게 나타난다 (Figure 87a). 이러한 분포 특성은 선행 2주차에도 유사하게 이어진다 (Figure 87b). 하지만 선행 3주의 경우 세 카테고리의 성능 평균이 유사해지고 AN, NN의 범위가 BN 범위보다 크게 나타나는 등 1주차 성능 구분 양상을 완전히 잃어버린다 (Figure 87c). 하지만, 선행 4주의 경우는 평균값, 최빈값이 BN, NN, AN 순으로 높아져서 일정 정도 초기 1주차 성능을 따라가는 양상을 보였다 (Figure 87d). 이는 예보 선행 4주차 성능을 가늠하는 데 있어 선행 1주 성능 정보를 활용할 수 있음을 의미한다. 하지만, 선행 1주 성능 검증률 얻기 위해서는 1주라는 시간이 필요하며, 실제 성능 추정은 앞으로 3주 이후에 대해서만 가능하다. 따라서 1주 이전 예측의 4주 선행 예측과 실시간 3주 선행 예측 정보를 합산하여 최종 3주차 예측정보를 결정하는데 있어 전자의 가중치를 결정하는 기준으로 활용할 수 있을 것이다 (부록 E 참조).

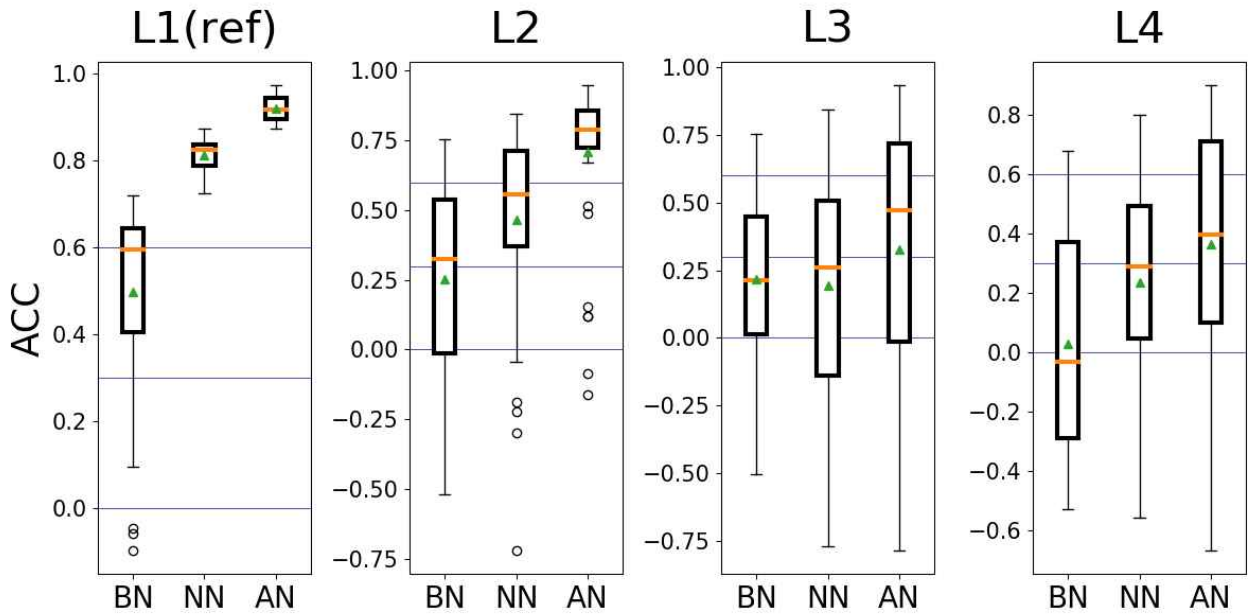


Figure 87. Box-whisker of ACC for BN, NN and AN groups at different 4 lead weeks. The three categories are based on lower (33.3%) and upper (66.6%) terciles of ACC at lead week 1. Green triangles indicates the mean of ACC.

(나) 기후 모드의 위상에 대한 예측 성능의 의존성

모형 예측성이 기후 모드 위상에 대해 의존성이 있음이 잘 알려져 있다. 계절 예측의 경우, 해양 강제력이 강할 때 즉 엘니뇨나 라니냐 위상일 때 성능이 중립 해양 상태일 때 보다 훨씬 높은 것이 잘 알려져 있다. 계절내 규모에서도 열대 매년-줄리안 진동의 위상에 따른 예측성능 의존성에 대한 연구들이 이루어져 왔다 (Baggett et al. 2017; DelSole et al. 2017; Li and Robertson 2015; Rodney et al. 2013). 동아시아 겨울 기온도 다양한 기후 모드와 역학적으로 관련되어 있기 때문에, 특정 기후 모드 위상에 따라 그 성능이 뚜렷이 월등한 조건이 존재할 것이다. 이런 조건들을 파악함으로써 실시간 예측 성능을 좀 더 구체적으로 추정할 수 있고, 따라서 계절내 예보 서비스를 한층 개선시킬 수 있을 것이다.

앞서 살펴본 9개 기후 지수들 (동아시아 평균 기온, 기온 변동모드 1&2, 4개의 동아시아 겨울몬순 지수, 극진동 지수, 시베리아 고기압 지수)을 각각 삼분위로 구분하고, 두 개 지수 교차 조건에 따른 9개 카테고리에서의 예측 성능 평균을 확인해 보았다. 모든 36개 지수 조합들 (부록 E) 중에서, 9개 카테고리 내에서 샘플 개수가 충분하면서 평균 성능차가 뚜렷한 카테고리가 존재하는 조합만을 Figure 88에 나타내었다. 선행 3주의 경우, 동아시아 평균 기온 - 기온 변동모드 1, 기온 변동모드 1 - Li_U 동아시아 겨울 몬순지수, Li_U 동아시아 겨울 몬순지수 - 기온 변동모드 2, 기온 변동모드 2 - 시베리아 고기압, Li_U와 WangC_P 동아시아 겨울 몬순지수간의 교차 조건에서 유의미한 예측성 구분이 이루어졌다. 선행 4주의 경우에는, Wang_Z 동아시아 겨울 몬순지수 - 기온 변동모드2, 기온 변동모드 2 - 시베리아 고기압, Wang-Z 동아시아 겨울 몬순지수 - 극진동 교차 조건에서 유의미한 예측성 구분이 이루어졌다. 이 파트는 실시간 예측성 추정을 위한 MOS (model output statistics) 관점으로 접근하였기 때문

에, 조건 구분을 위해 사용된 지수들은 모두 예측장에서 얻어진 지수들이다. 예측장 안에서의 역학관계가 관측과 정확히 같지 않을 것이므로, 관측 지수 조건을 적용한다면 상이한 결과를 얻을 수도 있을 것이다. 부록 E에서 확인할 수 있듯이, 예보장에서 얻은 기후 지수 교차 조건에 따라 순차적으로 삼분위로 성능을 추정을 하고 그것들을 합산하여 최종 성능의 삼분위 확률을 추정할 수 있다.

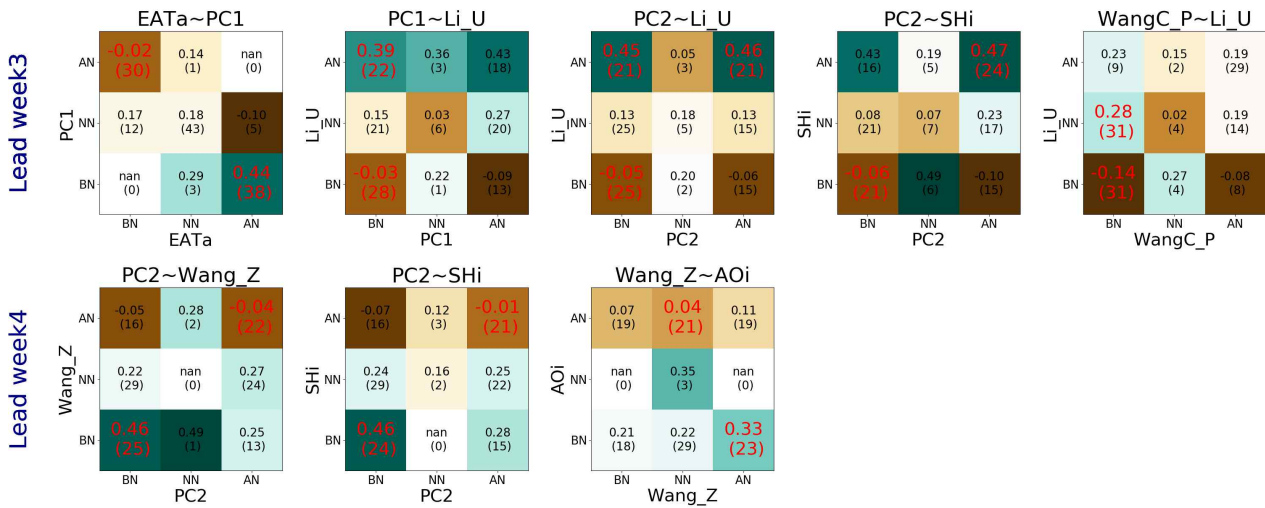


Figure 88. mean ACC of 9 categories based on two different indices' tercile criteria for lead week (top) 3 and (bottom) 4. For the tercile categorization, anomaly of each index is calculated then it is normalized by its standard deviation. Upper and lower tercile is -0.43 and 0.43 sigma, respectively. ACC average value and sample size within parenthesis are displayed in each box. Red color denotes the category of distinguished large or small ACC value with the sample size 20 and over.

(다) 예측 안정도에 대한 성능 민감도

계절내 예측 현업 운영자의 경험에 따르면 선행 시간 안에서 예보의 안정도가 클수록, 전체적인 성능이 높고, 안정도가 작을수록 전체 성능이 떨어지는 경향이 있다고 한다. 예를 들어, 전체 기간 안에서 기온의 등락이 거의 없이 안정된 상태로 예측된 경우에 전반적인 성능이 높았고, 반대로 기온의 등락이 심하게 예측된 경우는 전반적인 성능이 낮다는 의미이다. 이는 극한 기온 현상에 대한 단주기의 소규모 현상을 제대로 모의하지 못하는 모형의 한계 때문으로 예상할 수 있겠다. 따라서 예보 기간 내 안정도를 파악하고 그에 따른 예측 성능의 의존도를 확인할 필요가 있다. Figure 89는 4주 주평균 동아시아 겨울 기온 변동모드 1의 안정도와 선행 3주 동아시아 겨울 기온 ACC 사이의 산포도와 안정도의 3분위 기준에 따른 성능의 박스-휘스커 그래프이다. 여기서 안정도는 (표준 편차/평균)의 역으로 정의하였다. 산포도에서 안정도가 클 경우는 성능이 낮은 경우가 거의 없고, 시간상관계수도 통계적으로 유의한 0.47 정도 값을 보인다. 박스-휘스커 그래프에서 성능 분포를 확인하면 평균과 최빈값이 AN에서 뚜렷하게 높고 범위도 좁아 불확실성이 줄어든 것을 알 수 있다. 이러한 안정도 조건 역시 실사가 예보 성능 추정에 활용할 수 있을 것이다.

L3 skill ~ PC1 stability

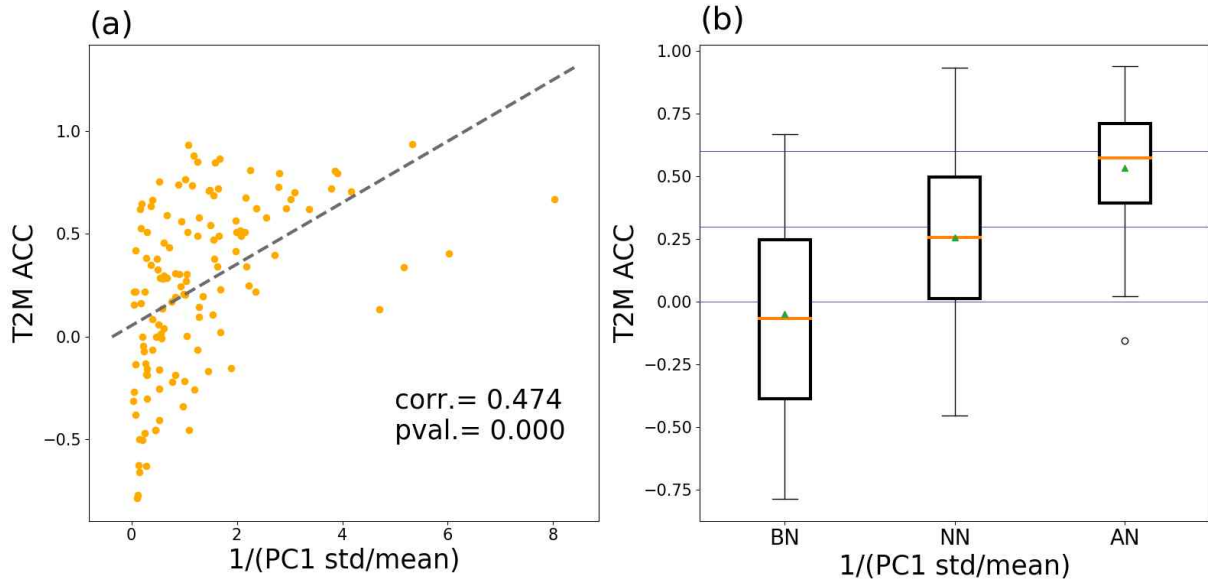


Figure 89. (a) scatter plot and (b) box-whisker plot between simulated PC1 persistency and EA T2M skill for lead time of 3 weeks from 132 samples (12 weeks for 11 winter seasons). X-axis displays an inverse of PC1 standard deviation for 4 lead weeks divided by their mean. Least square fitted line in (a) is delineated (gray dash).

(2) 다중모델 기반 BSISO 영향분석 기술 개발

(가) BSISO 영향장 산출 기법 간 비교 분석

이 연구에서는 BSISO 영향장을 추정할 수 있는 세 가지 통계적 선형 기법(합성장 분석, 회귀 분석, EOF 분석 기반 기법)을 개발하였고 기법에 대한 자세한 내용은 2장에서 소개하였다. 각 기법마다 1981년부터 2018년까지 5월에서 10월동안 매 일의 BSISO 영향장을 생산하였고 기법간 비교 분석을 통해 BSISO의 영향을 가장 잘 설명할 수 있는 하나의 기법을 선택하고자 하였다.

Figure 90은 상향장파복사에 대한 BSISO 영향장을 생산 한 뒤 각 기법별로 4개의 메트릭 (평균 오차, 평균 제곱근 오차, 아노말리 상관계수, 설명력)을 계산한 그림이다. M1은 M2와 M3에 비해 평균 오차가 크지만 평균 제곱근 오차는 작다. 값이 클수록 관측의 변동을 더 잘 따른다고 볼 수 있는 아노말리 상관계수에 있어서 M1이 다른 기법에 비해 높은 값을 가지고 있다. 또한 영향장이 전체 변동을 설명하는 정도를 보여주는 설명력에 대해서도 M1이 다른 기법들에 비해 큰 값을 가지고 있어 M1이 계절내 전체 변동을 가장 잘 설명하는 BSISO 영향장 분석 방법으로 고려할 수 있다. 이 결과는 상향장파복사 단일 변수에 대한 결과이므로 다양한 변수들에 대해 기법 비교를 좀 더 수행하였다.

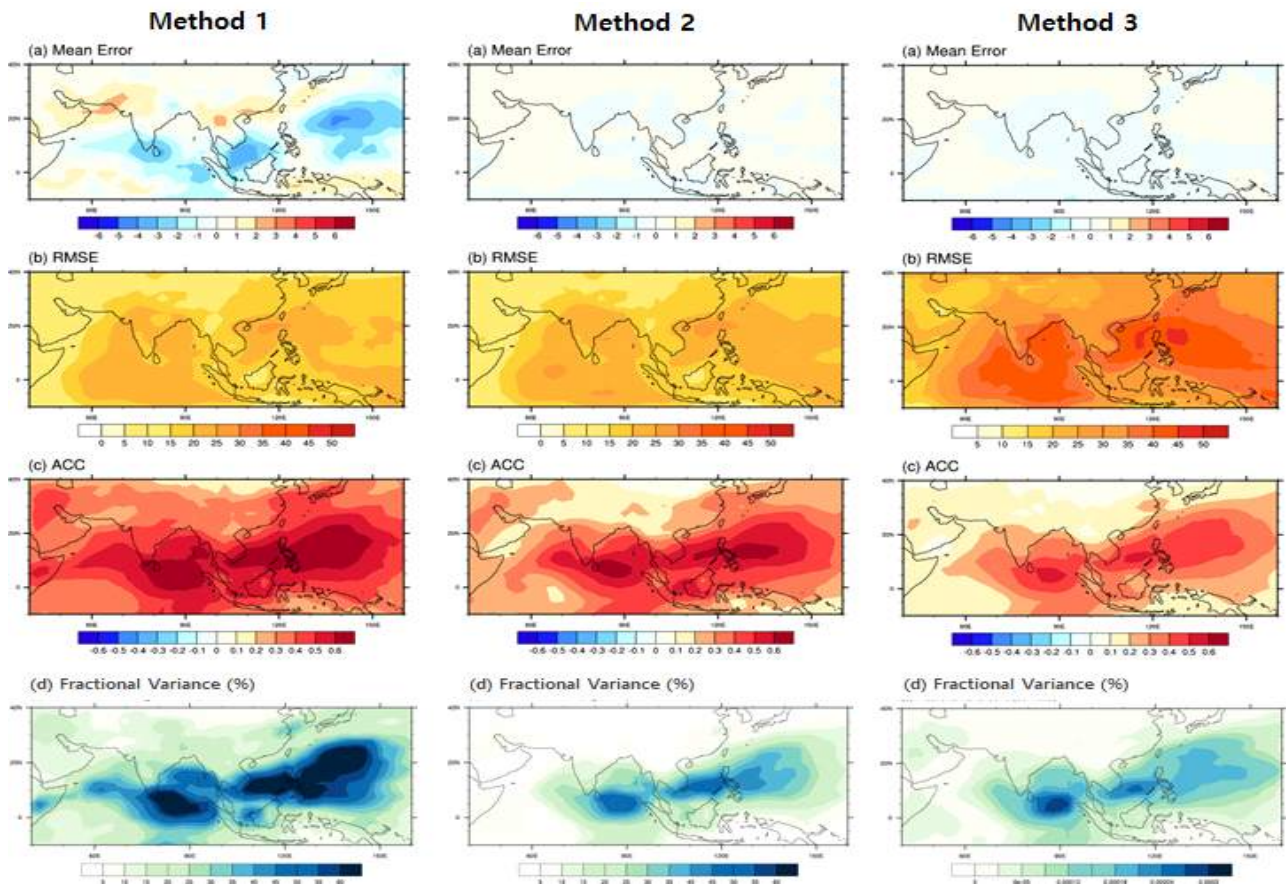


Figure 90. Skill comparison of BSISO impact for Outgoing Longwave Radiation over Asia-monsoon region for M1 (left), M2 (middle) and M3 (right). Mean error, root mean square error(RMSE), anomaly correlation(ACC) and fractional variance are used as skill metrics.




Figure 91. Skill comparison of BSISO impact for multi variable over Asia-monsoon region for M1 (left), M2 (middle) and M3 (right). Anomaly correlation(ACC) and fractional variance are used as skill metrics.

Figure 91은 상향 장파 복사, 850hPa 동서류, 850hPa 수분수렴, 500hPa 지위고도, 해면기압 그리고 2m 기온에 대한 BSISO 영향장을 각 기법별로 생산한 뒤 아노말리 상관계수와 설명력을 계산한 그림이다. 대부분의 변수에 있어서 M1 기법으로 생산된 BSISO 영향장이 다른 기법의 결과에 비해 좀 더 큰 아노말리 상관계수, 설명력 값을 가지고 있다. M1은 다른 기법과 비교했을 때 적게는 5%(850hPa 수분수렴)에서 크게는 10%(850hPa 동서류, 500hPa 지위고도)나 많이 계절내 변동을 설명하는 것으로 나타났다. 다양한 변수에서의 비교에서도 M1이 다른 기법에 비해 BSISO 영향장을 생산하기 좋은 방법임이 확인되었다. M1의 영향장은 아시아 몬순 지역 전반에 걸쳐 850hPa 동서류나 해면기압의 전체 변동의 30% 이상을 설명할 수 있는 것으로 나타났다.

Figure 92는 상향 장파 복사와 850hPa 동서류에 대한 각 기법별 BSISO 영향장을 아노말리 상관계수와 설명력을 통해 월별로 비교한 결과이다. 각 네모 상자는 네 개의 삼각형으로 구성되어 있고 좌측과 우측에 위치한 삼각형은 설명력을, 아래와 위에 위치한 삼각형은 아노말리 상관계수를 나타낸다. 색이 진할수록 설명력과 상관계수가 높아 관측과 더 유사한 변동을 가진다고 볼 수 있다. 월을 가리지 않고 제일 하단의 M1에 대한 상자가 나머지 기법들보다 더 짙은 색을 띠고 있어 M1 기법이 다른 기법에 비해 BSISO 변동성을 잘 설명한다고 할 수 있다. 모든 기법에서 9월에는 850hPa 동서류와 상향장파복사의 상관계수와 설명력이 다른 월에 비해 대체로 낮은 편이고 5월에는 BSISO 영향장이 실제 변동을 가장 잘 재현하는 특징을 보인다. 상관계수와 설명력 모든 측면에서 상향 장파 복사 보다는 850hPa 동서류를 BSISO 영향장이 더 잘 재현하는 것으로 나타난다.

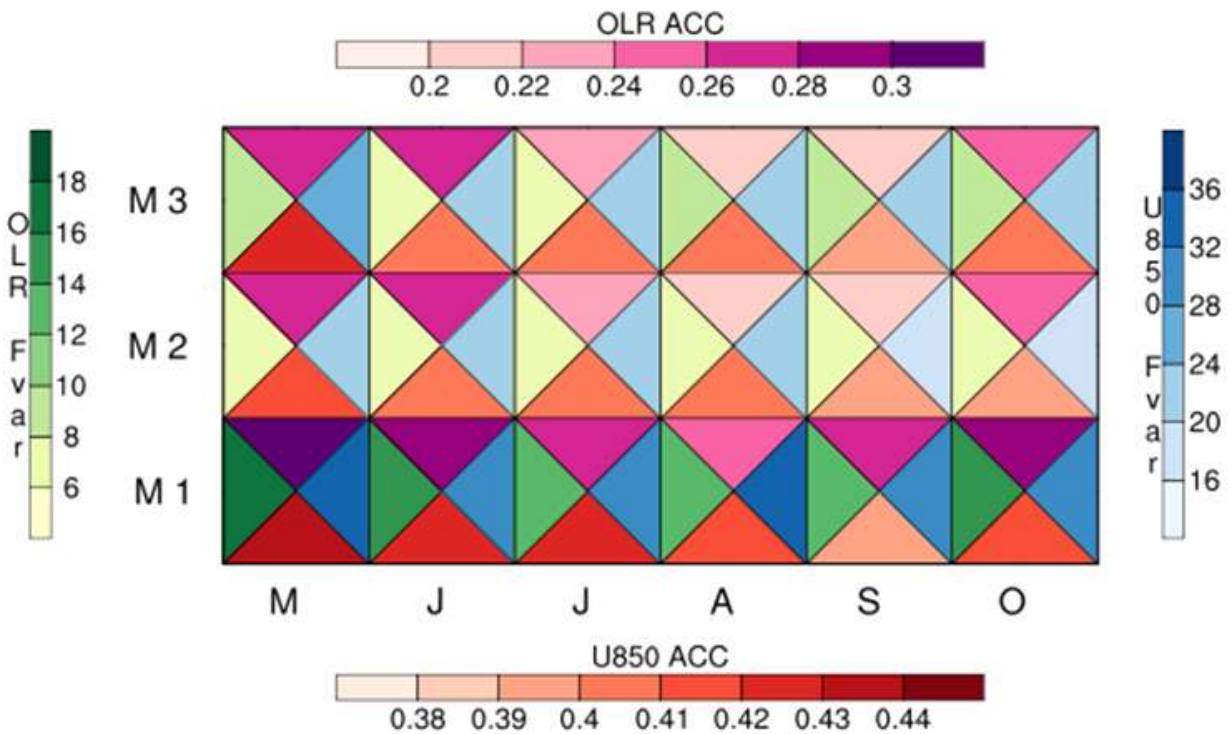


Figure 92. Monthly skill comparison of BSISO impact for OLR and zonal wind at 850hPa over Asia-monsoon region for M1 (bottom), M2 (middle) and M3 (top). Anomaly correlation(ACC) and fractional variance are used as skill metrics.

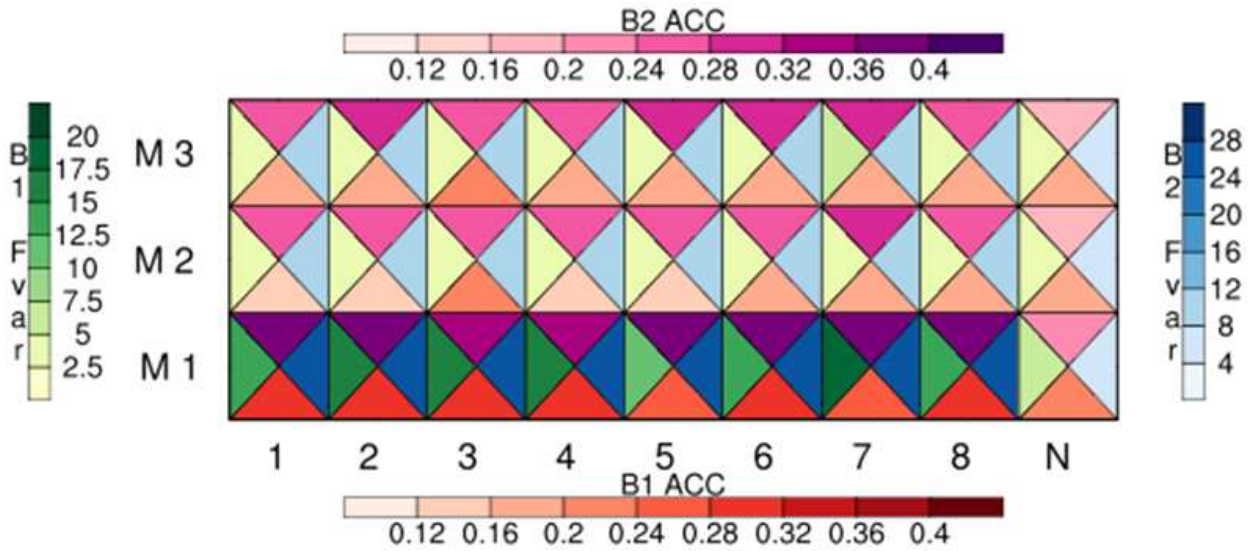


Figure 93. Phase dependency of anomaly correlation and fractional variance for BSISO impact. Outgoing longwave radiation over Asia-monsoon region for M1 (bottom), M2 (middle) and M3 (top) are used.

BSISO의 각 위상에 따라서 우수 기법이 달라질 수 있는지 살펴보기 위하여 상향 장파 복사 에 대한 각 기법별 BSISO 영향장을 BSISO 1과 2 각각에 대해 8개 위상으로 나눈 후 상관계 수와 설명력을 계산하였다(Figure 93). 네 개의 삼각형으로 구성되어 있는 각 네모 상자는 설명 력을 좌측과 우측 삼각형에 나타내고, 상관계수를 아래와 위 삼각형에 나타낸다. 아래와 좌측 삼각형은 BSISO1의 값을, 위와 우측 삼각형은 BSISO2의 값을 가진다. 모든 위상에 대해서 제일 하단의 M1에 대한 상자가 나머지 기법들보다 더 짙은 색을 띄고 있어 M1 기법이 다른 기법에 비해 BSISO를 더 잘 재현한다고 보여 진다. 모든 기법 그리고 모든 위상에서 BSISO가 약할 때 보다는 BSISO가 강할 때 영향장이 전체 변동을 더 많이 설명할 수 있다. BSISO 1에서는 흔히 예측 장벽이라 말하는 위상 4와 5에서 설명력과 상관계수가 떨어지는 것이 나타난다. BSISO 2 의 위상 3과 4에서 상관계수가 낮아지는 이유도 대류 중심이 maritime continent를 지나면서 대류대의 발달이 저해되기 때문으로 보인다.




Figure 94. Regional robustness of anomaly correlation for BSISO impact. Outgoing longwave radiation for M1 (pink), M2 (yellow) and M3 (green) are used.

지역별로 나누어서 비교하여도 M1기법의 탁월함이 나타나는지 살펴보기 위해 아시아 몬순 전체 지역과 인도양, 서태평양 그리고 한반도 네 지역으로 나누어서 분석하였다(Figure 94). 이때 BSISO는 강할 때(원)와 약할 때(삼각형)로 구분하여 BSISO의 강도에 대한 상관계수 변화도 함께 살펴보았다. 강한 BSISO 경우 대체로 모든 지역에 대해서 두 변수 모두에 있어서 M1 기법이 가장 높은 상관계수를 나타낸다. 강한 BSISO 일 때 M2와 M3의 상관계수 차이는 크게 없는 것으로 보인다. 지역 중에서는 서태평양 지역에서의 BSISO 영향장이 다른 지역에 비해 가장 실제 계절내 대기 변동을 잘 재현하는 것으로 보이고 한반도 지역에서는 BSISO 영향장 활용 시 신중할 필요가 있다. BSISO가 약할 때 보다는 강할 때 모든 변수와 지역, 기법에 대해서 높은 상관 계수를 보여준다. M1 기법을 적용할 시 BSISO가 강할 때 서태평양에서의 BSISO 영향장은 활용 가치가 높다고 여겨진다.

BSISO 영향장을 추정할 수 있는 세 가지 통계적 선형 기법을 개발하였고 기법 간 비교를 통해 우리는 대기의 계절내 변동을 가장 잘 그리고 합리적으로 재현할 수 있는 한 가지 기법을 찾고자 하였다. 다양한 비교 평가를 통해 세 가지 기법 중 합성장에 기반한 기법을 활용하는 것이 가장 적절하고 그 선택이 월별, 위상별, 강도별, 변수별, 지역별로도 강건함을 확인할 수 있었다. 합성장 기법을 적용한 영향장은 아시아 몬순 지역 전반에 대해서 전체 변동의 30% 이상을 설명할 수 있고 중위도 기후 예측의 원천이 될 수 있는 인도양 및 북서태평양 지역의 변동에 있어선 최대 60% 이상을 설명할 수 있었다.

(나) 합성장 기반 기법이 적용된 BSISO 영향장 특성 분석

합성장에 기반한 BSISO 영향장이 가지는 특성들을 다양한 측면에서 파악해보았다. Figure 95에서는 BSISO 영향장을 BSISO1과 2의 8개 위상들에 대해서 구분하여 상관계수를 계산한 뒤 각 위상 조합에 따라 값을 정렬하였다. 비교를 위해 BSISO 지수의 크기가 1.0 이하인 약한 BSISO에 대해서도 계산이 되었다. BSISO가 약할 때 보다는 강할 때 더 높은 상관계수를 나타내고 있다. 약한 BSISO가 있었던 경우들을 제외하면 상관계수 값은 0.3 이상을 가진다. 특히 BSISO1과 BSISO2 두 모드가 같은 위치에 대류셀을 가지는 경우(BSISO1과 2가 위상 2,3인 경우 인도양에서 대류 강화, BSISO1과 2가 이상 7,8인 경우에는 서태평양에서 대류 강화)에는 0.4 이상으로 큰 값이 나타나고 두 모드의 패턴의 합이 대류를 상쇄시키는 경우들에서는 상대적으로 작은 값을 보인다. 따라서 BSISO 영향장에는 위상 선호도가 존재하는 것 BSISO 두 모드의 대류대가 비슷한 위치를 갖는 위상인 날에는 BSISO 영향장을 더욱 적극적으로 활용하길 권한다.

BSISO 영향장의 지역적 특성과 계절적 특성의 유무를 살펴보기 위하여 사례들을 6개의 월과 아시아 몬순 지역, 북서태평양, 인도양, 한반도 4개 지역으로 구분하였다. 아시아 몬순 지역은 7,8월보다는 상대적으로 5,6월과 10월에 BSISO 영향장의 신뢰도가 높다. 서태평양의 BSISO 영향장도 다른 월에 비해 6월의 대기 변동을 잘 설명하는 특징이 있다. 인도양의 경우 7월과 8월에 BSISO 영향장의 신뢰도가 다른 계절에 비해 상대적으로 떨어지는 경향이 있다. 영역이 좁을수록 상관계수 값의 변동이 큰 것으로 보이고 BSISO의 영향이 적은 한반도의 경우 다른 지역에 비해 상관계수가 낮지만 6월과 7월에는 다른 지역과 견줄만큼 높은 값을 보인다. 이때는 우리나라 장마 시기와 일치하는 시기로 다른 계절에 비해서 우기인 장마 때에는 BSISO 영향장이 한반도 주변 계절내 대기 변동을 어느 정도 잘 설명한다고 생각된다.




Figure 95. Phase preference of BSISO impact field based on M1. Anomaly correlation coefficient of outgoing longwave radiation over Asia monsoon region is shown for eight phases of BSISO1(Y axis) and is for BSISO2(X axis).




Figure 96. Regional and seasonal preference of BSISO impact anomaly based on M1. Box plot indicates anomaly correlation coefficient of outgoing longwave radiation for six month and four region (Asia, Western North Pacific, Indian Ocean and Korea).

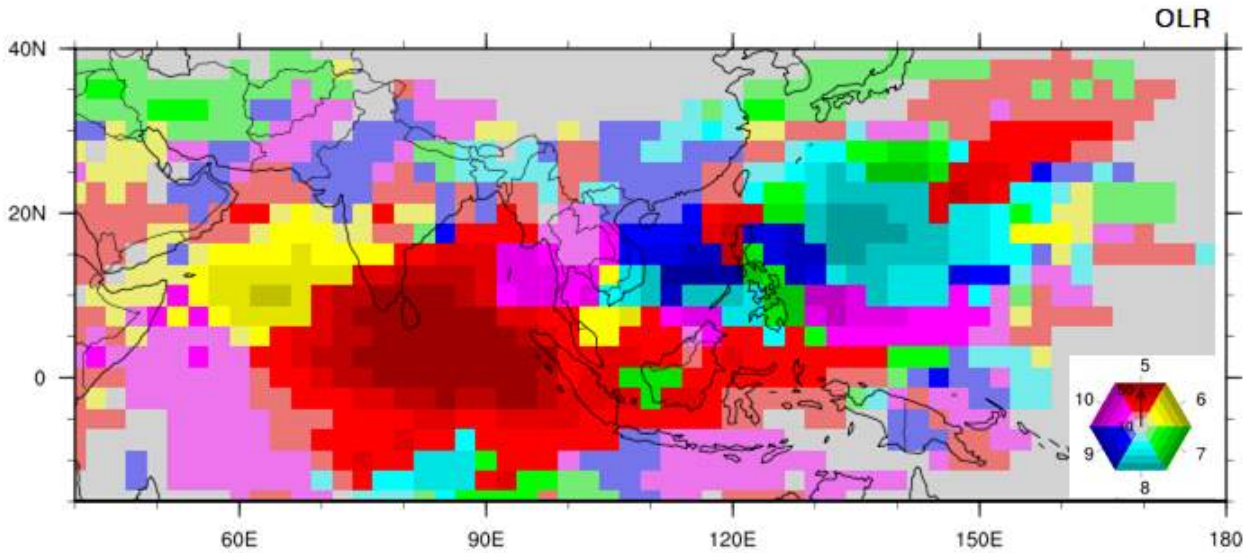


Figure 97. Month representing maximum fractional variance of BSISO impact anomaly for outgoing longwave radiation. Color indicates the month and the value of maximum fractional variance is distinguished by the depth of color.

Figure 97에서는 상향장파복사에 대한 BSISO 반응장이 전체 대기 변동을 설명하는 정도 (Fractional variance)를 계산한 뒤 여름철(5~10월) 중 가장 설명력이 높은 월을 도식화하였다. 각 색깔은 월을 나타내고 색의 짙은 정도로 설명력의 값을 표시하였다. 인도 몬순이 발달하는 5-6월, 남중국 메이유, 대만 메이유가 발달하는 5월, 우리나라 장마 시기인 7월, 북서태평양 태풍 활동이 활발한 8월,9월에 해당하는 색이 각 지역에서 두드러지게 나타나고 있다. 이는 아시아 몬순 지역의 우기에 BSISO 반응장이 대기 상황을 가장 잘 설명하는 특성을 가지고 있음을 의미한다. 즉, 아시아 몬순 지역의 몬순 변동에 BSISO가 상당히 기여함을 시사한다고 볼 수 있다.

실제 지역 몬순 변동에 BSISO 영향장이 어느 정도 설명할 수 있는가를 알아보기 위하여 최근 10년간의 남서 몬순과 대만 메이유 시작일을 수집하였다. 또한 BSISO 영향장을 두 몬순 시작 정의에 적용하여 최근 10년간의 몬순 시작일을 추정할 수 있었고 이 결과를 실제 몬순 시작일과 비교하였다(Figure 98). 남서 몬순과 대만 메이유 시작 정의에 대해서는 부록 F에서 상세히 다루었다. 남서 몬순의 경우 평균적으로 6월 1일에 시작하지만 5일 정도의 표준편차를 가진다. 2011년, 2015년, 2018년도에는 BSISO 영향장으로 추정한 몬순 시작일이 실제 몬순 시작 날짜와 정확히 맞아떨어졌다. 그리고 2012년, 2014년, 2017년, 2019년도에는 BSISO 영향장으로 추정한 몬순 시작 가능일에 실제 몬순이 시작되었다. 2013년의 경우 실제 몬순 시작일이 BSISO 영향장으로 추정한 기간보다 하루 앞섰지만 실제 몬순 시작일이 5일이라는 변동 폭을 가진다는 점을 본다면 상당히 고무적인 결과라 여겨진다. 대만 메이유의 경우 5월 18일이 평균적인 시작일이지만 9일의 표준편차를 가져 해마다의 시작일 변동이 상당히 크다고 볼 수 있다. 그럼에도 불구하고 2010년과 2011년에는 BSISO로 추정한 몬순 시작일이 실제 그 날과 잘 맞았고 2016, 2017, 2018, 2019년도에는 실제 몬순 시작일이 BSISO 영향장으로 추정한 몬순 기간 안에 속해있어 대만 메이유 역시 BSISO 변동에 영향을 받는다고 볼 수 있다. 상대적으로 남서

몬순이 대만 메이유보다 BSISO의 영향을 더 많이 받는다고 보여진다. 몬순 시작의 경향성에 있어서 BSISO 영향장의 설명 정도를 보기 위해 최근 10년간의 몬순을 세 가지 경향으로 구분하였다. 몬순의 평균적인 시작일로부터 앞뒤로 1일 정도 차이가 나는 경우를 평년의 사례로, 평균 시작일보다 2일 이상 빠른 경우 이른해로, 평균 시작일보다 2일 이상 늦은 경우 느린해로 나누어 도식화하였다(Figure 99). 실제 몬순의 경향과 비교했을 때, BSISO 영향장으로 추정된 몬순 시작일은 남서 몬순의 경우 2011, 2013, 2014, 2015, 2017, 2018년 총 6번 같은 경향을 보였다. 대만 메이유의 경우 2010, 2011, 2012, 2013년 총 4번 같은 경향을 가지고 있었다. 이로써 BSISO 영향장은 남서 몬순 시작일을 추정하는데 있어 유용한 정보가 될 수 있음을 알 수 있었고 이는 BSISO의 변동이 남서 몬순 변동과 상당한 관련이 있음을 암시한다.

선택된 합성장 기반 기법으로 만들어진 영향장은 여름철 6개월 중 인도, 중국, 북서태평양, 한반도 등 주요 몬순 지역마다 각각 몬순성 우기가 활발한 월에 대기 상황을 더 잘 설명하는 계절적 특성을 가지고 있어 건기에 비해 우기에 대한 활용도가 높음을 알 수 있었다. 그 중 남서 몬순에 대해서는 최근 10년 중 6년의 몬순 시작에 BSISO가 직접적인 기여를 한 것으로 분석되어 우기에 대한 BSISO 반응장의 활용 가능성이 대두되었다.




Figure 98. Monsoon onset date for Taiwan Mei-Yu and Southwest monsoon during the recent 10 years. Shaded bars indicate possible monsoon onset period when BSISO impact anomalies are applied to monsoon onset definition. Red(blue) circles represent real Southwest monsoon (Taiwan Mei-Yu) onset dates for each year. Dashed lines are the mean of monsoon onset dates for the recent 10 years.




Figure 99. Tendency diagram of monsoon onset for Taiwan Mei-Yu and Southwest monsoon during the recent 10 years. Blue boxes indicate the early of monsoon onset, yellow boxes represent normal monsoon onset, and pink boxes are for the late of monsoon onset. Upper boxes(OBS) are real monsoon onset and below(RES) boxes are estimated monsoon onset by BSISO impact field for each monsoon.

(다) BSISO 영향장 예측으로의 M1 기법 적용 가능성 평가

선정된 BSISO 영향장 분석 기법을 BSISO 예측 지수에 대해서도 적용하였을 때 적절한 BSISO 대기 반응 모드를 만들어 낼 수 있는지 살펴보았다. 이를 위해 최근 3년에 대해 여름철 (5월~10월) 동안의 모델 BSISO 예측 지수를 사용하여 주별 BSISO 영향장 예보를 생산/분석하였다. 사용된 모델은 BOM, ECMWF, GFS, GFS, CWB이고 모델에 대한 자세한 설명은 2장에서 다루었다. 모델마다 생산된 BSISO 영향장 예보를 사용하여 각 모델의 평균 편차, 평균제곱근오차, 아노말리 상관계수, 설명력을 계산하여 Figure 100와 Figure 101에 나타내었다. 리드타임 첫 주를 살펴보면, 적은 오차와 높은 상관 계수에 비춰볼 때 ECMWF로 생산한 BSISO 영향장 예보가 가장 예측성이 좋은 모델로 보여지고 CWB는 다른 모델에 비해 실제 BSISO 변동을 잘 표현하지 못한다. CFS와 GFS는 ECMWF 다음으로 예측성이 좋은 모델로 평가되고 그 정도는 서로 비슷하다. 설명력에 있어서는 CFS와 GFS가 오히려 ECMWF보다 더 우수한 것으로 나타나고 특히 북서태평양 지역에서는 관측에서의 BSISO 변동의 70% 이상을 설명하고 있다. 대체적으로 첫 번째 리드타임의 예측성 보다는 두 번째 리드타임의 예측성이 낮아지는 경향이 있다. 리드타임 두 번째 주를 살펴보면, ECMWF로 생산한 BSISO 영향장 예보는 타모델에 비해 상당히 낮은 오차와 높은 상관계수를 가지는 게 특징적이다. 그러나 관측에서 보여지는 BSISO의 대기 변동 설명 정도를 많이 재현해내지 못하는 점이 아쉽다. 이러한 설명력 부분에서의 단점은 CFS와 GFS의 BSISO 영향장 정보를 활용하여 해소할 수 있다. CFS와 GFS에서 모의된 BSISO 영향장 예보의 북서태평양 지역에서의 설명력은 관측에서의 BSISO 변동의 40% 이상을 설명하고 있다.

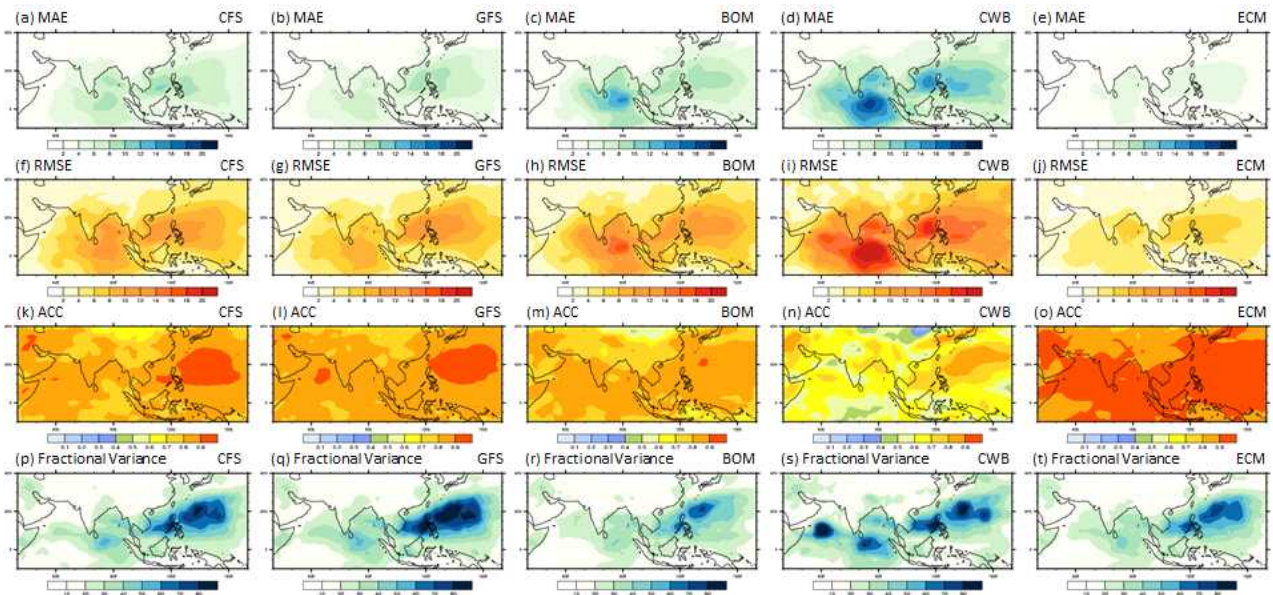


Figure 100. Skill comparison of BSISO impact forecast for WEEK1 in respect of Outgoing Longwave Radiation over Asia-monsoon region. Mean absolute error, root mean square error(RMSE), anomaly correlation coefficient(ACC) and fractional variance are used as skill metrics.

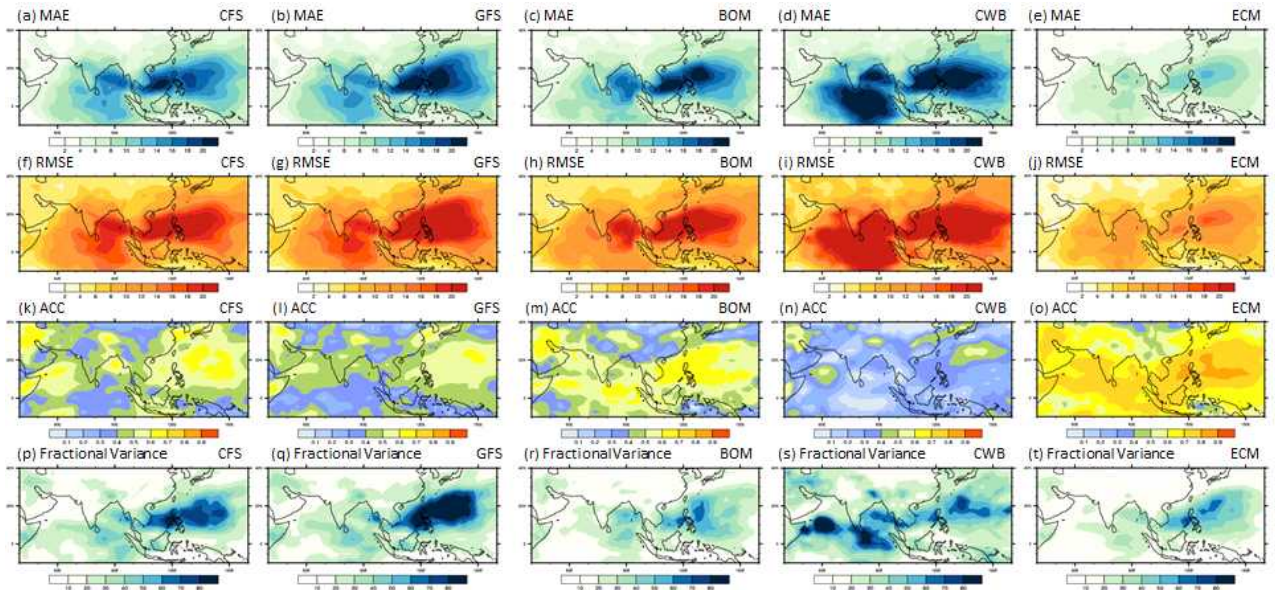


Figure 101. Same as Figure 100. But for the WEEK2.

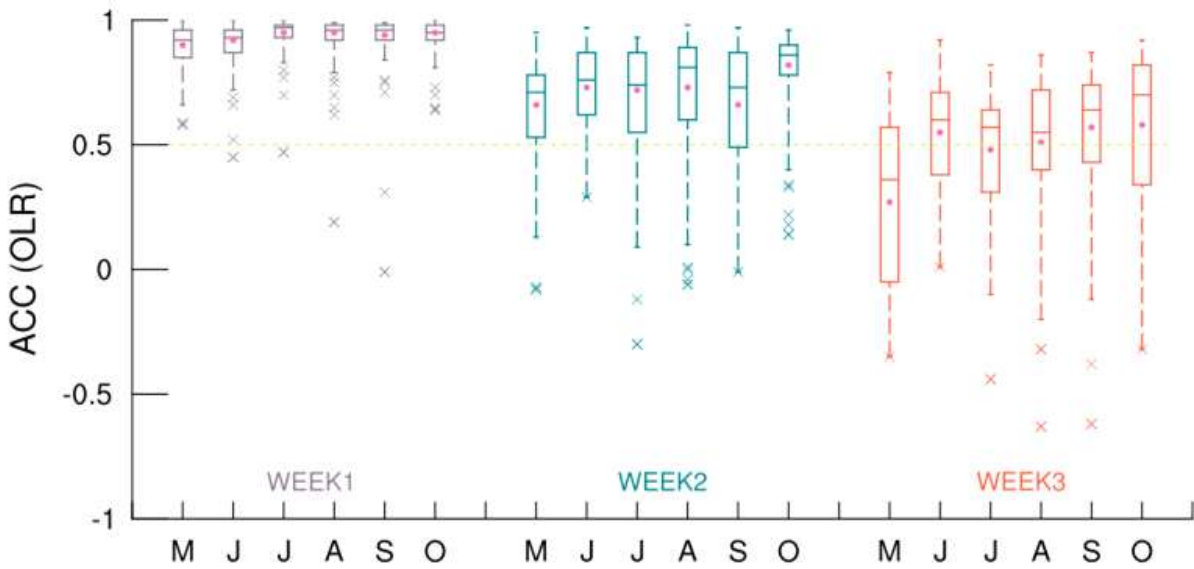


Figure 102. Anomaly correlation coefficient of BSISO impact forecast from ECMWF for WEEK1, WEEK2 and WEEK3 and each month.

관측을 가장 잘 모의하고 있는 ECMWF의 BSISO 영향장 예측을 가지고 상관계수를 구한 뒤 관측에서의 BSISO 변동을 특별히 더 잘 모의하는 계절이 있는지 확인해보았다(Figure 102). 상향장복사에 대한 BSISO 영향장을 사용하였고 리드타임 3주차까지 분석하였다. 첫 번째 주를 살펴보면 모든 월에 있어서 0.9에 가까운 높은 상관관계를 보이고 예측값의 변동 폭도 그리 크지 않아 BSISO 영향장에 대해 믿을만하고 안정적인 예측을 생산한다고 보여진다. 두 번째 주에서는 다른 월에 비해 10월의 영향장 패턴을 잘 모의하고 그 결과도 가장 안정적이다. 모든 월에서 평균적으로 0.7 이상의 아노말리 상관값을 나타내므로 2주차 영향장 예보 역시 믿을만하다. 세 번째 주는 5월을 제외한다면 모든 월이 신뢰도의 기준값인 0.5 이상의 평균값을 가진다. 평균과 중간값으로 봤을 때 3주차에서도 10월의 상관계수 값이 가장 크므로 적분 후 1주차에서 3주차까지 모두 10월의 영향장 예보가 가장 믿을만하다고 판단된다. 종합적으로 본다면 ECMWF에서 생산된 BSISO 영향장 예보는 적어도 2주, 길게는 3주까지 실제 BSISO 변동의 패턴을 잘 모의한다고 생각된다.




Figure 103. Scatter plot of forecast skills for multi-variables from multi models. Each model(variable) is distinguished by color(marker). Closed markers indicate WEEK1, open markers are for WEEK2 and markers with dot are for WEEK3.

Figure 103은 모든 모델, 모든 변수, 모든 리드타임에 대해 BSISO 영향장 예보의 평균제곱편차와 아노말리 상관관계를 보여준다. 모델은 색깔로, 변수는 도형의 모양으로 구분 지어져 있고 도형의 색이 채워진 정도로 리드타임이 표시되었다. 모든 값은 아시아 몬순 지역에 대해 계산된 결과이다. 아노말리 상관계수가 0.5 이상이고 평균제곱근편차 값이 1 이하인 분홍 영역 안에 위치한 모델과 변수는 관측에서의 BSISO 공간 패턴을 잘 모의한다고 생각할 수 있다. 해면기압, 500hPa 지위고도, 850hPa 동서류가 다른 변수에 비해 잘 모의된다. 대부분의 모델들이 리드타임 첫 번째 주에서는 분홍 영역 안에서 확인되고 있다. 그러나 리드타임이 길어지면서 예측성이 떨어지는 추세이다. 그러나 ECMWF의 BSISO 정보는 아시아 몬순 지역에 대해 적어도 2-3주까지 신뢰할만한 BSISO 대기 반응을 예측할 수 있다. 이는 Figure 102에서 도출된 결과와 유사하다.

선정된 BSISO 영향장 분석 기법인 합성장 기반 기법을 BSISO 예측 지수에 대해서도 적용하였을 때 적절한 BSISO 대기 아노말리를 만들어 낼 수 있는지를 판단하기 위해서 최근 3년 여름철(5월~10월) 동안의 다중모델 BSISO 예측 지수를 사용하여 주별 BSISO 반응장 예보를 생산/분석하였다. 그 결과 예측에도 적용 가능함을 확인하였다. 1주~3주까지의 주별 BSISO 반응장 예보는 리드타임이 짧을수록 관측의 BSISO 반응장과 비교했을 때 더 높은 상관관계와 더 낮은 평균제곱근편차를 가지고 있었다. 특히 ECMWF의 BSISO 반응장 예보는 다른 모델의 반응장에 비해 관측의 BSISO 반응장을 모의하는 능력이 더 뛰어나 아시아 몬순 지역에 있어서 적어도 2-3주까지는 신뢰할만한 BSISO 반응 정보를 제공할 수 있었다.

4. 요약 및 결론

이 과제에서 수행한 각 세부 주제 계절내 “모형 예측성 평가 및 오차 진단”, “모형 예측 보정 기술 개발”, “예측 정보 활용 가이드라인 개발”에 대한 결론 및 시사점은 다음과 같다.

A. 모형 예측성 평가 및 오차 진단

첫째, KMA-GloSea5 기후값 재현성 및 실시간 예측 성능을 타 기관 모형 (ECMWF, ECCO, NCEP) 과의 비교를 통해 객관적으로 평가하는 메트릭을 개발하고, 매 해 일관된 검증이 이루어질 수 있도록 평가 프레임워크를 고안하였다. 주요 평가 대상은 전지구, 동아시아 영역에 대한 기온, 강수, 500 hPa 지위 고도의 주평균 예측값으로 각 계절별 선행 시간별 민감도를 파악하고자 하였다. 올해는 특히, 결정론적 검증 정보 생산에 집중하였다.

- KMA-GloSea5의 기후값 재현성은 타 기관 모형에 비해 우수하며, 특히 동아시아의 재현성은 월등하다. 하지만 500 hPa 지위 고도의 경우는 ECMWF, ECCO에 비해 크게 떨어지는 것으로 나타나 향후 상층 대기 평균장 관련 모형 개선 가능성을 엿볼 수 있다.
- ECMWF에서 KMA-GloSea5의 실시간 예측성은 ECMWF 보다는 많이 뒤처지나 NCEP, ECCO 와 비등하거나 우위에 있음을 확인하였다.
- 2017년 겨울철 기온 예측성능은 전구와 동아시아에서 모두 2018년에 비해 우수하고 이러한 특성이 선행시간 4주까지 이어지는데, 이는 2017년 겨울에는 약한 라니냐 상태가 지속되었기 때문으로 짐작해 볼 수 있다.
- 변수별로 살펴보면 강수 예측성이 다른 변수에 비해 현저히 낮다. 동아시아의 경우, 기온 예측성이 지위 고도 예측에 비해 더 떨어지므로 동아시아 기온 예보 개선을 위한 추가적인 노력이 필요함을 알 수 있다.

KMA-GloSea5의 경우, 과거 재현 자료의 초기 시점 간격이 정확히 7일이 아니기 때문에 타 기관 모형들과 상이한 샘플들로부터 기후값을 생산하게 된다. 예측 타겟 날짜에 가까운 샘플들로부터 기후값을 계산할 때, a. 타겟 날짜에서 조금씩 어긋나더라도 일정한 선행 시간 예측값들을 합산하는 방법과, b. 선행 시간이 달라지더라도 타겟 날짜에 해당하는 예측값들을 합산하는 두 개의 방법을 비교를 통해서 KMA-GloSea5 기후값 생산에 대한 다음과 같은 결론을 얻을 수 있었다.

- 두 방법 간의 성능차는 전지구 영역에서는 미비하나, 동아시아 선행 3,4주에서는 타겟 날짜를 맞추는 b 방법의 성능이 좀 더 우수하다.
- 타겟 날짜를 맞춰 주는 형태로 기후값 생산 방식을 바꾸는 것이 예측성 향상을 위한 대안이 될 수 있음을 제안한다.

- 예측 스케줄 변경이 가능하다면 타 기관과의 객관적 비교를 위해 7일 간격의 과거 재현 자료 생산이 가장 바람직하다.

둘째, KMA-GloSea5의 계절내예측자료의 3-4주 예측 성능의 특성을 살펴보고, 구조적 오차를 파악하고자 하였다. GloSea5 지표온도 및 강수 예측장의 계통적 오차의 증분 특성을 살펴보기 위해 선행시간 2주, 4주, 6주, 8주의 여름철 (JJA) 및 겨울철 (DJF)의 변동성 특성 및 강수의 오차 분포를 분석하였다. 동아시아 여름 몬순 모의와 관련된 적도 태평양 및 대서양 해수면 온도와의 관계 재현성을 평가하고, 특히 강수 오차와 관련된 대기 대순환 및 열속 오차에 대해 살펴보았다.

- KMA-GloSea5 계절내 예측 결과는 동아시아 여름 몬순과 관련된 인덱스 및 수평장을 매우 잘 모의하며, 특히 겨울철(D(-1)JF(0)) 동태평양과 봄철(FMA(0)) 열대대서양의 해수면 온도의 상관관계도 매우 잘 나타내고 있음을 확인하였다.
- 동아시아 겨울 몬순 인덱스의 후반기의 낮은 성능의 패턴과 ENSO와의 상관관계의 모의 성능은 동일하게 나타나고 있으며, 이는 몬순 인덱스를 계산할 때 사용되는 상층 동서 바람의 예측 성능과도 크게 관련이 있다.
- ENSO와 동아시아 겨울몬순과의 상관성 예측이 90년대에는 선행시간 4주까지도 높게 나타났으나, 2000년대에는 매우 낮게 나타난다. 2000년대 선행시간 3주 이상 결과에서 서태평양의 바람장 및 동아시아 바람장(U200)을 모의하지 못하는 특징을 보인다. 이는 후반기의 ENSO의 중심이 동태평양에서 서쪽으로 이동한 것과 연관이 있을 것으로 짐작해 볼 수 있다.
- 지면기압 (SLP)의 모의 성능 저하로 시베리아 고기압 확장 모의 성능 역시 매우 떨어진 다. 하지만, 2000년대 동아시아 겨울 몬순 - 북극진동의 연관성은 매우 잘 모의하고 있어 예측 자료 해석시 유용하게 사용할 수 있을 것으로 판단된다.
- 강수의 양의 오차와 연관하여, 서태평양을 중심으로 상대적으로 강한 대류가 존재하며 줄어든 태양복사 지표도달 및 잠열로 인한 냉각 효과로 인해 음의 지표 열속 오차가 뚜렷하다. 이로 인해 선행시간이 긴 계절 규모에서 해양 연직 온도의 음의 오차가 뚜렷하며, 동태평양을 중심으로 얇은 혼합층으로 인한 해수면 냉각을 가져올 수 있다. 이러한 결과는 ENSO 예측에도 영향을 줄 수 있기 때문에 더욱 자세한 분석이 요구된다.

B. 모형 예측 보정 기술 개발

첫째, 계절내 (S2S) 예측 자료의 한반도 영역 내 강수, 최고기온, 최저기온의 딥러닝 기법 기반 예측 보정 기법 개발을 위해 딥러닝 알고리즘의 선정 및 구현, 입출력 데이터 구조 확정, 격자별 딥러닝 모형 구축, 예측 성능 비교 평가를 수행하였다. ECMWF 및 GloSea5 두 기후 모델의 예측 자료에 딥러닝을 적용한 자료와 ERA-Interim 재분석 자료를 통해 평가한 결과, 평방근제곱근오차(Root Mean Square Error, 이하 RMSE)의 경우 전체 선행시간의 일별 예측성이 3개 기후 변수(강수, 최고 및 최저기온) 모두에서 개선된 반면, 편차상관계수(Anomaly

Correlation Coefficient, 이하 ACC)에서는 최고기온과 강수에서만 소폭 개선되었다. 선행주수별 주평균에 대한 예측 성능 평가의 경우, 3-4주의 RMSE 및 ACC에서 소폭 개선을 보여 딥러닝 기법을 적용한 S2S 예측 기후자료의 선행시간 전체 및 선행주수별 예측력 향상이 가능함을 확인하였다. 또한 본 연구에서 적용한 LSTM 훈련 기법이 다른 훈련 기법에 비해 S2S 예측 자료의 오차 개선에서 우수한 성능을 보였다. 두 기후 모델의 S2S 예측 자료의 예측 성능 향상을 위한 딥러닝 활용 기술에 대해 다음과 같이 요약하였다.

- 기후 변수 예측성 향상의 경우, ACC에서 최고기온과 강수에서는 예측성이 개선되었고, RMSE에서는 3개 변수 모두에서 예측성이 개선되었다. 이것을 바탕으로 최저기온보다는 최고기온과 강수에서 딥러닝 훈련 기법의 적용에 대한 예측성능 개선 효과를 기대할 수 있다.
- 선행주수별 예측성 개선의 경우, 2~4주의 ECMWF S2S와 3~4주의 GloSea5 S2S에서 예측성 향상이 나타남으로써, 예측성 개선 타겟인 2주 이후, 특히 3~4주의 S2S예측성 향상에 딥러닝 훈련 기법, 특히 LSTM 적용이 확실히 도움됨을 확인할 수 있었다.
- 여름철 예측성 개선의 경우, 여름철 S2S 예측 자료에 딥러닝 훈련 기법을 적용함으로써 여름철, 특히 최고기온은 6~7월, 강수는 8월의 S2S 예측 성능 향상이 가능함을 확인하였다.
- 훈련 기법간 예측성 비교의 경우, 현재까지의 연구에서 여러 기계학습 방법 중 LSTM이 가장 효율적임을 확인하였다.

딥러닝 기술은 축적된 데이터가 많아질수록 학습 결과가 좋아지고 신뢰성이 높아진다. 본 연구에서 새로운 S2S 예측 데이터의 추가와 분석이 용이한 딥러닝 파이프라인을 구축함으로써 계절내 예측의 오차를 크게 감소함을 확인하였다. 이 결과들은 최고/최저온도, 강수량 등의 예측 성능을 향상시킴으로서, 폭염, 열대야, 호우 등의 기상 재해에 대비할 수 있는 자료로 활용될 수 있다.

향후 딥러닝을 통한 S2S 기후예측의 성능과 신뢰성을 향상시키기 위해서는 다음의 연구들이 수행되어야 한다. 여러 모델을 한번에 고려하는 multimodel ensembl (MME) 기법이 기후 예측의 신뢰성을 증가시킨다고 알려져있다. 본 연구에서는 GloSea5와 ERA-Interim의 두 가지 S2S 모델을 각각 딥러닝의 입력자료로 사용했으나, 다른 S2S 데이터를 통합하여 입력자료에 추가함으로써, S2S MME의 딥러닝 모델을 구축할 수 있다. 그러나 S2S 모델간 다른 생산 날짜, 예측 선행시간, 수평/수직 해상도, 앙상블 수 등을 우선적으로 해결해야 한다. 또한 이번 연구에서는 grid 기반으로 학습이 진행되었지만, 대기의 이동을 고려한 다중 격자 기반의 딥러닝 파이프라인이 구축되어야 한다. Feature engineering 기술은 머신러닝/딥러닝에 들어가는 개별 변수 혹은 모델 종류를 간소화하거나 입력 feature의 중요성을 파악하는데 사용할 수 있게 된다. MLP의 입력자료로 feature의 수를 조절해본 결과, 성능이 큰 폭으로 변화하였다 (Supplementary Table 2-11). 추후에 더 향상된 feature engineering 기술을 사용해, S2S 예측 성능을 올리고, 입력변수/모델의 상대적 중요성을 파악할 필요가 있다.

둘째, 한반도 한파 등 극한 기온 현상의 선행 인자로 알려진 동아시아 겨울 기온 예측성 향상을 위하여 회귀 분석, 경험적 직교 함수 등 고전 통계 기반의 보정 기법을 고안하였다. ECMWF, ECCC, NCEP 세 모형의 선행 3주차 동아시아 기온 SCM MME 자료에 경험적 직교 함수와 회귀장 분석 기법을 조합한 4가지 기법을 테스트하여 최대 성능 개선을 보이는 방법 (주요 33개 기온 변동 EOF 모드에 대한 회귀장과 동아시아 지역 평균 기온에 대한 회귀장을 관측에 상응하는 값으로 치환하고 이를 예측장에 투영하는 방식)을 선정하였다.

- Leave-One-Test를 통해 교차 검증 결과, 기존 SCM MME ACC 대비 19.4% 개선을 보인다.
- 성능 히스토그램에서 분포가 우측으로 이동하고, 음의 값의 케이스들이 줄어든 것을 보이지만, 이것이 모든 경우의 성능이 개선을 의미하는 것은 아님을 명시해야 한다.
- 기존은 11년 동안의 겨울철 각 12주의 샘플에 기반한 결과이다. 향후, 샘플수 확장을 통해서 보정 기법의 안정성을 높일 필요가 있다.

C. 예측 정보 활용 가이드라인 개발

첫째, 동아시아 겨울 3주차 주평균 기온 예측성 추정을 위한 가이드라인을 제안하였다. 계절내 예측 특히 중위도 대륙 동안에 위치한 동아시아의 경우 그 성능이 낮을 뿐만 아니라, 케이스별로 그 차이가 매우 크다. 계절예측에서 ENSO 위상에 따라 예보의 성능을 미리 가늠하듯이 계절내 예보에서도 이러한 정보를 확보함으로써 유용성 및 활용성 증대를 기대할 수 있을 것이다. 과거 예측 자료 분석을 통해, 예측 성능에 민감한 기후 모드 교차 조건, 1주 선행 예측 성능 지속성 조건, 선행 시간 내 예보 안정도 조건을 확인하였고, 이를 바탕으로 선행 3주차 동아시아 주평균 겨울 기온 예측성 추정을 위한 의사결정트리를 제시하였다 (부록 E).

- 동아시아 겨울 기온 변동모드, 동아시아 겨울 몬순, 태평양 제트 스트림, 시베리아 고기압, 극진동의 재현 특성 및 지수 예측성 등 다양한 분석을 수행하였음. 중위도 대기 변동성의 예측성은 기대했던 것처럼 크게 높지 않았으나, 극진동의 경우 선행 3-4주의 SCM MME의 성능이 ECMWF에 비해 높아 후보정 효과를 확인할 수 있었다.
- 선행 1-4주 동안 시베리아 고기압 지수 기울기에 대한 SCM MME 예측은 기후값 예측에 비해 우수하다. 시베리아 고기압 기울기에 기반한 향후 동아시아 기온 경향 예측 활용을 기대할 수 있다.
- 동아시아 평균 기온, 기온 변동모드 1 & 2, Li_U 과 WangC_P의 동아시아 겨울 몬순지수, 시베리아 고기압 간의 총 8개의 교차 조건에서 유의미한 예측성 구분이 이루어졌다. 1주 선행 예측성을 AN/NN/BN 3분위로 구분했을 때, 선행 3주차 예측 성능도 순서대로 낮아지는 경향이 있다. 또한, 선행 1-4주 예측 안정도가 높을수록 예측성이 높은 경향이 있다.

- 개발된 가이드라인을 활용하여 실시간 예측 시점에서 성능을 추정하고 불확실성을 줄일 수 있다면, 그 신뢰도를 기반으로 매뉴얼 예보에서 모형 정보 가중치 선정의 객관적 정보로 활용 될 수 있을 것이다. 향후, 개별 모형 적용 및 샘플수 확장을 통해서 성능 추정 조건의 안정도를 높일 필요가 있다.

둘째, BSISO 영향장을 추정할 수 있는 세 가지 통계적 선형 기법(EOF 분석, 회귀분석, 합성장 분석 기반)을 개발하였다. 세 가지 기법의 영향장을 비교 평가한 뒤 합성장에 기반 한 기법이 전체 대기 변동을 가장 적절하게 설명할 수 있는 방법임을 알아내었고 그 결과는 월별, 위상별, 강도별, 변수별, 지역별로도 강건함을 확인하였다. 합성장 기법을 적용한 영향장에 대한 분석을 요약하면 다음과 같다.

- 아시아 몬순 지역 전반에 대해서 전체 변동의 30% 이상을 설명할 수 있고 중위도 기후 예측의 원천이 될 수 있는 인도양 및 북서태평양 지역의 변동에 있어선 최대 60% 이상을 설명할 수 있다.
- 여름철 6개월 중 인도, 중국, 북서태평양, 한반도 등 주요 몬순 지역마다 각각 몬순성 우기가 활발한 월에 대기 상황을 더 잘 설명하는 계절적 특성을 가지고 있어 건기에 비해 우기에 대한 활용도가 높음을 알 수 있다.
- 인도 몬순에 대해서는 최근 10년 중 6년의 몬순 시작에 BSISO가 직접적인 기여를 한 것으로 분석되어 우기에 대한 BSISO 영향장의 활용 가치가 높음을 알 수 있다.

선정된 BSISO 영향장 분석 기법을 BSISO 예측 지수에 대해서도 적용해보았다. 최근 3년 여름철(5월~10월) 동안 5개 모형의 BSISO 예측 지수를 사용하여 주별 BSISO 반응장 예보를 생산/분석하였고 그 결과 예측에도 적용 가능함을 확인하였다.

- ECMWF의 BSISO 반응장 예보는 다른 모형의 반응장에 비해 관측의 BSISO 반응장을 모의하는 능력이 더 뛰어나 아시아 몬순 지역에 있어서 적어도 2-3주까지는 신뢰할만한 BSISO 반응 정보를 제공할 수 있음을 확인하였다.
- Figure 7을 다시 보자. 2018년 8월의 한 사례로 BSISO 지수(좌)를 활용하여 8/18에 해당하는 대기 반응장(우)을 생산하였다. 지수 정보에서 유추하기 힘들었던 북서태평양에서의 태풍 관련 변동을 영향장에서는 쉽게 확인할 수 있다. 실제 이 때 북서태평양 지역에 3개의 태풍(제 18호~20호)이 활동 중이었다. 이는 BSISO 영향장이 태풍을 비롯한 아시아 몬순 지역 대기 변동을 탐지하는데 활용할 수 있는 중요한 정보가 될 수 있음을 시사한다.

사사

본 연구는 APCC의 지원을 통해 수행되었습니다.

References

- 김가영, 이윤영, 윤순조, 오지현, 2019: S2S 자료를 이용한 계절내 다중모델 앙상블 예측성능 평가. *2019년 한국기상학회 기후분과 봄학술대회 논문집*, 62.
- 문자연, 오지현, 이윤영, 김가영, 윤순조, 2018: 아태지역 15-60일 MME 예측 기술 개발 및 검증 기술 개발, *APEC기후센터 연구보고서 2018-08*, APEC기후센터.
- 이우섭, 윤순조, 김가영, 김미아, 신지현, 이현록, 2017: WMO 장기예보 선도센터 운영(7차년도), *APEC기후센터 연구보고서 2017-20*, APEC기후센터.
- Abdel-Aal, R. E. and M. A. Elhadidy, 1995: Modeling and Forecasting the Daily Maximum Temperature Using Abductive Machine Learning. *Weather and Forecasting*, **10**, 310-325, [https://doi.org/10.1175/1520-0434\(1995\)010<0310:MAFTDM>2.0.CO;2](https://doi.org/10.1175/1520-0434(1995)010<0310:MAFTDM>2.0.CO;2).
- Baggett, C. F., E. A. Barnes, E. D. Maloney, and B. D. Mundhenk, 2017: Advancing atmospheric river forecasts into subseasonal-to-seasonal time scales. *Geophys. Res. Lett.*, **44**, 7528-7536.
- Brunet, G., M. Shapiro, B. Hoskins, M. Moncrieff, R. Dole, G. N. Kiladis, B. Kirtman, A. Lorenc, B. Mills, R. Morss, S. Polavarapu, D. Rogers, J. Schaake, and J. Shukla, 2010: Collaboration of the weather and climate communities to advance subseasonal-to-seasonal prediction. *Bulletin of the American Meteorological Society*, **91**, 1397-1406.
- Chan, J. C. L., and C. Li, 2004: The east Asia winter monsoon. East Asian Monsoon, *World Scientific*, 54-106.
- Chen, S., R. Wu, and W. Chen, 2018: Modulation of spring northern tropical Atlantic sea surface temperature on the El Niño-Southern Oscillation-East Asian summer monsoon connection, *International Journal of Climatology*, **30**(12), 1632, <https://doi.org/10.1002/joc.5710>.
- Dee, D. P., S. M. Uppala, A. J. Simmons, P. Berrisford, P. Poli S. Kobayashi, U. Andrae, M. A. Balmaseda, G. Balsamo, P. Bauer, P. Bechtold, A. C. M. Beljaars, L. van de Berg J. Bidlot, N. Bormann, C. Delsol R. Dragani, M. Fuentes, A. J. Geer, L. Haimberger, S. B. Healy, H. Hersbach, E. V. Hólm, L. Isaksen, P. Kállberg, M. Köhler, M. Matricardi, A. P. McNally, B. M. Monge-Sanz, J.-J. Morcrette, B.-K. Park, C. Peubey, P. de Rosnay, C. Tavalato, J.-N. Thépaut, and F. Vitart, 2011: The ERA-Interim reanalysis: Configuration and performance of the data assimilation system. *Q. J. R. Meteorol. Soc.*, **137**, 553-597, <https://doi.org/10.1002/qj.828>.
- DelSole, T., L. Trenary, M. K. Tippett, and K. Pegion, 2017: Predictability of week-3-4 average temperature and precipitation over the contiguous United States. *J. Clim.*, **30**,

3499–3512.

- Dueben, P. D. and P. Bauer, 2018: Challenges and design choices for global weather and climate models based on machine learning. *Geoscientific Model Development*, **11**, 3999–4009, <https://doi.org/10.5194/gmd-11-3999-2018>.
- ECMWF, S. P., 2014: In IFS documentation CY40R1 Part IV: Physical Processes. ECMWF: Reading, UK, 111–113.
- Emilcy, H., S. A. Victor, J. Vicente, J. Palanca, D. Néstor, 2016: Rainfall Prediction. *A Deep Learning Approach*. 151–162. https://doi.org/10.1007/978-3-319-32034-2_13.
- Ham, Y-G., J.-S. Kug, J.-Y. Park, and F.-F. Jin, 2013: Sea surface temperature in the north tropical Atlantic as a trigger for El Niño/Southern Oscillation events, *Nature Geoscience*, **6**(2), 112–116, <https://doi.org/10.1038/ngeo1686>.
- Hong, C.-C., T.-C. Chang, and H.-H. Hsu, 2014: Enhanced relationship between the tropical Atlantic SST and the summertime western North Pacific subtropical high after the early 1980s, *Journal of Geophysical Research Atmospheres*, **119**(7), 3715–3722, <https://doi.org/10.1002/2013JD021394>.
- Jhun, J. G., and E. J. Lee, 2004: A new East Asian winter monsoon index and associated characteristics of the winter monsoon. *J. Clim.*, **17**, 711–726.
- Kang, D. and M.-I. Lee, 2017: ENSO influence on the dynamical seasonal prediction of the East Asian Winter Monsoon. *Clim. Dyn.*, <https://doi.org/10.1007/s00382-017-3574-4>.
- Kim, S-W., H. Kim, K. Song, S.-W. Son, Y. Lim, H.-S. Kang, and Y.-K. Hyun, 2018: Subseasonal-to-Seasonal (S2S) Prediction Skills of GloSea5 Model: Part 1. Geopotential Height in the Northern Hemisphere Extratropics Atmosphere. *Korean Meteorological Society*, **28**(3), 233–245, <https://doi.org/10.14191/Atmos.2018.28.3.233>.
- Kug, J.-S., J.-H. Jeong, Y.-S. Jang, B.-M. Kim, C. K. Folland, S.-K. Min, and S.-W. Son, 2015: Two distinct influences of Arctic warming on cold winters over North America and East Asia. *Nat. Geosci.*, **8**, 759–763, <https://doi.org/10.1038/NGEO2517>.
- Lee, S. S., 2018: Development of flood risk analysis technique using seasonal to sub-seasonal data. *Annual Report*, APEC Climate Center, 9.
- Li, F., H. Wang, and Y. Gap, 2014: On the Strengthened Relationship between the East Asian Winter Monsoon and Arctic Oscillation: A Comparison of 1950–70 and 1983–2012, *Journal of Climate*, **27**, 5075–5091, <https://doi.org/10.1175/JCLI-D-13-00335.1>
- Li, J., and J. Wang, 2003: A new North Atlantic Oscillation index and its variability. *Adv. Atmos. Sci.*, **20**, 661–676. <https://doi.org/10.1007/BF02690792>.

- Li, J. P., and X. L. Wang, 2003: A modified zonal index and its physical sense, *Geophys. Res. Lett.*, **30**(12), 1632, doi:10.1029/2003GL017441.
- Li, S., and A. W. Robertson, 2015: Evaluation of submonthly precipitation forecast skill from global ensemble prediction systems. *Mon. Weather Rev.*, **143**, 2871–2889.
- Li, Y., and S. Yang, 2010: A dynamical index for the East Asian winter monsoon. *J. Clim.*, **23**(15), 4255–4262, <https://doi.org/10.1175/2010JCLI3375.1>.
- Lorenz, E. N., 1963: Deterministic nonperiodic flow. *J. Atmos. Sci.*, **20**, 130–141, [https://doi.org/10.1175/1520-0469\(1963\)020<0130:DNF>2.0.CO;2](https://doi.org/10.1175/1520-0469(1963)020<0130:DNF>2.0.CO;2)
- MacLachlan, C., A. Arribas K. A. Peterson A. Maidens D. Fereday A. A. Scaife M. Gordon M. Vellinga A. Williams R. E. Comer J. Camp P. Xavier and G. Madec, 2015: Global seasonal forecast system version 5 (GloSea5): a high-resolution seasonal forecast system. *Quart. J. Roy. Meteor. Soc.*, **141**(689), 1072–1084, <https://doi.org/10.1002/qj.2396>.
- Madec, G., 2008: NEMO ocean engine. *IPSL Tech. Rep.* **27**, 401 pp
- Mori, M., M. Watanabe, H. Shiogama, J. Inoue, and M. Kimoto, 2014: Robust Arctic sea-ice influence on the frequent Eurasian cold winters in past decades, *Nature Geoscience*, **7**, 869–873.
- Ortiz-García, E. G., S. Salcedo-Sanz, C. Casanova-Mateo, A. Paniagua-Tineo, J. A. Portilla-Figueras, 2012: Accurate local very short-term temperature prediction based on synoptic situation Support Vector Regression banks. *Atmospheric Research*, **107**, 1–8, <https://doi.org/10.1016/j.atmosres.2011.10.013>.
- Panagiotopoulos, F., M. Shahgedanova, A. Hannachi, and D. B. Stephenson, 2005: Observed trends and teleconnections of the Siberian high: A recently declining center of action. *J. Clim.*, **18**, 1411–1422.
- Paniagua-Tineo, A., S. Salcedo-Sanz, C. Casanova-Mateo, E. G. Ortiz-García, M. A. Cony, E. Hernández-Martín, 2011: Prediction of daily maximum temperature using a support vector regression algorithm. *Renewable Energy*, **36**, 3054–3060, <https://doi.org/10.1016/j.renene.2011.03.030>.
- Rae, J. G. L., H. T. Hewitt, A. B. Keen, J. K. Ridley, A. E. West, C. M. Harris, E. C. Hunke, and D. N. Walters, 2015: Development of the Global Sea Ice 6.0 CICE configuration for the Met Office Global Coupled model. *Geosci. Model Dev.*, **8**, 2221–2230, <https://doi.org/10.5194/gmd8-2221-2015>.

- Ramesh, K. and R. Anitha, 2014: MARSpline model for lead seven-day maximum and minimum air temperature prediction in Chennai, India. *Journal of Earth System Science*, **123**, 665–672, <https://doi.org/10.1007/s12040-014-0434-z>.
- Randall, D.A., R.A. Wood, S. Bony, R. Colman, T. Fichefet, J. Fyfe, V. Kattsov, A. Pitman, J. Shukla, J. Srinivasan, R.J. Stouffer, A. Sumi and K.E. Taylor, 2007: Climate Models and Their Evaluation. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change* [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller(eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- Rodney, M., H. Lin, and J. Derome, 2013: Subseasonal prediction of wintertime North American surface air temperature during strong MJO events. *Mon. Weather Rev.*, **141**, 2897–2909.
- Scaife A. A., A. Arribas, E. Blockley, A. Brookshaw, R. T. Clark, N. Dunstone, R. Eade, D. Fereday, C. K. Folland, M. Gordon, L. Hermanson, J. R. Knight, D. J. Lea, C. MacLachlan, A. Maidens, M. Martin, A. K. Peterson, D. Smith, M. Vellinga, E. Wallace, J. Waters and A. Williams, 2014: Skilful Long Range Prediction of European and North American Winters. *Geophysical Research Letters*, **41**, 2514–2519, <https://doi.org/10.1002/2014GL059637>.
- Scher, S. and G. Messori, 2018: Predicting weather forecast uncertainty with machine learning. *Quarterly Journal of the Royal Meteorological Society*, **144**, 2830–2841, <https://doi.org/10.1002/qj.3410>.
- Vitart, F., C. Ardilouze, A. Bonet, A. Brookshaw, M. Chen, C. Codorean, M. Déqué, L. Ferranti, E. Fucile, M. Fuentes, H. Hendon, J. Hodgson, H.-S. Kang, A. Kumar, H. Lin, G. Liu, X. Liu, P. Malguzzi, I. Mallas, M. Manoussakis, D. Mastrangelo, C. MacLachlan, P. McLean, A. Minami, R. Mladek, T. Nakazawa, S. Najm, Y. Nie, M. Rixen, A. W. Robertson, P. Ruti, C. Sun, Y. Takaya, M. Tolstykh, F. Venuti, D. Waliser, S. Woolnough, T. Wu, D.-J. Won, H. Xiao, R. Zaripov, and L. Zhang 2017: The Subseasonal to Seasonal (S2S) Prediction Project Database. *Bull. Am. Meteorol. Soc.*, **98**, 163–173, <https://doi.org/10.1175/bams-d-16-0017.1>.
- 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.
- Vitart, F., C. Ardilouze, A. Bonet, A. Brookshaw, M. Chen, C. Codorean, M. Déqué, L. Ferranti, E. Fucile, M. Fuentes, and H. Hendon, 2017: The subseasonal to seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, **98**, 163–173.

- Vitart, F., A. W. Robertson, and D. L. T. Anderson, 2012: Subseasonal to seasonal prediction project: bridging the gap between weather and climate. *Bulletin of the World Meteorological Organization*, **61**, 23.
- Wallace, J.M. and D.S. Gutzler, 1981: Teleconnections in the geopotential height field during the Northern hemisphere winter. *Mon. Wea. Rev.*, **109**, 784–812, [https://doi.org/10.1175/1520-0493\(1981\)109<0784:TITGHF>2.0.CO;2](https://doi.org/10.1175/1520-0493(1981)109<0784:TITGHF>2.0.CO;2)
- Walters, D., I. Boutle, M. Brooks, T. Melvin, R.I Stratton, S. Vosper, H. Wells, K. Williams, N. Wood, T. Allen, A. Bushell, D. Copsey, P. Earnshaw, J. Edwards, M. Gross, S. Hardiman, C. Harris, J. Heming, N. Klingaman, R. Levine, J. Manners, G. Martin, S. Milton, M. Mittermaier, C.I Morcrette, T. Riddick, M. Roberts, C. Sanchez, P. Selwood, A. Stirling, C. Smith, D. Suri, W. Tennant, P. Li Vidale, J. Wilkinson, M. Willett, S. Woolnough, and P. Xavier, 2017: The Met Office Unified Model Global Atmosphere 6.0/6.1 and JULES Global Land 6.0/6.1 configurations. *Geosci. Model Dev.*, **10**, 1487–1520, <https://doi.org/10.5194/gmd-10-1487-2017>.
- Wang, B. and Z. Fan, 1999: Choice of South Asian summer monsoon indices. *Bull. Amer. Meteor. Soc.*, **80**, 629–638.
- Wang, B., R. Wu, K.-M. Lau, 2001: Interannual variability of Asian summer monsoon: Contrast between the Indian and western North Pacific–East Asian monsoons. *J. Climate*, **14**, 4073–4090, [https://doi.org/10.1175/1520-0442\(2001\)014<4073:IVOTAS>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<4073:IVOTAS>2.0.CO;2)
- Wang, B., Y. Zhang, and M. M. Lu, 2004: Definition of South China Sea Monsoon onset and commencement of the East Asia Summer Monsoon, *J. Climate*, **17**, p699–710, <https://doi.org/10.1175/2932.1>
- Wang, B., and Q. Zhang, 2002: Pacific–east Asian teleconnection: Part II. How the Philippine Sea anticyclone is established during El Nino development, *J. Clim.*, **15**, 3252–3265, [https://doi.org/10.1175/1520-0442\(2002\)015<3252:PEATPI>2.0.CO;2](https://doi.org/10.1175/1520-0442(2002)015<3252:PEATPI>2.0.CO;2).
- Wang, L., J.-Y. Yu, and H. Peak, 2017: Enhanced biennial variability in the Pacific due to Atlantic capacitor effect, *Nature Communications*, <https://doi.org/10.1038/ncomms14887>.
- Wang, L., and W. Chen, 2014: The East Asian winter monsoon: Re-amplification in the mid-2000s. *Chinese Sci. Bull.*, **59**, 430–436.
- Wang, R. Huang, L. Gu, W. Chen, and L. Kang, 2009: Interdecadal variations of the East Asian winter monsoon and their association with quasi-stationary planetary wave activity. *J. Clim.*, **22**, 4860–4872.
- Webster, P. J. and S. Yang, 1992: Monsoon and ENSO: Selectively interactive systems. *Quart. J. Roy. Meteor. Soc.*, **118**, 877–926, <https://doi.org/10.1002/qj.49711850705>.

- Williams, K. D., C. M. Harris, A. Bodas-Salcedo, J. Camp, R. E. Comer, D. Copsey, D. Fereday, T. Graham, R. Hill, T. Hinton, P. Hyder, S. Ineson, G. Masato, S. F. Milton, M. J. Roberts, D. P. Rowell, C. Sanchez, A. Shelly, B. Sinha, D. N. Walters, A. West, T. Woollings, and P. K. Xavier, 2015: The Met Office Global Coupled model 2.0 (GC2) configuration. *Geosci. Model Dev.*, **8**, 1509–1524, <https://doi.org/10.5194/gmd-8-1509-2015>.
- World Meteorological Organization, 2015: Seamless prediction of the earth system: from minutes to months. WMO digital free hard copy, accessed 12 December 2019, <https://public.wmo.int/en/resources/library/seamless-prediction-of-earth-system-from-minutes-to-months>.
- World Meteorological Organization, 2018: S2S prediction. accessed 1 February 2018, <http://s2sprediction.net>.
- Xingjian, S. H. I., Z. Chen, H. Wang, D. Y. Yeung, W. K. Wong, and W. C. Woo, 2015: Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *28th Proc. on Advances in neural information processing systems*, 802–810.
- Yang, S., K. M. Lau, and K. M. Kim, 2002: Variations of the East Asian jet stream and Asian–Pacific–American winter climate anomalies. *J. Clim.*, **15**, 306–325.

부록 A. KMA 계절내 예측성능 비교·평가 메트릭 자동화
시스템 운영매뉴얼

APEC Climate Center (APCC)

운영매뉴얼:
KMA 계절내 예측성능 비교·평가
메트릭 자동화 시스템
(다중모델 기반 계절내 예측 활용 가이드라인 개발)

2019년

APEC기후센터 기후사업본부
예측기술과 김가영, 이운영

차 례

〈제목 차례〉	
1. 개요	1
가. 배경 및 목적	1
나. S2S 모델 소개	1
다. 검증을 위한 타겟주(target week) 선정 및 기후값 계산	1
2. KMA 예측성능 비교·평가 매트릭 자동화 시스템의 내용	2
가. 시스템 및 디렉토리 구조	2
3. 수행 절차	4
가. 흐름도	4
나. 수행방법	5
1) 시스템 설치	5
2) 시스템 수행	5
다. 파라미터	7
1) 총괄 쉘 스크립트 (Run_EAWM_hybrid.csh)	7
2) NCL 소스코드 내 공통 파라미터	8
라. KMA 계절내 예측성능 비교·평가 매트릭 자동화 시스템 내 부프로그램	8
4. 비교·평가 자동화 시스템 생산물	9
가. Climatology 재현성능 분석결과	9
나. 실시간 예측자료(forecast)	9
5. 참고문헌	9

1. 개요

가. 배경 및 목적

이음새 없는 기상예보를 위한 계절내 예측자료의 중요성에 대한 인식이 증가함에 따라 계절내 예측기술 향상을 위해 다양한 국제 연구들이 수행되고 있다. 그러나 이를 위해 생산되는 예측 데이터의 양이 방대할 뿐만 아니라 기후 모델 별 계절내 예측 시스템 프로토콜이 상이하다. 따라서 모델별 대등한 평가가 어렵고, 단기예측이나 장기예측과는 달리 자료처리 기법과 예측 정확도 평가 기법이 표준화 되어있지 않다. APCC에서는 WMO의 S2S prediction project database(Vitart et al., 2017)에서 수집되는 자료 중 목요일에 실시간 예측과 과거재현예측을 하는 3개 모델을 우선적으로 선정하여 계절내 예측 성능을 분석한 바 있다(문자연 등, 2018). 이를 기반으로 기상청 현업 기후예측모델인 GloSea5 (Global Seasonal Forecasting Model Version 5, 이하 KMA로 표현)의 예측성능을 비교평가하기 위한 시스템을 구축했다.

나. S2S 모델 소개

이 시스템에서 KMA와 비교평가를 위해 사용된 계절내 예측자료는 S2S prediction project database (Vitart et al., 2017)에서 수집되고 있는 자료이다. 현재 총 11개의 모델이 S2S 프로젝트를 위해 자료를 제공하고 있으며 본 연구에서는 그 중 세 모델(ECCC, ECMWF, NCEP)의 자료를 활용하였다(표 1). 세 모델은 예측날짜와 동일한 날짜에 과거재현자료를 제공하고 있으며, 세 모델 모두 매주 목요일에 예측을 수행한다. KMA 실시간 예측의 경우는 세 모델과 동일하게 예측초기날짜가 목요일인 예측자료를 사용하였고, 과거재현자료에 대해서는 1.다.에서 설명하겠다.

표 1 비교분석을 위해 사용된 S2S 모델

Center	Time Range	Resolution	Fcst.	Forecast	hcst.	hcst.	hcst.	hcst.
			Ens. Size	Frequency		Length	Frequency	Ens. Size
ECMWF	d 0-46	Tco639/319 L91	51	2/week (Mon, Thu)	on the fly	past 20 years	2/week (Mon, Thu)	11
ECCC	d 0-32	0.45x0.45 L40	21	weekly (Thu)	on the fly	1995-2014	Weekly (Thu)	4
NCEP	d 0-44	T126L64	16	daily	fix	1999-2010	Daily	4
KMA	d 0-60	N216L85	4	daily	on the fly	1991-2010	4/month (1, 9, 17, 25)	3

다. 검증을 위한 타겟주(target week) 선정 및 기후값 계산

이 시스템에서는 검증결과를 실제로 사용하는 수요자들의 입장에서 쉽게 사용할 수

있도록 검증시작일을 월요일로 선정하였다. 따라서 선행시간 5일인 월요일을 시작으로 7일씩 나누어 최대 4주까지 주평균 하였다. 기후값의 계산에 있어서, 과거예측자료의 양상 불 수가 실시간 예측에 비해 적은 문제점을 극복하기 위한 방안으로 예측시작일과 동일한 날짜를 기준으로 생산된 과거예측자료 포함하여 일주일 전, 후의 과거예측자료 총 3개를 평균하여 스무딩 된 기후값을 생산하였다(그림 1).

KMA 과거재현자료의 예측초기날짜는 목요일이 아닌 매 달 고정된 4개의 날짜이므로 (표 1 참고) KMA 실시간 예측이나 세 모델과는 달리 기후값을 계산하기 위해 타겟주(월요일-일요일)과 가장 가까운 3개의 예측초기날짜를 선택하여 요일을 기준으로 평균하는 Target 기준과 선행시간을 기준으로 평균하는 Lead 기준의 두 가지 방법이 제안되었다(표 2).




그림 1 ECCC, ECMWF, NCEP의 기후값을 구하기 위한 스무딩 방법의 예

표 2 KMA의 기후값을 구하기 위한 2가지 방법

Week	Target based	Lead based
Week 1	1 st Mon-Sun	5-11
Week 2	2 nd Mon-Sun	12-18
Week 3	3 rd Mon-Sun	19-25
Week 4	4 th Mon-Sun	26-32

2. KMA 예측성능 비교·평가 매트릭 자동화 시스템의 내용

가. 시스템 및 디렉토리 구조

앞서 언급한 대로, 이 시스템에서 사용되는 모델 자료는 S2S database에서 제공되는 자료로 APCC GB(/apccgb/APCC_S2S/)에 표준화 된 형식으로 저장되어 있다. 새로운 예측자료가 S2S database에 업로드 되면 자료를 다운로드 받아야 하나, 다운로드와 관련된 내용은 비교·평가 매트릭 자동화 시스템과 별개의 내용이기 때문에 이 메뉴얼에서는 제외한다. 따라서 이 비교 및 평가 시스템은 APCC GB에 구축되어 있는 자료를 처리하여 기후값과 실시간 예측 아노달리를 계산하고 관련된 데이터와 이미지를 생산하도록 구축되었다(그림 2 및 3).

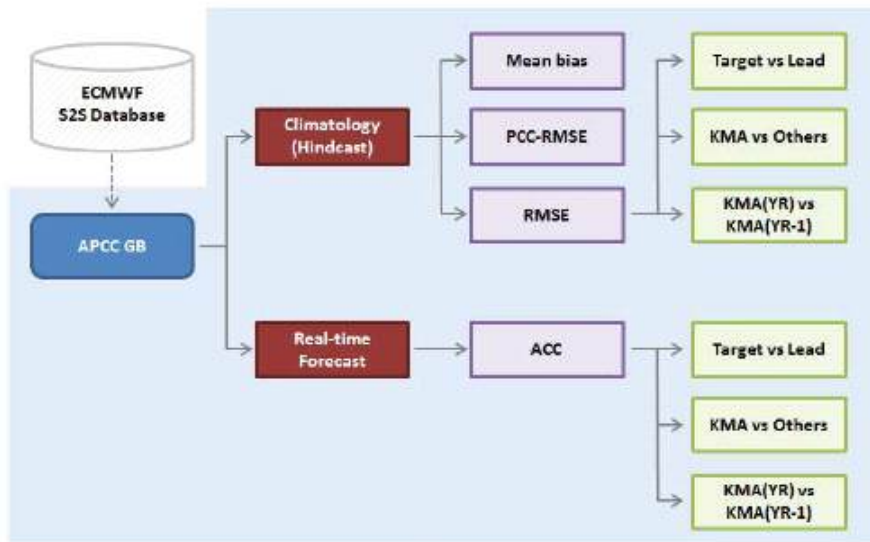


그림 2 KMA 예측성능 비교·평가 메트릭 자동화 시스템의 구조



그림 3 KMA 예측성능 비교·평가 메트릭 자동화 시스템 디렉토리 구조

- 소스코드 (NCL Version 6.4.0 기반)
 - `$(HOME)/NCL`
- 자동화 수행 셸스크립트 (csh 기반)
 - `$(HOME)/SHELL/Run_KMA_Verification.csh`: 총괄 셸 스크립트
- 결과 (NetCDF)
 - Hindcast
 - `$(HOME)/DATA/OUTPUT/$(FYEAR)/HINDCAST/v$(YEAR)`

- Forecast

\$\{HOME\}/DATA/OUTPUT/\{FY\}/FORECAST/v/\{YYYY\}

※ \$\{HOME\}\$: 홈 디렉토리

\$\{FY\}\$: 분석기준연도 (ex. 2018)

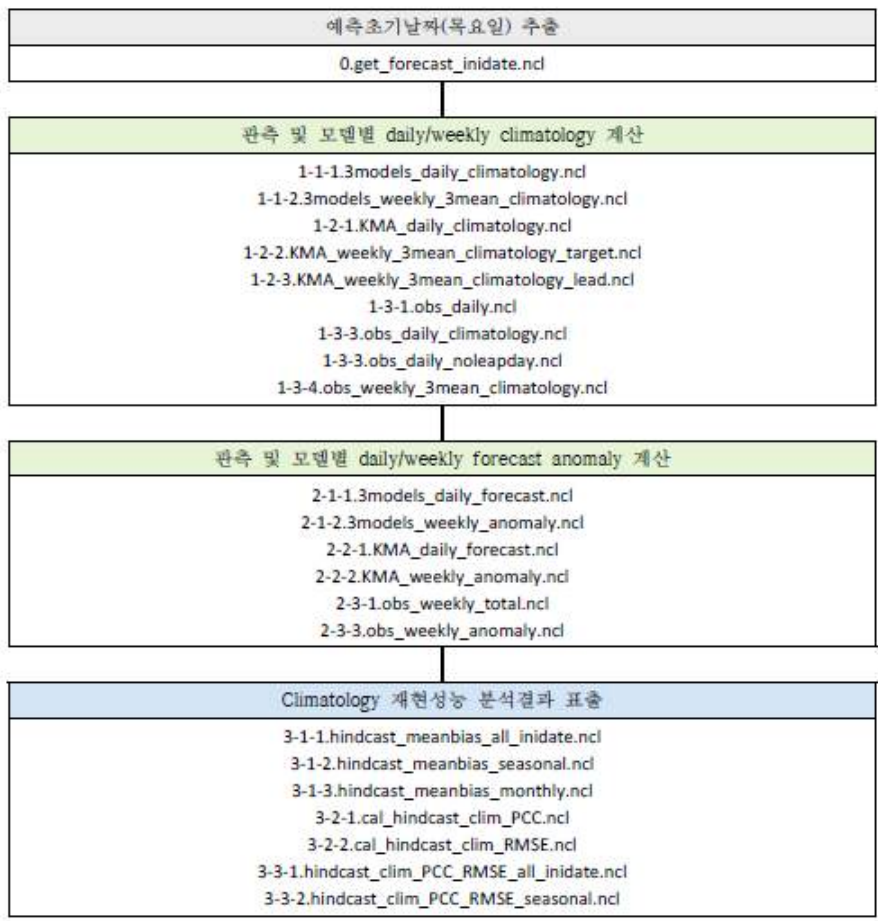
\$\{YYYY\}\$: 자료연도 (ex. 2018)

\$\{MODEL\}\$: 개별모델 및 MME

3. 수행 절차

가. 흐름도

- \$\{HOME\}/SHELL/Run_KMA_Verification.csh



```

3-3-3.hindcast_clim_PCC_RMSE_monthly.ncl
3-4-1.hindcast_clim_table_RMSE_method.ncl
3-4-2.hindcast_clim_table_RMSE_year.ncl
3-4-3-1.hindcast_table_RMSE_others_percentile_all_inidates.ncl
3-4-3-2.hindcast_table_RMSE_others_percentile_seasonal.ncl
3-4-3-3.hindcast_clim_table_RMSE_others.ncl

```

Forecast 성능 분석결과 표출

```

4-1-1.cal_forecast_ACC.ncl
4-2-1.forecast_ACC_all_inidate.ncl
4-2-2.forecast_ACC_seasonal.ncl
4-2-3.forecast_ACC_monthly.ncl
4-3-1.forecast_table_ACC_method.ncl
4-3-2.forecast_table_ACC_year.ncl
4-3-3-1.forecast_table_ACC_others_percentile_all_inidates.ncl
4-3-3-2.forecast_table_ACC_others_percentile_seasonal.ncl
4-3-3-3.forecast_table_ACC_others.ncl

```

나. 수행방법

1) 시스템 설치

설치를 원하는 디렉토리에 압축파일(KMA_S2S_Verify_v1.0.tar)을 복사한 후 해당파일의 압축을 풀어준다.

```

> cp KMA_S2S_Verify_v1.0.tar $(HOME)
> cd $(HOME)
> tar -xvf KMA_S2S_Verify_v1.0.tar
> ls
KMA_S2S_Verify_v1.0
> cd KMA_S2S_Verify_v1.0
> ls
NCL SHELL

```

2) 시스템 수행

```

> cd $(HOME)/SHELL
> csh Run_KMA_Verification.csh

```

```

#!/bin/csh
#####
# Verification system for GloSea5
# written by Gayoung Kim/20190820
#####
module load ncl/6.4.0

```

```

### 1. User Defined #####
set NowDate = `date -u +%Y%m` # (ex. 201901)

### 2. Set date #####
set FcstYear = `date -d "${NowDate}01 - 1 year" +%Y`
set sYear = 1999
set eYear = 2010

### 3. Set directories #####
set DirDATA = ../DATA
set DirINPUT = ${DirDATA}/INPUT/
set DirOUTPUT = ${DirDATA}/OUTPUT/
set DirNCL = ../NCL
set DirSHELL = ../SHELL/
set DirFIG = ../FIG/

cat > ${DirNCL}/common_info.ncl <<EOF
;--- directory -----
DirINPUT = "${DirINPUT}"
DirOUTPUT = "${DirOUTPUT}"
DirNCL = "${DirNCL}"
DirSHELL = "${DirSHELL}"
DirFIG = "${DirFIG}"

;--- parameters -----
FcstYear = ${FcstYear}
sYear = ${sYear}
eYear = ${eYear}
EOF

### 4. run initial date script #####
cd ${DirNCL}
echo "0 get forecast initial date"
ncl -Q ${DirNCL}/0.get_forecast_inidate.ncl

### 5. run Pre-processing for hindcast script #####
echo "1 Preprocessing for hindcast"
ncl -Q ${DirNCL}/1-1-1.3models_daily_climatology.ncl
ncl -Q ${DirNCL}/1-1-2.3models_weekly_3mean_climatology.ncl
ncl -Q ${DirNCL}/1-2-1.KMA_daily_climatology.ncl
ncl -Q ${DirNCL}/1-2-2.KMA_weekly_3mean_climatology_target.ncl
ncl -Q ${DirNCL}/1-2-3.KMA_weekly_3mean_climatology_lead.ncl
ncl -Q ${DirNCL}/1-3-1.obs_daily.ncl
ncl -Q ${DirNCL}/1-3-2.obs_daily_noleapday.ncl
ncl -Q ${DirNCL}/1-3-3.obs_daily_climatology.ncl
ncl -Q ${DirNCL}/1-3-4.obs_weekly_3mean_climatology.ncl

### 6. run Pre-processing for forecast script #####

```

```

echo "2 Preprocessing for forecast"
ncl -Q $(DirNCL)/2-1-1.3models_daily_forecast.ncl
ncl -Q $(DirNCL)/2-1-2.3models_weekly_anomaly.ncl
ncl -Q $(DirNCL)/2-2-1.KMA_daily_forecast.ncl
ncl -Q $(DirNCL)/2-2-2.KMA_weekly_anomaly.ncl
ncl -Q $(DirNCL)/2-3-1.obs_weekly_total.ncl
ncl -Q $(DirNCL)/2-3-2.obs_weekly_anomaly.ncl

### 7. draw climatology analysis script #####
echo "3 Draw climatoloy"
ncl -Q $(DirNCL)/3-1-1.hindcast_meanbias_all_inidate.ncl
ncl -Q $(DirNCL)/3-1-2.hindcast_meanbias_seasonal.ncl
ncl -Q $(DirNCL)/3-1-3.hindcast_meanbias_monthly.ncl
ncl -Q $(DirNCL)/3-2-1.cal_hindcast_clim_PCC.ncl
ncl -Q $(DirNCL)/3-2-2.cal_hindcast_clim_RMSE.ncl
ncl -Q $(DirNCL)/3-3-1.hindcast_clim_PCC_RMSE_all_inidate.ncl
ncl -Q $(DirNCL)/3-3-2.hindcast_clim_PCC_RMSE_seasonal.ncl
ncl -Q $(DirNCL)/3-3-3.hindcast_clim_PCC_RMSE_monthly.ncl
ncl -Q $(DirNCL)/3-4-1.hindcast_clim_table_RMSE_method.ncl
ncl -Q $(DirNCL)/3-4-2.hindcast_clim_table_RMSE_year.ncl
ncl -Q $(DirNCL)/3-4-3-1.hindcast_table_RMSE_others_percentile_all_inidates.ncl
ncl -Q $(DirNCL)/3-4-3-2.hindcast_table_RMSE_others_percentile_seasonal.ncl
ncl -Q $(DirNCL)/3-4-3-3.hindcast_clim_table_RMSE_others.ncl

### 8. draw forecast analysis script #####
echo "4 Draw forecast"
ncl -Q $(DirNCL)/4-1-1.cal_forecast_ACC.ncl
ncl -Q $(DirNCL)/4-2-1.forecast_ACC_all_inidate.ncl
ncl -Q $(DirNCL)/4-2-2.forecast_ACC_seasonal.ncl
ncl -Q $(DirNCL)/4-2-3.forecast_ACC_monthly.ncl
ncl -Q $(DirNCL)/4-3-1.forecast_table_ACC_method.ncl
ncl -Q $(DirNCL)/4-3-2.forecast_table_ACC_year.ncl
ncl -Q $(DirNCL)/4-3-3-1.forecast_table_ACC_others_percentile_all_inidates.ncl
ncl -Q $(DirNCL)/4-3-3-2.forecast_table_ACC_others_percentile_seasonal.ncl
ncl -Q $(DirNCL)/4-3-3-3.forecast_table_ACC_others.ncl

echo "... END ..."

```

다. 파라미터

- 1) 총괄 쉘 스크립트 (Run_EAWM_hybrid.csh)

파라미터	설명
NowDate	예측시스템 수행연월 (시스템에서 자동 추출)
FcstYear	예측연도
sHYear	공통 hindcast 시작연도 (1999)
eHYear	공통 hindcast 종료연도 (2010)
DirDATA	자료 디렉토리
DirINPUT	관측/모델별 daily 및 weekly climatology/forecast 디렉토리 (NetCDF)
DirOUTPUT	모델별 재현 및 예측성능 결과 디렉토리 (NetCDF)
DirNCL	NCL 소스코드 디렉토리
DirSHELL	C-Shell 스크립트 디렉토리
DirFIG	모델별 예측성능 비교평가 결과 이미지 디렉토리 (png)

2) NCL 소스코드 내 공통 파라미터

- \$HOME/NCL/common_info.ncl

총괄 셸 스크립트를 통해 NCL 디렉토리 안에 자동 생성된다.

파라미터	설명
DirINPUT	관측/모델별 daily 및 weekly climatology/forecast 디렉토리 (NetCDF)
DirOUTPUT	모델별 재현 및 예측성능 결과 디렉토리 (NetCDF)
DirNCL	NCL 소스코드 디렉토리
DirSHELL	C-Shell 스크립트 디렉토리
DirFIG	모델별 예측성능 비교평가 결과 이미지 디렉토리 (png)
FcstYear	예측연도
sHYear	공통 hindcast 시작연도 (1999)
eHYear	공통 hindcast 종료연도 (2010)

라. KMA 계절내 예측성능 비교평가 매트릭 자동화 시스템 내 부프로그램

- \$HOME/NCL/Subprograms.ncl

사용자 정의 함수	설명
Models_Initial_Date	세 모델의 예측초기날짜 추출
KMA_Initial_Date	KMA의 기후값 계산을 위한 hindcast 예측초기날짜 추출
Write_Model_TLL	모델자료를 NetCDF로 쓰기 (time, lat, lon)
Write_Model_TD	모델자료를 NetCDF로 쓰기 (domain, time)
Write_Model_T	모델자료를 NetCDF로 쓰기 (time)
Write_Model_Week	모델자료를 NetCDF로 쓰기 (week)
Write_Obs_TLL	관측자료를 NetCDF로 쓰기 (time, lat, lon)

※ 이 외의 함수는 table plot을 위한 것으로, ncl 홈페이지 내 table_8.ncl를 참고할 것.

4. 비교-평가 자동화 시스템 생산물

가. Climatology 재현성능 분석결과

- 디렉토리: OUTPUT/S{FYYY}/HINDCAST/v{YYYY}/

검증방법		설명
Mean bias	-	각 모델의 연도별/계절별/월별 mean bias
Clim	PCC	각 모델의 연도별/계절별/월별 기후값의 PCC
	RMSE	각 모델의 연도별/계절별/월별 기후값의 RMSE
	RMSE_percentile	기후값의 RMSE를 이용한 25 th /75 th percentile 값

나. 실시간 예측자료(forecast)

- 디렉토리: OUTPUT/S{FYYY}/FORECAST/v{YYYY}/

검증방법	설명
ACC	각 모델의 연도별/계절별/월별 실시간 예측자료의 ACC
ACC_percentile	실시간 예측자료의 ACC를 이용한 25 th /75 th percentile 값


5. 참고문헌

Vitart, F., and Coauthors (2017), The Subseasonal to Seasonal Prediction (S2S) project database. Bull. Amer. Meteor. Soc., 98, 163-173.


문자연, 오지현, 이윤영, 김가영, 윤순조 (2018), 아태지역 15-60일 MME 예측 기술 개발 및 검증 기술 개발, APEC기후센터 연구보고서 2018-08, APEC기후센터.

부록 B. 계절내 예측모델의 기후값 재현성능(RMSE-PCC)


(a) MAM T2M




(b) JJA T2M




(c) SON T2M




(d) DJF T2M




(e) MAM PREC




(f) JJA PREC




(g) SON PREC




(h) DJF PREC




(i) MAM Z500





(j) JJA Z500



(k) SON Z500



(l) DJF Z500



부록 C.

GloSea5 자료처리 시스템 매뉴얼

2019년 12월

APEC 기후센터 기후사업본부
예측기술과 정여민

차 례

I. 서론	1
II. 주요 내용	1
1. GloSea5 원시자료 전처리	1
2. GloSea5 및 재분석 자료 후처리	1
3. 추가 실험 오차 진단 매트릭	2
III. 자료처리 시스템	3
1. 디렉토리 구조 및 코드 설명	3
1) 디렉토리 구조	3
2) 코드 설명	3
2. 흐름도	5
3. 수행 방법	6
1) GloSea5 자료처리 시스템 설치	6
2) 파라미터 설정	6
3) GloSea5 자료처리 시스템 수행	7
참고문헌	7

I 서론

APEC 기후센터 (APEC Climate Center, 이하 APCC) 기후사업본부에서는 2019년부터 기상청 기후예측시스템 (KMA-Met Office Joint Seasonal Forecasting System) 인 GloSea5 (Global Seasonal Forecast System version5) 모델의 계절내 (Subseasonal to seasonal) 예측결과 오차 분석 및 해석을 통한 개선 지원 업무를 진행 중이다. 따라서, 모델 결과 분석의 신속성과 정확성을 위해 자료처리 자동화 시스템의 필요성이 높아졌고, 이에 GloSea5 모델의 연구 활용성을 증대시키기 위한 자료처리 시스템 및 추가 실험 오차 분석 매트릭을 개발하였다. 해당 자료처리 시스템은 모델 결과의 원시자료를 기후 연구에 적합한 형태로 변환하고, 계절내 시간규모의 연구에서 활용이 용이한 선행 시간 및 앙상블에 따른 결과물을 재생산한다. 또한, 추가되는 모델 실험 결과의 초기장 및 계통 오차 진단 수행이 가능한 매트릭을 개발하여, 추후 연구에 지속적으로 활용하고자 한다.

II 주요내용

1. GloSea5 원시자료 전처리 [Step 1]

GloSea5 계절내 예측 결과의 원시자료는 ieee 표준 형식이며, 기후 연구에 활용성이 높은 NetCDF 형태로의 변환 과정이 필요하다. 이 과정은 전처리 과정의 첫 번째 단계로 수행된다. 그리고, 분석을 위해 재분석자료와 공간해상도 및 시간 단위를 통일하는 두 번째 단계를 수행한다. 전처리 과정을 거쳐, 해당 자료는 1.5°×1.5° 공간해상도의 60일 시간자료로 변환된다.

- 결과 예시 : GS_{YYYYMMDD}_apf_{ENS}.nc
- 변수 정보 : VAR [time(60), lat(121), lon(240)]

2. GloSea5 및 재분석 자료 후처리 [Step 2]

GloSea5 계절내 예측 결과의 분석은 매달 1일, 9일, 17일, 25일 초기장을 사용한 3개 앙상블의 60일 적분 결과를 사용한다. 계절내 예측 시간 규모의 분석을 위해 모델 선행시간 (1주~8주) 에 따른 계절자료 (MAM, JJA, SON, DJF) 아노말로로 재생산한다. 계절내 예측 시간 규모의 계절자료 생산을 위한 초기장 정보를 그림 1에 제시하였다. 비교 분석을 위해 재분석 자료(ERA-Interim)를 이용한 계절자료는 모델의 1주 선행시간에 결과와 동일하게 설정하고, 선행시간 (1주~8주)에 따른 12개 계절내 예측 자료의 7일 예측에 맞춰 총 84일로 생산된다.

II

주요내용

- 결과 예시 : GS_{변수명}_{YYYYY-EYYYY}_{SEASON}.nc
- 변수 정보 : VAR [year(20), lead week(8), ens(3), lat(121), lon(240)]

JJA	Initial time											
1W	06-01	06-09	06-17	06-25	07-01	07-09	07-17	07-25	08-01	08-09	08-17	08-25
2W	05-25	06-01	06-09	06-17	06-25	07-01	07-09	07-17	07-25	08-01	08-09	08-17
3W	05-17	05-25	06-01	06-09	06-17	06-25	07-01	07-09	07-17	07-25	08-01	08-09
4W	05-09	05-17	05-25	06-01	06-09	06-17	06-25	07-01	07-09	07-17	07-25	08-01
5W	05-01	05-09	05-17	05-25	06-01	06-09	06-17	06-25	07-01	07-09	07-17	07-25
8W	04-09	04-17	04-25	05-01	05-09	05-17	05-25	06-01	06-09	06-17	06-25	07-01

그림 1. GloSea5 계절내 예측결과와의 계절 분석에 활용되는 초기장 정보이며, 1W은 1주 선행시간을 의미함(예시: JJA)

3. 추가 실험 오차 진단 매트릭 [Step 3]

GloSea5는 기상청의 기후예측시스템으로 현업에 활용됨에 따라, Hindcast 결과가 지속적으로 업데이트 되고 있으며, 모델 개선을 위한 다양한 민감도 실험 결과도 생산된다. 해당 자료의 분석에 앞서, 추가 실험의 초기장 오차 진단 및 기본 예측성 분석을 통해 추가 실험의 신뢰성을 확보하고 활용성을 증대시킬 수 있다. 기존 Hindcast 대비 1주 선행시간에 대한 500hPa 지위고도(Z500) 월별 RMSE와 ACC를 산출하고 가시화하여 신속한 진단을 수행한다.

- 결과 예시 : GS_Monthly_Z500_{YYYYY-EYYYY}.nc
- 변수 정보 : Z500 [year(-), month(12), lat(121), lon(240)]




그림 2. GloSea5 및 재분석자료 검증 결과 예시 (systematic errors)




그림 3. 추가 실험 오차 진단 결과 예시

III 자료처리 시스템

1. 디렉토리 구조 및 코드 설명

1) 디렉토리 구조




그림 4. GloSea5 자료처리 시스템 디렉토리 구조

2) 코드 설명

[Step 1]

- `$(HOME)/SCR`
1.convert2nc.csh
: GloSea5 원시자료 형태 변환 (ieee→NetCDF)
- 결과 `$(HOME)/DATA/PRE/RAW_nc`
※ 주의 | 결과파일 당 4.5GB 용량이므로 해당 디렉토리 가용 사용량 확인
작업시 HPC CPU 소모량이 크기 때문에 PBS 사용 권장
- `$(HOME)/NCL`
2-1.interpolation_spatial_mod.ncl
: GloSea5 공간 내삽 ($1.5^{\circ} \times 1.5^{\circ}$)
- 결과 `$(HOME)/DATA/PRE/POST_nc`
2-2.interpolation_temporal_mod.ncl
: GloSea5 시간 내삽 (6hourly data→ daily data, 일부 강수 관련 변수)
- 결과 `$(HOME)/DATA/PRE/POST_nc`

III 자료처리 시스템

[Step 2]

- \$(HOME)/NCL
 - 3-1.mk_s2s_seasonal_anomaly_mod.ncl
 - : GloSea5 선행시간 및 이상불 분석이 용이한 계절자료 생산
 - 결과 \$(HOME)/DATA/OUT/ANO
 - 3-2.mk_s2s_seasonal_anomaly_obs.ncl
 - : GloSea5와 비교 분석이 용이한 형태로 ERA-Interim 계절자료 생산
 - 결과 \$(HOME)/DATA/OUT/ANO
 - 4-1.verify_systematic_errors.ncl
 - : GloSea5 및 ERA-Interim 후처리 검증용 위한 계통 오차 산출
 - 결과 \$(HOME)/DATA/OUT/FIG
 - 4-2.draw_systematic_errors.ncl
 - : GloSea5 및 ERA-Interim 후처리 검증용 위한 계통 오차 가시화
 - 결과 \$(HOME)/DATA/OUT/FIG

[Step 3]

- \$(HOME)/NCL
 - 5-1.mk_s2s_monthly_anomaly_mod.ncl
 - : GloSea5 추가실험 오차 진단을 위한 1주 선행시간의 월자료 생산
 - 결과 \$(HOME)/DATA/OUT/ANO
 - 5-2.mk_s2s_monthly_anomaly_obs.ncl
 - : GloSea5와 비교 분석이 용이한 형태로 ERA-Interim 월자료 생산
 - 결과 \$(HOME)/DATA/OUT/ANO
 - 6-1.diagnose_errors.ncl
 - : Hindcast 대비 1주 선행시간의 월별 ACC 및 RMSE 산출
 - 결과 \$(HOME)/DATA/FIG
 - 6-2.draw_diagnosis_errors.ncl
 - : Hindcast 대비 1주 선행시간의 월별 ACC 및 RMSE 가시화
 - 결과 \$(HOME)/DATA/FIG

[자동화 코드]

- \$(HOME)/SCR
 - Run_GloSea5_Preprocess.csh
 - : Step1~Step3 총괄 스크립트
 - ※ 주의 | 작업시 HPC CPU 소모량이 크기 때문에 PBS 사용 권장

III 자료처리 시스템

2. 흐름도

- `$(HOME)/SCR/Run_GloSea5_Preprocess.csh`



III 자료처리 시스템

3. 수행방법

1) GloSea5 자료처리 시스템 설치

```
> cp GloSea5_Preprocess.tar ${HOME}
> cd ${HOME}
> tar -xvf GloSea5_Preprocess.tar
> ls
DATA FIG GloSea5_Preprocess.tar NCL SCR
```

2) 파라미터 설정

```
> cd ${HOME}/NCL
> vi 0.Parameter.Users.ncl
```

```
begin
;=====
; Set Parameter
;=====
nYear = 20
nlat  = 121
nlon  = 240
sYear = 1991
eYear = 2010
init  = 12
week  = 8
ens   = 3

;=====
; Set Directories
;=====
DirSCR = "./SCR/"
DirNCL = "./NCL/"
DirFIG = "./FIG/"
DirPRE = "./DATA/PRE/"
DirOUT = "./DATA/OUT/"
DirOBS = "/apccgb/APCC_S2S/RAW/OBS/ERA-Interim/1p5d/"
DirMOD = "/apccgb/APCC_S2S/PRE/HINDCAST/Seoul/v2018/"

;=====
; Set Seasonal initial data | No need to change
;=====
...
```

III 자료처리 시스템

3) GloSea5 자료처리 시스템 수행

```
> cd ${HOME}/SCR
> csh Run_GloSea5_Preprocess.csh
```

```
### [Step 0] #####
set DirSCR = ./
set DirNCL = ../NCL/
set DirDATA = ../DATA/
set DirFIG = ../FIG/

### [Step 1] #####
echo "1 Convert to NetCDF"
csh ${DirSCR}/1.convert2nc.csh

echo "2 Interpolation"
ncl -Q ${DirNCL}/2-1.interpolation_spatial_mod.ncl
ncl -Q ${DirNCL}/2-2.interpolation_temporal_mod.ncl

### [Step 2] #####
echo "3 Make s2s seasonal anomaly"
ncl -Q ${DirNCL}/3-1.mk_s2s_seasonal_anomaly_mod.ncl
ncl -Q ${DirNCL}/3-2.mk_s2s_seasonal_anomaly_obs.ncl

echo "4 Calculate systematic errors"
ncl -Q ${DirNCL}/4-1.verify_systematic_errors.ncl
ncl -Q ${DirNCL}/4-2.draw_systematic_errors.ncl

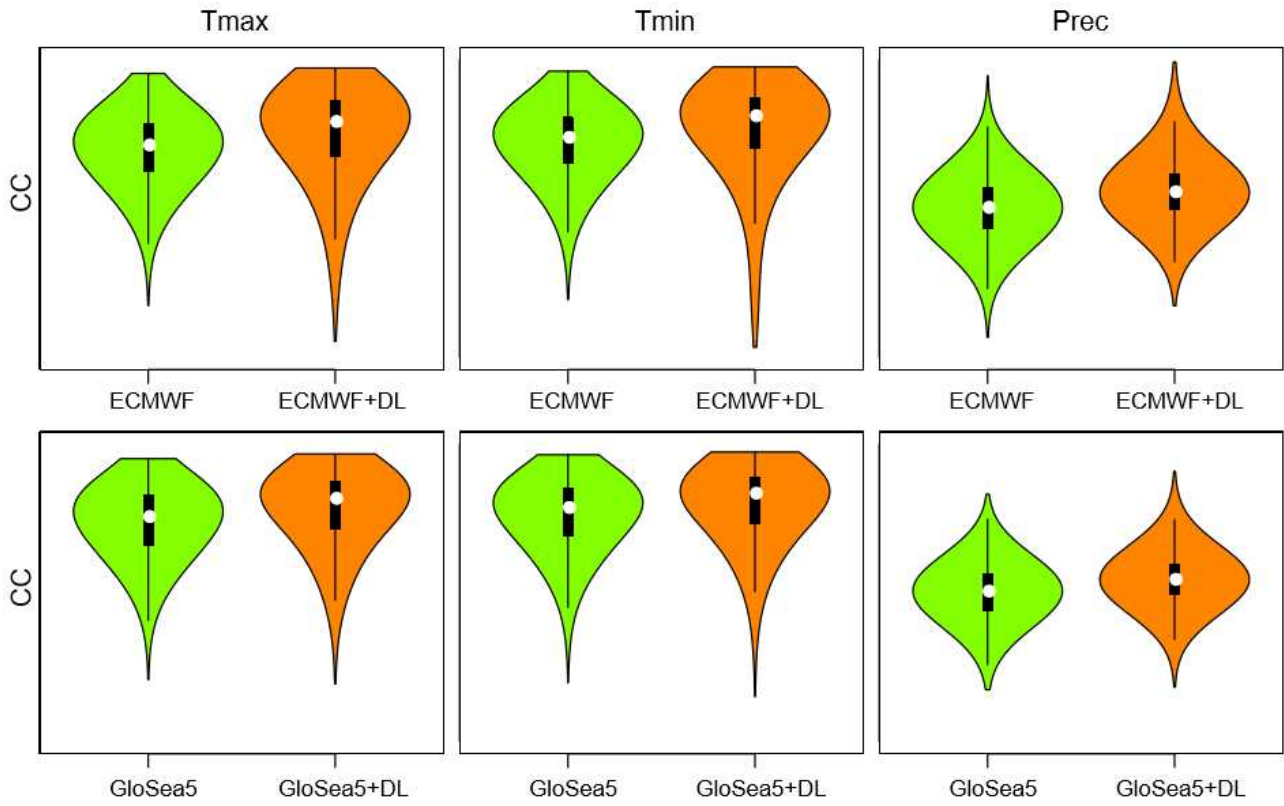
### [Step 3] #####
echo "5 Make s2s monthly anomaly"
ncl -Q ${DirNCL}/5-1.mk_s2s_monthly_anomaly_mod.ncl
ncl -Q ${DirNCL}/5-2.mk_s2s_monthly_anomaly_obs.ncl

echo "6 Diagnose 1week errors"
ncl -Q ${DirNCL}/6-1.diagnose_errors.ncl
ncl -Q ${DirNCL}/6-2.draw_diagnosis_errors.ncl
echo "-- END --"
```


※ 참고문헌

신선희, 김가영, 2018, 동아시아 겨울문순지수 하이브리드 예측시스템 운영매뉴얼, APEC 기후센터
함수련, 정여민, 2019, GloSea5 기술 보고서(I), APEC 기후센터


부록 D.




Supplementary Figure 1. Overall performance (Correlation coefficient) before and after applying LSTM.




Supplementary Figure 2. Comparison of correlation among machine learning algorithms.



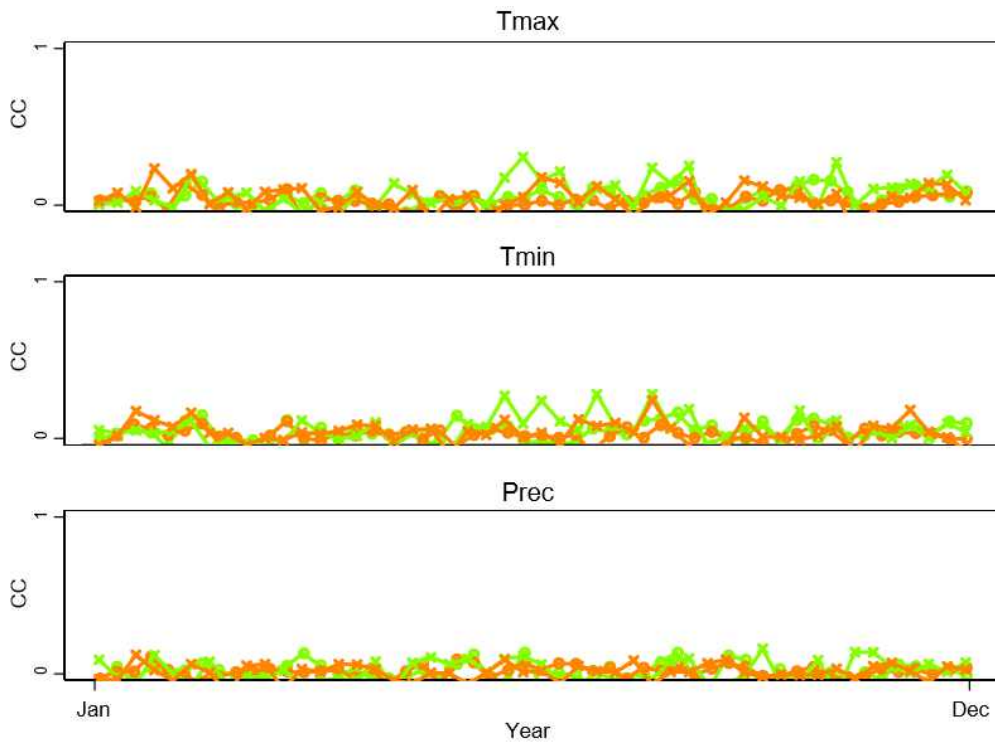
Supplementary Figure 3. Comparison of daily performance (CC) across entire forecast lead time.



Supplementary Figure 4. Weekly performance (CC) before and after applying LSTM algorithms to ECMWF and GloSea5.



Supplementary Figure 5. Seasonality of S2S-Deep learning prediction measured by CC (entire forecast lead time).



Supplementary Figure 6. Seasonality of S2S-Deep learning prediction measured by CC (week 3 forecast).

Supplementary Table 1. R program code for S2S-LSTM learning.

```

library("readr");
library("dplyr");
library("mxnet");
library("abind");
library("stringr");
library("Metrics");

S2S_DL <- function(grid_num, releaseDate, bat_size, tr_val_ratio, num_rnn_layer,
bidirectional, num_hidden, cell_type){
years = 1998:2017; # ECMWF
grid_num = "grid1";
releaseDate = "05-10";
releaseYearDates = paste0(years, "-", releaseDate);
num_rnn_layer = 1;
bidirectional = F;
num_hidden = 5;
cell_type = "lstm";

glosea5 <- read.table(file = paste0("processed_ECMWF/", grid_num, "_",
str_replace_all(releaseDate, "-", ""), ".txt"), header = TRUE, sep = "\t", row.names=NULL);

# Reorganize the table.
for (i in 1:20){
  print ((i-1)*176+1);
  temp = glosea5[((i-1)*176+1):((i-1)*176+176), ]; # each 176 rows (16 var X 11 cf/pf
runs)
  if (temp[1,1] != "cf_MSLP") print("***** Error on the data *****");
  for (r in 1:176){
    if (str_detect(temp[r,1], "1th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"1_pf"), "_1th", "");
    if (str_detect(temp[r,1], "2th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"2_pf"), "_2th", "");
    if (str_detect(temp[r,1], "3th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"3_pf"), "_3th", "");
    if (str_detect(temp[r,1], "4th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"4_pf"), "_4th", "");
    if (str_detect(temp[r,1], "5th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"5_pf"), "_5th", "");
    if (str_detect(temp[r,1], "6th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"6_pf"), "_6th", "");
    if (str_detect(temp[r,1], "7th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",

```

```

"7_pf"), "_7th", "");
  if (str_detect(temp[r,1], "8th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"8_pf"), "_8th", "");
  if (str_detect(temp[r,1], "9th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"9_pf"), "_9th", "");
  if (str_detect(temp[r,1], "10th")) temp[r,1] = str_replace(str_replace(temp[r,1], "pf",
"10_pf"), "_10th", "");
}
temp = temp[order(temp[,1]),];
glosea5[((i-1)*176+1):((i-1)*176+176), ] = temp;
}
glosea5[is.na(glosea5)] <- 0
glosea5 <- glosea5[, -1]; # Delete variable names

# normalise each feature to range(0,1)
glosea5 <- matrix(as.matrix(glosea5), ncol = ncol(glosea5), dimnames = NULL)
rangenorm <- function(x) {
  (x - min(x))/(max(x) - min(x))
}
glosea5 <- apply(glosea5, 1, rangenorm);
dim(glosea5); # 46 x 3520
glosea5 <- t(glosea5);

# convert training data to the form (n_dim x seq_len x num_samples)
n_dim <- 16
seq_len <- 46
num_samples <- 220 # 20 years X 11 runs
trainX <- matrix(rep(0, n_dim*seq_len*num_samples), n_dim, seq_len * num_samples);
dim(trainX) <- c(n_dim, seq_len, num_samples);
for (i in 1:num_samples){
  cat (i, (1+ n_dim*(i-1)), (n_dim*i), "\n", sep="\t");
  trainX[, , i] <- glosea5[((1+ n_dim*(i-1)):(n_dim*i), );
}
glosea5[1, ] == trainX[1, , 1];
glosea5[17, ] == trainX[1, , 2];
glosea5[33, ] == trainX[1, , 3];
glosea5[305, ] == trainX[1, , 20];

## Response variable (ERA interim)
era <- read.table(paste0("processed_ERAIinterim/", grid_num, "_Tmax.txt"),
stringsAsFactors=F, sep="\t");
era$V2 = rangenorm(era$V2);

```

```

trainY <- matrix(rep(0, seq_len*num_samples), seq_len, num_samples);

for (i in 1:20){    # 20years for the training set
  start = which(era$V1 == releaseYearDates[i]);
  end = which(era$V1 == (as.Date(releaseYearDates[i])+45));
  cat (i, start, end, "\n", sep="\t");
  trainY[, (i-1)*11 + 1] <- era[start:end, 2];
  trainY[, (i-1)*11 + 2] <- era[start:end, 2];
  trainY[, (i-1)*11 + 3] <- era[start:end, 2];
  trainY[, (i-1)*11 + 4] <- era[start:end, 2];
  trainY[, (i-1)*11 + 5] <- era[start:end, 2];
  trainY[, (i-1)*11 + 6] <- era[start:end, 2];
  trainY[, (i-1)*11 + 7] <- era[start:end, 2];
  trainY[, (i-1)*11 + 8] <- era[start:end, 2];
  trainY[, (i-1)*11 + 9] <- era[start:end, 2];
  trainY[, (i-1)*11 + 10] <- era[start:end, 2];
  trainY[, (i-1)*11 + 11] <- era[start:end, 2];
}

### Train model, predict, evaluate performance
batch.size <- bat_size;
shuffle_index <- sample(1:ncol(trainY));
trainX <- trainX[,shuffle_index];
trainY <- trainY[,shuffle_index];
folds <- cut(seq(1,ncol(trainY)),breaks=10,labels=FALSE)

allIndex = 1:ncol(trainY);
for(cv in 1:10){
  cat (cv, "-th cross-validation\n");
  #Segement your data by fold using the which() function
  testIndexes <- which(folds==cv,arr.ind=TRUE);
  remainIndexes <- allIndex[!(allIndex %in% testIndexes)];
  valIndexes = sample (remainIndexes, as.integer(length(allIndex) * tr_val_ratio));
  trainIndexes <- remainIndexes[!(remainIndexes %in% valIndexes)];

  train_ids <- trainIndexes;
  eval_ids <- valIndexes;

  train.data <- mx.io.arrayiter(data = trainX[, , train_ids, drop = F], label = trainY[,
train_ids],
                                batch.size = batch.size, shuffle = TRUE)
  eval.data <- mx.io.arrayiter(data = trainX[, , eval_ids, drop = F], label = trainY[,
eval_ids],

```

```

        batch.size = batch.size, shuffle = FALSE)
    symbol <- rnn.graph(num_rnn_layer = num_rnn_layer, bidirectional = bidirectional,
num_hidden = num_hidden, input_size = NULL, num_embed = NULL, num_decode = 1,
masking = F, loss_output = "linear", dropout = 0.2, ignore_label = -1, cell_type = cell_type,
output_last_state = T, config = "one-to-one");
    mx.metric.mse.seq <- mx.metric.custom("MSE", function(label, pred) {
        label = mx.nd.reshape(label, shape = -1)
        pred = mx.nd.reshape(pred, shape = -1)
        res <- mx.nd.mean(mx.nd.square(label - pred))
        return(as.array(res))
    })
    ctx <- mx.cpu()
    initializer <- mx.init.Xavier(rnd_type = "gaussian", factor_type = "avg", magnitude = 3)
    optimizer <- mx.opt.create("adadelta", rho = 0.9, eps = 1e-05, wd = 1e-06, clip_gradient
= 1, rescale_grad = 1/batch.size)
    logger <- mx.metric.logger()
    epoch.end.callback <- mx.callback.log.train.metric(period = 10,logger = logger)

    system.time(model <- mx.model.buckets(symbol = symbol, train.data = train.data,
eval.data = eval.data,
                                num.round = 100, ctx = ctx, verbose = TRUE,
                                metric = mx.metric.rmse, initializer = initializer,
optimizer = optimizer,
                                batch.end.callback = NULL, epoch.end.callback =
epoch.end.callback))

    internals <- model$symbol$get.internals()
    internals$outputs:
    sym_state <- internals$get.output(which(internals$outputs %in% "rnn.state"));
    sym_state_cell <- internals$get.output(which(internals$outputs %in% "rnn.state.cell"))
    sym_output <- internals$get.output(which(internals$outputs %in% "loss_output"))
    symbol <- mx.symbol.Group(sym_output, sym_state, sym_state_cell)

    for (i_test in 1:length(testIndexes)){
        forecast_sample = testIndexes[i_test];
        print(forecast_sample);
        pred_length <- nrow(trainY);
        predicted <- numeric()
        data <- mx.nd.array(trainX[, , forecast_sample, drop = F])
        label <- mx.nd.array(trainY[, forecast_sample, drop = F])
        infer.data <- mx.io.arrayiter(data = data,label = label,batch.size = 1,shuffle = FALSE)
        infer <- mx.infer.rnn.one(infer.data = infer.data,symbol = symbol,arg.params =
model$arg.params,

```

```

                                aux.params = model$aux.params,input.params = NULL,ctx
= ctx)

    actual <- trainY[, forecast_sample];

    for (i in 1:pred_length) {
        data_pred <- mx.nd.array(trainX[, i, forecast_sample, drop = F])
        label_pred <- mx.nd.array(trainY[i, forecast_sample, drop = F])
        infer.data <- mx.io.arrayiter(data = data_pred, label = label_pred, batch.size =
1, shuffle = FALSE)
        infer <- mx.infer.rnn.one(infer.data = infer.data,symbol = symbol,ctx =
ctx,arg.params = model$arg.params,
                                aux.params = model$aux.params, input.params =
list(rnn.state = infer[[2]],
                                rnn.state.cell = infer[[3]]))

        pred <- infer[[1]]
        predicted <- c(predicted, as.numeric(as.array(pred)))
    }
    cor(actual, trainX[7, , forecast_sample]);
    rmse(actual,predicted);
    rmse(actual, trainX[7, , forecast_sample]);

    cat(forecast_sample, actual, "\n", file = paste0("DL_output_ECMWF_Tmax/", grid_num,
"_, releaseDate, "_", bat_size, "_", tr_val_ratio,
                                "_", num_rnn_layer,
"_, bidirectional, "_", num_hidden, "_", cell_type, "_ERA.txt"), sep = "\t", append = T);
    cat(forecast_sample, predicted, "\n", file = paste0("DL_output_ECMWF_Tmax/",
grid_num, "_", releaseDate, "_", bat_size, "_", tr_val_ratio,
                                "_",
num_rnn_layer, "_", bidirectional, "_", num_hidden, "_", cell_type, "_DL.txt"), sep = "\t",
append = T);
    cat(forecast_sample, trainX[7, , forecast_sample], "\n", file =
paste0("DL_output_ECMWF_Tmax/", grid_num, "_", releaseDate, "_", bat_size, "_", tr_val_ratio,
                                "_", num_rnn_layer, "_", bidirectional, "_", num_hidden, "_",
cell_type, "_S2S.txt"), sep = "\t", append = T);

    }
}

return:
}

```

Supplementary Table 2. Python program code for S2S-LSTM learning.

```

# multi-step lstm
from math import sqrt
from numpy import split
from numpy import array
from pandas import read_csv

from pandas import DataFrame
from sklearn.metrics import mean_squared_error
from matplotlib import pyplot
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import Flatten
from keras.layers import LSTM

# set filename suffix
replicate = 1

# train/test sets
def split_dataset(data):
train, test = data[1:5482], data[5483:7303]
return train, test

# evaluate
def evaluate_forecasts(actual, predicted):
# calculate an RMSE score
scores = list()
for i in range(actual.shape[1]):
# calculate mse
mse = mean_squared_error(actual[:, i], predicted[:, i])
# calculate rmse
rmse = sqrt(mse)
scores.append(rmse)
s = 0
for row in range(actual.shape[0]):
for col in range(actual.shape[1]):
s += (actual[row, col] - predicted[row, col])**2
score = sqrt(s / (actual.shape[0] * actual.shape[1]))
return score, scores
# summarize scores
def summarize_scores(name, score, scores):
s_scores = ', '.join(['%.1f' % s for s in scores])
print('%s: [%.3f] %s' % (name, score, s_scores))

```

```

# convert history into inputs and outputs
def to_supervised(train, n_input, n_out=1):
    data = train.reshape((train.shape[0]*train.shape[1], train.shape[2]))
    X, y = list(), list()
    in_start = 0

# train the model
def build_model(train, n_input):
    # prepare data
    train_x, train_y = to_supervised(train, n_input)
    # define parameters
    verbose, epochs, batch_size = 0, 70, 16
    n_timesteps, n_features, n_outputs = train_x.shape[1], train_x.shape[2], train_y.shape[1]
    # define model
    model = Sequential()
    model.add(LSTM(200, activation='relu', input_shape=(n_timesteps, n_features)))
    model.add(Dense(100, activation='relu'))
    model.add(Dense(n_outputs))
    model.compile(loss='mse', optimizer='adam')
    model.fit(train_x, train_y, epochs=epochs, batch_size=batch_size, verbose=verbose)
    # plot
    pyplot.plot(history.history['loss'], label='train')
    pyplot.plot(history.history['val_loss'], label='test')
    pyplot.legend()
    pyplot.title('model loss')
    pyplot.ylabel('loss')
    pyplot.xlabel('epoch')
    pyplot.savefig('C:/Users/ZestPC/Downloads/20190619_DL_ / /save_fig_loss' + str(replicate) +
'.png', dpi=100)
    pyplot.show()

    pyplot.plot(history.history['acc'], label='train')
    pyplot.plot(history.history['val_acc'], label='test')
    pyplot.legend()
    pyplot.title('model accuracy')
    pyplot.ylabel('accuracy')
    pyplot.xlabel('epoch')
    pyplot.savefig('C:/Users/ZestPC/Downloads/20190619_DL_ / /save_fig_accuracy' +
str(replicate) + '.png', dpi=100)
    pyplot.show()

# save text files

```

```

sys.stdout.write('C:/Users/ZestPC/Downloads/20190619_DL_ / /save_LSTM_v3_summary' +
str( replicate) + '.txt')
sys.stdout = open('C:/Users/ZestPC/Downloads/20190619_DL_ / /save_LSTM_v3_summary' +
str( replicate) + '.txt', 'a')
model.summary()
return model

# prediction
def forecast(model, history, n_input):
# data
data = array(history)
data = data.reshape((data.shape[0]*data.shape[1], data.shape[2]))
# retrieve last observations for input data
input_x = data[-n_input:, 0]
# reshape into [1, n_input, 1]
input_x = input_x.reshape((1, len(input_x), 1))
# predict the day
yhat = model.predict(input_x, verbose=0)
yhat = yhat[0]
return yhat

# evaluate a single model
def evaluate_model(train, test, n_input):
# build model
model = build_model(train, n_input)
# daily data
history = [x for x in train]
# walk-forward validation
predictions = list()

for i in range(len(test)):
# predict the week
yhat_sequence = forecast(model, history, n_input)
# append/s the predictions
predictions.append(yhat_sequence)
# get real observation and add to daily data for predicting
history.append(test[i, :])
# evaluate predictions days
predictions = array(predictions)
score, scores = evaluate_forecasts(test[:, :, 0], predictions)

for j in range(len(predictions)):
print("testVari=%s, Predicted=%s" % (test[j], predictions[j]))

```

```

numpy.savetxt('C:/Users/ZestPC/Downloads/20190619_DL_ / /save_LSTM_v3_predicted_' +
str(replicate) + '.csv',predictions, delimiter=',')
return score, scores

# load the new file
dataset = read_csv('C:/Users/ZestPC/Downloads/20190619_DL_ / /v3_ECMWF.csv',
header=0, infer_datetime_format=True, parse_dates=['datetime'], index_col=['datetime'])
# split into train and test
train, test = split_dataset(dataset.values)
# evaluate model and get scores
n_input = 1
score, scores = evaluate_model(train, test, n_input)
# summarize scores
summarize_scores('lstm', score, scores)
# store files
with open("C:/Users/ZestPC/Downloads/20190619_DL_ / /save_LSTM_v3_test_" +
str(replicate) + ".csv", "w") as out_test:
for i in range(len(test)):
out_string = ""
out_string += str(test[i])
out_string += "\n"
out_test.write(out_string)
with open("C:/Users/ZestPC/Downloads/20190619_DL_ / /save_LSTM_v3_score_" +
str(replicate) + ".txt", "w") as out_score:
for i in range(len(scores)):
out_string2 = ""
out_string2 += str(scores[i])
out_string2 += "\n"
out_score.write(out_string2)

#sys.stdout.close()

```

Supplementary Table 11. Prediction performance with single input variable (ECMWF-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP	pre	0.08758	0.04494
PREC			0.12083
T2M			0.02243
U850			0.06988
V850			0.06957
MSLP	T2M	0.2363	0.08047
PREC			-0.01789
T2M			0.33190
U850			0.09903
V850			0.10218

Supplementary Table 12. Prediction performance with two input variables (ECMWF-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC	pre	0.08758	0.4698
MSLP, T2M			0.04834
MSLP, U850			0.04538
MSLP, V850			0.04170
PREC, T2M			0.10790
PREC, U850			0.10770
PREC, V850			0.12210
T2M, U850			0.02387
T2M, V850			0.04670
U850, V850			0.09298
MSLP, PREC	T2M	0.2363	0.07750
MSLP, T2M			0.08272
MSLP, U850			0.07837
MSLP, V850			0.07825
PREC, T2M			0.33530
PREC, U850			0.02970
PREC, V850			0.09292
T2M, U850			0.33000
T2M, V850			0.33210
U850, V850			0.10530

Supplementary Table 13. Prediction performance with three input variables (ECMWF-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC, T2M	pre	0.08758	0.04762
MSLP, PREC, U850			0.04653
MSLP, PREC, V850			0.04689
MSLP, T2M, U850			0.04722
MSLP, T2M, V850			0.04517
MSLP, U850, V850			0.04321
PREC, T2M, U850			0.10470
PREC, T2M, V850			0.10773
PREC, U850, V850			0.11376
T2M, U850, V850			0.04423
MSLP, PREC, T2M	T2M	0.2363	0.0764
MSLP, PREC, U850			0.07836
MSLP, PREC, V850			0.07222
MSLP, T2M, U850			0.08118
MSLP, T2M, V850			0.08346
MSLP, U850, V850			0.08037
PREC, T2M, U850			0.3394
PREC, T2M, V850			0.3389
PREC, U850, V850			0.09052
T2M, U850, V850			0.3311

Supplementary Table 14. Prediction performance with four input variables (ECMWF-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC, T2M, U850	pre	0.08758	0.04729
MSLP, PREC, T2M, V850			0.04711
MSLP, PREC, U850, V850			0.04422
MSLP, T2M, U850, V850			0.04496
PREC, T2M, U850, V850			0.11311
MSLP, PREC, T2M, U850	T2M	0.2363	0.07848
MSLP, PREC, T2M, V850			0.07478
MSLP, PREC, U850, V850			0.0617
MSLP, T2M, U850, V850			0.08083
PREC, T2M, U850, V850			0.33552

Supplementary Table 15. Prediction performance with five input variables (ECMWF-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC, T2M, U850, V850	pre	0.08758	0.04706
MSLP, PREC, T2M, U850, V850	T2M	0.2363	0.08077

Supplementary Table 16. Prediction performance with single input variables (GloSea5-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
pre			0.09347
MSLP			0.04737
T2M	pre	0.06944	0.01935
U850			0.04854
V850			0.04481
pre			-0.01823
MSLP			0.05615
T2M	T2M	0.20318	0.23360
U850			0.02040
V850			0.06329

Supplementary Table 17. Prediction performance with two input variables (GloSea5-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC			0.04889
MSLP, T2M			0.04867
MSLP, U850			0.05124
MSLP, V850			0.04962
PREC, T2M	pre	0.06944	0.08493
PREC, U850			0.09312
PREC, V850			0.09335
T2M, U850			0.03325
T2M, V850			0.01896
U850, V850			0.04214
MSLP, PREC			0.05264
MSLP, T2M			0.05489
MSLP, U850			0.05540
MSLP, V850			0.05142
PREC, T2M	T2M	0.20318	0.23624
PREC, U850			0.04260
PREC, V850			-0.02076
T2M, U850			0.23428
T2M, V850			0.23410
U850,V850			0.06216

Supplementary Table 18. Prediction performance with three input variables (GloSea5-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC, T2M	pre	0.06944	0.04840
MSLP, PREC, U850			0.04798
MSLP, PREC, V850			0.05105
MSLP, T2M, U850			0.04745
MSLP, T2M, V850			0.05117
MSLP, U850, V850			0.04900
PREC, T2M, U850			0.08675
PREC, T2M, V850			0.08985
PREC, U850, V850			0.08861
T2M, U850, V850			0.03346
MSLP, PREC, T2M	T2M	0.20318	0.05624
MSLP, PREC, U850			0.05484
MSLP, PREC, V850			0.05019
MSLP, T2M, U850			0.05467
MSLP, T2M, V850			0.05472
MSLP, U850, V850			0.059067
PREC, T2M, U850			0.23884
PREC, T2M, V850			0.23687
PREC, U850, V850			0.04226
T2M, U850, V850			0.23445

Supplementary Table 19. Prediction performance with four input variables (GloSea5-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC, T2M, U850			0.05092
MSLP, PREC, T2M, V850			0.049501
MSLP, PREC, U850, V850	pre	0.06944	0.04868
MSLP, T2M, U850, V850			0.04721
PREC, T2M, U850, V850			0.08491
MSLP, PREC, T2M, U850			0.05528
MSLP, PREC, T2M, V850			0.05536
MSLP, PREC, U850, V850	T2M	0.20318	0.05539
MSLP, T2M, U850, V850			0.05566
PREC, T2M, U850, V850			0.238

Supplementary Table 20. Prediction performance with five input variables (GloSea5-MLP).

Input variable	Target variable	Original correlation coefficient	Correlation coefficient after applying deep learning
MSLP, PREC, T2M, U850, V850	pre	0.06944	0.04853
MSLP, PREC, T2M, U850, V850	T2M	0.20318	0.05625

부록 E. 동아시아 겨울 기온 선행3주 예측의 성능 추정을 위한 가이드라인

V2019 by Yun-Young Lee

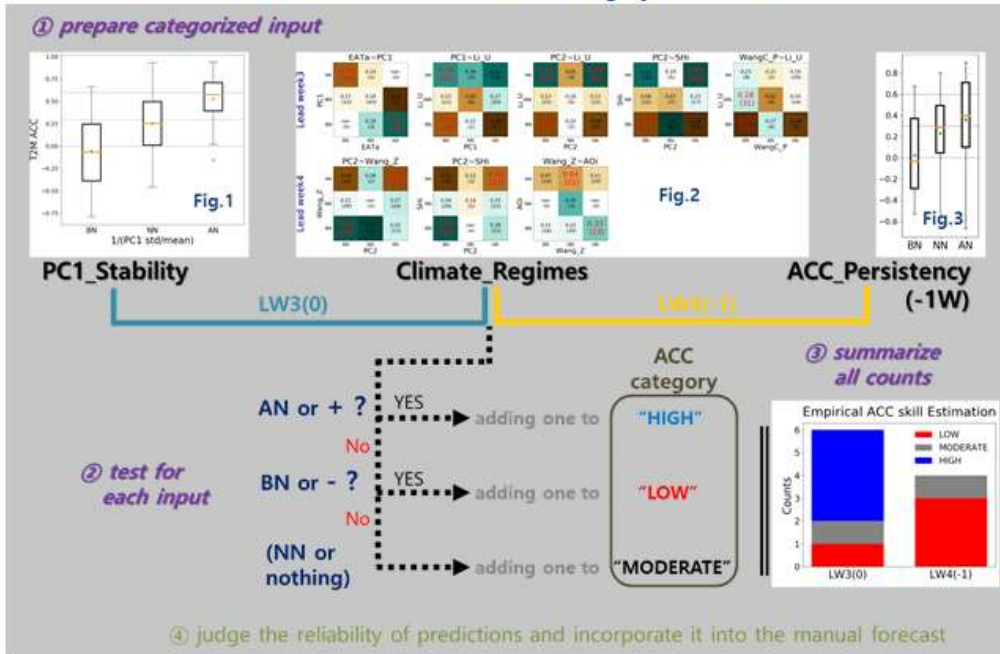
동아시아 겨울 기온 선행3주 예측의 성능 추정을 위한 가이드라인 A guide to estimating lead week3 forecast skill of weakly mean East Asia temperature during boreal winter

수주의 계절내 규모에서 역학 예측은 그 성능이 매우 낮고 불확실성이 큰 것이 잘 알려져 있음. 실시간으로 불확실성의 정도를 특정할 수 있다면, 역학 모형 신뢰 여부를 선 판단하여 기타 정보와의 상대적 가중치를 결정할 수 있고, 궁극적으로 객관적이고 최적화된 consolidated 예보 생산에 일조할 것으로 기대함.

ECCC, NCEP, ECMWF 세 모형의 Simple Composite Mean MME 과거 예측 정보 분석에 따르면, 동아시아 겨울 기온 주평균 예측성능이 뚜렷이 구분되는 여러 조건들을 존재함. 이러한 정보를 활용하여 선행 3주 예측성을 미리 가늠할 수 있게끔 가이드라인을 제시하고자 함.

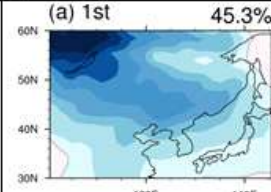
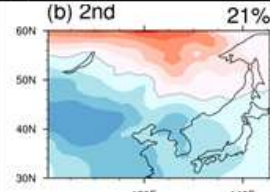
Target	Ingredient	Input information transformed
겨울철 동아시아 지역 (100.5°-135.5°E, 30°-60°N) 선행3주 주평균 기온 (T2m) 예측의 ACC skill 정도	weakly mean MME 실시간 예측 (전주 & 금주)	- Simulated Climate_Regimes: 동아시아 주평균 기온 변동성 (EATa, PC1, PC2), 동아시아 몬순 지수 L_U, WangC_P, Wang_Z), 시베리아고기압 지수 (SHI), 극진동 지수 (AOI) (Table 1,2) - PC1_Stability: $1/[\text{std}(\text{PC1})/\text{mean}(\text{PC1})]$ for 1-4 lead weeks - ACC_Persistence: 선행1주 예측 ACC

Decision tree based on tercile category information



Supplementary

Table 1 East Asia temperature variability

Abbr.	EATa	PC1	PC2
Definition	T2m* average (40°-65°N, 80°-120°E)	PC1 of T2m* over (40°-65°N, 80°-120°E)	PC2 of T2m* over (40°-65°N, 80°-120°E)
Reference		(a) 1st 45.3% 	(b) 2nd 21% 

* indicates normalized value

Table 2 Climate indices used in this study

Index	Definition	Reference
EAWM	Wang_C_P Sea Level Pressure (SLP)* gradient (2xSLP*1-SLP*2-SLP*3)/2 SLP*1: normalized area-averaged SLP over Siberia (40°-60°N, 70°-120°E) SLP*2: the North Pacific (30°-50°N, 140°E-170°W) SLP*3: the Maritime Continent (20°S-10°N, 110°-160°E)	Wang and Chen (2014)
	Wang_P SLP* gradient (40°-70°N, 110°E)-(40°-70°, 160°E)	Wang et al. (2009)
	Wang_Z PC1 of 500hPa geopotential height (Z500hPa)*, (25°-50°N, 100°-180°E)	Wang et al. (2009)
	Li_U 200hPa zonal wind (U200hPa) gradient $\{[(30°-35°N, 90°-160°E)-(50°-60°N, 70°-170°E)] + [(30°-35°N, 90°-160°E)-(5°S-10°N, 90°-160°E)]\} / 2$	Li and Yang (2010)
Siberia High (Shi)	SLP* average (40°-65°N, 80°-120°E)	Panagiotopoulos et al. (2005)
Arctic Oscillation (AOi)	PC1 of SLP* poleward of 20°N	Thompson and Wallace (1998)

* indicates normalized value




Figure 1 Box-whisker of ACC for BN, NN and AN groups at four lead weeks. The three categories are based on lower (33.3%) and upper (66.6%) terciles of lead week1 ACC. Green triangles indicates the mean of ACC.

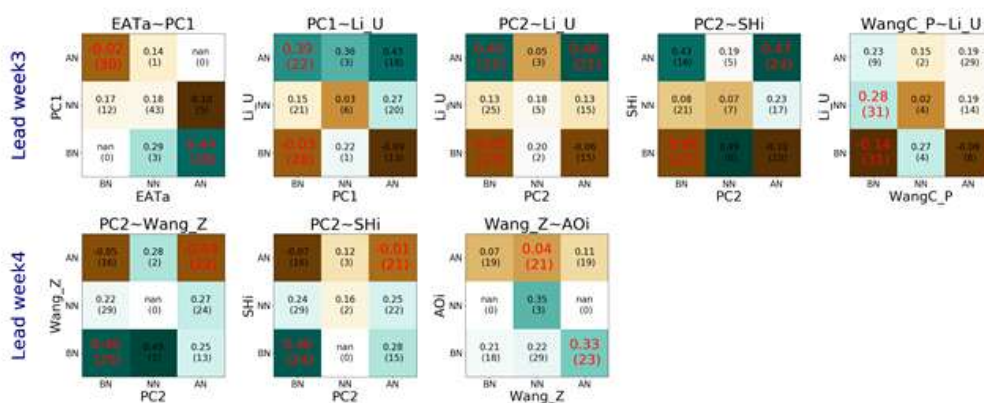


Figure 2 mean ACC of 9 categories based on two different indices' tercile criteria for lead week (top) 3 and (bottom) 4. For the tercile categorization, anomaly of each index is calculated then it is normalized by its standard deviation. **Upper and lower tercile is -0.43 and 0.43 sigma**, respectively. ACC average value and sample size within parenthesis are displayed in each box. Red color denotes the category of distinguished large or small ACC value with the sample size 20 and over.

L3 skill ~ PC1 stability




Figure 3 (a) scatter plot and (b) box-whisker plot between simulated PC1 stability and EA T2m skill for lead time of 3 weeks from 132 samples (12 weeks for 11 winter seasons). X-axis displays an inverse of PC1 standard deviation for 4 lead weeks divided by their mean. Least square fitted line in (a) is delineated (gray dash). *The three categories in (b) are based on lower (33.3%) and upper (66.6%) terciles of PC1 stability.*




Figure 4 mean ACC of 9 categories based on all available two different indices' tercile criteria for lead week 3. For the tercile categorization, anomaly of each index is calculated then it is normalized by its standard deviation. **Upper and lower tercile is -0.43 and 0.43 sigma**, respectively. ACC average value and sample size within parenthesis are displayed in each box. Red color denotes the category of distinguished large or small ACC value with the sample size 8 and over.




Figure 5 same as in Figure 4 but for lead week 4.

부록 F. 몬순 시작일 정의와 평가 기법

Table 1. Definition of Southwest Monsoon Onset

Southwest Monsoon Onset

The guidelines to be followed for declaring the onset of monsoon over Kerala and its further advance over the country are enlisted below:

a) Rainfall

If after 10th May, 60% of the available 14 stations enlisted*, viz. Minicoy, Amini, Thiruvananthapuram, Punalur, Kollam, Allapuzha, Kottayam, Kochi, Thrissur, Kozhikode, Thalassery, Kannur, Kudulu and Mangalore report rainfall of 2.5 mm or more for two consecutive days, the onset over Kerala be declared on the 2nd day, provided the following criteria are also in concurrence.

b) Wind field

Depth of westerlies should be maintained upto 600 hPa, in the box equator to Lat. 10° N and Long. 55° E to 80° E. The zonal wind speed over the area bounded by Lat. 5-10° N, Long. 70-80° E should be of the order of 15 – 20 Kts. at 925 hPa. The source of data can be RSMC wind analysis/satellite derived winds.

c) Outgoing Longwave Radiation (OLR)

INSAT derived OLR value should be below 200 wm^{-2} in the box confined by Lat. 5-10° N and Long. 70-75° E.

Table 2. Definition of Taiwan Mei-Yu Onset

Taiwan Mei-Yu Onset
When Hshear Index > 0 and Vshear Index > 0
Hshear Index = $U_{850}[(115^{\circ}\text{E}-125^{\circ}\text{E}, 17.5^{\circ}\text{N}-22.5^{\circ}\text{N}) - (110^{\circ}\text{E}-120^{\circ}\text{E}, 25^{\circ}\text{N}-30^{\circ}\text{N})]$
Vshear Index = $U_{850}(110^{\circ}\text{E}-130^{\circ}\text{E}, 12.5^{\circ}\text{N}-20^{\circ}\text{N}) - U_{200}(110^{\circ}\text{E}-130^{\circ}\text{E}, 12.5^{\circ}\text{N}-20^{\circ}\text{N})$

Table 3. Skill Metric for continuous variables

Methods for forecasts of continuous variables

1. Mean error

- What is the average forecast error?
- Mean Error (ME), also called Bias, represents the mean value of deviations between forecasts and verification values, and is defined by

$$ME = \frac{1}{N} \sum_{i=1}^N (F_i - O_i)$$

- Range: $-\infty$ to ∞
- Perfect score: 1
- Characteristics: Simple, familiar, does not measure the magnitude of the errors, does not the correspondence between forecasts and obs.

2. RMSE

- What is the average magnitude of the forecast errors?
- Root Mean Square Error (RMSE) is often used for representing the accuracy of forecasts, and is defined by

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - O_i)^2}$$

- Range: -1 to 1
- Perfect score: 0
- Characteristics: Simple, familiar, measures "average" error, weighted according to the square of the error, does not indicate the direction of the deviations, puts greater influence on large errors than smaller errors, which may be a good thing if large errors are especially undesirable.

3. Anomaly Correlation Coefficient

- How well did the forecast anomalies correspond to the observed anomalies?
- Anomaly Correlation Coefficient (ACC) is the correlation between anomalies of forecasts and those of verifying values with the reference values, such as climatological values, and is defined by

$$\frac{\sum_{i=1}^N (F_i - C_i) - (\overline{F_i - C_i})(\overline{O_i - C_i})}{\sqrt{\sum_{i=1}^N (F_i - C_i)^2} \sqrt{\sum_{i=1}^N (O_i - C_i)^2}}$$

- Range: -1 to 1
- Perfect score: 1
- Characteristics: one of the most widely used measures in the verification of spatial fields. Measures correspondence or phase difference between forecast and observations, subtracting out the climatological mean at each point, C, rather than the sample mean values.

4. Mean Absolute Error

- What is the average magnitude of the forecast errors?

$$MAE = \frac{1}{N} \sum_{i=1}^N |F_i - O_i|$$

- Range: 0 to ∞
- Perfect score: 0
- Characteristics: Simple, familiar, does not indicate the direction of the deviations.

5. Fractional variance

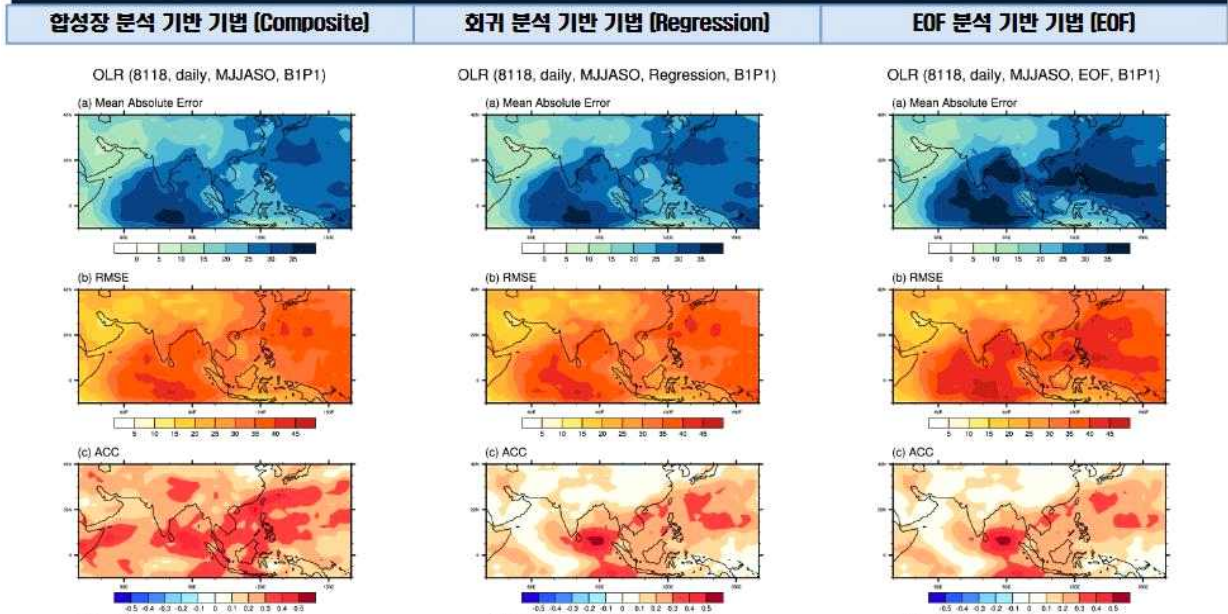
- as a fraction of total variance
 - is defined as the ratio of the variance of the ISO composite which undergoes through its life cycle to the total variance of the intraseasonal (25-90 day) fluctuation (K. Kikuchi et al.,)
-

부록 G. 위상별 BSISO 영향장 비교 검증

BSISO 1

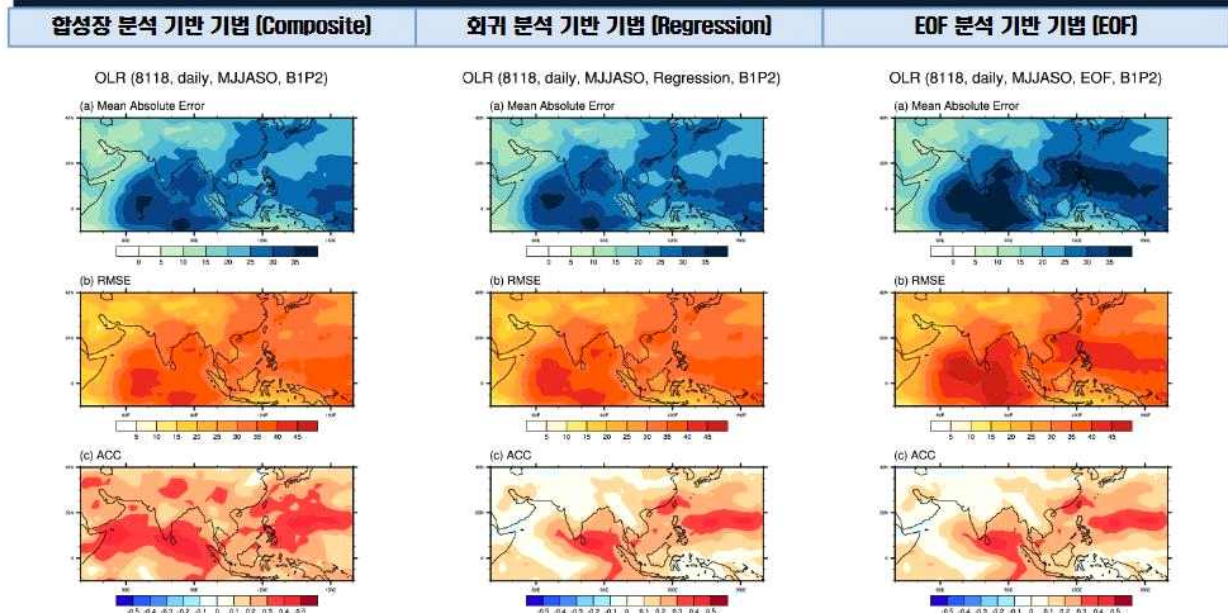
❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 38yr*184day=6992개의 샘플)
- Strong BSISO1 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

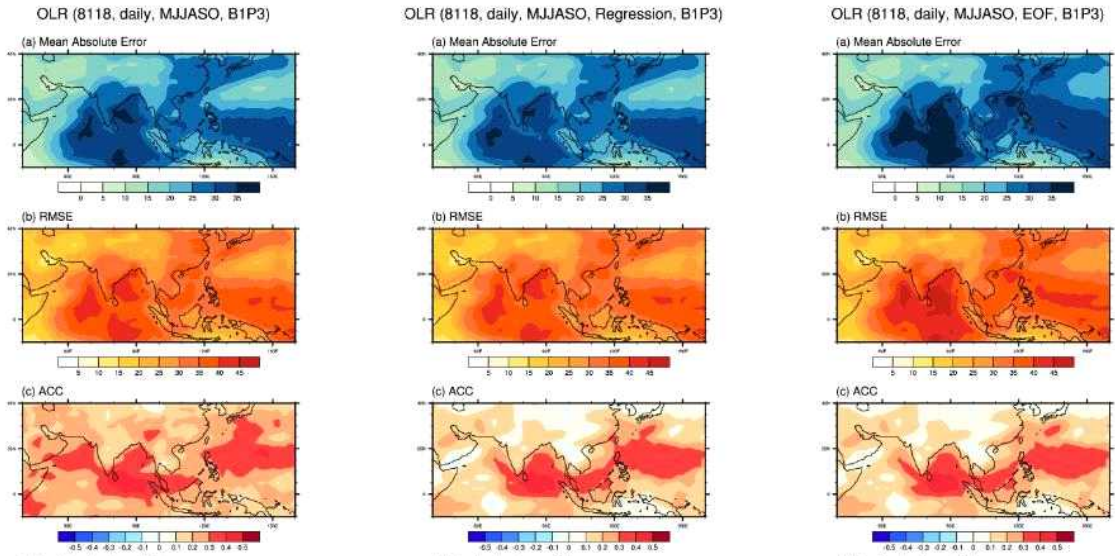
- 1981-2018, MJJASO, daily (총 38yr*184day=6992개의 샘플)
- Strong BSISO1 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 38yr*184day=6992개의 샘플)
- Strong BSIS01 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

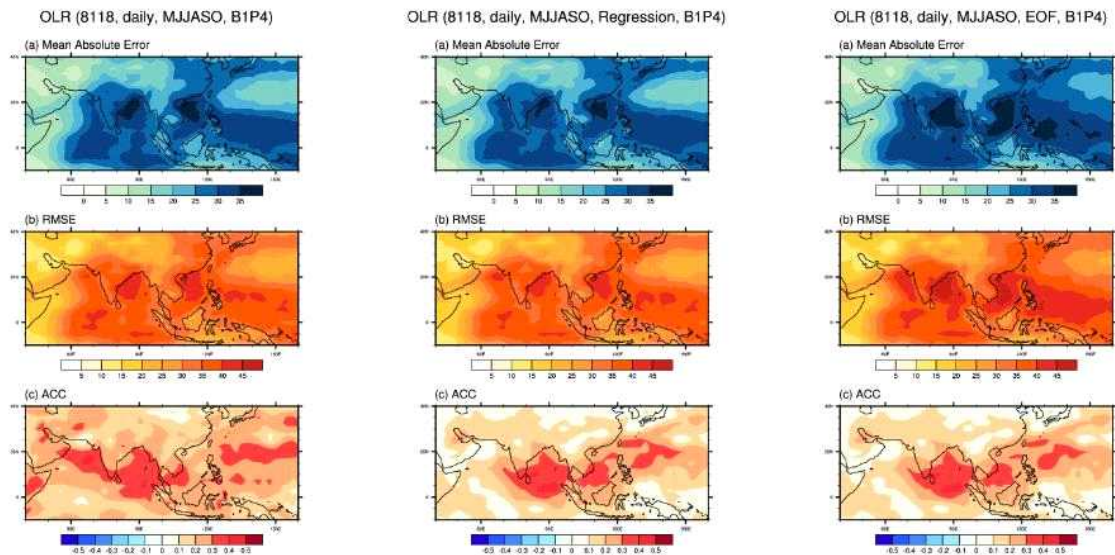
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 38yr*184day=6992개의 샘플)
- Strong BSIS01 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

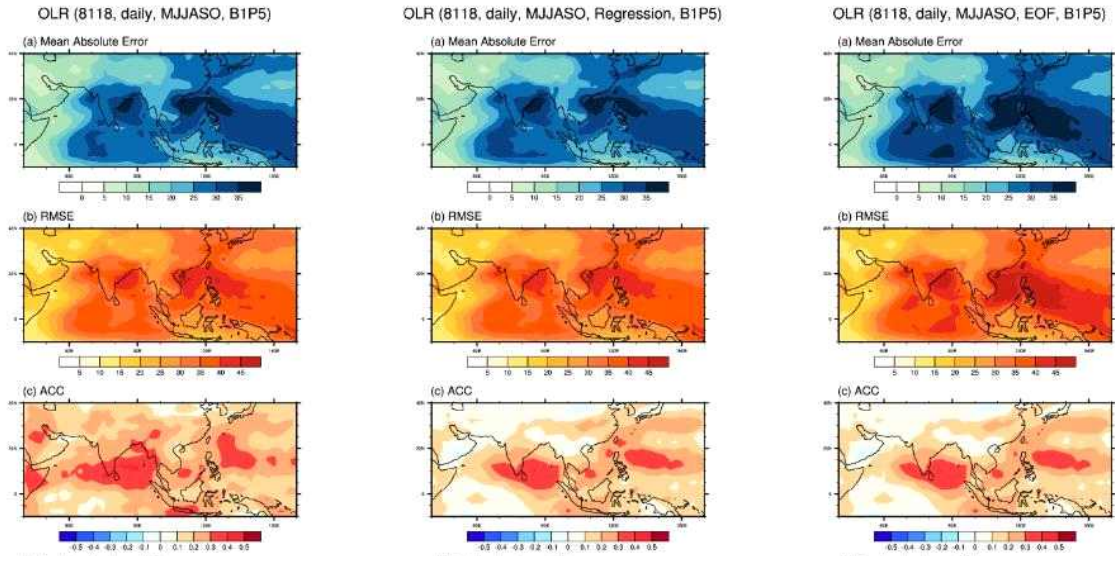
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 38yr*184day=6992개의 샘플)
- Strong BSIS01 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

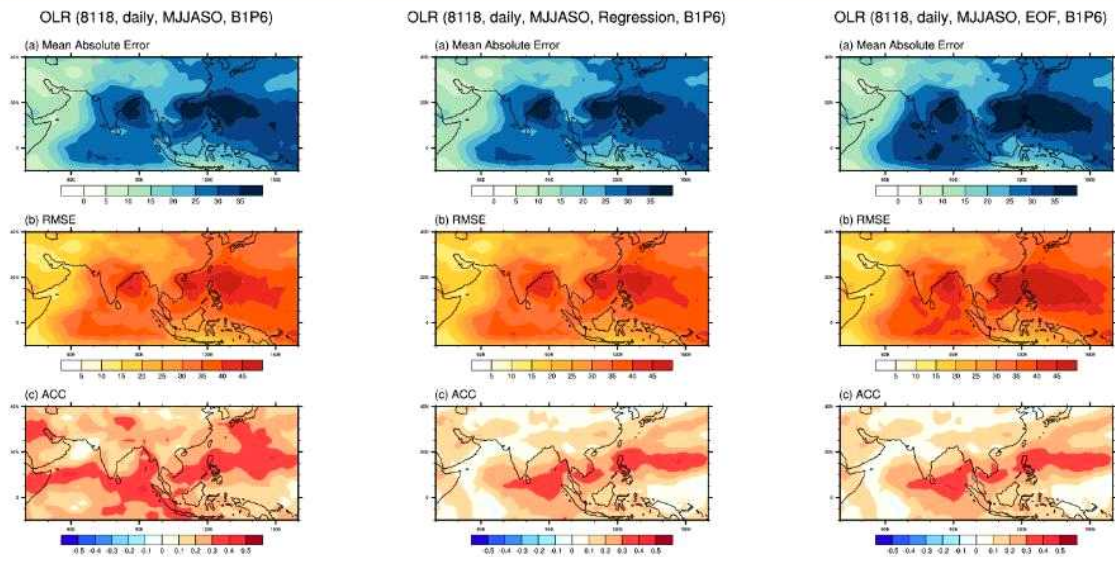
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
- Strong BSIS01 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

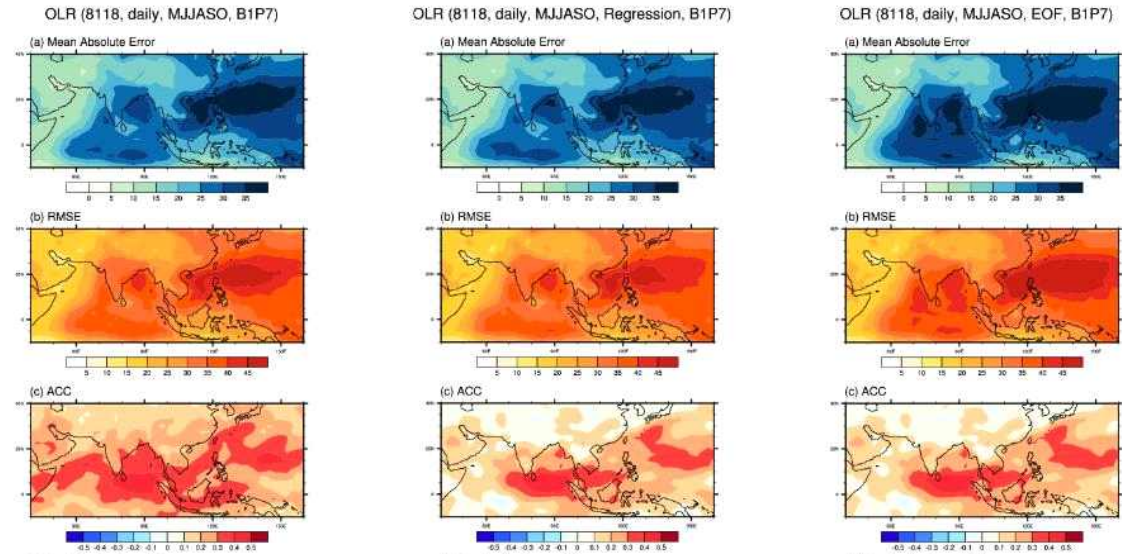
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSIS01 phase1, phase2, phase3, phase4, phase5, phase6, **phase7**, phase8

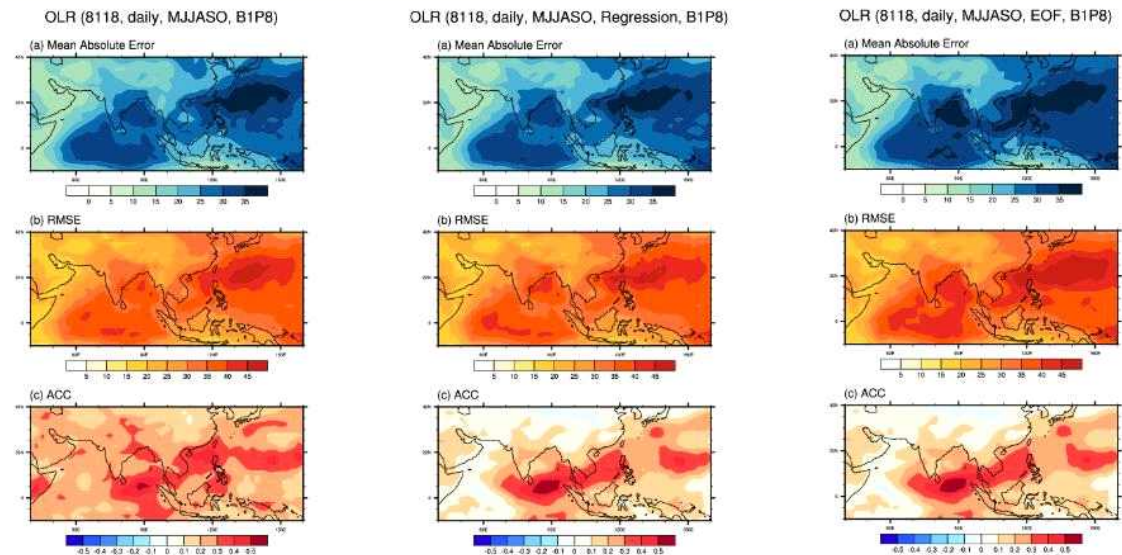
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

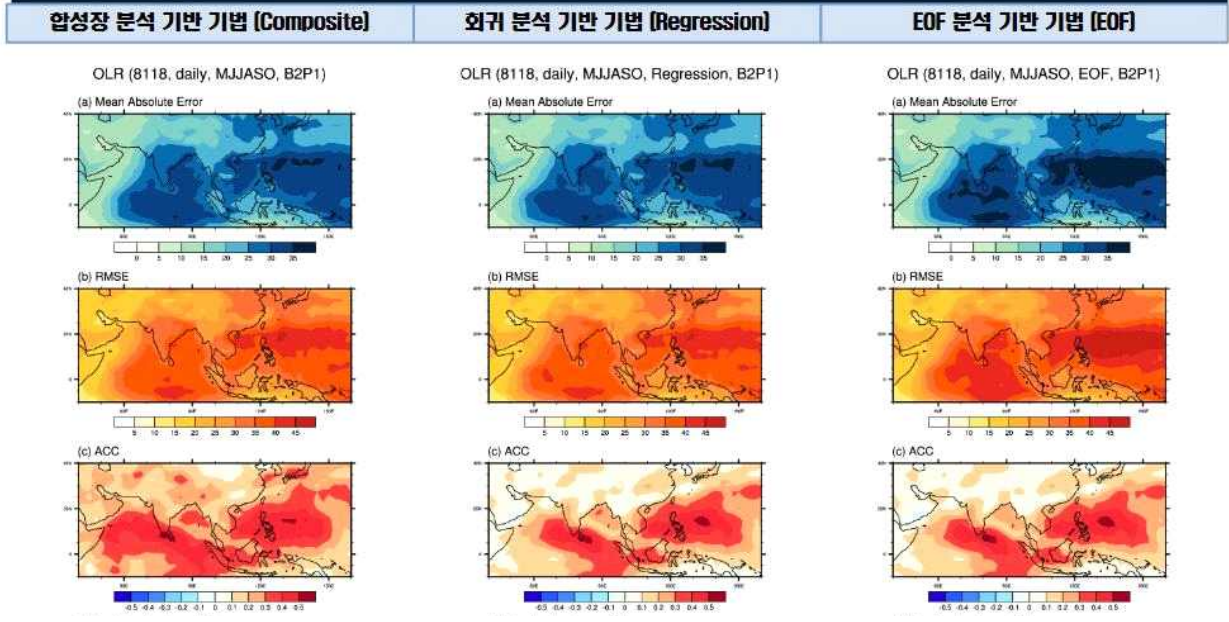
- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSIS01 phase1, phase2, phase3, phase4, phase5, phase5, phase7, **phase8**

합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



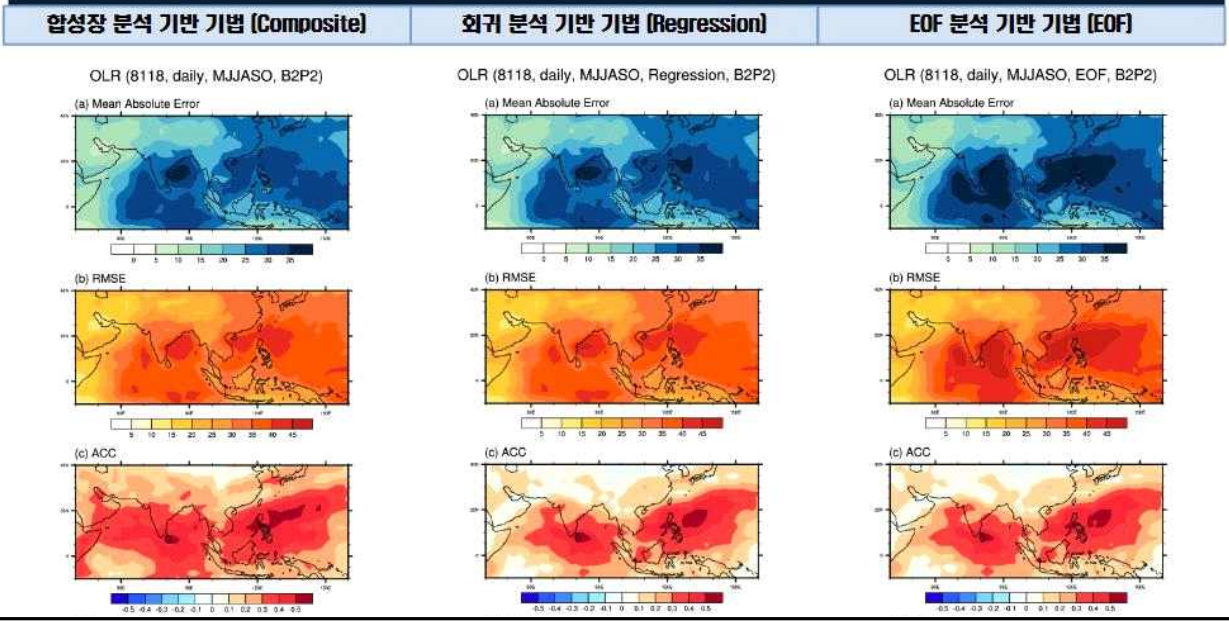
❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSISO2 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

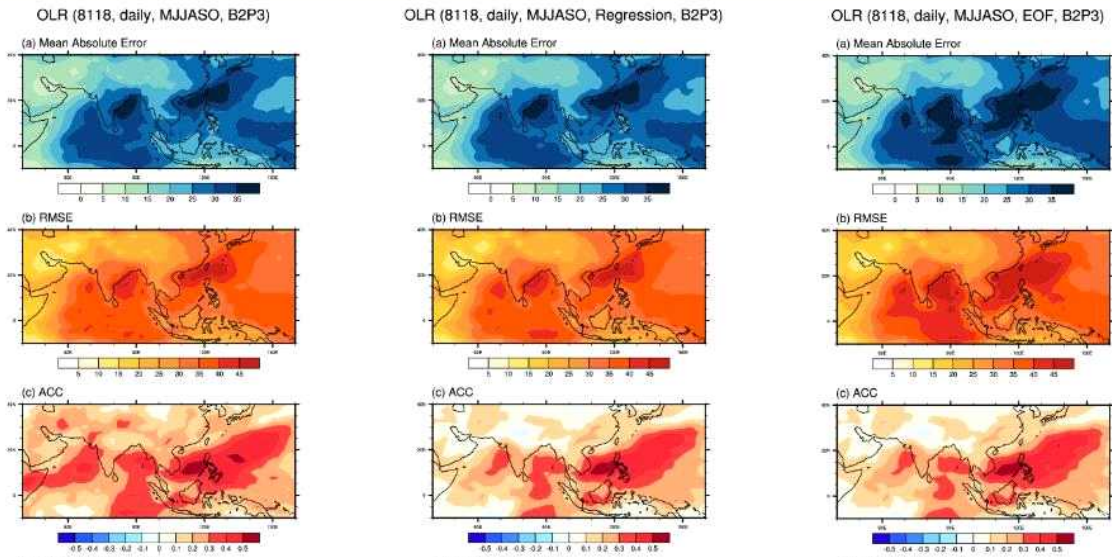
- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSISO2 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
- Strong BSISO2 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

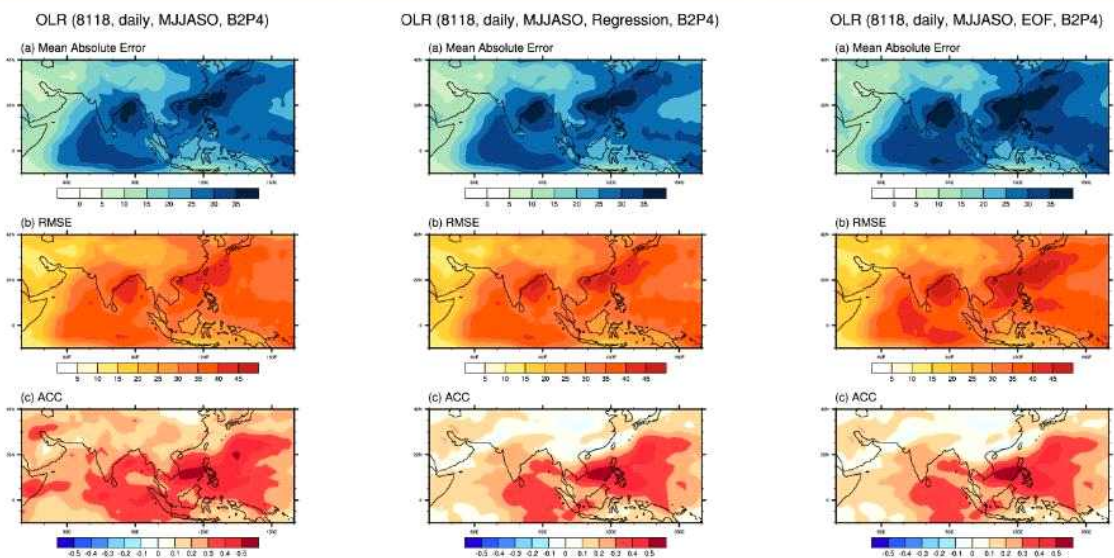
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
- Strong BSISO2 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

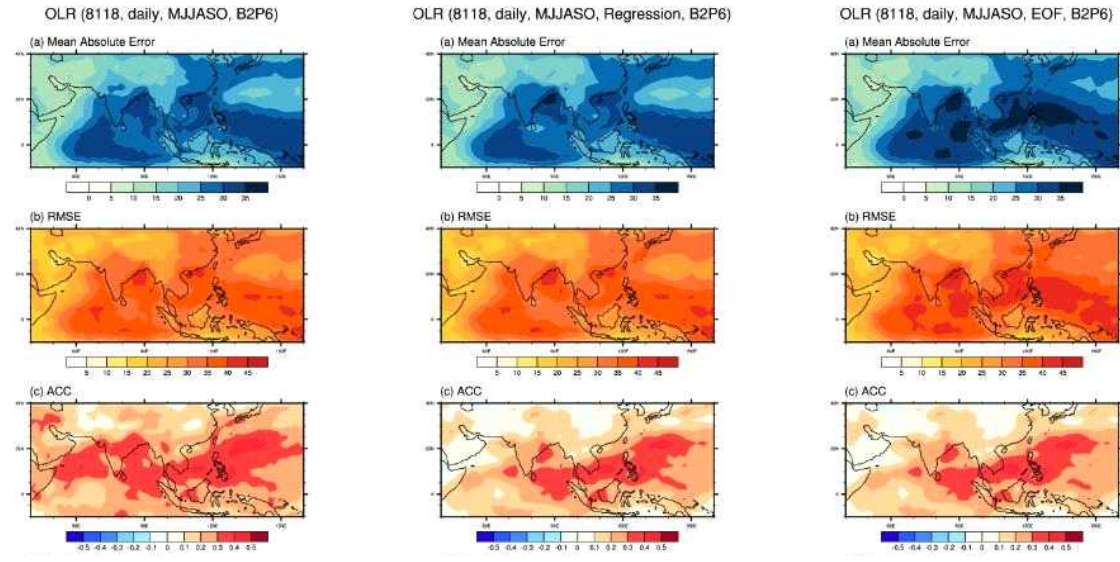
합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSIS02 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

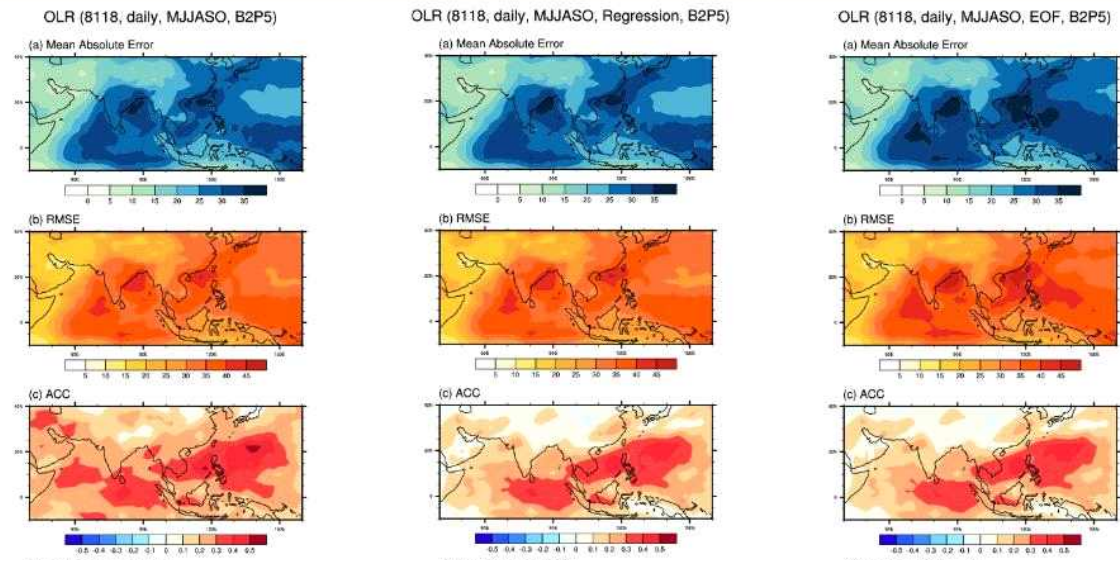
합성장 분석 기반 기법 (Composite)	외귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSIS02 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

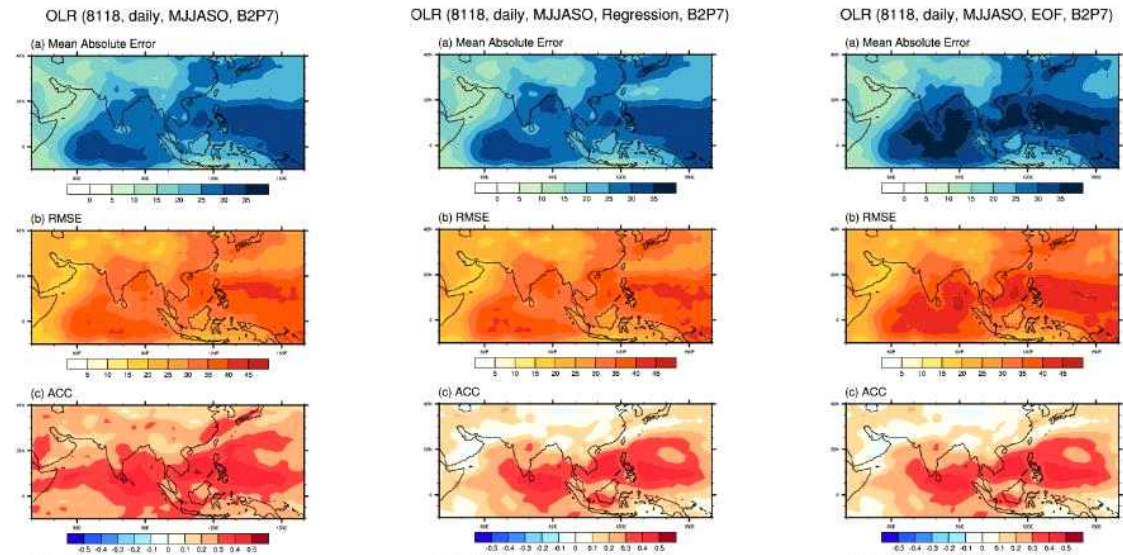
합성장 분석 기반 기법 (Composite)	외귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSIS02 phase1, phase2, phase3, phase4, phase5, phase6, phase7, phase8

합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------



❖ 상향장파복사(OLR) 아노말리 공간 분포 비교 검증

- 1981-2018, MJJASO, daily (총 5814개의 샘플)
 - Strong BSIS02 phase1, phase2, phase3, phase4, phase5, phase5, phase7, phase8

합성장 분석 기반 기법 (Composite)	회귀 분석 기반 기법 (Regression)	EOF 분석 기반 기법 (EOF)
--------------------------	--------------------------	--------------------

