

예측성 향상을 위한 다중모델기반 기후예측기술 개발
**Development of multi-model-based climate
prediction technique for the predictability
improvement**

손수진, 김광형, 김원무, 박경원, 박지훈, 정유란
기후사업본부 예측기술과

2020.12.

APEC기후센터

평문 초록

유사한 기후 특성을 기반으로 하는 지역 규모의 기후 전망에서는 그 지역을 위해서 개발된 선도 기후예측 기술이 그 근간이 됩니다. 따라서 이 연구에서는 계절 및 계절 내 시간규모를 예측 목표로 하고 동아시아 및 한반도 지역을 중점 연구 지역으로 하여, 센터에서 수집 가능한 여러 역학 기후 모델을 바탕으로 모델간 앙상블을 활용하는 기후 예측 기술을 개발 하였습니다.

계절 기후예측을 위해서 모델간 앙상블을 구축하는 방안으로 크게 다음의 세 가지 방안이 고려되었습니다. 첫째, 역학 모델의 예측 결과를 후보정 하지 않고, 역학 모델의 예측 성능을 바탕으로 우수 모델을 선별하여 모델간 앙상블을 수행하는 방법입니다. 단, 모델 선정의 기준은 예측하고자 하는 기후변수가 아니라 기후인자와 그 영향에 대한 모델의 재현 능력을 바탕으로 합니다. 먼저 엘니뇨-남방진동의 복잡성을 기준으로 선별된 모델간 앙상블이 가용한 모델 구성 자체가 다르거나 과거재현기간이 다를 경우에도 불구하고 가용한 모델 전체를 사용한 모델간 앙상블에 비해 예측성능이 향상 되었습니다. 또한 엘니뇨-남방진동과 더불어 서태평양 강수 변동을 기후인자로 고려하여 선별한 모델간 앙상블이 가용한 모델 전체를 사용한 모델간 앙상블에 비해 예측성능이 높고 불확실성이 낮은 예측 결과를 도출하였습니다. 둘째, 과거 동아시아 지역의 관측 자료를 이용하여 기후 모델이 예측하는 동아시아 지역의 기후 상황을 보정함으로써 실질적인 예측 성능을 올릴 수 있습니다. 이 연구에서는 과거 관측 자료와 기후 모델의 예측 사이의 관계를 학습하고, 이를 이용하여 기후 모델의 예측 자료를 보정하여 보다 예측성 높은 기후 전망을 제시하고자 하였습니다. 특히, 이 과정에서 보정이 안정적으로 이루어질 수 있도록 정규화 기법을 적용하였습니다. 동아시아 강수 예측에 경험적 직교함수로부터 추출한 주요 모드에 정규화 기법을 적용할 경우 일반적으로 예측 성능이 개선되었습니다. 또한, 이러한 후처리를 동아시아의 기온 예측에 적용한 결과 가을철 해양 지역에서의 예측 성능 향상이 큰 것으로 나타났으나, 고위도 대륙 지역에서의 예측 성능 향상은 미미한 것으로 보입니다. 셋째, 개별 모델 대신에 모델간 앙상블 예측 결과를 후보정하는 방안으로 지점 대 지점 간의 후보정은 예측 성능 개선에 기여하지 않았습니다.

한반도 지역 기후의 계절내 예측 성능 향상 및 오차 저감을 위해서, 가용한 모델로부터 최적의 모델간앙상블을 구축하고 이를 다시 딥러닝 기법으로 후보정하는 방안이 개발되었습니다. 먼저, 지점 대 지점 간의 기후 관계를 시간의 변동에 대해서 학습하는 장단기 기억 기술을 적용한 결과, 목표 선행 주인 3주와 4주에서 최고기온, 최저기온, 강수량의 예측성능이 향상되었습니다. 또한, 지점 대 지역 간 기후 관계를 학습하는 ConvLSTM 기술의 효과를 개별 모델에 시험 적용한 결과 그 예측 오차가 크게 줄어들었습니다.

향후에는 이러한 연구 결과를 바탕으로 다중모델 기반의 지역특화 계절예측시스템을 구축하고 계절내예측 기반기술을 고도화하고자 합니다. 이를 통해 개발된 동아시아 특화형 선도 예측 기술은 동아시아의 계절 및 계절내 기후예측 및 예측성 향상에 기여할 것으로 기대합니다.

Executive Summary

It is quite essential for valuable and reliable climate outlook at a regional scale based on similar climate variability and characteristics to develop regional-specific climate prediction techniques. Therefore, this research project is set to be carried out for three years from 2019 to 2021 to develop regional-specific leading climate prediction technology. In the first year, regional-specific seasonal multimodel ensemble (MME) climate prediction technology development systems were established. Based on this, regionally customized seasonal and intra-seasonal MME climate prediction technology were developed in 2020. For the development of multi-model-based seasonal prediction technology, physical phenomena-based ensemble model reconstruction, multi-model-based prediction model development using a regularization technique and Bayesian approach, and climate probability prediction correction through Probability Anomaly Correlation (PAC) were performed. A study on reducing prediction errors in sub-season forecasting was also conducted to develop multi-model-based sub-seasonal prediction technology.

In the first year, in order to prepare a system for the development of climate prediction technology for regionally tailored seasonal MMEs, the predictive performance of the complexity of El Niño-Southern Oscillation (ENSO) and its climate impacts were diagnosed, and this was used as a factor to improve local climate prediction. Through the ensemble reconstruction based on physical phenomena, it was found that the seasonal prediction performance of precipitation in the East Asia and Australasian monsoon regions was improved during the non-mature phase of ENSO season. The 2020 year aims to improve the regional-specific seasonal prediction technology and verify its predictability through reconstruction of the ensemble model developed in the first year. In the first year of the project, the study was conducted based on the individual climate model participating in the MME version 1 for the APCC 6-month seasonal prediction, but the 6-month seasonal prediction of the APCC, which is in operation in the middle of the second year, is officially changed to MME version 2. Therefore, in order to properly evaluate the utility of the operation field, stability evaluation was carried out through the verification of climate prediction performance of climate prediction data with various versions, and as a result, consistent improvement of prediction performance was confirmed. Also, in the second year, the target region was specialized in East Asia, and the variation of precipitation in the western Pacific was discovered as an additional climate factor and applied together with ENSO to develop and evaluate probabilistic MME prediction technology. The probabilistic MME prediction constructed in this way showed more improved predictability in terms of category verification compared to the existing MME based on all available models.

Next, a multi-model-based seasonal prediction regression model using a regularization

technique was developed. The definition of the regularization technique is to add a penalty term to the least squares method, and in this study, a seasonal prediction regression model was constructed using LASSO regression. The seasonal prediction regression model was constructed using the PC time series for each observed value/individual model. It was analyzed that the prediction performance of the LASSO-based model was generally improved compared to APCC MME, for East Asian seasonal precipitation forecasts. We also introduced Bayesian regression with L2 regularization (Bayesian ridge) for post-processing. Using the hindcast relationship between the observed reanalysis and the individual dynamical model output, the relationship is updated with regularization at the grid point. The Bayesian ridge post-processing resulted in enhanced prediction skill over the oceanic area in Autumn, but the high-latitude land area does not show significant improvement. Also, the variance is underestimated during some seasons. The grid-to-grid post-processing may lack of predictability source, so further improvement based on the model output statistics should follow. Finally, using PAC, a statistical post-processing technique using a regression method between the predicted probability value and the observed probability value was evaluated. As a result of evaluating whether the predictability of APCC PMME is improved through the PAC technique in East Asia, it was found that the predictability was not improved after the application of PAC in all seasons overall.

To improve S2S forecasting performance, deep learning techniques as big data and artificial intelligence analysis techniques can be utilized. Therefore, we conducted this study to enhance the S2S prediction performance on the Korean Peninsula and to develop S2S predictive-based technologies that can be operated and utilized for the field. First, MME-based seasonal predicted climate data were constructed from six individual climate models, and the predicted data was learned by Long-Term Short Memory (LSTM). As a result, the prediction skills of all three MME- and LSTM-based S2S climate variables, such as daily maximum and minimum temperature, and daily total precipitation, were significantly improved. Therefore, the application of deep learning training to MME-based constructed S2S prediction climate data is expected to improve the S2S climate forecast skills for 3-4 weeks. ConvLSTM deep learning technology was also applied to improve S2S prediction performance on the Korean Peninsula. ConvLSTM-based model was developed with the convolutional data of gridded GloSea5 model data. It was found that the prediction performance of the maximum/minimum temperature is improved to the prediction performance of the LSTM using the point data.

In the next year, based on these research results, we intend to build a regional-specific seasonal prediction system based on multiple models and to advance the technology based on seasonal prediction. Through this, it is expected that the region-specific leading forecasting technology will contribute to predicting seasonal and intra-seasonal climate in East Asia and improving their predictability.

국문 요약

유사한 기후 특성을 기반으로 하는 지역 규모에서 기후 전망을 위해서는 지역 특화형 선도 기후예측 기술 개발이 이루어져야 한다. 따라서 이 연구과제는 “지역특화형 선도 기후예측 기술 개발”을 목표로 2019년부터 2021년까지 3년 동안 수행되는 사업으로, 1차년도에는 지역 맞춤형 계절 다중모델앙상블(multimodel ensemble, MME) 및 계절내(sub-seasonal to seasonal, S2S) MME 기후예측 기술 개발 체계가 마련되었다. 2020년에는 이를 기반으로 하여 지역 맞춤형 계절 및 계절내 MME 기후예측 기술을 개발하였다. 이 과제에서는 예측 시간 규모 및 예측자료의 유용성 등을 고려하여, 예측성 향상을 위한 다중모델 기반 계절 예측 기술개발과 계절내 예측 기법 기술 개발로 구분하여 연구를 진행하고자 하였다. 다중모델 기반 계절 예측 기술개발을 위해서는 물리현상 기반의 앙상블모델 재구성, 정규화기법을 활용한 다중모델 기반 예측모델 개발, 베イズ 접근법에 의한 다중모델 앙상블 기법 개발, Probability Anomaly Correlation (PAC)를 통한 기후 확률 예측 보정을 수행하였으며, 다중모델 계절내 예측 기반 기술 개발을 위해서는 계절내 예측의 오차 저감 연구를 수행하였다.

1차 년도에는 지역 맞춤형 계절 MME 기후예측 기술 개발체계 마련을 위해서, 엘니뇨-남방진동(El Niño-Southern Oscillation, ENSO)의 복잡성과 그 원격상관의 예측성을 진단하고, 이를 지역 기후예측을 향상시키기 위한 물리 인자로 사용하였다. 물리현상 기반의 앙상블 재구성을 통해 ENSO가 비활성화 되는 계절 동안 동아시아-호주 몬순지역 강수의 계절 예측성능이 향상됨을 발견하였다. 2020년 당해 연도는 1차 년도에 개발된 지역특화 계절 예측기술을 개선하고 그 예측성을 검증하였다. 1년차에는 APCC 6개월 계절예측의 MME version 1에 참여 중인 개별 기후모델을 바탕으로 연구가 진행되었으나, 2년차인 당해 연도 중반에 APCC 6개월 계절예측이 공식적으로 MME version 2로 변경되었다. 따라서 현업 활용성을 제대로 평가하기 위해서 다양한 기후 자료의 기후예측성 검증을 통한 안정성 평가가 수행 되었고, 이를 바탕으로 일관된 예측 성능 향상을 확인하였다. 또한 2차 년도에는 대상 지역을 동아시아로 특화하고 서태평양 강수 변동을 추가 기후인자로 발굴하여 ENSO와 함께 적용하여 확률론적 MME 예측기술을 개발하고 평가하였다. 이렇게 구성된 확률 MME 예측은 가용한 모든 모델을 바탕으로 한 기존의 MME에 비해서 카테고리 검증 측면에서 예측성이 개선된 결과를 보였다.

다음으로 계절 예측 기술개발을 위해서 정규화 기법을 사용한 다중모델기반 계절예측회귀모형을 개발하였다. 정규화 기법의 수학적 정의는 최소제곱법에 벌점항을 도입하는 것이며, 이 연구에서는 LASSO 회귀를 이용하여 계절예측회귀모형을 구축하고 분석하였다. 관측값/개별 모형별 EOF 분석을 수행하여 산정한 PC 시계열을 이용하여 계절예측회귀모형 구축하였다. 전반적으로 월별/계절별 동아시아 강수 예측에 대해서 일부 연도를 제외하고는 현업에서 사용하는 APCC MME 대비 LASSO의 예측성능이 개선된 것으로 분석되었다.

계절 예측 기술 개발을 위한 세 번째 방안으로 베イズ 접근법에 의한 다중모델 앙상블 기법이 개발 되었다. 구체적으로 정규화 기법을 적용한 베イズ 후처리를 이용하여 과거 재현 기간의 관측 재분석 자료와 MME에 참여하는 기후 모델의 예측 자료를 적합하였다. 적합 과정의 안정성을 높이기 위하여 능형 회귀를 이용하였고, 모수의 추정은 베イズ 이론에 기초하여 수행

하였다. 정규화 베이스 후처리를 통한 예측 성능은 가을철 해양 지역에서 높은 예측성 향상을 보여주고 있다. 그러나 고위도 대륙 지역의 예측 성능의 산포가 매우 크게 나타나고 일부 기간의 예측 분포가 과소 추정되는 모습을 보여 추가적인 후처리 기법의 개발이 필요한 것으로 보인다.

마지막으로 APCC 확률적 다중모형앙상블 계절 예측정보의 예측성을 개선하기 위해 예측값과 실제 관측값과의 함수관계를 구축하여 예측을 보정하는 PAC 보정 방법을 도입하여 적용하였다. PAC는 예측 확률값과 관측 확률값 사이의 회귀 방법을 이용한 통계적 후처리 기법으로써, 물리적 단위와 확률적 단위의 변수를 사용한 회귀의 형식적 유사성을 중심으로 개발되었다. 본 연구에서는 동아시아 지역을 대상으로 ERA5 재분석 자료에 기반한 기존 APCC PMME 예측정보의 예측성을 계산한 후, 추가로 PAC를 적용한 예측정보의 예측성과 비교하여 PAC 적용 전후로 예측성이 어떻게 변하는지를 평가하였다. 그 결과, 전반적으로 모든 계절에서 PAC 적용 이후 예측성이 오히려 낮아지는 것을 확인하였다. 이는 적은 자료 표본과 관련되 과소 또는 과대 추정으로 사료된다.

한반도 지역 기후의 계절내 예측 성능 향상 및 오차 저감을 위한 다중모델 기반 계절내 예측 기술이 개발 되었다. 그 첫 번째 방안으로 계절내 예측 기후모델 자료의 MME 방법을 개발하고 여기에 심층학습의 하나인 장단기기억기술(Long-Term Short Memory, LSTM)을 적용하였다. 6개 S2S 기후 예측 모델들로 가능한 조합을 구성하여 그 예측성능을 검증한 결과, 전체 모델을 평균한 MME에 학습 모델을 구축하였다. 지표면 기온, 최고기온, 최저기온, 강수량, 해면 기압, 850 hPa에서의 동서·남북바람, 500 hPa에서의 지위고도 등의 기후 변수가 학습 모델의 예측인자로 이용되었다. S2S MME 기후예측 자료에 LSTM을 적용하여 예측된 최고기온, 최저기온, 강수량 모두 평방제곱근오차의 감소와 시상관계수(Temporal Correlation Coefficient)에서의 향상이 뚜렷하게 나타났다. 특히, 목표 선행주수인 3~4주에서 유럽중기예보센터 기후모델 대비, 최고기온의 TCC는 39%와 54%, 최저기온의 TCC는 29%와 51%까지 향상되는 것으로 나타났다. 또한 강수의 TCC는 130%와 44%로, 3주에서 획기적인 향상을 보였다. 따라서 S2S MME 기후예측 자료에 딥러닝 훈련기법을 적용하면 3~4주 기후예측에서 예측 성능을 개선할 수 있을 것으로 보인다.

계절내 예측의 오차 저감을 위한 두 번째 방안으로 계절내 예측자료에 ConvLSTM 딥러닝 적용기술을 개발하였다. GloSea5의 격자화된 모델 입력자료 기반으로 ConvLSTM 기반 계절내 예측기술을 개발하고, 재분석자료와의 비교분석 평가하였다. 지점자료를 이용한 LSTM과 GloSea5 격자자료의 합성곱 된 자료를 적용한 ConvLSTM을 비교하면, ConvLSTM이 한반도 지점의 최대/최소온도를 예측함에 있어 LSTM보다 우위에 있음을 확인하였다. 향후 ECMWF 모델이나 앙상블 기법에 의해 다양한 입력자료를 활용한다면 보다 높은 정확도를 제공할 것으로 사료되며, 발전적인 형태의 격자화 된 계절내 서비스의 기초프레임이 될 것이다.

차 년도에는 이러한 연구 결과를 바탕으로 다중모델 기반의 지역특화 계절예측시스템을 구축하고 계절내예측 기반기술을 고도화하고자 한다. 이를 통해 궁극적으로 개발된 지역특화형 선도 예측 기술은 동아시아 계절 및 계절내 기후예측 및 예측성 향상에 기여할 것으로 기대한다.

목차

평문 초록	i
Executive Summary	ii
국문 요약	iv
목차	vi
표 차례	ix
그림 차례	x
1. 서론	1
가. 연구의 배경	1
나. 연구의 목표	2
다. 연구의 내용 및 추진전략	3
라. 연구의 추진체계	3
2. 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술 개선 및 예측성 검증	5
가. 개요	5
나. 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술	6
(1) 앙상블 재구성을 위한 물리현상	7
(2) 물리현상 기반의 앙상블모델 재구성	10
(3) 지역특화 계절예측 기술 개발	11
다. 다양한 기후예측자료의 기후예측성능 검증을 통한 안정성 평가	12
(1) 과거재현 자료의 통계적 안정성 확인	12
(2) 물리현상 기반의 앙상블 재구성을 통한 다양한 과거기후예측자료 및 실시간 기후예측자료 생산	13
라. 동아시아 지역에 대해서 계절별로 분석된 model set을 바탕으로 MME 적용 및 예측성 평가	14
(1) 과거기후 예측기간 (1982-2005년)에 대해서 cross-validation을 통해 예측력 재평가	14
(2) 실시간예측기간(2006년 이후~)에 대한 예측력 평가	16
(3) 2020년 현업기준에 따른 과거예측기간에 대한 재평가	16
마. 동아시아 지역의 계절 MME 기후예측을 위한 climate driver 추가 발굴	16
(1) 동아시아 강수예측 영향 기후인자 등에 대한 문헌 조사	16

- (2) 동아시아 강수의 영향 기후인자 (climate driver) 선정17
- 바. 추가 발굴된 climate driver를 바탕으로 다중모델기반 기후예측 기술 개발20
 - (1) 예측 절차 및 방법20
 - (2) 선정된 climate driver의 재현성 모의 능력을 기준으로 새 MME를 위한 조합 구성 및 예측성능 평가21
 - (3) ENSO 유형과 강수예측 성능에 기반 한 앙상블모델 재구성23
 - (4) predictability source 파악25
 - (5) 예측 성능에 대한 요인26
- 3. 정규화기법을 활용한 다중모델 기반 통계예측모델 개발32
 - 가. 개요32
 - 나. 방법 및 자료32
 - (1) 자료32
 - (2) 개발방법33
 - 다. 결과39
 - (1) 월 강수량 적용 결과39
 - (2) 계절 강수량 적용 결과43
- 4. 베이즈 정규화 후처리 기법57
 - 가. 베이즈 접근법에 기반한 다중모델 격자 자료의 후처리57
 - (1) 베이즈 접근법57
 - (2) 정규화를 도입한 베이즈 회귀59
 - 나. 하인드캐스트 기간의 교차 검증 및 평가65
 - 다. 실시간 예측의 예시67
- 5. Probability Anomaly Correlation 을 통한 확률적 기후예측 보정70
 - 가. Probability Anomaly Correlation 기법에 기반한 다중모델 격자 자료의 통계적 후처리 ..70
 - 나. PAC 기법 적용을 위한 자료의 구성 및 후처리71
 - (1) 기후자료71
 - (2) PAC 기법의 후처리 방법71
 - (3) PAC 기법 적용 후 예측 성능평가 방법72
 - 다. PAC 기법 적용에 따른 다중모델 격자 자료의 통계적 후처리 결과73
 - (1) PAC 후보정의 공간적 분포73
 - (2) PAC 후보정의 정량적 결과78
- 6. 딥러닝 기반 계절내 예측기후 오차 저감 기법80

- 가. 신경망 훈련 기법 및 계절내 예측 자료80
- 나. 장단기기억기술 기반의 계절내 예측기후 자료의 구성 및 후처리81
 - (1) 참여 개별 기후모델81
 - (2) 개별 기후모델 및 다중모델앙상블 기반 계절내 예측기후 자료의 후처리 및 구성83
 - (3) 최적화된 장단기기억기술86
- 다. 딥러닝 적용에 따른 계절내 예측기후 자료의 후보정 결과89
 - (1) 개별 기후모델의 LSTM 적용에 따른 예측 성능 평가89
 - (나) 선행예측시간 3-4주의 예측성91
 - (2) MME 기반 계절내 예측기후의 LSTM 적용에 따른 예측 성능 평가99
- 7. 격자기반 계절내 예측 딥러닝 기법 개발108
 - 가. 자료 및 방법108
 - (1) 자료108
 - (2) 방법115
 - 나. 결과123
 - (1) 피쳐 엔지니어링 적용 결과123
 - (2) ConvLSTM 모델 개발125
- 8. 요약 및 결론130
 - 가. 요약 및 결론130
 - (1) 앙상블 재구성을 위한 물리현상130
 - (2) 정규화기법을 활용한 다중모델 기반 통계예측모델 개발132
 - (3) 베이즈 접근법에 의한 다중모델 앙상블 기법 개발133
 - (4) Probability Anomaly Correlation (PAC)를 통한 확률적 기후예측 보정133
 - (5) 딥러닝 기반 계절내 예측기후 오차 저감 기법133
 - (6) 격자기반 계절내 예측 딥러닝 기법 개발134
 - 나. 연구개발결과의 활용 방안 및 기대성과135
 - (1) 과학적·기술적 성과135
 - (2) 경제적·사회적 성과135
- 사사137
- References138

표 차례

Table	page
1. Final goal and annual objectives of the research project.	4
2. Main achievements of the first year 2019 of research project.	5
3. Annual plans and corresponding implementation methods of the second year 2020 of research project.	6
4. Description of the seven coupled climate models used in this study.	7
5. Three versions of hindcast data sets and experimental design.	14
6. Three versions of real-time forecast period, data availability and time-averaged anomaly correlation coefficients for East Asian precipitation prediction.	16
7. Summary of APCC MME models.	33
8. Brief description of the Least square method and Regularization method.	34
9. Brief description of LASSO (Least Absolute Shrinkage and Selection Operator) regression and Ridge regression.	34
10. Comparison of RMSE (Root-Mean-Square-Error) of PC time series between conventional linear model, LASSO regression and SCM for each season.	51
11. Seasonal Heidke Skill Score of both precipitation and temperature variables, which are averaged for all grids over the target East Asia region.	79
12. Information of 6 single climate models.	83
13. Information of climatic variables of 6 single climate models.	83
14. Classification of individual climate models for MME, MME-1, and MME-2.	85
15. The relative improvement of correlation coefficient of three climatic variables during target lead-time (week 3 and 4).	107
16. Summary of training dataset for ConvLSTM Model.	114

그림 차례

Figure	page
1. Research Structure.	3
2. (a) First and (b) second EOF patterns of a monthly rolling 3-month mean SSTAs computed for 25° S-25° N and 140° E-80° W during 1983-2005, based on OISST.	9
3. Time series of the combined PCs of (a) the first mode (red solid line for left y-axis) and (b) the second mode (blue dashed line for right y-axis) associated with Figure 2 with all months during January 1982 to December 2005.	10
4. Relative signs and distance magnitudes (see the relevant coordinate and scale at bottom, respectively) on a 2-dimensional plane depicting regression coefficients of the seasonal mean anomalous precipitation onto the first two PCs for (a-l) JFM to DJF.	11
5. Time-averaged ACC skills of the two MME mean (a) Australasian and (b) East Asian precipitation predictions as a function of seasons.	12
6. Time series (left panels) and their statistical distribution (right panels) of interannual variation of ACC skills averaged during corresponding AMJ-OND and FMA-MJJ seasons to (a) Australasian and East Asian precipitation predictions, based on training (1982-1993) and test (1994-2005) periods.	13
7. Time-averaged ACC skills of the two MME mean (upper and middle panels) Australasian (left panels) and East Asian precipitation predictions (right panels) and their difference fraction (%).	15
8. Climatological seasonal mean of East Asian and tropical west Pacific rainfall.	18
9. Regression of seasonal mean anomalous East Asian rainfall on tropical Western Pacific rainfall.	19
10. Temporal correlation coefficients of seasonal mean anomalous tropical western Pacific rainfall between observations and models.	20
11. East Asia with South Korea indicated by shading. (Adapted from Sohn et. al. (2013)). ..	21
12. Pattern correlation coefficients of regressions of seasonal mean anomalous East Asian rainfall on tropical western Pacific rainfall.	22
13. Time-averaged ACC skills of the two MME mean East Asian precipitation predictions as a function of seasons.	23
14. Probability distribution functions of regionally aggregated HSS (% , solid) and not EC coverage (% , dashed).	24
15. Probability distribution functions of regionally aggregated HSS (%).	25
16. Skill variation in response to Nino 3.4.	26
17. Skill variation in response to ENSO.	26
18. Temporal variations of the proportion of grid points in the above normal category (upper panel) and below normal category (bottom panel).	27
19. Time series of the anomaly pattern correlation coefficient (ACC) skill of the one-month lead MME mean East Asian (20° -60° N, 90° -150° E) precipitation prediction (blue dashed	

line for left y-axis) based on MME1 and the observed monthly three-month mean Niño 3.4 amplitude (red dashed line for right y-axis), within the period of 1982 to 2005.28

20. Same as Figure 19, but for MME 2 and the period of 1991 to 2010.29

21. Time-averaged ACC skills (for left y-axis) of the model-simulated precipitation prediction based on MME1 for the East Asia as a function of targeted forecast time.30

22. Same as Figure 21, but for MME2.31

23. Contours of the error and constraint functions for the LASSO regression.35

24. Contours of the error and constraint functions for the Ridge regression.36

25. Regression equation using the time series of principal components obtained from EOF analysis applied for observations and individual models.36

26. Examples of the time series of principal components obtained from EOF analysis.37

27. Selection of the regression coefficient as a function of λ37

28. LASSO solution path as a function of λ38

29. Time series of principal components used for regression equation for monthly precipitation in February. The PC time series are obtained from EOF analysis using k-fold cross validation (Fold 1).40

30. Selection of the regression coefficient and LASSO solution path as a function of λ using k-fold cross validation (Fold 1) for monthly precipitation in February.41

31. (left) Comparison of PC time series between conventional linear model (green), LASSO regression (red) and SCM (blue) for monthly precipitation in February.42

32. Comparison of ACC between conventional linear model (green), LASSO regression (red) and SCM (blue) for monthly precipitation in February.43

33. Spatial distribution of precipitation bias estimated from the LASSO regression for monthly precipitation in February 2010.43

34. Examples of the time series of principal components used for regression equation for seasonal precipitation.44

35. Selection of the regression coefficient for each season as a function of λ using k-fold cross validation (Fold 1).45

36. LASSO solution path for each season as a function of λ using k-fold cross validation (Fold 1).47

37. Comparison of PC time series between conventional linear model (green), LASSO regression (red) and SCM (blue) for each season.50

38. Comparison of ACC range during the hindcast period between conventional linear model, LASSO regression and SCM for each season.52

39. Comparison of ACC between conventional linear model (green), LASSO regression (red) and SCM (blue) for each season. Box plots shows the ACC range of individual models in each year.54

40. Spatial distribution of precipitation bias estimated from the LASSO regression for seasonal precipitation in January–February–March 2010.56

41. Schematics of Bayesian regression. <http://www.indiana.edu/~kruschke/BMLR>58

42. Schematics of regularization effects: (Left) l1-norm LASSO and (Right) l2-norm Ridge. Source: https://towardsdatascience.com/ridge-and-lasso-regression-a-complete-guide-with-python-scikit-learn-e20e34bcbf0b	59
43. Strategies of Bayesian post-processing with regularization applied in this study.	60
44. One-month lead July prediction for (a) Bayesian Ridge post-processing, (b) APCC-PMME, and (c) the observation reanalysis during the hindcast period.	61
45. Same as above except for August.	62
46. Same as above except for September.	63
47. Same as above except for October.	64
48. Same as above except for November.	65
49. Hindcast Heidke Skill Scores (HSS) for (Left) point-wise BMME, (Middle) APCC-PMME, and (Right) their difference for July 1-lead forecasts.	66
50. Same as above but for August.	66
51. Same as above but for September.	66
52. Same as above but for October.	67
53. Same as above but for November.	67
54. Real-time forecasts for the (Left) 1-month lead November, (Middle) 2-month lead December, and (Right) 3-month lead January forecasts.	68
55. Distribution of the HSS for hindcast cross-validation of (Left) 1-month lead November, (Middle) 2-month lead December, and (Right) 3-month lead January.	68
56. Equation for Heidke Skill Score calculation.	73
57. Precipitation and temperature HSS maps of the PAC-applied PMME (PAC PMME) and original APCC PMME (APCC PMME) with 1 month lead time in October, and maps of the HSS difference (Difference) between the PAC-applied PMME and original APCC PMME, which are calculated based on the hindcast from 1983-2010.	74
58. Precipitation HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jan to Jun using the hindcast from 1983-2010.	75
59. Precipitation HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jul to Dec using the hindcast from 1983-2010.	76
60. Temperature HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jan to Jun using the hindcast from 1983-2010.	77
61. Temperature HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jul to Dec using the hindcast from 1983-2010.	78
62. Explanation of k-fold cross validation in the research.	85
63. The repeating module in a standard RNN contains a single layer(A) and a LSTM contains four interacting layers(B) (Source: modified the 2019 research report and http://colah.github.io/posts/2015-08-Understanding-LSTMs/).	86
64. Description of feature engineering used in the research: (A) describes as a feature engineering process within the LSTM, (B) describes as the LSTM, (C) describes the entire	

modeling process.	87
65. Comparison of temporal correlation coefficient and root mean square error of S2S(gray box) and LSTM (green box) of daily maximum temperature of six single climate models during overall hindcast period.	90
66. Comparison of temporal correlation coefficient and root mean square error of S2S(gray box) and LSTM (green box) of daily minimum temperature of six single climate models during overall hindcast period.	90
67. Comparison of temporal correlation coefficient and root mean square error of S2S(gray box) and LSTM (light blue box) of daily total precipitation of six single climate models during overall hindcast period.	91
68. Comparison of weekly performance of temporal correlation coefficient and root mean square of S2S(gray box) and LSTM (green box) of daily maximum temperature of six single climate models.	92
69. Comparison of weekly performance of temporal correlation coefficient and root mean square of S2S(gray box) and LSTM (green box) of daily minimum temperature of six single climate models.	92
70. The comparison of weekly performance of temporal correlation coefficient and root mean square of S2S(gray box) and LSTM (light blue box) of daily total precipitation of single climate models.	93
71. Comparison of the temporal correlation coefficient density distribution at the daily maximum temperature for 3 and 4 week of lead-time of six single climate models.	94
72. Comparison of the temporal correlation coefficient density distribution at the daily minimum temperature for 3 and 4 week of lead-time of six single climate models.	94
73. Comparison of the temporal correlation coefficient density distribution at the daily total precipitation for 3 and 4 week of lead-time of six single climate models.	95
74. Comparison of the monthly temporal correlation coefficient scatter plot at the daily maximum temperature for 3 and 4 week of lead-time of six single climate models.	96
75. Comparison of the monthly temporal correlation coefficient scatter plot at the daily minimum temperature for 3 and 4 week of lead-time of six single climate models.	96
76. Comparison of the monthly temporal correlation coefficient scatter plot at the daily total precipitation for 3 and 4 week of lead-time of six single climate models.	97
77. Comparison of the average of temporal correlation coefficient of the daily maximum temperature of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of six single climate models.	98
78. Comparison of the average of temporal correlation coefficient of the daily minimum temperature of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of six single climate models.	98
79. Comparison of the average of temporal correlation coefficient of the daily total precipitation of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of six single climate models.	98

80. Comparison of the temporal correlation coefficient of overall hindcast period at the box plot(A) and the monthly temporal correlation coefficient at the scatter plot(B) for the daily maximum temperature of ECMWF, MME-1 and MME-2.	99
81. Comparison of the temporal correlation coefficient of overall hindcast period at the box plot(A) and the monthly temporal correlation coefficient at the scatter plot(B) for the daily minimum temperature of ECMWF, MME-1 and MME-2.	100
82. Comparison of the temporal correlation coefficient of overall hindcast period at the box plot(A) and the monthly temporal correlation coefficient at the scatter plot(B) for the daily total precipitation of ECMWF, MME-1 and MME-2.	100
83. Comparison of the temporal correlation coefficient of the 3 and 4 week of lead-time at the box plot(A) and the monthly temporal correlation coefficient of the 3 and 4 week of lead-time at the scatter plot(B and C) for the daily maximum temperature of ECMWF, MME-1 and MME-2.	101
84. Comparison of the temporal correlation coefficient of the 3 and 4 week of lead-time at the box plot(A) and the monthly temporal correlation coefficient of the 3 and 4 week of lead-time at the scatter plot(B and C) for the daily minimum temperature of ECMWF, MME-1 and MME-2.	102
85. Comparison of the temporal correlation coefficient of the 3 and 4 week of lead-time at the box plot(A) and the monthly temporal correlation coefficient of the 3 and 4 week of lead-time at the scatter plot(B and C) for the daily total precipitation of ECMWF, MME-1 and MME-2.	102
86. Comparison of the temporal correlation coefficient density distribution of the three target climatic variables(the daily maximum and minimum temperature, and the total precipitation) of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of ECMWF and MME.	103
87. Comparison of the monthly temporal correlation coefficient of the daily maximum temperature at the 3 and 4 week of the lead-time of MME.	104
88. Comparison of the monthly temporal correlation coefficient of the daily minimum temperature at the 3 and 4 week of the lead-time of MME.	104
89. Comparison of the monthly temporal correlation coefficient of the daily total precipitation at the 3 and 4 week of the lead-time of MME.	104
90. Comparison of the average of temporal correlation coefficient of the daily maximum temperature of the original S2S, LSTM, and the optimized LSTM, respectively during about one month of the lead-time of MME(left).	105
91. Comparison of the average of temporal correlation coefficient of the daily minimum temperature of the original S2S, LSTM, and the optimized LSTM, respectively during about one month of the lead-time of MME(left).	106
92. Comparison of the average of temporal correlation coefficient of the daily total precipitation of the original S2S, LSTM, and the optimized LSTM, respectively during about one month of the lead-time of MME(left).	106

93. Glosea5 model.	108
94. The clipping temperature data of Glosea5.	109
95. The input data of ConvLSTM model.	110
96 Globally averaged temperature data(top), radiance from MSU satellite data(center) and global mean bias adjustments(bottom).	111
97. Daily total precipitation of Glosea5 at Jan 1, 2006.	112
98. Maximum temperature of Glosea5 at Jan 1, 2006.	113
99. Minimum temperature of Glosea 5 at Jan 1, 2006.	114
100. Represent functions of RNN' s state.	115
101. A diagram of LSTM https://mikigom.github.io/jekyll/update/2017/06/13/deep-learning-forecast-research-1.html	116
102. A diagram of Long-term Recurrent Convolutional Networks https://mikigom.github.io/jekyll/update/2017/06/13/deep-learning-forecast-research-1.html	117
103. The structure of ConvLSTM.	118
104. The usage of Colaboratory by google drive.	119
105. Conceptual diagram of CNN-LSTM.	120
106. The Structure diagram of ConvLSTM framework.	121
107. The structure diagram of feature engineering for LSTM.	123
108. RMSE of Tmax by feature engineering for leadtime.	124
109. RMSE of Tmin by feature engineering for leadtime.	125
110. RMSE of precipitation by feature engineering for leadtime.	125
111. The result of cost function for ConvLSTM model.	126
112. The example of overfitting by normalization.	127
113. Comparison of forecast performance for entire lead time.	128
114. RMSE of prediction by ConvLSTM model.	129

1. 서론

가. 연구의 배경

날씨부터 기후까지 이음새 없는 예측 (Seamless prediction) 시스템은 World Climate Research Program (WCRP)의 주요 관심분야 중 하나일 정도로 최근 전 세계적 이슈로 부각되고 있다. 이에 신뢰도 높은 전지구적 혹은 지역적 중장기 계절 예측 정보 제공을 위한 사회적, 경제적 요구들이 급증하고 있으며, 아울러 계절내 시간 규모(2주-2달) 예측자료에 대한 수요와 인식도 증가하고 있다(Vitart et al., 2017).

APEC (Asia-Pacific Economic Cooperation) 기후센터 (APEC Climate Center, APCC)에서는 2005년 개소 이후부터 지난 십여 년 이상 아시아-태평양 지역 내 다중모형 앙상블 (Multi-Model Ensemble, MME) 기반의 고품질의 계절기후예측자료를 생산 및 제공하기 위해 꾸준한 노력을 해 오고 있다. 현재는 정기적으로 매월 3개월에서 6개월의 MME 기반의 기후예측자료를 결정론적/확률론적 형태로 생산하고 있으며, 기후예측 검증자료 또한 함께 제공하고 있다. 아울러, 이러한 현업 운영 및 서비스 이외에 MME 참여 모형의 진단, 예측시스템의 개선 및 안정화, 기후예측자료의 검증, 새로운 콘텐츠 개발을 통한 기후예측서비스 다변화와 같은 기후예측 기술 개발 및 향상을 위한 노력이 꾸준히 지속되어 왔다. 또한 이러한 내부적 노력 이외에도 APCC MME 참여 기후예측모델/시스템이 15여 개에 달하며, 최근까지 명실공이 가장 폭 넓은 기후모델자료를 보유, 이것이 바로 고품질의 계절기후예측자료를 생산하는 주된 요인으로 여겨져 왔다.

최근에는 세계기상기구 (World Meteorological Organization, WMO) 선도센터, 유럽의 C3S, 북미의 MME (North American Multi-model Ensemble) 등 MME를 위한 플랫폼이 APCC 이외에도 다수 존재하며, APCC를 위협하며 새로운 시장 및 경쟁자로 부상하고 있다. 이들은 최근 계절 내에서 계절 (Subseasonal-to-Seasonal, S2S) 규모의 기후예측 자료 등 다양한 자료를 보유하면서, APCC를 위협하며 새로운 시장의 경쟁자로 부상하고 있다. 따라서 이러한 기관들과 비교하여 우위를 확보하기 위해서는 기후예측 기술의 고도화가 필요하다. 또한, 그 간의 역학모형 기반의 기후예측 정보는 전구 관점에서 서비스 되어 오고 있으나, WMO에서는 유사한 기후 특성을 기반으로 하는 지역 규모에서 기후 전망이나 해석이 이루어져야 함을 권고하고 있다 (<https://public.wmo.int/en/our-mandate/climate/regional-climate-outlook-products>).

기존 MME 기법은 가능한 모든 자료를 활용하여 결정론적으로 단순 평균하거나(Simple Composite Method, SCM), 앙상블 멤버의 크기에 따라 가중치를 주어 확률적으로 가중 평균하는 통상적인 결합방식으로, 중위도 이상 지역에서는 예측성능이 낮다. 일반적으로, MME 기법에서는 개별모델의 역학적 특성뿐만 아니라 모델예측 간 상관관계도 주요한 역할을 하는데, 현행의 MME 기법에서는 그러한 점이 고려되지 않고 있다. 또한, 널리 사용되는 회귀모형과 같은 자료 중심적(data-driven) 방법은 표본수가 충분하지 못한 자료 특성이 있어 과적합(overfitting)의 문제를 내포하고 있다. 아울러, 다중 모델이 예측하는 미래 기후의 경향성을 파악하는 데 집중하여 모형 내/외의 불확실성 등의 부가 정보는 일부만 활용하고 있다.

한편, WMO 선도센터 및 NMME는 최근 S2S 예측자료를 보유 및 제공 중이며 국제적으로 다양한 연구들이 수행되고 있다. 하지만, 그 성능은 단기, 장기 예보에 비해 현저히 떨어진다. 특히 한반도를 비롯한 동아시아 지역의 성능은 다른 지역에 비해 현저히 떨어지고 MME 적용의 효용성도 미비하다. 반면에 최근 각광받고 있는 딥러닝 기술은 다양한 알고리즘의 개발과 디지털 혁명, 컴퓨터의 발달로 갈수록 방대해지는 데이터의 축적에 따라, 다양한 분야에서 복잡한 문제들을 해결하는데 널리 적용되고 있다. 이러한 딥러닝 기술은 예측이 어려운 기후 분야에서도 강수량 등의 예측성능개선 가능성을 보여 주었다. 일반적인 기계학습 기술을 이용하여 계절 예측 데이터의 정확성을 향상시키려는 연구가 최근 수년 동안 수행되고 있지만, 계절내 예측 자료의 경우 일반 기계학습이나 딥러닝 기술을 활용한 연구는 계절 예측에 거의 없다. 따라서 모델 기반 예측기술 개발에 집중하고, 예측성 향상을 위한 계절/계절내 기후예측 기술을 고도화 할 필요가 있다.

MME 계절기후예측의 예측성 근간은 앙상블에 참여하는 개별모델의 성능에 크게 의존하는데, 참여 모델 자체의 성능 개선은 센터 내에서는 수행하기 어려우며 모형 운영 기관 (Model provider)의 모델 향상 계획에 전적으로 의존한다. 또한, 계절기후예측에서는 월별 자료만 제공하는 등 자료 가용성 (data availability)에 대한 한계가 존재한다. 따라서 센터 내 수집된 다중 모델 자료를 바탕으로 기후예측 자료를 분석 및 해석하고, 다양한 통계적 기법을 적용하여 예측성 향상을 위한 계절 및 계절내 기후예측 기술을 개발하고자 한다.

기존의 통상적인 MME 기법과 달리 물리 현상 및 통계 분석을 기반으로 모델선별 방법에 대한 연구가 필요하며, 정규화(regularization) 기법으로 고차원 자료의 회귀모형 과적합을 방지하고자 함. LASSO(Least Absolute Shrinkage and Selection Operator)와 같은 정규화 기법을 기반한 예측회귀모형 연구가 비교적 최근에 기후예측분야에도 도입됨에 힘입어 (cf. Lim et al (2014)), 본 연구에서는 다각도로 정규화 기법을 적용하여 보다 일반적이고 현업적용이 가능한 MME 기법을 개발하고자 한다. 정규화 기법을 이용한 EOF 분석 기반 계절예측회귀모형은 계절예측자료의 공간적으로 의미 있는 기상패턴을 찾아 정규화 기반의 회귀분석을 수행하여 최종적으로 APCC MME에 내재한 자료의 특성을 고려한 MME 기법을 제공할 수 있다. 아울러 다중 모델 예측 자료의 보정을 통해 MME 예측 성능을 향상시키고 소실되던 부가 정보를 활용하고자 한다.

상대적으로 성능이 떨어지는 계절내 시간규모 예측정보의 활용성을 증대시키기 위해서 계절내 역학예측을 개선하는 통계적 기술 개발이 요구된다. 또한, MME 계절내 예측 자료에 딥러닝 기술을 적용하여 기후예측 자료의 오차를 줄이고 정확성을 향상할 수 있는 기술 개발이 필요하다. 예측 성능의 오차가 큰 것으로 알려진 3주에서 4주에 대한 계절내 기후예측 자료에 MME 자료와 딥러닝 기술을 적용하면, 3~4주 내의 계절내 예측 자료의 오차 감소와 더불어 신뢰도 높은 자료를 제공할 수 있을 것으로 보인다.

나. 연구의 목표

이 과제에서는 동아시아 지역을 중점 연구지역으로 설정하여 지역별 특화된 다중모형 기반

계절/계절내 예측 기술 개발을 통해 계절/계절내 예측성 향상을 목표로 한다. 따라서 이 과제를 통해

- (1) 예측성 향상을 위한 다중모델 기반의 지역 특화 계절 예측 보정 기술 개발 및 제안,
- (2) 계절내 예측의 예보관 활용을 위한 가이드라인 개발 및 제안,
- (3) 딥러닝을 활용한 계절내 강수, 최저/최고기온 예측 MME 기법 개발,
- (4) 계절내 예측의 오차 저감

을 달성하고자 한다.

다. 연구의 내용 및 추진전략

이 과제에서는 예측 시간 규모 및 예측자료의 유용성 등을 고려하여, Figure 1과 같이 크게 (1) 예측성 향상을 위한 다중모델 기반 계절 예측 기술개발 및 (2) 다중모델 계절내 예측 기반 기술 개발로 구분하여 연구를 진행하고자 한다. 연구 내용 (1)과 (2)에 관련된 연구 방법 및 결과는 다음 2-5장과 6-7장에서 각각 나타내었다.

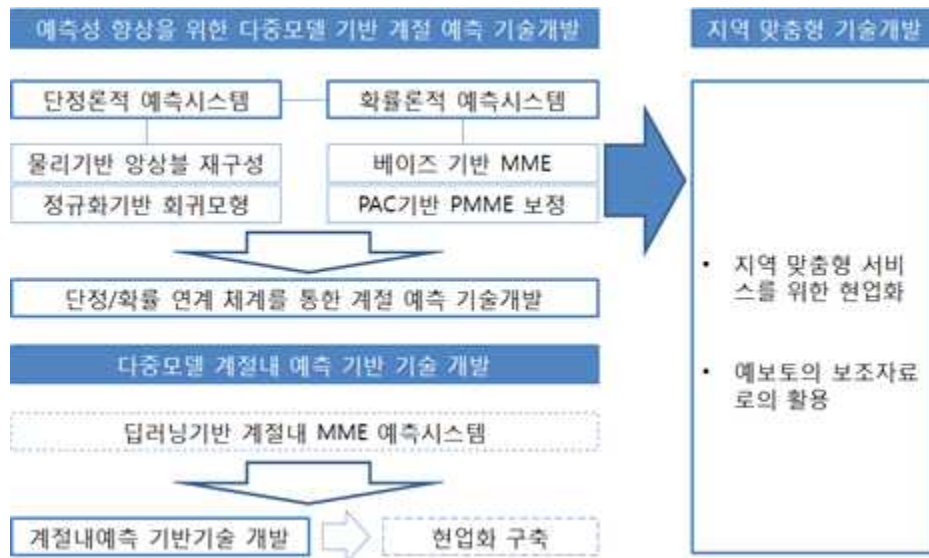


Figure 1. Research Structure.

라. 연구의 추진체계

이 과제는 5단계 아태사업으로 총 2019년부터 2021까지 3년 동안 수행되는 다단계 사업이다. 5단계 사업의 최종 목표는 “지역특화형 선도 기후예측 기술 개발”으로 연차별 최종 목표는 Table 1과 같다. 2020년 당해연도는 전체 사업의 2차년도로 1차년도에 구축된 지역 맞춤형 계절 MME 및 계절내 MME 기후예측 기술 개발 체계를 기반으로 지역 맞춤형 계절 MME 및

계절내 MME 기후예측 기술 개발을 목표로 한다. Figure 1의 연구의 추진 전략에서 나타낸 세부 연구와 그에 따른 구체적인 2020년 목표 및 달성내용은 Table 1에 나타내었다. 올해 수행된 세부 연구의 자세한 연구 방법 및 연구 결과는 2장부터 7장까지 기술되었다. 과제가 마무리되는 3차년도에는 2021년에는 2차년도에 개발된 계절예측 기술을 바탕으로 다중모델 기반의 지역특화 계절예측시스템을 구축하고, 기반 기술인 계절내 예측 기술을 고도화하고자 한다.

Table 1. Final goal and annual objectives of the research project.

5단계 (2019–2021) 최종목표		
지역특화형 선도 기후예측 기술 개발		
연차별 최종목표 및 현재까지의 달성내용		
1차년도('19)	지역 맞춤형 계절 다중모델 앙상블 및 계절내 MME 기후예측 기술 개발 체계 구축	
2차년도('20)	지역 맞춤형 계절 MME 및 계절내 MME 기후예측 기술 개발	
	물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술 개선 및 예측성 검증	물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 예측성능 안정성 평가 및 동아시아 지역의 계절 MME 기후예측을 위한 climate driver 추가 발굴
	베이지스 접근법에 의한 다중모델 앙상블 기법 개발	베이지스 회귀를 통한 과거 관측 -개별 모델 예측을 적합(fitting)하고 정규화 기법을 적용해 안정성을 향상시킨 후처리 기법을 개발, 과거기후예측 (hindcast) 기간의 삼분위 확률 예측 정보 생산, 기존 기법 및 관측과 결과 비교
	Probability Anomaly Correlation (PAC)를 통한 확률적 기후예측 보정	동아시아 지역 계절 확률 MME 기후예측에 대한 PAC 적용 및 검증
	딥러닝을 활용한 계절내 예측 강수, 최고·최저 기온의 MME 기법 개발 및 계절내 예측의 오차 저감	예측빈도 및 기간이 상이한 기후모델 기반의 통합 MME 기법 구축 및 딥러닝 기술 적용에 따른 MME 기반 계절내 예측자료의 오차 저감
3차년도('21)	다중모델 기반의 지역특화 계절예측시스템 구축 및 계절내예측 기반기술 기술 고도화	

2. 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술 개선 및 예측성 검증

가. 개요

1차년도인 2019년에는 “지역 맞춤형 계절 다중모델앙상블 기후예측 기술 개발을 위한 체계가 구축” 되었으며, 이는 물리현상 기반의 앙상블 재구성을 통한 지역특화 계절 예측기술 개발을 통해서 그 체계가 마련되었다. 참여모델의 지역별 예측성능 평가 및 차별화된 MME 구성을 위해서 APCC MME 기후예측에 참여하는 모델의 후보자료(1982-2005)를 바탕으로 SST, 강수량 및 지표면온도의 예측성능이 분석되었다. 엘니뇨-남방진동(El Nino와 Southern Oscillation, ENSO)의 복잡성과 그 원격상관의 예측성능을 진단하고 향상시키기 위한 물리적 인자로 사용되었다. 즉 ENSO 및 그 복잡성에 대한 모델의 재현성이 모델의 충실성(fidelity)을 위해서 사용되었다. 그 결과를 바탕으로 충분한 충실성을 가진 모델을 가지고, 여러 가지 모델 선별 방안으로 MME를 구성하였다. MME 조합은 모델의 충실성을 어떻게 평가하느냐에 따라 달라지는데, ENSO를 바로 평가하거나 그 원격상관의 재현성을 평가하는가에 따라 다르게 구성하였다. 모델 선택의 효과는 계절 및 지역에 따라 달랐다. 1차 년도의 주요 연구 성과는 Table 2와 같으며, 구체적인 내용은 Sohn and Kim (2020)에 기술되었다.

Table 2. Main achievements of the first year 2019 of research project.

1차년도('19) 최종목표
지역 맞춤형 계절 다중모델앙상블 및 계절내 MME 기후예측 기술 개발 체계 구축
주요 연구 성과
<p>(1) 아태지역을 대상으로 지역적·계절적 특징을 반영하는 새로운 다중모델앙상블 계절예측 구성 방안 제시</p> <ul style="list-style-type: none"> · 다중모델 기반 지역 맞춤형 계절예측 기술개발을 위해서, 차별화된 다중모델 앙상블 구성에 대한 근거로 ENSO Complexity를 아태지역 계절 변동의 새로운 주요인자로 도입. 이는 단순 통계 결과가 아닌 역학적 근거에 바탕을 둔 모델 선정 과정으로 기존의 연구와 차별화 <p>(2) Non-mature phase of ENSO 계절 동안 동아시아-호주 몬순지역 강수량의 계절 예측성능 향상 방안 발견</p> <ul style="list-style-type: none"> · ENSO의 변동성이 작은 non-mature phase 기간 동안 호주 및 동아시아 강수예측에 대한 ENSO complexity 각 모드의 영향을 파악하여, 두 지역의 계절 강수량 예측에 대한 새로운 단서를 제공. 즉, ENSO complexity의 계절성을 활용한 지역 맞춤형 계절 기후 예측 향상 방안 제시

2020년 당해 연도는 전체 연구사업의 2차 년도로 1차 년도에 구축된 기술 개발 체계를 바탕으로, 지역 맞춤형 계절 MME 기후예측 기술을 개발하고자 한다. 따라서 1차 년도에 개발된 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술을 개선하고 그 예측성을 검증하고자 한다. 세부적인 연구 추진 내용은 Table 3에 나타난다.

Table 3. Annual plans and corresponding implementation methods of the second year 2020 of research project.

해당년도(2020년) 계획 및 연구추진체계 · 방법		연구수행 내용
물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술 개선 및 예측성 검증	<ul style="list-style-type: none"> 다양한 기후예측자료의 기후예측성능 검증을 통한 안정성 평가 	<ul style="list-style-type: none"> 물리현상 기반의 앙상블 재구성을 통한 다양한 과거기후예측자료 및 실시간 기후예측자료 생산
	<ul style="list-style-type: none"> 동아시아 지역에 대해서 계절별로 분석된 model set을 바탕으로 MME 적용 및 예측성 평가 	<ul style="list-style-type: none"> 과거기후 예측기간 (1982-2005년)에 대해서 cross-validation을 통해 예측력 재평가 실시간예측기간(2006년 이후-)에 대한 예측력 평가 2020년 현업기준에 따른 과거예측기간에 대한 재평가
	<ul style="list-style-type: none"> 동아시아 지역의 계절 MME 기후예측을 위한 climate driver 추가 발굴 	<ul style="list-style-type: none"> 동아시아 강수의 영향 기후인자에 대한 문헌 조사 및 climate driver 선정
	<ul style="list-style-type: none"> 추가 발굴된 climate driver를 바탕으로 다중모델기반 기후예측 기술 개발 	<ul style="list-style-type: none"> 선정된 climate driver의 재현성 모의 능력을 기준으로 새 MME를 위한 조합 구성 및 예측성능 평가

나. 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측 기술

이 과제는 2018년 4월에 과제 컨셉 기획, 같은 해 9월에 과제의 전체 3년 내용이 제안되었

다. 따라서 과제 수행 1년차에는 APCC 6개월 계절예측 현업 기준으로 MME version 1에 참여 중인 개별 기후모델을 바탕으로 연구가 진행되었다. 사용된 모델 자료는 Table 4와 같다. 하지만 과제 2년차인 당해연도 중반에 APCC 6개월 계절예측이 MME version 2로 변경되었다. 따라서 현업 활용성을 제대로 평가하기 위해서 다양한 기후 자료의 기후예측성능 검증을 통한 안정성 평가가 수행 되었다. 그 결과는 2. 다절에서 소개하도록 한다.

Table 4. Description of the seven coupled climate models used in this study.

Country ^⓪	Institute ^⓪	Model ^⓪	AGCM/resolution ^⓪	OGCM/resolution ^⓪	Ensemble	
					Member ^⓪	Hindcast Period ^⓪
Australia ^⓪	BOM ^⓪	POAMA2.4 ¹ ^⓪	BAMv3.0d/T47L17 ^⓪	ACOM2/0.5-1.5°lat x 2°lon L25 ^⓪	33 ^⓪	1983-2011 ^⓪
Canada ^⓪	MSC ^⓪	CCCma CGCM2 ^⓪	AGCM3/T63L31 ^⓪	OGCM4 ^⓪	10 ^⓪	1982-2010 ^⓪
			AGCM4/T63L31 ^⓪	(1.41°lon x 0.94°lat L40) ^⓪	10 ^⓪	1982-2010 ^⓪
Italy ^⓪	CMCC ^⓪	CMCC-SPSv2 ³ ^⓪	ECHAM5.3/T63L19 ^⓪	OPA8.2/ORCA2 grid_L31 ^⓪	9 ^⓪	1982-2005 ^⓪
Japan ^⓪	JMA ^⓪	JMA/MRI-CPS2 ⁴ ^⓪	JMA-GSM/TL159L60 ^⓪	MRI.COMv3/0.3-0.5x1.0°L53 ^⓪	10 ^⓪	1979-2014 ^⓪
South Korea ^⓪	APCC ^⓪	SCoPS ⁵ ^⓪	ECHAM5.3/T159L31 ^⓪	POP2.0.1/0.3-0.5x1.0°L40 ^⓪	5 ^⓪	1982-2013 ^⓪
USA ^⓪	NASA ^⓪	GMAO ⁶⁻⁷ ^⓪	GEOS-5/288x181L72 ^⓪	MOM4/720 x 410 L40 ^⓪	11 ^⓪	1982-2011 ^⓪
	NCEP ^⓪	CFSv2 ⁸ ^⓪	GFS/T126L64 ^⓪	MOM4/½°lat x 1°lon L40 ^⓪	20 ^⓪	1982-2010 ^⓪

(1) 앙상블 재구성을 위한 물리현상

1차 년도인 2019년도에는 지역 특화형 선도 기후예측 기술 개발을 위한 지역 맞춤형 계절 다중모델 앙상블 기후예측 기술 개발 체계가 구축되었다. 이 연구에서 개발된 기술 체계는 크게 다음 두 가지 과정으로 구성된다.

- (1) 참여모델의 지역별 예측 성능 평가,
- (2) 차별화된 MME 구성 방안

참여모델의 일반적 예측 성능 평가 및 특성을 분석하고, 이에 기반을 둔 아태지역 내 지역별 차별화된 MME 구성 적용 가능성을 평가 하였다. 즉 지역 특화형 선도 기후예측 기술 개발을 위해서, 물리현상을 기반으로 앙상블을 재구성하였다. 기후 커뮤니티에서, 엘니뇨-남방진동¹⁾은 전 지구 및 지역기후 변동의 가장 영향력이 있는 기후인자이며(Seow, 2018), 역학 모델

1) 가장 친숙하고 대표적인 '기후 모드'로, 적도 태평양에서 지표 바람과 해류 상호작용의 지표이다. 그 경우에 평균 이상의 따뜻한 적도 해수면 온도는 무역풍 양화를 초래하고, 다시금 해수면 온도 상승을 유발한다(양의 피드백).

에서 예측성의 주 원천으로 알려져 있다. 따라서 이 연구에서는 엘니뇨-남방진동을 새롭게 정의하고 기후영향(climate impact)을 분석하였다. 또한, 이에 대한 모델의 재현성을 바탕으로 모델을 선별하여 지역 맞춤형 MME를 개발하였다.

최근 21세기에 발견된 ENSO Modoki(Seow, 2018)와 같은 다른 종류의 ENSO를 포함하여 엘니뇨-남방진동은 아시아-태평양 내 많은 지역에서 기후 변동 및 수문 사이클에 많은 영향을 미친다(Ashok et al., 2007, 2009; Weng et al., 2007; Zhang et al., 2007; Feng et al., 2010; Pradhan et al., 2011; Sohn et al., 2012). 하지만, 관례적으로 Nino3.4 지수로 정의된 엘니뇨-남방진동 (Footnote 1 참조) 및 그 기후영향은 엘니뇨-남방진동의 다양성 및 그에 따른 기후영향의 차이를 반영하지 못 한다. 그러므로 엘니뇨-남방진동의 다양성(또는 복잡성) 및 그에 따른 기후영향의 차이에 대한 모델의 재현성을 모델 선정의 기준으로 삼았다. ENSO 이벤트와 두 몬순 지역(즉, 호주와 동아시아)에서의 ENSO와 관련된 강수 영향은 관측 자료를 바탕으로 진단되었다. 관측된 전구 해수면온도는 최적내삽법을 사용하여 지점 관측과 위성 자료를 바탕으로 향상된 분석 자료이다(Reynolds et al., 2002). 관측 강수 자료는 Climate Anomaly Monitoring System (CAMS) and Outgoing Longwave Radiation (OLR) Precipitation Index (OPI) (CAMS OPI) 로 지점강수와 위성으로부터 추정된 자료를 바탕으로 한다(Jonowiak and Xie, 1999).

매월 열대 태평양 지역(25° S- 25° N, 140° E- 80° W) 의 계절 평균 해수면 아노말의 EOF 분석 결과가 ENSSO의 상태를 정의하기 위해서 사용되었다. 이 연구에서 ENSO는 중-동태평양 ENSO의 혼합을 캡처하기 위해서 처음 두 EOF 모드(Figures 2와 3 참조)의 결합으로 정의되었다(Timmermann et al., 2018). 첫 번째 공간 구조는 중-동 열대 태평양의 warming(cooling)으로 특징지어진다. 두 번째 모드는 첫 번째 모드에 직교함수이며, 첫 번째 모드의 동서방향 전치(shift)를 나타낸다. 양(음)의 위상이 클수록, 중-동 열대 태평양 시그널(예를 들어, warming)의 서쪽(동쪽) 편향을 나타낸다. 이 연구에서는 ENSO의 복잡성을 반영하여 엘니뇨-남방진동의 2 가지 공간 유형(Figure 2 참조) 및 시간적 변화(Figure 3 참조)를 활용하여 매월 엘니뇨-남방진동의 발달 상황을 분석하였다.

엘니뇨는 복잡함 현상일지라도, 보통 전구 패턴은 평균으로부터 해수면 온도의 편차로 설명하다. 따라서 이 현상은 적도 태평양의 평균 해수면 온도의 편차로 간단히 지수화 되어 잘 설명할 수 있으며, 평균 이상의 온도 일 때를 엘니뇨 이벤트라고 한다(Neelin and Latif, 1998).




Figure 2. (a) First and (b) second EOF patterns of a monthly rolling 3-month mean SSTAs computed for 25° S- 25° N and 140° E- 80° W during 1983-2005, based on OISST. The fractional variance explained by each mode and season are provided in the upper right of each panel. The horizontal and vertical black dashed lines denote the equator and International Date Line.

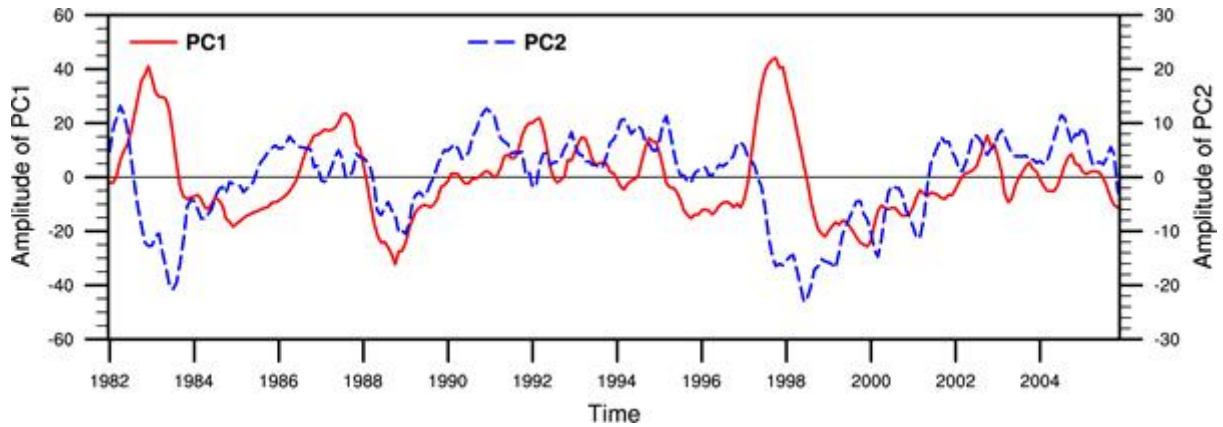


Figure 3. Time series of the combined PCs of (a) the first mode (red solid line for left y-axis) and (b) the second mode (blue dashed line for right y-axis) associated with Figure 2 with all months during January 1982 to December 2005.

(2) 물리현상 기반의 앙상블모델 재구성

아태지역 특화 계절예측기술 개발을 위해서 엘니뇨-남방진동의 강수 및 기온 기후영향 (climate impact)에 기반 하여 아태지역 내 주요 영역을 선정 (Figure 4 참조)하였다. 호주, 동아시아, 북미, 열대 남미지역이 선정되었으며, 이 지역을 대상으로 재구성된 다중모델 기반 계절예측 성능 및 특성이 분석 되었다. ENSO 모드와 지역 강수의 관련성에 대한 재현성은 모델의 성능을 평가하고 새로운 MME의 서브셋을 위해서 성능 좋은 모델을 선별하기 위해 사용되었다. 새 MME를 바탕으로 예측성능 및 계절간 변동(inter-season spread)의 특징이 분석 되었으며, ENSO의 non-mature phase에서의 예측성능 및 요인 또한 분석되었다.

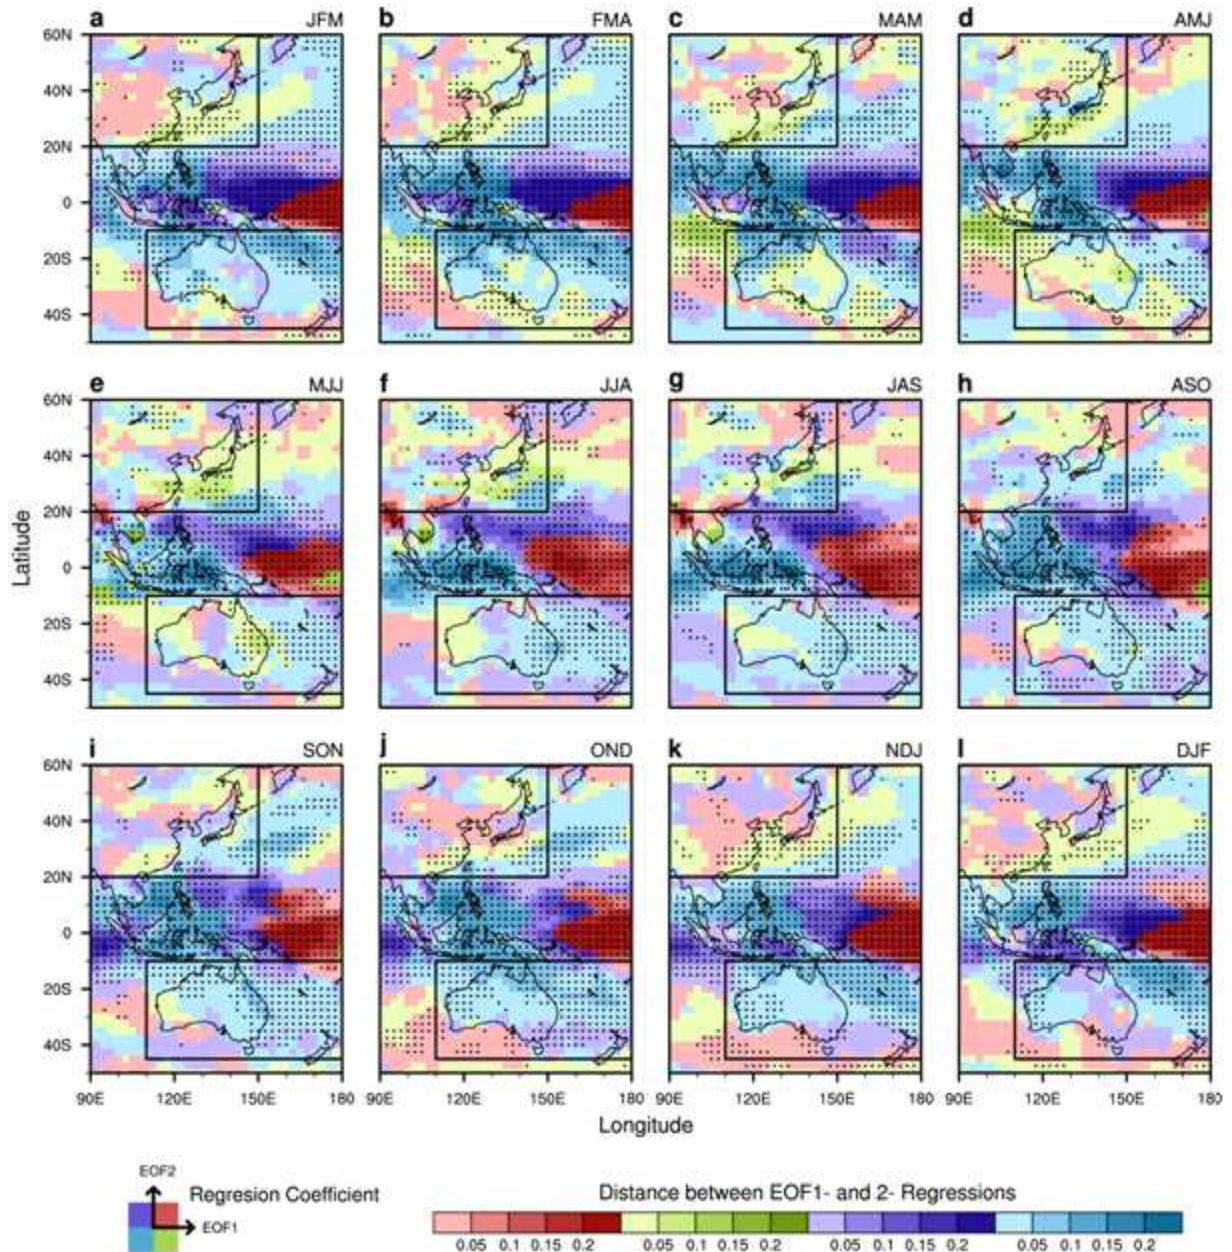


Figure 4. Relative signs and distance magnitudes (see the relevant coordinate and scale at bottom, respectively) on a 2-dimensional plane depicting regression coefficients of the seasonal mean anomalous precipitation onto the first two PCs for (a-l) JFM to DJF.

(3) 지역특화 계절예측 기술 개발

다중 참여모델의 일반적인 아태지역 계절예측 성능 평가 및 특성 분석이 되었다. 지역/계절 별로 참여모델의 예측성능을 Anomaly Pattern Correlation Coefficient (ACC), MME Efficiency Index(MEI) 등을 기준으로 평가하고, 평가 결과를 바탕으로 아태지역 내 지역별 차별화된 MME 구성(model combination) 방안을 연구하고 적용 가능성을 평가하였다. 이를 통해 지역 특화형 MME 구성을 통한 기후예측의 정확도 향상을 확인하였다(Figure 5참조).




Figure 5. Time-averaged ACC skills of the two MME mean (a) Australasian and (b) East Asian precipitation predictions as a function of seasons.

다. 다양한 기후예측자료의 기후예측성능 검증을 통한 안정성 평가

(1) 과거재현 자료의 통계적 안정성 확인

1차 년도의 연구에서는 ENSO 모드와 지역 강수의 관련성에 대한 재현성을 모델의 성능을 평가하고 새로운 MME의 서브셋을 위해서 성능 좋은 모델을 선별하기 위한 기준으로 사용하였다. 따라서 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 예측성능 안정성 평가를 위해 과거예측기간 (1982-2005년)에 대한 예측성능의 정상성(stationarity) 검증을 수행하였다. 과거예측기간 자료를 훈련기간(1982-1993, 12년)과 검증기간(1994-2005, 12년)으로 나누어 분석한 결과, 두 기간 모두 재구성된 앙상블 예측의 예측성능이 우수하고 특이점이 나타나지 않아 예측성이 안정적인 것을 알 수 있다(Figure 6 참조). 두 지역의 강수예측 성능의 전체 시계열은 지역이나 MME에 상관없이 어떠한 추이(trend)도 나타나지 않으며, Augmented Dickey-Fuller (ADF) test를 통한 유의성 검정 수행 결과 1% 유의 수준에서 통계적으로 안정적임을 나타낸다.

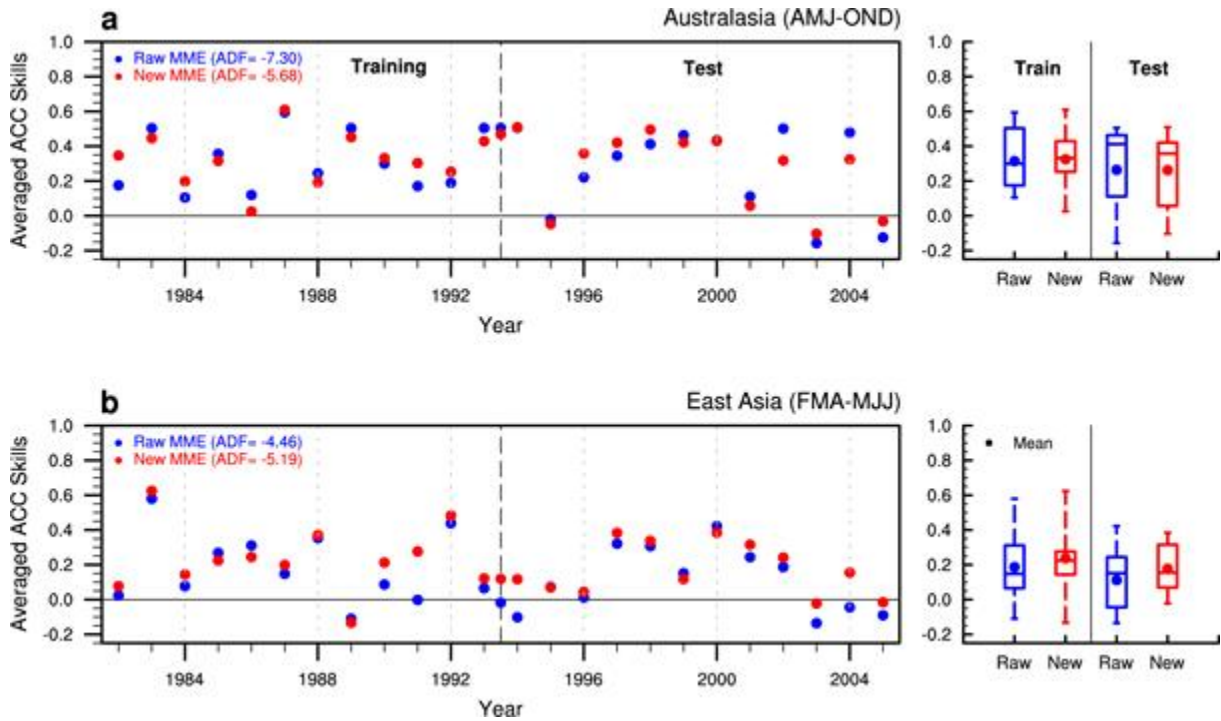


Figure 6. Time series (left panels) and their statistical distribution (right panels) of interannual variation of ACC skills averaged during corresponding AMJ-OND and FMA-MJJ seasons to (a) Australasian and East Asian precipitation predictions, based on training (1982–1993) and test (1994–2005) periods. Blue and red circles denote the raw MME based on all-inclusive models and new MME based on best performing models, respectively. Augmented Dickey–Fuller (ADF) tests are applied to test the stationarity of whole time series, and the relevant ADF statistics are provided in parentheses following the labelled targeted data sets of upper left of each panel. The statistical distribution of these time series for the raw and new MMEs are illustrated by box plots and mean values (circles), based on training and test periods.

(2) 물리현상 기반의 앙상블 재구성을 통한 다양한 과거기후예측자료 및 실시간 기후예측자료 생산

물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 예측성능 안정성을 평가하기 위해서 다양한 과거기후예측자료 및 실시간 기후예측자료 생산 하였다(Table 14참조). 이를 바탕으로 예측 성능 검증 및 예측성 향상을 확인하였다.

Table 5. Three versions of hindcast data sets and experimental design.

구성 버전	사용 모델	과거 예측기간	K Fold	실험 설계
V2019	APCC, CMCC, JMA, MSC, NASA, NCEP, PNU, POAMA	1982-2005	23	과거 예측기간 차이
V2019*	상동	1991-2010	19	
V2020	APCC, BCCV2, CMCC_SPS3, GLOSEA5, JMA, MSC_CANSIPSV2, NASA, NCEP, PNU, BOM_ACESS-S1, UKMO	상동	19	사용 모델 차이

라. 동아시아 지역에 대해서 계절별로 분석된 model set을 바탕으로 MME 적용 및 예측성 평가

물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 예측성능 안정성을 평가하기 위해서 다양한 과거기후예측자료 및 실시간 기후예측자료 생산하고, 이를 바탕으로 예측 성능 검증 및 예측성 향상을 확인하였다.

(1) 과거기후 예측기간 (1982-2005년)에 대해서 cross-validation을 통해 예측력 재평가

위 2.(다).(1)절의 통계 검정을 일반화하기 위해서, cross-validation을 통해 예측을 재평가하였다. 즉 원시 MME와 새 MME의 통계적인 정상성을 확인하고, 뿐만 아니라 임의적으로 생산된 성능, 과적합된 관련성, 임의의 모델 선택을 회피하기 위해서 표준 leave-one-out cross-validation method (Michaelsen, 1987; Jolliffe and Stephenson, 2012)이 아노말리 및 EOF 계산, 재현성 평가, 과거기후예측자료와 관측 사이의 예측성능 검증을 포함하는 전 과정에서 적용되었다. 예를 들어, 하나의 목표 예측 해에 대한 계절평균 아노말리는 그 목표 해를 제외한 나머지 참조 기간에 대해서 해당기후학적 계절 평균으로부터 계산된다. 목표 계절 및 해에 대한 예측 성능은 교차 검증된 과거 기후 예측 성능의 범위 내에 존재하며, 교차검증에 의한 차이는 일반적으로 사소하여 무시하였다. 또한 과거기후 예측기간에 대한 평균 예측력이 교차 검증된 과거기후 예측기간의 예측성능 분포 범위 내에 존재하였다. 따라서 통계 분석 결과가 독립된 자료(independent data)에 대해서 일반화 할 수 있음을 알 수 있었다(Figure 7 참조).

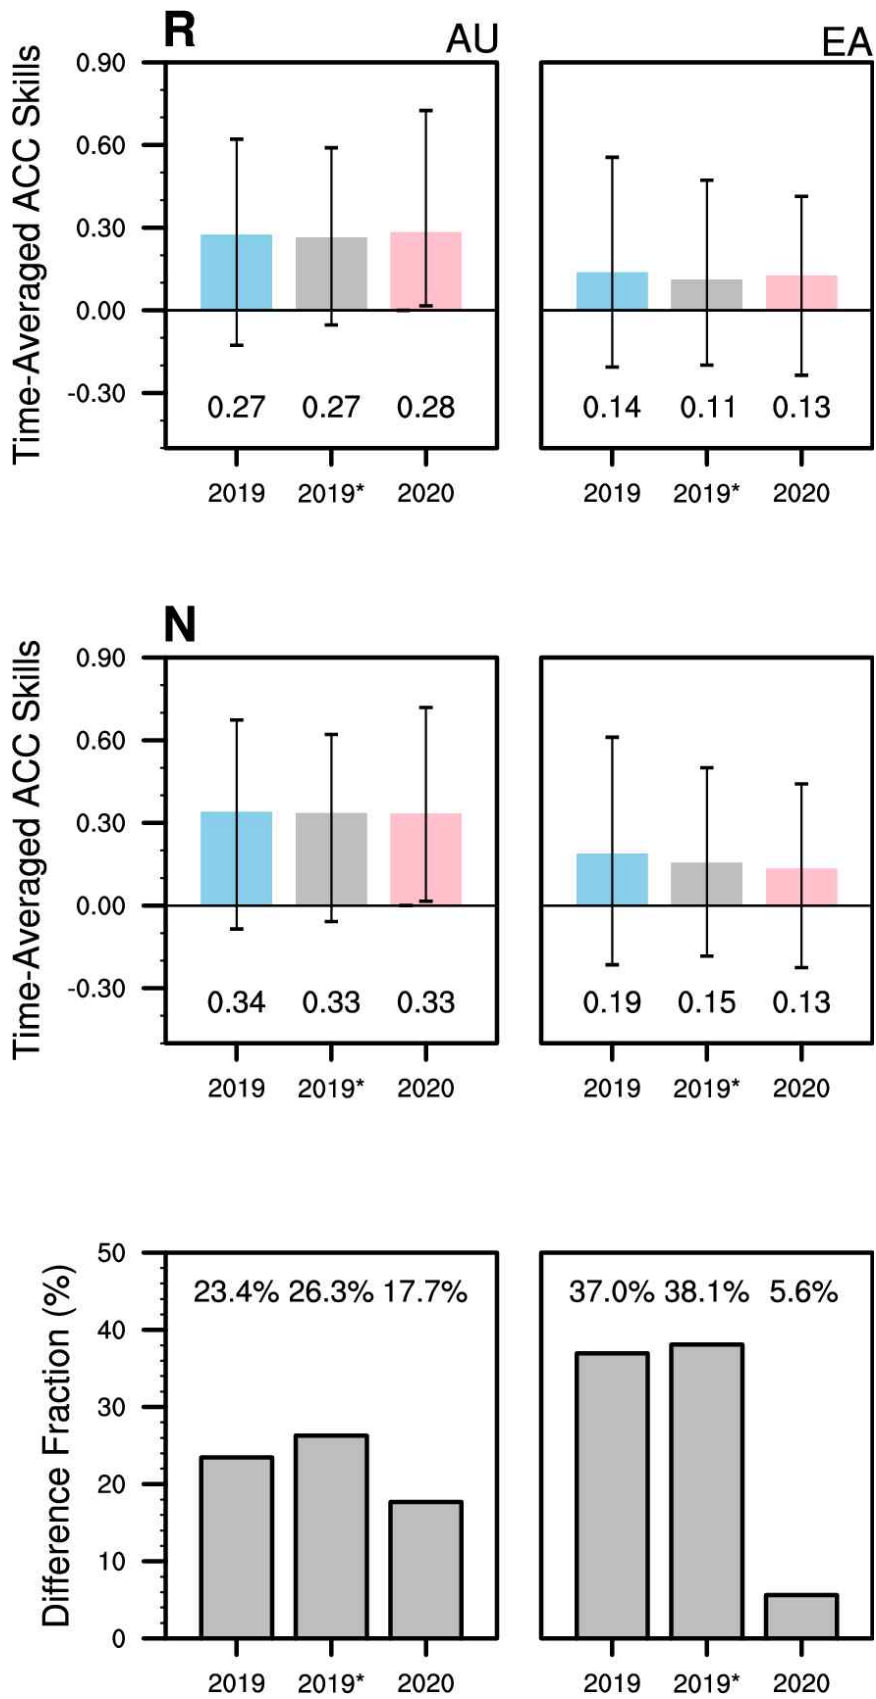


Figure 7. Time-averaged ACC skills of the two MME mean (upper and middle panels) Australasian (left panels) and East Asian precipitation predictions (right panels) and their difference fraction (%).

(2) 실시간예측기간(2006년 이후~)에 대한 예측력 평가

실시간예측기간(2006년 이후)에 대한 예측력 평가를 수행하였다. 과거기후 예측기간 내에 구축된 모델 선별 과정을 실시간 예측자료에 적용 시에도 예측 성능 개선이 유지, 이를 통해 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 안정성을 확인하였다 (Table 6 참조).

Table 6. Three versions of real-time forecast period, data availability and time-averaged anomaly correlation coefficients for East Asian precipitation prediction.

구성 버전	실시간 예측기간	참여모델 점유율(%)	예측 성능 (평균 ACC)		
			Raw MME	New MME	예측 개선율
V2019	2006-2020	83.3%	0.10	0.15	57.9%
V2019*	2011-2020	81.0%	0.14	0.15	8.3%
V2020	2011-2020	75.3%	0.23	0.13	※모델 선정을 위한 자료 불충분

(3) 2020년 현업기준에 따른 과거예측기간에 대한 재평가

2020년 현업기준에 따른 과거예측기간에 대한 재평가 및 이전 자료와 상호비교를 수행하였다. 세 가지 버전의 과거기후 예측자료(Table 5 참조)에 물리현상기반의 앙상블모델 재구성 적용한 결과 물리현상기반의 앙상블모델 재구성은 사용된 자료 및 과거기후 예측기간에 상관없이 예측력 개선에 기여함을 알 수 있었다(Figure 7 참조).

마. 동아시아 지역의 계절 MME 기후예측을 위한 climate driver 추가 발굴

(1) 동아시아 강수예측 영향 기후인자 등에 대한 문헌 조사

동아시아 지역의 계절 MME 기후예측을 위한 기후영향인자(climate driver) 추가 발굴을 위한 선행연구에 대해 조사하였다. 전년도 겨울철 ENSO는 이듬해 동아시아 여름 몬순 강수의 높

은 관련성을 나타낸다(Ding and Chan, 2005; Wang et al., 2008; Chen et al., 2013). MME 기후 예측의 6개월 선행시간을 고려 할 때, 전년도 겨울철 ENSO와 이듬해 동아시아 여름 몬순 강수의 관련성은 역학 모델 내에서는 구현하기가 힘들다. 따라서 역학모델과 이러한 관련성을 바탕으로 한 통계모형과의 합성을 향후 고려 해 볼 수 있다. 동아시아 여름 몬순은 대기 원격 상관에 의해 영향을 받으며(Zhang and Zhou 2015), 그 대표적인 예가 Silk Road Pattern이다. 단일 역학 모델에서의 예측성 평가가 이루어졌으나(Li et al., 2020), 모델 선별을 위한 기후인자로 사용하기에는 어려움이 있어 향후 연구에 고려하기로 한다.

(2) 동아시아 강수의 영향 기후인자 (climate driver) 선정

중위도 기후는 열대 강수에 의해 영향을 받는데, 이는 로스비파(Hosstins and Karoly, 1981; Simons et al., 1983; Li et al., 2014)와 수증기 수송(Martin et al. 2020)에 의해서 이루어진다. 이 중 동아시아 여름 몬순 강수의 예측성능은 열대 태평양 및 Maritime Continent의 강수예측 성능과 관련(Li et al., 2015)이 있는 것으로 알려져 있다. 특히 열대 서태평양 강수는 역학 모델에서 비교적 예측 가능하다(Scaife et al. 2019).

Figure 8은 동아시아와 열대 서태평양의 기후학적 계절 평균을 나타낸다. 남중국해-한반도-일본 열도를 지나는 강수 밴드가 연중 내내 보이며, 이 지역을 중심으로 하는 동아시아 지역(Figure 8에서 상위 네모 박스로 표시)은 이 연구의 예측 목표 지역이다((Figure 11 참조). 그 아래 필리핀을 중심으로 하는 지역(Figure 8에서 하위 네모 박스로 표시)은 동아시아 강수 예측을 위한 기후영향인자로, 이 열대 태평양 강수 예측 성능을 모델 선별을 위한 인자로 추가 발굴하였다. 동아시아 강수와 관련성 및 예측 성능을 효과적으로 평가하기 위해서 (110° - 140° E, 5° S- 25° N)의 영역(Figure 8에서 하위 네모 박스로 표시)에서 해당 기후 계절 아노말리를 평균하여 사용하였다.

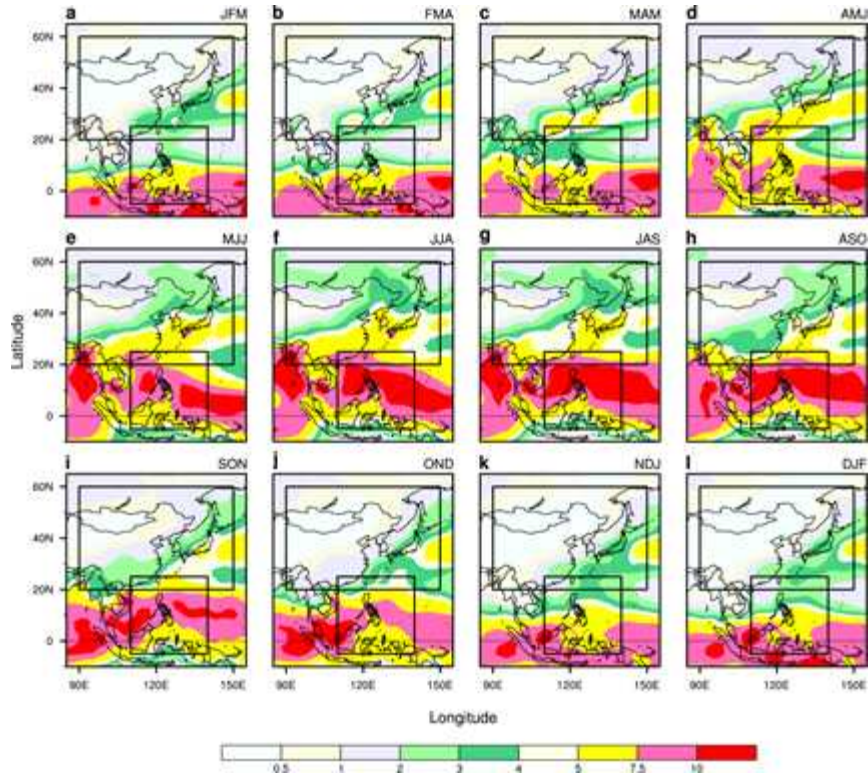


Figure 8. Climatological seasonal mean of East Asian and tropical west Pacific rainfall.

(가) 열대 서태평양 강수와 동아시아 강수의 관련성

Figure 9은 열대 서태평양 지역(110° -140° E, 5° S-25° N)에서 영역 평균된 강수 지수에 대한 동아시아 여름 강수 변동성에 대한 회귀 계수를 나타낸다. 연중 한반도를 영역을 중심으로 유의미한 상관 관계를 보인다. 계절마다 관련성이 있는 영역은 세부적인 차이를 보이기는 하지만, 시간적으로 살펴보면 겨울(JFM)부터 한여름(JJA)까지는 음의 상관관계를 가진다. 반면에 늦여름(JAS)부터 가을(SON)까지는 양의 상관관계를 보이다가, 늦가을(OND)부터 한겨울(DJF)까지는 다시 음의 상관관계로 돌아선다. 이러한 동아시아 여름 강수와 열대 서태평양 강수의 변동성 사이의 관련성은 통계적으로 유의하며, 대부분의 계절에서 95% 신뢰구간(Figure 9에서 검은 점으로 표시된 격자)을 넘어선다.




Figure 9. Regression of seasonal mean anomalous East Asian rainfall on tropical Western Pacific rainfall.

(나) 열대 서태평양 강수의 재현성

Figure 10은 열대 서태평양 지역(110° -140° E, 5° S-25° N)에서 영역 평균된 강수 지수에 대한 계절별 시계열의 예측성능을 검증한 결과이다. Figure 10에서 각 숫자는 해당 개별 모델을 나타내며, 계절별로 나타나는 바의 분홍색 부분은 모델 성능의 중간 값을 상회하는 그룹을, 보라색은 모델 성능의 중간 값을 하회하는 그룹을 나타낸다. JFM을 제외하고, 대부분의 계절에서 관측에서 보이는 서태평양 강수 변동의 상당 부분이 대부분의 모델에 의해서 예측 가능함을 알 수 있다. 예측성능은 계절적인 변동성을 보이는데, 여름에는 예측성이 타 계절에 비해 약간 떨어지기는 하나, 대체적으로 높은 예측성능을 보인다.

이러한 예측성능은 통계적으로도 유의하며, 대부분 95% 신뢰구간(Figure 10에서 파란색 실선으로 표시)에서 유의하다. 즉 하위그룹은 99%의 신뢰구간(Figure 10에서 파란색 파쇄선으로 표시)에서 유의하며, 상위그룹은 99.9% 신뢰구간(Figure 10에서 파란색 점선으로 표시)에서 유의하였다. 따라서 모델 간 성능 분포가 작아, 상위 그룹과 하위그룹의 격차가 크지 않음을 알 수 있다. 따라서 지수 자체의 성능으로 모델 선별을 할 경우 동아시아 예측 성능의 개선이 크지 않았다(그림 미 제시).




Figure 10. Temporal correlation coefficients of seasonal mean anomalous tropical western Pacific rainfall between observations and models.

결과적으로 ENSO complexity 이외에 열대 태평양 강수예측성능을 향후 모델 선별 과정을 위한 영향 기후인자로 선정하였다. 기후인자의 예측성능을 바로 사용하는 대신에 기후인자와 동아시아 강수 사이의 관련성 및 모델의 재현성을 바탕으로 모델을 선별하였다(아래 2.바절 참조).

바. 추가 발굴된 climate driver를 바탕으로 다중모델기반 기후예측 기술 개발

(1) 예측 절차 및 방법

(가) 대상 예측영역

이 연구의 목적은 지역 기후 (예를 들어, 강수)를 정확하게 예측하는 것으로 대상 예측영역은 동아시아(Figure 11 참조)이며, 그 한가운데 33° N - 39° N 와 124 ° E - 130 ° E의 범위에서 한반도의 남한 영역 (6-7장의 대상 연구영역)을 포함한다.




Figure 11. East Asia with South Korea indicated by shading. (Adapted from Sohn et. al. (2013)).

(나) 확률 예측방법

이 연구에서 개발된 확률 예측방법은 기후학적 평균 바이어스가 보정된 자료를 바탕으로 한다. 카테고리 바운더리는 1991-2010에서 산출되었으며, 비모수화 카운팅 및 경험적 폴링 방법으로부터 확률이 예측되었다.

(2) 선정된 climate driver의 재현성 모의 능력을 기준으로 새 MME를 위한 조합 구성 및 예측 성능 평가

추가 발굴된 기후영향인자(climate driver)인 서태평양 강수 변동성을 이용하여 다중모델기반 기후예측 기술을 개발하였다. 선정된 climate driver의 재현성 모의 능력을 기준으로 새 MME를 위한 조합을 구성 할 때 모델 간 성능 분포가 작아, 이 연구에서는 서태평양 강수와 동아시아 강수의 관련성에 대한 모델의 재현성을 바탕으로 새 MME를 위한 조합을 구성하고 그 예측성능을 평가하였다.

(가) 열대 서태평양 강수와 동아시아 강수의 관련성에 대한 재현성

Figure 12은 Figure 10과 동일한 정보를 나타내나, 차이점은 열대 서태평양 강수와 동아시아 강수의 관련성에 대한 모델의 재현성을 나타낸다. 즉 Figure 9과 같은 동아시아 지역의 회귀계수에 대해 관측과 모델 간 공간에 대한 상관계수를 나타낸다. 관련성에 대한 모델의 재현성은 열대 서태평양 강수 자체의 예측성(Figure 10 참조)보다 그 예측성능이 다소 낮다. 또한

계절 변동성도 좀 더 명확하여, 늦여름부터 여름철에 가장 낮은 예측성을 보인다. 예를 들어, JAS 계절에 공간에 대한 상관계수가 떨어져 정반대의 재현성을 보이는 모델도 관측된다. 또한, 재현성능이 상대적으로 높은 NDJ나 DJF 계절 동안에는 특정 모델의 재현 능력이 나머지 모델 그룹으로부터 크게 벗어나는 사례를 보여준다. 재현성능의 수준과 상관없이 모델 간 성능 분포가 작은 것을 알 수 있다.




Figure 12. Pattern correlation coefficients of regressions of seasonal mean anomalous East Asian rainfall on tropical western Pacific rainfall.

(나) 동아시아 지역에 대한 검증 결과

Figure 13은 Figure 5b와 동일한 정보를 나타내나, 그 차이점은 Figure 5b은 ENSO를 기후 인자로 활용하여 MME1에 적용한 결과이고, Figure 11은 열대서태평양 강수를 바탕으로 MME2에 적용한 결과이다. Figure 5b에서는 모델 선별을 통해서 상당한 개선을 확인한 반면에, Figure 13은 모델 선별을 통한 예측성능 개선이 상대적으로 미비하다. 이는 열대서태평양 강수와 동아시아 강수의 관련성에 대한 모델 재현성의 모델간 분포가 작아, 기존의 가용한 모델을 바탕으로 한 앙상블에 비해, 선별된 모델을 바탕으로 한 앙상블의 예측 개선율이 크지 않음을 알 수 있다.

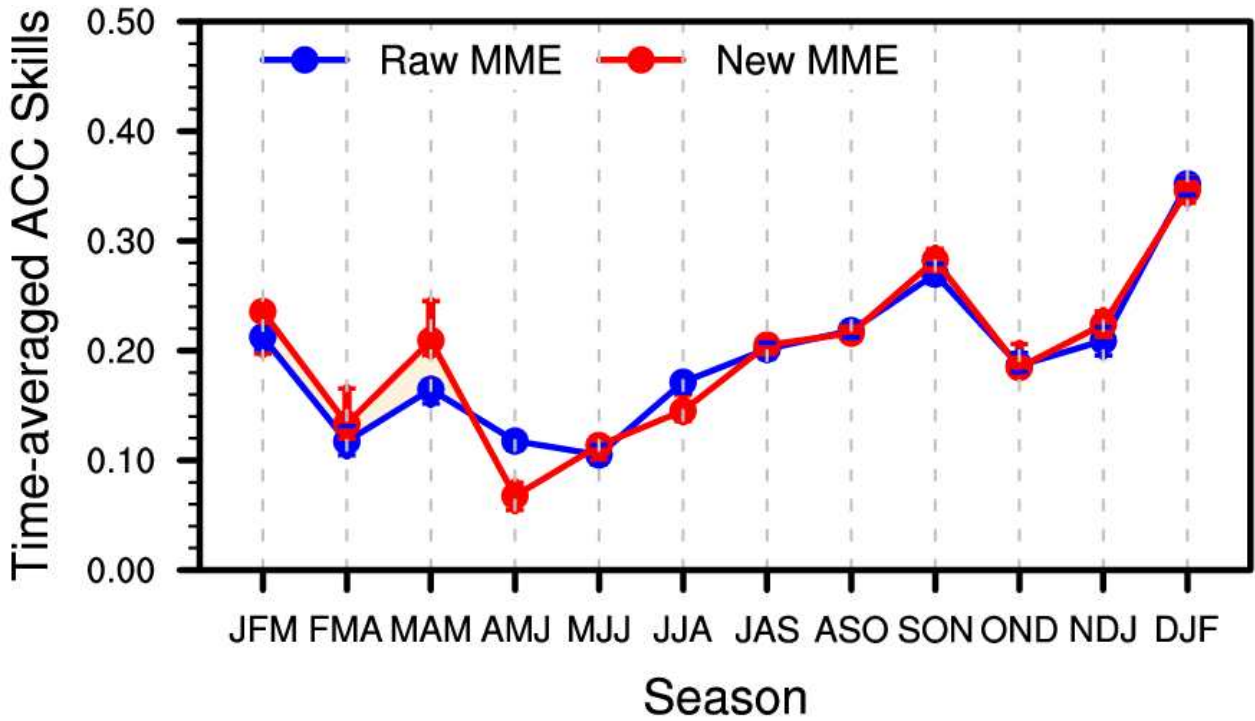


Figure 13. Time-averaged ACC skills of the two MME mean East Asian precipitation predictions as a function of seasons.

(3) ENSO 유형과 강수예측 성능에 기반 한 앙상블모델 재구성

동아시아 강수 변동에 영향을 줄 수 있는 주요 기후 인자인 ENSO와 서태평양 강수 변동을 각각 사용하여 모델 선별을 수행, 앙상블을 재구성하는 경우에 각 기후인자와 동아시아 강수 간 재현성에 대한 모델 분포가 작아 예측성능의 개선이 크지 않음을 알 수 있었다. 이에 Johnson et al. (2014)에서 이용된 방법과 같이 각각의 기후인자에 대해 재구성 두 MME를 합성하여 최종 앙상블을 구성하고자 한다. 아래는 ENSO 유형과 서태평양 강수 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술 개선 결과를 일반적인 방법으로 (기후값 대비) 예측성을 검증한 결과(아래 2.바.(3).(가)절 참조)와 앙상블모델 재구성을 통한 MME 예측성능을 이전과 상호 비교한 결과(아래 2.바.(3).(나)절 참조)를 보여준다.

(가) 기후값 대비

ENSO 유형 및 열대 태평양 강수의 예측성능을 이용한 다중모델기반 동아시아 기후예측 기술을 개발하였다. Figure 14은 과거재현 자료의 동아시아 강수량에 대해 계산된 HSS와 not EC coverage의 확률밀도 함수를 가용한 모든 모델로 구성된 앙상블(P0, 검은색)과 선별된 모델로 구성된 앙상블(P3, 녹색)에 대해서 나타났다. P0와 P3를 비교할 때, HSS와 not EC coverage의 품위(performance) 분포가 P0보다 P3에서 모두 개선된 것을 알 수 있다.

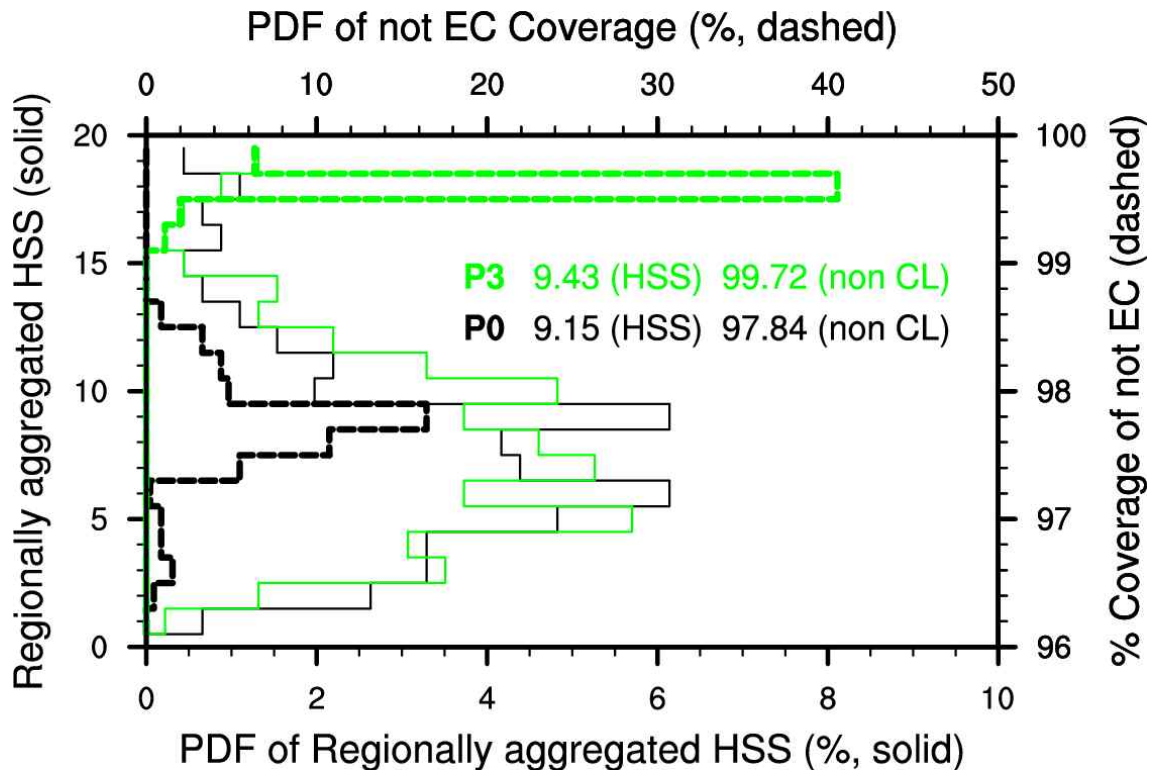


Figure 14. Probability distribution functions of regionally aggregated HSS (%, solid) and not EC coverage (%, dashed).

(나) 표준 예측 시스템 대비

Figure 15은 표준 예측 시스템(여기서는 P0) 대비 계산된 P3의 HSS의 밀도확률함수를 나타낸다. HSS가 0인 경우는 P0와 P3의 성능이 같음을 나타낸다, 음의 값은 P0가 P3보다 성능이 우세한 경우를 나타내며, 반대로 양의 값은 P3가 P0보다 성능이 우세한 경우를 나타낸다. 전체 예측된 값 중 60.53%가 예측성능이 개선된 경우이며, 39.47%가 예측성능이 개선되지 못한 경우를 나타낸다. 평균적으로 P3가 P0에 비해 예측이 개선되었으며, 이는 1,000개의 부트 스트랩을 수행할 경우 95% 신뢰구간에서 통계적으로 유효한 값이다.




Figure 15. Probability distribution functions of regionally aggregated HSS (%).

선별된 모델을 바탕으로 한 앙상블은 기존의 가용한 모델을 바탕으로 한 앙상블에 비해, 기 후값 대비(Figure 14 참조) 또는 표준 예측 시스템 대비(Figure 15 참조) 향상된 예측 성능을 보여 줌을 알 수 있었다. 따라서 아래 2.바.(4)절에서는 예측성의 원천을 알아보기로 한다.

(4) predictability source 파악

(가) ENSO와 관련된 예측성의 시간 변동성 분석

예측성의 원천을 알아보기 위해서, ENSO와 관련된 예측성의 시간 변동성을 분석하였다. Nino 3.4에 대한 HSS의 시간적인 반응을 살펴보면, 선별된 모델을 바탕으로 한 앙상블은 기존의 가용한 모델을 바탕으로 한 앙상블에 비해, ENSO와의 관련성이 더 컸다(Figure 16 참조). 또한 엘니뇨보다는 라니냐이거나 중립일 경우의 예측성능이 훨씬 높았다. ENSO의 복잡성을 기준으로 HSS의 시간적인 반응을 살펴보면, P0보다 P3에서 예측성이 높은 요인은 중동태평양의 warming/cooling보다 그것의 zonal shift가 더 큰 역할을 하는 것을 알 수 있다(Figure 17 참조).




Figure 16. Skill variation in response to Nino 3.4.




Figure 17. Skill variation in response to ENSO.

(5) 예측 성능에 대한 요인

(가) 기존('20년 연구결과)의 앙상블 재구성을 바탕으로 한 MME의 한계 파악

Figure 18은 전체 격자에 대한 각 above와 below 카테고리의 비율(%)의 시간적인 변동성을 나타낸다. HSS는 결국 각 카테고리에 대해서 전체 격자수 중 기후값 대비 예측한 카테고리의 hit 수를 나타내는 것으로, 각 카테고리에 대해서 관측과 같은 비율을 가질수록 높은 예측 성능을 가진 것으로 간주된다. 각 카테고리에 대해서 관측과 좀 더 가깝거나 유사한 시계열을 보일수록 이는 높은 예측성으로 귀결됨을 알 수 있다. 따라서 기존의 가용한 모델을 바탕으로 한 앙상블에 비해, 선별된 모델을 바탕으로 한 앙상블은 관측값과 좀 더 근사한 시계열을 보이면서 결국 예측성능의 향상을 보인다. 하지만, P와 P3의 차이가 크지 않으며, 관측 시계열과 다소 유사성이 떨어지는 것을 알 수 있다. 이는 곧 P0이든 P3이든 모델의 강수 예측성 자체에 의해 제한됨을 알 수 있다. 즉, 두 시스템은 동일 시스템으로 태생적으로 예측성의 한계를 지님을 알 수 있다.

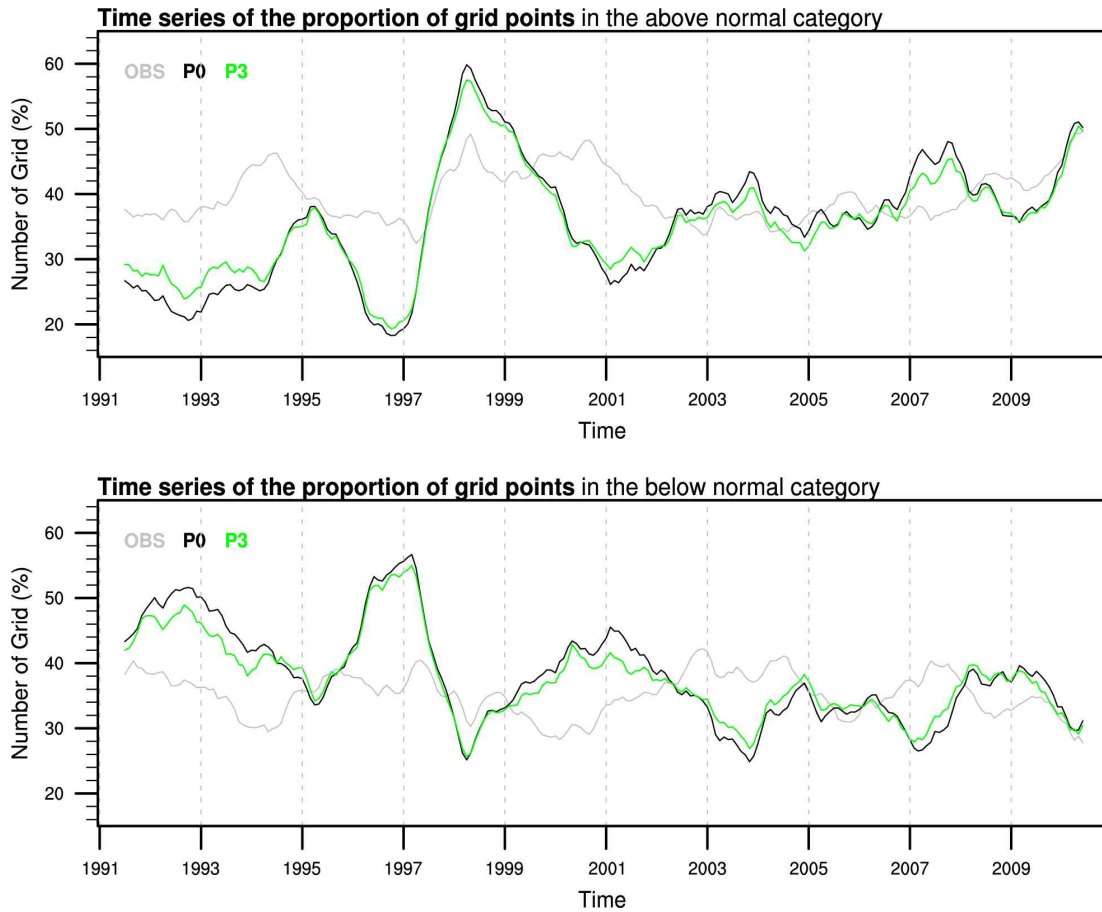


Figure 18. Temporal variations of the proportion of grid points in the above normal category (upper panel) and below normal category (bottom panel).

(나) 예측성 한계의 요인 분석

Figures 19와 20는 동아시아 강수 예측 성능에 있어서 ENSO의 영향을 나타낸다. 구체적으로 Figures 19은 MME1 자료를 기준으로 하여 24년 동안의 모든 계절에 대해 동아시아 지역의 APCC MME 1개월 선행 강수 예측과 관측과의 아노말리 패턴 상관 계수(anomaly pattern correlation coefficient, ACC)를 바탕으로 MME 강수 예측 성능의 시간적인 변동을 나타낸다. 교차 검증된 ACC 성능은 목표 예측 계절과 해에 대한 개별 모델 예측과 관측 자료의 강수 아노말리로부터 계산된다(2.라.(1)절 참조). 1992-2005년 동안의 목표 MME ACC 성능은 교차 검증된 과거예측기후 예측성능의 범위 내에 존재한다. 예측성능을 명백한 연간 사이클을 보여주면, 계절에 따라 변동한다. 지역 MME 예측 성능은 상대적으로 제한되어 있는데, MME 1개월 선행 강수 예측의 시간 평균된 동아시아 ACC 값은 0.18이다.

하지만, 동아시아 지역에 대한 MME 강수 예측 성능은 관측 Niño 3.4 지수 크기의 변동과 (99% 신뢰구간에서) 통계적으로 유의하게 관련성이 있으며, 그 상관관계 값은 0.28이다. MME2 자료에서는 동아시아 지역 MME 강수예측 성능과 관측 Niño 3.4 지수 크기의 변동의 상관관계는 좀 더 커져서, 그 값은 0.41을 나타낸다(Figure 20 참조).

높은 예측 성능은 엘니뇨가 강할 때인 1982/1983, 1987/1988과 1997/1998의 ENSO 성쇠기에 관측 된다(Figures 19와 20 참조). 강수 예측 성능과 Niño 3.4 해수면온도 지수에서 2년 주기의 시그널을 제외하면 그 상관관계가 더 커져서, MME1에서는 0.54를 MME2에서는 0.66을 나타낸다. 동아시아 지역에 대한 강수 예측 성능과 ENSO 강도 사이의 관련성의 상대적인 정도는 ENSO에 의해 설명되는 fractional variance로 표현될 수 있다. 동아시아 지역에서 강수 예측의 변동성은 전형적인 ENSO에 의해서 근사적으로 MME1에서는 8%가, MME2에서는 17%가 설명된다. MME1과 MME2를 상호 비교할 때, 동아시아 강수 예측성능에서 ENSO의 영향이 MME2에서 훨씬 커짐을 알 수 있다.




Figure 19. Time series of the anomaly pattern correlation coefficient (ACC) skill of the one-month lead MME mean East Asian (20° - 60° N, 90° - 150° E) precipitation prediction (blue dashed line for left y-axis) based on MME1 and the observed monthly three-month mean Niño 3.4 amplitude (red dashed line for right y-axis), within the period of 1982 to 2005. The area filled in light blue indicates the ACC skill distribution of cross-validated hindcasts associated with the targeted season and year of prediction. Solid lines show the 2-year low pass filtered data of the former two time series. Temporal correlation coefficients (TCCs) between the observed Niño 3.4 amplitudes and MME simulated precipitation skills are given in parentheses following the legends (with values exceeding the 1% significant level marked by double asterisks).




Figure 20. Same as Figure 19, but for MME 2 and the period of 1991 to 2010.

Figures 21과 22는 동아시아 강수예측성능의 모델 간 분포를 나타낸다. MME2는 상대적으로 원시 예측성이 낮고 모델 간 분포가 작아 MME1과 비교했을 때 예측성능의 개선율이 상대적으로 작다. 따라서 지역 강수예측에서 ENSO의 영향이나 모델간 성능 분포를 고려할 때 물리현상 기반의 앙상블모델 재구성은 가용한 모델 자료의 기본 특성에 의존함을 알 수 있다.




Figure 21. Time-averaged ACC skills (for left y-axis) of the model-simulated precipitation prediction based on MME1 for the East Asia as a function of targeted forecast time. Solid blue circled and green circled lines of each panel denote the MME mean simulation skill and the average value of individual models' skills, respectively. In upper panel, the areas filled in light blue and light green indicates the ACC skill distribution of cross-validated hindcasts associated with the targeted season and year of prediction. The red dashed line (for right y-axis) of upper panel shows the TCC (γ) between the observed Niño 3.4 index amplitude and the ACC skill of MME mean simulations (with those exceeding the 5% significance level marked by the squares) for each season. The green bar (for left y-axis) and black dashed line (for right y-axis) of bottom panel show the spread of individual models' skills and its amplitude, respectively.




Figure 22. Same as Figure 21, but for MME2.

3. 정규화기법을 활용한 다중모델 기반 통계예측모델 개발 가. 개요

기존 MME 기법은 가능한 모든 자료를 활용하여 결정론적으로 단순 평균하거나, 앙상블 멤버의 크기에 따라 가중치를 주어 확률적으로 가중 평균하는 통상적인 결합방식으로, 중위도 이상 지역에서는 예측성능이 낮은 특징이 있다. 또한, 널리 사용되는 회귀모형과 같은 자료중심적 방법은 표본수가 충분하지 못한 자료 특성이 있어 과적합의 문제를 내포하고 있는 실정이다.

기존의 통상적인 MME 기법과 달리 통계 분석을 기반으로 모델선별 방법에 대한 연구가 필요하며, 정규화 기법으로 고차원 자료의 회귀모형 과적합을 방지하고자 한다. LASSO와 같은 정규화 기법을 활용한 예측회귀모형 연구가 비교적 최근에 기후예측분야에도 도입되었다 (Lim et al., 2014; DelSole et al., 2013; DelSole and Banerjee, 2017). 본 연구에서는 다각도로 정규화 기법을 적용하여 보다 다중모델기반 계절예측회귀모형을 개발하고자 한다.

나. 방법 및 자료

(1) 자료

정규화 기법을 활용한 다중모델 기반 통계예측모델 개발의 예측대상은 동아시아 지역의 월/계절 강수량이며, 동아시아 지역을 대상으로 EOF 분석을 수행하여 계절예측회귀모형 구축하였다. 분석기간은 과거재현기간(1991-2010년), 동아시아 영역은 $75^{\circ} E-150^{\circ} E$, $15^{\circ} N-60^{\circ} N$ 을 사용하였다. 과거재현기간은 1991-2010년이나 UKMO와 CMCC에서 제공하는 모형이 93년부터 자료를 제공하기 때문에 1993-2010년을 사용하였다.

정규화 기법을 활용한 다중모델 기반 통계예측모델 개발에 사용한 자료는 관측격자자료와 APCC MME 생산에 사용하는 개별모델이다. 관측격자자료는 CAMS OPI를 사용하였고, 개별모델은 Table 7에 정리하였다.

Table 7. Summary of APCC MME models.

#	Institute	Model Name	Hindcast Period	apccdb(3_leadtime)
1	APCC	SCoPS	1982-2013	APCC
2	CWB	GFST119	1982-2017	CWB_GFST119
3	JMA	JMA/MRI-CPS2	1979-2014	JMA
4	MSC	CanSIPsv2	1981-2010	MSC_CANSIPSV2
5	NASA	GMAO	1982-2016	NASA
6	NCEP	CFSv2	1982-2010	NCEP
7	PNU	PNU CGCM v2	1980-2018	PNU
8	UKMO	GLOSEA5	1993-2016	UKMO
9	BCC	BCC	1991-2015	BCCV2
10	KMA	GLOSEA5GC2	1991-2010	GLOSEA5
11	HMC	HMC	1985-2010	HMC
12	CMCC	CMCC-SPSv3	1993-2016	
13	BOM	ACCESS-S	1990-2012	BOM_ACCESS-S1

(2) 개발방법

(가) 정규화 기법(Regularization)

계절예측자료의 자료크기가 충분하지 않아 발생하는 과적합을 해결하기 위해 정규화 기법을 사용하였다. 일반적인 회귀분석은 회귀식의 차수가 높아질수록 Training data의 error는 감소하지만, Testing data의 error는 증가하는 특징을 가진다. 정규화 기법은 회귀계수에 제약조건을 줘서 모델링에 변화를 줄 수 있는 방법이다. 최소제곱법을 사용하였을 때 발생하는 과적합을 방지하여 예측성 향상을 기대할 수 있다. 즉, bias를 조금 손해 보더라도 variance를 더욱 많이 개선하여 예측 성능을 증가시킬 수 있는 특징을 가진다. Table 8는 최소제곱법과 정규화 기법을 비교하여 보여주고 있다.

Table 8. Brief description of the Least square method and Regularization method.

최소제곱법(Least square method)	정규화 기법(Regularization)
<ul style="list-style-type: none"> • 통상적인 회귀모형적합방식 • 자료크기가 충분하지 않거나 많은 예측인자를 고려하는 경우 과적합된 모형이 도출됨 → 낮은 예측성능을 보임 	<ul style="list-style-type: none"> • 일반 선형회귀 모형에서 도출된 회귀계수($\hat{\beta}$)에 제약조건을 부여하는 방법 • 회귀계수에 제약을 줘서 모델링의 변화를 주는 것이 정규화의 개념 • 회귀계수에 제약을 줘서 과적합 방지함 → 예측성 향상 기대

정규화 기법의 수식적인 정의는 최소제곱법에 벌점항을 도입하는 것이다. $\gamma=1$ 이면 LASSO, $\gamma=2$ 이면 Ridge(능형회귀)를 의미한다 (Eq. 1). 정규화 기법에서 기본적으로 γ 가 커지면 회귀 계수가 작아진다. 최소제곱법은 $\gamma=0$ 인 경우이다. 최적화과정에서 무의미한 회귀계수의 역할을 줄여서 과적합을 방지한다. Table 9은 LASSO와 Ridge의 특징을 비교하여 정리하였다.

Table 9. Brief description of LASSO (Least Absolute Shrinkage and Selection Operator) regression and Ridge regression.

LASSO	Ridge
L1-norm regularization	L2-norm regularization
Closed form solution 존재하지 않음 (numerical optimization 이용)	Closed form solution 존재 (미분으로 구함)
x 변수 간 상관관계가 높은 상황(collinearity)에서 ridge에 비해 상대적으로 예측 성능이 떨어짐	x 변수 간 상관관계가 높은 상황(collinearity)에서 좋은 예측 성능을 보임

Figure 23와 같이 LASSO 회귀는 마름모형의 제약조건을 가진다. 기존의 $\hat{\beta}^{LS}$ 에서 마름모의 제약조건을 만족시키는 $\hat{\beta}^{LASSO}$ 를 찾는 것이 특징이다. 마름모 크기를 변화시키면서 최적의 $\hat{\beta}$ 를 찾는다. γ 와 마름모 크기는 반비례 관계를 가진다.

$$\hat{\beta} = \min_{\beta} \left\{ \sum_{i=1}^n \left(Y_i - \beta_0 - \sum_{k=1}^p \beta_k X_{i,k} \right)^2 + \lambda \sum_{k=1}^p |\beta_k|^\gamma \right\} \quad [1]$$

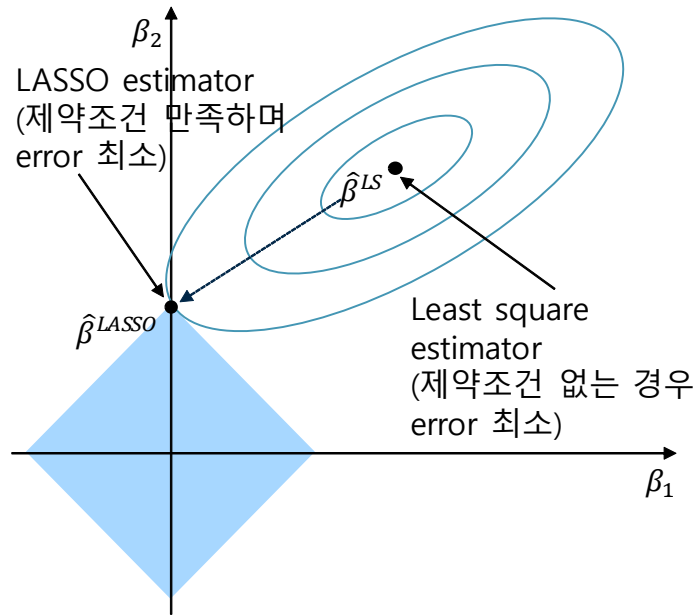


Figure 23. Contours of the error and constraint functions for the LASSO regression.

Figure 24과 같이 Ridge 회귀는 원형의 제약조건을 가진다. 기존의 $\hat{\beta}^{LS}$ 에서 원형의 제약조건을 만족시키는 $\hat{\beta}^{Ridge}$ 를 찾는 것이 특징이다. 원의 크기를 변화시키면서 최적의 $\hat{\beta}$ 를 찾는다. γ 와 원의 크기는 반비례 관계를 가진다.

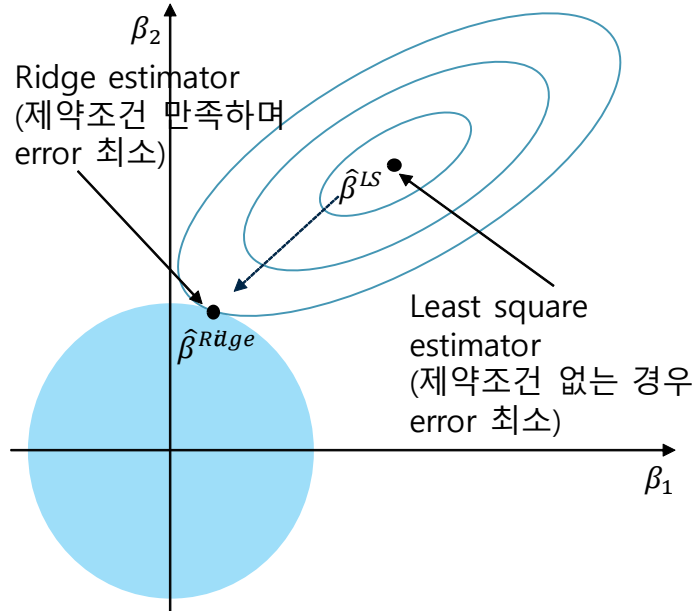


Figure 24. Contours of the error and constraint functions for the Ridge regression.

(나) 정규화 기법을 이용한 EOF 분석 기반 계절예측회귀모형 구축

관측값/개별모형별 EOF 분석을 수행하여 PC 시계열(PC time series)을 산정하였다. PC 시계열을 X, Y에 대입하여 계절예측회귀모형 구축하였다 (Figure 25). Figure 26는 개별모델별 PC 시계열을 산정한 예시를 보여주고 있다.

$$\begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \dots \\ \hat{y}_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots \\ 1 & x_{n1} & \dots & x_{nk} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \dots \\ \beta_k \end{bmatrix}$$

X: PC time series of individual model hindcasts

Y: PC time series of observed/reanalysis data

Figure 25. Regression equation using the time series of principal components obtained from EOF analysis applied for observations and individual models.

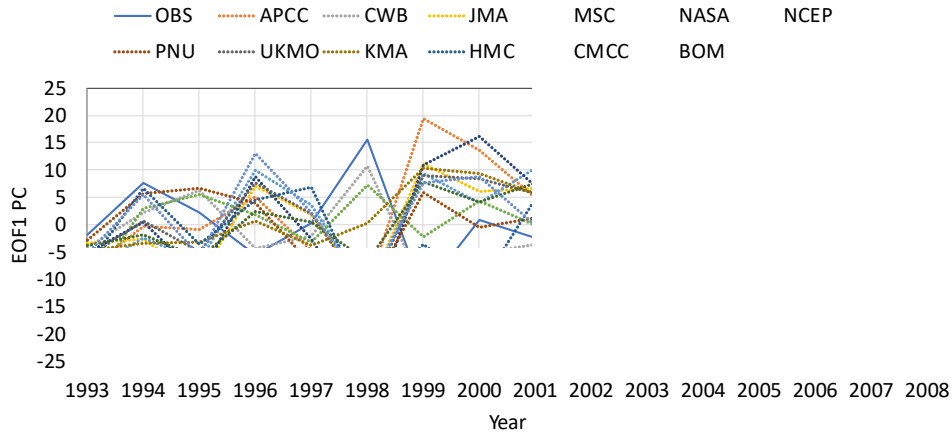


Figure 26. Examples of the time series of principal components obtained from EOF analysis.

교차검증(k-fold cross validation)을 사용하여 모형의 훈련, 매개변수 선택, 평가를 수행하였다. γ 를 증가시키면서 MSE가 가장 작은 회귀계수를 선택 한다(Figure 27). LASSO solution path를 보면 λ 가 커지면서 회귀계수가 작아지는 것(Shrinkage)을 확인할 수 있다 (Figure 28).

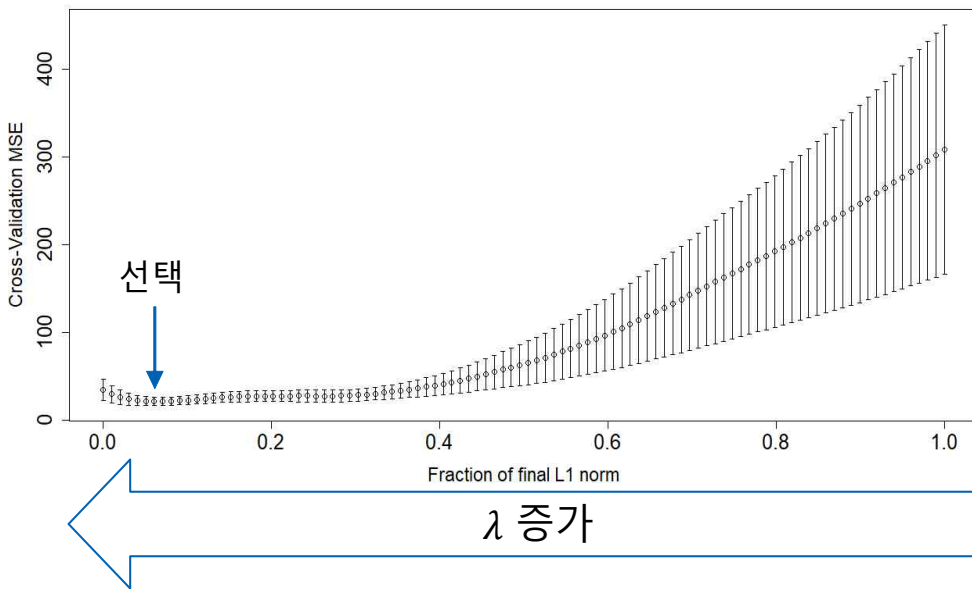


Figure 27. Selection of the regression coefficient as a function of λ .




Figure 28. LASSO solution path as a function of λ .

(다) 평가측도

구축한 계절예측회귀모형을 적용하면 PC 시계열이 결과물로 산출된다. 과거재현자료에 대한 교차검증을 수행하여 생산한 PC 시계열에 대한 평가는 MSE, RMSE를 평가측도로 선정하여 수행하였고, 강수 편차(anomaly)에 대한 평가는 현업에서 사용하고 있는 ACC(Anomaly Correlation Coefficient)를 사용하였다.

ACC 산정하는 방법은 ACc와 ACu 2가지 방법이 있다 (Eq. 2-3). 편차를 구하는 것은 같으나 편차에 대해 centered를 적용하느냐 안하느냐의 차이이다. 현재 현업에서는 centered를 적용하지 않은 ACu 방법을 사용하므로 동일한 비교를 위해 본 연구에서도 ACu 방법을 사용하였다. ACC를 산정할 때 위도에 따라 격자의 크기가 달라지므로 위도에 따른 가중치를 적용해야 한다. 현업에서 사용하는 가중치 $\cos(\text{lat} \cdot \pi/180)$ 를 동일하게 적용하였다.

$$AC_C = \frac{\sum_{m=1}^M (y'_m - \bar{y}') (o'_m - \bar{o}')}{\sqrt{\sum_{m=1}^M (y'_m - \bar{y}')^2 \sum_{m=1}^M (o'_m - \bar{o}')^2}} \quad [2]$$

$$AC_U = \frac{\sum_{m=1}^M (y_m - c_m)(o_m - c_m)}{\sqrt{\sum_{m=1}^M (y_m - c_m)^2 \sum_{m=1}^M (o_m - c_m)^2}} = \frac{\sum_{m=1}^M (y'_m)(o'_m)}{\sqrt{\sum_{m=1}^M (y'_m)^2 \sum_{m=1}^M (o'_m)^2}} \quad [3]$$

다. 결과

(1) 월 강수량 적용 결과

2월을 대상으로 1개월 예측선행시간 기준 과거재현자료를 구축하고, 과거재현자료를 대상으로 LASSO 회귀 기반 계절예측회귀모형을 구축하여 평가하였다.

(가) MME 참여 개별모형별 EOF 분석 코드 적용

먼저, 정규화 기법(LASSO 회귀) 적용을 위한 입력자료 전처리를 수행하였다. 관측값/개별모형별 EOF 분석을 수행하여 PC 시계열을 산정하고, PC 시계열을 X, Y에 대입하여 계절예측회귀모형을 구축하였다. 첫 번째 EOF 모드의 결과를 사용하였다. Figure 29은 모형 구축에 사용한 PC 시계열을 보여주고 있다.

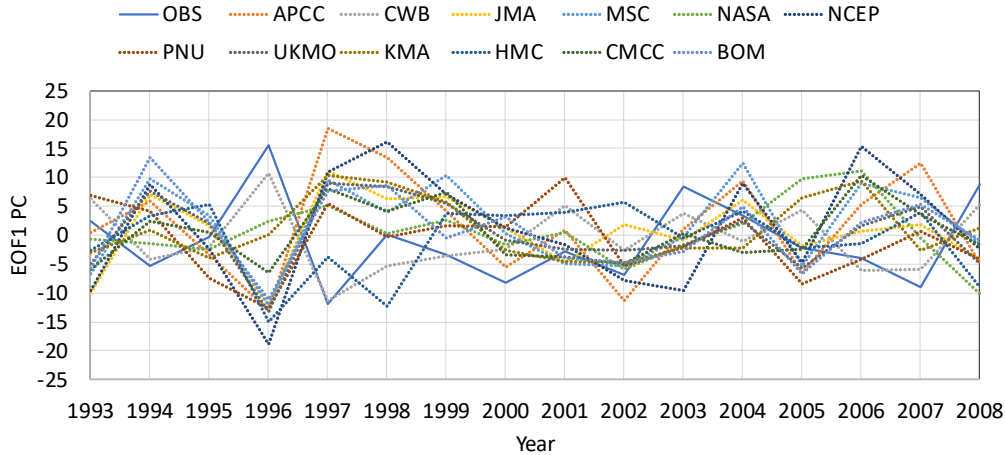


Figure 29. Time series of principal components used for regression equation for monthly precipitation in February. The PC time series are obtained from EOF analysis using k-fold cross validation (Fold 1).

교차검증(k-fold cross validation)을 사용하여 모형의 훈련, 매개변수 선택, 평가를 수행하였다. 가장 작은 MSE를 기준으로 λ 를 선택하도록 설계하였다. PC 시계열을 독립변수로 사용하기 때문에 훈련세트에 따라 PC 시계열 값에 차이가 발생할 수 있으므로 훈련세트마다 EOF 분석을 수행하여 PC 시계열을 산정하도록 코드를 구현하였다.

(나) 정규화 기법(LASSO 회귀)을 이용한 계절예측회귀모형 구축

Figure 30은 LASSO 제약조건을 이용한 교차검증을 수행한 결과를 보여주고 있다. Figure 30(a)는 λ 에 따른 MSE의 결과를 보여주고 있다. λ 값이 커질수록 Fraction of final L1 norm이 작아지는 경향을 보인다. 가장 작은 MSE값을 보여주는 λ 를 결정하여 최종적인 회귀계수를 결정하였다. Figure 30(b)는 λ 에 따라 회귀계수에 제약이 가해지는 결과를 보여주고 있다. LASSO solution path를 보면 λ 가 커지면서 회귀계수가 작아지는 것(Shrinkage)을 확인할 수 있다. 회귀계수에 제약을 가함으로써 Training data의 error를 일정부분 증가시키고, Testing data의 error를 감소시켜 예측성을 향상시킨다.

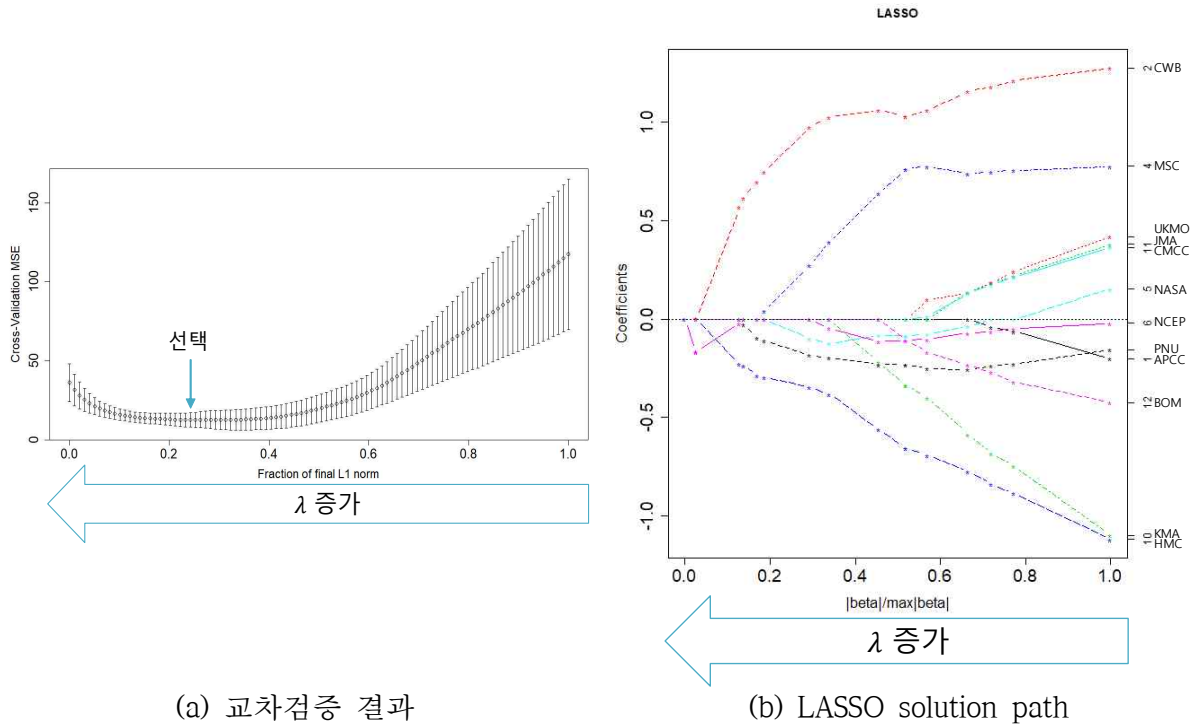



Figure 30. Selection of the regression coefficient and LASSO solution path as a function of λ using k-fold cross validation (Fold 1) for monthly precipitation in February.

Figure 31는 정규화 기법(LASSO 회귀)을 이용하여 PC 시계열을 추정한 결과를 보여주고 있다. 관측자료(OBS), 회귀분석(lm), 정규화 기법(LASSO 회귀), SCM의 순서로 나타내었다. 정규화 기법(LASSO 회귀)을 이용하여 추정된 PC 시계열이 전반적으로 회귀분석, SCM에 비해 OBS와 유사한 경향을 보여주고 있다. RMSE 기준으로 회귀분석, SCM 대비 상당히 개선된 것으로 분석된다.



	RMSE
OBS vs. lm	13.898
OBS vs. LASSO	5.330
OBS vs. SCM	8.701

Figure 31. (left) Comparison of PC time series between conventional linear model (green), LASSO regression (red) and SCM (blue) for monthly precipitation in February. (right) Comparison of RMSE (Root-Mean-Square-Error) of PC time series between conventional linear model, LASSO regression and SCM for monthly precipitation in February.

본 연구는 정규화 기법을 활용하여 과적합을 완화하는 다중모델 기반 통계예측모델(LASSO 회귀)을 개발하였다. 회귀분석(lm), SCM 대비 정규화 기법(LASSO 회귀)의 ACC가 얼마나 개선되었는지 비교분석하여 예측성 개선의 척도로 제공하고자 한다.

본 연구는 다중모델 기반의 지역특화 계절예측 보정 기술을 개발하였으며, 2월 강수량을 대상으로 예측성을 평가하였다. 정규화 기법 (LASSO 회귀)을 이용하여 추정한 PC 시계열을 월 강수량으로 변환하여 ACC를 산정하였다. Figure 32에서 초록색은 회귀분석(lm), 빨간색은 LASSO 회귀, 파란색은 SCM의 ACC를 의미한다. 왼쪽 그림의 상자그림은 개별모형의 ACC 범위를 의미한다. 회귀분석(lm)과 비교하면 특정 해(1995, 2008, 2008)에 LASSO의 ACC가 더욱 개선되었고, 다른 해는 대체로 비슷한 것으로 나타났다. 전반적으로 일부 해(1994, 2000, 2003)를 제외하고는 LASSO의 ACC가 SCM 대비 개선된 것으로 분석된다. 또한 오른쪽 그림에 과거재현기간에 대해 상자그림으로 나타내어 ACC의 범위를 보여주었다. 현업에서 사용하는 Time-averaged ACC를 산정하면 SCM 대비 10.052% 개선된 것으로 분석되었다. Figure 33은 정규화 기법(LASSO 회귀) 기반 계절예측회귀 모형을 이용한 2010년 2월 강수량 편차 추정 결과를 보여주고 있다.




Figure 32. Comparison of ACC between conventional linear model (green), LASSO regression (red) and SCM (blue) for monthly precipitation in February. Box plots in the left panel shows the ACC range of individual models in each year, while those in the right panel shows the ACC range during the hindcast period.

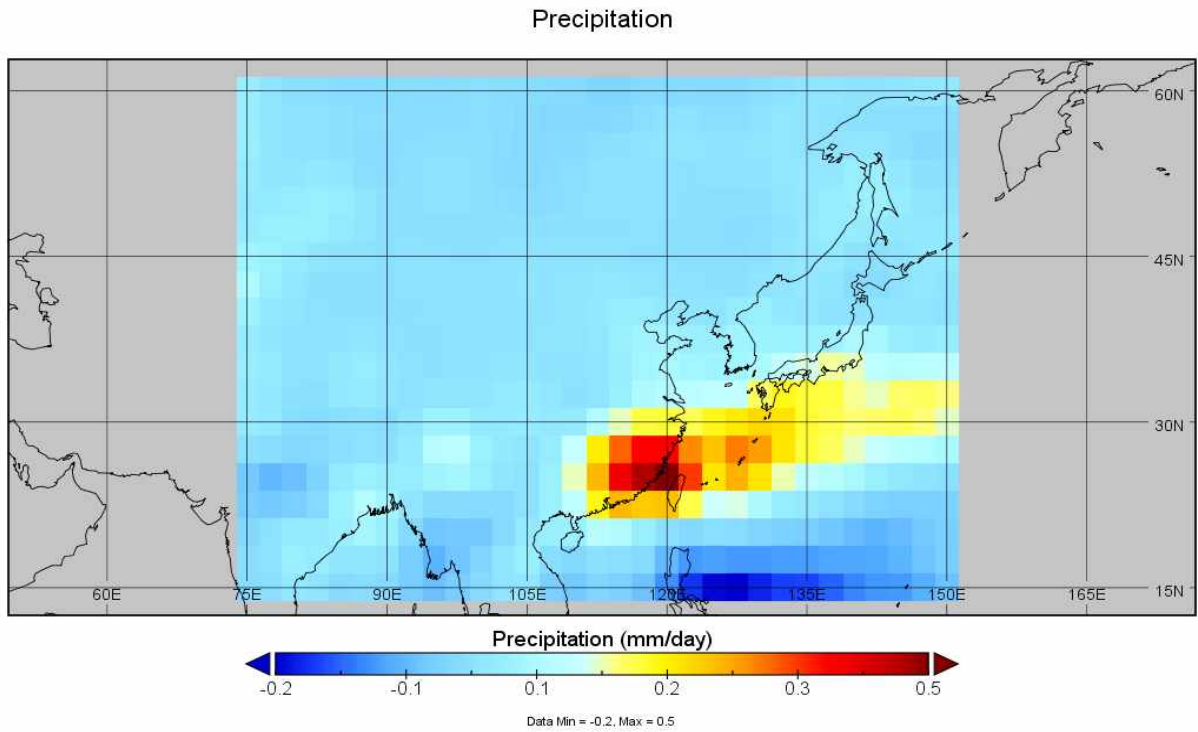


Figure 33. Spatial distribution of precipitation bias estimated from the LASSO regression for monthly precipitation in February 2010.

(2) 계절 강수량 적용 결과

과거재현자료의 계절 강수량을 대상으로 LASSO 회귀 기반 계절예측회귀모형을 구축하여 평가하였다.

(가) MME 참여 개별모형별 EOF 분석 코드 적용

정규화 기법(LASSO 회귀) 적용을 위한 입력자료 전처리를 수행하였다. 관측값/개별모형별 EOF 분석을 수행하여 PC 시계열을 산정하고, PC 시계열을 X, Y에 대입하여 계절예측회귀모형을 구축하였다. 첫 번째 EOF 모드의 결과를 사용하였다. Figure 34는 모형 구축에 사용한 PC 시계열을 보여주고 있다.




Figure 34. Examples of the time series of principal components used for regression equation for seasonal precipitation. The PC time series are obtained from EOF analysis using k-fold cross validation (Fold 1).


교차검증(k-fold cross validation)을 사용하여 모형의 훈련, 매개변수 선택, 평가를 수행하였다. 가장 작은 MSE를 기준으로 λ 를 선택하도록 설계하였다.

(나) 정규화 기법(LASSO 회귀)을 이용한 계절예측회귀모형 구축


Figure 35은 LASSO 제약조건을 이용한 교차검증을 수행한 계절별 결과를 보여주고 있다. λ 에 따른 MSE의 계절별 결과를 보여주고 있다. 전반적으로 λ 값이 커질수록 Fraction of final L1 norm이 작아지는 경향을 보인다. 가장 작은 MSE값을 보여주는 λ 를 결정하여 최종적인 회귀계수를 결정하였다.

Figure 36는 λ 에 따라 회귀계수에 제약이 가해지는 결과를 계절별로 보여주고 있다.


LASSO solution path를 보면 FMA와 NDJ 계절을 제외하고 전반적으로 λ 가 커지면서 회귀계수가 작아지는 것(Shrinkage)을 확인할 수 있다. 회귀계수에 제약을 가함으로 Training data의 error를 일정부분 증가시키고, Testing data의 error를 감소시켜 예측성을 향상시킨다.




(a) JFM




(b) FMA




(c) MAM




(d) AMJ




(e) MJJ




(f) JJA




(g) JAS




(h) ASO (Fold3)




(i) SON



(j) OND




(k) NDJ




(l) DJF


Figure 35. Selection of the regression coefficient for each season as a function of λ using k-fold cross validation (Fold 1).




(a) JFM




(b) FMA




(c) MAM




(d) AMJ




(e) MJJ



(f) JJA



(g) JAS



(h) ASO

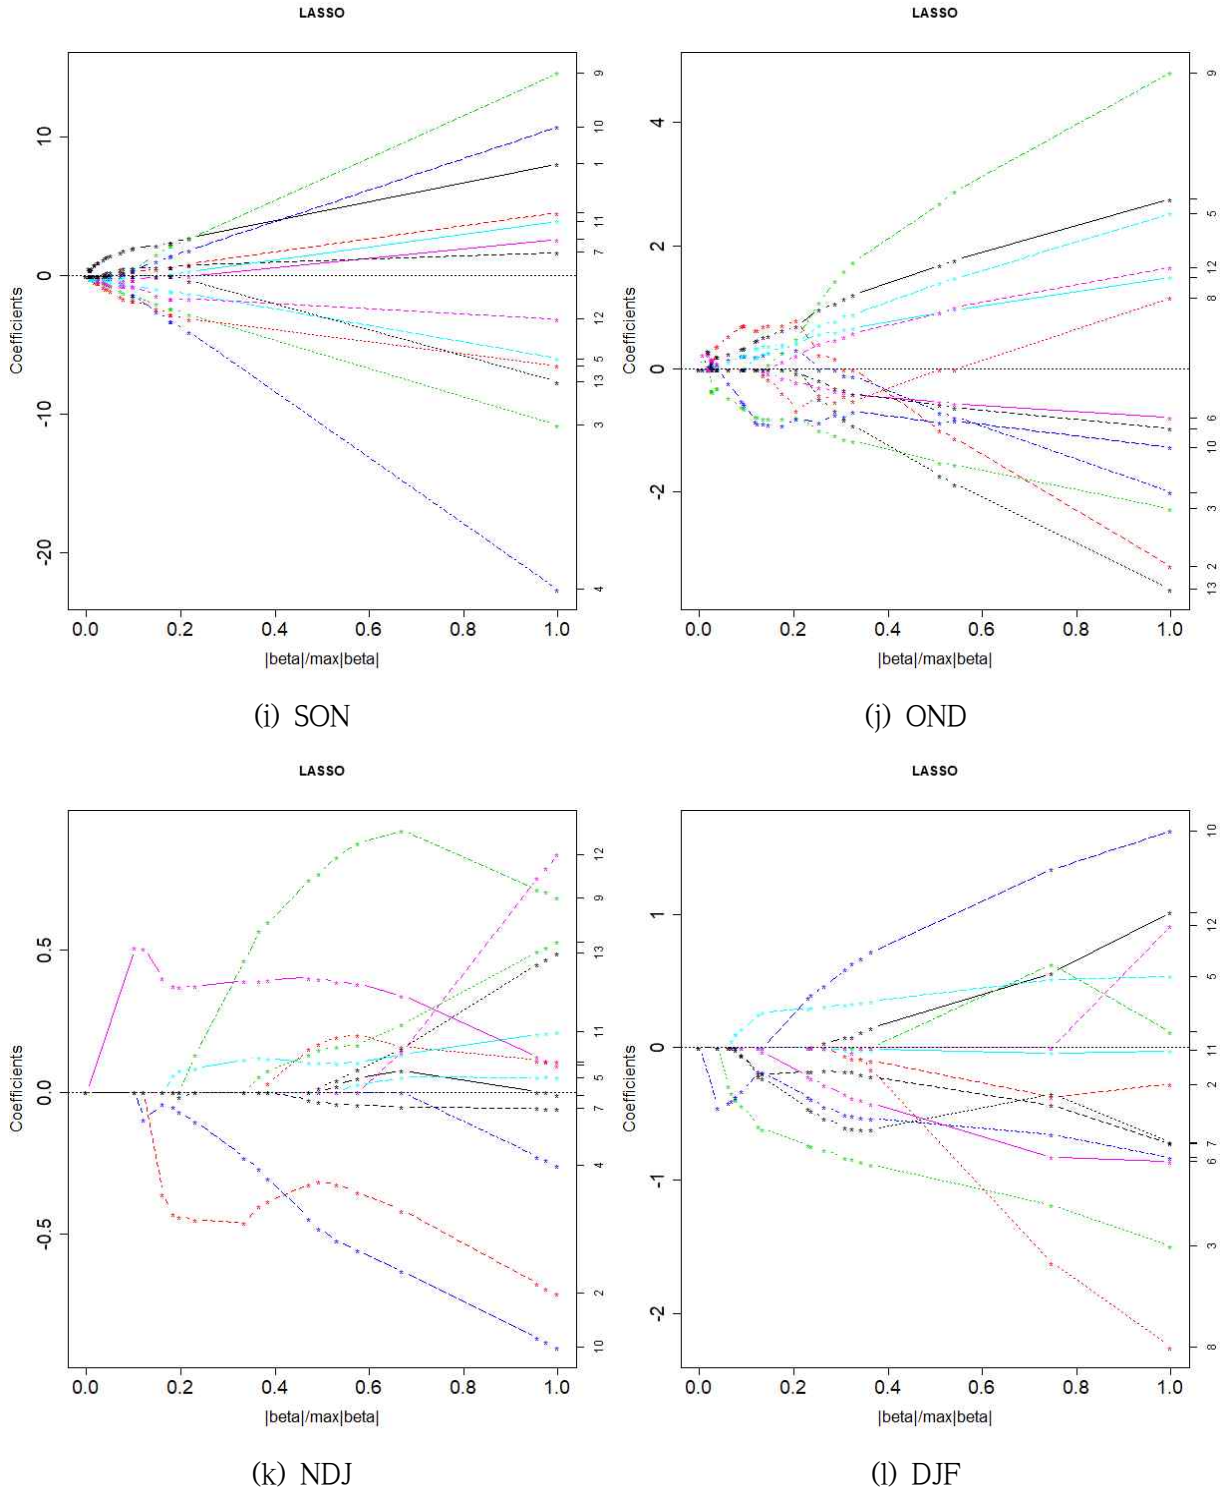




Figure 36. LASSO solution path for each season as a function of λ using k-fold cross validation (Fold 1).

Figure 37는 정규화 기법(LASSO 회귀)을 이용하여 PC 시계열을 추정한 결과를 계절별로 보여주고 있다. 관측자료(OBS), 회귀분석(lm), 정규화 기법(LASSO 회귀), SCM의 순서로 나타내었다. 정규화 기법(LASSO 회귀)으로 추정된 PC 시계열이 전반적으로 회귀분석(lm), SCM에 비해


OBS와 유사한 경향을 보여주고 있다. 특히 JFM, FMA, AMJ, MJJ, JJA, JAS, ASO, SON 계절을 살펴보면 회귀분석(lm) 결과가 관측자료와 큰 차이가 발생하는 연도가 존재하는데 비해 정규화 기법은 이러한 차이를 보정하여 관측자료와 유사한 경향을 나타내고 있다.




(a) JFM




(b) FMA




(c) MAM




(d) AMJ




(e) MJJ



(f) JJA



(g) JAS



(h) ASO

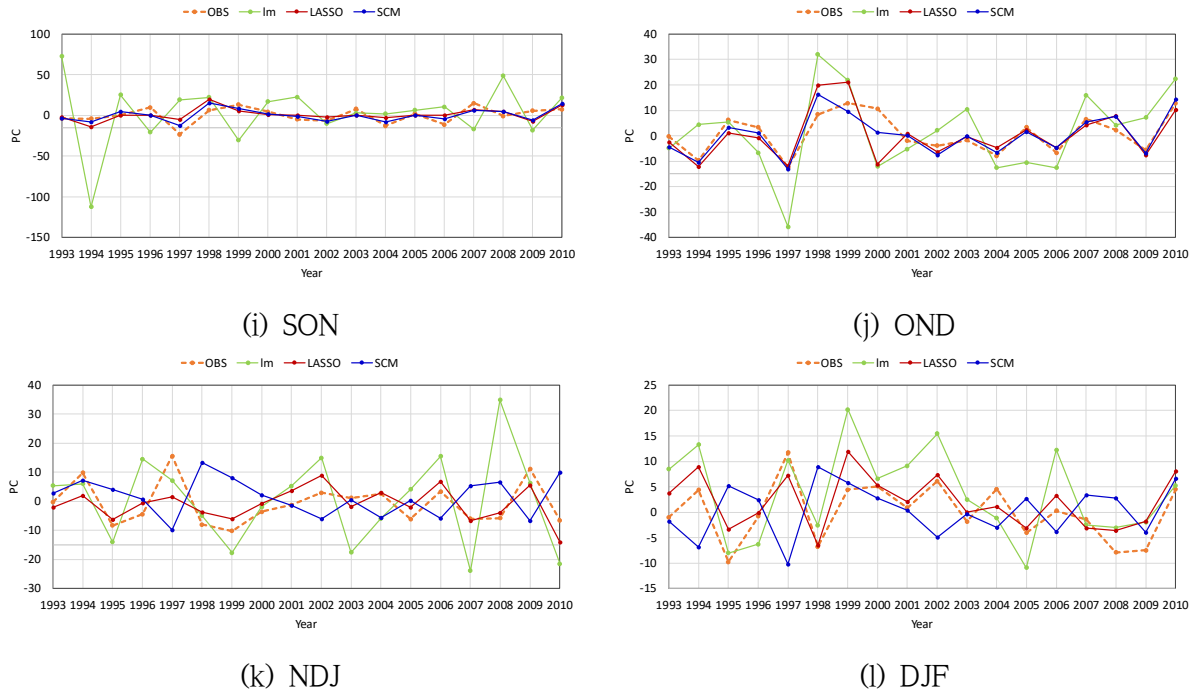


Figure 37. Comparison of PC time series between conventional linear model (green), LASSO regression (red) and SCM (blue) for each season.


Table 10는 정규화 기법(LASSO 회귀) 기반 계절예측회귀 모형으로 추정된 PC 시계열을 RMSE를 이용하여 평가한 결과를 나타내고 있다. 관측자료를 기준으로 회귀분석(lm)과 정규화 기법(LASSO 회귀)에 대해 RMSE를 산정하였다. RMSE기준으로 정규화 기법(LASSO 회귀) 기반 PC 시계열 추정 결과는 회귀분석(lm) 대비 전계절에 걸쳐 상당히 개선된 것으로 분석된다. SCM과 비교하면 JFM, FMA, MAM, NDJ, DJF 계절에는 상당히 개선된 것으로 분석되나 다른 계절에는 RMSE가 증가한 것으로 분석되었다. 특히, MJJ, JJA, ASO, SON, OND 계절에는 RMSE가 SCM 대비 상당히 증가한 것으로 분석되었다. 전반적으로 계절예측회귀 모형이 여름철보다는 늦가을, 겨울철, 봄에 보정 효과가 있는 것으로 분석된다.

Table 10. Comparison of RMSE (Root-Mean-Square-Error) of PC time series between conventional linear model, LASSO regression and SCM for each season.


	RMSE											
	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ	DJF
OBS vs. lm	17.102	12.947	10.497	53.056	34.904	27.520	30.755	24.252	40.070	12.496	14.249	7.178
OBS vs. LASSO	2.228	2.513	3.836	6.440	11.301	10.771	9.389	12.372	8.890	6.710	5.325	3.766
OBS vs. SCM	2.831	5.338	4.978	6.182	7.266	8.084	9.088	7.778	6.640	3.760	12.459	9.103

정규화 기법을 활용하여 다중모델 기반의 지역특화 계절예측 보정 기술(LASSO 회귀)을 개발하였다. 정규화 기법 (LASSO 회귀)을 이용하여 추정된 PC 시계열을 계절 강수량으로 변환하여 ACC를 산정하여 예측성을 평가하였다. 회귀분석(lm), SCM 대비 정규화 기법(LASSO 회귀)의 ACC가 얼마나 개선되었는지 비교분석하였다.


Figure 38은 정규화 기법(LASSO 회귀) 기반 계절예측회귀 모형을 이용하여 산정한 과거재현자료의 연도별 ACC를 상자그림으로 나타내었다. 회귀분석(lm)과 비교하면 중간값을 기준으로 특정 계절(JJA, JAS, ASO)을 제외하고는 정규화 기법(LASSO 회귀)의 ACC가 개선되거나 비슷한 것으로 분석되었다. 정규화 기법(LASSO 회귀)이 여름철에 보정 효과가 떨어지는 것으로 보이며 여름철 예측성 향상을 위해서는 추후 모델 개선이 필요할 것으로 사료된다. SCM과 비교하면 중간값을 기준으로 JFM, MAM, OND, NDJ, DJF 계절에서 정규화 기법(LASSO 회귀)의 ACC가 개선된 것으로 분석되었다.




(a) JFM




(b) FMA




(c) MAM




(d) AMJ




(e) MJJ




(f) JJA



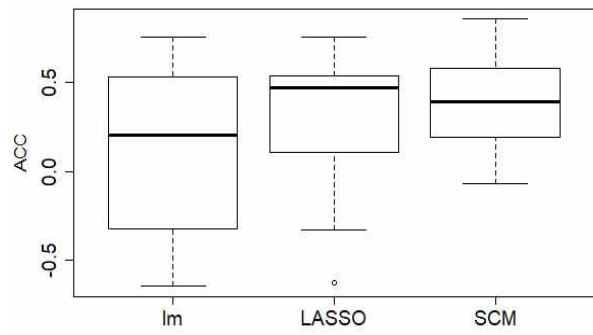
(g) JAS




(h) ASO




(i) SON



(j) OND




(k) NDJ




(l) DJF

Figure 38. Comparison of ACC range during the hindcast period between conventional linear model, LASSO regression and SCM for each season.


Figure 39은 정규화 기법(LASSO 회귀) 기반 계절예측회귀 모델을 이용하여 산정한 과거재현자료의 연도별 ACC를 보여주고 있다. 앞서 중간값을 기준으로 SCM과 비교하여 ACC가 개선된 JFM, MAM, OND, NDJ, DJF 계절을 살펴보면, MAM 계절을 제외하고는 2005-2009년 동안 보정효과가 있어 전체적으로 예측성이 개선된 것으로 분석된다. Figure 40은 정규화 기법(LASSO 회귀) 기반 계절예측회귀 모델을 이용한 2010년 JFM 계절 강수량 편차 추정 결과를 보여주고 있다.




(a) JFM




(b) FMA




(c) MAM




(d) AMJ




(e) MJJ




(f) JJA




(g) JAS



(h) ASO



(i) SON



(j) OND

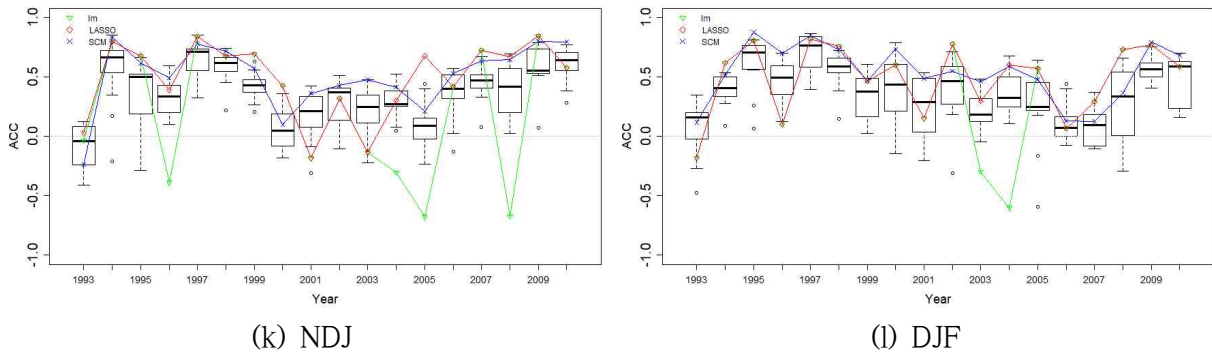


Figure 39. Comparison of ACC between conventional linear model (green), LASSO regression (red) and SCM (blue) for each season. Box plots shows the ACC range of individual models in each year.

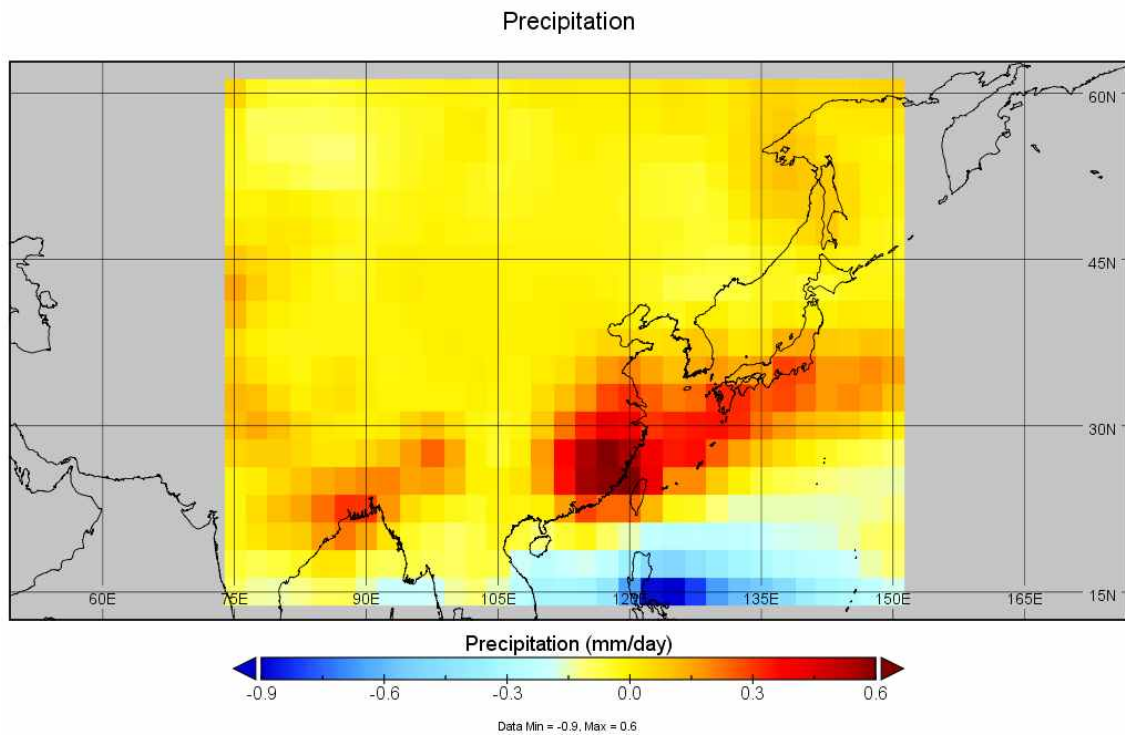


Figure 40. Spatial distribution of precipitation bias estimated from the LASSO regression for seasonal precipitation in January-February-March 2010.

본 연구에서 개발한 정규화 기법(LASSO 회귀) 기반 계절예측회귀 모형은 회귀분석(lm)과 비교하면 대체로 예측성이 개선된 것으로 분석되나, SCM과 비교하면 일부 계절에서만 개선효과가 보이는 것으로 나타났다. 추후 건기/우기 등으로 구분하여 모델 고도화를 추가적으로 수행하면 보다 예측성이 개선될 수 있을 것으로 사료된다.

4. 베이즈 정규화 후처리 기법

가. 베이즈 접근법에 기반한 다중모델 격자 자료의 후처리

신뢰도 높은 계절 예측을 위하여 우리 센터에서는 다중모델앙상블(Multi-Model Ensemble; MME) 기법을 활용하여 여러 예측 센터에서 생산한 역학 모델의 예측 결과를 종합한 최적의 예보를 생산하고 있다. 이러한 다중모델앙상블 기법을 통해 앙상블에 참여하는 개별 모델의 바이어스가 제거되어 보다 안정적이고 신뢰도 높은 계절 예측이 가능한 것으로 알려져있다. 우리 센터에서는 객관적인 예측 정보 생산을 위하여 주로 결정론적 예측값은 단순합성법을 사용하고 확률론적 예측값은 가우스 방법을 활용하고 있다. 그러나, 이러한 자료 정합성 중심의 접근 방법은 역학 모델이 모의하는 기후 시스템과 실제 기후 시스템간의 괴리에 대한 고려가 부족하여, 예측성이 중요한 현업 기후 계절 전망 측면에서는 아쉬움이 남아있다. 따라서, 이 연구에서는 자료 정합성 중심의 다중모델앙상블 기법을 확장하여 현업 예측성 향상에 초점을 맞추고, 이를 위해 정규화 기법이 적용된 베이즈 회귀를 이용하여 과거 관측 자료와 다중 모델의 예측 자료를 적합하고자 하였다.

(1) 베이즈 접근법

기존의 빈도론적 접근법에서 회귀는 다음과 같이 표현된다.

$$f(\mathbf{X}) = \beta_0 + \sum_{j=1}^p \mathbf{X}_j \beta_j + \epsilon = \boldsymbol{\beta}^T \mathbf{X} + \epsilon$$

여기서 β 는 회귀 계수를 의미하며 $\epsilon \sim N(0, \sigma^2)$ 는 원점 주위에 표준편차 σ 로 분포하고 있는 오차를 나타낸다. 일반적인 최소곱제법에서는 잔차제곱항의 합을 최소화하는 방법으로 회귀 계수의 초평면을 적합하며, 이 경우 최대 우도 추정법의 회귀 계수는 다음과 같이 나타낼 수 있다.

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

한편, 베이즈 추론에서는 수집된 정보(E)를 바탕으로 기존의 확률(p(H))을 갱신(p(H|E))해 나간다. 이를 수식으로 표현하면 다음과 같다.

$$P(\theta | D) = \frac{P(D|\theta)P(\theta)}{P(D)} = \frac{P(D|\theta)}{\int P(D|\theta)P(\theta)d\theta} P(\theta)$$

베이즈 회귀를 통해 다음과 같은 예측값을 업데이트하게 된다.

$$\mathbf{y} \sim \mathcal{N}(\beta^T \mathbf{X}, \sigma^2 \mathbf{I})$$

이 연구에서는 다중모델앙상블에 참여하는 개별 모델의 예측값을 관측에 적합하는 과정에서 베이지 접근법을 활용하였다. 적합의 대상이 되는 관측 자료로 ECMWF (European Centre for Medium-Range Weather Forecasts)의 재분석 자료인 ERA5를 사용하였고, 예측 변수는 우리 센터에서 운용하고 있는 다중모델앙상블에 참여하는 역학 모델 예측 자료의 개별 평균값을 이용하였다. 기본적인 자료의 정합성을 유지하기 위해, 관측 재분석 자료의 변수에 해당하는 개별 모델의 예측 변수만을 사용하였으며, 개별 모델의 격자값으로부터 관측 재분석 자료의 격자값을 예측하는 격자-격자 적합을 수행하였다.

이러한 자료를 이용하여 각 격자의 개별 모델 예측 격자값(x)으로부터 베이지 회귀를 통해 예측 격자값을 예측하게 되며, 이를 수식으로 표현하면 위와 같다.

예측 값의 사전 확률 분포는 가우스 분포를 가정하였으며, 이는 원점 주위에 매우 넓게 분포된 무정보적 가우스 분포를 사용하였다. 이를 기반으로 각 격자별 개별 예측 모델의 평균값과 관측 재분석 자료의 회귀를 통해 최종 예측값의 위치 및 모양 파라미터를 추정하였다.




Figure 41. Schematics of Bayesian regression.
<http://www.indiana.edu/~kruschke/BMLR>

(2) 정규화를 도입한 베이지 회귀

베이지 회귀를 통한 추정에서 입력 자료는 다중모델앙상블에 참여하는 개별 모델의 예측 평균값이나, 간혹 개별 예측의 바이어스 등으로 인하여 실제 예측에 기여하지 못하거나 부정적인 영향을 미치는 경우가 존재한다. 이는 추후 격자-격자 모형을 벗어나 모델 결과 통계량 (Model Output Statistics; MOS)를 이용하는 방법에서도 나타날 수 있는 현상으로, 회귀 모형이 실제 관련성에 적합되기보다는 자료 자체의 특성에 적합되는 경우를 의미한다. 이러한 자료 과적합을 방지하기 위하여, 이 연구에서는 정규화 기법을 도입하였다. 정규화 기법은 회귀 계수에 패널티를 부여함으로써 특정 회귀 계수가 과도하게 성장하는 것을 막고 회귀에 영향을 미치지 못하는 변수의 가중치를 제거하여 회귀 모형이 안정적으로 파라미터를 추정할 수 있도록 돕는다. 이 연구에서는 유클리드 공간에서의 거리 제곱에 해당하는 l2-norm 을 이용한 능형 회귀를 도입하여 위와 같은 자료 과적합 현상을 방지하고 안정적인 예측이 수행되도록 구성하였다.




Figure 42. Schematics of regularization effects: (Left) l1-norm LASSO and (Right) l2-norm Ridge. Source: <https://towardsdatascience.com/ridge-and-lasso-regression-a-complete-guide-with-python-scikit-learn-e20e34bcbf0b>

이 연구에서 사용한 후처리 방법론과 자료 처리 방안을 간단히 모식화하면 아래와 같다.

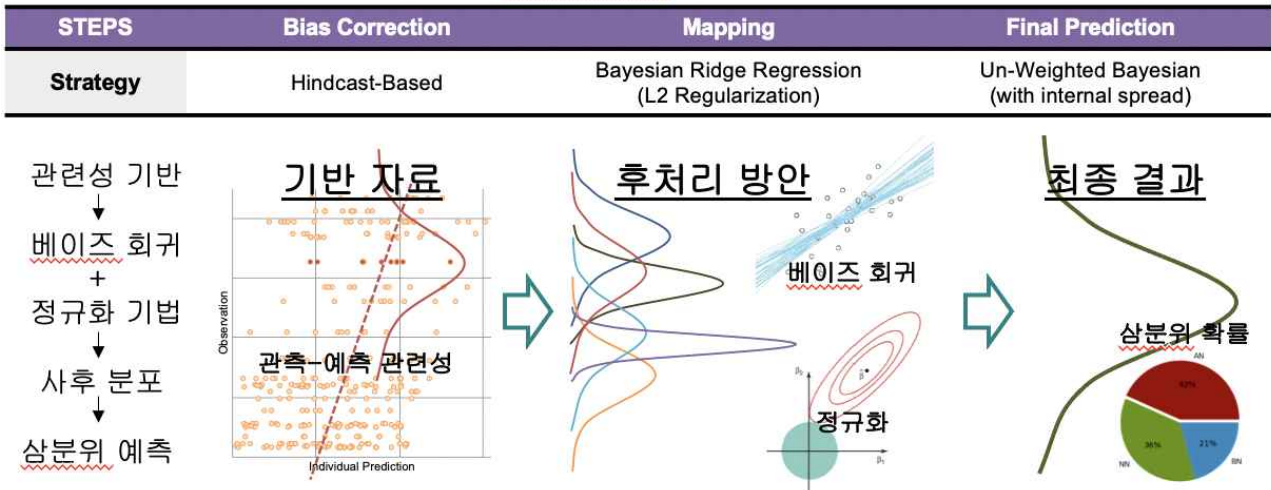


Figure 43. Strategies of Bayesian post-processing with regularization applied in this study.

나. 하인드캐스트 기간의 예측 결과

하인드캐스트 기간에 leave-one-out 방식으로 계산된 예측 결과를 표시하면 다음과 같다. 이 연구에서는 가용한 하인드캐스트 기간(7 월 ~ 11 월)의 1, 2, 3 개월 선행 예측을 수행하였으나, 다음 예시에서는 정규화 베이지스 1 개월 선행 예측과 이에 해당하는 APCC PMME의 예측 정보, 그리고 관측 재분석 자료를 선별하여 제시하고 있다.

전체적으로 정규화 베이지스 7 ~ 9 월 1 개월 선행 예측의 특성과 10, 11 월 1 개월 선행 예측의 특성이 조금 다른 것으로 나타난다. 즉, 10, 11 월의 경우 예측 분산이 과소 추정되어 대부분의 예측 범주가 니어-노멀에 머무는 문제가 있는 것으로 나타났으며, 이는 추후 연구를 통해 보완해야 할 사항으로 보인다. 많은 경우, 기반 MME 예측과 정규화 베이지스 후처리를 통한 예측이 비슷한 범주값을 예측하는 것으로 보이나, 일부 관측 자료에 적합된 정규화 베이지스 후처리는 기반 MME 예측과 상이한 결과를 보이기도 한다. 이러한 경향성은 대륙 혹은 해양 등 경계면의 특성이나 위도에 관계 없이 공히 관측되고 있으나, 전체적으로 해양 지역에서의 후처리 효과가 탁월한 것으로 판명되었다. 자료에 민감하게 반응하는 대륙에서의 후처리는 예측성에 큰 영향을 주지 못하는 것으로 나타난다.

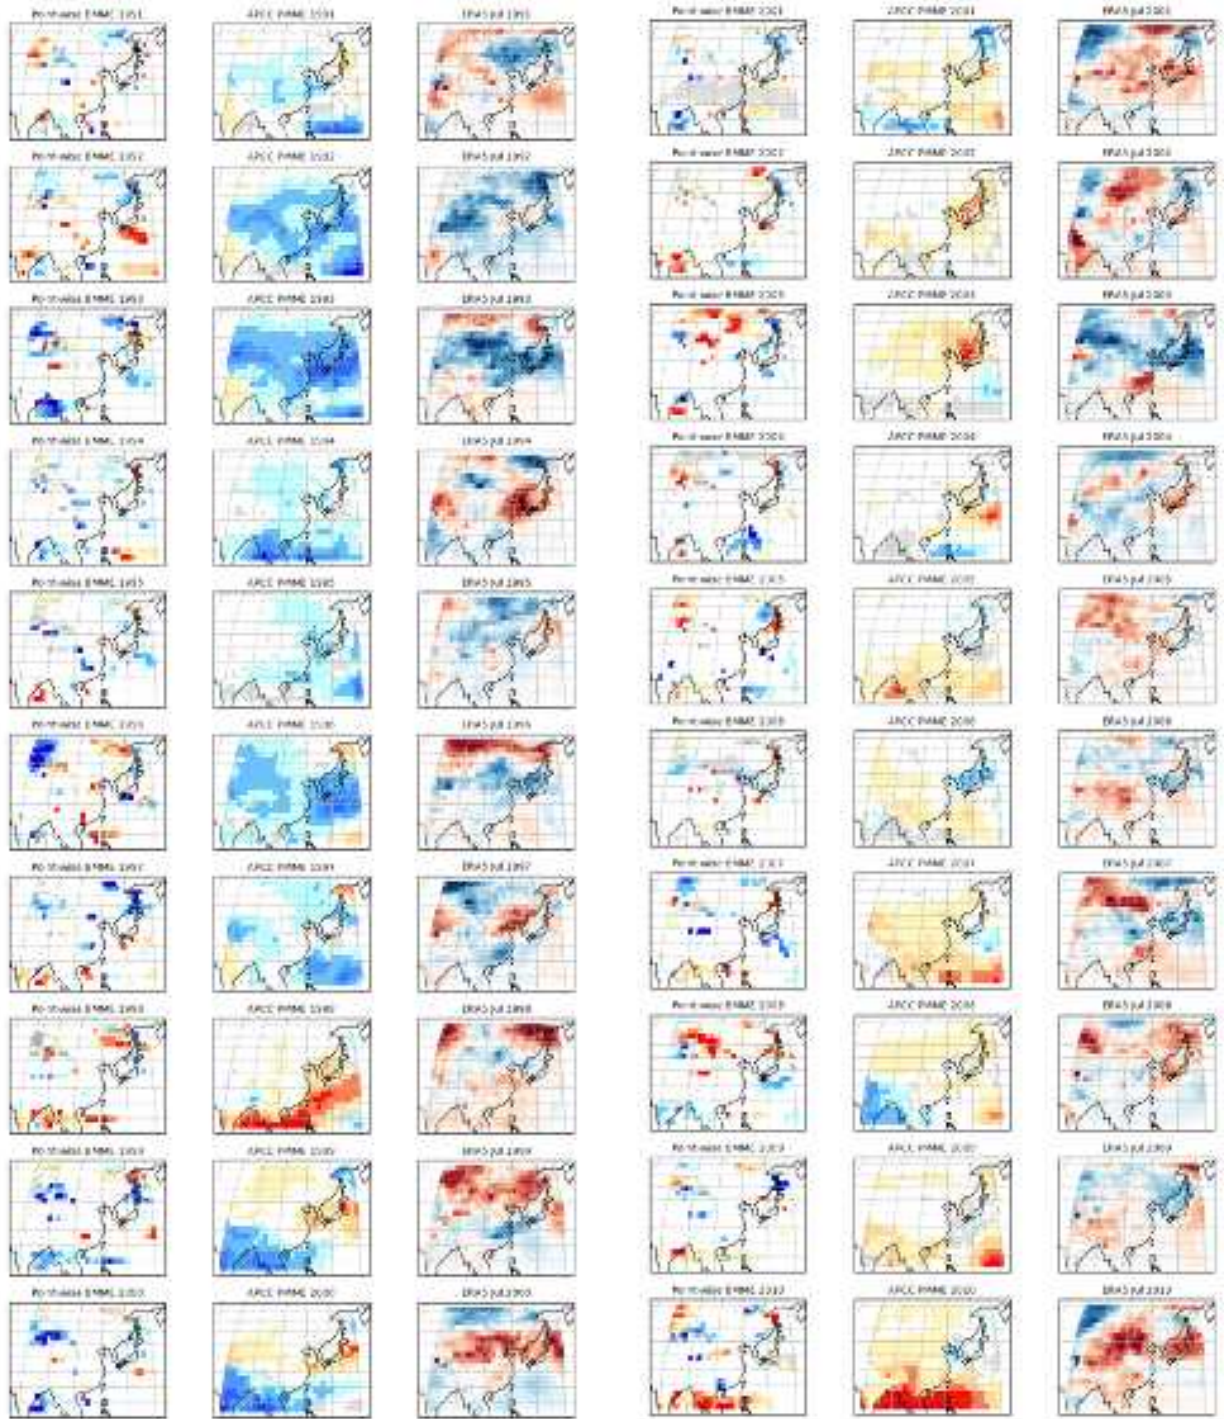


Figure 44. One-month lead July prediction for (a) Bayesian Ridge post-processing, (b) APCC-PMME, and (c) the observation reanalysis during the hindcast period.

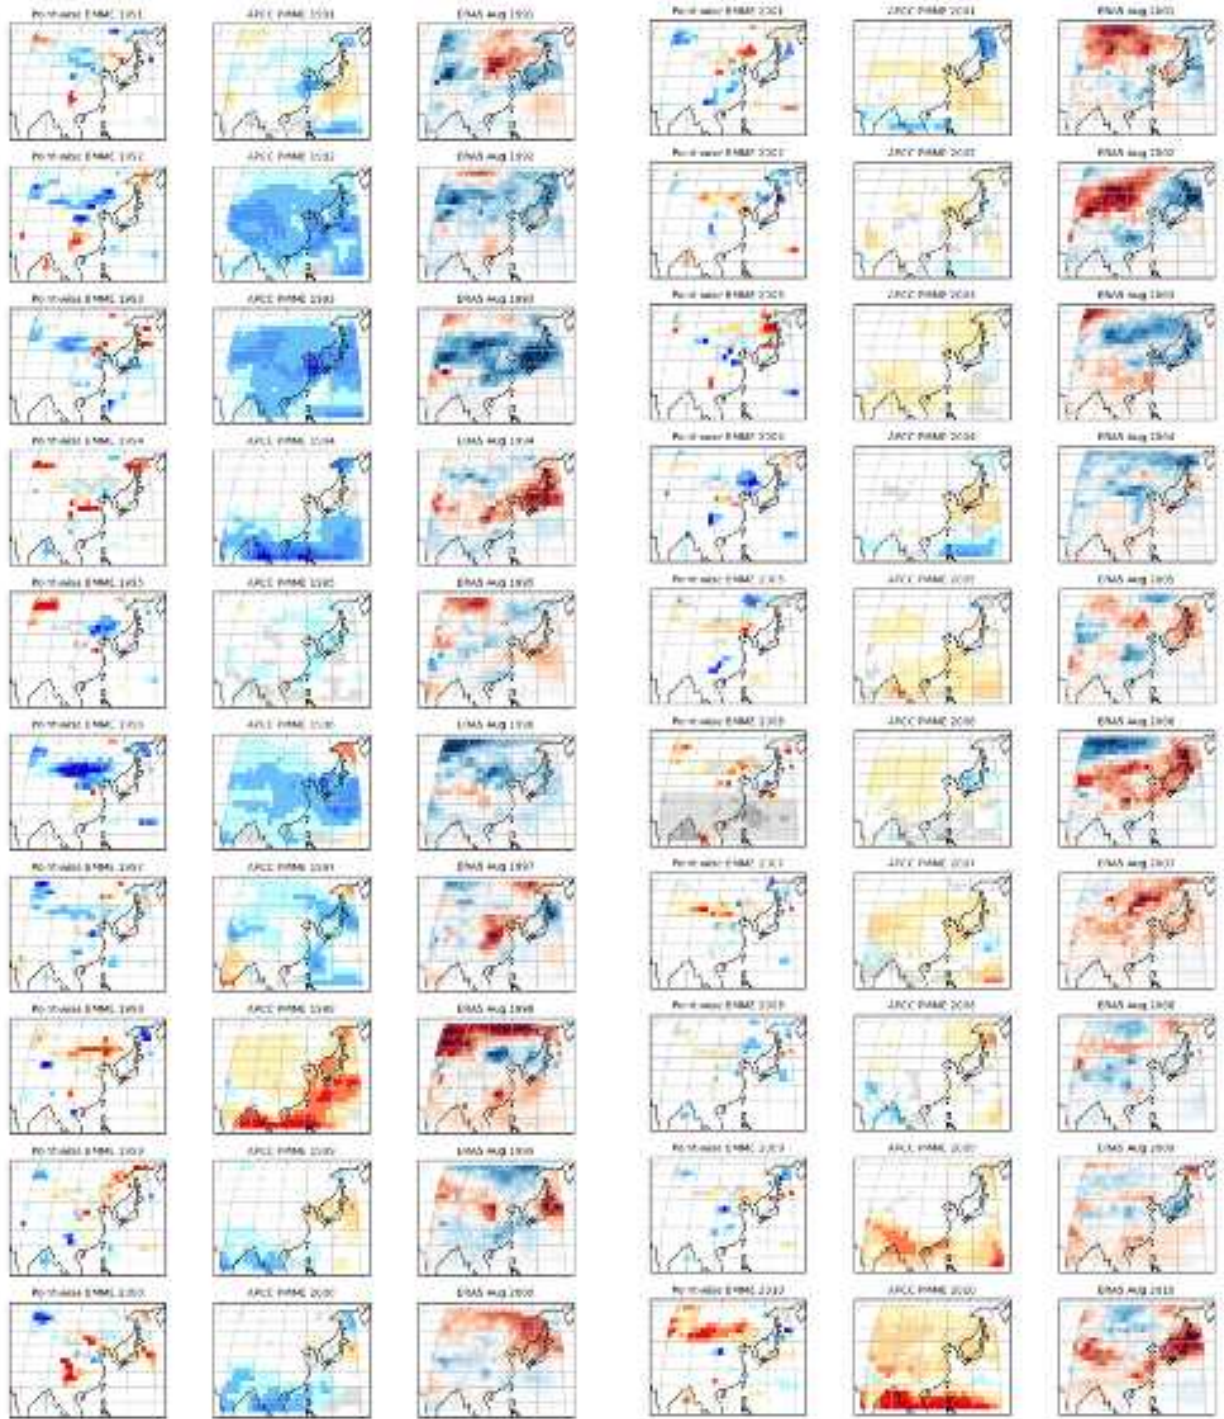


Figure 45. Same as above except for August.

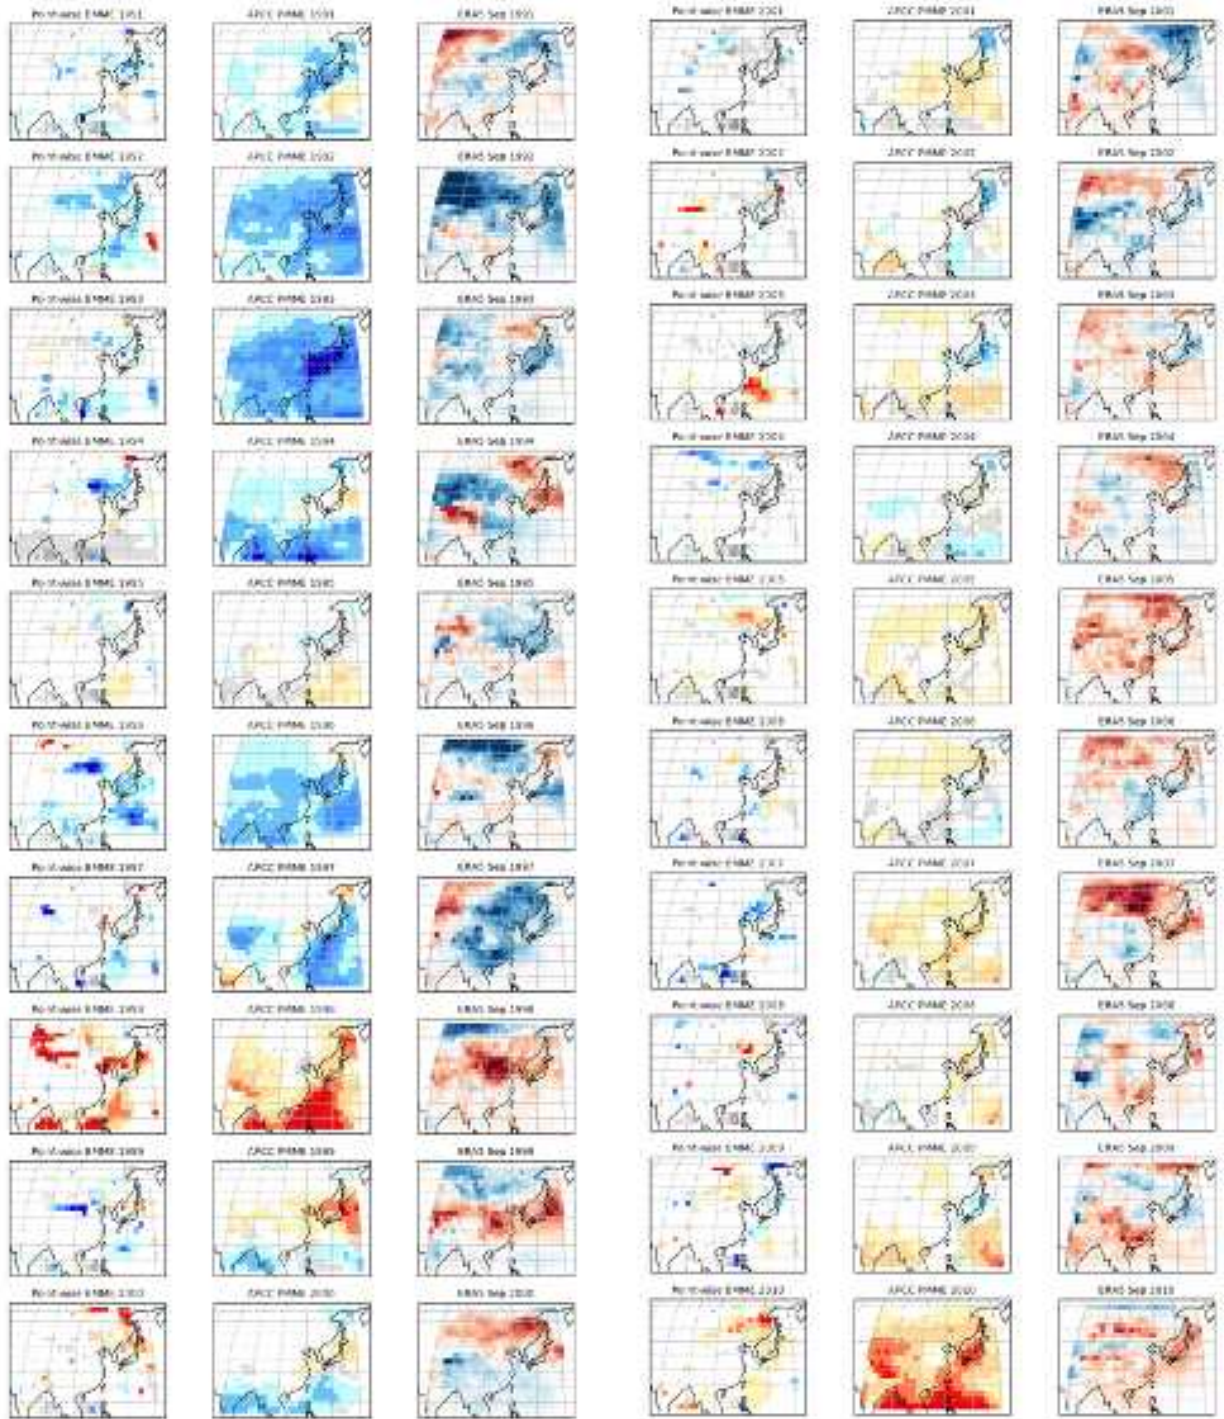


Figure 46. Same as above except for September.

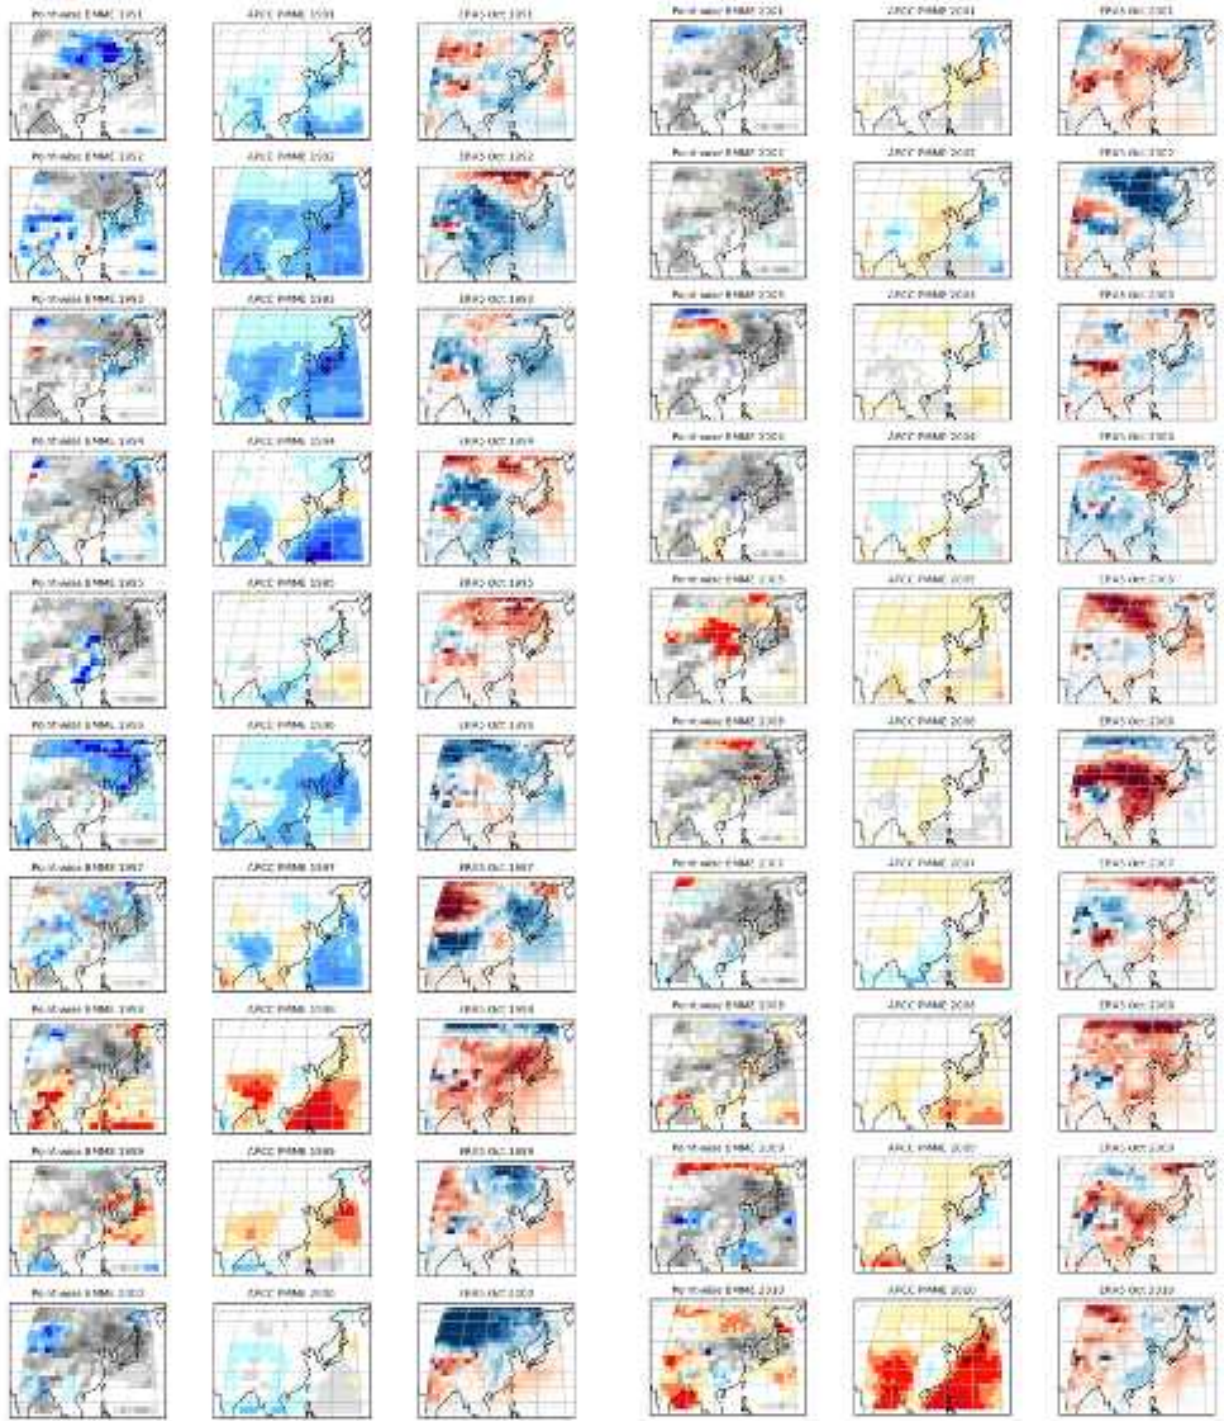


Figure 47. Same as above except for October.

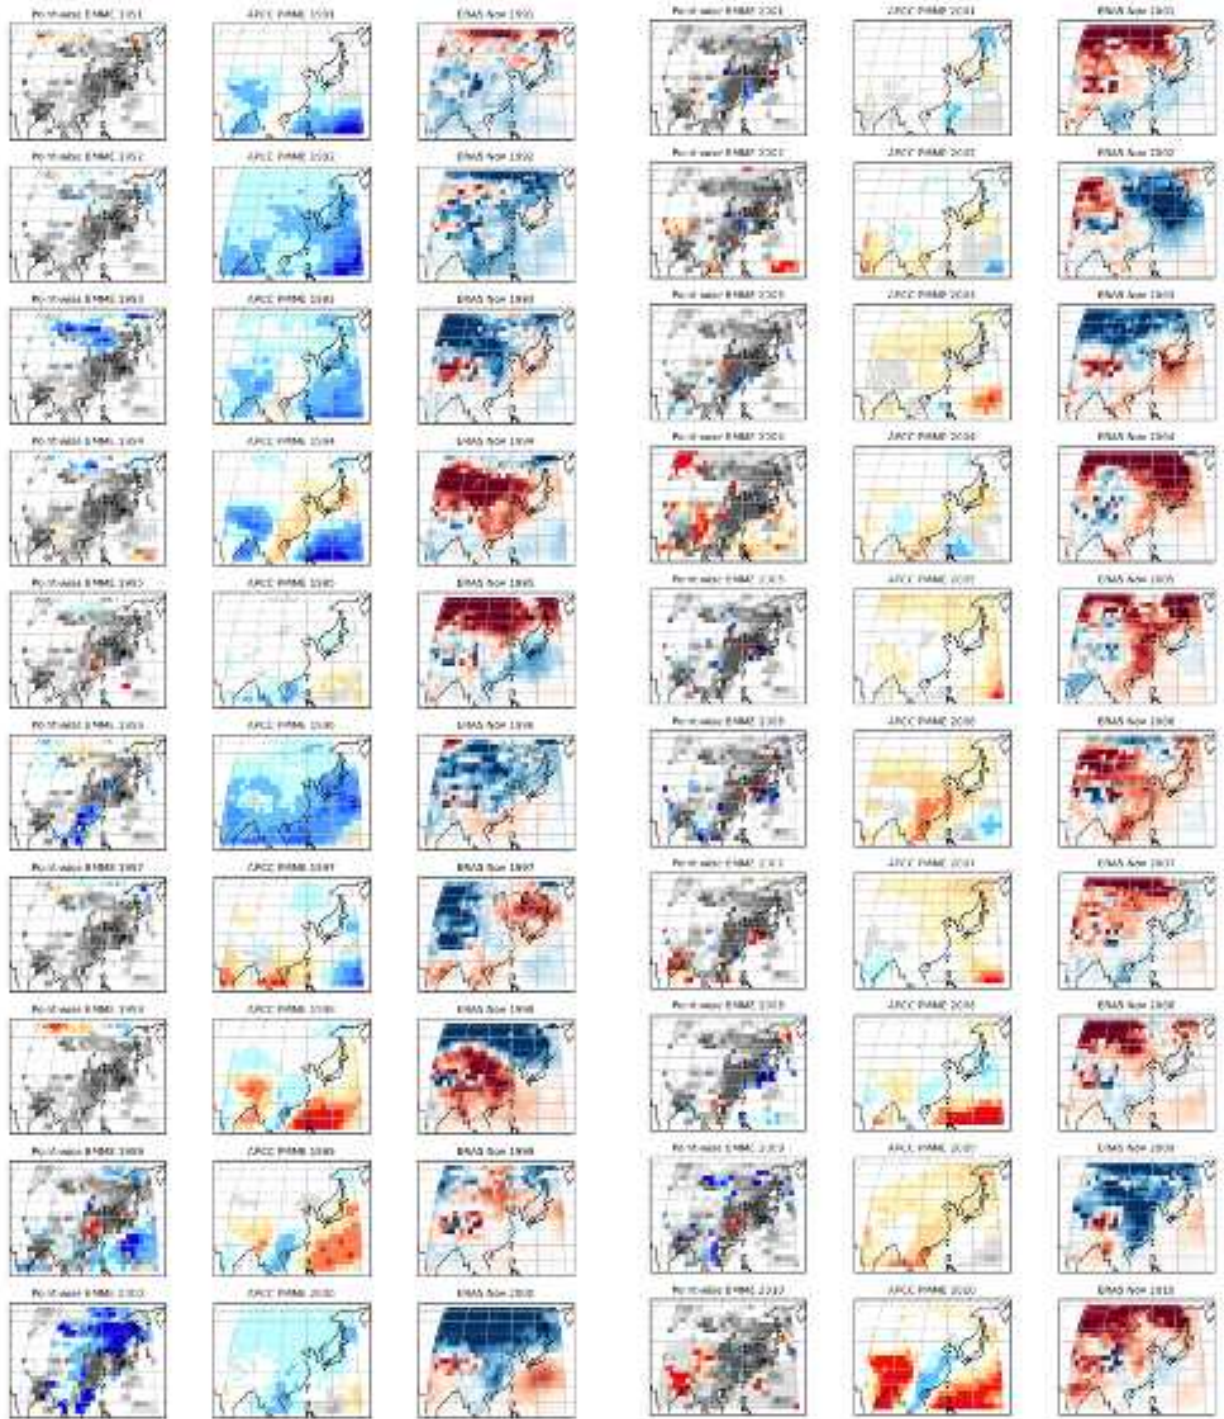


Figure 48. Same as above except for November.

나. 하인드캐스트 기간의 교차 검증 및 평가

하인드캐스트 기간에서 교차 검증한 정규화 베이지 후처리 결과와 기존 APCC PMME의 예측 성능 검토를 위해, 범주형 예측 자료 검증에 주로 사용되는 Heidke Skill Score를 계산하여

상호 비교하였다. 아래 그림에서 나타나는 바와 같이 짧은 자료 기간으로 인하여 대부분의 경우 후처리 결과가 기존 예측값에 비해 향상되지 않은 것을 확인할 수 있다. 다만, 해양의 영향이 강해지는 겨울철로 진입할 수록 해양 지역에서 후처리 효과는 긍정적인 역할을 기대할 수 있는 것으로 보인다.

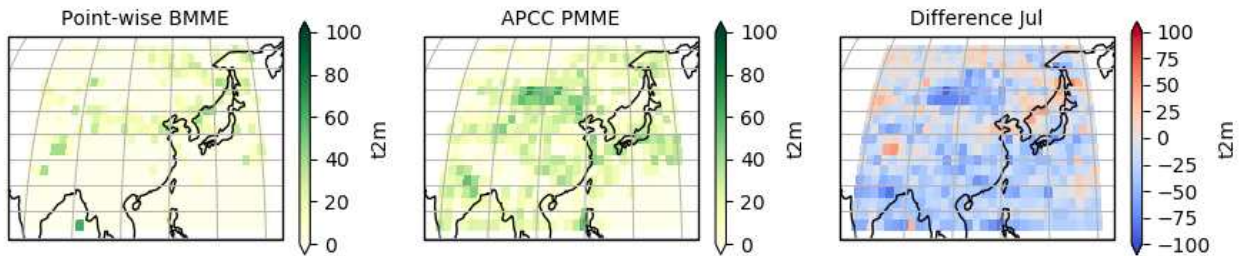


Figure 49. Hindcast Heidke Skill Scores (HSS) for (Left) point-wise BMME, (Middle) APCC-PMME, and (Right) their difference for July 1-lead forecasts.

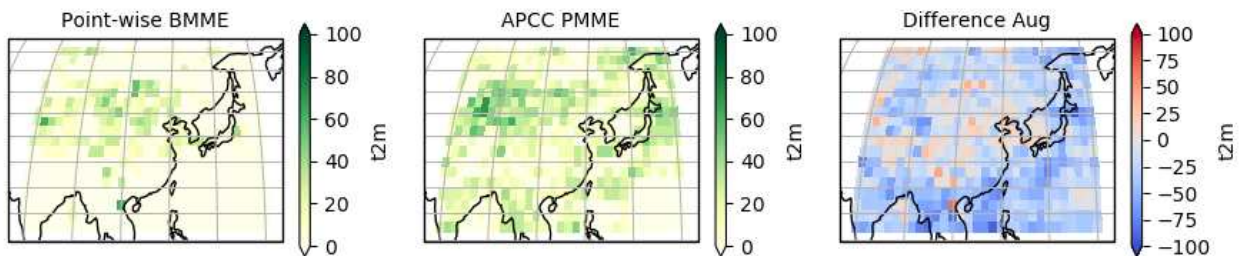


Figure 50. Same as above but for August.

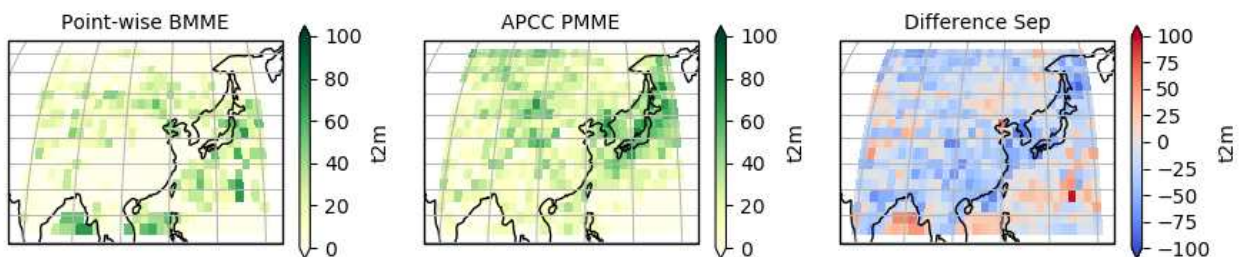


Figure 51. Same as above but for September.

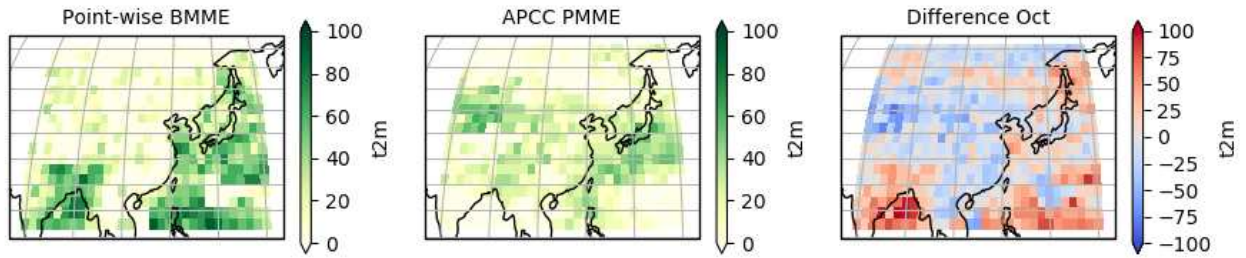


Figure 52. Same as above but for October.

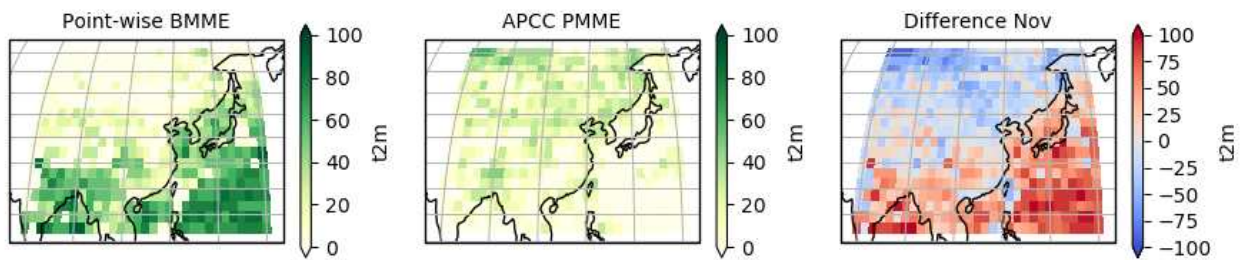


Figure 53. Same as above but for November.

다. 실시간 예측의 예시

하인드캐스트 기간의 자료를 바탕으로 구축된 정규화 베이지 후처리 모델을 이용하여, 실시간 예측도 수행하였다. 그러나, 예측 분산이 과소모의되는 경향이 커서 각 범주별로 정확한 범주 구분이 이루어지지 않는 문제가 발생하고 있다. 이는 향후 후처리 모델 구성을 발전시키는 데 고려해야할 것으로 보인다.

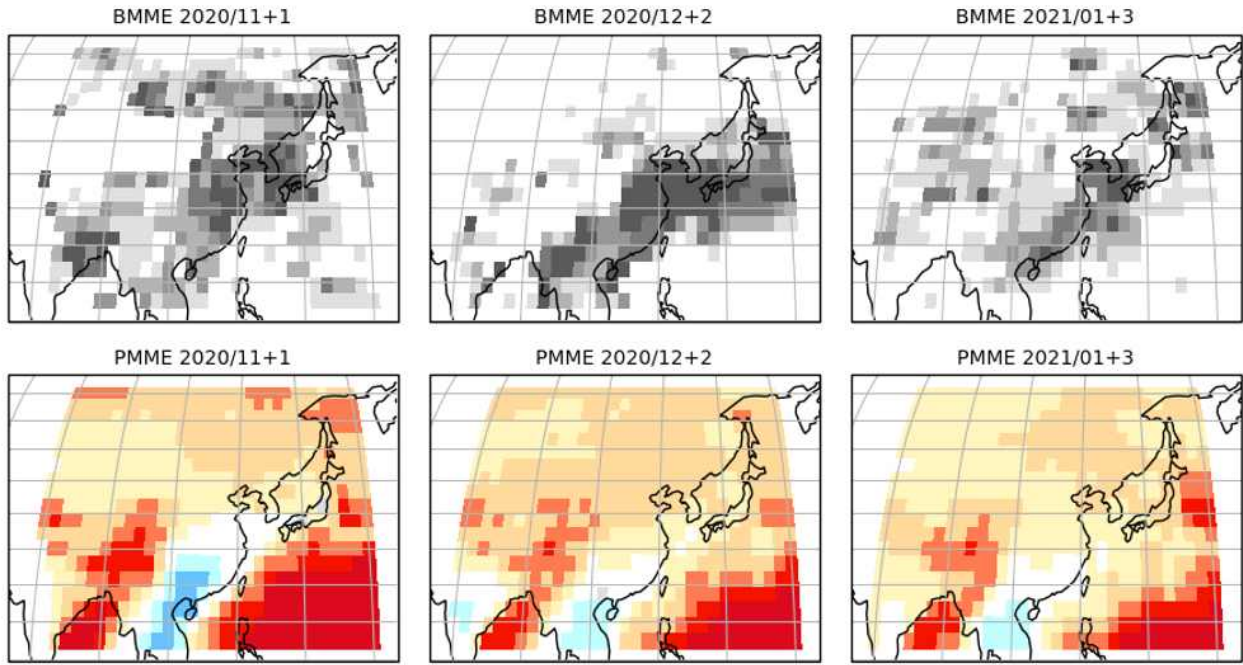


Figure 54. Real-time forecasts for the (Left) 1-month lead November, (Middle) 2-month lead December, and (Right) 3-month lead January forecasts. (Upper) Bayesian ridge post-processing and (Lower) APCC-PMME.

기반 APCC-PMME 예측에서는 북서태평양 북동인도양 등 해양 지역에서의 고온이 예측되는 반면 후처리 이후 이러한 고온 예측은 줄어들고 중국 동남쪽으로부터 우리나라를 통과하는 밴드 지역의 평년값 예측이 두드러지게 올라가는 모습을 보이고 있다.




Figure 55. Distribution of the HSS for hindcast cross-validation of (Left) 1-month lead November, (Middle) 2-month lead December, and (Right) 3-month lead January.

예측 성능은 평균적으로는 향상되는 것으로 보이나, 공간적인 산포가 매우 크게 벌어지고 있음을 확인할 수 있다. 따라서, 적은 자료를 이용해 안정적으로 적합을 수행하고 최종 예측 값을 추정하는 방식으로 추가 개발이 진행되어야 할 것으로 보인다.

5. Probability Anomaly Correlation 을 통한 확률적 기후예측 보정

가. Probability Anomaly Correlation 기법에 기반한 다중모델 격자 자료의 통계적 후처리

APCC에서는 전세계 10개국 14개 APEC 회원국 기상청 및 연구 기관으로부터 수집된 전지구 기후모형의 300개 이상의 앙상블 자료를 바탕으로 다중모델앙상블(Multi-Model Ensemble, MME) 기법 기반 계절예측을 생산하여 제공하는데, 이는 기후모형으로부터 생산된 계절 예측은 자연의 비선형적 특성에 의해서 발생하는 불확실성을 내포하고 있기 때문이다. 다시 말해, 기후모형의 역학적 계절 예측은 실제 기후현상의 모든 물리과정을 수치 모사할 수 없기 때문에 실제 관측 값과 편이 (bias) 가 발생할 수밖에 없고 기후예측에 필수적으로 수반되는 불확실성에 대한 정보를 포함하고 있지 않기 때문에 모든 앙상블 멤버 결과값을 활용한 다중기후모형 앙상블 기반 계절예보를 생산하여 제공하게 된다.

계절 예측은 크게 단정적 (deterministic) 예측과 확률적 (probabilistic) 예측 기법으로 생산된다. 단정적 예측은 개별 모델의 모든 앙상블 예측값을 각 모델에 동일한 가중치를 부여하여 평균한 값을 제공하는 방식인데 예측값은 편차 (bias) 로 제공되며 편차란 기후값 혹은 평년값과의 차이를 이른다. 확률적 예측은 개별 모델의 예측 확률을 각 모델별로 가중치를 부여하여 통합하는 방식을 사용하는데, 확률값은 3분위의 범주로 나누어 제공되며 평년보다 높을 확률, 평년과 비슷한 확률, 평년보다 낮을 확률로 확률 예보가 제공된다.

이렇게 전지구 범위로 제공되는 APCC의 확률적 다중모형앙상블 계절 예측정보 (Probabilistic Multi-Model Ensemble, PMME) 는 상당히 낮은 시공간적 해상도 (시간: monthly or 3-monthly, 공간: 2.5 degree) 와 예측성의 한계를 가지고 있기 때문에 실제 다양한 응용분야 의사결정에 활용하기엔 부족함이 있다. 따라서 예측성을 조금이라도 개선하기 위한 다양한 후처리 기법이나 그 외 역학적/통계적으로 예측성을 개선하기 위한 연구들이 시도되고 있다.

다양한 확률적 계절 예측정보의 후처리 기법이 존재하지만 최근에는 예측값과 실제 관측값과의 함수관계를 구축하여 예측을 보정하는 MOS (Model output statistics) 방법이 주로 사용되고 있다. Kim 등(2004)은 여러 일반 순환모형에서 나온 예측치들을 다중 선형 회귀모형 (Multiple linear regression model)을 이용하여 결합하는 super-ensemble 기법을 개발하였고, Lim 등(2012)은 관측치와 일반 순환모형에서 나온 예측값들을 각각 독립성분분석(Independent component analysis)를 통해 차원을 축소 후 정준상관분석(Canonical correlation analysis)을 실시하여 후보정을 시도하였다. 이 외에, Jo 등(2012)은 여름철 강수량 예측에 있어서 베이지안 회귀모형을 이용한 후보정을 개발하였다.

PAC는 Van Den Dool et al.(2017)에 의해 North American Multimodel Ensemble (NMME) 확률 계절예측 정보에 처음으로 시도 되었으며, 현재도 PAC에 의해 후보정된 PMME 예보가 NMME 웹사이트를 통해 함께 제공이 되고 있다

(<https://www.cpc.ncep.noaa.gov/products/NMME/data.html>). PAC는 예측 확률값과 관측 확률값 사이의 회귀 방법을 이용한 통계적 후처리 기법이다. PAC는 물리적 단위와 확률적 단위의 변수를 사용한 회귀의 형식적 유사성을 중심으로 개발되었다. 예를 들면, 수치기상예측(Numerical Weather Prediction, NWP)의 예측성 추적을 위한 보다 일반적인 성능 평가지표 중 하나는 아노말리 상관관계(Anomaly Correlation, AC)인데, PAC는 이 AC의 논리와 목적을 확률 예측의 영역으로 확장하여 적용한 기법이다.

2019년에는 확률예측에 대한 PAC의 적용가능성 (feasibility) 을 평가하기 위해 상대적으로 예측성이 높은 것으로 보고된 적도 부근에 위치하는 필리핀을 대상지역으로 선정하였다. 2019년 연구 결과, 필리핀에 대한 행정구역 별 APCC PMME Hindcast의 예측성 평가 결과를 월 별로 얻을 수 있었으며, PAC 통계적 후처리 기법을 적용한 후에 PMME Hindcast의 예측성이 전반적으로 개선되었음을 확인하였다. 그 결과 PAC를 적도 부근 필리핀 지역에 대한 APCC PMME에 적용하여 예측성을 개선하는 것이 가능한 것으로 판단되었다. 이러한 2019년 연구 결과를 바탕으로 2020년 연구에서는 한반도를 포함한 동아시아 지역에 대해 PAC에 대한 적용성을 평가하였다.

나. PAC 기법 적용을 위한 자료의 구성 및 후처리

(1) 기후자료

APCC 확률예측에 대한 PAC의 적용가능성을 평가하기 위해 APCC MME의 동아시아 (West = 90; South = 20; East = 150; North = 50) 경계를 대상지역으로 선정하였다. APCC에서 생산하는 확률계절예측 정보는 1983년부터 2010년 동안의 Probabilistic MME (PMME) Hindcast를 사용하였고, PAC를 적용하고 전후의 예측성을 평가할 관측자료로 Copernicus Climate Change Service (C3S)의 ERA5 재분석 (Reanalysis) 자료를 사용하였다. ERA5 재분석 자료는 Monthly averaged reanalysis 자료를 Climate Data Store (<https://cds.climate.copernicus.eu/>)에서 1983년부터 2010년 동안의 모든 월 자료를 다운로드 받아서 사용하였다. ERA5 재분석자료의 해상도는 $0.25^{\circ} \times 0.25^{\circ}$ 로써 APCC MME의 공간적 해상도($2.5^{\circ} \times 2.5^{\circ}$)에 비해 10배 작은 크기의 격자로 제공이 된다.

우선 APCC PMME Hindcast 자료 중 선행시간이 한 달인 자료만을 추출하여 월별 데이터베이스를 구축하였고, 해당 확률예보를 각 tercile(Above Normal, Near Normal, Below Normal)별로 나누어 예측값 데이터베이스를 구축하였다. APCC PMME의 공간적 해상도가 2.5° 격자이므로 공간적 해상도가 0.25° 인 ERA5 재분석자료의 값을 APCC PMME의 2.5° 격자에 맞춰 Aggregation을 하여 재격자화(re-gridding)를 하여 관측값 데이터베이스로 구축하였다.

(2) PAC 기법의 후처리 방법

본 연구에서 PAC는 다음과 같은 식을 사용하여 계산하였다.

$$PAC = \frac{\frac{1}{N} \sum_{i=1}^N p'_i o'_i}{\sqrt{\frac{1}{N} \sum_{i=1}^N p_i'^2 \frac{1}{N} \sum_{i=1}^N o_i'^2}}$$

위 계산식에서 p는 특정 tercile의 확률예측값이고, o는 관측값을 바탕으로 예측값의 특정 tercile이 맞았는지 여부(a hit of that tercile)를 0 또는 1로 나타낸 값이고, p와 o의 프라임(')은 기후학적 확률인 1/3에서 p 또는 o의 차이값(departure)을 나타낸다. N은 1983년에서 2010년까지의 Hindcast 기간인 28이 사용되었다.

일단 PAC가 계산되면 다음과 같은 식을 이용해 원래 확률예보값을 보정한 새로운 확률예보값을 생성하게 된다.

$$p_i'^{adj} = PAC \frac{sd_o}{sd_p} p_i'$$

위 계산식에서 sdo는 o의 표준편차, sdp는 p의 표준편차를 나타내며, pi'adj은 원래 특정 tercile의 확률예측값(기후학적 확률과의 차이, pi')를 PAC를 이용해 후처리한 확률예측값을 나타낸다.

(3) PAC 기법 적용 후 예측 성능평가 방법

확률 예측은 NWP 결과값의 양상블을 생성하기 위한 다중 시뮬레이션이 컴퓨터를 통해 충분히 가능해짐에 따라 최근에 본격적으로 시작되었는데, 가장 대표적으로 쓰이는 평가지표로 Heidke Skill Score (HSS)가 있다. Heidke Skill Score (HSS)는 당연히 올바르게 예측할 경우를 제거한 정확도를 의미한다. 예를 들면 사막에서 비가 오지 않을 확률처럼 당연한 경우는 예측성에서 배제한다. HSS는 예측 범주가 관측된 범주와 일치하는 빈도를 우연으로 예측되는 빈도 이상의 값을 비교한다. HSS는 1에 가까울수록 예측성이 좋고 0에 가까울수록 예측성이 없음을, 0 미만일 경우 우연히 맞출 확률이 예측성보다 높음을 의미한다. 0보다 큰 점수는 무작위 예측에 비해 개선되었음을 나타낸다.

HSS 계산식은 다음 Figure 56과 같다. 계산식에서 A+F+K는 예측을 시도한 총 횟수(Number of hits)를 나타내고, C1은 우연으로 예측되는 빈도(Expected number of hits)를, P는 예측에 성공한 빈도(Total number of forecasts)를 나타낸다.

Fcst Obs	+	0	-	Total
+	A	B	C	D
0	E	F	G	H
-	I	J	K	L
Total	M	N	O	P

$$\text{Heidke Skill Score} = \frac{(A + F + K) - C1}{P - C1} \quad (\text{Perfect: } 1)$$

$$C1 = (M \times D) + (N \times H) + (O \times L) \div (P \times P)$$

Figure 56. Equation for Heidke Skill Score calculation.

PAC는 그 자체로도 단일 숫자(0-1)로 나타내지는 성능지표일 뿐만 아니라, 예측값과 관측값 사이의 확률아노말리를 회귀 방법에 의해 감쇠(damping)시킴으로써 HSS를 최대화하기 위한 통계적 후처리 기법이다. 이 PAC를 적용한 예측자료의 확률 예측성 평가를 위해, 동아시아 지역을 대상으로 PAC 적용 전후의 APCC PMME Hindcast 자료를 각각의 격자 별로 추출된 ERA5 관측값을 이용해 HSS를 계산하여 예측성의 변화를 평가하였다.

다. PAC 기법 적용에 따른 다중모델 격자 자료의 통계적 후처리 결과

(1) PAC 후보정의 공간적 분포

PAC 후보정 기법 적용 전후의 HSS 성능평가 결과를 동아시아 전체 격자 별로 계산하여 PAC에 의한 성능 개선 정도가 시공간적으로 특정 패턴을 보이는지를 확인하였다. 1월부터 12월까지 매월 1 month 선행시간 (Lead time)의 계절예측을 대상으로 PAC를 적용한 후 원 자료인 APCC PMME와의 HSS 결과값을 직접 비교하고 그 차이를 격자 별로 계산하여 지도상에 나타내었다.

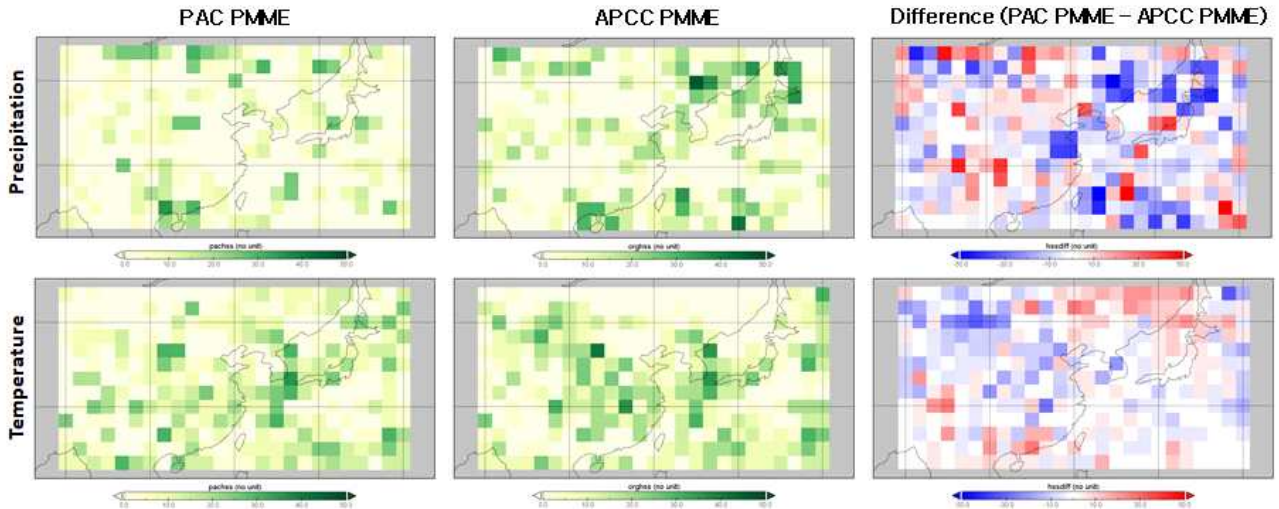


Figure 57. Precipitation and temperature HSS maps of the PAC-applied PMME (PAC PMME) and original APCC PMME (APCC PMME) with 1 month lead time in October, and maps of the HSS difference (Difference) between the PAC-applied PMME and original APCC PMME, which are calculated based on the hindcast from 1983-2010.

Figure 57은 10월에 생산되는 1 month 선행시간의 3개월 계절예측에 대한 PAC 보정 전후 HSS에 대한 결과를 보여준다. 강수량 (Precipitation)의 경우, PAC 후보정에 대해 지역에 따른 뚜렷한 차이가 보이지 않고 모자이크 형식의 결과나 나타나는 것으로 보아 PAC 후처리에 의한 개선이 유의미하게 보이지 않았다. 기온 (Temperature)의 경우 역시, 강수량과 마찬가지로 PAC 후보정에 대해 지역에 따른 뚜렷한 차이가 보이지 않고 모자이크 형식의 결과나 나타나는 것으로 보아 PAC 후처리에 의한 개선이 유의미하게 보이지 않음을 확인하였다.

10월 계절예측과 유사하게, HSS의 차이를 바탕으로 모든 월에서 기온과 강수량의 계절예측에 대한 PAC 후보정의 뚜렷한 공간적 분포 패턴을 찾을 수 없었다 (Figures 58-61). 또한 특정 계절에 대한 PAC 후보정의 효과가 전혀 보이지 않았으며, 전반적으로 모자이크 식의 예측성능 차이가 나타났다. 다만 강수량이 기온에 비해서 성능이 오히려 상당히 낮아지는 격차가 다수 발견되었으며, 특히 7월부터 12월 기간 동안 그 정도가 심하게 나타났다.

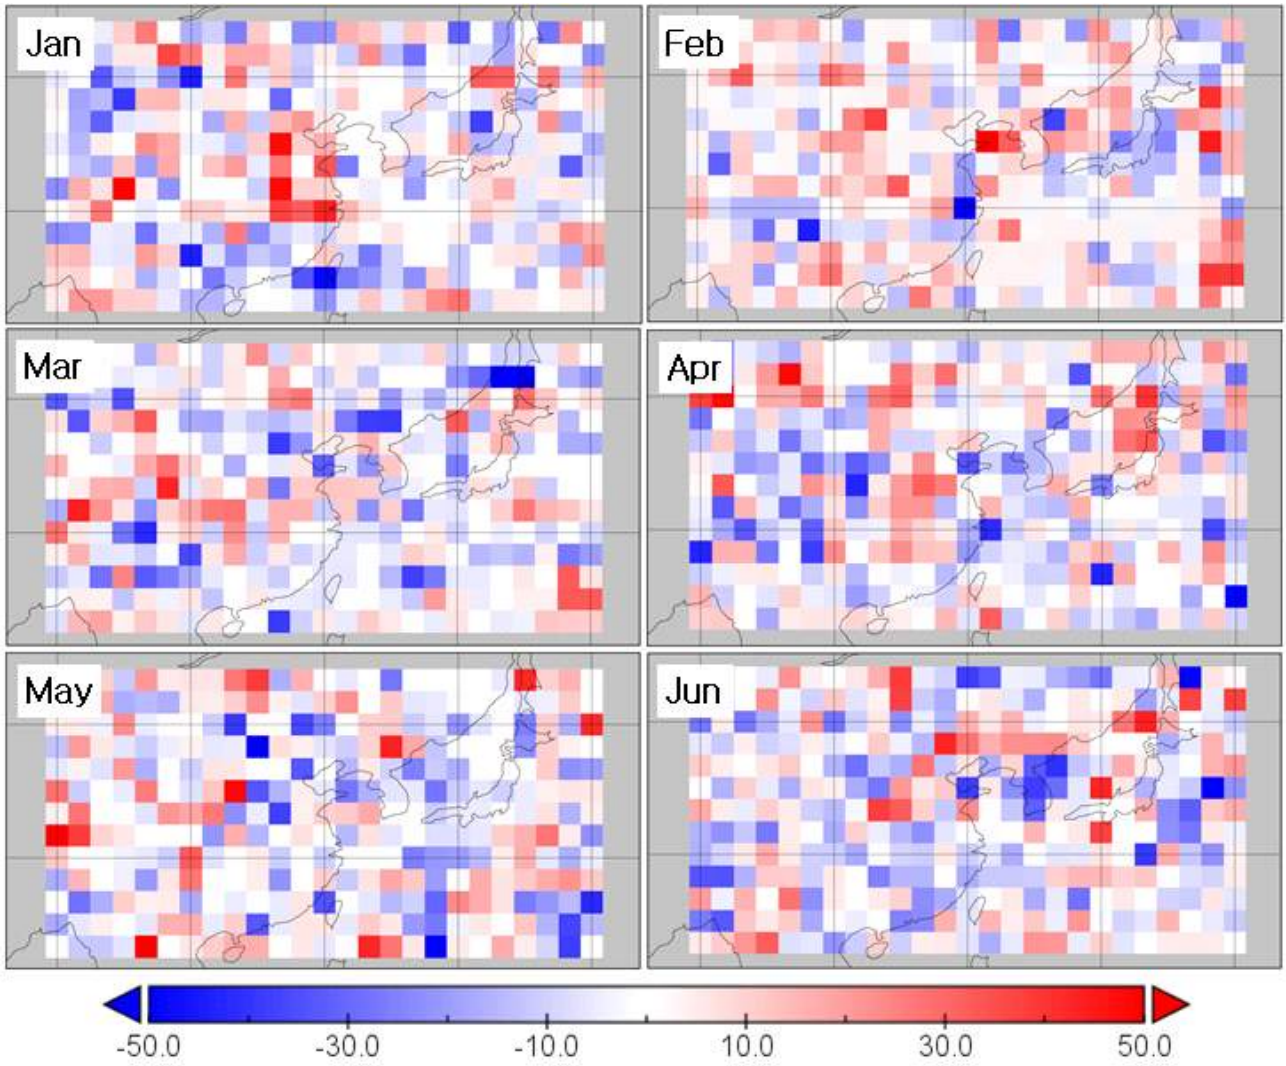


Figure 58. Precipitation HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jan to Jun using the hindcast from 1983-2010.

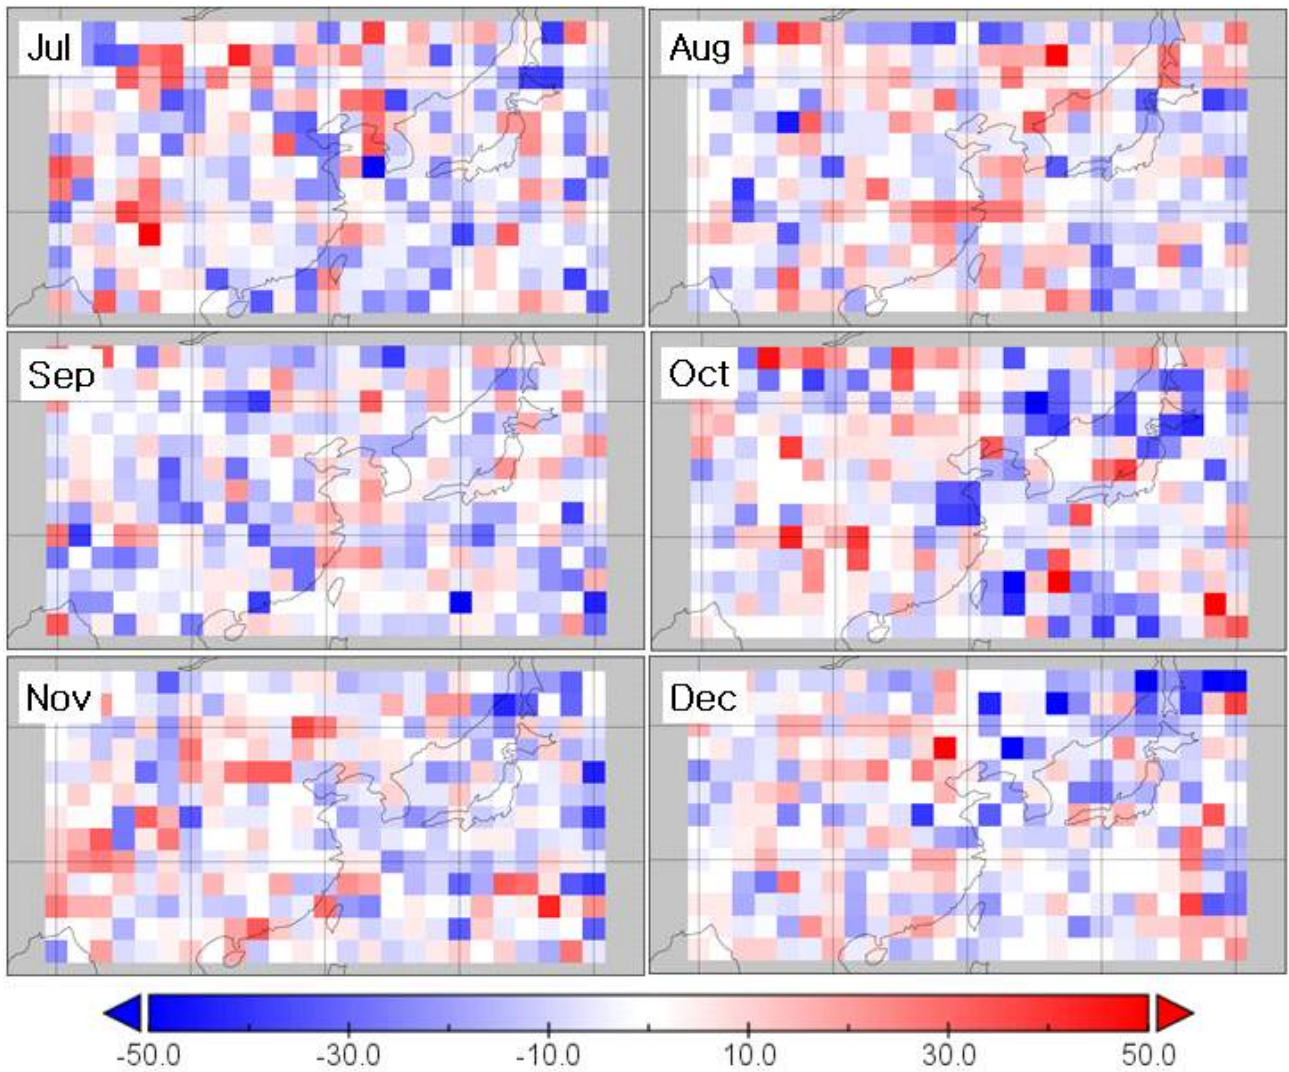


Figure 59. Precipitation HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jul to Dec using the hindcast from 1983-2010.

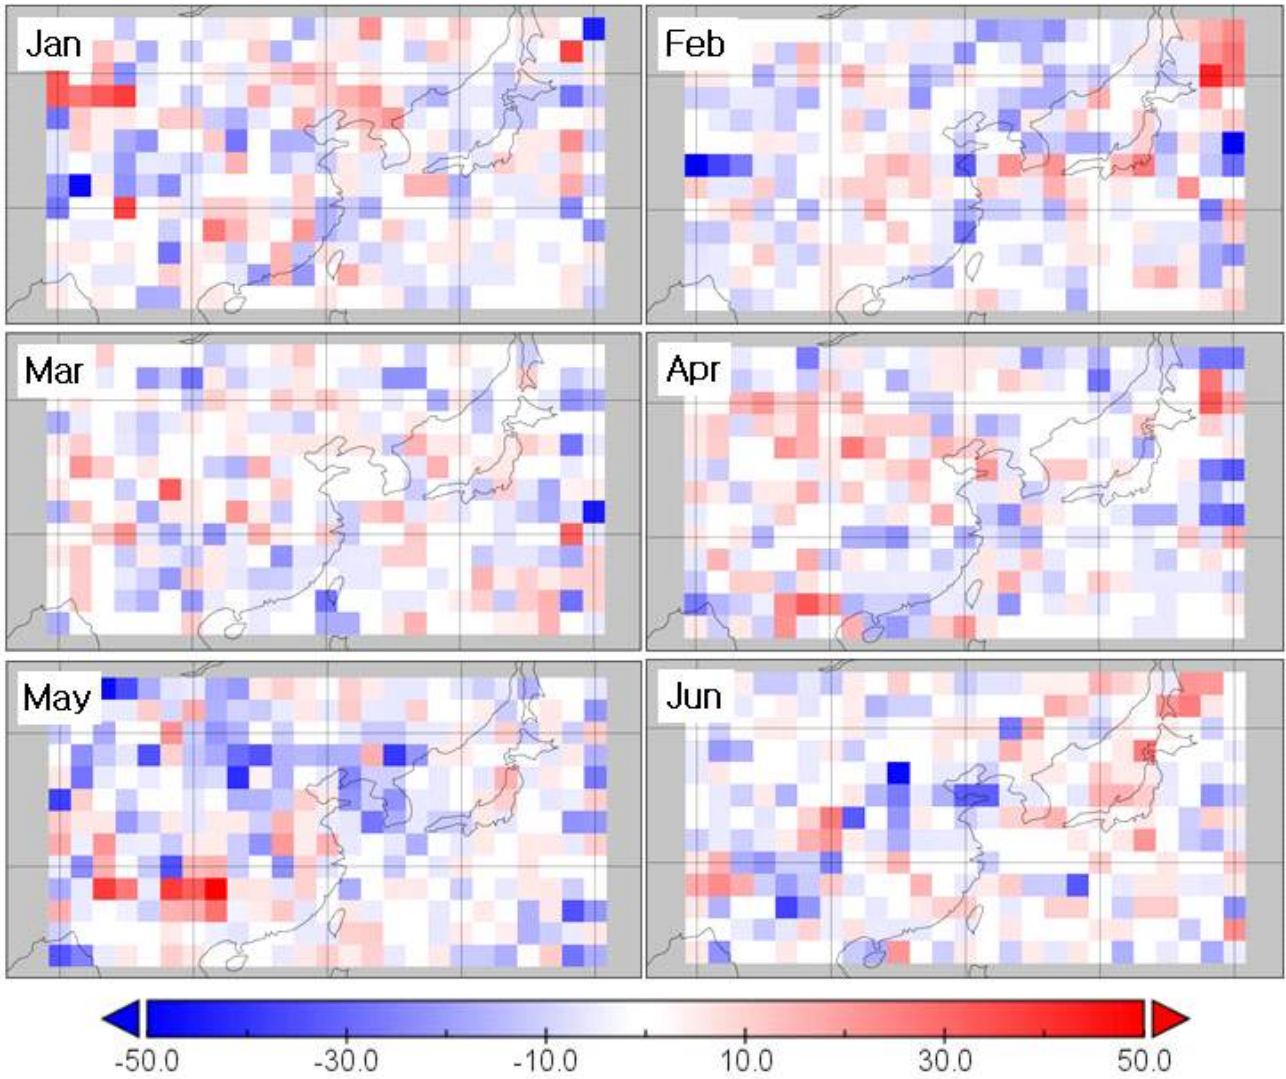


Figure 60. Temperature HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jan to Jun using the hindcast from 1983-2010.

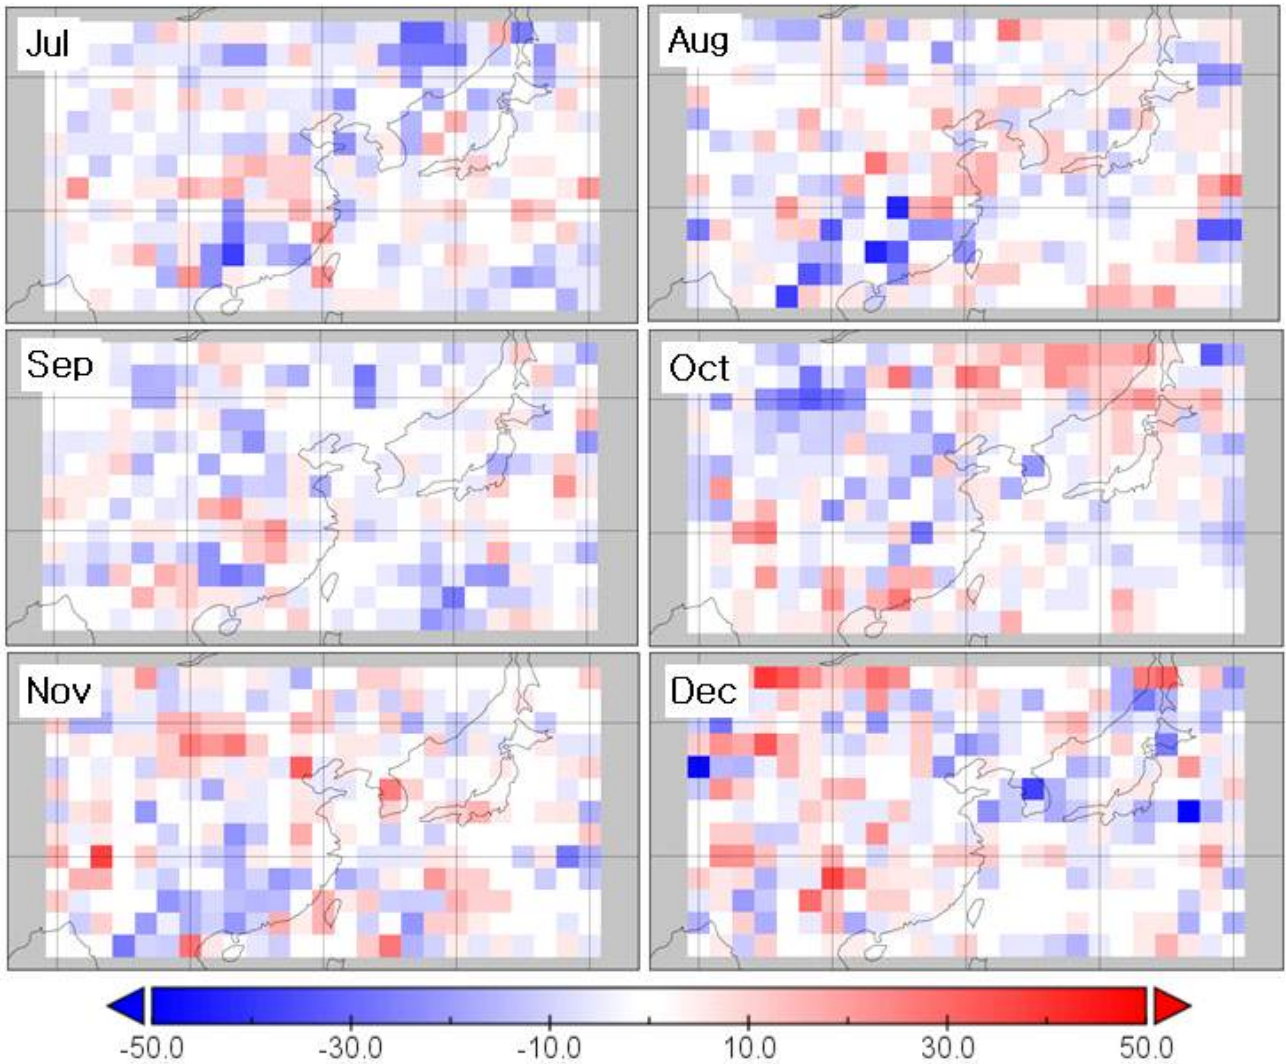


Figure 61. Temperature HSS differences between PAC-applied PMME and original APCC PMME with 1 month lead time from Jul to Dec using the hindcast from 1983-2010.

(2) PAC 후보정의 정량적 결과

정량적인 개선 정도를 파악하기 위해 각각의 기후변수에 대해 전체 계절예측 격자의 HSS 평균값을 월 별로 계산하여 PAC 적용 전과 후의 결과를 표로 나타내었다 (Table 11). 표와 같이 PAC로 보정된 확률예측정보는 대부분의 월에서 예측성이 개선되지 않고 오히려 예측성능이 평균적으로 감소했음을 알 수 있었다.

Table 11. Seasonal Heidke Skill Score of both precipitation and temperature variables, which are averaged for all grids over the target East Asia region.

	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ	DJF
Precipitation	-0.32	-0.82	-1.48	-0.90	-0.70	-1.76	-2.37	0.00	-3.64	-2.55	-1.73	-2.88
Temperature	-0.70	-1.62	-1.07	-1.00	-3.02	-1.07	-2.10	-0.87	-1.88	-0.59	0.01	0.20

강수량의 경우 8월을 제외한 모든 시기에 PAC 적용 후 HSS 평균값이 오히려 줄어든 경우를 볼 수 있었는데, 특히 9월부터 12월까지 HSS가 급격하게 떨어지는 것을 알 수 있었다. 앞서 공간적 분포 지도를 통해 특정 지역에 대한 패턴을 찾아보려 했으나 불규칙한 지역에서 HSS 값이 변동하는 것을 확인 할 수 있었다. 기온의 경우 강수량에 비해 HSS가 많이 떨어지지 않았지만, 대부분의 월에서 오히려 PAC 후보정으로 인해 예측성이 낮아졌는데, 다만 일부 11월과 12월에서는 HSS 평균값이 소폭 증가하는 결과를 나타내었다. 그럼에도 불구하고 Figure 60와 Figure 61에서 기온에 대한 PAC 후보정의 공간적 패턴을 여전히 찾을 수 없었다.

결과적으로 본 연구를 통해 PAC의 동아시아 지역 적용가능성(feasibility) 평가 결과, PAC 통계적 후처리 기법을 적용한 후에 PMME Hindcast의 예측성이 대부분의 월에서 평균적으로 낮아지는 결과를 확인하였다. 따라서 PAC를 APCC PMME에 적용하여 동아시아 지역에 대한 예측성을 개선하는 것이 어려운 것으로 판단되었다.

다만 PAC 후보정의 공간적 분포에 일정한 패턴이 보이지 않고 모자이크 식의 변이가 큰 결과가 나타난 것은 과학적으로 설명하기 어려운 분석결과이기 때문에 방법의 적용이나 계산 상에서 오류가 있었는지 면밀히 검토하고, 이러한 예측치 못한 결과가 나온 것에 대해 추가적인 연구가 뒤따를 필요가 있다. 또한 개별 격자별로 PAC 후보정을 적용한 단순하고 직접적인 방법을 넘어 제한된 샘플수로 인한 한계를 극복하기 위한 다양한 방법론(다격자(multi-grids) 기반 통계 분석, 3개 tercile을 모두 포함한 통계분석, 관측값의 tercile을 0 또는 1이 아닌 좀더 세분화하는 다양한 방법 등)이 추가적으로 시도되어야 할 것이다.

6. 딥러닝 기반 계절내 예측기후 오차 저감 기법

가. 신경망 훈련 기법 및 계절내 예측 자료

딥러닝(deep learning) 기술은 다양한 알고리즘의 개발과 디지털 혁명, 컴퓨팅 기술의 발달로 갈수록 방대해지는 데이터의 축적에 따라 다양한 분야에서 복잡한 문제들을 해결하는데 널리 적용되고 있다 (LeCun et al. 2015; Kurth et al. 2018). 또한, 축적된 데이터의 패턴을 신속하게 발견하고 현재 관측 자료와 패턴을 병합하여 미래에 발생할 수 있는 일을 예측하기 위해 강력한 슈퍼 컴퓨팅 시스템 및 알고리즘 개발에 점점 더 많은 투자를 하고 있다. 이러한 최근 딥러닝 기술은 날씨 예측 분야에서 가능성을 보여주는 기술 중 하나로 인식되고 있다. 그러나 매우 복잡한 역학적 데이터로 구성된 날씨 패턴을 예측하는 일은 데이터 및 계산 집약적인 과정이기 때문에 날씨 예측에 딥러닝 기술의 적용은 아직 초기 단계에 있다. 그러나, 이러한 딥러닝 기술이 최근 강수량 등의 예측 성능 개선 가능성을 보여주면서 (Hernández et al. 2016), 예측이 어려운 기후 분야에서도 예측 개선 및 적용 가능성을 보여주는 기술로 발전하고 있다. 예를 들면, Poornima and Pushpalatha 2019는 다양한 신경망 알고리즘(예, RNN, ARIMA, LSTM 등)을 강수 자료에 적용하여 강수를 예측하기도 하였다. 또한, 내일의 평균기온 혹은 최고기온을 예측하기 위한 방법으로 관측 자료에 다양한 통계적 기법 뿐만 아니라 기계학습, 다층퍼셉트론(Multi-layer Perceptron, 이하 MLP), 지도선형기계학습(Support Vector Machine, 이하 SVM) 및 극한 기계학습(Extreme learning Machine, 이하 ELM)을 적용하여 다음 날의 기온을 예측하는 방법 등을 제시하였다 (Paniagua-Tineo et al. 2011; Abdel-Aal and Elhadidy 1995; Haupt et al. 2018; Abrahamsen et al. 2018; Dibike and Coulibaly 2006). Nooteboom et al. 2018와 Ham et al. 2019은 기계학습 및 딥러닝 기법으로부터 El Nino 예측에 우수한 결과를 도출하였다. Ortiz-García et al. 2012와 Ramesh and Anitha 2014와 Abrahamsen et al. 2018은 종관기상관측 자료에 다양한 기계학습 기법 적용을 통해 다음 6시간 및 7~10일 동안의 기온을 예측하였으며, Karevan and Suykens 2020은 장단기기억(Long Short-Term Memory, 이하 LSTM) 기법을 시계열 관측 자료에 적용하여 실시간 기상자료를 예측하였다. Shi et al. 2015은 강수의 현재 예보를 시공간적(spatiotemporal)으로 연속하는 문제로 인식하여 레이더 관측 이미지를 이용하여 미래 12시간까지 강수 예측을 수행하였다. 예측 모델을 구축하기 위하여 일반적인 LSTM 기법의 내부에 Convolution 기법을 적용한 ConvLSTM을 제안하였으며, 다른 기법들에 비해 우수한 성능을 보여주는 결과를 도출하였다. Nair et al. 2018은 ANN 기법을 이용하여 Global Climate Models(GCMs) 자료의 예측성을 향상시키는 연구를 수행한 바 있으며 인도 지역에 대해 몬순(monsoon) 기간의 강수량 연 변동(year to year variations)의 예측성을 향상시킬 수 있음을 보인다. 또한 GCM의 모수화(parameterization scheme) 프레임에 신경망(Neural networks) 기법을 통해 훈련시켜 GCM의 예측력을 향상시키는데 심층학습을 적용하였다 (Scher and Messori 2018; Dueben and Bauer 2018; Salcedo-Sanz et al. 2016). 이와 같이 강수 등의 예측 정확성을 향상시키기 위해 많은 연구가 수행되었으나 대부분의 연구가 종관기상 관측자료의 단기 예보 및 계절 규모 예보 관점에서 이루어졌고, S2S 시간 규모에서의 강수 혹은 기온 예측성 향상에 기계학습 혹은 신경망 알고리즘 적용에 관한 연구는 미진하다. 또한, 계절 기후에서는 여러 기후모델을 한번에 고려하는 다중모델앙상블(multi-model ensemble) 기법을 통해 계절 기후 예측

의 신뢰성을 증가시키는 연구가 다수 진행되어왔다. 그러나, S2S 규모에서의 MME 적용 기법에 관한 연구는 연구는 드물다 (Wang et al. 2020; Park et al. 2018). 또한, 기계학습 및 딥러닝은 가용할 수 있는 데이터가 많을수록 학습 효과가 좋아지고 결과의 신뢰성이 높아진다. 최근 World Weather Research Program 및 World Climate Research Program, National Oceanic and Atmospheric Administration 및 National Integrated Drought Information System 등 국제 S2S 연구 그룹에서는 S2S 예측 성능을 향상 시키기 위해 인공지능(artificial intelligence, AI) 및 기계학습(machine learning, ML) 등을 적용한 연구와 그 결과를 공모하는 등 콘테스트를 추진했으며 (<https://www.drought.gov/drought/forecast-rodeo-ii-leaderboard>), 향후에도 계획되었다 (<http://s2sprediction.net/xwiki/bin/view/Phase2/MachineLearning>).

이 연구는 신경망 모델을 이용한 S2S 예측 자료에 후처리(post-processing)를 통해 한반도 영역의 S2S 예측 자료의 오차 저감 기술을 개발하기 위해 수행하였다. 특히, 올해는 다수의 기후모델의 S2S 예측기후 자료로부터 되도록 많은 양의 S2S 예측기후 자료를 생산할 수 있는 앙상블 방법을 찾고, 여기에 신경망 모델을 적용하여 한반도 영역의 S2S 예측 자료(최고 및 최저기온, 강수)의 예측 성능을 향상시키기 위해 수행되었다. 먼저, 학습 모델 구축을 위한 MME 기반 S2S 예측기후 입력 자료는 기준 예측빈도로부터 6개(ECMWF, MSC, NCEP, KMA, UKMO, CMA) 개별 기후모델을 결합하여 MME 기반 S2S 예측 자료를 생산하였다. 학습 모델은 선례 연구에서 활용된 LSTM을 차용하였다. 입력된 예측기후 변수는 지표면 평균기온(T2M), 최고기온(TMAX), 최저기온(TMIN), 강수(PREC), 해면기압(MSLP), 850hPa 기압면에서의 동서남북 방향의 바람(U850 및 V850), 지위고도(Z500) 등의 기후 변수로 구축하였다. 훈련 모델에 입력될 관측값으로는 재분석 자료인 ERA-Interim 자료로 구축하였다. MME 기반의 S2S 예측기후 자료의 과거예측재현(이하 Hindcast) 자료의 기간은 6개 개별 기후모델의 Hindcast 기간이 각각 다르지만 이들의 Hindcast 기간이 최대한 포함되도록 1995년부터 2014년까지로 설정되었다. 이렇게 구축된 MME 기반의 S2S 예측기후 자료 중 75%에 해당하는 기간은 학습에 이용되었으며, 25%는 테스트 기간으로 활용하였다. 다시 말해서 25%에 해당하는 기간의 모델 결과로부터 LSTM 적용에 따른 MME 기반의 S2S 예측기후의 선행예측기간 전체 일별 및 선행예측 3-4주의 예측성 향상 정도를 평가하였다.

나. 장단기 기억기술 기반의 계절내 예측기후 자료의 구성 및 후처리

(1) 참여 개별 기후모델

계절내-계절(Sub-seasonal to seasonal, 이하 S2S) 예측을 위해 현재 11개 기관에서 생산하는 S2S 자료는 선행예측시간, 수평 및 연직 해상도, 앙상블 수, 과거 예측자료 생산방법(고정 또는 on the fly), 과거 예측자료 기간, 예측자료의 생산주기 등이 모두 다르다. 본 연구에서는 현재 까지 예측성이 가장 우수하다고 평가되고 있는 European Centre for Medium-Range Weather Forecasts(이하 ECMWF)의 S2S 자료 (Vitart and Robertson 2018; de Andrade et al. 2019; ECMWF 2020)와 연구 대상 기후 모델인 Global Seasonal Forecast System version 5(이하 GloSea5)의 S2S (Scaife et al. 2014; MacLachlan et al. 2015)뿐만 아니라, Meteorological Service

of Canada(이하 MSC), NOAA의 National Centers for Environmental Prediction(이하 NCEP), China Meteorological Administration(이하 CMA) 및 영국(United Kingdom)의 Met Office(이하 UKMO) 등 참여 개별 기후모델 4개를 추가하였다. 본 연구에 활용한 6개 개별 기후모델의 S2S 자료의 특징은 Table 12과 같다.

ECMWF 모델은 일주일에 2번씩 향후 46일에 대해 전 지구 예보를 생산하고 있다. 모델의 예측 성능을 파악하기 위해 과거 20년 기간(이하 Hindcast 기간)에 대해서 11개의 앙상블 멤버를 이용하여 과거 예측을 수행하고 51개의 앙상블 멤버를 구성하여 향후 46일에 대해서 일주일에 2회씩 예측을 수행하고 있다. MSC 모델은 일주일에 1번씩 향후 32일에 대한 전 지구 예보를 생산하는 기후모델이다. MSC(ECCC)는 예측 성능을 파악하기 위해 Hindcast 기간 1995년부터 2014년에 대해서 4개의 앙상블 멤버를 이용해서 과거 예측을 수행하고 21개의 앙상블 멤버를 구성한 후 향후 32일에 대한 예측을 주 1회씩 수행하고 있다. NCEP 모델은 앞서 설명된 2개 기후모델과 다르게 매일에 대해 향후 44일에 대해 전 지구 예보를 생산한다. NCEP은 예측 성능을 파악하기 위해 Hindcast 기간 1999년부터 2010년에 대해 4개 앙상블 멤버를 이용해서 과거 예측을 수행하고 16개의 앙상블 멤버를 구성한 후 향후 44일에 대한 예측이 매일 수행된다. 반면, GloSea5 모델(이하 KMA)은 매월 4번씩 정해진 날짜에서(1일, 9일, 17일, 25일) 향후 60일에 대해 전 지구 예보를 생산하고 있다. 역시 모델의 예측 성능을 파악하기 위해 Hindcast 기간 1991년부터 2010년에 대해서 3개의 앙상블 멤버를 이용하여 과거 예측을 수행하고 4개의 앙상블 멤버를 구성하여 향후 60일에 대한 예측이 Hindcast와 다르게 매일 수행하고 있다. UKMO 모델도 KMA와 같이 매월 4회 정해진 날짜(1일, 9일, 17일, 25일)에서 향후 60일에 대해 전 지구 예보를 생산한다. 모델의 예측 성능 파악을 위해 Hindcast 기간 1993년부터 2015년에 대한 7개 앙상블 멤버를 이용하여 과거 예측을 수행하고 다시 4개 앙상블 멤버를 구성하여 향후 60일에 대한 예측이 매일 수행된다. CMA 모델은 NCEP과 같이 매일 예측이 수행되지만, 선행예측시간은 향후 KMA와 UKMO와 동일하게 60일에 대한 전 지구 예보가 수행된다. CMA 모델도 예측 성능을 파악하기 위해 Hindcast 기간 1994년부터 2014년에 대해 4개의 앙상블 멤버를 이용해서 매일 과거 예측을 수행하고 동일하게 4개 앙상블을 구성하여 향후 60일에 대한 예측을 수행한다.

개별 기후모델의 전체 예측기후 변수는 약 17개로 Table 13와 같다. 이중에서 UKMO는 MSLP(Mean Sea Level Pressure)가 없으며, KMA는 SST(Sea surface temperature), OLR(Top net thermal radiation), Q700(Specific humidity at 700hPa), Q850(Specific humidity at 850hPa)이 없는 상태이다.

Table 12. Information of 6 single climate models.

Center	Nation	Forecast Ens.size	Forecast frequency	Hincast Ens.size	Hindcast length	Hindcast frequency	Time Range
KMA	Seoul	4	daily	3	1991-2010	4/month (1,9,17,25)	0-60
UKMO	Exeter	4	daily	7	1993-2015	4/month (1,9,17,25)	0-60
CMA	Beijing	4	daily	4	1994-2014	daily	0-60
ECMWF	ECMWF	51	2/week (Mon,Thu)	11	Past 20 years	2/week (Mon,Thu)	0-46
NCEP	Washington	16	daily	4	1999-2010	daily	0-44
MSC	Montreal	21	Weekly (Thu)	4	1995-2014	Weekly (Thu)	0-32

Table 13. Information of climatic variables of 6 single climate models.

Center	Climate variables of Sub-seasonal to seasonal																
KMA	TMAX	TMIN	T2M	MSLP	PREC			U50	V850	U850	V200	U200	W500		Z200	Z500	
UKMO	TMAX	TMIN	T2M		PREC	SST	OLR	U50	V850	U850	V200	U200	W500	Q700	Q850	Z200	Z500
CMA	TMAX	TMIN	T2M	MSLP	PREC	SST	OLR	U50	V850	U850	V200	U200	W500	Q700	Q850	Z200	Z500
ECMWF	TMAX	TMIN	T2M	MSLP	PREC	SST	OLR	U50	V850	U850	V200	U200	W500	Q700	Q850	Z200	Z500
NCEP	TMAX	TMIN	T2M	MSLP	PREC	SST	OLR	U50	V850	U850	V200	U200	W500	Q700	Q850	Z200	Z500
MSC	TMAX	TMIN	T2M	MSLP	PREC	SST	OLR	U50	V850	U850	V200	U200	W500	Q700	Q850	Z200	Z500

(2) 개별 기후모델 및 다중모델앙상블 기반 계절내 예측기후 자료의 후처리 및 구성

Table 12과 같이 ECMWF는 매주 월요일과 목요일 두 번씩 향후 46일, MSC는 매주 목요일 주 1회씩 향후 32일, GloSea5와 UKMO는 매월 4회 향후 60일, NCEP과 CMA는 매일 향후 각각 44일과 60일간의 S2S 예측 자료 및 과거 예측 자료를 반복적으로 생산한다.

본 연구에서는 ECMWF와 MSC의 경우 2018년 예측을 위해 생산된 과거 예측 자료 중 목요일마다 초기화 된 Hindcast 기간 동안의 과거 예측 자료를 앙상블 평균하여 사용하였다. 이때 Hindcast 기간은 ECMWF의 경우 1998년부터 2017년까지, MSC의 경우 1998년부터 2014년까지이다. KMA, UKMO, CMA 및 NCEP도 2018년 예측을 위해 생산된 S2S 예측 자료를 사용하였다. 그런데 초기화된 날짜간의 간격, 즉 선행예측 기간이 ECMWF, MSC의 경우는 7일, KMA와 UKMO는 8일, CMA와 NCEP은 1일로 훈련 시간으로는 짧은 기간이다. 따라서 훈련 자료의 연속성과 활용성을 높이기 위해서는 하나의 초기 조건(예, 선행예측 날짜)에서 생산된 자료를 최대한 이용하는 것이 필요하다. 그래서 앞서 Table 12에서 언급 바와 같이 선행예측기간 전체 S2S 예측 자료를 훈련시키면 충분할 것으로 판단했다. KMA, UKMO, CMA의 time range가 60일

이고, ECMWF는 46일, NCEP이 44일, MSC가 32일로 대략 1개월에서 2개월의 S2S 예측 자료를 훈련 시키면 될 것이다. 따라서 선행예측 날짜별로 수집된 자료를 time rang가 반영될 수 있도록 자료의 구조를 변형시켜 처리하였다. 예를 들어, 2018년 ECMWF의 경우, 예측 날짜는 1월 4일부터 12월 27일까지 52개 중에서 6주 간격의 예측 자료(1월 4일, 2월 15일, 3월 29일, 5월 10일, 6월 21일, 8월 2일, 9월 13일, 10월 25일, 12월 6일)에서 각각 42일씩 추출한 후 연속될 수 있도록 처리하였다. 이렇게 구성된 ECMWF S2S의 과거 예측 자료의 기간은 1998년 1월 4일부터 2017년 1월 3일까지이다. 2018년 NCEP의 경우도 42일씩 연속될 수 있게 처리하였으며 2018년 MSC는 time range 32일이 1개월로 월별로 연결되도록 처리하였다. KMA, UKMO 및 CMA의 경우, 예측 날짜는 1월 1일부터 12월 25일까지 48개 중에서 8주 간격의 예측 자료(1월 1일, 3월 1일, 5월 1일, 7월 1일, 9월 1일, 11월 1일)에서 각각 56일씩 추출한 후 연속될 수 있도록 처리하였다. 단, KMA S2S의 Hindcast 기간은 1991년 1월 1일부터 2010년 12월 31일까지이고, UKMO S2S의 Hindcast 기간은 1993년 1월 1일부터 2015년 12월 31일까지이고 CMA S2S의 Hindcast 기간은 1994년 1월 1일부터 2014년 12월 31일까지이다. 대상 영역 격자 지점은 ERA-Interim 자료와 매칭되도록 4개 격자 자료이다. 입력 자료 구축에는 개별 기후모델의 예측기후 변수 모두를 사용하지 않았는데, 6개 개별 기후모델의 예측기후 변수들 중에서 최고 온도(maximum temperature, Tmax), 최저 온도(minimum temperature, Tmin), 평균 온도(2 metre temperature, T2M), 해면기압(Mean Sea Level Pressure, MSLP), 850 hPa 기압면에서의 동서 방향과 남북 방향(U850 and V850), 지위고도 500(Geopotential Height, Z500) 및 강수(Total Precipitation, PREC) 등의 기후 예측 변수를 선택하여 입력 자료를 구축하였다.

다중모델앙상블(multi-model ensemble, 이하 MME) 기반의 S2S 예측기후 자료 생성을 위해서 먼저 3개 type으로 구성하였다. 앞서 Table 12에서 설명한 바와 같이 6개 개별 기후모델의 time range가 60일, 46일, 44일, 32일 등으로 각각 다를 뿐만 아니라 매주 2회 혹은 매주 1회, 혹은 매월 고정된 날짜로 4회 혹은 매일 수행 등 예측빈도가 다르다. 그러나 크게 전체 예측기후 관과 예측빈도로 그룹을 구분할 수 있다. 예를 들면, KMA와 UKMO 및 CMA의 예측기간은 60일로 동일하며, CMA는 Hindcast 예측이 매일 수행되고 KMA와 UKMO는 매월 4회 같은 고정된 날짜에 예측이 수행되어 같은 그룹으로 구분할 수 있다. 그래서 이들 개별 기후모형을 결합하여 MME-1이라 명명하였다(Table 3). 반면, ECMWF와 MSC 및 NCEP은 전체 예측기간이 약 31-40일 범위에 있고, 특히 ECMWF와 MSC는 매주 목요일에 예보가 수행된다. 그래서 이 그룹을 MME-2로 명명하였다 (Table 14). 예측기간과 예측빈도가 다름에도 불구하고 모두 결합한 것은 MME로 명명하였다. 다만, 결합할 때 MSC의 예측기간이 32일이지만 훈련 자료의 수를 고려하여 뒤 8일 정도가 모자라더라도 MME의 예측기간을 약 40일 기간으로 설정하였다. 최고기온, 최저기온, 평균기온, 강수, 해면기압, 지위고도가 MME 기반의 S2S 예측기후 변수로써 MME 기반 S2S 예측 최고기온과 최저기온, 강수를 예측하는데 입력되었다.

훈련 기간과 테스트 기간은 개별 기후모델의 Hindcast 기간에 따라 연도는 각각 달라지는데 Hindcast 기간 전체에 대해 75%는 훈련 기간, 25%는 테스트 기간으로 계산된다. MME의 경우 개별 기후모델 전체의 Hindcast 기간을 포함하도록 설정되어야 하지만, 그렇게 되면 1999년부터 2010년으로 기간이 짧아진다. 그래서 앞뒤 년도가 완벽하게 포함되지 않더라도 Hindcast 기간을 최대 20년에 맞추기 위해 1995년부터 2014년으로 설정되었다. 그래서 1995년부터 2009년까지 15년은 훈련 기간으로, 2010년부터 2014년까지 5년은 테스트 기간이 된다. MME 기반의

S2S 입력 자료 구조에서 앞 해에서는 1995년부터 1998년까지 앞 해의 약 4년에 대한 부분이 포함되지 않는 개별 기후모델은 ECMWF와 MSC, NCEP이고, 2011년부터 2014년까지 뒤 해의 약 4년에 대한 부분이 포함되지 않는 개별 기후모델은 KMA와 NCEP이 된다. 예측 성능 평가를 위해 교차 검증(k-fold cross validation)을 수행하였는데, 본 연구에서 사용한 것은 3-fold cross validation이다 (Figure 62).

Table 14. Classification of individual climate models for MME, MME-1, and MME-2.

Center	Nation	Hincast Ens.size	Hindcast length	Hindcast frequency	Time Rang e	Ensemble
KMA	Seoul	3	1991-2010	4/month (1,9,17,25)	0-60	MME1 (TR60)
UKMO	Exeter	7	1993-2015	4/month (1,9,17,25)	0-60	
CMA	Beijing	4	1994-2014	daily	0-60	MMEn (TR60+TR40)
ECMWF	ECMWF	11	Past 20 years	2/week (Mon,Thu)	0-46	
NCEP	Washington	4	1999-2010	daily	0-44	
MSC	Montreal	4	1995-2014	Weekly (Thu)	0-32	MME2 (TR40)




Figure 62. Explanation of k-fold cross validation in the research.

(3) 최적화된 장단기억기술

본 연구에서 입력된 시계열 기후자료를 자동으로 학습시키고 다변량 데이터를 지원하며 다 단계 예측에 사용할 수 있는 가변 길이를 출력할 수 있는 장단기억기술(Long Short-Term Memory, 이하 LSTM)로 2019년 연구에 활용한 LSTM을 채택하였다. 또한, TensorFlow와 Theano backend, Keras (2.2 이상)를 설치하였고, scikit-learn, Pandas, NumPy 및 Matplotlib이 설치된 Python SciPy 환경에서 수행하였다. LSTM은 딥러닝 훈련 기법 순환 신경망(Recurrent Neural Networks, 이하 RNN)의 일종이다. Figure 63의 A는 single tanh layer(이하, 단일 탄젠트 에이치 레이어)를 가지고 반복되는 표준 RNN 모듈을 설명한 것이다. 연속이 되어 있다는 의미에서는 체인 구조라고 표현하기도 하는데, RNN는 깊이가 깊어질수록 처음 시간대에 대한 반영이 0에 수렴한다는 Long-term dependency 단점이 있다. 즉, RNN은 관련 정보와 그 정보를 사용하는 지점 사이 거리가 멀 경우, 학습 능력이 크게 저하된다(vanishing gradient problem). 이 문제를 극복하기 위해 고안된 것이 LSTM이며, LSTM에는 상호 작용하는 4개의 layer(이하, 레이어)가 존재한다 (Figure 63의 B). LSTM에서 핵심적인 부분은 RNN의 hidden layer(이하 은닉층)에 cell-state(이하 셀 스테이트)를 추가한 구조이다. 이 셀 스테이트는 하나의 컨베이어 벨트처럼 전체 체인을 통과하는데, 이 구조를 통해서 정보는 큰 변함 없이 계속 다음 단계에 전달이 될 수 있다. 또한 LSTM은 이 셀 스테이트에 신중하게 정제된 구조를 가진 gate(이하 게이트)라는 요소를 활용해서 정보를 더하거나 제거하는 기능을 수행한다. 게이트들은 선택적으로 정보들이 흘러 들어갈 수 있도록 만드는 장치를 의미한다. 게이트들은 sigmoid neural net layer(이하 시그모이드 신경망 레이어)와 점 단위 곱하기 연산으로 구성되어 있다.

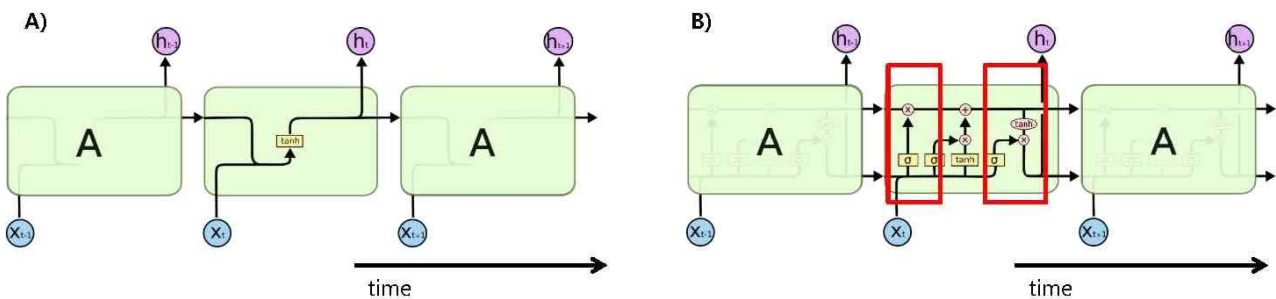


Figure 63. The repeating module in a standard RNN contains a single layer(A) and a LSTM contains four interacting layers(B) (Source: modified the 2019 research report and <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>).

Sigmoid layer(이하 시그모이드 레이어)는 0 혹은 1의 값을 출력한다. 각 구성 요소가 영향을 주게 될지를 결정해 주는 역할을 한다. 0이라는 값을 가지게 되면 해당 구성 요소가 미래의 결과에 아무런 영향을 주지 않게 된다. 1이라는 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 낸

다. 어떤 값을 출력할지 결정하는 시그모이드 레이어와 셀 스테이드의 값이 tanh 함수를 거쳐서 -1과 1 사이의 값으로 출력되면, 시그모이드 레이어에서 얻은 값과 tanh 함수를 거쳐 얻은 값을 곱해서 출력하는 과정이 표준적인 LSTM 방식이 2019년에 사용한 LSTM에 대한 설명이다. 이 LSTM에서 overfitting(이하 과적합)과 속도 개선을 위한 최적화가 필요하였다.

(가) 최적화

기존 LSTM의 경우 활성화 함수와 은닉층(hidden layer) 노드 개수를 산정했는데, 먼저 단일 층을 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. 이 은닉층의 노드가 200개 이며 활성화 함수가 ReLU일 때 가장 우수한 학습 결과를 보여주었다. 또한 기존 LSTM에서 채택한 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 매트릭스의 경우 평방근제곱근오차(Root Mean Square Error, 이하 RMSE)가 더 일반적이어서 채택하였지만 평균절대오차(Mean Absolute Error, 이하 MAE)도 채택하였다. 그래서 예측 모델 LSTM의 성능 지표로는 7일과 8일 동안의 각각 리드 타임에 대한 RMSE와 MAE으로 구성된다. 최적화 알고리즘은 기존 LSTM에서 Feature Engineering에 의해 최적화 과정이 수행되었는데, Feature Engineering은 feature selection, classification, extraction, transformation 등을 통해 입력된 자료를 모델링에 적합하게 변환하여 과적합 위험을 줄이고 학습 속도를 개선하여 딥러닝 알고리즘(예, 209년에 활용한 LSTM)의 성능을 향상시키는 과정으로 본 연구에서는 신경망층(layer depth) 수정, dropout 및 상태유지 하이퍼파라미터 등을 조절하여 LSTM 알고리즘을 최적화하였다 (Figure 64).

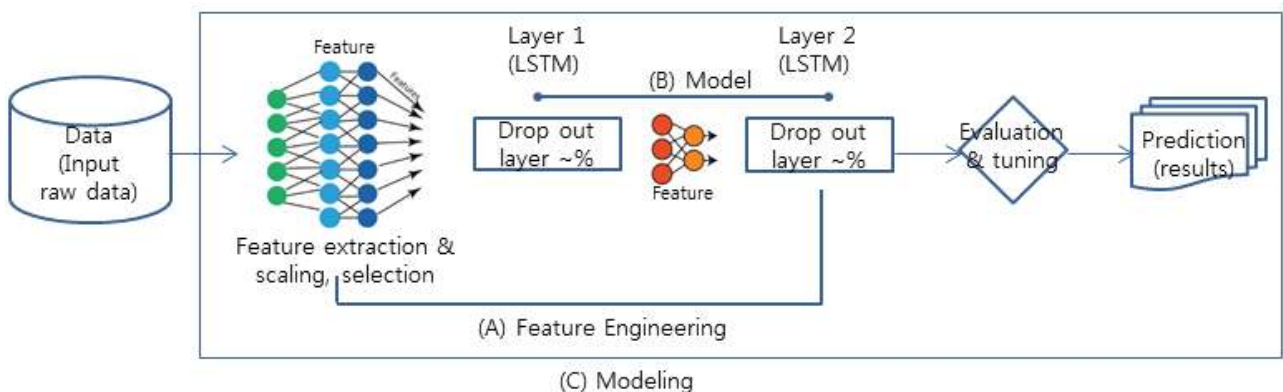


Figure 64. Description of feature engineering used in the research: (A) describes as a feature engineering process within the LSTM, (B) describes as the LSTM, (C) describes the entire modeling process.

(나) 훈련 및 검증

학습 및 검증을 위해서는 ECMWF의 S2S 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 테스트에 활용하였다. MSC는 1995년 1월 4일부터 2014년 1월 3일까지 총 17년 동안의 일별(daily) 자료 중 75%(1998년 1월 4일~2011년 1월 3일)를 학습에, 25%(2011년 1월 4일~2014년 1월 3일)를 테스트에 활용하였다. 또한, NCEP은 1999년 1월 1일부터 2010년 12월 31일까지 총 12년 동안의 일별(daily) 자료 중 75%(1999년 1월 1일~2007년 12월 31일)를 학습에, 25%(2008년 1월 1일~2010년 12월 31일)를 테스트에 활용하였다. KMA의 S2S 입력 자료의 경우 1991년 1월 1일부터 2010년 12월 31일까지 총 20년 동안의 자료 중 마찬가지로 75%(1991년 1월 1일~2005년 12월 31일)를 학습에, 25%(2006년 1월 1일~2010년 12월 31일)를 테스트에 이용하였다. UKMO는 1993년 1월 1일부터 2015년 12월 31일까지 총 23년 동안의 자료 중 75%(1993년 1월 1일~2009년 12월 31일)를 학습에, 25%(2010년 1월 1일~2015년 12월 31일)를 검증에 이용하였다. CMA는 1994년 1월 1일부터 2014년 12월 31일까지 총 21년 동안의 자료 중 75%(1994년 1월 1일~2009년 12월 31일)를 학습에, 25%(2010년 1월 1일~2014년 12월 31일)를 테스트에 이용하였다.

MME 기반의 S2S의 입력 자료의 경우 KMA, UKMO, CMA를 제외하고 ECMWF, MSC 및 NCEP의 앞 해가 포함되지 않지만, 1995년 1월 1일부터 2014년 12월 31일까지 총 20년 동안의 자료 중 75%(1995년 1월 1일~2009년 12월 31일)를 학습에, 25%(2010년 1월 1일~2014년 12월 31일)를 테스트에 이용하였다. 또한, 학습 모델 구축을 위해 훈련 자료로 사용된 ERA-Interim 자료의 기간도 각각의 개별 기후모델과 MME 기반의 Hindcast 기간을 포함할 수 있도록 각각 설정되었다. 훈련 기법에 따른 선행예측기간 전체 예측 기후 변수의 일별, 선행주수별 및 계절별 예측성 평가는 평방근제곱근오차(Root Mean Square Error, 이하 RMSE)와 편차상관계수(temporal anomaly correlation coefficient, 이하 TCC)를 계산하여 사용된 딥러닝 알고리즘 훈련 기법인 LSTM과 알고리즘 최적화에 대한 예측 변동성과 상관성 및 개선 정도 등을 평가하였다. 개선도(improvement)는 LSTM이 적용되지 않은 MME 기반 S2S의 예측 성능 대비 LSTM 혹은 최적화된 LSTM이 적용된 MME 기반 S2S 예측 성능의 변화량을 계산하여 평가하였다.

$$TCC_i = \frac{\sum_{j=1}^N (x_{i,j} - \bar{x}_i) \times (y_j - \bar{y})}{\sqrt{\sum_{j=1}^N (x_{i,j} - \bar{x}_i)^2} \times \sqrt{\sum_{j=1}^N (y_j - \bar{y})^2}}$$

여기서 x_i 는 학습 전 혹은 학습 후 각각의 개별 기후모델(KMA, UKMO, CMA, ECMWF, MSC, NCEP) 및 MME 기반의 S2S 예측기후 자료의 예측 날짜 i 일째의 값이고, \bar{x}_i 는 훈련 기간 동안 개별 기후모델 혹은 MME 기반 계절내 예측기후 자료의 평균, 즉 모델의 기후 평균값을 나타낸다. y_i 는 i 일째에서의 관측 자료, \bar{y}_i 는 훈련 기간 동안 관측 자료의 평균, 즉 기후값을 나타낸다. j 는 예측 선행 시간, N 은 예측 개수를 각각 나타낸다.

$$= \sqrt{\frac{\sum_{i=1}^n (x_{1,i} - x_{2,i})^2}{n}}$$

여기서 $x_{1,i}$ 는 i 일짜의 학습되지 않은 각각의 개별 기후모델과 MME 기반의 S2S 예측기후 자료이며, $x_{2,i}$ 는 i 일짜에서 LSTM에 의해 학습된 각각의 개별 기후모델과 MME 기반 S2S의 예측기후 자료이다. N 은 예측 개수를 각각 나타낸다.

$$\text{Improvement (\%)} = (\text{Evaluation index of training data} / \text{Evaluation index of original data}) \times 100$$

여기서 original data는 검증에 해당된 25% 기간 동안 학습되지 않은 개별 기후모델 혹은 MME 기반 S2S 예측기후 자료를 의미하며, trained data는 동일 기간에 대해 LSTM 모델에 의해 학습되어 후보정된 값을 나타낸다.

다. 딥러닝 적용에 따른 계절내 예측기후 자료의 후보정 결과

(1) 개별 기후모델의 LSTM 적용에 따른 예측 성능 평가

(가) 선행예측시간 전체의 일별 예측성

개별 기후모델 6개 계절내(sub-seasonal to seasonal, 이하 S2S) 예측기후 자료에 LSTM 적용에 따른 선행예측 전체 기간에 대한 결과이다 (Figure 65 to Figure 67). 먼저, LSTM 적용에 따른 개선 효과의 스프레드를 분석한 후 상자수염도를 작성했다. 그림에서 회색은 LSTM 적용 전 개별 기후모델의 계절내 예측기후의 계산된 편차상관계수(Temporal Correlation Coefficient, 이하 TCC)와 평방근제곱근오차(Root Mean Square Error, 이하 RMSE)를 나타낸다. 각각의 색상(초록색, 밝은 초록색 및 밝은 파란색)은 LSTM이 적용된 계절내 예측기후의 TCC 및 RMSE를 나타낸다. 전반적으로, KMA, UKMO, CMA의 선행예측 전체 기간은 60일인데, 선행예측 전체 기간에 대해 최고기온 및 최저기온에서 CMA와 KMA LSTM의 TCC 향상과 RMSE 감소는 두드러졌다 (Figure 65 and 66). UKMO LSTM 적용에서 최고기온의 TCC는 개선되고 RMSE는 감소되는 것으로 나타났지만, 최저기온의 경우 LSTM에 의한 TCC 개선 및 RMSE 감소 효과는 다소 낮은 것으로 나타났다. 강수의 경우, 3개 기후모델 모두에서 LSTM 적용에 따른 TCC 향상이 두드러졌다. RMSE 또한 감소되었지만 평균적으로는 감소되지 않는 것으로 나타났다 (Figure 67). ECMWF, MSC, NCEP의 선행예측 전체 기간은 각각 46일, 33일, 44일인데, 선행예측 전체 기간에 대해 최고기온에서 3개 기후모델의 TCC 향상과 RMSE 감소는 두드러졌다 (Figure 65). 최저기온에서 ECMWF와 NCEP의 TCC 향상과 RMSE 감소로 LSTM 적용 효과가 나타났지만, MSC의 경우 LSTM 적용에 의한 TCC 향상이 다소 미흡한 것으로 나타났다 (Figure 66). 강수의 경우, 3개 기후모델에서 LSTM 적용에 따른 TCC 향상이 나타났다. RMSE 또한 감소되었는데, ECMWF와 MSC의 RMSE 중앙값으로는 뚜렷한 감소를 보이지 않았다 (Figure 67).




Figure 65. Comparison of temporal correlation coefficient and root mean square error of S2S(gray box) and LSTM (green box) of daily maximum temperature of six single climate models during overall hindcast period.




Figure 66. Comparison of temporal correlation coefficient and root mean square error of S2S(gray box) and LSTM (green box) of daily minimum temperature of six single climate models during overall hindcast period.

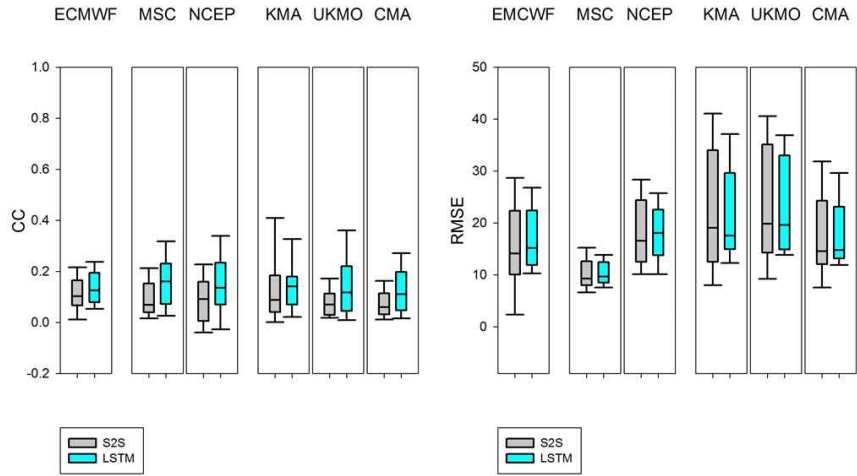


Figure 67. Comparison of temporal correlation coefficient and root mean square error of S2S(gray box) and LSTM (light blue box) of daily total precipitation of six single climate models during overall hindcast period.

(나) 선행예측시간 3-4주의 예측성

개별 기후모델 6개에 LSTM 적용에 따른 선행예측시간 주별 평가의 결과는 Figure 68에서 Figure 70까지이다. 먼저, LSTM 적용에 따른 6개 개별 기후모델 각각의 주별 개선 효과의 스프레드를 분석하여 전체 주별 상자수염도를 작성했다. 역시 회색은 LSTM 적용 전의 TCC 혹은 RMSE를 나타내며, 각각의 색상은 LSTM 적용 후의 TCC 및 RMSE이다. 또한 심볼 ×와 점선은 LSTM 적용 전 6개 개별 기후모델의 평균 TCC 혹은 평균 RMSE를 나타내고, 채워진 심볼 ▲과 실선은 LSTM 적용 후 6개 개별 기후모델의 평균 TCC 혹은 평균 RMSE를 나타낸다. 전반적으로, 3개 목표 기후변수 모두에서 1주에서 6주까지 LSTM 적용에 따른 TCC(향상) 및 RMSE(감소)의 개선이 뚜렷했다.

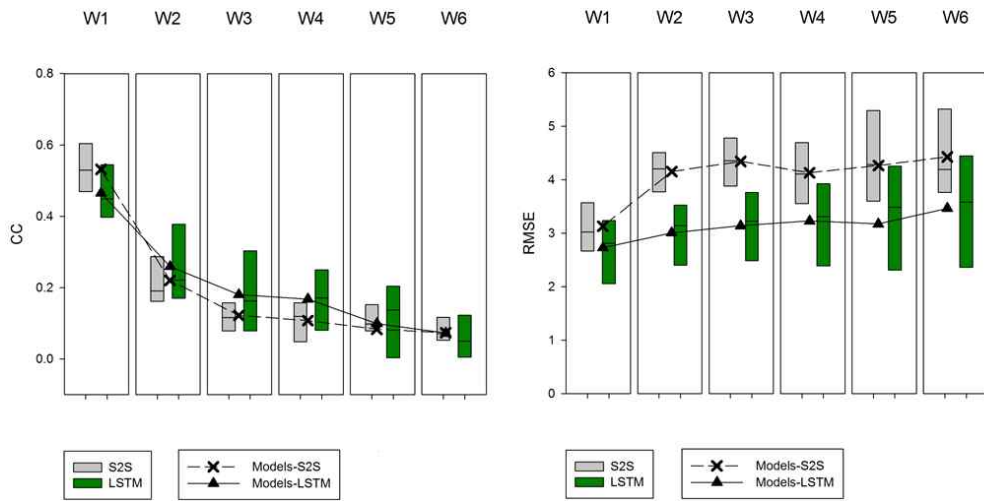


Figure 68. Comparison of weekly performance of temporal correlation coefficient and root mean square of S2S(gray box) and LSTM (green box) of daily maximum temperature of six single climate models.

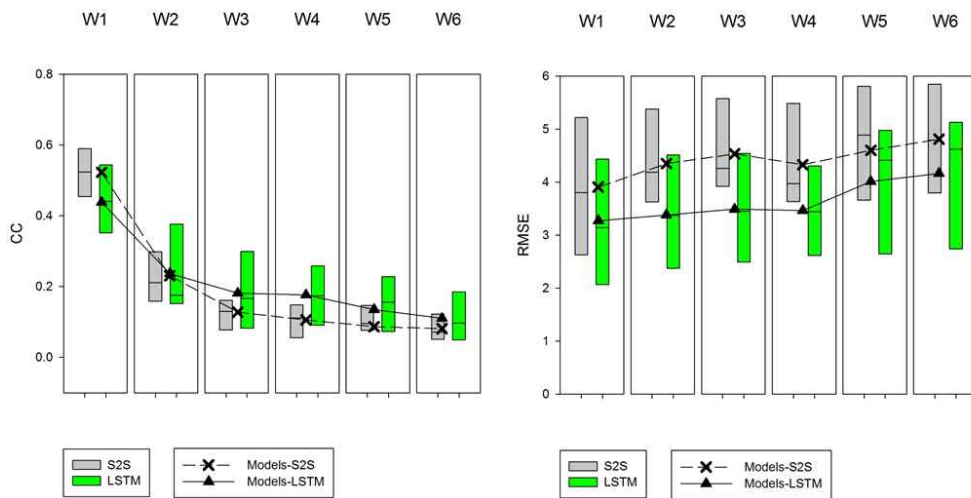


Figure 69. Comparison of weekly performance of temporal correlation coefficient and root mean square of S2S(gray box) and LSTM (green box) of daily minimum temperature of six single climate models.

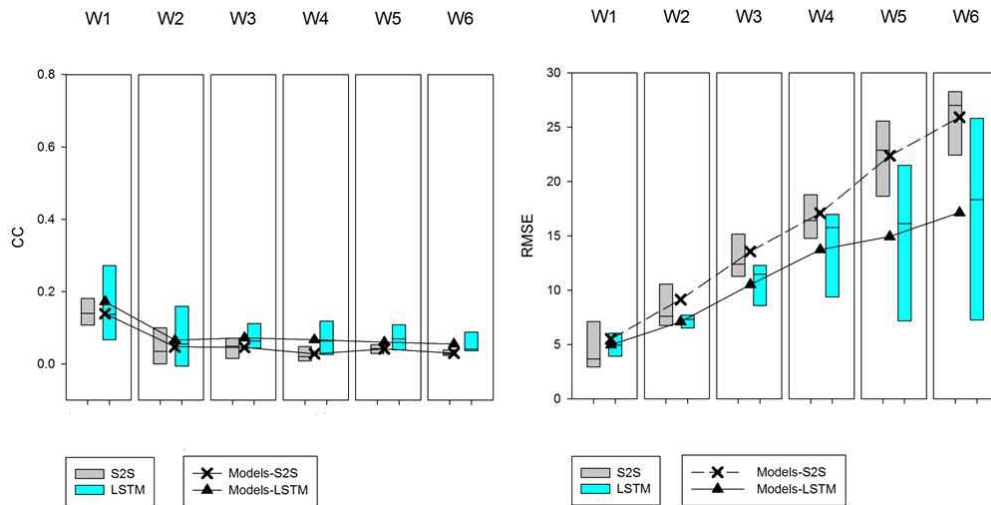


Figure 70. The comparison of weekly performance of temporal correlation coefficient and root mean square of S2S(gray box) and LSTM (light blue box) of daily total precipitation of single climate models.

본 연구의 목표 주는 3-4주인데, 아래부터는 LSTM 및 최적화된 LSTM 적용이 S2S 예측기후의 3-4주 개선에 얼마나 기여했는가를 분석하기 위해 TCC의 밀도 분포를 분석하였다. Figure 71에서 Figure 73까지 6개 개별 기후모델의 S2S 3개 기후변수(최고기온 및 최저기온, 강수)의 3-4주에서 LSTM 및 최적화된 LSTM 적용에 따른 TCC의 밀도 분포이다. 회색 점선은 LSTM 적용 전의 3-4주 S2S 최고기온 및 최저기온, 강수 각각의 TCC 분포이며, 분홍색과 파란색은 각각 LSTM과 최적화된 LSTM 적용 후의 3-4주 S2S 예측 최고기온 및 최저기온, 강수 각각의 TCC 밀도 분포이다. 본 연구에서 활용한 6개 개별 기후모델 대부분에서 LSTM 적용 후 낮은 TCC의 분포는 감소하고 높은 TCC의 분포는 증가하는 것으로 나타났다. 그러나 최적화 LSTM에 의해 높았던 TCC 분포가 더 증가하여 3-4주의 S2S 예측기후 자료가 LSTM 적용보다 더 개선되지는 않았다. 즉 최적화가 모두 적용되지는 않는 것으로 나타났다.

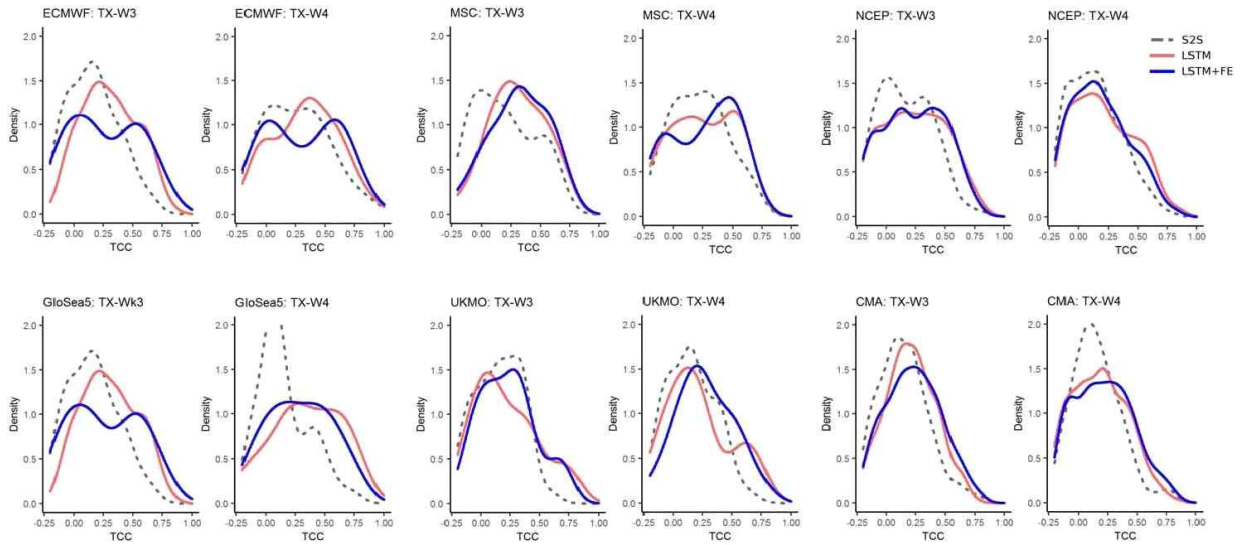


Figure 71. Comparison of the temporal correlation coefficient density distribution at the daily maximum temperature for 3 and 4 week of lead-time of six single climate models.

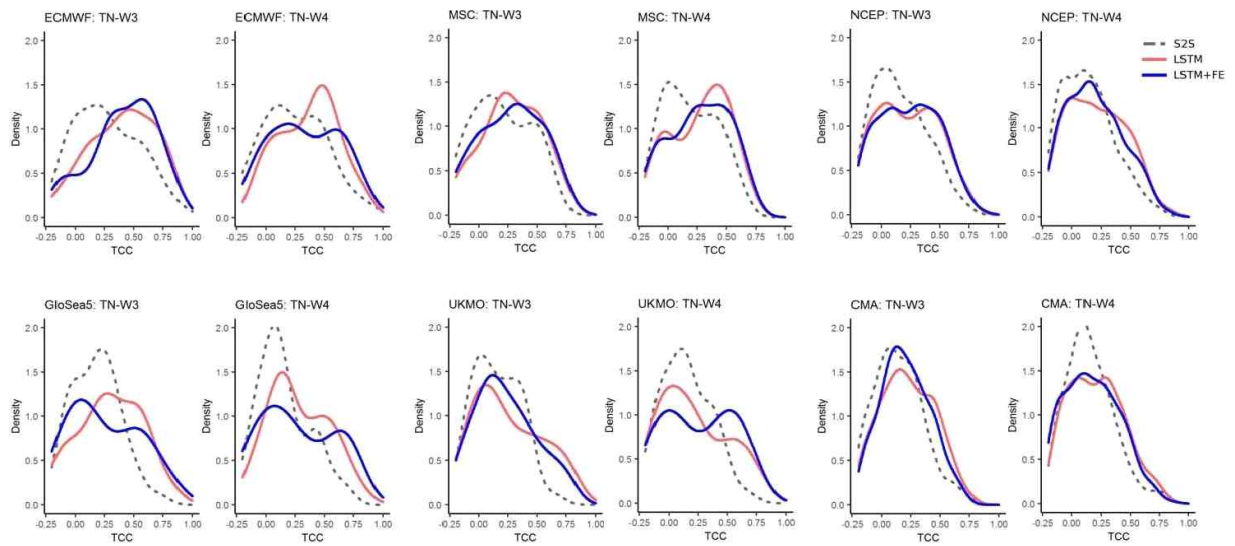


Figure 72. Comparison of the temporal correlation coefficient density distribution at the daily minimum temperature for 3 and 4 week of lead-time of six single climate models.

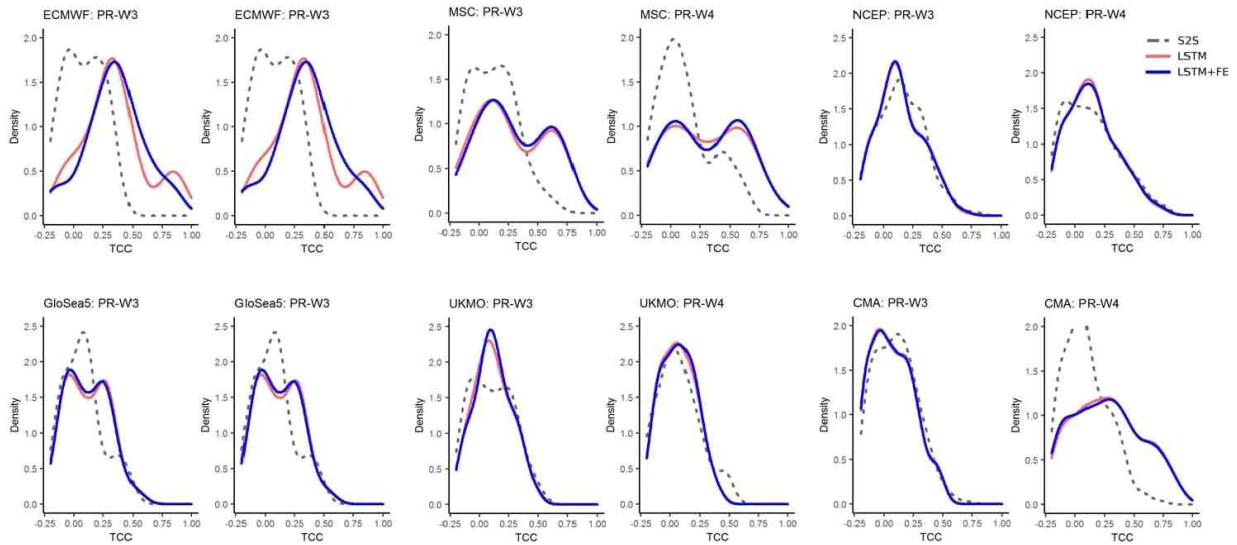


Figure 73. Comparison of the temporal correlation coefficient density distribution at the daily total precipitation for 3 and 4 week of lead-time of six single climate models.

다음은 3-4주에서 6개 개별 기후모델에 LSTM 적용 후의 TCC의 계절적 분포를 분석한 후 산포도를 작성하였다 (Figure 74to Figure 76). 그림에서 겨울(DJF)는 파랑색, 봄(MAM)은 초록색, 여름(JJA)은 빨강색, 가을(SON)은 보라색으로 표현하였으며, 채워진 O 심볼은 ECMWF 모델 예측, 채워진 ◇ 심볼은 MSC 모델, 채워진 △ 심볼은 NCEP 모델, X 심볼은 GloSea5, + 심볼은 UKMO 모델, * 심볼은 CMA를 나타낸다. 대부분의 월에서, 6개 개별 기후모델의 3-4주 S2S 예측기후에 LSTM을 적용한 TCC가 기준선(이하 reference line)의 우상단으로 분포가 증가함으로써 S2S 예측기후의 오차가 개선되는 것으로 나타났다. 특히 여름철에서 LSTM 적용 효과가 나타났는데, 딥러닝 기술이 여름철 3-4주 S2S 예측기후의 오차 개선에 기여할 수 있을 것으로 판단된다.




Figure 74. Comparison of the monthly temporal correlation coefficient scatter plot at the daily maximum temperature for 3 and 4 week of lead-time of six single climate models.




Figure 75. Comparison of the monthly temporal correlation coefficient scatter plot at the daily minimum temperature for 3 and 4 week of lead-time of six single climate models.




Figure 76. Comparison of the monthly temporal correlation coefficient scatter plot at the daily total precipitation for 3 and 4 week of lead-time of six single climate models.

Figure 77에서 Figure 79까지는 6개 개별 기후모델에 최적화된 LSTM을 적용한 결과이다. 그림에서 6개 개별 기후모델의 3개 예측기후 변수(강수, 최고 및 최저기온)의 예측선행 3-4주에서 원시 예측기후의 TCC는 회색, LSTM을 적용한 예측기후의 TCC는 빨강색, 최적화된 LSTM을 적용한 예측기후의 TCC는 파랑색으로 표현하였다. 각각의 영어 알파벳 대문자는 개별 기후모델명의 첫 글자를 나타낸다. 최적화된 LSTM의 예측성은 전체적으로 원형 LSTM보다 소폭 향상되었다. 최고기온의 경우, GloSea5와 ECMWF에서 최적화 개선폭이 높게 나타났다. 3주에서, 원형 LSTM 예측성과 같아 최적화에 따른 개선폭이 보이지 않았던 UKMO나 CMA(베이징)은 4주에서 개선폭이 나타나는데, 이 기후모델에서는 최적화에 의해 3주 예측성이 4주까지 지속되는 것으로 추측된다 (Figure 74). UKMO는 최고기온에서 최적화에 따른 개선 효과가 미미했던 반면, 최저기온에서는 개선 효과가 두드러질 뿐만 아니라 LSTM에 따른 예측 개선이 미미했던 4주에서도 개선 효과가 뚜렷하게 나타났다 (Figure 78). GloSea5는 최저기온에서 개선 효과가 미미한데, NCEP에서는 기온 변수 모두에서 최적화에 따른 개선 효과가 미미한 것으로 나타났다. 강수에서는, UKMO를 제외하고 최적화에 따른 개선 효과 나타났다. 특히, ECMWF는 최적화에 의해 LSTM 후보정에 의한 강수 오차가 뚜렷하게 감소하였다 (Figure 79). CMA와 MSC S2S의 3-4주에서는 예측성이 낮는데 LSTM 적용 후 예측성 개선뿐만 아니라 최적화에 의해 예측성이 더 개선되는 것으로 나타났다.




Figure 77. Comparison of the average of temporal correlation coefficient of the daily maximum temperature of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of six single climate models.




Figure 78. Comparison of the average of temporal correlation coefficient of the daily minimum temperature of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of six single climate models.




Figure 79. Comparison of the average of temporal correlation coefficient of the daily total precipitation of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of six single climate models.

(2) MME 기반 계절내 예측기후의 LSTM 적용에 따른 예측 성능 평가

(가) MME 기반 계절내 예측기후의 선행예측시간 전체의 일별 예측성

본 연구에서 구축된 MME 기반의 S2S 예측기후에 LSTM 적용에 따른 선행예측 전체 기간에 대한 결과는 Figure 80에서 Figure 82이다. 먼저, Table 14에서 설명된 바와 같이 선행예측 기간이 60일인 개별 기후모델과 대략 40일인 개별 기후모델을 결합하여 생성된 MME-1 기반 S2S 예측기후와 MME-2 기반 S2S 예측기후에 LSTM을 적용한 후, 그 개선 효과의 스프레드와 계절 분포를 분석하였다. 상자수염도에서 회색이 LSTM 적용전의 MME-1과 MME-2 기반 S2S 예측기후인데, 3개 예측 기후변수 모두에서, MME-1과 MME-2 기반의 S2S 예측기후 자료는 예측성이 가장 우수하다고 평가 받고 있는 ECMWF의 LSTM 보정 전보다 예측력이 낮게 나타났다. 그러나 LSTM을 적용하면(상자수염도에서 각각의 색상) 그 예측성이 월등히 개선되는 것으로 나타났다. 그런데 그 개선 정도는 MME-1이 MME-2보다 더 좋은 것으로 나타났다. 그림에서 오른쪽에 있는 B는 TCC의 계절 분포를 분석하여 산포도를 작성하였다. 그림에서 × 심볼은 MME-1, 빈 □는 MME-2, 채워진 O 심볼은 ECMWF 모델의 월별 평균 TCC를 나타낸다. LSTM이 적용된 MME-1과 MME-2 기반의 S2S 3개 예측기후의 TCC 계절 분포를 살펴보면, ECMWF와 같이 대부분의 TCC가 reference line의 우상단에 분포하는 것으로 나타나서, 대부분의 월에서 LSTM 후보정에 따른 TCC가 향상된 것을 확인할 수 있었다.

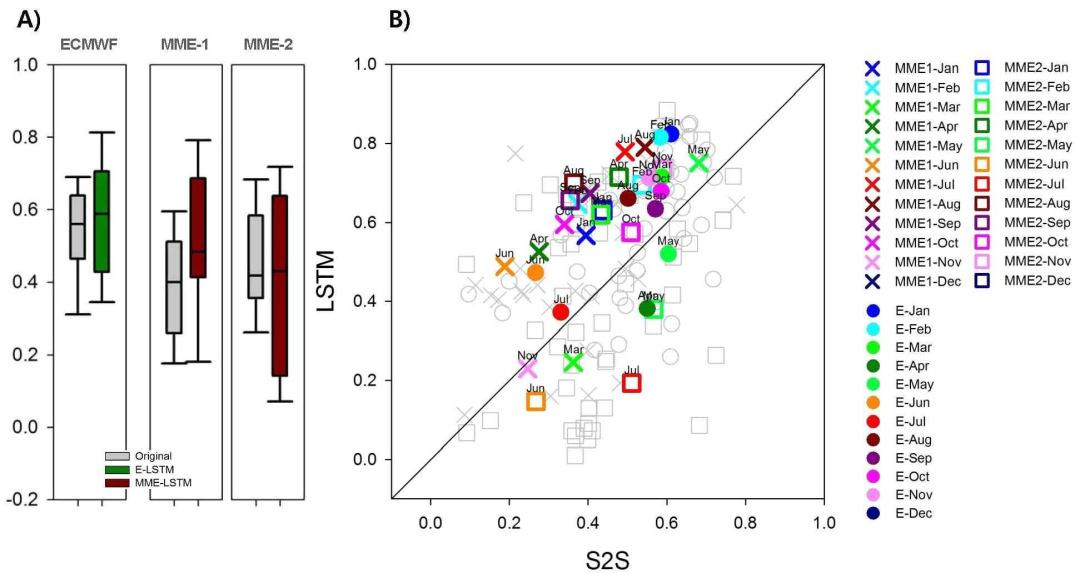


Figure 80. Comparison of the temporal correlation coefficient of overall hindcast period at the box plot(A) and the monthly temporal correlation coefficient at the scatter plot(B) for the daily maximum temperature of ECMWF, MME-1 and MME-2.

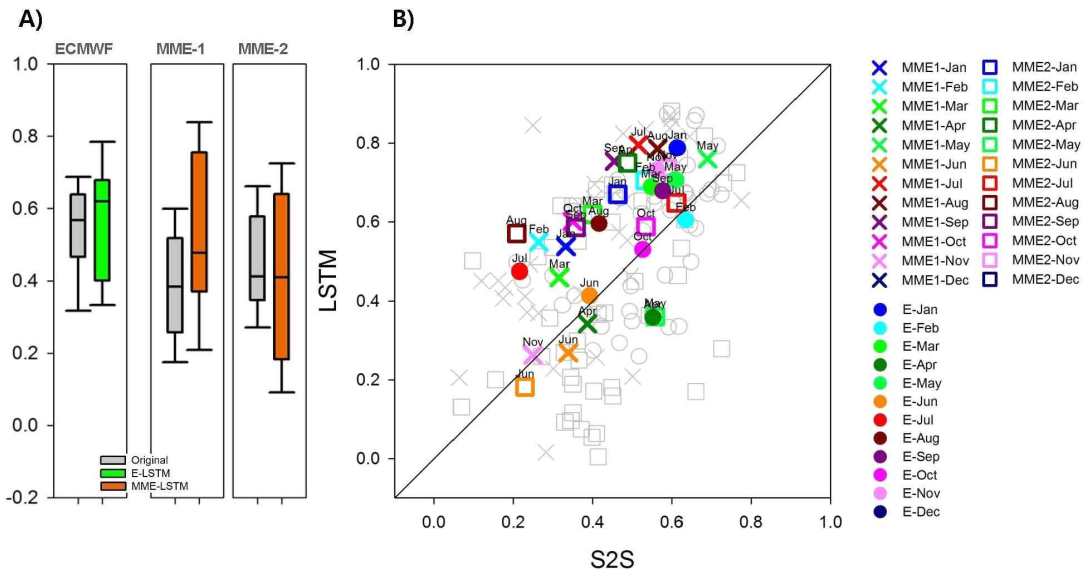


Figure 81. Comparison of the temporal correlation coefficient of overall hindcast period at the box plot(A) and the monthly temporal correlation coefficient at the scatter plot(B) for the daily minimum temperature of ECMWF, MME-1 and MME-2.

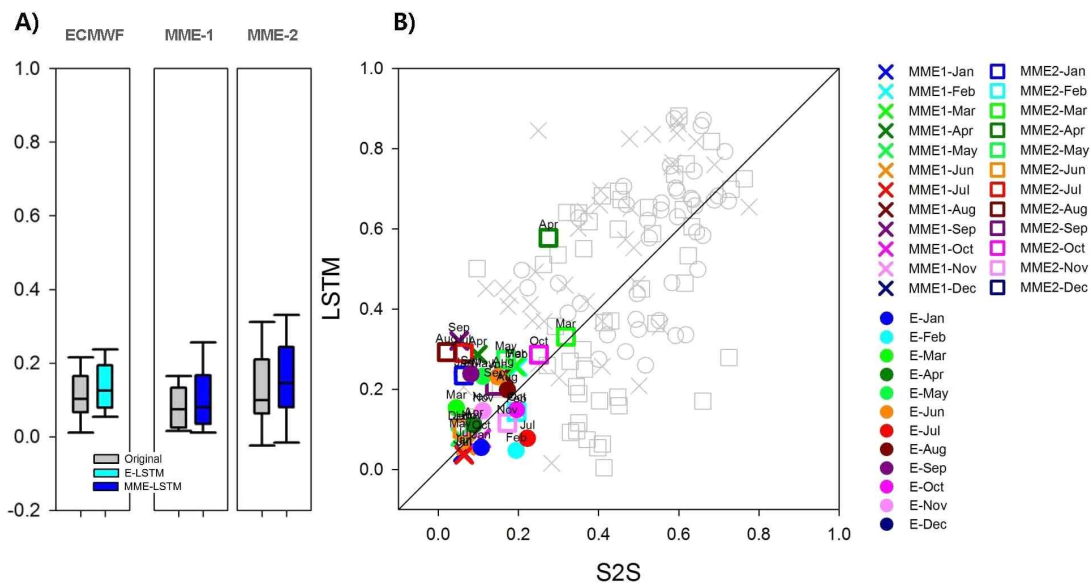


Figure 82. Comparison of the temporal correlation coefficient of overall hindcast period at the box plot(A) and the monthly temporal correlation coefficient at the scatter plot(B) for the daily total precipitation of ECMWF, MME-1 and MME-2.

(나) MME 기반 계절내 예측기후의 선행예측시간 3-4주의 예측성

LSTM 적용에 따른 MME-1과 MME-2 기반의 S2S 예측기후에서 3개 예측 기후 변수의 선행 예측시간 주별 예측성 변화를 평가하였다 (Figure 83 to Figure 85). 먼저, Figure 22와 Figure 23은 최고기온과 최저기온으로, Figure 83와 Figure 84의 A에서, MME-1과 MME-2 기반의 S2S 예측 최고기온 및 최저기온의 3-4주 LSTM의 TCC(상자수염도에서 각각의 색상)는 보정 전(상자수염도의 회색)보다 월등히 높은 스프레드 분포를 보였다. Figure 83와 Figure 84의 B와 C에서는 그 높은 TCC 분포가 계절별로 고르게 분포하는 것으로 나타나서, LSTM 적용에 따른 오차 개선이 대부분의 계절에서 나타났음을 확인하였다. MME-1과 MME-2 기반의 S2S 예측 강수의 3-4주 LSTM의 TCC는 보정 전보다 개선된 경향을 보였지만 기온과 같이 월등하지 않았다 (Figure 85의 A). 그러나 기온과 같이 LSTM의 TCC가 대부분의 계절에서 LSTM 적용 전의 TCC보다 reference line의 위에 분포함으로써 MME-1과 MME-2의 3-4주 강수에서도 LSTM 적용에 의해 오차를 개선할 수 있음을 확인하였다 (Figure 85의 B와 C).

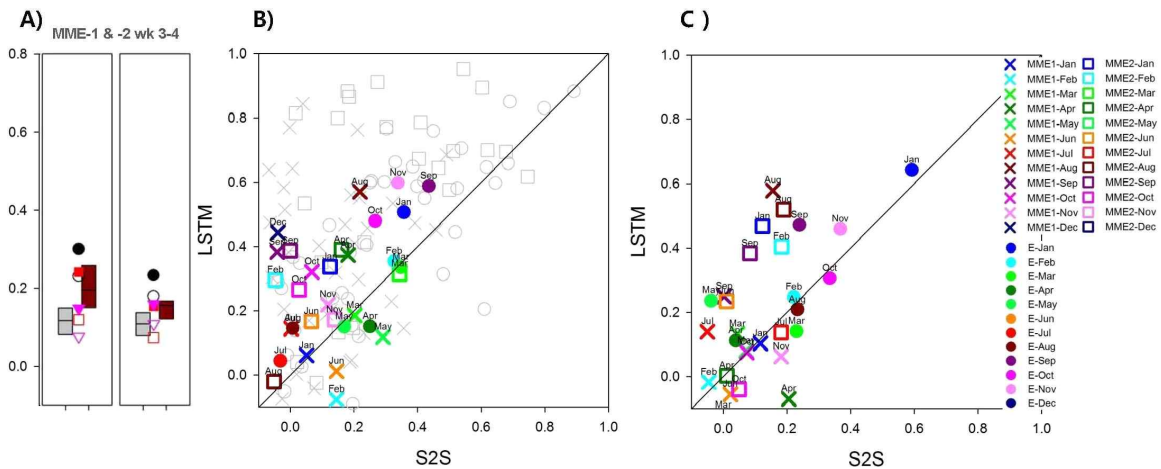


Figure 83. Comparison of the temporal correlation coefficient of the 3 and 4 week of lead-time at the box plot(A) and the monthly temporal correlation coefficient of the 3 and 4 week of lead-time at the scatter plot(B and C) for the daily maximum temperature of ECMWF, MME-1 and MME-2.

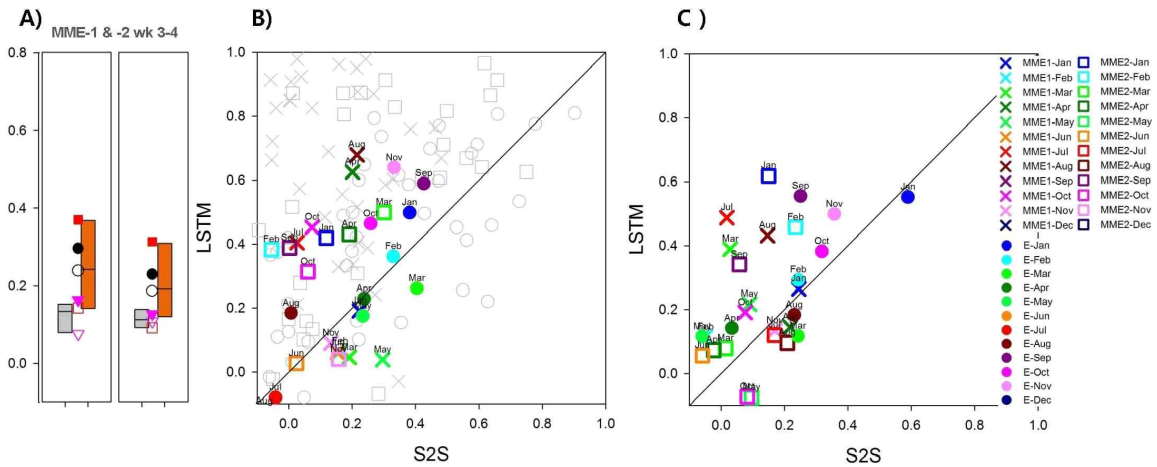


Figure 84. Comparison of the temporal correlation coefficient of the 3 and 4 week of lead-time at the box plot(A) and the monthly temporal correlation coefficient of the 3 and 4 week of lead-time at the scatter plot(B and C) for the daily minimum temperature of ECMWF, MME-1 and MME-2.

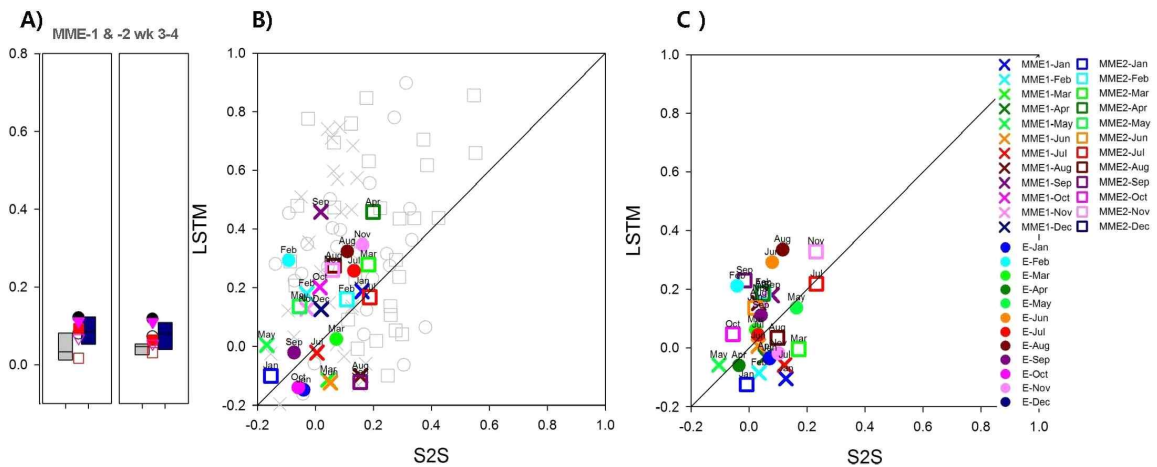


Figure 85. Comparison of the temporal correlation coefficient of the 3 and 4 week of lead-time at the box plot(A) and the monthly temporal correlation coefficient of the 3 and 4 week of lead-time at the scatter plot(B and C) for the daily total precipitation of ECMWF, MME-1 and MME-2.

다음은 전체 MME 기반의 3-4주 S2S 예측기후 자료에 LSTM 적용에 따른 예측성 변화를 평가하였다. 먼저, LSTM 및 최적화된 LSTM 적용이 MME 기반 S2S 예측기후의 3-4주 개선에 얼마나 기여했는가를 분석하기 위해, MME 기반의 S2S 예측 최고기온 및 최저기온과 강수의 TCC 밀도 분포와 통계적 유의성을 분석하였다 (Figure 86). 회색 ECMWF를 나타내고 분홍색은 MME를 나타내며, 점선은 LSTM 적용 전, 실선은 LSTM 적용 후를 각각 나타낸다. 3개 예측기후 변수 모두에서, ECMWF 대비 LSTM이 적용된 MME에서 낮은 TCC 분포는 감소하고 높은

TCC 분포가 증가하는 것으로 나타났다. Figure 86에서 높은 TCC가 우측으로 이동되는 것이 확인되었다. 또한, 그 개선 경향이 4주까지 지속되었다. 원시 S2S 예측기후 자료와 LSTM이 적용된 예측기후 자료간의 통계적 유의성(독립적 두 그룹의 평균의 차이)은 인정되었다 (data not show).

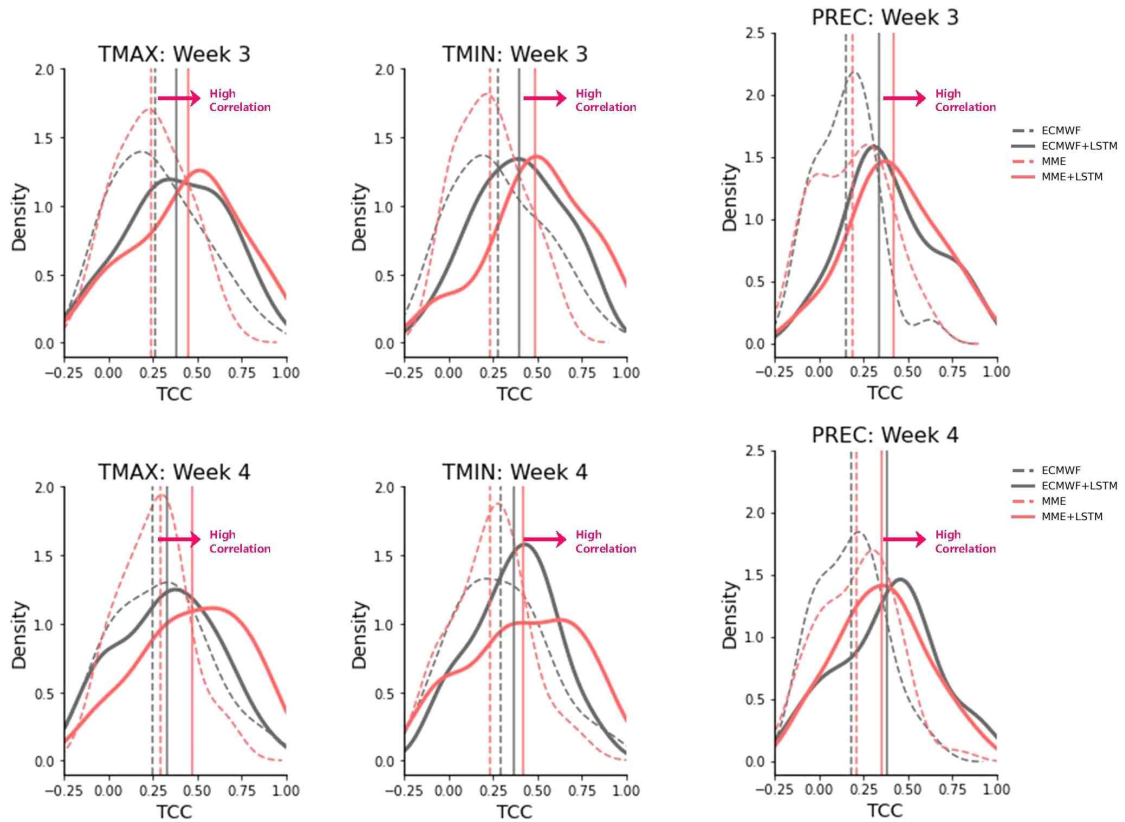


Figure 86. Comparison of the temporal correlation coefficient density distribution of the three target climatic variables(the daily maximum and minimum temperature, and the total precipitation) of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of ECMWF and MME.

3-4주에서 MME 기반 예측 최고기온과 최저기온, 강수의 TCC의 월별 분포를 분석한 후 계절별 산포도를 작성하였다 (Figure 87 to Figure 89). 12개 색상은 각각의 월을 나타내며 + 심볼은 통합 MME의 TCC, 채워진 O 심볼은 ECMWF의 TCC를 나타낸다. MME 기반 3개 예측기후 변수는 대부분의 월과 계절에서 MME 기반 S2S 예측기후 자료의 TCC가 개선되었다. ECMWF 대비 봄과 여름철에서 MME 기반의 S2S 예측기후 자료에 대한 딥러닝 적용 효과가 뚜렷하게 나타났다.

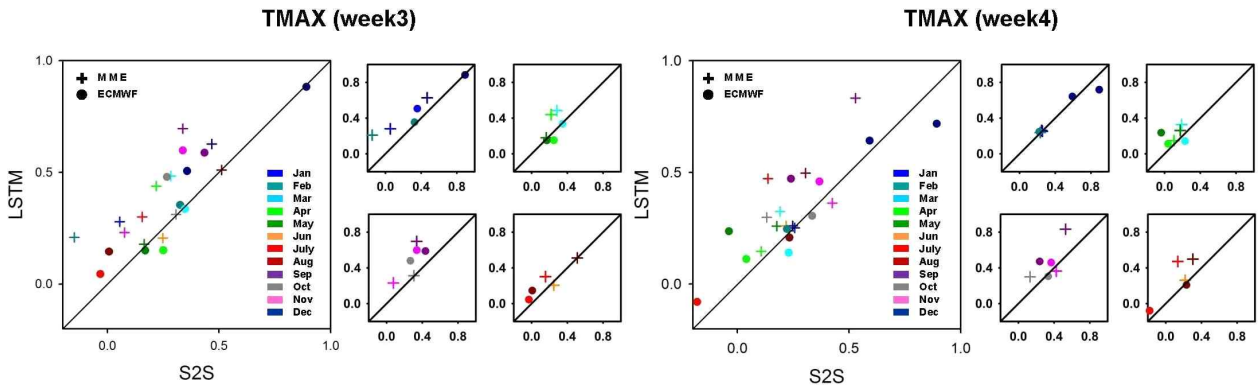


Figure 87. Comparison of the monthly temporal correlation coefficient of the daily maximum temperature at the 3 and 4 week of the lead-time of MME.

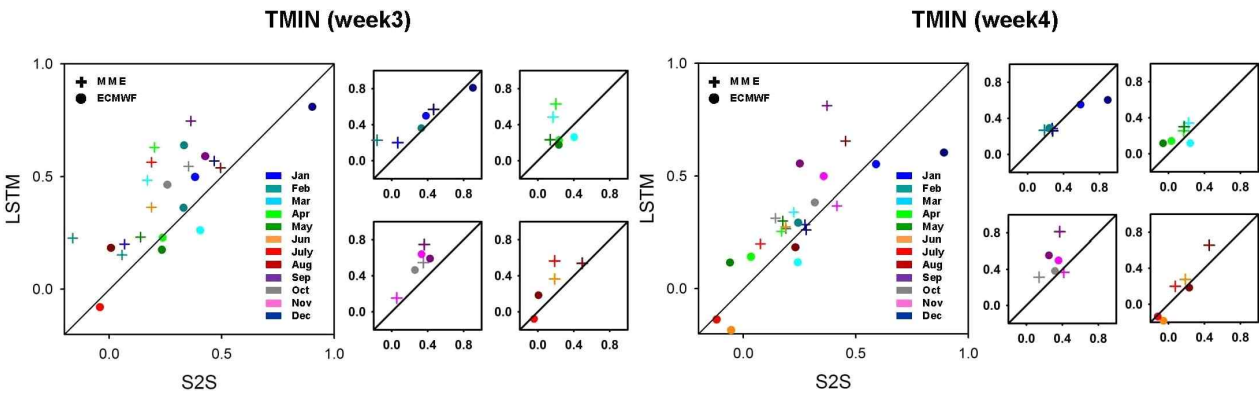


Figure 88. Comparison of the monthly temporal correlation coefficient of the daily minimum temperature at the 3 and 4 week of the lead-time of MME.

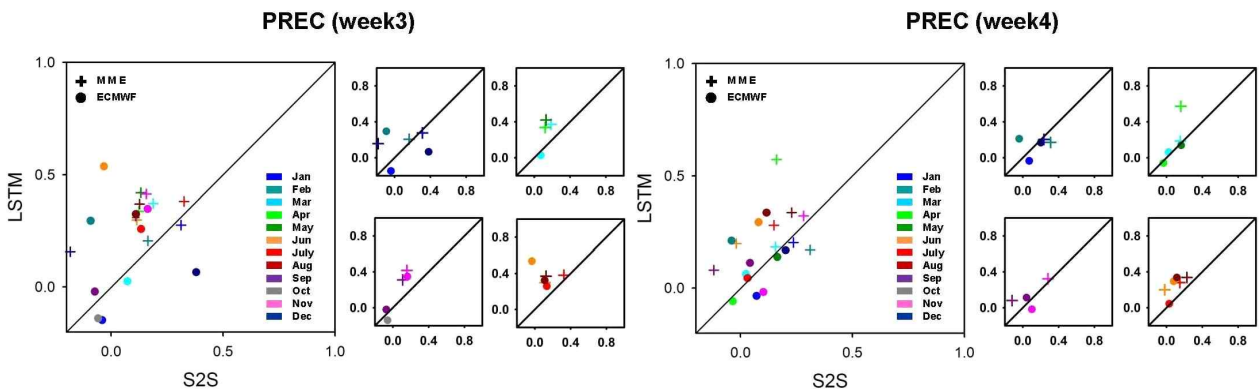


Figure 89. Comparison of the monthly temporal correlation coefficient of the daily total precipitation at the 3 and 4 week of the lead-time of MME.

Figure 90에서 Figure 92의 왼쪽 선 그래프는, LSTM 적용 전의 ECMWF의 S2S, LSTM 적용 전의 MME 기반의 계절내 예측기후 자료, LSTM 및 최적화된 LSTM이 적용된 MME 기반 계절내 예측기후의 TCC를 예측 전체 기간(약 40일)에 대해 비교한 것이다. 밝은 회색의 점선과 회색의 실선은 각각 LSTM 보정 전 ECMWF의 TCC와 통합 MME의 TCC를 나타내며, 어두운 빨강색 실선과 파란색 실선은 각각 LSTM 및 최적화된 LSTM이 적용된 통합 MME의 TCC를 나타낸다. 또한 Figure 90에서 Figure 92의 오른쪽 막대 그래프는, 3-4주 TCC에 대해서만 평균한 것을 비교한 것이다. 왼쪽의 선 그래프와 마찬가지로 밝은 회색과 회색은 LSTM 보정 전 3-4주에서 ECMWF와 통합 MME의 TCC를 각각 나타내며, 핑크색과 파란색은 각각 통합 MME에 대해 LSTM과 최적화된 LSTM이 적용된 TCC를 나타낸다. 전반적으로 ECMWF 대비 MME S2S의 개선은 뚜렷하지 않지만, MME에 LSTM을 적용하면 그 예측성 개선이 뚜렷하며, LSTM 모델 최적화에 의해 예측 개선의 고도화가 가능함을 확인하였다. 이러한 경향은 3개 예측기후 변수 모두에서 나타나는 것이 확인되었다. Table 15는 LSTM 적용 전의 ECMWF의 3-4주 S2S 예측기후 대비 최적화된 LSTM을 적용한 MME 기반 3-4주 S2S 예측기후의 예측 성능 개선도를 계산한 것이다. 기온의 경우 4주까지 지속되는 것이 뚜렷하게 나타나지만 강수는 3주에서는 월등하게 개선되나 4주까지의 지속이 다소 미흡한 것으로 나타났다. 그럼에도 불구하고, LSTM 적용 오차 저감 기술은 3개 S2S 예측기후(최고기온 및 최저기온, 강수)의 예측성을 모두 개선할 수 있을 것으로 판단된다. Rasp and Lerch 2018도 딥러닝 후보정을 통해 기상 자료의 예측성을 크게 개선 시켰는데, 본 연구는 시계열로 구축된 MME 기반 S2S 예측기후 자료에 딥러닝 후보정 적용을 통해 그 예측성을 월등하게 개선시켰다.

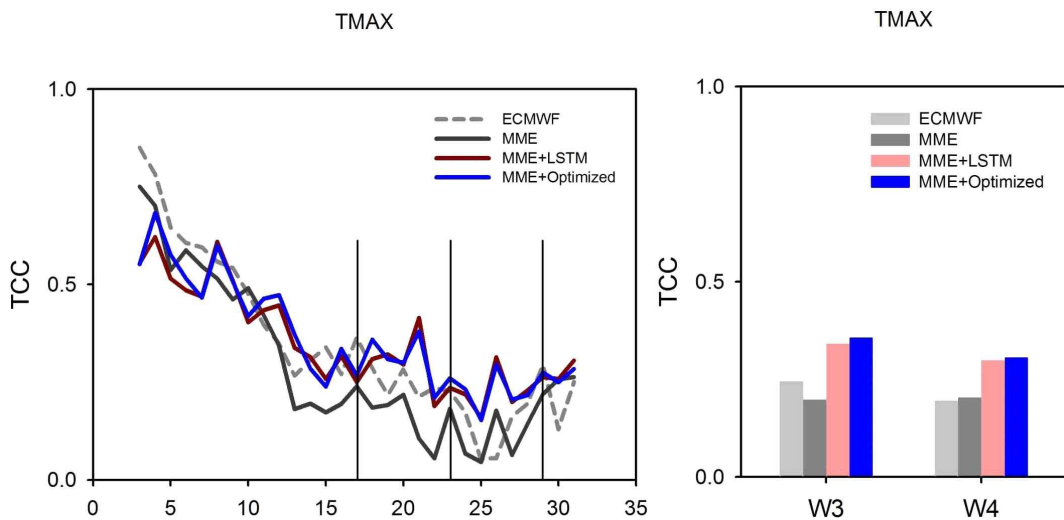


Figure 90. Comparison of the average of temporal correlation coefficient of the daily maximum temperature of the original S2S, LSTM, and the optimized LSTM, respectively during about one month of the lead-time of MME(left). Comparison of the average of temporal correlation coefficient of the daily maximum temperature of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of MME(right).

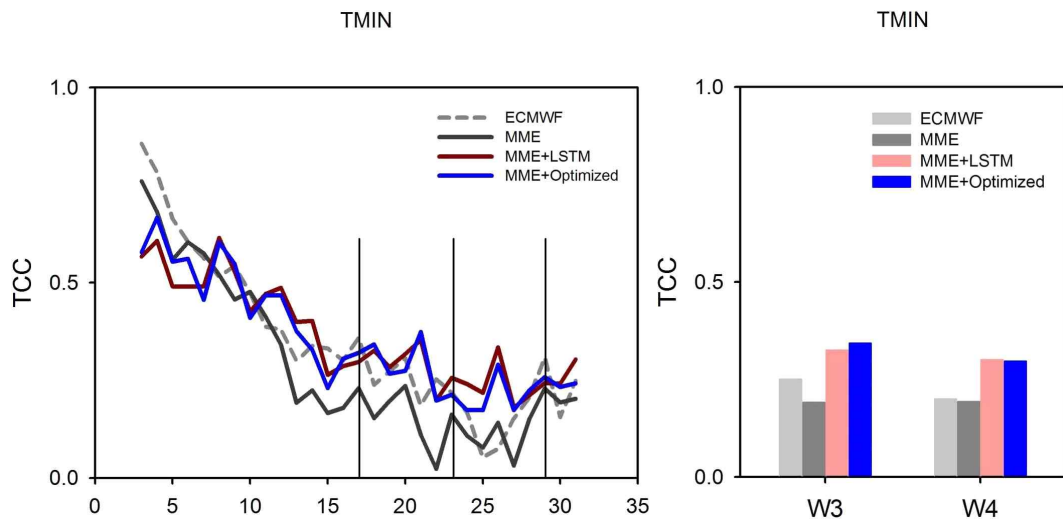


Figure 91. Comparison of the average of temporal correlation coefficient of the daily minimum temperature of the original S2S, LSTM, and the optimized LSTM, respectively during about one month of the lead-time of MME(left). Comparison of the average of temporal correlation coefficient of the daily minimum temperature of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of MME(right).




Figure 92. Comparison of the average of temporal correlation coefficient of the daily total precipitation of the original S2S, LSTM, and the optimized LSTM, respectively during about one month of the lead-time of MME(left). Comparison of the average of temporal correlation coefficient of the daily total precipitation of the original S2S, LSTM, and the optimized LSTM, respectively at the 3 and 4 week of the lead-time of MME(right).

Table 155. The relative improvement of correlation coefficient of three climatic variables during target lead-time (week 3 and 4).

Target climate variables	Relative improvement (%)	
	Target lead-time	
	W3	W4
TMAX	45.66	57.60
TMIN	36.70	48.83
PREC	184.44	52.42

7. 격자기반 계절내 예측 딥러닝 기법 개발

가. 자료 및 방법

(1) 자료

(가) Glosea 5

Glosea5(Global Seasonal Forecasting System version5; MacLachlan et al 2015, Scaife et al 2014)는 Met Office의 계절내 예측을 위해서 만들어져서 현재 현업운영 중에 있다. Glosea5는 Met Office 기후모델인 HadGEM3의 패밀리 형태의 모델로 고해상도 앙상블 모델로서 대기-지표-해양-해빙 결합모델이다. 대기는 Met Office Unified Mode(UM; Brown et al., 2012)을 기본 모델로 채택하여 이용하고 있으며, 지표는 UK Land Environment Simulator(JULES; Best et al., 2011), 해양은 Nucleus for European Modeling of the Ocean(NEMO; Madec, 2008), 해빙은 The Los Alamos Sea Ice Mode(CICE; Hunke and Lipscomb, 2010)을 모델로 구성되어 있다. Glosea5는 N216공간해상도로 대략 위도 0.8°, 경도 0.5°의 해상도를 가지고 있으며, 해양에서는 0.25°의 해상도의 데이터를 제공한다(Figure 93).

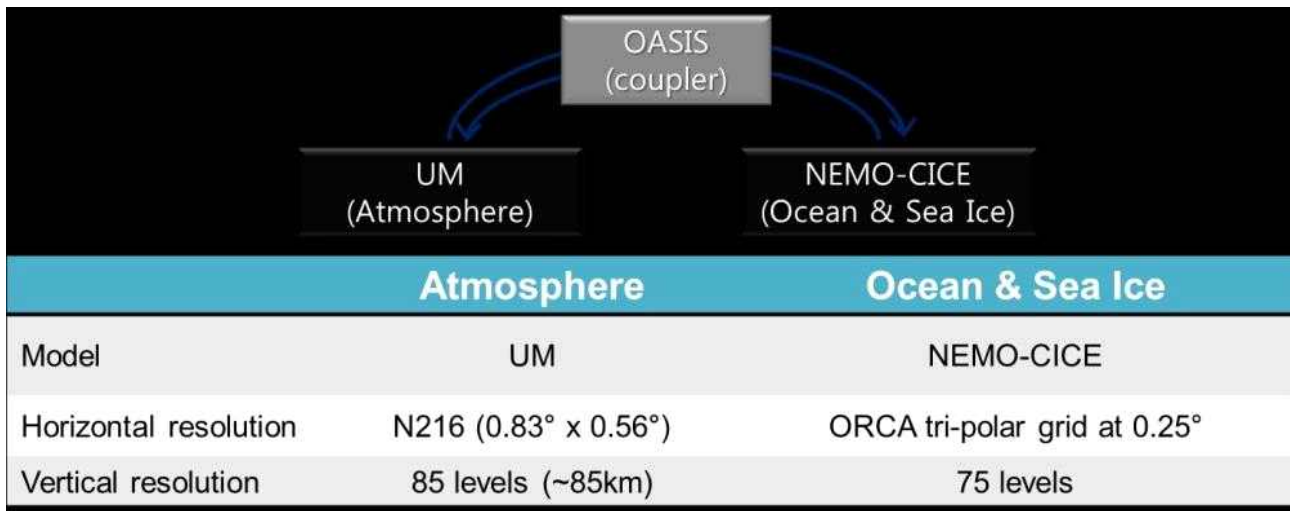


Figure 93. Glosea5 model.

Glosea5자료는 1991년부터 2010년까지 자료를 위도 20-50N, 경도 90-150E의 자료를 ERA-Interim에 맞는 공간해상도로 interpolation해서 배열(39,41)로 resampling하였다(Figure 94). 초기의 배열(39, 41)을 합성곱과 LSTM의 딥러닝 방법으로 PC로 학습하기에는 계산시간이 많아서 자료를 다시 배열(20,20)으로 줄이고, 이 또한 계산시간이 수일에서 일주일 걸리는 시간이다.

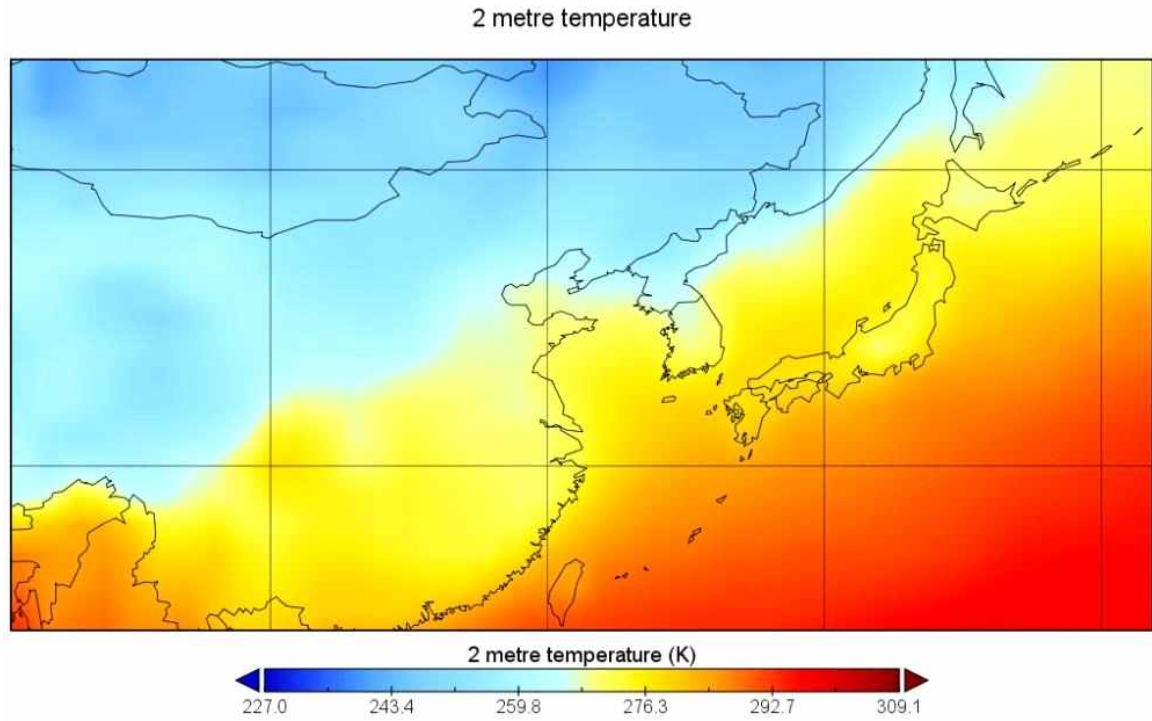


Figure 94. The clipping temperature data of Glosea5.

Glosea5는 위도 28-40N, 경도 120-132E로 한반도 주변의 격자자료로 9×9로 39개의 변수자료를 입력자료로 만들었다(Figure 95).




Figure 95. The input data of ConvLSTM model.

(나) ERA-Interim

ERA-Interim는 대기모델 ERA-40에서 발전되어 제공하는 재분석자료로 1979년부터 2018년도까지 자료를 제공하고 있다. ERA-Interim자료는 다변수, 격자화된 시공간 해상도의 자료이며, 모델과 관측자료를 결합한 자료이다. 자료는 1979년 1월부터 2019년 9월까지 자료로 자료의 포맷은 netCDF, GRIB형태로 제공된다. 시간 해상도는 sub-daily, daily, monthly자료를 제공하며 공간적 해상도는 $0.75^{\circ} \times 0.75^{\circ}$ 으로 해양 및 지표로 관측자료는 지상관측자료, 위성자료, 위성 radiance 및 모델 자료로 이루어져 있다(Figure 96). 재분석자료 ERA-Interim는 1° 의 해상도로 전처리 하였다.




Figure 96 Globally averaged temperature data(top), radiance from MSU satellite data(center) and global mean bias adjustments(bottom).

입력자료 중 재분석자료인 ERA-Interim자료는 Glosea5와 기간이 같은 1990년부터 210년까지의 자료를 배열(41,39),(20,20),(9,9)으로 만들어서 학습하였으나 앞서서도 언급한 것과 같이 계산시간이 오래 걸리는 단점으로 최종적으로 한반도 지점 자료를 만들어서 데이터를 전처리하였다. 학습해야 할 변수로는 강수, 최대 온도, 최저 온도이며, 3개의 각각의 변수자료들을 Glosea5의 자료와 같은 배열로 3개의 데이터셋을 구성하였다.

Total Precipitation

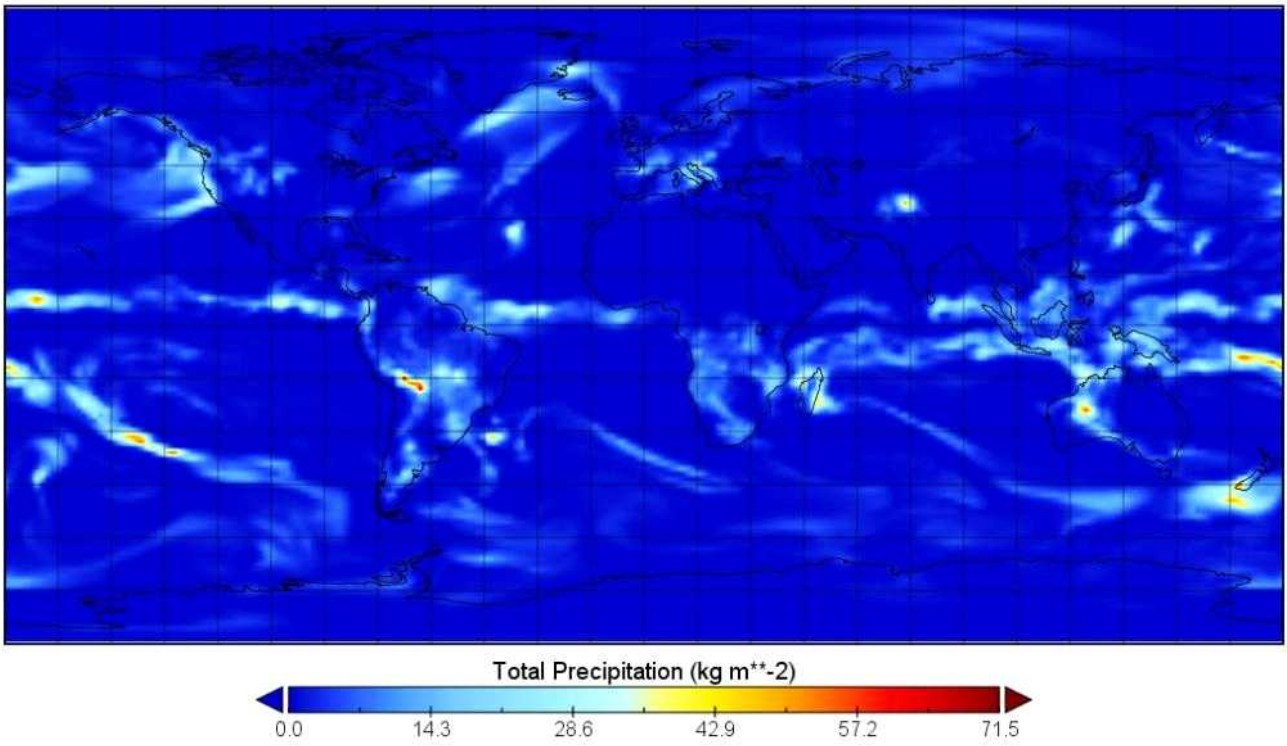


Figure 97. Daily total precipitation of GloSea5 at Jan 1, 2006.

Maximum temperature at 2 metres in the last 6 hours

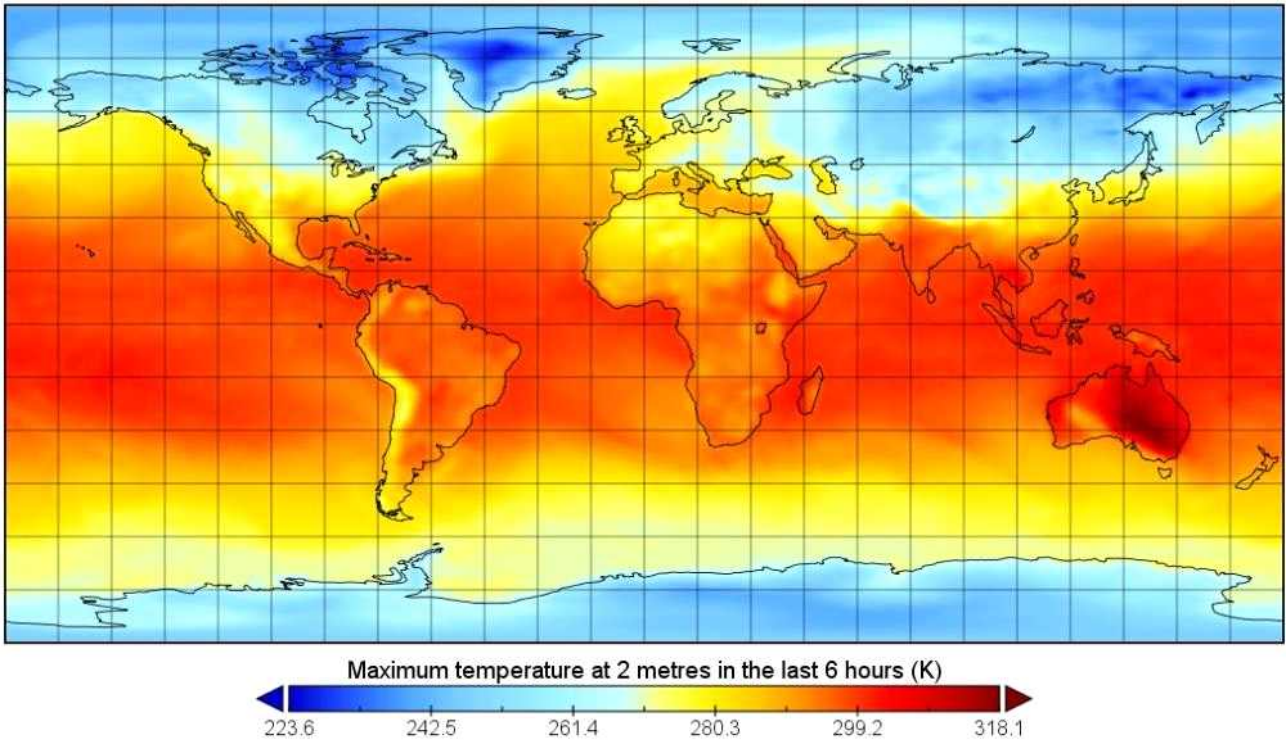


Figure 98. Maximum temperature of Glosea5 at Jan 1, 2006.

Minimum temperature at 2 metres in the last 6 hours

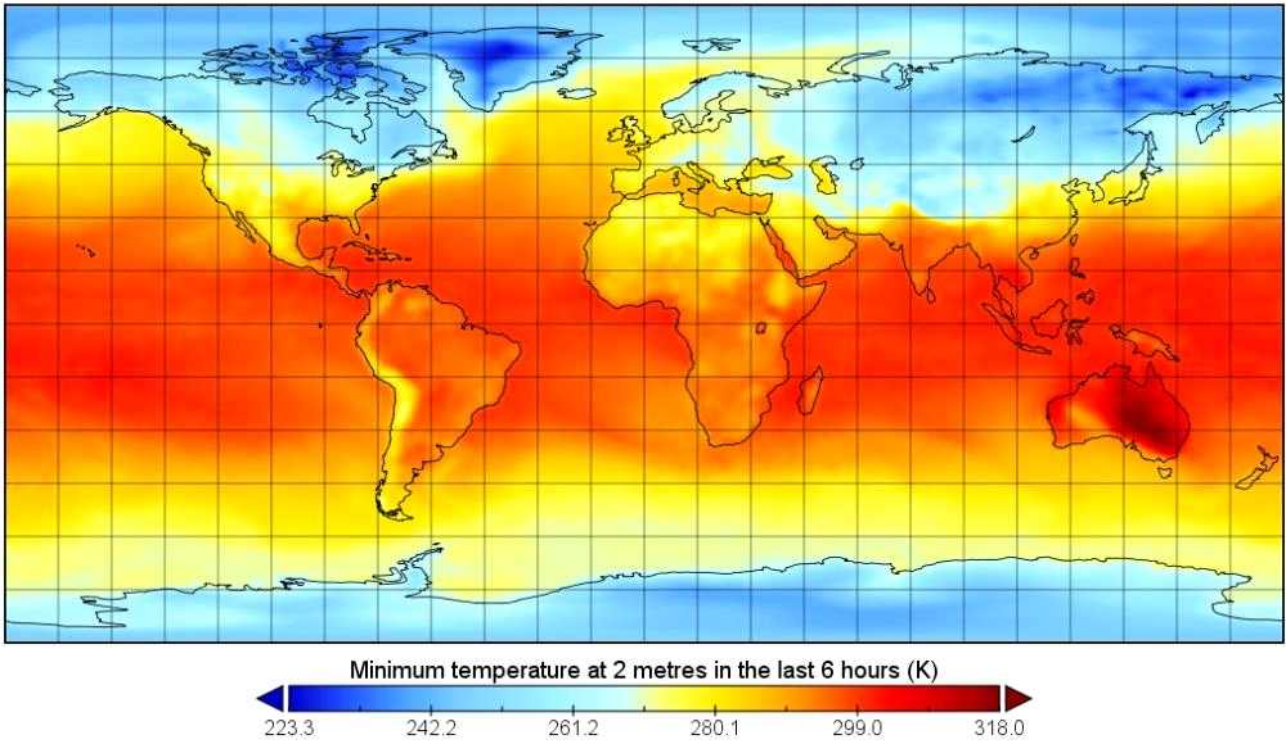


Figure 99. Minimum temperature of GloSea 5 at Jan 1, 2006.

딥러닝 모델의 입력자료는 1991년부터 2010년까지 20년간의 데이터로 GloSea5는 일자료로 13변수와 3개의 앙상블 자료를 입력자료로 활용하며, release date에 따라 월에 1,9,17,24일의 총 4개의 데이터셋으로 1년 48개의 총 데이터에서 한번 release date 60일 예측자료가 더해진다. 학습해야 할 변수는 강수, 최대/최소 온도 자료이며, ERA-Interim 재분석자료를 학습자료로 활용한다. 일자료를 GloSea5의 예측기간인 60일과 같은 기간으로 전처리 하여 자료를 구성하였다(Table 16).

Table 16. Summary of training dataset for ConvLSTM Model.

	Observed ERA-Interim	S2S model GloSea5
Period	1990-2018	1991-2010
Time scale	daily	daily
Time range	-	0-60 days
Ens. size		3
ConvLSTM input	release date(39 variable X 60 day)	
ConvLSTM output	daily Tmax, Tmin, Precipitation	

(2) 방법

(가) 딥러닝 방법

딥러닝 방법은 머신러닝의 한 방법중에 하나로 인공지능의 한 분야로서 현재 검색엔진, 자동번역, 문서분류, 시장예측, DNA 분석, 음성인식, 의료, 로봇 등 광범위한 분야에 이용되고 있다. 초기의 DNN(Deep Neural Network)에서 이미지 인식작업에 CNN(Convolutional Neural Network)의 방법에서 이미지를 인식하고 분류하고, 자율주행에서 사물을 인지하는 방법등에 널리 이용되고 있다. 또한 의료분야에서 다양하게 활용되고 있는데 CT, MRI와 같은 영상의학분야에서 질병부위 탐지, 진단 등의 분야에서 성과를 내고 있다. 최근에는 실제 존재하는 이미지를 자동으로 만드는 이미지 생성 기술 오토인코더, GAN(Generative Adversarial Networks)의 방식으로 모네, 고희의 그림을 학습하면 실제 존재하지 않지만 고희나 모네가 그린듯한 그림도 만들 수 있다. 이상탐지 기법은 대량의 데이터를 학습시켜 발생하는 복잡한 패턴이 정상인지 비정상적인지를 탐지하는 기술로 불법거래, 공장에서의 고장 여부를 탐지하는데 많이 활용하고 있다. 특히 GAN은 Generator와 Discriminator를 학습시켜 정상/비정상을 판독해 내는 방법으로 발전하고 있다. 강화학습은 주어진 환경에서 보상받는 방법으로 학습하는 방식으로 기계 제어나 게임에서 많이 활용되고 있다. 또한 구글의 딥마인드 알파고는 바둑을 강화학습 방식으로 학습하여 인간을 이기고 이 분야 최고의 경쟁자로 군림하고 있다. 자연어 처리는 컴퓨터를 이용하여 자연어를 처리하는 기술로 문장을 이해하거나 생성하는 작업을 RNN(Recurrent Neural Networks)기술을 이용하여 자연어 처리 분야에 많이 활용한다. 이 작업은 기후와 날씨와 같이 시간이 연속적으로 변하는것에 따라서 값이 변하는 분야에 많이 이용된다. 시계열 데이터를 효과적으로 학습하기 위하여 RNN방법을 이용하여 데이터의 추세와 주기, 시간에 따른 순서대로 전파되는 데이터를 학습하여 다음 시점의 값을 정확하게 예측하는 방법이다. Figure 100과 같이 다양한 입력 피처에 따라 다양한 학습된 시계열 예측값을 생성한다.




Figure 100. Represent functions of RNN' s state.

RNN에서 시계열 데이터에서 특정시점의 오차의 출력 기울기는 출력층에서 역전파해 온 출력값의 기울기와 이후 시점에서 거슬러 온 출력 기울기 합이 되는데, 몇 개의 레이어를 걸치면서 오차를 저파시키면 기울기가 소실 또는 발산하는 문제가 있어, 특정시점의 정보가 일정 시간이 지난 시점에까지 가중치가 전달되지 않는데 이러한 문제점을 “장기 의존성의 문제”라고 한다. 이러한 문제점을 해결하기 위해 LSTM (Long Short-Term Memory)방법을 많이 이용한다(Figure 101).




Figure 101. A diagram of LSTM
<https://mikigom.github.io/jekyll/update/2017/06/13/deep-learning-forecast-research-1.html>

$$i_t = \sigma(W_{\xi}x_t + W_{hi}h_{t-1} + W_{ci} \odot c_{t-1} + b_i)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf} \odot c_{t-1} + b_f)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co} \odot c_t + b_o)$$

$$h_t = o_t \odot \tanh(c_t)$$

한 지점의 시계열 자료의 다음값을 예측할 때 일반적으로 이용하는 FC(Fully-Connected)-LSTM을 이용하여 다변수를 1차원 벡터로 학습하여 예측값을 생성하는 방

법은 과거부터 연구를 통하여 적용한 방법으로 현재 계절내 예측모델을 이용하는 방법보다 더 정확도가 높았다. 하지만 동아시아와 같은 지역에 1차원 LSTM을 바로 적용하기엔 무리가 있다. 따라서 2차원 배열을 가진 GloSea5의 예측자료를 합성곱 LSTM인 ConvLSTM으로 데이터셋을 구성하고 최종적으로 한지점의 20년 자료로 학습하여 비교분석하였다(Figure 93). 2차원 GloSea5 데이터는 빅데이터로 데이터 차원이 크게 증가하고 또한 공간적 상관성이 있는 데이터이므로 피처간의 특성을 고려한 CNN을 이용하는 것이 향후 정확도 개선에 합리적 방법이라고 판단된다. 본 연구에서는 LRCN(Donahue, 2017)에 기반하여 CNN으로 각각의 GloSea5 feature 특징 벡터를 추출하고 이를 기반으로 LSTM을 적용하였다(Figure 102).

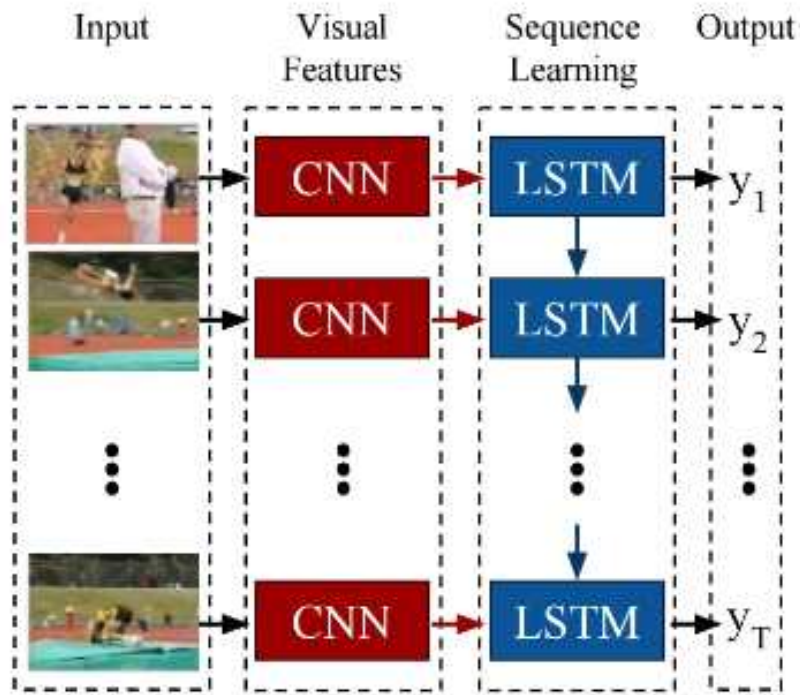


Figure 102. A diagram of Long-term Recurrent Convolutional Networks <https://mikigom.github.io/jekyll/update/2017/06/13/deep-learning-forecast-research-1.html>.

$$i_t = \sigma(W_{\xi}^* X_t + W_{hi}^* H_{t-1} + W_{ci} \odot C_{t-1} + b_i)$$

$$f_t = \sigma(W_{xf}^* X_t + W_{hf}^* H_{t-1} + W_{cf} \odot C_{t-1} + b_f)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_{xc}^* X_t + W_{hc}^* H_{t-1} + b_c)$$

$$o_t = \sigma(W_{xo}^* X_t + W_{ho}^* H_{t-1} + W_{co} \odot C_t + b_o)$$

$$H_t = o_t \odot \tanh(c_t)$$

LSTM과의 ConvLSTM과의 큰 차이는 X_t 가 2차원의 GloSea5의 피쳐가 들어가고 ConvLSTM의 입력, 망각, 출력 게이트 i, f, o 와 셀 입력 X , 셀 출력 C , 셀 상태 H 는 모두 3차원 벡터로 1차원인 FC-LSTM과 차이가 있다. 3차원 벡터에 관련된 이미지를 Figure 103과 같고, 입력, 상태, 출력 모두 3차원 텐서이며, 본 연구에서는 3차원 텐서를 이용하여 지점 60일을 예측하였다. 향후 2차원의 계절내 모델값은 2차원 내의 재분석자료와의 학습을 통하여 최종적으로 2차원 예측값을 산출하고자 한다.




Figure 103. The structure of ConvLSTM.

(나) 계산방법

대용량의 2차원 GloSea5의 자료를 합성곱으로 레이어를 크게 늘이고 LSTM으로 학습할 때 계산해야할 파라미터가 많아지게 되기 때문에 PC에서는 사용하기 어려운 문제점이 있다. 계산 시간을 효과적으로 이용하기 위해서는 GPU의 병렬컴퓨팅이 딥러닝 학습하는데 매우 효과적으로 계산시간을 단축할 수 있다. 현재 GPU 컴퓨팅의 서버를 구축하기에 비용이 많이 드는 관계로 12시간 이전의 짧은 학습시간으로 결과를 볼 수 있는 모델은 구글의 colab을 이용하였다 (Figure 104). colab은 구글 클라우드에서 무료로 가상서버를 지원하기 때문에 가상서버를 통하여 부분 학습하였다. 구글 드라이브와 연동되기 때문에 훈련셋 자료는 구글 드라이브에 업로드하여 colab과 연동하면 colab에서 구글드라이브를 하드처럼 인식하여 사용가능하다. colab은 지속적으로 12시간 사용이 가능하기 때문에, 12시간보다 더 자원이 필요할 경우에는 연산자원에 대한 업그레이드가 필요하다.

```

1 # -*- coding: utf-8 -*-
2 ***
3 Created on Fri Sep 11 17:59:20 2020
4
5 @author: kwp
6 ***
7 from google.colab import drive
8 drive.mount('/gdrive', force_remount=True)
9 from numpy import array
10 from keras.models import Sequential
11 from keras.layers import LSTM
12 from keras.layers import Dense
13 from keras.layers import Flatten
14 from keras.layers import Dropout
15 from keras.layers import ConvLSTM2D, Conv2D, MaxPooling2D
16 from tensorflow.keras.layers import BatchNormalization
17 import numpy as np
18 from math import sqrt
19 from numpy import concatenate
20 from matplotlib import pyplot
21 from pandas import read_csv
22 from pandas import DataFrame
23 from pandas import concat
24 import pandas as pd
25 from sklearn.preprocessing import MinMaxScaler
26 from sklearn.preprocessing import LabelEncoder
27 from sklearn.metrics import mean_squared_error
28 from sklearn.metrics import r2_score

```

Figure 104. The usage of Colaboratory by google drive.

(다) ConvLSTM

CNN-LSTM은 인코딩 모델과 디코딩 모델로 이루어져 인코딩 모델이 연속적인 GloSea5의 변수들을 받고, 예측모델인 LSTM 모델에서 60일의 데이터의 값들을 예측하도록 설계하였다. 설계 당시의 GloSea5 MSLP, PREC, T2M, TMAX, TMIN, U200, U850, V200, V850, W500, Z200, Z500의 변수값을 Conv2D필터를 통해서 피쳐 특징을 뽑아내고 다시 MaxPooling을 통해서 차원을 줄이고, MaxPooling후에 다시 Conv2D를 실행하고 다시 Maxpooling을 실시하는 하여 최종적으로 Geosea5 변수자료를 concatenation함수를 통해서 자료를 합치고 합쳐진 자료를 다시 LSTM으로 60일 예측자료로 학습하고자 하였다.




Figure 105. Conceptual diagram of CNN-LSTM.

하지만 설계하는 과정에 한번에 ConvLSTM을 적용하여 39변수에서 각각의 피쳐들에서 가중치를 뽑아내고 다시 한반도 지점의 ERA-Interim자료와 학습하는 것이 정확도 개선에서 더 합리적인 선택일 것으로 판단하여 ConvLSTM방법으로 설계하고 학습하였다. GloSea5의 39개의 입력자료를 ConvLSTM 함수를 이용하여 한반도 지점 60일 예측자료로 학습하였다(Figure 106).

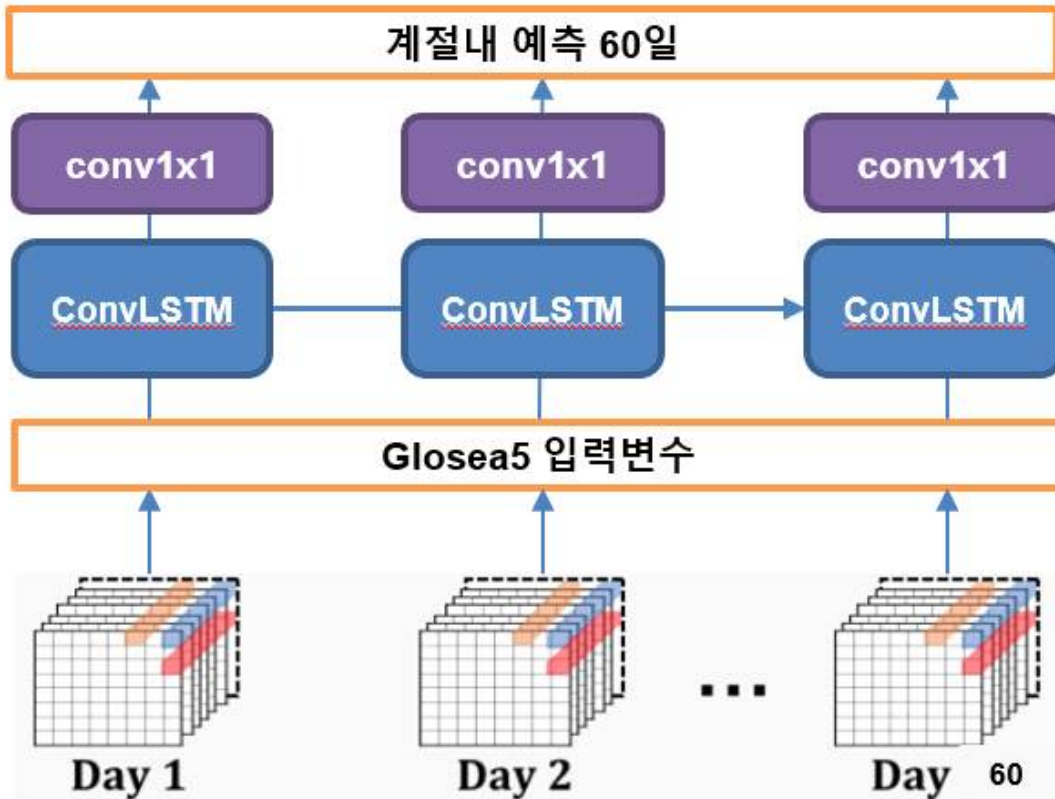


Figure 106. The Structure diagram of ConvLSTM framework.

Glosea5 MSLP, PREC, T2M, TMAX, TMIN, U200, U850, V200, V850, W500, Z200, Z500의 변수값을 배열(9,9)에 3개의 양상블 멤버에 총 39개의 피쳐와 20년치의 자료를 입력받고, 재분석 자료 ERA-Interim자료를 입력받는다.

```

from keras.models import Sequential

from keras.layers import Dense

from keras.layers import Flatten

from keras.layers import ConvLSTM2D

```

케라스에서 필요한 Dense, Flatten, convLSTM2D 함수를 불러와서 라이브러리로 활용하고, Glosea5의 변수값의 최대값과 최소값이 다르기 때문에 학습할 때 가중치가 변수마다 다르게 들어가기 때문에 이러한 부분을 같은 최대값 및 최소값으로 만들어 주기 위하여 MinMaxScaler 을 통하여 39개의 피쳐를 0-1로 노말라이즈를 실행하였다. ERA-Interim자료도 본 연구에서 학습하고자 하는 변수, 강수, 최대온도, 최소온도에 대해서 MinMaxScaler로 0-1 노말라이즈를 실

행하였다. 훈련셋은 20년치중에 70%를 훈련셋으로 30%을 테스트셋으로 나누어 자료를 나누었으며, train_test_split함수로 랜덤으로 자료를 6세트로 나누어 학습하였다.

```
with tf.device('/device:gpu:0'):

model = Sequential()

model.add(ConvLSTM2D(filters=64, kernel_size=(2,2),
input_shape=(n_for, lonnum, latnum, feature),padding='same', return_sequences=True))

model.add(ConvLSTM2D(filters=32, kernel_size=(2,2),padding='same', return_sequences=True))

model.add(ConvLSTM2D(filters=16, kernel_size=(2,2),padding='same', return_sequences=True))

model.add(ConvLSTM2D(filters=8, kernel_size=(2,2),padding='same', return_sequences=True))

model.add(ConvLSTM2D(filters=4, kernel_size=(2,2),padding='same', return_sequences=True))

model.add(Flatten())

model.add(Dense(60))

model.summary()
```

대략 100만개의 배열을 합성곱으로 계산하기 때문에 계산시간이 오래 걸리기 때문에 PC내의 GPU를 이용하여 CPU와 GPU를 같이 활용하여 학습하였고, ConvLSTM모델은 입력자료는 60일의 예측자료와 배열(9,9)의 자료 및 변수 39개의 훈련자료와 ERA-Interim자료도 Glosea5와 같이 60일의 강수, 최대/최소 온도를 70%의 훈련자료로 구성하였다. 모델은 필터를 64,32,16,8,4로 적용하였고, kernel_size는 배열(41,49),(20,20)일때는 3×3으로 적용하였으나 계산시간으로 인하여 배열을 9×9로 줄인상황에서는 kernel_size를 2×2 했을 때 학습 결과가 3×3보다 높은 학습 정확도를 보여주었다. optimizer함수는 'adam'으로 손실함수는 mean square error (mse)함수로 학습하였을 경우에 학습에 의한 오차가 가장 적어 adam, mse 함수를 선택하였다. 학습할 때 기울기값이 사라지는 문제(vanishing gradient problem)는 LSTM을 이용하였고, 많은 양의 학습데이터에서 오는 과적합을 줄이기 위하여 batch normalization을 적용하였으나 크게 개선되지 않았기 때문에 batch normalization은 적용하지 않았다. epochs는 50회를 기본적으로 적용했으나, 계산시간의 어려움으로 1000회 넘어가면서 epochs에 따른 민감도 분석을 하고자 하였으나 컴퓨팅의 성능으로 적용하지 못했다. 향후 컴퓨터 파워가 가능해지면 epoch횟수에 따른 결과를 적용해 볼 필요가 있다. 훈련셋의 학습자료 결과를 테스트셋에 적용하면 epoch횟수에 따라 오차값이 잘 줄어들어가는 것을 볼 수 있다.

(라) 피쳐 엔지니어링

2019년 과제에서 LSTM 딥러닝은 아마존 MXNET엔진 기반으로 R프로그램으로 구축되었으나 딥러닝 라이브러리를 쉽게 활용할 수 있고, 가장 범용적인 딥러닝 엔진인 구글의 텐서플로 기반 파이썬 딥러닝 프로그램으로 변환하였다. 파이썬 기반 LSTM 코딩의 변환은 계산속도를 향상할 수 있도록 병렬컴퓨팅을 제공하고, 딥러닝 코드 공유 및 향후 현업 운영할 때 쉽게 시스템 구축할 수 있도록 모듈화 할 수 있기 때문에 파이썬 코드로 변경하였다. 2019년도 과제에서는 한반도 지역의 한 지점의 LSTM 딥러닝 기법을 개발하여 개선된 결과를 제시하였다. 개발된 LSTM의 딥러닝 기법은 원시 데이터의 피처를 어떤 자료로 구성하는지 배치사이즈 및 dropout같은 다양한 파라미터를 조정하여 피쳐 엔지니어링 기법을 적용하여 민감도 분석을 통하여 개선된 모델을 개발하고자 하였다(Figure 107). Feature engineering 민감도 분석을 위하여 Glosea5 모델을 하나의 입력자료로 적용하고 성능평가는 RMSE를 통하여 성능평가를 하였다.

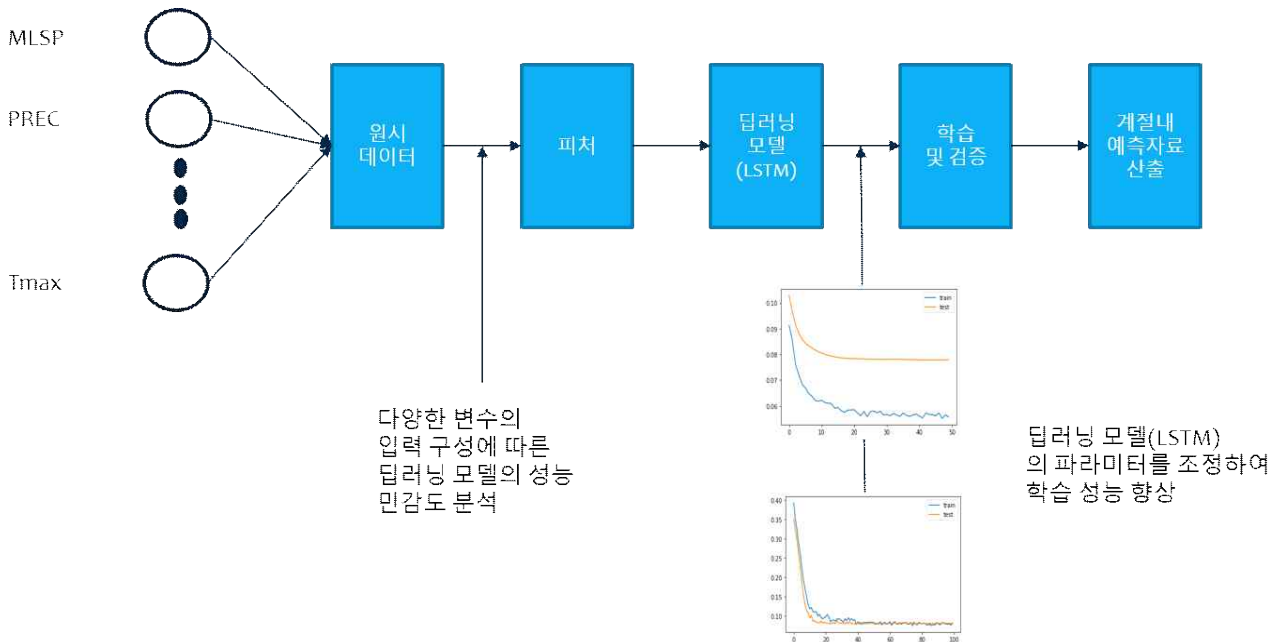


Figure 107. The structure diagram of feature engineering for LSTM.

나. 결과

(1) 피쳐 엔지니어링 적용 결과

Feature selection을 통한 입력 모델 민감도 분석을 위하여 모델 변수를 다양하게 선택하여 적용하였으나 MSLP, PREC, T2M, TMAX, TMIN의 핵심변수와 U50, U200, U850, V200, V850, W500, Z200, Z500을 각기 다른 결합형태로 입력자료로 민감도 분석을 실시한 결과 정확도 개선에는 크게 영향이 없었다. 학습 시간의 축소와 오버피팅을 줄이기 위해서 핵심변수로만 입력

자료를 구성하는 것이 13개의 변수를 모두 사용하였을 경우와 크게 차이가 없기 때문에 5개의 변수(MSLP, PREC, T2M, TMAX, TMIN)을 활용하였다. Glosea5의 일강수자료값의 raw데이터값을 $\text{kgm}^{**}-2$ 값을 이용하기 보다 mm/day로 변환하여 학습하였을 때 정확도가 개선이 되었다. 훈련데이터셋의 cost값을 mse함수일 경우와 optimizer함수는 'rmsprop', 'adam'의 다양한 함수중에서 adam의 함수를 적용했을 경우 가장 좋은 결과값을 보였다. epoch는 50회 이상으로 민감도 분석을 실시한 결과 50회 이후로 결과가 수렴하였기 때문에 계산시간을 위하여 50회로 적용하여 학습을 실시하였다. 또한 LSTM 파라미터의 민감도 분석을 수행한 결과 Glosea5 각각의 앙상블 예측자료의 13개 변수에 재분석자료를 배치하여 학습한 결과보다 39개의 모든 앙상블 변수에 대해서 하나의 재분석 자료를 배치하여 학습 입력자료를 구성하고, 딥러닝 레이어를 더 깊게 적용하고, 그 과정에서 발생할 수 있는 과대적합을 개선하기 위하여 dropout을 적용했을 경우에 정확도가 개선이 되었다.

피쳐 엔지니어링을 적용한 결과 최대기온 RMSE의 결과를 보면 정확도에서 2019년 LSTM결과와 거의차이가 없었으나(Figure 108), 최소온도값은 리드타임별로 대략 10%의 성능이 향상되었다(Figure 109). 강수의 경우 2019년도 Glosea5 LSTM에 비해 피쳐 엔지니어링을 적용한 결과는 RMSE가 선행시간 3~4주에서 성능이 25% 개선되었음을 확인 할 수 있었다(Figure 110).




Figure 108. RMSE of Tmax by feature engineering for leadtime.




Figure 109. RMSE of Tmin by feature engineering for leadtime.




Figure 110. RMSE of precipitation by feature engineering for leadtime.

(2) ConvLSTM 모델 개발

1차원 벡터의 LSTM보다 정확도 향상을 위하여 2차원 배열의 딥러닝 기법인 ConvLSTM을 개발하였다. PC에서 CPU의 코어에 의존한 학습 계산시간이 오래 걸리는 단점이 있어, 동아시아지역의 41×39, 20×20배열의 합성곱에 의한 LSTM결과를 적용하기 어려웠다. 9×9배열을 통

하여 공간특성을 반영한 Convolutional LSTM(ConvLSTM)을 적용하였다. 모델 입력은 샘플수와 60일의 예측자료, 행열의 배열자료와 39개의 GloSea5의 입력자료를 70%, 30%의 훈련셋과 테스트셋으로 나누어서 학습하였다. 초기의 ConvLSTM모델의 경우 layer를 2개 층만 적용하여 모델을 학습한 결과는 2019년도에 개발된 1차원 LSTM모델보다 정확도가 떨어지는 것으로 나타났으며, Convolution Layer를 겹겹이 쌓고 학습한 결과값은 정확도가 개선이 된 것을 확인할 수 있었다(Figure 111).




Figure 111. The result of cost function for ConvLSTM model.

GloSea5 MSLP, PREC, T2M, TMAX, TMIN, U200, U850, V200, V850, W500, Z200, Z500의 값이 다 최대, 최소값이 다르기 때문에 학습의 어려움이 있어, 이 문제를 해결하기 위하여 값을 0-1로 맞추는 노말라이즈를 적용하였다. Normalization 함수로는 sklearn 함수의 MinMaxScaler를 39개의 피처에 대해서 0-1로 전처리 하였고, Scaler.fit_transform과 scaler.inverse_transform 함수로 0-1값을 원값으로 되돌리때 마지막 normalization 한 함수로 모든 값이 복원되기 때문에, GloSea5와 ERA-Interim을 각기 Scaler.fit_transform로 노말라이즈하고, 마지막에 실행된 scaler.inverse_transform으로 하나의 함수로 원값으로 복원되어 과적합되고 상관관계수가 0.9이상으로 잘 학습이 되었다. 이러한 과적합을 해결하기 위해서는 GloSea5와 ERA-Interim을 하나의 데이터로 구성하여 노말라이즈 및 복원하여야 한다(Figure 112).





Figure 112. The example of overfitting by normalization.

ConvLSTM2D 함수를 최대한 겹겹이 레이어를 구성하고 필터를 64개에서 4개까지 적용하고 배치사이즈를 32로 충분히 두어 훈련했을 경우에 가장 정확도 높은 학습결과를 도출하였다. 최소온도의 통계적 검증결과를 RMSE로 두고 결과를 보면 Glosea 5의 모델 예측결과와 2019년도에 개발한 1차원 벡터의 LSTM, LSTM에 피쳐 엔지니어링을 적용한 FE+Feature Engineering 와 비교분석을 하였다. 결과를 보면 Glosea5의 모델 결과는 5.05로 정확도가 떨어지는 것을 확인 할 수 있었고, 1차원 벡터 LSTM은 2.98로 Glosea 예측자료에 비해서 RMSE가 확연히 줄어드는 것을 볼 수 있다. LSTM에 입력자료 변경, dropout등의 피쳐엔지니어링을 적용나 LSTM+FE의 경우에는 LSTM단독보다 2.75로 정확도가 개선이 되었다. ConvLSTM모델을 적용한

결과 계산속도로 인하여 9×9 배열만 적용하였음에도 불구하고 2.68로 가장 정확도가 높았다. 최대온도의 결과는 최소온도와 거의 유사한 결과를 도출하였다(Figure 113).



Figure 113. Comparison of forecast performance for entire lead time.

강수의 경우에는 RMSE는 오차개선이 있으나 상관계수 값이 Glosea5와 거의 유사하게 좋은 결과를 나타내지 못했다. 향후 강수와 온도에 대한 입력자료, ConvLSTM 모델 방법 및 모델 최적화 방법들을 달리 하여 학습을 진행할 필요성이 있다. 각각의 월에 1일, 9일 17일, 24일에 대한 각각의 RMSE결과를 보게 되면 Glosea5와 비슷한 추세를 나타내지만, RMSE값이 적어 보다 우수한 정확도를 보여준다. 겨울철에 Glosea5와 ConvLSTM의 결과가 여름철에 비해 정확도가 떨어지며, 여름철에 우수한 딥러닝 모델 성능을 보여준다(Figure 22). 모델 입력자료의 정확도에 따른 딥러닝 모델의 성능이 개선되기 때문에 향후 ECMWF와 같은 예측성능이 뛰어난 모델 입력자료를 활용한다면 개발된 ConvLSTM모델의 정확도 개선에 도움이 될 것이다.



Figure 114. RMSE of prediction by ConvLSTM model.

더불어 계절내 모델 MME를 적용한다면 보다 정확도 높은 결과값을 제공할 것으로 판단되며, ECMWF등과 같이 모델 입력자료에 의한 민감도 분석이 연구되어야 한다. 또한 차년도에서는 ConvLSTM의 파이프라인이 완성되었기에 파라미터 최적화를 통한 정확도 향상이 기대되며, 컴퓨팅 능력 부족으로 적용하지 못한 확장된 배열의 지역의 입력값과 더불어 보다 깊게 레이어층을 결합한다면 보다 정확도 높은 딥러닝 모델 개발 및 결과값이 산출가능할 것으로 판단된다.

8. 요약 및 결론

가. 요약 및 결론

유사한 기후 특성을 기반으로 하는 지역 규모에서 기후 전망이나 해석을 위해서는 지역 특화형 선도 기후예측 기술 개발이 이루어져야 한다. MME 계절기후예측의 예측성 근간은 앙상블에 참여하는 개별모델의 성능에 크게 의존하는데, 참여 모델 자체의 성능 개선은 센터 내에서는 수행하기 어려우며 모형 운영 기관의 모델 향상 계획에 전적으로 의존한다. 또한, 계절기후예측에서는 월별 자료만 제공하는 등 자료 가용성에 대한 한계가 존재한다. 따라서 센터 내 수집된 다중모델 자료를 바탕으로 기후예측 자료를 분석 및 해석하고, 다양한 통계적 기법을 적용하여 예측성 향상을 위한 계절 및 계절내 기후예측 기술을 개발하고자 하였다. 이 과정은 “지역특화형 선도 기후예측 기술 개발”을 최종목표로 하는 5단계 아태사업으로 총 2019년부터 2021까지 3년 동안 수행된다. 1차년도에 구축된 지역 맞춤형 계절 MME 및 계절내 MME 기후예측 기술 개발 체계를 기반으로, 2차년도인 2020년 당해연도에는 지역 맞춤형 계절 MME 및 계절내 MME 기후예측 기술 개발을 목표로 하였다.

특히 2020년에는 동아시아 지역을 중점 연구지역으로 설정하고 지역별 특화된 다중모형 기반 계절/계절내 예측 기술을 개발하였다. 다음 4가지 중점 사항을 통해서 계절/계절내 예측성 향상을 수립하고자 하였다.

- (1) 예측성 향상을 위한 다중모델 기반의 지역 특화 계절 예측 보정 기술 개발 및 제안,
- (2) 계절내 예측의 예보관 활용을 위한 가이드라인 개발 및 제안,
- (3) 딥러닝을 활용한 계절내 강수, 최저/최고기온 예측 MME 기법 개발,
- (4) 계절내 예측의 오차 저감

이 과제에서는 예측 시간 규모 및 예측자료의 유용성 등을 고려하여, (1) 예측성 향상을 위한 다중모델 기반 계절 예측 기술개발 및 (2) 다중모델 계절내 예측 기법 기술 개발로 구분하여 연구를 진행하고자 하였다. (1)을 위해서는 (가) 물리현상 기반의 앙상블모델 재구성, (나) 정규화기법을 활용한 다중모델 기반 통계예측모델 개발, (다) 베イズ 접근법에 의한 다중모델 앙상블 기법 개발, (라) Probability Anomaly Correlation (PAC)를 통한 확률적 기후예측 보정을 수행, (2)을 위해서는 딥러닝을 활용한 계절내 예측 강수, 최고·최저 기온의 MME 기법 개발 및 계절내 예측의 오차 저감 연구를 수행하였다.

(1) 앙상블 재구성을 위한 물리현상

1차 년도인 2019년에는 “지역 맞춤형 계절 다중모델앙상블 기후예측 기술 개발을 위한 체계가 구축” 되었으며, 이는 물리현상 기반의 앙상블 재구성을 통한 지역특화 계절 예측기술 개발을 통해서 그 체계가 마련되었다. 참여모델의 지역별 예측성능 평가 및 차별화된 MME 구성을 위해서 APCC MME 기후예측에 참여하는 모델의 후보자료(1982-2005)를 바탕으로 SST, 강수량 및 지표면온도의 예측성능이 분석되었다. 엘니뇨-남방진동의 복잡성과 그 원격상관의 예측

성능을 진단하고, 지역 기후예측을 향상시키기 위한 물리적 인자로 사용하였다. 모델 선택의 효과는 계절 및 지역에 따라 달랐다. 물리현상 기반의 앙상블 재구성을 통해 Non-mature phase of ENSO 계절 동안 동아시아-호주 몬순지역 강수량의 계절 예측성능이 향상됨을 발견하였다.

2020년 당해 연도는 전체 연구사업의 2차 년도로 1차 년도에 구축된 기술 개발 체계를 바탕으로, 지역 맞춤형 계절 MME 기후예측 기술을 개발하고자 한다. 따라서 1차 년도에 개발된 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술을 개선하고 그 예측성을 검증하고자 한다. 과제 수행 1년차에는 APCC 6개월 계절예측 현업 기준으로 MME version 1에 참여 중인 개별 기후모델을 바탕으로 연구가 진행되었다. 과제 2년차인 당해 연도 중반에 현업 운영 중인 APCC 6개월 계절예측이 공식적으로 MME version 2로 변경되었다. 따라서 현업 활용성을 제대로 평가하기 위해서 다양한 기후 자료의 기후예측성능 검증을 통한 안정성 평가가 수행되었다. 또한 1차 년도에는 모델의 충실성을 판단하기 기후 인자로 ENSO만을 고려하고 여러 대상 지역에 적용하여 결정론적 MME 예측기술을 개발하고 평가하였으나, 2차 년도에는 대상 지역을 동아시아로 특화하고 기후 인자를 추가로 발굴하여 ENSO와 함께 적용하여 확률론적 MME 예측기술을 개발하고 평가하였다.

먼저 1차 년도에 기 수행된 연구 성능에 대한 안정성 검증을 수행하였다. 즉 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 예측성능 안정성 평가를 위해 과거예측기간 (1982-2005년)에 대한 예측성능의 정상성 검증을 수행하였다. 과거예측기간 자료를 훈련기간(1982-1993, 12년)과 검증기간(1994-2005, 12년)으로 나누어 분석한 결과, 두 기간 모두 재구성된 앙상블 예측의 예측성능이 우수하고 특이점이 나타나지 않아 예측성이 안정적인 것을 알 수 있었다. 두 지역의 강수예측 성능의 전체 시계열은 지역이나 MME에 상관없이 어떠한 추이도 나타나지 않으며, ADF 검정을 통한 유의성 검정 수행 결과 1% 유의 수준에서 통계적으로 안정적임을 알 수 있었다. 이러한 통계 검정을 일반화하기 위해서, MME1과 MME2를 바탕으로 과거 예측 기간의 차이와 사용 모델의 차이를 제대로 평가하기 위한 세 가지 버전 (V2019, V2019*, V2020)의 과거기후예측 자료 및 실시간 기후예측자료를 생산하였다. 이를 바탕으로 예측 성능 검증 및 예측성 향상을 확인하였다. 예측성능의 안정성을 평가하기 위해서 다음 세 가지 주안점을 바탕으로 평가하였고, 그 결과를 요약하면 아래와 같다.

1. 과거기후 예측기간 (1982-2005년)에 대해서 cross-validation을 통해 예측력 재평가 - 과거기후 예측기간에 대한 평균 예측력이 교차검정 된 과거기후 예측기간의 예측성능 분포 범위 내에 존재하였다. 따라서 통계 분석 결과가 독립된 자료(independent data)에 대해서 일반화 할 수 있음을 알 수 있었
2. 실시간예측기간(2006년 이후~)에 대한 예측력 평가 - 과거기후 예측기간 내에 구축된 모델 선별 과정을 실시간 예측자료에 적용 시에도 예측 성능 개선이 유지, 이를 통해 물리현상 기반의 앙상블모델 재구성을 통한 지역특화 계절 예측기술의 안정성을 확인하였다
3. 2020년 현업기준에 따른 과거예측기간에 대한 재평가 - 세 가지 버전의 과거기후 예측자료에 물리현상기반의 앙상블모델 재구성 적용한 결과 물리현상기반의 앙상블모델 재구성은 사용된 자료 및 과거기후 예측기간에 상관없이 예측력 개선에 기여함을 알 수 있었

다.

2020년 당해 연도는 동아시아 강수예측을 좀 더 향상시키기 위해서, 동아시아 강수 변동성과의 물리적 관련성 및 모델 내 재현성을 바탕으로 열대태평양 강수 변동을 추가 기후인자로 발굴하였다. ENSO 및 서태평양 강수를 기준으로 각각 선별된 모델을 바탕으로 MME를 구성, 이를 합성한 새로운 확률 MME 예측 시스템을 개발 하였다. 이렇게 구성된 확률 MME 예측은 가용한 모든 모델을 바탕으로 한 기존의 MME에 비해서 카테고리 검증 측면에서 좀 더 예측성이 개선된 결과를 보였다. 또한 예측 검증의 기준을 기후값으로 하든 표준 예측 시스템 (기존의 MME)으로 하든 예측성능이 개선된 결과를 보여 줌으로써, 물리현상을 바탕으로 한 앙상블 재구성이 지역 특화 계절 예측 성능 향상을 위한 방안임을 증명하였다.

(2) 정규화기법을 활용한 다중모델 기반 통계예측모델 개발

기존 MME 기법은 중위도 이상 지역에서는 예측성능이 낮은 특징이 있다. 또한, 널리 사용되는 회귀모형은 표본수가 충분하지 못한 자료 특성이 있어 과적합(overfitting)의 문제를 내포하고 있다. 본 연구에서는 계절예측자료의 자료크기가 충분하지 않아 발생하는 과적합을 해결하기 위해 정규화 기법을 사용한 다중모델기반 계절예측회귀모형을 개발하였다.

정규화 기법은 수식적인 정의는 최소제곱법에 벌점항을 도입하는 것이며, 본 연구에서는 LASSO 회귀를 이용하여 계절예측회귀모형을 구축하고 분석하였다. 관측값/개별모형별 EOF 분석을 수행하여 산정한 PC 시계열을 이용하여 계절예측회귀모형 구축하였다. 교차검증을 수행하여 모형의 훈련, 매개변수 선택, 평가를 수행하였다.

2월 강수량을 대상으로 정규화 기법(LASSO 회귀)을 이용하여 PC를 추정된 결과, PC 시계열이 전반적으로 회귀분석, SCM에 비해 OBS와 유사한 경향을 보여주고 있다. RMSE 기준으로 회귀분석, SCM 대비 상당히 개선되었다. 정규화 기법 (LASSO)를 이용하여 추정된 PC를 월강수량으로 변환하여 ACC를 산정한 결과, 전반적으로 일부 연도를 제외하고는 SCM 대비 LASSO의 ACC가 개선된 것으로 분석되었다. 현업에서 사용하는 Time-averaged ACC를 산정하면 SCM 대비 10.052% 개선되었다.

계절 강수량을 대상으로 정규화 기법(LASSO 회귀)을 이용하여 PC를 추정된 결과, PC 시계열이 전반적으로 회귀분석(lm), SCM에 비해 OBS와 유사한 경향을 보여주었다. 특히, JFM, FMA, AMJ, MJJ, JJA, JAS, ASO, SON 계절을 살펴보면 회귀분석(lm) 결과가 관측자료와 큰 차이가 발생하는 연도가 존재하는데 비해 정규화 기법은 이러한 차이를 보정하여 관측자료와 유사한 경향을 나타내고 있다. RMSE기준으로 정규화 기법(LASSO 회귀) 기반 PC 시계열 추정 결과는 회귀분석(lm) 대비 전계절에 걸쳐 상당히 개선되었고, SCM 대비 JFM, FMA, MAM, NDJ, DJF 계절에 상당히 개선되었다. 정규화 기법 (LASSO)을 이용하여 추정된 PC를 계절 강수량으로 변환하여 ACC를 산정한 결과, 회귀분석(lm)과 비교하면 중간값을 기준으로 특정 계절(JJA, JAS, ASO)을 제외하고는 정규화 기법(LASSO 회귀)의 ACC가 개선되거나 비슷한 것으로 분석되었다. SCM과 비교하면 중간값을 기준으로 JFM, MAM, OND, NDJ, DJF 계절에서 정규화 기법(LASSO 회귀)의 ACC가 개선된 것으로 분석되었다.

(3) 베이지 접근법에 의한 다중모델 앙상블 기법 개발

다중모델앙상블에 참여하는 기후 모델의 예측을 기반으로 관측의 특성을 반영한 예측 정보를 생산하기 위하여 베이지 접근법에 기반 한 회귀를 이용한 후처리 방안을 채택하였다. 이 과정에서 모형의 안정성을 향상시키기 위하여 앞서 설명한 정규화 기법(능형 회귀)을 도입하였다. 한편으로는 입력 정보와 출력 정보의 정합성을 위하여 예측 대상 출력 격자와 기후 모델의 입력 격자를 통일시키는 격자 기반 후처리를 적용하였다.

위와 같이 구성한 정규화 기법을 적용한 베이지 후처리 기법을 통하여, 과거 재현 자료의 교차 검증을 실시한 결과, 일부 기간 및 일부 지역(특히 가을철 해양)에서는 Heidke Skill Score 로 정의한 예측 성능의 향상이 나타나기도 하였다. 그러나 고위도 지역의 대륙 격자에서는 성능 향상이 미미하거나 예측성의 분포가 불안정해지는 모습이 관찰되었다. 격자 기반 후처리의 경우, 해당 격자의 낮은 기후 모델 예측성이 적함에 부정적인 영향을 미치는 것으로 보인다. 따라서, 추후 연구를 통해 모형 결과 통계량(MOS; Model Output Statistics)을 적극 활용하여 역학 모델의 예측 성능이 비교적 높은 것으로 알려진 열대 해양의 정보 등을 이용하는 방법을 고려해볼 수 있을 것으로 보인다.

한편으로는 겨울철 과거 재현 예측 및 실시간 예측에서 베이지 후처리가 예측 분산을 과소 모의하는 현상이 발견되었다. 분산 추정의 정확도를 높이고 실제 현업 운영에 문제가 없도록 예측 사후 분포를 추가 보정하는 방법도 고려해야할 것으로 보인다.

(4) Probability Anomaly Correlation (PAC)를 통한 확률적 기후예측 보정

본 연구에서는 PAC 통계적 후보정 기법을 통해 동아시아 지역을 대상으로 APCC PMME의 예측성을 개선하는 것이 가능한지 조사하였다. 결과적으로 PAC 후보정 적용에 대한 뚜렷한 시공간적 패턴을 확인할 수 없었으며, 전반적으로 PAC 후보정 적용 이후 예측성이 오히려 낮아지는 시기(월)이 대부분임을 HSS 평균값 차이를 통해 확인하였다. 추가적인 분석을 통해 방법론 적용의 적절성이나 정확성이 판단될 필요가 있지만, 동아시아 지역에 대한 PAC 후보정은 APCC PMME의 예측성을 개선하지 못함을 확인하였다.

(5) 딥러닝 기반 계절내 예측기후 오차 저감 기법

본 연구에서는 개별 기후모델을 6개(ECMWF, MSC, NCEP, KMA, UKMO, CMA)로 확대하여 계절내(Sub-seasonal to seasonal, 이하 S2S) 예측 자료를 생성하고, 이들을 결합하여 다중모델 앙상블(multi-model ensemble, 이하 MME) 기반의 S2S 예측 자료를 구축할 수 있는 방법을 개발하였다. 또한 구축된 한반도 영역 내의 S2S 예측 자료의 최고기온 및 최저기온과 강수에 적용된 딥러닝 기법의 예측 성능을 평가함으로써, 결과적으로 MME 기반의 S2S 입력자료 구축, 딥러닝 알고리즘의 최적화 기법 개발 및 예측 성능 비교 평가가 수행되었다. 따라서 구축된

MME 기반의 S2S 예측 자료에 장단기기억기술(이하 LSTM)을 적용한 자료와 ERA-Interim 재분석 자료를 통해 평가한 결과, 전체 선행예측시간의 일별 예측성의 경우 3개 예측기후 변수(강수, 최고 및 최저기온) 모두에서 평방근제곱근오차(Root Mean Square Error, 이하 RMSE)는 감소되었고, 편차상관계수(Anomaly Correlation Coefficient, 이하 TCC)는 향상되었다. 선행주수별 주평균에 대한 예측 성능 평가의 경우, 3개 예측기후 변수의 3-4주의 RMSE 및 TCC에서 개선을 보였다. 특히, 기온에서 월등하게 개선되었으며, LSTM 알고리즘 최적화에 의해 MME 기반의 3-4주 S2S 예측 성능 개선이 지속되었다. 따라서 MME 기반의 S2S 예측 자료와 딥러닝 기법 적용을 통해 3-4주 S2S 예측기후의 예측력이 향상됨을 확인하였다. S2S 예측 자료의 예측 성능 향상을 위한 MME 기반의 S2S 예측 자료 구축과 LSTM 적용 기술에 대해 다음과 같이 요약하였다.

1. 계절내 기후의 예측빈도 및 기간이 다른 다수의 기후모델(ECMWF, MSC, KMA, UKMO, CMA, NCEP)의 S2S 예측 자료를 통합하는 앙상블 기법을 통해 한반도 계절내 MME 예측기후 자료를 생산하고 딥러닝 훈련 기법을 적용하는 프레임워크를 구축하였다.
2. 선행예측 전체 기간(예, 60일 및 약 40일)에 대한 예측성 개선 평가 결과, 예측기후 변수 3개(최고기온 및 최저기온, 강수) 모두에서 RMSE의 감소가 나타났으며, 최고기온과 강수에서 TCC의 향상이 뚜렷하였다.
3. 선행주수별 예측성 개선의 경우, 3개 예측기후 변수 모두에서 MME 기반 S2S의 예측성이 향상되었는데, 특히 예측성 개선 타겟인 3~4주에서 뚜렷한 예측성 향상이 나타났다. 또한 대부분의 계절에서 3~4주의 MME 기반 S2S의 오차 감소가 확인되었다.
4. 따라서, 구축된 MME 기반의 계절내 예측기후 자료에 딥러닝 훈련기법 적용을 통해 3-4주 S2S 예측기후의 예측 성능이 개선될 수 있을 것으로 기대한다.

올해 연구는 한반도의 MME 기반 S2S 예측기후 자료에 LSTM을 적용한 것이었다. 그러나 신경망(neural network) 연구 분야에서는 신경망 모델의 높은 분산을 줄이기 위해, 단일 신경망 모델 대신 여러 신경망 모델로부터 학습시키고, 그 예측값을 결합하는 앙상블 학습 기법이 많이 활용되고 있다(Di et al. 2019). 또한, 본 연구는 한반도 내의 독립된 격자들의 시계열 자료인데, 기후학적으로 대기의 이동이 고려된 온전한 한반도 및 주변 예측 기후 정보를 구축하기 위해서는 동아시아로 확장된 기후 정보를 가진 다중 시계열 격자 정보로 확대되어 딥러닝 알고리즘에 입력될 필요가 있다. 최근 Convolution LSTM을 S2S 예측 자료에 적용하는 연구가 활발히 진행되고 있다(Shi et al. 2015; Wang et al. 2019; Yan et al. 2020; Chattopadhyay et al. 2020). 따라서 향후 한반도 주변 대기 이동을 고려한 동아시아로 확장된 MME 기반의 S2S 예측기후 입력 자료의 구축이 필요하고, 여기에 신경망 앙상블 학습 기법을 적용하여 신경망 앙상블 기반의 MME S2S 예측 성능 개선의 고도화가 필요하다.

(6) 격자기반 계절내 예측 딥러닝 기법 개발

동아시아 지역의 정확도 높은 계절내 예측자료 생산을 위하여 격자기반 딥러닝 프레임

ConvLSTM 및 피쳐 엔지니어링 기법을 구축하였다. 격자자료는 GloSea5의 다양한 변수를 PC기반에서 계산이 가능한 9×9배열로 1991년 1월부터 2010년 12월까지 1°의 공간해상도로 자료를 구축하였다. 테스트셋과 한반도 지점 LSTM기법과의 비교분석을 위하여 재분석자료 ERA-Interim을 GloSea5와 같은 시공간해상도 자료로 전처리 하였다.

LSTM기법에 입력자료 변환, dropout, 배치사이즈 등의 민감도 분석을 통하여 피쳐 엔지니어링을 적용한 결과 강수의 RMSE 비교분석 결과는 선행시간 3~4주에서 성능이 25%로 개선이 되었고, 최대기온은 RMSE가 LSTM단독기법과 거의차이가 없었으나, 최소온도에 있어 LSTM에 피쳐엔지니어링을 적용한 결과값은 리드타임별로 대략 10%의 성능이 향상이 있었다.

ConvLSTM의 격자화된 GloSea5의 합성곱 LSTM을 한반도 지점에 적용결과 최대온도는 LSTM과 피쳐엔지니어링을 적용한 결과와 거의 같았으며, 최소온도의 RMSE 비교결과 2.75에서 2.68로 정확도가 개선이 되었다.

GloSea5 단독 모델에 대한 ConvLSTM 딥러닝 프레임워크를 개발하였으며, ECMWF와 같이 정확도 높은 계절내 예측모델을 적용한다며 보다 성능개선이 될 것이다. 또한 다양한 머신러닝 및 딥러닝 모델을 하이브리드 기법으로 결합시켜 계절내 예측자료의 정확도 개선의 딥러닝 한 기법으로 활용이 가능하며, 컴퓨팅의 전산자원이 확충되어 보다 레이어를 깊고 확장된 격자화의 입력자료으로 훈련이 된다면 계절내 예측자료의 정확도 개선 및 기후분야의 기초자료로 활용할 수 있다.

나. 연구개발결과의 활용 방안 및 기대성과

이 연구는 2019년부터 2021까지 수행되는 다년도 과제로, 현재까지 “지역 맞춤형 계절 MME 및 계절내 MME 기후예측 기술 개발”을 완료하였다. 차 년도에는 이를 발판으로 “다중 모델 기반의 지역특화 계절예측시스템 구축 및 계절내예측 기반기술 고도화”를 마무리하고, 최종적으로 “지역특화형 선도 기후예측 기술 개발”을 하고자 한다. 이 연구개발결과는 크게 다음의 과학적·기술적 측면과 경제적·사회적 측면으로 활용 가능하다.

(1) 과학적·기술적 성과

1. 동아시아 지역에 특화된 MME 기반 기후예측 기술 개발 및 예측 향상에 기여, 신뢰도 높은 예측자료 제공
2. 한반도 내 3-4주 계절내 예측오차 저감 기술 개발 및 방향 제시
3. 계절내 예측 기술과 딥러닝 기술 융합에 기여

(2) 경제적·사회적 성과

1. 세계기상기구의 계절예측 실효성 제고 방안인 지역 규모 계절 예측 생산 및 활용에 대한 권

고사항 준수

2. 1개월(4주) 전망에 보조 자료로써 제공
3. 인공지능 예보에 계절내 예측 기술 참여 및 확대
4. 기후 빅데이터 활용 및 딥러닝 기술 확대를 통한 그린뉴딜 정책의 선도적 이행에 기여

따라서 궁극적으로 이러한 선도적 기술 개발을 통해서 동아시아 계절 및 계절내 기후예측과 그 향상에 기여할 것으로 기대한다.

사사

본 연구는 APCC의 지원을 통해 수행되었습니다.

References

- Abdel-Aal, R. E., and M. A. Elhadidy, 1995: Modeling and Forecasting the Daily Maximum Temperature Using Abductive Machine Learning. *Weather Forecast.*, **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..)
- Abrahamsen, E., O. M. Brastein, and B. Lie, 2018: Machine Learning in Python for Weather Forecast based on Freely Available Weather Data. *Proceedings of The 59th Conference on imulation and Modelling (SIMS 59)*, 26–28 September 2018, Oslo Metropolitan University, Norway, **153**, 169–176, DOI: 10.3384/ecp18153169.
- Ashok, K., S. K. Behera, S. A. Rao, H. Weng, and T. Yamagata, 2007: El Niño Modoki and its possible teleconnection. *J. Geophys. Res. Ocean.*, **112**, <https://doi.org/10.1029/2006JC003798>.
- Ashok, K., C.-Y. Tam, and W.-J. Lee, 2009: ENSO Modoki impact on the Southern Hemisphere storm track activity during extended austral winter. *Geophys. Res. Lett.*, **36**, L12705, <https://doi.org/10.1029/2009GL038847>.
- Best, M. J., and Coauthors, 2011: The Joint UK Land Environment Simulator (JULES), model description – Part 1: Energy and water fluxes. *Geosci. Model Dev.*, **4**, 677–699, <https://doi.org/10.5194/gmd-4-677-2011>.
- Brown, A., S. Milton, M. Cullen, B. Golding, J. Mitchell, and A. Shelly, 2012: Unified modeling and prediction of weather and climate: A 25-year journey. *Bull. Am. Meteorol. Soc.*, **93**, 1865–1877, <https://doi.org/10.1175/BAMS-D-12-00018.1>.
- Chattopadhyay, A., P. Hassanzadeh, and S. Pasha, 2020: Predicting clustered weather patterns: A test case for applications of convolutional neural networks to spatio-temporal climate data. *Sci. Rep.*, **10**, 1317, <https://doi.org/10.1038/s41598-020-57897-9>.
- Chen, W., J. Feng, and R. Wu, 2013: Roles of ENSO and PDO in the link of the east asian winter monsoon to the following summer monsoon. *J. Clim.*, **26**, 622–635, <https://doi.org/10.1175/JCLI-D-12-00021.1>.
- de Andrade, F. M., C. A. S. Coelho, and I. F. A. Cavalcanti, 2019: Global precipitation hindcast quality assessment of the Subseasonal to Seasonal (S2S) prediction project models. *Clim. Dyn.*, **52**, 5451–5475, <https://doi.org/10.1007/s00382-018-4457-z>.
- Dee, D., and National Center for Atmospheric Research Staff (Eds), Last modified 31 Oct 2019. “The Climate Data Guide: ERA-Interim.” Retrieved from <https://climatedataguide.ucar.edu/climate-data/era-interim> (Accessed December 29, 2020).

- DelSole, T., and A. Banerjee, 2017: Statistical seasonal prediction based on regularized regression. *J. Clim.*, **30**, 1345–1361, <https://doi.org/10.1175/JCLI-D-16-0249.1>.
- Delsole, T., L. Jia, and M. K. Tippett, 2013: Scale-selective ridge regression for multimodel forecasting. *J. Clim.*, **26**, 7957–7965, <https://doi.org/10.1175/JCLI-D-13-00030.1>.
- Di, Q., and Coauthors, 2019: An ensemble-based model of PM_{2.5} concentration across the contiguous United States with high spatiotemporal resolution. *Environ. Int.*, **130**, 104909, <https://doi.org/https://doi.org/10.1016/j.envint.2019.104909>.
- Dibike, Y. B., and P. Coulibaly, 2006: Temporal neural networks for downscaling climate variability and extremes. *Neural Networks*, **19**, 135–144, <https://doi.org/https://doi.org/10.1016/j.neunet.2006.01.003>.
- Donahue, J., L. A. Hendricks, M. Rohrbach, S. Venugopalan, S. Guadarrama, K. Saenko, and T. Darrell, 2017: Long-Term Recurrent Convolutional Networks for Visual Recognition and Description. *IEEE Trans. Pattern Anal. Mach. Intell.*, **39**, 677–691, <https://doi.org/10.1109/TPAMI.2016.2599174>.
- Dueben, P. D., and P. Bauer, 2018: Challenges and design choices for global weather and climate models based on machine learning. *Geosci. Model Dev.*, **11**, 3999–4009, <https://doi.org/10.5194/gmd-11-3999-2018>.
- Feng, J., W. Chen, C. Y. Tam, and W. Zhou, 2011: Different impacts of El Niño and El Niño Modoki on China rainfall in the decaying phases. *Int. J. Climatol.*, **31**, 2091–2101, <https://doi.org/10.1002/joc.2217>.
- Ham, Y. G., J. H. Kim, and J. J. Luo, 2019: Deep learning for multi-year ENSO forecasts. *Nature*, **573**, 568–572, <https://doi.org/10.1038/s41586-019-1559-7>.
- Haupt, S. E., J. Cowie, S. Linden, T. McCandless, B. Kosovic, and S. Alessandrini, 2018: Machine learning for applied weather prediction. *Proceedings - IEEE 14th International Conference on eScience, e-Science 2018*, 276–277.
- Hernández, E., V. Sanchez-Anguix, V. Julian, J. Palanca, and N. Duque, 2016: Rainfall Prediction: A Deep Learning Approach. *Hybrid Artificial Intelligent Systems*, F. Martínez-Álvarez, A. Troncoso, H. Quintián, and E. Corchado, Eds., Cham, Springer International Publishing, 151–162.
- Hochreiter, S., and J. Schmidhuber, 1997: Long Short-Term Memory. *Neural Comput.*, **9**, 1735–1780, <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Hoskins, B. J., and D. J. Karoly, 1981: The steady linear response of a spherical atmosphere to thermal and orographic forcing. *J. Atmos. Sci.*, **38**, 1179–1196,

[https://doi.org/10.1175/1520-0469\(1981\)038<1179:TSLROA>2.0.CO;2](https://doi.org/10.1175/1520-0469(1981)038<1179:TSLROA>2.0.CO;2).

- Hunke, E. C., and W. H. Lipscomb, 2008: the Los Alamos sea ice model documentation and software user' s manual, Version 4.0, LA-CC-06-012, Los Alamos National Laboratory, N.M.
- Janowiak, J. E., 1999: CAMS-OPI: A global satellite-rain gauge merged product for real-time precipitation monitoring applications. *J. Clim.*, **12**, 3335-3342, [https://doi.org/10.1175/1520-0442\(1999\)012<3335:COAGSR>2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)012<3335:COAGSR>2.0.CO;2).
- Jo, S., Y. Lim, J. Lee, H. S. Kang, and H. S. Oh, 2012: Bayesian regression model for seasonal forecast of precipitation over korea. *Asia-Pacific J. Atmos. Sci.*, **48**, 205-212, <https://doi.org/10.1007/s13143-012-0021-7>.
- Johnson, N. C., D. C. Collins, S. B. Feldstein, M. L. L'heureux, and E. E. Riddle, 2014: Skillful wintertime North American temperature forecasts out to 4 weeks based on the state of ENSO and the MJO. *Weather Forecast.*, **29**, 23-38, <https://doi.org/10.1175/WAF-D-13-00102.1>.
- Jolliffe, I. T., and D. B. Stephenson, Eds., 2011: Forecast Verification: A Practitioner' s Guide in Atmospheric Science. 2nd Edition. John Wiley & Sons, 292 pp.
- Karevan, Z., and J. A. K. Suykens, 2020: Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, **125**, 1-9, <https://doi.org/https://doi.org/10.1016/j.neunet.2019.12.030>.
- Kim, M.-K., I.-S. Kang, C.-K. Park, and K.-M. Kim, 2004: Superensemble prediction of regional precipitation over Korea. *Int. J. Climatol.*, **24**, 777-790, <https://doi.org/10.1002/joc.1029>.
- Kurth, T., and Coauthors, 2018: Exascale deep learning for climate analytics. *SC18: International Conference for High Performance Computing, Networking, Storage and Analysis*, IEEE, 649-660.
- LeCun, Y., Y. Bengio, and G. Hinton, 2015: Deep learning. *Nature*, **521**, 436-444, <https://doi.org/10.1038/nature14539>.
- Li, R. K. K., C. Y. Tam, N. C. Lau, S. J. Sohn, and J. B. Ahn, 2020: Potential predictability of the Silk Road pattern and the Role of SST as inferred from seasonal hindcast experiments of a coupled climate model. *J. Clim.*, **33**, 9567-9580, <https://doi.org/10.1175/JCLI-D-20-0235.1>.
- Li, S., and A. W. Robertson, 2015: Evaluation of submonthly precipitation forecast skill from global ensemble prediction systems. *Mon. Weather Rev.*, **143**, 2871-2889, <https://doi.org/10.1175/MWR-D-14-00277.1>.

- Lim, Y., S. Jo, J. Lee, H.-S. Oh, and H.-S. Kang, 2012: An improvement of seasonal climate prediction by regularized canonical correlation analysis. *Int. J. Climatol.*, **32**, 1503–1512, <https://doi.org/10.1002/joc.2368>.
- Lim, Y., S. Jo, J. Lee, H.-S. Oh, S.-G. Lee, Y. Park, and H.-S. Kang, 2014: Multimodel ensemble forecasting of rainfall over East Asia: regularized regression approach. *Int. J. Climatol.*, **34**, 3720–3731, <https://doi.org/10.1002/joc.3938>.
- Maclachlan, C., and Coauthors, 2015: Global Seasonal forecast system version 5 (GloSea5): A high-resolution seasonal forecast system. *Q. J. R. Meteorol. Soc.*, **141**, 1072–1084, <https://doi.org/10.1002/qj.2396>.
- Michaelsen, J., 1987: Cross-Validation in Statistical Climate Forecast Models. *J. Clim. Appl. Meteorol.*, **26**, 1589–1600, [https://doi.org/10.1175/1520-0450\(1987\)026<1589:cviscf>2.0.co;2](https://doi.org/10.1175/1520-0450(1987)026<1589:cviscf>2.0.co;2).
- Nair, A., G. Singh, and U. C. Mohanty, 2018: Prediction of Monthly Summer Monsoon Rainfall Using Global Climate Models Through Artificial Neural Network Technique. *Pure Appl. Geophys.*, **175**, 403–419, <https://doi.org/10.1007/s00024-017-1652-5>.
- Neelin, J. D., and M. Latif, 1998: El Niño dynamics. *Phys. Today*, **51**, 32–36, <https://doi.org/10.1063/1.882496>.
- Nooteboom, P. D., Q. Y. Feng, C. López, E. Hernández-García, and H. A. Dijkstra, 2018: Using network theory and machine learning to predict *El Niño*. *Earth Syst. Dyn.*, **9**, 969–983, <https://doi.org/10.5194/esd-9-969-2018>.
- Ortiz-García, E. G., S. Salcedo-Sanz, C. Casanova-Mateo, A. Paniagua-Tineo, and J. A. Portilla-Figuera, 2012: Accurate local very short-term temperature prediction based on synoptic situation Support Vector Regression banks. *Atmos. Res.*, **107**, 1–8, <https://doi.org/https://doi.org/10.1016/j.atmosres.2011.10.013>.
- Paniagua-Tineo, A., S. Salcedo-Sanz, C. Casanova-Mateo, E. G. Ortiz-García, M. A. Cony, and E. Hernández-Martín, 2011: Prediction of daily maximum temperature using a support vector regression algorithm. *Renew. Energy*, **36**, 3054–3060, <https://doi.org/https://doi.org/10.1016/j.renene.2011.03.030>.
- Park, J., H.-S. Kang, Y.-K. Hyun, and T. Nakazawa, 2018: Predictability of the Arctic Sea Ice Extent from S2S Multi Model Ensemble. *Atmosphere (Basel)*, **28**, 15–24, <https://doi.org/10.14191/Atmos.2018.28.1.015>.
- Poornima, S., and M. Pushpalatha, 2019: Prediction of rainfall using intensified LSTM based recurrent Neural Network with Weighted Linear Units. *Atmosphere (Basel)*, **10**, <https://doi.org/10.3390/atmos10110668>.

- Pradhan, P. K., B. Preethi, K. Ashok, R. Krishnan, and A. K. Sahai, 2011: Modoki, Indian Ocean Dipole, and western North Pacific typhoons: Possible implications for extreme events. *J. Geophys. Res.*, **116**, D18108, <https://doi.org/10.1029/2011JD015666>.
- Ramesh, K., and R. Anitha, 2014: MARSpline model for lead seven-day maximum and minimum air temperature prediction in Chennai, India. *J. Earth Syst. Sci.*, **123**, 665–672, <https://doi.org/10.1007/s12040-014-0434-z>.
- Rasp, S., M. S. Pritchard, and P. Gentine, 2018: Deep learning to represent subgrid processes in climate models. *Proc. Natl. Acad. Sci.*, **115**, 9684, <https://doi.org/10.1073/pnas.1810286115>.
- Reynolds, R. W., N. A. Rayner, T. M. Smith, D. C. Stokes, and W. Wang, 2002: An improved in situ and satellite SST analysis for climate. *J. Clim.*, **15**, 1609–1625, [https://doi.org/10.1175/1520-0442\(2002\)015<1609:AIISAS>2.0.CO;2](https://doi.org/10.1175/1520-0442(2002)015<1609:AIISAS>2.0.CO;2).
- Salcedo-Sanz, S., R. C. Deo, L. Carro-Calvo, and B. Saavedra-Moreno, 2016: Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms. *Theor. Appl. Climatol.*, **125**, 13–25, <https://doi.org/10.1007/s00704-015-1480-4>.
- Scaife, A. A., and Coauthors, 2014: Skillful long-range prediction of European and North American winters. *Geophys. Res. Lett.*, **41**, 2514–2519, <https://doi.org/https://doi.org/10.1002/2014GL059637>.
- Scaife, A. A., and Coauthors, 2014: Skillful long-range prediction of European and North American winters. *Geophys. Res. Lett.*, **41**, 2514–2519, <https://doi.org/10.1002/2014GL059637>.
- Scaife, A. A., and Coauthors, 2019: Tropical rainfall predictions from multiple seasonal forecast systems. *Int. J. Climatol.*, **39**, 974–988, <https://doi.org/10.1002/joc.5855>.
- Scher, S., and G. Messori, 2018: Predicting weather forecast uncertainty with machine learning. *Q. J. R. Meteorol. Soc.*, **144**, 2830–2841, <https://doi.org/https://doi.org/10.1002/qj.3410>.
- Seow, M. X. C., 2018: A new type of tropical Pacific warming - El Niño Modoki. *Phys. Today*, **71**, 50–52, <https://doi.org/10.1063/PT.3.4092>.
- Shi, X., Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W. Woo, 2015: Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Adv. Neural Inf. Process. Syst.*, **28**, 802–810.
- Simmons, A. J., J. M. Wallace, and G. W. Branstator, 1983: Barotropic wave propagation and instability, and atmospheric teleconnection patterns. *J. Atmos. Sci.*, **40**, 1363–1392, [https://doi.org/10.1175/1520-0469\(1983\)040<1363:BWPAIA>2.0.CO;2](https://doi.org/10.1175/1520-0469(1983)040<1363:BWPAIA>2.0.CO;2).
- Sohn, S. J., Y. M. Min, J. Y. Lee, C. Y. Tam, I. S. Kang, B. Wang, J. B. Ahn, and T.

- Yamagata, 2012: Assessment of the long-lead probabilistic prediction for the Asian summer monsoon precipitation (1983–2011) based on the APCC multimodel system and a statistical model. *J. Geophys. Res. Atmos.*, **117**, <https://doi.org/10.1029/2011JD016308>.
- Sohn, S.-J., J.-B. Ahn, and C.-Y. Tam, 2013: Six month-lead downscaling prediction of winter to spring drought in South Korea based on a multimodel ensemble. *Geophys. Res. Lett.*, **40**, 579–583, <https://doi.org/10.1002/grl.50133>.
- Sohn, S.-J., and W. Kim, 2020: Toward a better multi-model ensemble prediction of East Asian and Australasian precipitation during non-mature ENSO seasons. *Sci. Rep.*, **10**, 20289, <https://doi.org/10.1038/s41598-020-77482-4>.
- Timmermann, A., and Coauthors, 2018: El Niño–Southern Oscillation complexity. *Nature*, **559**, 535–545, <https://doi.org/10.1038/s41586-018-0252-6>.
- van den Dool, H., E. Becker, L. C. Chen, and Q. Zhang, 2017: The probability anomaly correlation and calibration of probabilistic forecasts. *Weather Forecast.*, **32**, 199–206, <https://doi.org/10.1175/WAF-D-16-0115.1>.
- Vitart, F., and Coauthors, 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 Clim. Atmos. Sci.*, **1**, 3, <https://doi.org/10.1038/s41612-018-0013-0>.
- Wang, B., Z. Wu, J. Li, J. Liu, C.-P. Chang, Y. Ding, and G. Wu, How to Measure the Strength of the East Asian Summer Monsoon. *J. Clim.*, **21**, 4449–4463, <https://doi.org/10.1175/2008JCLI2183.1>.
- Wang, Y., H.-L. Ren, F. Zhou, J.-X. Fu, Q.-L. Chen, J. Wu, W.-H. Jie, and P.-Q. Zhang, 2020: Multi-Model Ensemble Sub-Seasonal Forecasting of Precipitation over the Maritime Continent in Boreal Summer. *Atmosphere (Basel)*, **11**, 157–172.
- Wang, Y., Z. Liu, D. Hu, and M. Zhang, 2019: Multivariate Time Series Prediction Based on Optimized Temporal Convolutional Networks with Stacked Auto-encoders. *Proc. Mach. Learn. Res.*, **101**, 157–172.
- Weng, H., K. Ashok, S. K. Behera, S. A. Rao, and T. Yamagata, 2007: Impacts of recent El Niño Modoki on dry/wet conditions in the Pacific rim during boreal summer. *Clim. Dyn.*, **29**, 113–129, <https://doi.org/10.1007/s00382-007-0234-0>.
- Yan, J., L. Mu, L. Wang, R. Ranjan, and A. Y. Zomaya, 2020: Temporal Convolutional Networks for the Advance Prediction of ENSO. *Sci. Rep.*, **10**, 8055,

<https://doi.org/10.1038/s41598-020-65070-5>.

Yihui, D., and J. C. L. Chan, 2005: The East Asian summer monsoon: An overview. *Meteorol. Atmos. Phys.*, **89**, 117-142, <https://doi.org/10.1007/s00703-005-0125-z>.

Zhang, L. X., and T. J. Zhou, 2015: Decadal change of East Asian summer tropospheric temperature meridional gradient around the early 1990s. *Sci. China Earth Sci.*, **58**, 1609-1622, <https://doi.org/10.1007/s11430-015-5117-3>.

Zhang, Q., C. Yu Xu, T. Jiang, and Y. Wu, 2007: Possible influence of ENSO on annual maximum streamflow of the Yangtze River, China. *J. Hydrol.*, **333**, 265-274, <https://doi.org/10.1016/j.jhydrol.2006.08.010>.