

현업 장기예보 정확도 향상을 위한 장기예보 지원체계 정립
Establishment of APCC-KMA collaboration system
for improving operational long-range forecast

김가은, 김옥연, 윤순조, 이성규, 이진영, 이현주, 정유림
기후사업본부 기후분석과

2021.12.

APEC기후센터

평문 초록

우리나라를 포함한 동아시아 지역의 기후변동성 및 기후변화·기후예측에 대한 많은 연구결과들이 제시되고 있지만, 실제 우리나라 월별 기후예측에 적용하기에는 각 연구에 대한 적절한 가공과 해석이 필요합니다. 2019년부터 2021년까지 5단계 사업을 통해 현업장기예보 정확도 향상을 위한 APCC-기상청 협력시스템을 구축하고 이를 바탕으로 장기예보에 실질적으로 기여할 수 있는 아래의 연구성과를 도출하였습니다.

우리나라 장기예보 개선을 위해 이상기후 3개월 장기예보 콘텐츠를 개발하고 이를 효과적으로 나타낼 수 있는 표현방식을 제시하고자 가우시안 프로세스의 기계학습을 통해 이상기후지수의 확률예측정보를 전국 뿐 아니라 북한을 제외한 10개 지역에 대해 생산하였습니다. 또한 여러 모델에서 나오는 방대한 예측결과를 베이지안 모델 평균이나 다중모델 슈퍼앙상블 기법을 이용하여 객관적으로 결합하여 비교적 안정적인 전망정보를 생산하는 방안을 제시하였습니다. 한편, 최근 몇 년에 걸쳐 국내외적으로 인공지능에 대한 관심이 높아지면서 전통적인 컴퓨터 비전분야 뿐만 아니라 농업, 기상, 기후 분야 등 여러 분야에서 딥러닝과 같은 인공지능을 활용한 연구가 활발하게 진행되고 있습니다. 이에 이 연구에서는 동아시아지역 계절내 1개월 예측성을 높이기 위해 ERA-5 T2M 일단위 재분석자료를 활용하여 딥러닝 학습 모델을 설계하고 평가하였습니다. 딥러닝 학습 모델을 기존 수치예보모델의 예보자료와 함께 활용하면 계절내 예측분야에서 예보 2~2주의 예측성을 높이고 현업에서도 활용이 가능할 것으로 판단됩니다.

과거 다수의 연구과제로부터 개발된 통계 예측모델들의 개발시점 대비 현재의 예측성능과 통계모델에서 사용된 예측인자들의 상관관계 변화를 살펴봄으로써 오래된 통계모델들의 활용가능성을 제시하였습니다. 또한 현재 기상청 장기예보를 위해 사용하고 있는 역학 예측모델의 경우, 여타의 모델과 마찬가지로 계통적 오차를 가지고 있으며, 실제 예보를 위해서는 이러한 계통적 오차에 대한 분석과 보정이 필요합니다. 따라서 장기예보 개선을 위해 현업모델이 가지는 오차를 보정하는 방법을 제안하였으며, 이로부터 예측성이 향상됨을 확인하였습니다. 뿐만 아니라, 가장 최신의 여름철 계절내 진동 감시 및 예측 정보를 생산하고, BSISO 대류활동 위치에 따른 우리나라 여름철 기온/강수 변동 특성 정보를 함께 제시함으로써 1개월 여름철 전망 예측성 향상에 기여하고자 하였습니다.

APCC는 2011년부터 각 GPC (Global Producing Centre)에서 생산하는 장기예보 자료를 수집하여 일관된 형태의 GPC 예측자료와 다중모델앙상블 예측자료를 생산·제공하는 ‘one-stop shop’의 역할을 수행하는 WMO 장기예보 선도센터를 운영하고 있습니다. 또한, WMO 장기예보 선도센터 운영의 효율적, 안정적 운영과 회원국의 요구에 부합하는 고품질 기후예측 서비스를 제공하기 위해 시스템 개선 등의 노력을 이어가고 있습니다. 그 결과 WMO 장기예보 선도센터 기후예측 자료의 활용성 증가와 국제 사회에서의 WMO 장기예보 선도센터의 역할과 입지 강화에 기여할 것으로 보입니다. 또한, 앞서 설명한 연구 결과물을 바탕으로 최종 생산한 APCC의 1개월 예측결과는 기후 예측모델 대비 상대적으로 우수한 결과를 보였으며, 예보토의 시 기상청 최종 예측에 반영되어 장기예보 정확도 향상에 이바지하였습니다.

Executive Summary

In this study, 3-month long-range forecast contents on climate extremes in South Korea were developed using a Gaussian Process, which is a non-parametric bayesian machine learning model. Probabilistic forecast information of climate extremes was produced and visualized for South Korea as well as ten regions within South Korea. Four different ways of organizing input data were compared: predictors and their locations as well as times of interest are determined by the long-range forecast guidance, locations of predictors are from the long-range forecast guidance but their times of interest are determined by the correlations between the predictors and climate extreme indices, locations of predictors are determined by clustering the correlation coefficients between the predictors and climate extreme indices, and principal components of CL are used as predictors. Also, various probabilistic forecast results have been integrated based on the Bayesian Model Averaging (BMA). Models with locations of predictors by clustering as well as BMA produced better results overall. We proposed a visualization method of tercile probabilistic forecast results.

As a way to improve predictability of subseasonal forecast in the climatology, five models were designed and evaluated for predictability using U-NET architecture, bi-directional convolutional long short term memory (ConvLSTM), a channel-attention mechanism like squeeze and excitation block, and densely connectivity pattern of DenseNet model. Also, using the best model. In a perspective of an operational system, the applicability of a deep learning-based model was evaluated through subseasonal predictability evaluation of week 3 and 4 with the best model. The models were designed and trained to predict a day with data from the last 14 days using the ERA-5 T2M reanalysis data. Also, the predictability evaluation used anomaly correlation coefficient (ACC). As a result, the model 4 applying bi-directional ConvLSTM, a channel-attention mechanism like squeeze and excitation block, and densely connectivity pattern of DenseNet model to U-NET architecture showed the best predictability. The predictability of the model 4 showed lower than ECMWF forecast data, but a result of the seasonal evaluation showed higher predictability when the week 3 forecast data is in autumn (SON, September-October-November). And in the seasonal predictability of week 4, the week 4 forecast data of the model 4 in spring (MAM, March-April-May) and winter (DJF, December-January-February) was lower predictability than the ECMWF forecast data, but other seasons showed similar predictability. Therefore, it is conducted that the proposed deep learning-based model in this study can be helpful to improve the predictability of subseasonal forecast.

The systematic error characteristics of GloSea5 anomalies operationally used in KMA is different from that of the raw forecast values of its model. When making a forecast based on the anomalies as we operationally do, this cause wrong forecasts in real-time forecast. Therefore, we tried to make use of simple bias correction of GloSea5 for weekly forecasts in

1-month forecast. To do this, we developed the simple statistical relationships between the bias and bias climatology of GloSea5, and then verified bias corrected real-time forecast against raw forecast. When applied bias correction method proposed in this study, we can obtain reduced bias and rmse on average. In particular, the bias correction affects significantly maximum temperature forecast compared to the minimum and average temperature. In terms of accuracy, the maximum and average temperature forecast are improved as much as 7.7% and 1.2%, respectively. The accuracy of minimum temperature forecast, however, became so worse that it needs further investigation in the future.

We analyzed the changes in the old statistical model's predictability and the relationship between its predictors and the prediction target. Generally, statistical climate models' predictability and the relationship between the predictors and the target decrease over time, because climatological teleconnection changes with the climate change, regime shift, or shift in climate normal. There are many statistical climate models had been developed but it has not been used much due to the lack of information on its predictability. Therefore, we suggested whether the old statistical models are still usable through this project.

We have established the BSISO impact monitoring and forecast system to achieving useful 1 month forecast in extended summer (May–October). It is shown that dominant BSISO modes and associated extratropical teleconnections which contributes to summer temperature and precipitation variability over Korea based on reanalysis data. It is found that BSISO forecast was fairly reliable at lead times of 3–5 weeks through case study of this year.

Since 2011, APCC has operated WMO Lead center for Long Range Forecast (WMO LC-LRFMME). It collects forecast data from global producing center and standardizes forecast and hindcast data and displaying the Multi Model Ensemble (MME) results including deterministic and probabilistic method through the website on a monthly basis. The WMO LC-LRFMME has engaged in efforts to share information on the climate services and to enhance international cooperation. One of the Center's activities in this regard is to provide the seasonal forecast information to Regional Climate Outlook Forums (RCOF), Global Seasonal Climate Updates (GSCU) and KMA to a consensus on the state of the global and regional climate outlook. Also the improvements of forecast system in terms of operation on stable and efficient basis and climate service have made.

APCC has been operating a 1-month prediction system since August 2017 to support the KMA's 1-month forecast. This system has been continuously improved with changes in climate normal and model characteristics. In addition, various 1-month forecast contents were added to enhance the analysis skill of the model outputs. The forecast results produced by APCC using these research results showed better skill than the other climate prediction models. These results were directly applied to the KMA's 1-month forecast and contributed to the improvement of prediction accuracy.

국문 요약

이상기후 3개월 장기예보 콘텐츠를 개발하고 이를 효과적으로 나타낼 수 있는 표현방식을 제시하고자 비모수 베이지안 모델인 가우시안 프로세스의 기계학습을 이용하여 전국 및 지역별 혹서기 이상기후지수 3개월 확률전망정보를 생산하였다. 이를 위해 장기예보 가이드선의 예측인자를 이용한 모델, 해당 예측인자를 이상기후지수와의 상관관계를 이용하여 확장한 모델, 군집분석을 통해 도출한 예측인자를 이용한 모델 등을 통해 확률전망정보를 생산하였고 베이지안 모델 평균을 이용하여 결합모델을 구축하여 군집분석을 통한 모델과 결합 모델의 이상기후지수 예측 성능이 우수함을 확인하였다. 또한 삼분위 확률예측정보를 지역별로 시작적으로 전달하는 이상기후 전망정보 표현방식을 제시하였다. 장기예보 객관화 기술을 개발하여 기온 및 강수 3개월 예측에 적용, 현업 장기예보를 지원하고자 앞서 개발한 가우시안 프로세스 모델의 입력자료를 확장하여 관측자료뿐 아니라 APCC MME 예측자료를 활용할 수 있도록 하였으며, 다양한 입력변수와 이상기후지수와의 상관관계를 이용하여 예측인자의 선정이 객관적으로 이루어질 수 있도록 하였다. 모델과 관측을 통합하고자 다양한 기계학습모델 및 역학모델의 결과를 베이지안 모델 평균 및 다중모델 슈퍼앙상블 기법을 이용하여 객관적으로 결합하여 비교적 안정적인 전망정보를 생산하는 방안을 제시하였다.

기후분야의 계절내 예측성을 높이기 위한 방법으로 U-NET 아키텍처를 기반으로 양방향 ConvLSTM, 채널 어텐션 매커니즘(SE 블록), DenseNet의 밀집 연결 패턴 등을 활용하여 5종류의 학습 모델을 설계하고 예측성 평가하였다. 이를 통해 선정된 계절내 예측모델을 이용하여 현업관점에서 수치예보모델과 딥러닝 모델의 예보 1-2주 예측성 평가를 통해 딥러닝 기법의 활용가능성을 평가하였다. ERA-5 T2M 일단위 재분석자료를 이용하여 과거 14일 자료로 하루를 예측하도록 5종류의 모델을 설계하고 학습하였다. 학습 모델의 예측성 평가는 ACC를 이용하였다. 결과로 모델 U-NET 아키텍처에 양방향 ConvLSTM, 채널 어텐션 매커니즘(SE 블록), DenseNet의 밀집 연결 패턴을 모두 적용한 모델 4가 가장 좋은 예측력을 보였다. 현업관점에서 베스트 모델을 평가하기 위해 2016-2020년 기간에 생산된 ECMWF T2M 예보자료의 1-2주 데이터를 입력자료로 이용하여 롤링 예측 방법으로 3-4주 예측데이터를 생산하였다. 예측성 검증 결과, 딥러닝 모델의 예측성이 ECMWF 예보자료와 비교하여 전체기간에서는 다소 낮은 예측성을 보였지만 계절별 평가에서는 3주차 가을철 예측성은 다소 높은 예측성을 보였다. 4주차의 계절별 예측성 평가에서는 봄과 겨울철의 예측성이 낮게 나왔지만 다른 시점은 유사한 예측성을 보였다. 그러므로 본 연구에서 제안된 딥러닝 기반 모델은 계절내 예측성을 개선하는데 도움이 될 것으로 판단된다.

기상청 현업모델은 예측 아노말리와 예측값 자체의 계통적 오차 특징이 다르게 나타난다. 이는 우리가 아노말리 값으로 예측을 하는 경우, 틀린 예측정보를 생산하는 요인이 될 수 있다. 따라서 이 연구에서는 기상청 현업모델의 일정한 편차(bias)의 보정을 통해 예보하는 방안을 마련하고자 하였다. 이 연구에서는 기후예측모델의 편의값과 편의기후값 사이의 통계산출식 개발을 통해 편차를 보정할 수 있는 방안을 개발하고, 실제예측자료를 활용하여 예측성을 검증한다. 실제 이 연구에서 제시한 편차보정방법을 활용했을 때, 평균적으로 편차(bias)와 제공근 오차(rmse)가 감소하였는데, 특히 최고기온에서 보정효과가 가장 크게 나타나다. 또한 적중률

(accuracy)에 대해 검증한 결과에서도, 최고기온(7.7%↑)과 평균기온(1.1%↑)은 개선되었다. 하지만, 최저기온(18.5%↑)의 경우 적중률이 하락하여 이에 대한 추가 연구가 필요할 것으로 판단된다. 역학모델 뿐 아니라, 기 개발된 통계모델들의 개발시점 대비 현재의 예측성능과 통계모델에서 사용된 예측인자들의 상관관계 변화를 분석하였다. 일반적으로 기후변화나 레짐이동, 표준편년이동 등과 연관되어 시간이 지날수록 원격상관에 변화가 나타나기 때문에 대부분 기후예측 통계모델은 시간이 지날수록 예측인자와의 상관성이 낮아지고, 그에 따라 예측성능도 낮아지는 모습을 보인다. 현업에 사용하기 위해 개발되었지만 예측수준에 대한 정보가 부재해 활용성이 떨어졌던 기 개발된 통계모델들의 활용가능성을 제시하였다.

1개월 전망을 위한 BSISO 감시 및 예측 영향장을 생산하는 체계를 마련하고 여름철 장기예보에 적극 활용하였다. 관측 자료를 기반으로 계절내 시간 규모에서 아시아 여름 몬순지역의 대류활동이 우리나라 여름철 기온의 상승 또는 하강, 강수의 증가 또는 감소를 유발하는 대표 결합모드를 찾아내고 관련 기작을 분석하여 객관적 자료를 제시하였다. 올해 발생한 사례분석을 통해 3~5주 선행 BSISO 예측 정보의 1개월 전망 활용 가능성이 높음을 확인하였다.

계절예측 전문 기관인 APCC는 2011년부터 WMO 장기예보 선도센터 운영의 실질적인 업무를 담당하고 있다. 매월 각 Global Producing Center (GPC)에서 생산되는 장기예보 자료를 수집하고 표준화하여, 결정론적 다중모델 앙상블 기법과 확률론적 다중모델 앙상블 기법으로 예측된 계절예측 정보를 WMO 장기예보 선도센터 홈페이지를 통해 WMO 회원국 및 계절예측 사용자에게 안정적으로 서비스하고 있다. 이와 함께 보다 안정적인 시스템 운영과 사용자 맞춤형 고품질의 예측정보를 서비스하기 위해 WMO 장기예보 선도센터 예측시스템 개선과제를 수행하고 있다. 또한 다양한 지역기후포럼에 맞춤형 다중모델 앙상블 예측정보를 제공하고 Global Seasonal Climate Update (GSCU) 발간을 지원하는 등 계절예측자료 활용도 향상과 국제적 협업 체계 강화를 위해 노력하고 있다.

APCC는 기상청 1개월 전망 지원을 위해 2017년부터 8월부터 1개월 전망 예측시스템을 운영하고 있다. 이 시스템은 기후값 변화와 예측 모델의 변경에 따른 수정사항 등을 적용하면서 지속적으로 개선하고 있다. 또한 다양한 1개월 전망 예측 콘텐츠를 추가하면서 예보관의 수요에 대응하고, 모델 결과에 대한 분석력을 높이는 데 이바지하였다. 이렇게 개선된 콘텐츠와 전담팀의 연구 결과물을 활용하여 최종 생산한 APCC의 1개월 예측결과는 기후 예측모델 대비 상대적으로 우수한 결과를 보였다. 이러한 APCC의 예측결과는 예보토의 시 기상청 최종 예측에 반영되어 장기예보 정확도 향상에 이바지하였다.

목차

평문 초록	i
Executive Summary	ii
국문 요약	iv
목차	vi
표 차례	viii
그림 차례	x
1. 서론	1
2. 방법 및 자료	3
가. 장기에보 객관화 기술개발 및 적용	3
(1) 기계학습 모델을 활용한 3개월 장기에보 개선	3
(2) 신기술을 적용한 동아시아 계절내 예측성 개선	22
나. 장기에보 모델정보 개선 및 적용	28
(1) 현업모델 편차보정을 통한 1개월 기온예보 콘텐츠 개발	28
(2) 여름철 계절내 진동(BSISO)를 활용한 1개월 예보 콘텐츠 개선	31
다. 기존 장기에보 기술의 활용가능성 평가	31
(1) 기존 통계모델의 예측성 및 활용성 평가	31
라. 현업 장기에보 지원	35
(1) WMO 장기에보 선도센터 운영 및 개선	35
3. 결과	54
가. 장기에보 객관화 기술개발 및 적용	54
(1) 기계학습 모델을 활용한 3개월 장기에보 개선	54
(2) 신기술을 적용한 동아시아 계절내 예측성 개선	82
나. 장기에보 모델정보 개선 및 적용	93
(1) 현업모델 편차보정을 통한 1개월 기온예보 콘텐츠 개발	93
(2) 여름철 계절내 진동(BSISO)를 활용한 1개월 예보 콘텐츠 개선	108
다. 기존 장기에보 기술의 활용가능성 평가	120
(1) 기존 통계모델의 예측성 및 활용성 평가	120

(2) 예측인자 상관성 변화 상세 분석	134
라. 현업 장기예보 지원	142
(1) WMO 장기예보 선도센터 운영 및 개선	143
4. 요약 및 결론	189
사사	192
References	193
부록 A. 예보1주차 ECMWF 예보자료 대비 딥러닝 기법의 ACC 예측성 평가 상위 5위	199
부록 B. GloSea5/ECMWF 장기예보 자료 수집 및 생산 시스템	202
부록 C. 1개월 전망 활용을 위한 관측 기반 우리나라 여름철 기온 및 강수 변동에 대한 BSISO 영향 위상 분석 Fact Sheet	216

표 차례

Table	page
Table 1. Global gridded datasets used to derive predictors.	8
Table 2. Sea ice and pre-calculated atmospheric and oceanic indices used as predictors.	9
Table 3. APCC MME datasets used to derive predictors.	10
Table 4. Eight individual models and APCC MME datasets used for objective combinations of model results.	10
Table 5. Pre-determined predictors for existing statistical models (KMA 2018).	11
Table 6. Machine learning models used for objective combinations.	16
Table 7. Climate models used for objective combinations.	19
Table 8. Summary of ECMWF ERA-5 reanalysis data downloaded in this study	23
Table 9. Summaries of deep learning models tested in this study	26
Table 10 Statistical models' information	33
Table 11 Multi-category contingency table	34
Table 12 Dichotomous contingency table	35
Table 13. Characteristics of seasonal forecast model from GPCs.	41
Table 14. Reanalysis data used for verification of real-time forecast.	42
Table 15. Reanalysis data used for verification of hindcast.	43
Table 16. Characteristics of GPC data for WMOLC-LRFMME subseasonal prediction.	44
Table 17. Operational setup for subseasonal MME prediction system.	46
Table 18. Participating GPCs in subseasonal MME prediction each forecast before November 2019.	46
Table 19. Participating GPCs in subseasonal MME prediction each forecast since October 2020.	47
Table 20. Used data list for subseasonal MME prediction system.	49
Table 21. Summaries for training, validation, and test dataset	83
Table 22. Initialize values and hyper-parameters for deep learning training	83
Table 23. Summaries of basic statistical analysis of the cases	87

Table 24. Input data summaries for training, validation, and test dataset	89
Table 25. Summaries of comparison between deep learning and ECMWF prediction ACC based on ECMWF T2M forecast data every Month of 2016-2020	90
Table 26 Change of RMSE. The change rate is defined as the difference of RMSE from raw GloSea5 and each bias correction method.	101
Table 27. Statistical models' predictability scores	121
Table 28. Statistical analysis of reconstructed wintertime(DJF) monthly temperature prediction model	123
Table 29. Statistical analysis of reconstructed summertime(JJA) monthly temperature prediction model	127
Table 30. Date of data reception from GPCs.	143
Table 31. Yearly Relative Operating Characteristic (ROC) score aggregated over globe of probabilistic real-time forecast of 2m temperature and precipitation.	146
Table 32. Yearly Relative Operating Characteristic (ROC) score aggregated over East Asia of probabilistic real-time forecast of 2m temperature and precipitation.	146
Table 33. Improvements of long-range forecast system from GPC Toulouse.	149
Table 34. Improvements of long-range forecast system from GPC CMCC.	150
Table 35. Improvements of long-range forecast system from GPC Melbourne.	151
Table 36. The list of participating RCOF in 2021.	157

그림 차례

Figure	page
Figure 1. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for TMm.	4
Figure 2. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for TNm.	5
Figure 3. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for TXm.	6
Figure 4. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for SPI1.	7
Figure 5. Flow diagrams for the selection of predictors (a) from observations (example for the target variable of TMm, target month of August, predictor variable of Z500, and monitoring month of April) and (b) from observations and MME (example for the target variable of TMm, target month of August, predictor variable of Z500, and monitoring month of June).	12
Figure 6. Various model conditions were selected by leave one year out cross-validations for (a) the GP model with pre-determined predictors from observations (GP-PD) and (b) the GP model with objectively derived predictors from observations (GP-OBS) as well as the GP model with objectively derived predictors from observations and MME (GP-MME) for the train period.	14
Figure 7. The GP models (a) with pre-determined predictors from observations (GP-PD), (b) with objectively derived predictors from observations (GP-OBS), and (c) with objectively derived predictors from observations and MME (GP-MME) were developed based on selected conditions.	15
Figure 8. Structures of RNN, LSTM, and GRU (http://dprogrammer.org/rnn-lstm-gru)	24
Figure 9. Concept of vanilla U-NET	25
Figure 10. Design of Case 4 model	26
Figure 11. Example of an one-month forecasting schedule operated by the APEC Climate Center	27
Figure 12. Illustration for date-distance weighted average using GloSea5 subseasonal hindcast.	28
Figure 13. Diagram for bias and bias climatology definition.	29
Figure 14. Functions of WMO LC-LRFMME.	37

Figure 15. A parametric Gaussian fitting method for estimate of tercile-based categorical probabilities.	40
Figure 16. Forecast procedures at WMO LC-LRFMME.	42
Figure 17. The variables and covering periods of graphical products for subseasonal prediction.	50
Figure 18. Operation schedule for APCC 1 month forecast.	51
Figure 19. Sample of APCC 1 month forecast chart.	51
Figure 20. Sample of subseasonal model output for APCC 3-month forecast.	52
Figure 21. Performance of GP-PD from 34 LOOCV train-validation sets for (a) PC, (b) HSS, (c) AUC, and (d) RPSS.	54
Figure 22. Performance of GP-OBS from 34 LOOCV train-validation sets with ISO and P5 conditions for (a) PC, (b) HSS, (c) AUC, and (d) RPSS.	55
Figure 23. Performance of GP-PD, GP-OBS, and GP-MME for the test period for (a) PC, (b) HSS, (c) AUC, and (d) RPSS.	56
Figure 24. Tercile results of all models for the test period. Adopted from Rhee and Myoung (2021).	56
Figure 25. Operational products of TMm, TNm, TXm, and SPI1 probabilistic forecast results based on GP-MME: Example of TMm (LT1) forecasts for November, 2021.	58
Figure 26. Performance of deterministic forecasts of ANN	59
Figure 27. Performance of deterministic forecasts of RF	60
Figure 28. Performance of deterministic forecasts of Adaboost	60
Figure 29. Performance of deterministic forecasts of SVR	61
Figure 30. Performance of deterministic forecasts of GP-PD	61
Figure 31. Performance of deterministic forecasts of GP-OBS	62
Figure 32. Performance of deterministic forecasts of GP-MME	62
Figure 33. Performance of probabilistic forecasts of GP-PD	63
Figure 34. Performance of probabilistic forecasts of GP-OBS	63
Figure 35. Performance of probabilistic forecasts of GP-MME	64
Figure 36. Performance of deterministic forecasts of APCC	64
Figure 37. Performance of deterministic forecasts of BCC	65
Figure 38. Performance of deterministic forecasts of CWB	65

Figure 39. Performance of deterministic forecasts of KMA	66
Figure 40. Performance of deterministic forecasts of MSC	66
Figure 41. Performance of deterministic forecasts of NASA	67
Figure 42. Performance of deterministic forecasts of NCEP	67
Figure 43. Performance of deterministic forecasts of PNU	68
Figure 44. Performance of deterministic forecasts of APCC MME	68
Figure 45. Performance of probabilistic forecasts of APCC	69
Figure 46. Performance of probabilistic forecasts of BCC	69
Figure 47. Performance of probabilistic forecasts of CWB	70
Figure 48. Performance of probabilistic forecasts of KMA	70
Figure 49. Performance of probabilistic forecasts of MSC	71
Figure 50. Performance of probabilistic forecasts of NASA	71
Figure 51. Performance of probabilistic forecasts of NCEP	72
Figure 52. Performance of probabilistic forecasts of PNU	72
Figure 53. BMA results of deterministic forecasts: an example for TMm (LT3) forecast of January 2022.	73
Figure 54. Boxplots of TMm forecast performance of BMA of deterministic forecasts for each season and model.	73
Figure 55. Boxplots of SPI1 forecast performance of BMA of deterministic forecasts for each season and model.	74
Figure 56. BMA results of probabilistic forecasts: an example for TMm (LT3) forecast of January 2022.	74
Figure 57. Boxplots of TMm forecast performance of BMA of probabilistic forecasts for each season and model.	75
Figure 58. Boxplots of SPI1 forecast performance of BMA of probabilistic forecasts for each season and model.	75
Figure 59. Boxplots of TMm forecast performance of Super-ensemble of deterministic forecasts for each season and model.	76
Figure 60. Boxplots of SPI1 forecast performance of Super-ensemble of deterministic forecasts for each season and model.	76
Figure 61. Super-ensemble results of probabilistic forecasts: an example for TMm (LT3)	

forecast of January 2022.	77
Figure 62. Boxplots of Tm forecast performance of Super-ensemble of probabilistic forecasts for each season and model.	77
Figure 63. Boxplots of SPI1 forecast performance of Super-ensemble of probabilistic forecasts for each season and model.	78
Figure 64. Comparisons of PC scores of BMA and Super-ensemble.	79
Figure 65. Comparisons of HSS scores of BMA and Super-ensemble.	80
Figure 66. Comparisons of AUC scores of BMA and Super-ensemble.	81
Figure 67. Comparisons of RPSS scores of BMA and Super-ensemble.	82
Figure 68. Training results of cases	84
Figure 69. ACC of predictions from case models by region and year	85
Figure 70. ACC of predictions from case models by region and month	85
Figure 71. ACC of predictions from case models by region and season	86
Figure 72. Anomaly correlation coefficients(ACC) of predictions from case models by case	86
Figure 73. Maps of one prediction result of the cases (first row: ground true, second row: prediction, third row: prediction-ground true)	87
Figure 74. Example of rolling prediction method for predicting 14 days	88
Figure 75. New case 4 model with added climatology data input data as BConvLSTM block input data of the last skip connection in the decoder part	88
Figure 76. Boxplotting comparison results between deep learning and ECMWF prediction F1(W+3) ACC based on ECMWF T2M forecast data every Month of 2016–2020	91
Figure 77. Boxplotting comparison results between deep learning and ECMWF prediction F2(W+4) ACC based on ECMWF T2M forecast data every Month of 2016–2020	92
Figure 78. Time-series of GloSea5(blue) and observation(red) anomalies for (a) maximum, (b) minimum, and (c) 2-m temperature for each week from week1 to week4.	96
Figure 79. Bias climatology from GloSea5 for (a) maximum, (b) minimum and © 2-m temperature for each week from week1 to week4.	97
Figure 80. Box-plot of bias after bias correction for the (a) maximum, (b) minimum and (c) mean temperature or each week from week1 to week4.	99
Figure 81. Comparison of RMSE after bias correction for the (a) maximum, (b)	

minimum and (c) mean temperature or each week from week1 to week4.	100
Figure 82. Categorical temperature forecasts from raw GloSea(left triangle), MBC(bottom triangle), EQM(right triangle) and observation(top triangle).	102
Figure 83. Comparison of accuracy in contingency table after bias correction for the (a) maximum, (b) minimum and (c) mean temperature or each week from week1 to week4.	103
Figure 84. Time-series of bias-corrected forecasts for (a) maximum, (b) minimum and (c) 2-m temperature from week1 to week6.	104
Figure 85. Comparison of accuracy from (blue) raw GloSea5 and (pink) bias correction.	105
Figure 86. Week3 tercile-based probabilistic forecasts of raw GloSea5, MVA, MBC and EQM bias-corrected for (top) maximum, (middle) minimum and (bottom) mean temeprature, which is forecasted at June 14, 2021.	106
Figure 87. Week 3 tercile-based probabilistic forecast of (to) maximum, (middle) minimum and (bottom) mean temperature, which is forecasted at June 14, 2021. (Left) raw GloSea5 and (right) bias-corrected forecasts.	107
Figure 88. A document from KMA/CPD for operational use of APCC bias correction method for the purpose of 1-month forecast	108
Figure 89. An example of weekly BSISO monitoring and forecast for 1-month outlook	109
Figure 90. Schematic diagram of BSISO phase selection process affecting Korean summer temperature and precipitation variation.	110
Figure 91. Time series of weekly mean Korean temperature(precipitation) anomalies for warm/cool(wet/dry) phase cases.	111
Figure 92. BSISO phase diagram of exception case for warm phase case(red) and cool phase case(blue).	112
Figure 93. Composite map of 2m temperature intraseasonal anomalies for the warm phase case(left) and cool phase case(right) with respect to BSISO mode.	112
Figure 94. Composite map of outgoing long wave radiation(top left), 500hPa(shading) and 200hPa(contour) geopotential height(top right), omega(shading) and meridional-vertical circulation(bottom left), and 1000-700hPa integrated moisture convergence(shading) and 850hPa moisutre flux(bottom right) intraseasonal anomalies for the BSISO warm phase case in June-August.	113
Figure 95. Same as Figure 6 except for the BSISO cool phase case in June-August.	114

Figure 96. Composite map of precipitation intraseasonal anomalies for the wet phase case(left) and dry phase case(right) with respect to BSISO mode. 115

Figure 97. Same as Figure 94 except for the BSISO wet phase case in June-Aug. 116

Figure 98. Same as Figure 94 except for the BSISO dry phase case in June-August. 116

Figure 99. Weekly mean anomalies of outgoing longwave radiation(left), 1000-700hPa integrated moisture convergence(shading) and 850hPa moisture flux(right) for the period 24-30 July, 2021. 117

Figure 100. Phase diagram of observed(red) and predicted(purple to green) BSISO for the period 24-30 July, 2021. 118

Figure 101. BSISO impact anomalies of OLR and 850hPa wind(left), 500hPa geopotential height(middle), and precipitation(right) estimated using the BSISO forecast index for each lead time. 118

Figure 102. Weekly mean of 500hPa geopotential height anomalies from GloSea5 atmospheric initial data(left) and ECMWF based on week-three forecasts(middle), and 200hPa geopotential height anomalies from ECMWF based on week-three forecasts(right) valid for 11-17 October 2021. 119

Figure 103. Phase diagram of observed(red) and predicted(purple to green) BSISO for the period 11-17 October, 2021. 119

Figure 104. BSISO impact anomalies of OLR and 850hPa wind(left), 500hPa geopotential height(middle), and temperature(right) estimated using the BSISO forecast index for each lead time. 120

Figure 105. Changes in temporal correlation coefficient between model's prediction and the observation 121

Figure 106. Changes in temporal correlation coefficient between model's predictor and the target. 122

Figure 107. Scatter plots showing the relationship between predictors and standardized December mean temperature. 124

Figure 108. Bar chart showing standardized December mean temperature (skyblue) and model's prediction (blue). 124

Figure 109. Scatter plots showing the relationship between predictors and standardized January mean temperature. 125

Figure 110. Bar chart showing standardized January mean temperature (skyblue) and model's prediction (blue). 125

Figure 111. Scatter plots showing the relationship between predictors and standardized

February mean temperature. Orange lines denote 1979~2015, and blue lines denote 1979~2020.	126
Figure 112. Bar chart showing standardized February mean temperature (skyblue) and model's prediction (blue).	126
Figure 113. Scatter plots showing the relationship between predictors and standardized June mean temperature.	127
Figure 114. Bar chart showing standardized June mean temperature (skyblue) and model's prediction (blue).	128
Figure 115. Scatter plots showing the relationship between predictors and standardized July mean temperature.	128
Figure 116. Bar chart showing standardized July mean temperature (skyblue) and model's prediction (blue).	129
Figure 117. Scatter plots showing the relationship between predictors and standardized August mean temperature.	129
Figure 118. Bar chart showing standardized August mean temperature (skyblue) and model's prediction (blue).	130
Figure 119. Scatter plots showing the relationship between predictors and standardized July-August mean temperature.	131
Figure 120. Bar chart showing standardized July-August mean temperature (skyblue) and model's prediction (blue).	131
Figure 121. Scatter plots showing the relationship between predictors and standardized August mean precipitation.	132
Figure 122. Bar chart showing standardized August mean precipitation (skyblue) and model's prediction (blue).	132
Figure 123. Scatter plots showing the relationship between predictors and standardized Chang-ma precipitation.	134
Figure 124. Bar chart showing standardized Chang-ma precipitation (skyblue) and model's prediction (blue).	134
Figure 125. Rolling Correlation between averaged Indian Ocean SST from April to May and averaged Korea precipitation in August.	135
Figure 126. Regression map of April-May averaged sea surface temperature over Indian Ocean onto (upper) 500hPa geopotential height, (lower) 850hPa wind, and precipitation.	

Figure 127. August precipitation and July-August 200hPa velocity potential in (left) 1998 and (right) 2016	137
Figure 128. Daily MJO phase frequency in August (Epoch1: 1991-2010, Epoch2: 2011-2020).	137
Figure 129. Regression map of Barents-Kara sea ice concentration onto geopotential height (200hPa and 500hPa), 200hPa wind, 850hPa wind and precipitation.	139
Figure 130. Time-lagged composite temperature over East Asia from week1 to week4 by utilizing the information of ENSO and MJO phases.	141
Figure 131. Weekly temperature anomalies over Korean Peninsula, conditional on the initial state of the MJO phase 3.	142
Figure 132. Weekly temperature anomalies over Korean Peninsula, conditional on the initial state of the MJO phase 7.	142
Figure 133. Relative Operating Characteristic (ROC) score aggregated over globe of probabilistic real-time forecast of 2m temperature for three terciles, i.e., a) the above normal, b) near normal and below normal for the period JFM2017-ASO2021.	144
Figure 134. Relative Operating Characteristic (ROC) score aggregated over globe of probabilistic real-time forecast of precipitation for three terciles, i.e., a) the above normal, b) near normal and below normal for the period JFM2017-ASO2021.	145
Figure 135. Improvements of operational system at WMO LC-LRFMME in 2021.	147
Figure 136. Deterministic forecast for OND2021 GPC CMCC and WMOLC-LRFMME.	152
Figure 137. Probabilistic forecast for OND2021 from GPC CMCC and WMOLC-LRFMME.	153
Figure 138. Anomaly correlation coefficient (ACC) for JJA forecast for the period 1993-2009.	153
Figure 139. Anomaly correlation coefficient (ACC) for JJA forecast for the period 1993-2009.	154
Figure 140. Example of seasonal outlook table.	155
Figure 141. Example of precipitation probability forecast based on WMO LC-LRFMME.	156
Figure 142. Example of temperature probability forecast based on WMO LC-LRFMME.	156
Figure 143. Example of materials for WMO expert team.	159
Figure 144. The bulletin board for GSCU on WMO LC-LRFMME website.	159

Figure 145. The number of monthly visitors of WMO LC-LRFMME website in 2021.	160
Figure 146. Verification of climate indices in WMOLC-LRFMME.	162
Figure 147. Observational anomaly display webpage in WMOLC-LRFMME.	164
Figure 148. Verification display web page with added reanalysis data in WMOLC-LRFMME.	164
Figure 149. Anomaly correlation coefficient (ACC) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe.	166
Figure 150. Anomaly correlation coefficient (ACC) of monthly averaged 1 week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe.	168
Figure 151. Anomaly correlation coefficient (ACC) of monthly averaged 3 weeks real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Oct 2021 over the globe.	169
Figure 152. Root mean square error (RMSE) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe.	170
Figure 153. Root mean square error (RMSE) of monthly averaged 1 week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe.	172
Figure 154. Root mean square error (RMSE) of monthly averaged 3 weeks real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Oct 2021 over the globe.	173
Figure 155. Anomaly correlation coefficient of weekly mean prediction of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2019 to Aug 2021 over the East Asia.	176
Figure 156. Root mean square error of weekly mean prediction of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2019 to Aug 2021 over the East Asia.	177
Figure 157. Sample of 1-month PMME prediction trend analysis chart.	178
Figure 158. Sample of Z500 Hovmoller diagram.	179
Figure 159. Sample of Z500 anomaly chart over Northern Hemisphere.	181
Figure 160. Sample of Z200, Z500, MSLP and 850hPa wind anomaly chart over East Asia.	182

Figure 161. Sample of final result table of APCC 1-month forecast.	183
Figure 162. APCC 1-month forecast presentation format. (a) Dec 2020, (b) May 2021 and (c) Sep 2021.	183
Figure 163. Heidke skill score for 2m temperature forecast of GloSea5, ECMWF and APCC from Jan 2021 to Nov 2021.	185
Figure 164. Heidke skill score for precipitation forecast of GloSea5, ECMWF and APCC from Jan 2021 to Nov 2021.	185
Figure 165. 12 weeks moving window Heidke skill score of GloSea5, ECMWF and APCC at temperature forecast.	186
Figure 166. 12 weeks moving window Heidke skill score of GloSea5, ECMWF and APCC at precipitation forecast.	187
Figure 167. The ratio of above normal, near normal and below normal categorical forecast of GloSea5, ECMWF and APCC.	188
Figure A1. Comparison of ECMWF forecast (CF member) and deep learning-based forecast	199

1. 서론

APCC는 MME 기술을 바탕으로 신뢰도 높은 기후예측정보 생산 및 서비스를 목표로 하고 있으며, 이를 토대로 기상청 현업 장기예보 생산에 지속적으로 기여하고 있다. 특히, 기후예측 전문가 그룹으로서 WMO 장기예보 선도센터를 2011년부터 계속하여 운영하고 개선하여 왔으며 이는 현업 장기예보 생산에 중요한 자료로 활용되고 있다. 2019~2021년의 3년에 걸친 5단계 아태 사업을 통해 기상청과의 협력체계를 통해 현업 장기예보 기술개발 및 개선에 기여함으로써 장기예보관의 의사결정을 지원하고, 기 개발된 기술을 현업화하여 운영함으로써 장기예보 실무 분야의 역할을 정립하고자 하였다. 특히, 5단계 아태사업의 최종 년도로써 실제 장기예보 현업 업무에 활용할 수 있는 결과물을 도출하는 등, 이 연구결과가 현업 장기예보 기술개선에 실질적으로 기여할 수 있도록 과제를 제안한 바 있다. APCC의 고품질 기후정보와 기후예측에 대한 전문지식 및 그간의 경험을 바탕으로 우리나라 장기예보 정확도 향상을 위한 연구를 지속적으로 수행함으로써, 우리나라 장기예보 관련 전문 기술을 축적하고 향후 장기예보 객관화 기술개발 추진을 위한 기반기술을 확보할 수 있었다. 관련한 연구내용을 하나씩 살펴보면 다음과 같다.

첫째, 장기예보 객관화 기술을 개발하여 기온 및 강수 3개월 예측에 적용, 현업 장기예보를 지원하고자 한다. 비모수 베이지안 기계학습 모델인 가우시안 프로세스 모델을 이용하여 전국 및 지역별 이상기후지수 3개월 확률전망정보를 생산하고, 다양한 기계학습모델 및 역학모델의 결과를 베이지안 모델 평균 및 다중모델 슈퍼앙상블 기법을 이용하여 객관적으로 결합하여 비교적 안정적인 전망정보를 생산하는 방안을 제시한다. 이를 통해 방대한 정보를 객관적으로 통합하여 예보관의 의사결정을 지원하는 예보 객관화에 한걸음 다가갈 수 있을 것이다.

둘째, Lecun et al.(1998)이 CNN(Convolution Neural Network) 개념을 최초로 개발한 LeNet-5 구조가 등장한 이후 2012년에 개최된 ILSVRC(ImageNet Large Scale Visual Recognition Challenge) 대회에서 CNN 기반 AlexNet이 우승을 차지하면서 딥러닝에 대한 관심이 증가하기 시작하였다. CNN 외에도 시퀀스 문제를 해결하는데 적합한 순환 신경망(RNN, Recurrent Neural Network), 장단기 메모리(LSTM, Long Short Term Memory), 게이트 순환 유닛(GRU, Gated Recurrent Unit) 등이 등장하면서 전통적인 통계방법에서 벗어나 인공신경망을 활용하여 시계열 문제를 해결하기 위한 노력하고 있다. 2015년 이미지 분할 분야에서 FCN(Fully Convolutional Networks)를 확장한 U-NET 구조(Ronneberger et al., 2015)가 바이오 메디컬 분야에서 이미지 분할(segmentation)을 목적으로 제안되면서 시계열 예측 분야에서 활용하는 사례가 증가하고 있다. 최근에는 계절내 기후예측분야에서 머신러닝(machine learning), 딥러닝 기법 등을 이용하여 예측성을 높이기 위해 활용되고 있다(Hwang et al., 2019, Pan et al., 2020). 본 연구에서는 계절내 예측성을 개선을 위해 기존에 제안된 기법들을 활용하여 딥러닝 모델을 설계하고 현업관점에서의 실험을 통해 활용가능성을 평가하고자 한다.

셋째, 여름철 계절내 진동(Boreal Summer Intraseasonal Oscillation, BSISO)이 아시아 여름 몬순 지역의 대기에 미치는 영향을 보다 더 알기 쉽고 직관적으로 해석할 수 있는 BSISO 영향 분석 기술이 개발(김해정 등, 2018)되었고, 2020년부터 BSISO 영향 편차장의 감시 및 예측 정보가 APCC 홈페이지를 통해 서비스되고 있다. 그러나 현재 APCC에서 제공하고 있는 BSISO 콘텐츠의 경우 예측 기간이 20일로 짧고 최신 예측자료 제공에 제약이 있어 1개월 전망 활용에

어려움이 따른다. 따라서 기개발된 방법을 토대로 최신 예측장을 활용한 BSISO 예측정보 생산 시스템을 구축하고 매주 향후 6주에 대한 예측정보를 제공함에 따라 1개월 여름철 예보 정확도 향상에 기여하고자 한다. 이와 더불어 예보관의 의사결정에 대한 객관적 근거 마련을 위해 여름철 우리나라 기온 및 강수 변동에 미치는 BSISO 영향 위상 분석을 수행하였고, 올해 발생한 사례를 통해 BSISO 예측정보 활용 가능성을 평가하였다.

넷째, 2011년부터 계절예측 전문기관인 APCC에서 운영하고 있는 WMO 장기예보 선도센터에 대한 전반적인 사항과 안정적인 기후예측 정보 서비스를 위한 노력의 일환으로 진행된 시스템 개선 사항을 서술하였다. 또한 WMO 장기예보 선도센터 기후예측 자료 활용성 향상과 국제적 협업 체계 강화를 위한 WMO 지역기후전망 포럼 참가, 예보자를 위한 교육 프로그램 강의, GSCU 발간지원, 계절내 기후예측자료 제공 등 WMO 장기예보 선도센터의 국내·외 활동을 서술하였다.

다섯째, 계절 예측에서 역학 모델의 한계를 보완하기 위해 많은 통계 모델들이 개발되었다. 통계 모델은 극 지역, 중위도 지역, 열대지역의 다양한 인자들을 고려할 수 있어 더욱 우수한 예측성능 얻을 수 있다는 장점이 있다. 기상청에서도 다수의 R&D를 통해 통계 모델의 개발을 독려하고 개발된 통계 모델을 현업 장기 예측에 적용할 수 있도록 하고 있다. 그러나 통계모델이 구축된 후 시간이 지남에 따라 regime shift, 기후변화, 평년이동 등 다양한 요인에 의해 예측인자와 예측타깃의 상관성이 변하게 되기 때문에, 현재는 개발된 통계 모델 중 일부만이 실제로 현업 운영에 활용되고 있는 실정이다. 따라서 이 연구에서는 기개발된 통계 모델들의 개발 시점 이후 예측인자 상관성 변화 및 모델의 예측성 변화를 분석하여 통계 모델의 가용성 여부를 제시하고자 한다.

여섯째, 지난 몇 년간의 장기예보를 위한 기후예측모델의 예측자료는 warm 아노말리가 지속적으로 나타났으며, 이로 인해 예보에 어려움을 겪어왔다. 기후예측모델의 경우, 단정예보의 편차값을 보정하여 평균·최고·최저기온 예측정확도 향상과 함께 최고, 최저기온 장기전망 서비스 개발에 기여할 수 있는 연구가 필요하다. 따라서 본 연구에서는 기온 장기전망 예측성을 향상하는 한편, 최고·최저기온 장기전망 서비스 개발에 기여하기 위한 기후예측모델 편차 보정 방안을 개발하였다. 특히, 기상청 현업모델의 예보 아노말리의 계통적 오차와 실제 예측값의 계통적 오차특징이 다르게 나타나므로, 항상 warm 하게 나타나는 아노말리를 통한 예보보다, 일정한 편차의 보정을 통해 예보할 수 있는 방안을 마련한다. 이와 함께 최근 기후이슈(평년값 변경 등) 및 기후변화를 고려한 기존 장기예보 예측인자들의 개선방안을 제시함으로써 현업 장기예보의 정확도 향상에 기여하고자 한다. 또한, 평년값 변경 및 기상청 현업 모델자료의 과거재현기간 연장 등을 고려하여 최고·최저기온 1개월 장기예보 생산에 대응하고자 한다.

2. 방법 및 자료

가. 장기에보 객관화 기술개발 및 적용

(1) 기계학습 모델을 활용한 3개월 장기에보 개선

(가) 관측 및 모델자료

① 지상관측자료

신평년(1991-2020년) 적용을 위해 선정된 66개 ASOS (Automatic Synoptic Observing System) 지점에 대해 일별 평균, 최저, 최고기온 및 강수 자료를 1980년 이후 기간에 대해 수집하였다(<https://data.kma.go.kr>). 지점별로 월별 자료로 전환하여 월별로 평균한 일평균기온(TMm; mean daily mean temperature), 일최저기온(TNm; mean daily minimum temperature), 일최고기온(TXm, mean daily maximum temperature) 및 월 합산 강수량을 얻었으며 제주도의 4개 지점을 제외한 62개 지점 값을 평균하여 전국에 대한 TMm, TNm, TXm 및 강수 시계열을 산정하였다. 강수는 모델 적용의 편의를 위해 SPI1 (1-month Standardized Precipitation Index)로 전환하였다. 전국 뿐 아니라 서울경기, 강원영서, 강원영동, 대전충남, 충북, 대구경북, 전북, 광주전남, 부산경남 및 제주의 10개 지역에 대해서도 각 지역에 존재하는 지점 값을 이용하여 TMm, TNm, TXm 및 SPI1 시계열을 산정하였다.

각 시계열 자료에 대해 추세분석을 수행하였다. 구평년 기간(1981-2010년)과 비교하여 신평년 기간(1991-2020년)에는 기온 변수의 추세가 두드러지게 나타났다. 추세분석은 모수적인 방법의 선형회귀와 비모수적인 방법의 Mann-Kendall 방법을 이용하여 수행하였는데, 두 방법은 대부분 같은 결과를 보이거나 지역과 월에 따라 다른 결과를 보이기도 하였다. 추세제거(detrend)는 선형회귀를 통해 도출한 선형 추세를 제거하는 방식을 사용하였으므로, 추세제거한 후에 선형회귀를 하면 추세가 없는 것으로 나타나나, Mann-Kendall로 테스트하면 간혹 추세가 잔존하거나 새로이 발생하거나, 반대 방향으로 나타나는 경우도 존재하였다. 구평년을 기반으로 한 '20년 연구에서 가우시안 프로세스 모델에 추세제거 하지 않은 입력변수 및 목표변수를 적용하였던 것을 신평년을 적용한 ' 21년 연구에서는 추세제거하여 적용하는 것으로 변경하였다.

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1																						
2															1							
3	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1			1	1
4																						
5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
6	1	1			1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
7							1		1													
8	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1		1	1	1
9							1	1	1	1				1								
10			1	1			1	1	1				1									1
11																						
12																						

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1																						
2																						
3																						
4																						
5																						
6																						
7																						
8																						
9																						
10																						
11																						
12									1													

Figure 1. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for TMm. The number 1 means the increasing trend and 0 means the decreasing trend.

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1																						
2																						
3						1		1						1		1						
4																						
5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
7							1		1					1								
8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
9		1							1	1	1	1	1		1							
10	1	1	1	1					1		1	1	1	1	1	1	1	1	1	1	1	1
11																						
12																						

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1																						
2																						
3																						
4																						
5			0																			
6																						
7																						
8																						
9																						
10																						
11																						
12																						

Figure 2. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for TNm. The number 1 means the increasing trend and 0 means the decreasing trend.

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1							1															
2																						
3	1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1		1	1
4																						
5	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
6	1	1			1	1	1	1	1	1	1	1	1	1		1	1	1			1	1
7																						
8	1	1	1	1	1	1	1	1						1	1	1	1			1	1	1
9																						
10																						
11																						
12																				0		

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1																						1
2																						
3																						
4																						
5													1		1				1			
6													0									
7																						
8																						
9	0														0							
10																						
11																						
12																						

Figure 3. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for TXm. The number 1 means the increasing trend and 0 means the decreasing trend.

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1								0														
2																						
3																						
4																				1		
5																						
6								0														
7							1															
8																					0	
9																						
10				1											1					1	1	1
11																						
12																						

Month	전국		제주		강원영동		강원영서		서울경기		대전충남		충북		대구경북		전북		광주전남		부산경남	
	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR	MK	LR
1																						1
2																						
3																						
4																						
5						1																
6																						
7																						
8																						
9																						
10																						
11																						
12																						

Figure 4. Before (top) and after (bottom) the detrend by linear regression (LR) and Mann-Kendall (MK) for SPI1. The number 1 means the increasing trend and 0 means the decreasing trend.

② 관측자료

기계학습모델의 예측인자 도출에 활용하기 위해 상향장파복사(outgoing longwave radiation, OLR), 해수면온도(sea surface temperature, SST), 강수(precipitation, PRCP), 눈덮임(snow cover extent, SCE), 500hPa 및 850hPa의 지위고도(Z500 and Z850), 해면기압(sea level pressure, SLP), 850hPa 기온(T850)의 전지구 격자자료를 수집하였다.

월별 OLR 자료는 미국 NOAA (National Oceanic and Atmospheric Administration) NCEP (National Centers for Environmental Prediction)의 CPC (Climate Prediction Center)의 자료로, 미 콜럼비아 대학 IRI (International Research Institute for Climate and Society)에서 수집하였다 (<https://iridl.ldeo.columbia.edu/SOURCES/.NOAA/.NCEP/.CPC/.GLOBAL/.monthly/.olr/datafiles.html>). 월별 SST 자료는 NOAA의 Extended Reconstructed Sea Surface Temperature (ERSST) Version 5 자료를 사용하였는데, OAR (Office of Oceanic and Atmospheric Research)의 PSL (Physical Sciences Laboratory)에서 수집하였다(<https://psl.noaa.gov/data/gridded/data.noaa.ersst.v5.html>). 강수자료는 NOAA의 CPC Merged Analysis of Precipitation (CMAP) 자료 또는 NOAA GPCP

V2.3 Combined Precipitation 자료를 사용하였으며 OAR/PSL에서 수집하였다 (<https://psl.noaa.gov/data/gridded/data.cmap.html>). 주별 SCE 자료는 NOAA의 CDR (Climate Data Record) Northern Hemisphere (NH) Snow Cover Extent (SCE) 자료로 수집하였으며 (<https://www.ncei.noaa.gov/data/snow-cover-extent/access/>), 수집 후 월별 자료로 전환하였다. 월별 Z500, Z800, T850 및 SLP 자료는 NCEP Reanalysis 1 자료로, NOAA/OAR/PSL로부터 수집하였다(<https://psl.noaa.gov/data/gridded/data.ncep.reanalysis.pressure.html>).

Table 1. Global gridded datasets used to derive predictors.

Variable	Dataset	Origin (Upper Left Corner)	Resolution
Outgoing Long wave Radiation (OLR)	NOAA NCEP CPC GLOBAL monthly olr	91.25° N, 0.0° E	2.5 dd (73×144)
Sea Surface Temperature (SST)	NOAA ERSST V5	89.0° N, -1.0° E	2.0 dd (89×180)
Precipitation (PRCP)	NOAA CPC Merged Analysis of Precipitation (CMAP)	88.75° N, 1.25° E	2.5 dd (72×144)
	NOAA GPCP V2.3 Combined Precipitation	90.0° N, 0.0° E	
Snow Cover Extent (SCE)	NOAA Climate Data Record (CDR) of Northern Hemisphere (NH) Snow Cover Extent (SCE) V1	88.0° N, 0.0° E	1.0 dd (88×88)
500 hPa Geopotential Height (Z500), 850 hPa Geopotential Height (Z850), 850hPa Air Temperature (T850), Sea Level Pressure (SLP)	NOAA NCEP/NCAR Reanalysis 1	91.25° N, -1.25° E	2.5 dd (73×144)

바렌츠, 베링, 카라, 랍테프해의 해빙(sea ice area, SIA) 자료, 그리고 북극진동(Arctic Oscillation Index, AO)과 같은 다양한 월별 대기 및 해양 지수들도 수집하여 활용하였다. 월별 SIA 자료는 NSIDC (National Snow & Ice Data Center)에서 수집하였으며 (<https://nsidc.org/data/G02135/versions/3>), 대기 및 해양 지수들은 NOAA/OAR/PSL (<https://psl.noaa.gov/data/climateindices/list/>), 원격상관 지수들은 NOAA/CPC에서 수집하였고 (<https://www.cpc.ncep.noaa.gov/data/teledoc/telecontents.shtml>), 월별 PDO는 Tokyo Climate Center에서 수집하였다(https://ds.data/jma.go.jp/tcc/tcc/products/elnino/decadal/pdo_month.html)

Table 2. Sea ice and pre-calculated atmospheric and oceanic indices used as predictors.

Type	Name
Sea Ice Area (SIA)	Barents
	Bering
	Kara
	Laptev
Teleconnections	North Atlantic Oscillation (NAO)
	East Atlantic Pattern (EA)
	West Pacific Pattern (WP)
	East Pacific/North Pacific Pattern (EP/NP)
	Pacific/North American Pattern (PNA)
	East Atlantic/West Russia Pattern (EA/WR)
	Scandinavia Pattern (SCA)
	Polar/ Eurasia Pattern (PE)
	Pacific Decadal Oscillation (PDO)
Atmospheric Indices	Quasi-Biennial Oscillation (QBO)
	Southern Oscillation Index (SOI)
	Arctic Oscillation (AO)
SST Indices	East Central Tropical Pacific SST (Nino 3.4)
	Eastern Tropical Pacific SST (Nino 3)
	Central Tropical Pacific SST (Nino 4)
	Extreme Eastern Tropical Pacific SST (Nino 1+2)
	Oceanic Nino Index (ONI)
	Trans-Nino Index (TNI)
	Tropical Northern Atlantic Index (TNA)
	Tropical Southern Atlantic Index (TSA)
	Western Hemisphere Warm Pool (WHWP)
	Atlantic Multidecadal Oscillation (AMO)
	Atlantic Meridional Mode (AMM)

③ 모델자료

이 연구에서는 가우시안 프로세스 모델의 입력 자료로 APCC MME의 SST, PRCP, Z500, T850, SLP 자료를 사용하였다. 또한 객관적 정보결합을 위해 8개 개별모델과 APCC MME의 T2M 및 PRCP 자료도 사용하였다. 모든 모델자료는 APCC의 Climate Information toolKit (CLIK) (<https://cliks.apcc21.org/dataset/mme/6-MON>) 및 내부 데이터베이스를 통해 수집하였다. 개별모델자료는 원자료가 아닌, MME를 위해 전처리된 자료를 이용하였다.

Table 3. APCC MME datasets used to derive predictors.

Variable	Dataset	Origin (Upper Left Corner)	Resolution
MME Sea Surface Temperature (MME SST)	APCC MME sst	91.25° N, -1.25° E	2.5 dd (73×144)
MME Precipitation (MME PRCP)	APCC MME prec		
MME 500 hPa Geopotential Height (MME Z500)	APCC MME z500		
MME 850 hPa Air Temperature (MME T850)	APCC MME t850		
MME Sea Level Pressure (MME SLP)	APCC MME slp		

Table 4. Eight individual models and APCC MME datasets used for objective combinations of model results.

Institute, Model	Dataset	Origin (Upper Left Corner)	Resolution
APCC, SCOPS	T2M, PRCP	91.25° N, -1.25° E	2.5 dd (73×144)
BCC, CSM1.1M			
CWB, TCWB1Tv1.1			
KMA, GLOSEA5GC2			
MSC, CANSIPsv2			
NASA, GEOS-S2S-2.1			
NCEP, CFSv2			
PNU, CGCMv2.0			
APCC, MME (SCM)			

(나) 가우시안 프로세스 모델을 활용한 여름철 기온 확률예측 방법론

① 예측인자 도출


장기예보 가이드스 인자를 활용한 모델(GP-PD)을 위해 사용한 예측인자는 13개로(Table 5), 이 중 많은 인자가 우리나라 여름철 기온과 관련된 대기 및 해양 변수의 쌍극 및 삼극 패턴을 분석하여 도출되었다(기상청 2018). 이 인자들은 평균기온 예측을 위해 개발되었으나, 이 연구에서는 TMm, TNm, TXm 예측을 위해 사용되었다.

Table 5. Pre-determined predictors for existing statistical models (KMA 2018).

Variable	Region	Boundary	Monitoring Month	Target Month
SCE	Northeast China	(103-123° E, 45-50° N) + (123-133° E, 40-50° N)	MAR	JUN
PRCP	Near Australia	(185-200° E, 20-35° S) - (120-180° E, 25-35° S)	APR	JUN
SST	Tropical West Pacific	(145-180° E, 10° S-15° N)	JAN	JUN
Z500	Eurasia	(10-40° E, 25-45° N) + (60-90° E, 20-50° N) - (0-45° E, 55-70° N)	MAR	JUL
SST	South Indian Ocean, Philippine Sea, East Indian Ocean	(90-120° E, 40-25° S) + (120-140° E, 0-20° N) - (90-110° E, 10° S-5° N)	APR	JUL
Z850	Atlantic Ocean	(265-300° E, 20-40° N) - (255-295° E, 50-65° N)	APR	JUL
PRCP	North of Australia	(110-180° E, 20-5° S)	MAY	AUG
SCE	East-West Asia	(105-135° E, 48-60° N) - (50-70° E, 45-55° N)	APR	AUG
SST	North of Australia	(10-14° E, 20° S-0°)	FEB	AUG
SST	Tropical Indian Ocean	(90-105° E, 10° S-0°)	APR	JUL AUG
SCE	Manchuria	(120-140° E, 40-50° N)	APR	JUL AUG
SIA	Bering Sea	(180-205° E, 55-65° N)	APR	JUL AUG
SST	North Atlantic Ocean	(320-360° E, 55-65° N)	APR	JUL, AUG

관측기반 모델(GP-OBS)과 APCC MME와 관측을 결합한 모델(GP-MME)을 위해서는 객관적 선정 과정을 통해 예측인자가 도출되도록 하였다. 관측기반의 입력자료에 대해서는 목표월 이전의 6개월 자료를 선정에 사용하였으며 APCC MME의 경우 지연상관 및 동시상관을 고려할 수 있도록 관측이 없는 월부터 목표월까지의 예측자료를 사용하였다. 우선 추세제거된 목표변수와 추세제거된 입력변수의 상관관계장을 구하여 상관관계가 높은 지역을 도출하고, 각 지역에 대해 영역평균 및 추세제거한 시계열을 산정한다. APCC MME의 경우, 지역 도출은 관측 자료를 이용하고 선정된 지역에 대해 MME 예측자료의 영역평균을 구하여 편의보정 및 추세제거하여 시계열을 산정한다.

(a) Selection of predictors from observations: Example for target variable Tm (target month: AUG) and predictor variable Z500 (monitoring month: APR)



(b) Selection of predictors from MME: Example for target variable Tm (target month: AUG) and predictor variable Z500 (monitoring month: JUN)

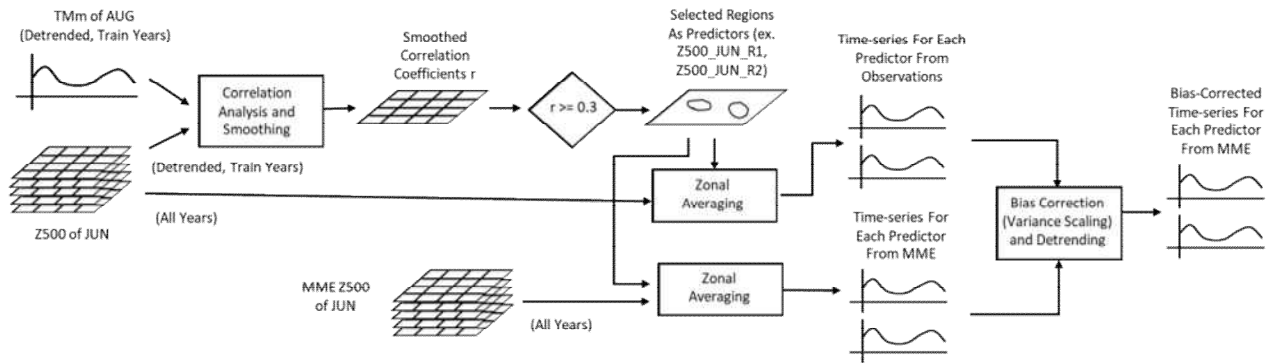


Figure 5. Flow diagrams for the selection of predictors (a) from observations (example for the target variable of Tm, target month of August, predictor variable of Z500, and monitoring month of April) and (b) from observations and MME (example for the target variable of Tm, target month of August, predictor variable of Z500, and monitoring month of June). Adopted from Rhee and Myoung (2021).

② 가우시안 프로세스 모델

가우시안 프로세스(GP)는 실수 값을 가지는 N 개의 한정된 입력변수가 있을 때, 임의의 위치 x_1, \dots, x_n 에서의 확률변수(random variable) $f(x_1), \dots, f(x_n)$ 의 가우스 결합확률분포인 $p(f(x_1), \dots, f(x_n))$ 로 정의되는 확률과정(random process, stochastic process)이다.

GP 사전분포(prior)는 다음과 같은 다변수 정규분포로,

$$p(f|X) = N(f|\mu, K) \quad [1]$$

$$f = (f(x_1), \dots, f(x_N)), \mu = (m(x_1), \dots, m(x_N)), K_{ij} = \kappa(x_i, x_j) \quad [2]$$

여기서 m 은 평균함수이며 k 는 양의 정부호(positive definite) 공분산(또는 kernel) 함수로, GP의 모양이 K 에 의해 결정된다. 확률변수 $f(x_1), f(x_2)$ 두 개의 결합확률분포를 생각하면 kernel k 에 의해 (x_{1i}, x_{2i}) 와 (x_{1j}, x_{2j}) 가 가까우면, 이 위치에서의 $p(f(x_{1i}), f(x_{2i})), p(f(x_{1j}), f(x_{2j}))$ 도 가깝다.

관측자료 y 를 통해 GP 사전분포는 GP 사후분포(posterior) $p(f|X, y)$ 로 전환할 수 있는데, 이를 이용하여 새로운 입력 X^* 에 대한 미래 예측값 f^* 를 구할 수 있다. 이때, 이미 관측한 자료 y 와 미래 예측값 f^* 의 결합확률분포는 아래와 같으므로,

$$\begin{pmatrix} y \\ f_* \end{pmatrix} \sim N\left(0, \begin{pmatrix} K_y & K_* \\ K_*^T & K_{**} \end{pmatrix}\right) \quad [3]$$

$$K_y = \kappa(X, X) + \sigma_y^2 I = K + \sigma_y^2 I, K_* = \kappa(X, X_*), K_{**} = \kappa(X_*, X_*) \quad [4]$$

다변수 정규분포인 GP 사후확률분포(posterior predictive distribution)는 다음과 같이 나타낼 수 있다.

$$p(f_* | X_*, X, y) = \int p(f_* | X_*, f) p(f | X, y) df = N(f_* | \mu_*, \Sigma_*) \quad [5]$$

$$\mu_* = K_*^T K_y^{-1} y, \Sigma_* = K_{**} - K_*^T K_y^{-1} K_* \quad [6]$$

Radial-Basis Function (RBF) kernel을 이용하였는데, 이는 Squared exponential kernel 또는 Gaussian kernel과 같으며 자료 간의 거리의 제곱으로 유사성을 측정한다.

$$\kappa(X_i, X_j) = \sigma_f^2 \exp\left(-\frac{1}{2l^2} (x_i - x_j)^T (x_i - x_j)\right) \quad [7]$$

Vertical variation parameter σ_f 은 함수의 vertical variation을 제어하는데, σ_f 가 커지면 훈련자료의 범위 밖으로 더 넓은 신뢰 구간을 가지게 된다. Length parameter l 은 함수의 매끄러운 정도(smoothness)를 제어하는데, l 이 커지면 더 매끄럽게 훈련자료에 대해 거칠게 예측을 하며 l 이 작으면 좀 더 구불구불하게 훈련자료 사이에 넓은 신뢰 구간을 가지도록 된다. 정규화를 위해 별도로 alpha를 설정하거나 RBF kernel에 white noise kernel을 더하여 훈련자료의 global noise 수준을 설정할 수 있는데 σ_y 가 커지면 noise가 많은 자료에 과적합을 피하며 coarse한 예측을 할 수 있다.

우도함수는 주어진 입력자료와 kernel parameters로부터 관측 y 를 얻을 확률이므로 LML(log marginal likelihood)를 최대화하는 값으로 선정한다.

$$\log p(y|X) = \log N(y|0, K_y) = -\frac{1}{2} y^T K_y^{-1} y - \frac{1}{2} \log |K_y| - \frac{N}{2} \log(2\pi) \quad [8]$$

③ 우리나라 여름철 기온 확률예측

장기예보 가이드선 인자를 활용한 모델(GP-PD), 관측기반 객관적 인자 도출 모델(GP-OBS)과 APCC MME와 관측을 결합한 모델(GP-MME)을 결합에 활용할 수 있도록 예측 결과를 생산하고 성능을 평가하였다. 모델 개발을 위해 초매개변수 및 조건 선정을 위해 GP-OBS 모델을 이용하여 1980-2013년의 기간을 이용하여 Leave-One(year)-Out 교차검증

(Cross Validation, CV)을 실행하고 모델의 성능을 2014-2020년 기간에 대해 검증하였다.

비교한 모델의 조건은 커널 함수에서 isotropic length scale matrix를 사용할지(ISO) 아니면 anisotropic length scale matrix를 사용할지(ANISO), 그리고 예측인자 도출지역을 과거 장기예보 가이드스에서 활용해오던 지역에 한정할지(LR) 아니면 지역적 한정 없이 수행할지(LNR), 그리고 최종적으로 예측인자를 선정할 때 상관관계의 통계적 유의성이 특정 수준에 도달하는 인자만을 사용할지(p-value 수준에 따라 P1, P5, 또는 P10)의 세 기준을 살펴보았다.

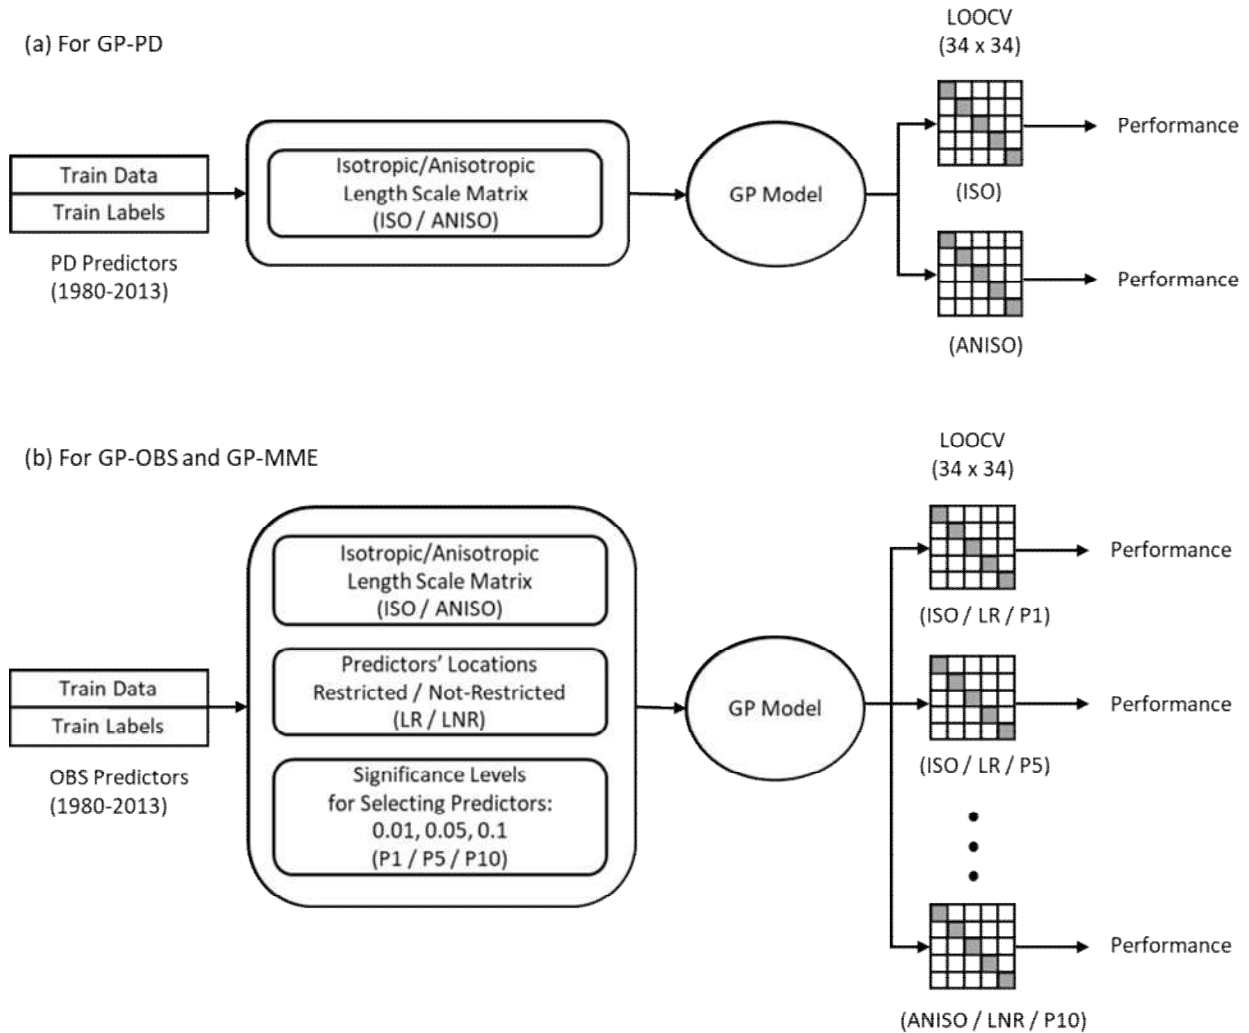


Figure 6. Various model conditions were selected by leave one year out cross-validations for (a) the GP model with pre-determined predictors from observations (GP-PD) and (b) the GP model with objectively derived predictors from observations (GP-OBS) as well as the GP model with objectively derived predictors from observations and MME (GP-MME) for the train period. Adopted from Rhee and Myoung (2021).

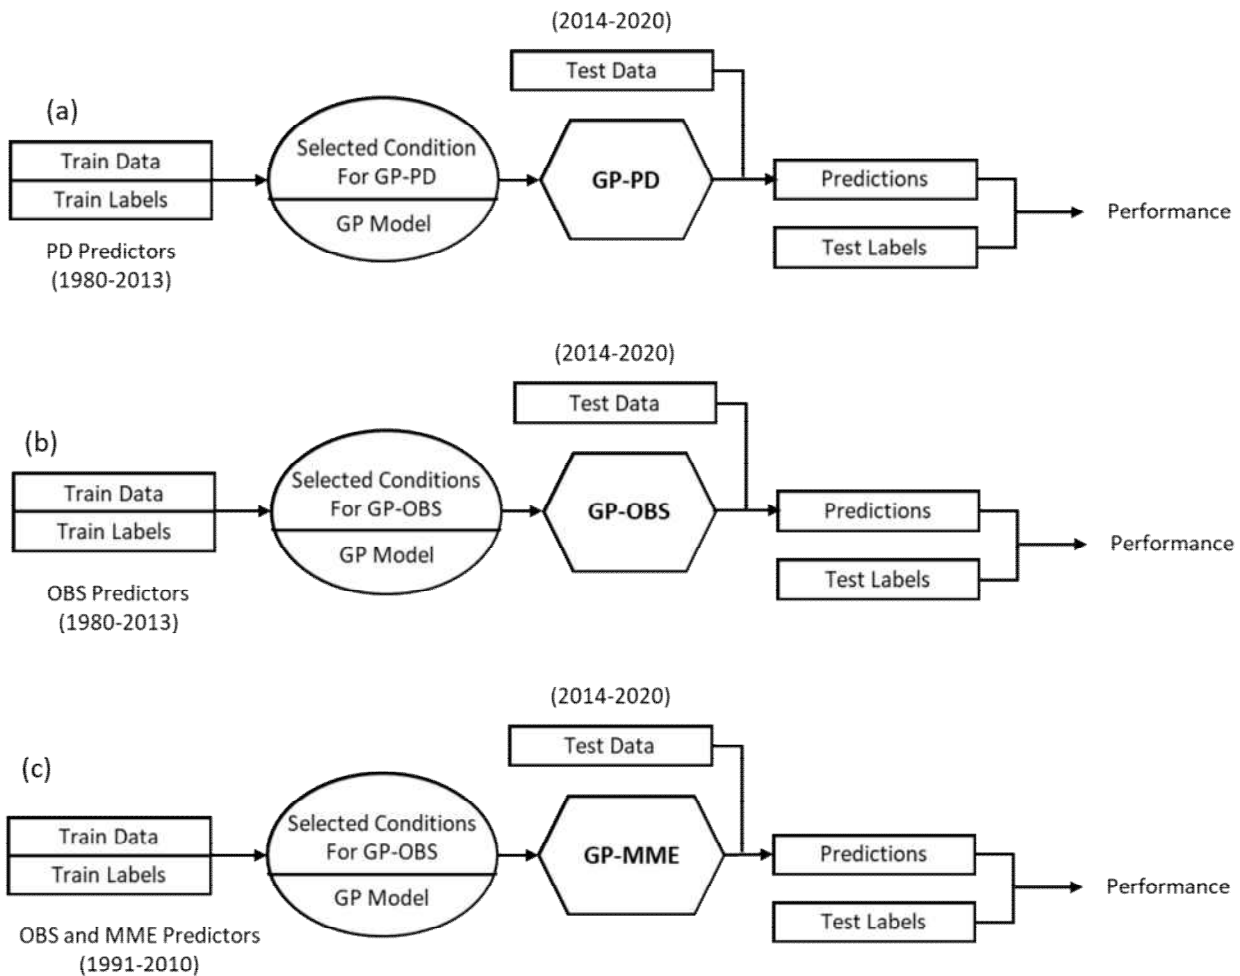


Figure 7. The GP models (a) with pre-determined predictors from observations (GP-PD), (b) with objectively derived predictors from observations (GP-OBS), and (c) with objectively derived predictors from observations and MME (GP-MME) were developed based on selected conditions. Then final model performances were evaluated for the test period. Adopted from Rhee and Myoung (2021).

(다) 모델 및 관측 정보를 통합한 객관적 정보결합 방법론

개별역학모델의 경우 초기조건, 자료통화 시스템, 모델의 물리과정 등을 다양하게 적용하여 방대한 앙상블 멤버의 예측 결과를 얻고 이를 활용한다. 이와 비교하여 여러 기관의 모델 결과를 활용하는 경우를 poor man's ensemble이라고 하며(Wobus and Kalnay, 1995; Ebert, 2001), 여러 개별역학모델의 다양한 조건 및 예측기법 등으로부터 불확실성 정보를 제공하는 장점이 있다(Du et al., 2018). 일반적으로 다양한 모델의 결과를 선형으로 결합하는데, 단순 모델 평균(Simple Model Average, SMA)의 경우 각 모델의 가중치를 동일하게 적용한다(Hagedorn et al., 2005). SMA의 경우 성능이 좋은 모델과 성능이 좋지 못한 모델의 예측 결과가 같은 비중으로 반영된다는 단점이 있다.

다양한 모델 결과의 결합은 여러 역학모델 결과의 결합에 국한하지 않고 여러 기계학습 및 통계모델 결과에도 적용할 수 있는데. 이러한 객관적 결합을 통해 안정적인 예측정보를

생산할 수 있다. 각각의 모델의 경우 목표월과 목표변수, 선행시간에 따라 성능의 변동이 있을 수 있는데, 각 목표월과 목표변수 등에 대해 모든 가용한 모델의 결과를 참고하기보다는 각각의 경우마다 훈련기간 동안 예측성능이 높은 모델을 선정하여 참고하거나 훈련기간 동안의 성능을 이용하여 모델마다 다른 가중치를 적용하는 기법을 활용할 수 있다. 이 연구에서는 베이저안 모델 평균(Bayesian Model Averaging, BMA)과 다중모델 슈퍼앙상블(Super-ensemble) 방법을 조사하여 적용하였다.

① 다양한 기계학습모델

객관적 정보결합에 활용된 기계학습모델의 목록 및 각 모델의 개요는 다음과 같다.

Table 6. Machine learning models used for objective combinations.

Model	Description	Output
ANN	Artificial Neural Networks	Deterministic
RF	Random Forest	
Adaboost	Adaptive Boosting	
SVR	Support Vector Regression	
GP-PD	Gaussian Process (with Pre-Determined predictors)	Deterministic / Probabilistic
GP-OBS	Gaussian Process (with Obs.-based predictors)	
GP-MME	Gaussian Process (with Obs. and MME predictors)	

㉠ 각 모델 개요

인공신경망

인공신경망 개념은 1940년대에 시작되었는데(McCulloch and Pitts, 1943), 인간의 신경구조는 여러 스위치를 연결해서 모의할 수 있으며 이를 이용해 컴퓨터의 계산 능력을 향상시킬 수 있을 것으로 전망하였다. 최초의 인공신경망 모델은 퍼셉트론으로(Rosenblatt, 1957) 인간 뇌의 신경 활동을 모방하도록 뉴런을 수학적으로 구조화하였으며 뉴런은 각각의 입력층에 대해 입력값과 가중치를 곱한 것의 합에 편향을 더하여 활성화함수를 적용하여 출력값을 생산한다. 퍼셉트론 알고리즘을 향상시켜 회귀 문제에 적용할 수 있게 한 에이다라인(Adaline) 모델도 개발되었다(Widrow and Hoff, 1960). XOR (Exclusive OR) 문제 해결을 위해 은닉층을 지닌 다층퍼셉트론(Multi-Layer Perceptron, MLP)이 제안되었으며 MLP에서 가중치 업데이트 문제를 해결하기 위해 역전파(Backpropagation) 알고리즘이 제안되었다(McClelland et al., 1986). 오늘날에도 지도 학습을 위해서는 다층 전방향 역전파 신경망(Multilayer Feedforward Backpropagation Network) 등이 많이 사용된다. 가중치의 업데이트를 위한 학습은 기본적으로 경사하강법(Gradient Descent)에 기반한 알고리즘을 통해 이루어지며 활성화함수로 과거 시그모이드(sigmoid) 함수를 많이 사용하였으나 은닉층의 증가와 함께 기울기 소멸(vanishing gradients) 문제가 발생하여 근

래에는 렐루(ReLU) 함수, 하이퍼볼릭탄젠트(tanh) 함수 등이 많이 활용된다.

랜덤포레스트

랜덤포레스트는 기본학습자(base estimator)로 결정트리(Decision Tree)를 이용하는데, 결정 트리는 분류의 경우 순도가 증가하고 불순도 혹은 불확실성이 최대한 감소하는 방향으로, 회귀의 경우 평균제곱오차 또는 평균절대오차 등이 감소하는 방향으로 학습을 진행한다. 결정 트리는 훈련 자료로부터 직접 규칙과 조건들을 생성하여 전문가 시스템을 훈련하므로, 전문가 시스템의 결과를 평가할 수 있고 결론에 어떻게 도달했는지 역으로 확인할 수 있다. 또한 입력변수의 분포에 대해 어떠한 가정도 필요없으며 입력변수 사이의 비선형적 및 계층적 관계를 밝힐 수 있는 장점이 있다. 랜덤포레스트(Random Forest; Breiman, 2001)는 여러 결정트리를 취합하여 과적합을 줄이고 학습 성능을 높이는 앙상블 기법으로, 각 트리에 대해 사용할 자료를 같은 크기와 확률분포를 갖도록 일부 무작위 복원 추출하는 자료 부트스트랩(Bootstrap) 랜덤 샘플링과 각 트리에서 가지를 나눌 때마다 입력변수 중 일부를 무작위 복원 추출하는 입력변수의 랜덤 샘플링을 이용하여 모델이 이상치와 노이즈에 대해 안정적인 성능을 가지도록 하며 과적합을 줄인다.

에이다부스트

에이다부스트(Freund and Schapire, 1997)는 이상치나 노이즈에 민감한 메타 학습자(meta-estimator)로 여러 학습 알고리즘의 결과물들을 가중치를 두어 더하여 학습 성능을 높이는 가속화 기법이다. 약한 학습기(weak learner)의 결과물에 가중치를 주어 성능을 향상시키는데, 즉 M개의 약한 학습자가 있다고 할 때 순차적으로 첫번째 학습자에 대해 N개 자료의 초기 가중치는 $1/N$ 으로 동일하게 설정하고 분류 또는 회귀를 수행하여 분류가 잘못되었거나 오차가 큰 자료의 가중치를 증가시킨다. 두 번째 학습자에서 업데이트된 가중치를 이용하여 분류 또는 회귀를 수행하고 학습자 결과에 학습률을 곱하여 더하여 가중치를 업데이트하며 이러한 과정을 M번 반복하여 완벽한 분류 또는 회귀 시 종료한다. 이 연구에서는 기본학습자로 결정 트리를 사용하였다.

서포트벡터회귀

서포트벡터머신(Support Vector Machine, SVM; Platt, 1999, Pal and Mather, 2005)은 클래스의 경계에 놓여있는 훈련 자료들(서포트 벡터) 사이의 마진을 최대화하도록 분류를 수행하는 방법으로, 그 마진의 중간이 클래스를 분리하는 최적의 초평면(hyperplane)이 된다. 선형의 초평면을 찾는 것이 불가능할 경우 커널 함수를 이용하여 고차원 공간으로 변환하여 적합한 초평면을 찾으며, 훈련 과정에서 잘못 분리된 자료에 음의 가중치를 주어 그 영향을 줄인다. 적은 훈련 자료만으로도 정확한 분류를 수행하는 것으로 알려져 있다.

서포트벡터회귀(Support Vector Regression)는 SVM을 회귀 문제에 적용한 것으로, 단순선형회귀를 위한 최소제곱법(Ordinary Least Squares, OLS)에서 목적함수가 예측값과 관측값의 차이의 제곱을 최소화하도록 설정되는 것과 비교하여 서포트벡터회귀에서는 목적함수가 회귀계수의 제곱을 최소화하도록 설정된다(단, 예측값과 관측값의 차이(절대오차)가 특정한 마진(최대오차)보다 작도록 함). 최대오차보다 더 큰 오차를 가지는 자료가 있을 수 있으므로 여유변수(slack variable)로 마진으로부터의 거리를 정의하여 이 거리의 합에 초매개변수 C를 곱한 값을 더하여 목적함수를 정의할 수 있으며 초매개변수 C값을 조정하여 최대오차 밖으로 허용하는 범위를 정할 수 있다.

㉑ 성능평가 조건

위 4가지 기계학습모델은 가우시안 프로세스 모델과는 달리 모델의 초매개변수를 선정하지 않았으므로 우선 각 모델에 대해 1980-2013 기간에 대해 LOOCV를 통해 초매개변수를 구하고 2014-2020 기간에 대해 성능을 검토하였다(관측기반 객관적으로 도출된 GP-OBS의 입력자료 이용). 이 연구에서 다양한 기계학습모델을 구축하여 예측 결과를 생산하는 목적은 여러 모델의 객관적 정보결합을 테스트하는 것이므로, 초매개변수 선정 시 전체적인 Grid Search를 수행하지는 않고 주요 초매개변수의 몇몇 조합을 테스트하였다. 객관적 정보결합을 위해 1991-2020의 기간에 대해 다시 LOOCV를 수행하여 예측 결과를 생산하고 성능을 평가하였다(MME 포함한 GP-MME 입력자료 이용).

장기예보 가이드스 인자를 활용한 모델(GP-PD), 관측기반 객관적 인자 도출 모델(GP-OBS)과 APCC MME와 관측을 결합한 모델(GP-MME)에 대해서는 기존 모델 개발을 위해서는 초매개변수 및 조건 선정을 위해 GP-OBS 모델을 이용하여 1980-2013의 기간을 이용하여 Leave-One(year)-Out 교차검증(Cross Validation, CV)을 실행하고 모델의 성능을 2014-2020 기간에 대해 검증하였는데, 이 연구에서는 이미 선정된 초매개변수 및 조건을 활용하므로 전체 기간인 1980-2020의 41년의 기간에 대해 LOOCV를 수행, 그 결과를 평균하여 모델의 성능을 평가하였다. 단, GP-MME의 경우에는 1980-2020 기간 중 MME 존재하는 1991-2020 기간을 적용하였다. 목표월 1-12월, 선행시간 1-3개월의 평균기온(TMm), 최저기온(TNm), 최고기온(TXm) 및 강수(SPI1을 산정하여 활용)에 대해 예측성능을 평가하였으며 편차산정, SPI산정, MME 편의보정 등의 기준기간은 1991-2020 기간을 사용하였다. GP-PD의 경우 인자가 존재하지 않는 목표월의 경우 예측이 불가하였다.

㉒ 다양한 개별역학모델 및 APCC MME

객관적 정보결합에 활용된 개별역학모델의 목록은 다음과 같다. APCC에서 MME 생산을 위해 예측 결과를 제공받는 모델 중 1-3개월 선행시간의 예측을 포함하는 9개 모델을 식별하였으며 이 중 최근에(2021년 8월) 모델이 변경된 CMCC를 제외하고 8개 모델을 사용하였다.

Table 7. Climate models used for objective combinations.

Institute, Model	Ens. (H/F)	Forecast Period	Hindcast period	Atmosphere Model Resolution	Output
APCC, SCOPS	10/10	6-month	1982-2013	T159, L31	Deterministic / Probabilistic
BCC, CSML1M	24/24	6-month	1991-2015	T106, L26	
CWB, TCWB1Tv1.1	30/30	6-month	1982-2019	T119, L40	
KMA, GLOSEA5GC2	12/42	6-month	1991-2016	N216, L85	
MSC, CANSIPsv2	20/20	11-month	1981-2010	T63, L35	
NASA, GEOS-S2S-2.1	10/11	8-month	1982-2016	288x181, L72	
NCEP, CFSv2	20/20	6(9)-month	1982-2010	T126, L64	
PNU, CGCMv2.0	35/35	6-month	1980-Present	T42, L18	
APCC, MME (SCM)	-	6-month	1991-2010	-	Deterministic

㉔ 성능평가 기준 및 조건

우리나라를 포함한 두 개의 그리드 값을 평균해서 사용하였으며, 목표월 1-12월 및 선행 시간 1-3개월의 평균기온(TMm) 및 강수(SPII를 산정하여 활용)에 대해 예측 성능을 평가하였다. 편차산정, SPI산정, 편의보정 등의 기준기간은 1991-2020년을 사용하였으며 성능 평가는 1980-2020년의 41년 기간 중 모델 예측자료가 존재하는 기간에 대해 수행하였다.

㉕ 개별모델 평균기온 및 SPII 산정 과정

연도별, 월별, LT별, 앙상블 멤버별로 평균기온 및 강수에 대해 우리나라를 포함한 두 개의 그리드 평균 값을 산정하였다. 연도별, 월별, LT별, 앙상블 멤버별로 평균기온은 편차를 산정하고, 강수는 평균하여 SPII를 산정하였다. 이때 Hindcast 기간과 Forecast 기간에 대해 앙상블 멤버 개수가 상이한 모델도 있으며 기간별로 앙상블 멤버 수가 변화하기도 하므로 평균기온 편차를 산정하기 위한 평균, 또는 SPII 산정을 위한 평균, 표준편차를 얻기 위한 자료의 pool은 월별 그리고 LT별로 구성하였다(즉, 모든 앙상블 멤버 자료 통합). 연도별, 월별, LT별로 SPII에 대해 앙상블 멤버 값의 평균 및 표준편차(스프레드)를 산정하였다. 평균기온의 경우 관측과 비교하여 모델 예측값의 편차가 작은 경향이 있으므로 비교·평가하기 위해 기준기간의 관측값을 이용하여 각 앙상블 멤버의 편차값을 편의보정하였으며 연도별, 월별, LT별로 편의보정된 평균기온에 대해 평균 및 표준편차(스프레드)를 산정하였다.

㉖ APCC MME 평균기온 및 SPII 산정 과정

SCM 결과에 대하여 연도별, 월별, LT별로 평균기온 및 강수 편차값을 읽고 두 개의 그리드 평균 값 산정하였다. 강수 편차값을 이용하여 연도별, 월별, LT별 SPII 값 산정하였으며 평

균기온의 경우 관측과 비교하여 모델 값의 편차가 작은 경향이 있으므로 비교·평가하기 위해 기준기간의 관측값을 이용하여 편의보정하였다.

③ 베이저안 모델 평균

BMA는 사회과학, 건강 분야에서 다양한 통계 모델의 결과를 결합하기 위해 사용하던 방법론으로 역학모델의 앙상블 예측 후처리를 위한 기법으로 확장되었으며(Raftery et al., 2005) 다양한 통계적 예측 모델의 결합을 위해 활용되어 왔다(e.g., Zhang et al. 2019). BMA 확률분포함수는 결합된 각 개별모델의 조건부 확률분포함수(정규분포 가정)의 가중평균으로, 각 모델의 가중치는 개별모델의 훈련기간에 대한 상대적인 예측성능이 반영된 사후확률이 된다. 개별모델의 앙상블 스프레드(Ensemble Spread)는 모델간 분산(Between-model Variance)만을 나타내는데 비하여 BMA 예측 분산은 모델간 분산과 모델내 분산(Within-model Variance)을 모두 포함한다(Raftery et al., 2005).

훈련기간의 예측값은 이미 편의보정된 값이라고 하더라도 관측값과의 단순선형회귀를 통해 추가로 보정한 후 이용하기도 하는데(Raftery et al., 2005), 이 연구에서는 특히 훈련기간의 성능이 좋지 않은 모델의 경우 추가로 보정하였을 때 예측값의 오차가 지나치게 커지는 경우가 종종 발생하여 Zhang et al. (2019)의 경우와 같이 추가적인 보정은 적용하지 않았다. BMA 예측 시 최대우도법을 통해 로그우도함수 값이 최대가 될 때까지 가중치와 분산을 Expectation-Maximization (EM) Algorithm (Dempster et al., 1977)을 이용하여 업데이트한다(Raftery et al., 2005, Zhang et al., 2019). Raftery et al. (2005)는 개별모델의 예측 분산이 같다고 가정하였으나 각 모델의 성능 차이가 큰 경우를 고려하기 위해 모델 고유의 분산을 추정하였다(e.g., Fang and Li, 2016; Zhang et al., 2019).

BMA 산정 과정은 초기화, EM 알고리즘의 Expectation 단계, Maximization 단계로 나누어 설명할 수 있다.

㉑ 초기화

w_k 는 모델 k의 가중치, σ_k^2 는 모델 k의 분산이며 t는 훈련자료의 시점(전체 개수 T), k는 모델(k = 1, ..., K)이며 y_t 는 시점 t에서의 관측값, f_{kt} 는 시점 t에서 모델 k의 예측값이다.

$$\begin{aligned} j &= 0 \\ w_k^{(j)} &= K^{-1} \end{aligned} \quad [9]$$

$$j = 0$$

$$\sigma_k^{2(j)} = \frac{1}{T} \sum_t \sum_{k=1}^K [y_t - f_{kt}]^2 \quad [10]$$

㉞ EM Algorithm의 Expectation 단계

E단계에서는 잠재변수 z 를 정의하여 추정하는데, z 는 시점 t 에서 모델 k 가 가장 우수한 모델일 때 1, 그 밖의 경우 0 값을 가지는 변수로 정의됨. 아래 식과 같이 추정할 수 있으며 추정값은 0과 1 사이의 값을 가짐. $g_k(y_t|f_{kt}, \sigma_k^2)$ 는 평균이 f_{kt} , 분산이 σ_k^2 인 정규분포의 y_t 에서의 확률밀도가 된다.

$$z_{kt}^{(j)} = \frac{w_k^{(j-1)} g_k(y_t|f_{kt}, \sigma_k^{2(j-1)})}{\sum_i w_i^{(j-1)} g_i(y_t|f_i, \sigma_i^{2(j-1)})} \quad [11]$$

㉞ EM Algorithm의 Maximization 단계

M단계에서는 추정된 z 를 이용하여 가중치와 분산을 업데이트한다.

$$w_k^{(j)} = \frac{1}{T} \sum_t z_{kt}^{(j)} \quad [12]$$

$$\sigma_k^{2(j)} = \frac{\sum_t z_{kt}^{(j)} [y_t - f_{kt}]^2}{\sum_t z_{kt}^{(j)}} \quad [13]$$

㉞ 반복

로그우도함수의 증가분이 매우 작아질 때까지 E단계와 M단계를 반복하는데, Zhang et al. (2019)의 경우 $1e-8$ 을 기준으로 사용하였는데 이 연구에서는 가중치 산정의 신속함을 위하여 $1e-5$ 기준을 사용하였으며 도중에 로그우도함수값이 증가하는 경우 반복을 멈추고 그 전 값을 사용하였다.

$$l[w_1^{(j)}, \dots, w_k^{(j)}, \sigma_1^{(j)}, \dots, \sigma_k^{(j)}] = \sum_t \log \left\{ \sum_{k=1}^K w_k^{(j)} g_k(y_t | f_{kt}, \sigma_k^{2(j)}) \right\} \quad [14]$$

④ 다중모델 슈퍼앙상블

다중모델 슈퍼앙상블(Super-ensemble) 방법은 Krishnamurti et al. (1999), Krishnamurti et al. (2000), Krishnamurti et al. (2016)에 제안되었으며 훈련자료를 이용하여 각 위치(수직 및 수평), 예측 변수, 예측일 등의 조합 각각에 대하여 사용 모델의 가중치를 구하고 검증자료에 반영한다. 위치(grid locations; 수평 및 수직), 예측 변수(base variables), 예측일(forecast intervals)의 각각의 조합에 대해 모든 사용 모델들(member models)에 대해 모두 가중치를 구하므로 가중치의 수가 매우 많아지는데, 다시 말하면 각각의 위치, 변수, 예측일 조합에 대하여 사용 모델들에 대한 가중치 집합이 정해진다. 이 연구의 경우에는 우리나라에 위치한 두 그리드 평균에 대한 예측만을 테스트하므로 예측 변수, 목표월 및 선행시간의 조합에 대해 각 모델의 가중치가 구해지게 된다.

슈퍼앙상블의 산정 과정은 다음과 같다. 단정예측의 경우 가중치를 정할 때 다중회귀모델을 사용하여 다중회귀모델의 회귀계수를 가중치로 사용하며, 확률예측의 경우 각 모델의 Continuous Ranked Probability Score (CRPS) 값의 역수를 가중치로 사용하여 다중모델 확률분포함수를 얻는다(Cane et al., 2012). X 가 확률변수, F 는 X 의 누적분포함수($F(y) = P[X \leq y]$)이며 x 가 관측값인 경우, x 와 F 사이의 CRPS는 다음과 같이 정의됨. 이때 H 는 Heaviside step function으로, 인수가 0이나 양수이면 1, 그 밖의 경우 0 값을 가진다.

$$CRPS(F, x) = \int_{-\infty}^{\infty} (F(y) - H(y - x))^2 dy \quad [15]$$

$$CRPS(F, x) = \int_{-\infty}^x F(y)^2 dy + \int_x^{\infty} (F(y) - 1)^2 dy \quad [16]$$

(2) 신기술을 적용한 동아시아 계절내 예측성 개선

(가) 기후자료

① ERA-5 재분석자료

유럽중기예보센터(ECMWF, European Centre for Medium-range Weather Forecasts)에서는 2006년부터 기존에 제공되던 저해상도의 ERA-Interim reanalysis를 대체하기 위해 ERA-5 reanalysis 연구를 시작하였다. ERA-5는 새로운 통합예측시스템(IFS, Integrated Forecasting

System) Cycle 41R2을 적용하여 고해상도 $0.25^\circ \times 0.25^\circ$ 격자자료를 제공한다. ERA-5 데이터는 기존 ERA-Interim 자료의 수평해상도 80km가 31km로 향상되었다. ERA-5 데이터는 ECMWF의 코페르니쿠스 기후 변화 서비스(C3S, Copernicus Climate Change Service)에 의해 생산된다 (Hersbach et al., 2020). 본 연구에서는 1950년부터 2020년까지 공간해상도 $1.5^\circ \times 1.5^\circ$ 의 6시간 단위 ERA-5 재분석자료 중 T2M, Z500, PREC, MSLP, TMIN, TMAX, SP, Q850, SST, V850, U850, V200, U200 등의 변수를 수집하고 일 단위자료로 변환하여 사용하였다. Table 8은 수집한 ERA-5 재분석 자료에 대한 요약정보이다. 수집된 ERA-5 재분석자료 중에서 T2M 변수를 대상으로 연구를 수행하였다.

Table 8. Summary of ECMWF ERA-5 reanalysis data downloaded in this study

Variable	Long name	Unit
T2M	2 meter temperature	K
Z500	Geopotential height at 500 hPa	$m^2 s^{-2}$
PREC	Total precipitation	m
MSLP	Mean sea level pressure	Pa
TMIN	Minimum temperature at 2 metres since previous post-processing	K
TMAX	Maximum temperature at 2 metres since previous post-processing	K
SP	Surface pressure	Pa
Q850	Specific humidity	$kg kg^{-1}$
SST	Sea surface temperature	K
V850	V component of wind at 850 hPa	$m s^{-1}$
U850	U component of wind at 850 hPa	$m s^{-1}$
V200	V component of wind at 200 hPa	$m s^{-1}$
U200	U component of wind at 200 hPa	$m s^{-1}$
OLR	Top net thermal radiation	$J m^{-2}$

② 기상자료(Climatology Data)

기상자료는 일단위로 변환된 1991년부터 2020년까지 30년 기간의 ERA-5 재분석자료를 이용하여 Eq. 17을 이용하여 1월1일부터 12월31일(윤달포함)까지 일자별로 위경도 격자별로 평균값을 계산하여 일자별로 생산한다.

$$C_{day,lat_i,lon_j} = \frac{\sum_{p=1}^{n_{day}} d_{day,p,lat_i,lon_j}}{n_{day}} \quad [17]$$

여기서, day 는 일자, lat_i 은 i 번째 위도, lon_j 는 j 번째 경도, d_{day,p,lat_i,lon_j} 은 i 번째 위도와 j 번째 경도의 총 기간 중 p 번째 day 날짜의 자료, n_{day} 는 1991년부터 2020년까지 30년 기간의 day 날짜의 총 데이터수이다. 2월 29일을 제외한 날짜는 데이터가 30건이고 2월 29일은 1992년, 1996년, 2000년, 2004년, 2008년, 2012년, 2016년, 2020년 총 8건이다.

(나) 시계열 예측을 위한 딥러닝 모델 설계 및 평가방법

① 동아시아 계절내 1개월 전망예측을 위한 딥러닝 모델 설계

시계열 데이터와 같이 시퀀스 데이터(sequence data)에는 순환 신경망(RNN, Recurrent Neural Network), 장단기 메모리(LSTM, Long Short Term Memory), 게이트 순환 유닛(GRU, Gated Recurrent Unit) 등이 이용이 된다(Figure 8). 이러한 모델들을 응용하여 음성, 텍스트 등을 이용한 TTS(Text-To-Speech), 음성인식(STT, Speech-To-Text 등), 언어 번역(language translation) 등에 주로 사용되어 왔다. 이러한 장·단기 기억을 통해 문제를 해결하는 방법을 시계열 예측 문제 해결을 위해 활용하는 연구가 많이 진행되고 있다.




Figure 8. Structures of RNN, LSTM, and GRU (<http://dprogrammer.org/rnn-lstm-gru>)

기존에 많이 사용되어 온 RNN, LSTM, GRU 같은 기법은 시계열 문제를 해결하는데 유용하지만, 기상/기후 분야에서는 시공간 데이터 모델(spatio-temporal data model)을 다루기 때문에 특정 지점뿐만 아니라 주변 데이터의 영향까지 고려해야 한다는 점에서 적용하기에는 다소 한계가 있다. 이러한 한계를 해결하기 위해 Shi et al.(2015)는 강우레이더 데이터로 강우 예측 문제(precipitation nowcasting problem)에 적합한 종단간 학습모델(end-to-end trainable model)인 convolutional LSTM(ConvLSTM)을 제안하였다. ConvLSTM은 일반적인 CNN (Convolutional Neural Network)로 처리 후 LSTM 방식으로 학습하는 방식이 아니라 1차원 데이터 구조가 아니라 2차원 이상의 데이터를 처리할 수 있도록 LSTM 구조 내에 CNN을 넣은 구조로 설계를 하였다. ConvLSTM은 그래픽카드 하드웨어적인 관점에서는 layer 구조에 따라 GPU memory를 많이 필요하다. 예를 들어, Time, Lat, Lon, Variable로 구성된 4차원(dimension) 입력 자료를 ConvLSTM으로 구성하면 필터 크기만큼 4차원 데이터로 처리하기 때문에 그 만큼 많은 GPU memory를 필요로 한다. 반면, 단순 CNN 구조는 Time, Lat, Lon, Variable로 구성된 4차원 입력

자료를 3D CNN이 아닌 2D CNN으로 처리할 때는 데이터 구조를 Variable과 Time을 순차적으로 나열해서 Lat, Lon, Variable+Time인 3차원 데이터로 처리하기 때문에 필터 크기에 따라 2D CNN 구조에서는 ConvLSTM에 비해 GPU memory를 많이 필요로 하지는 않는다.

ConvLSTM 외에도 Ronneberger et al.(2015)이 바이오메디컬 분야에서 이미지 분할(segmentation)을 목적으로 제안한 U-NET 모형을 시계열 예측에 활용된다. U-NET 모형은 이미지의 context를 캡처하는 contracting path와 contracting path에서 캡처된 특징맵을 이용하여 정밀한 localization을 가능하게 하는 expanding path로 구성된다. contracting path와 expanding path는 각 인코더(encoder)와 디코더(decoder)로 불리기도 한다. 그리고 모형의 구조가 U와 닮았다고 하여 U-Net 으로 불린다.

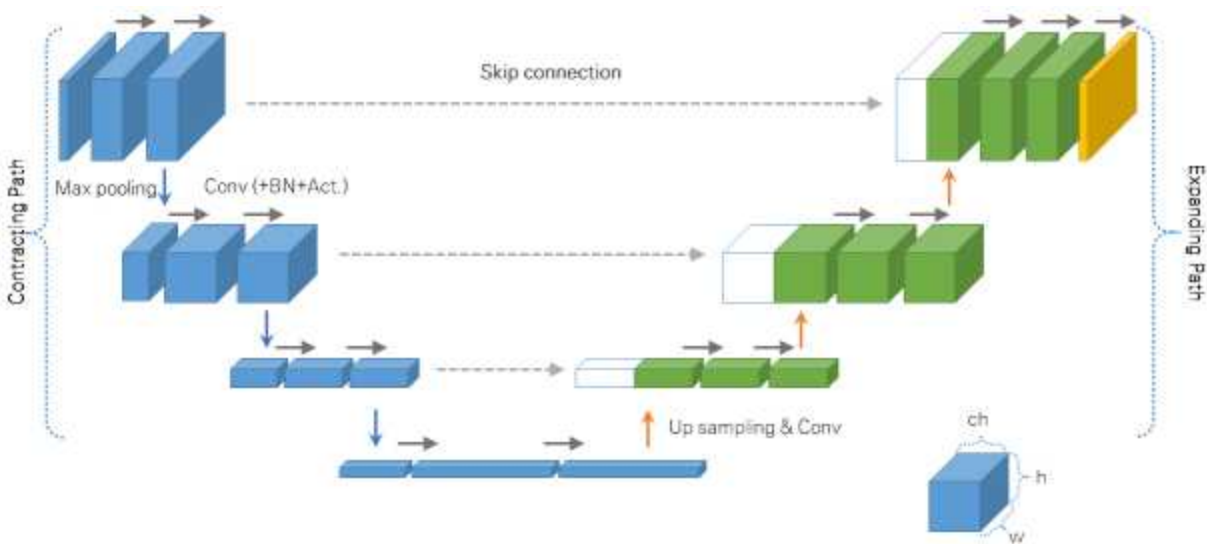


Figure 9. Concept of vanilla U-NET

본 연구에서는 Azad et al.(2019)이 의료영상 분류(medical image segmentation)를 위해 U-NET을 확장하여 제안한 BCDU-Net (Bi-direction ConvLSTM U-Net with Densely connected convolutions)을 기반으로 총 5종류의 네트워크를 설계하였다 (Table 9). BCDU-Net 모형은 Figure 9를 기초로 깊이 3, densely connected convolutions, skip connection에 Bi-directional ConvLSTM을 추가하여 설계하였다. Case 1~5 모두 BCDU-Net 모형을 기초로 설계하였다. Case 1은 BCDU-Net에서 Ronneberger et al.(2015)이 제안한 기법을 제외한 기법들을 제거해서 만든 기본 U-NET 모형이다. Case 2는 기본 U-NET 모형에 U-Net의 contracting path와 expanding path 구간을 연결해주는 bottleneck에 Huang et al.(2017)이 제안한 DenseNet(Dense Convolutional Network)의 densely connected convolutions 기법을 적용한 모형이다. Case 3은 Azad et al.(2019)이 제안한 모형이다. Case 4는 Case 3의 모형 구조에 Hu et al.(2018)이 제안한 channel-attention mechanism인 SE (Squeeze and excitation) 블록을 up sampling 과정에 포함하여 설계하였다(Figure 10). Case 5는 Case 4에 contracting path 부분만을 Simonyan and Zisserman(2014)이 제안한 VGG (Visual Geometry Group) 팀의 VGG 16 모형로 사전 학습된 모형의 가중치 등을 사용하는 모형이다.

Table 9. Summaries of deep learning models tested in this study

Model No	Concept of Model Structure ^a	Remarks
Case 1	Vanilla U-Net	
Case 2	Vanilla U-Net + three densely connected convolutions	
Case 3	BCDU-Net-Depth3	Original BCDU-Net
Case 4	BCDU-Net-Depth3 + SE(Squeeze and excitation) blocks	
Case 5	VGG16 pre-trained model (only contracting path) + BCDU-Net-Depth3 + SE blocks	

a modified from BCDU-Net-Depth3 (Azad et al., 2019)

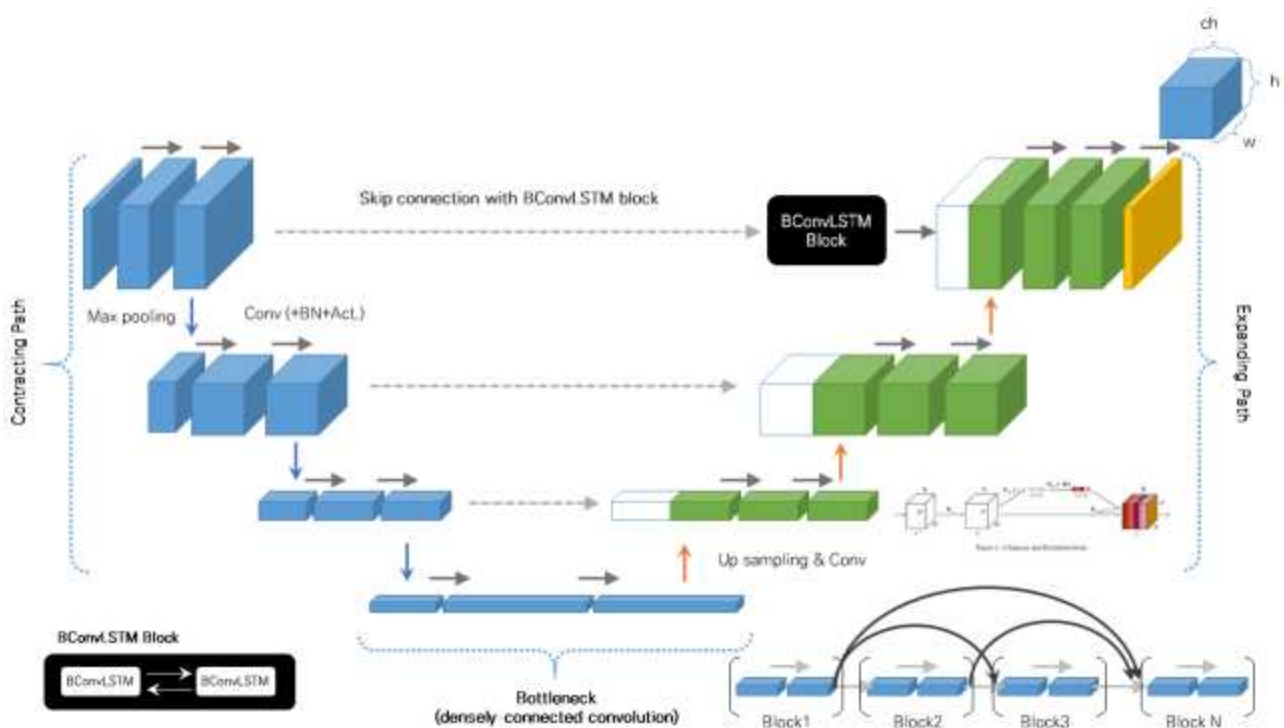


Figure 10. Design of Case 4 model

② 동아시아 계절내 1개월 전망예측을 위한 딥러닝 모델 결과 평가방법

딥러닝 모델의 예측결과와 평가지표로 ACC (Anomaly Correlation Coefficient)를 이용하였다 (eq. 27). ACC는 기후값(climatological values)을 이용하여 계산된 예측자료와 참조자료(참값) 간 아노말리의 상관관계를 의미하며 공간장(spatial fields)을 검증하는데 광범위하게 사용되는 방법 중 하나이다(Jolliffe and Stephenson, 2003; JMA, 2013 재인용).

$$ACC = \frac{\sum_{i=1}^n w_i f_i a_i}{\sqrt{\sum_{i=1}^n w_i f_i^2 \sum_{i=1}^n w_i a_i^2}}, w_i = \cos\phi, f_i = F_i - C_i, a_i = A_i - C_i \quad [18]$$

여기서, w_i 는 위도별 $\cos\phi$, f_i 는 예측값(F_i)과 기후자료(C_i)로 계산한 아노말리, a_i 는 관측값(A_i)와 기후자료(C_i)로 계산한 아노말리이다. ACC 값은 -1 ~ 1 사이의 값을 가지며 1에 가까운 양의 편차를 보일수록 예측값과 관측값 간에 상관관계가 높다는 것을 의미한다.

(다) 현업관점에서의 동아시아 지역 계절내 예측방법

APEC 기후센터는 세계 여러 기관에서 받은 기후자료를 바탕으로 매주 1개월 전망예측자료를 생산하고 있다. Figure 11은 ECMWF 예보자료를 이용한 1개월 전망자료 생산 일정에 대한 예시이다. ECMWF를 비롯해 여러 기간에서 예보자료를 2021년 8월 2일에 수신하면 2주 뒤인 16일~22일(F1, 1주), 23일~29일(F2, 2주), 30일~9월5일(F3, 3주), 9월6일~12일(F4, 4주)을 APEC 기후센터에서 개발한 SCM(Simple Composite Method), PMME(Probabilistic Multi Model Ensemble) 등을 기법을 이용하여 1개월 전망자료를 생산한다.

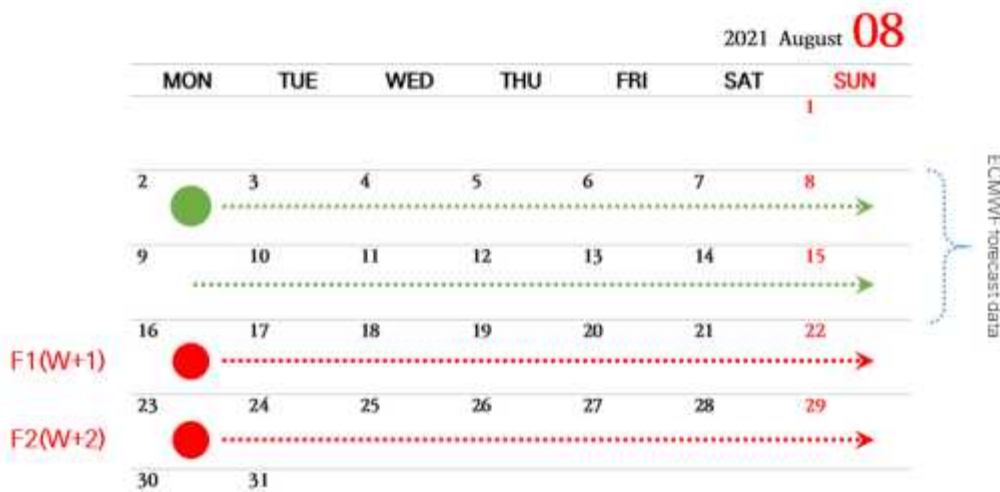


Figure 11. Example of an one-month forecasting schedule operated by the APEC Climate Center

본 연구에서는 현업관점에서의 1개월 전망자료를 생산하는 방법을 월요일에 수신된 ECMWF의 예측자료를 이용하여 2주 뒤인 예보 1주(F1), 예보 2주(F2)에 대해 예측을 하고자 하였다. 이는 ECMWF 예보자료의 1~2주 예측력이 3주 이후의 예측력에 비해 상대적으로 높은 예측성을 보이고, 현업에서 필요한 예보자료는 2주 뒤인 예보 1주차부터 필요하기 때문이다.

개발된 딥러닝 모델을 이용하여 ECMWF 일단위 예보자료의 1-2주 데이터를 입력자료로 이용하여 3-4주(예보 1-2주차) 예측을 수행하고자 한다.

나. 장기예보 모델정보 개선 및 적용

(1) 현업모델 편차보정을 통한 1개월 기온예보 콘텐츠 개발

(가) 관측 및 모델자료

① 현업모델 자료

기상청 현업모델(GloSea5)의 과거재현자료(hindcast)의 경우, 매일 생산하는 예측장(forecast)와 달리 특정일(1, 9, 17, 25일/매월)을 hindcast 적분 시작일로 정의하여 초기화한다. 이때, 예측장에 준하는 매일의 hindcast 결과가 필요하기 때문에, 예측장 날짜를 기준으로 전후의 가까운 hindcast 초기 날짜 2개를 찾고, 해당되는 기후장의 자료를 날짜 거리에 따른 가중평균을 하여 예측장의 날짜에 준하는 hindcast를 생산한다(Ham et al. 2017). 영국 UKMO에서도 유사한 방법으로 기후값을 계산하여, 예측값에 대한 편차 보정을 하고 있으므로, 위 방법(날짜 거리에 따른 가중평균, Figure 12)에 따라 예측장의 편차를 보정할 수 있을 것이다(Arribas et al. 2011; MacLachlan et al. 2015).

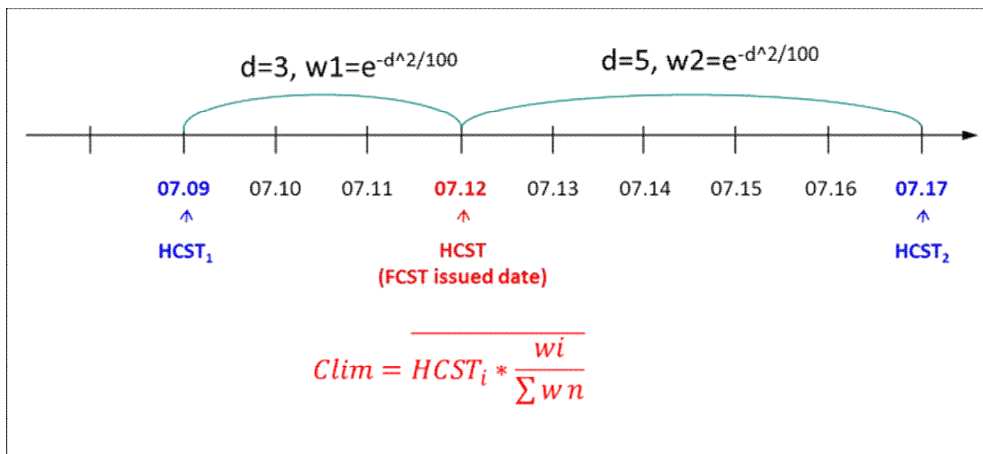


Figure 12. Illustration for date-distance weighted average using GloSea5 subseasonal hindcast.

② 통계적 훈련자료 및 관측자료

본 연구에서 사용한 통계적 훈련자료는 GloSea5의 과거재현자료로써 기간은 1991년부터 2016년까지 26년 자료이다. 모델 예측자료에 대한 실제 검증자료로써 ASOS 65개 지점의 관측 자료를 사용하였으며, 관측 기후값 산정을 위해서 2021년부터 장기예보를 위해 활용된 기후값 변경을 반영하여, 1991년부터 2020년까지의 30년 기준을 고려하였다. 최종예측 변수는 최저, 최고, 평균기온이며, 실제 예측기간(2020년 9월~2021년 6월) 동안 주별 생산한 한반도 전체 영역

평균 예측자료를 편차보정하여 65개 관측자료 전체평균과의 정확도를 비교하였다.

(나) 편차보정 방법

① Mean and variance adjustment (MVA)

앙상블 평균 및 분산을 관측과 일치하게 보정하는 방법으로써, 수년간 계절예측에 있어 가장 흔하게 사용되어 온 편차방법이다(Manzanas et al., 2019). 모델 world에서는 관측과는 다른 기후평균값이 존재하기 때문에 이를 반영한 모델 아노말리를 사용함으로써 평균을 보정한 다. 또한, 모델 world는 관측에 비해 분산이 작기때문에(overconfident, underdispersion) 모델의 분산 또한 보정해 주었다. 이에 관측 기후값을 더해 오차를 보정하였다.

② Mean bias correction (MBC)

편의값(bias)과 편의기후값(bias climatology) 사이의 통계산출식을 통해 보정하는 방법이다. 기상청 현업모델 최고·최저기온에 대한 편차를 다음과 같이 정의하였다. 매주 월요일(00KST 기준) 총 21개 멤버(최근 7일×3개/hindcast)에 대해 time-lag 앙상블을 구성하여 앙상블 평균(ensemble mean forecast)과 관측값(ASOS)의 차이를 주별 단위로 평균한 값을 편차(bias)로 정의하였다. 또한, 1991~2020년까지 30년 동안의 주별 예측자료에 대한 bias 평균치를 bias 기후값(climatology)로 정의하였다(Figure 13; Guan et al., 2019). 대개의 계절내 예측에서는 예측일 기준으로 앞뒤 31일 기간을 sampling window로 하여 bias correction sampling 수를 확보할 수 있는데, 본 연구에서는 기상청 기후예측과 현업을 위한 자료 가용성을 고려하여 예측 타겟 시점 기준 +/-15일의 time-window(초기화 4~5개)를 고려하였다.

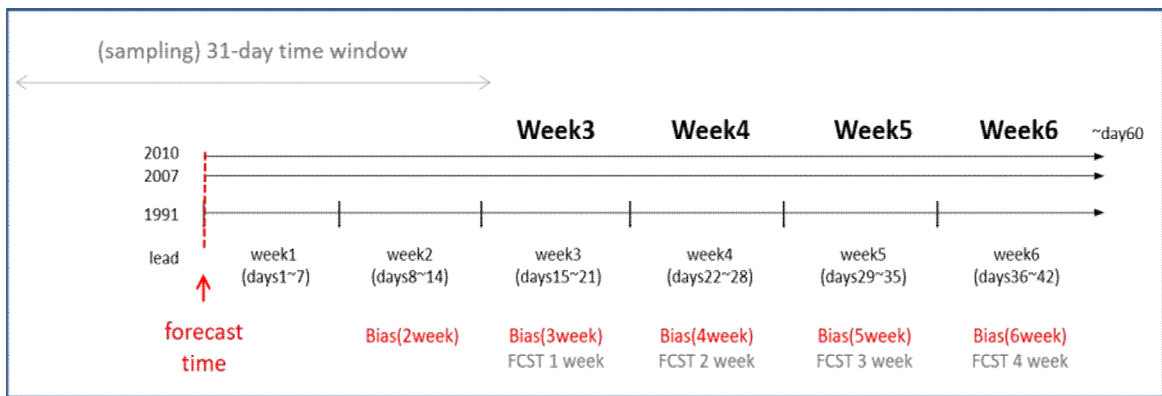


Figure 13. Diagram for bias and bias climatology definition.

편차기후값을 정의할 때 window를 어떻게 정하느냐에 따라 결과가 달라질 수 있기에, 이에 대한 민감도 비교 결과를 분석한 바 있다(2020년도 연구보고서 참조). 간단히 요약하자면,

time window에 따른 기후예측모델의 과거재현자료에서 나타나는 bias 값을 비교하였는데, 이때 window를 0로 했을 경우(window 없음), ± 15 일로 했을 경우, 그리고 -7 일로 했을 경우를 비교하였다. -7 일은 기후예측과의 현업일정을 고려한 것으로, 예측 시작 시점에 미래 시점에 대한 hindcast가 가용하지 않기 때문에 별도로 고려한 것이다. 결과를 살펴보면, time window가 0일 때를 제외하고는 window에 따른 bias가 크지 않음을 알 수 있다. 즉, time window가 일정 이상 일 때는 편차보정 후 예측성에 미치는 영향이 미미하다고 할 수 있다. 여기서 특이할 점은, 예측 타겟일을 기준으로 전/후 window($=\pm 15$ 일)를 사용한 경우와, 예측 타겟 전 시간의 window($=-7$ 일)을 사용한 경우, bias의 차이가 크지 않다. 따라서 본 연구 결과에서는 전/후 window($=\pm 15$ 일)를 사용하여 편차보정을 하였다.

③ Empirical quantile mapping (EQM)

관측자료의 확률분포와 모델자료의 확률분포를 일치시켜 보정하는 방법이다(Monhart et al., 2018). 선행연구에 따른 QM은 여러 가지 오차 보정 방법 중 하나로 실제 관측값과 모의값의 차이를 줄여주는데 있어 큰 효과를 보인다. 관측값의 분포와 동일하도록 모델의 분포를 만들기 위한 변환함수(또는 분위함수)를 찾는 과정을 말한다. 본 방법은 과거 수문분야의 유출량을 보정하는 방법으로 많이 쓰여왔는데(Wood et al., 2004), 기후분야에서도 전지구 기후예측 모델의 예측값을 실제 관측값에 맞게 보정하기 위하여 빈번하게 사용되어 왔다. 특히 QM의 경우 모수변환법(Parametric Transformation, PT), 비모수변환법(NPT), 분포기반 변환법(DDT)으로 구분하는데, 본 연구에서는 비모수변환법을 사용하였다. 비모수변환법의 하나로 경험적 추정법(empirical quantiles, EQ)를 사용하였는데, 이는 관측값과 모델에서 예측값 값의 경험적 누적분포함수를 일치시켜 변환하는 방법이다.

(다) 검증방법

① 정량적 검증

본 연구에서의 편차보정 방법에 따른 예측성을 비교평가하기 위하여, mean bias와 root mean square error(rmse)를 사용하였다. RMSE는 모델값과 실제 관측값의 차이를 평가할 때 주로 사용되며 각 모형의 정밀도(precision)를 나타내는데 적합하다. 특히 제곱단위가 아닌 원래 데이터와 동일한 단위로 측정되므로 전형적인 오류의 크기를 더 잘 나타낸다. Mean bias는 기후예측모델의 예측값과 관측값의 평균오차량을 나타낸다. 주로 예측모델의 성능을 예측하는데 사용되는 오류 성능지표이다.

② 범주예보 검증

실제 1개월 예보에서는 모델에서의 아노말리가 관측의 평년범위(normal range)의 어느 범주에 속하는지로 범주예보를 하게 된다. 예를 들어, 모델에서의 아노말리가 $+2.0^{\circ}\text{C}$, 관측의 아

노말리가 +1.5°C, 관측의 평년범위가 +/-1.8°C 라고 하면, 모델은 평년보다 높음(above normal, AN)을 예측하였으나, 실제 관측값은 평년범위(near normal, nn)에 속하게 되는 것이다. 즉, 모델과 관측값 각각에 대하여 3×3의 contingency table를 구성하여, 전체 예보 경우의 수 대비, 모델과 관측의 예보가 맞은 수의 비율로써 정확도(accuracy)를 계산한다.

(2) 여름철 계절내 진동(BSISO)를 활용한 1개월 예보 콘텐츠 개선

(가) 자료 및 방법

1개월 전망을 위한 주별 BSISO 영향 편차장은 기개발된 방법론(김해정 등, 2018)을 차용하여 매일의 BSISO 예측 지수에 관측으로부터의 합성장을 결합한 값을 주별 평균하여 산출한다. 매일의 BSISO 위상별 관측 합성장은 강수의 경우 1997년부터 2018년까지의 GPCP 자료로, 그 외 대기 변수의 경우 1981년부터 2018년까지의 NCEP/DOE Reanalysis 2 자료로 생산된 통계적으로 유의한 결과이며 예측운영과로부터 제공받는다. BSISO 예측 지수의 경우 WMO S2S ECMWF 예측자료를 활용하여 예측 기간을 6주까지 확장하였고, 기존 방법(Lee et al., 2013)과 동일하나 장주기 성분 제거 시 관측이 아닌 모델 기후장 값을 사용하여 산출하였으며 기제공되는 APCC BSISO 지수 값과 거의 유사한 결과를 보인다(not shown). 2019년 예측기술과 연구보고서의 “다중모델 기반 BSISO 영향분석 기술 개발” 파트에 기술되어 있는 연구 내용에 의하면 다른 모델에 비해 ECMWF 모델 예측 기반 BSISO 영향 편차장 결과가 아시아 몬순 지역에 있어서 3주까지 신뢰할 만한 정보를 제공함에 따라 1개월 전망 활용에 적합할 것으로 판단하였다. WMO S2S ECMWF 예측장(forecast)의 경우 46일의 예측기간, 51개의 앙상블 멤버로 구성되고 기후장(Hindcast)의 경우 2001년부터 2020년까지 총 20년의 예측기간, 11개의 앙상블 멤버로 구성되어 있으며 매주 월요일 최신 초기장 예측 결과가 제공된다. BSISO 영향 분석을 위한 우리나라 기온 및 강수는 기상청에서 제공하는 ASOS(Automated Synoptic Observing System) 56개 지점을 평균한 자료를 사용하였으며, 관련 대기 순환장의 경우 ECMWF Reanalysis v5(ERA5) 자료를 사용하였다. 분석 기간은 1981년부터 2020년까지 총 40년으로 6월부터 8월까지의 여름철 결과이다. BSISO 합성도 분석 시 Student t-test를 적용하여 통계적 유의성 검증을 수행하였다.

다. 기존 장기에보 기술의 활용가능성 평가

(1) 기존 통계모델의 예측성 및 활용성 평가

연구를 수행하기에 앞서 그동안 개발된 통계 모델의 현황을 파악하였다. 장기에보 가이드스(기상청, 2018)에 기록된 통계 모델과 기상청 기후예측과의 협조하에 확인한 통계 모델 전체 중 분석에 사용할 모델 9개를 선정하였다. 다음으로 선정된 9개 모델에 대하여 모델별로 모델을 구축하는 데 사용한 자료의 기간, 사용된 예측인자의 시·공간 정보, 예측 타깃의 기준 등을 Table10에 정리하였다.

예측 타깃으로 전국 62개 ASOS 지점에서 평균 된 기온과 강수량 자료를 사용하였고, 예측인자로 활용된 자료들은 NOAA (National Oceanic and Atmospheric administration)의 Sea Ice Cover, Sea Ice Extent, OISST (Optimum Interpolation Sea Surface Temperature), GPCP (Global Precipitation Climatology Project)의 강수량, NCEP reanalysis v2의 OLR (Outgoing Longwave Radiation) 이다.

월 강수량 모델과 장마강수량 예측 모델의 예측 타깃은 태풍에 의한 강수량을 제외한 8월 평균 강수량과 6월 15일부터 7월 29일의 평균 강수량이다. 태풍에 의한 강수량을 제거하기 위해 태풍백서(기상청, 2011)와 연도별 한반도 영향 태풍 분석보고서(기상청, 2012; 2013; 2014; 2015; 2016; 2017; 2018; 2019;) 등을 참고하여 태풍에 의해 강수가 발생한 날을 제외한 나머지 날에 발생한 강수량을 기간에 맞게 평균하여 예측 타깃으로 사용하였다. 모델 재구성을 위해 Python statsmodels 패키지의 다중 선형 회귀분석 메서드를 사용하였다. 최소자승법을 적용하여 회귀식을 피팅하고 예측값을 구하였다.

Table 10 Statistical models' information

예측시기	예측변수	통계식	분석기간 [m/yr/cst]	시기	예측인자	지역1	latS	latN	lonL	lonR	지역2	latS	latN	lonL	lonR	지역3	latS	latN	lonL	lonR	Static
DEC	TEMP	$= 0.81 \times SIC_{Laptev} + 0.73 \times ENSO - 0.19 \times SAI$	1973-2014/ 2015-2017	OCT SEP, OCT OCT	SIC SST SC	Laptev Sea Subtropical East Pacific Eurasia	65N 80N 10N 20N 25N 60N	80N 103E 150W 130W 180W 0W	150E 130W 0W		Equatorial	5S	5N	90W	110W					anomaly 두 지역 공간평균의 (10월 -9월) 경향의 평균 10월 마지막주 눈덮임 - 10월 첫째주 눈덮임 표준편차로 시계열 정규화	
JAN	TEMP	$= 0.41 \times SIC_{Kara} + 0.61 \times ENSO - 0.48 \times Z500_{Tamy} + L_{Trend}$	1974-2015/ 2016-2018	OCT SEP, OCT OCT JAN	SIC SST Z500 SAT_KOR_obs	Kara Sea Tropical East Pacific Tymyr 197	78N 82N 8S 2S 70N 80N	50E 80E 113W 97W 80E 120E	80E 97W 120E		Tropical West Pacific	13S	3S	145E	175E					anomaly 두 지역 공간평균의 (10월 -9월) 경향의 (동지역) - (서지역) 정도 anomaly 1973-2015 Trend (1.5도 이상)	
FEB	TEMP	$= 0.41 \times SIC_{Barent} - 0.54 \times ENSO - 0.52 \times SST_{Gulf} + L_{Trend}$	1974-2015/ 2016-2018	OCT SEP, OCT OCT FEB	SIC SST SST SAT_KOR_obs	Barent Sea north of Australia Bay of Gulf 329	78N 82N 15S 2S 35N 50N	25E 55E 130E 160E 75W 55W	55E 160E 55W											anomaly anomaly 공간평균의 (10월 -9월) 경향 anomaly 공간평균 1973-2015 Trend (2.0도 증가)	
JUN	TEMP	$= 0.45 \times SnowMar + 0.42 \times SST_{(Mar-Jan)} + 0.32 \times SST_{Jan}$	1979-2016	MAR APR JAN	SC PREC SST	northeast of China A1 tropical West Pacific	45N 50N 35S 20S 10S 15N	103E 123E 185E 200E 145E 180E	123E 200E 180E			40N 50N 35S 25S	123E 120E 180E							anomaly의 합 anomaly (A1 - A2) anomaly	
JUL	TEMP	$= 0.34 \times GPH500Mar + 0.42 \times SST_{Apr} - 0.39 \times SST_{Mar}$	1979-2016	MAR APR APR	Z500 SST Z500	A1 A1 A1	25N 45N 40S 25S 20N 40N	10E 40E 90E 120E 265E 300E	40E 120E 300E			20N 50N 0	60E 90E 5N 70N	0 45E 10S 5N	90E 110E					anomaly (A1+A2+A3) anomaly (A1+A2+A3) anomaly (A1-A2)	
AUG	TEMP	$= 0.30 \times SnowApr + 0.38 \times SST_{Feb} + 0.27 \times PrecMar$	1979-2016	MAR APR FEB	PREC SC SST	north of Australia A1 northwest of Australia	20S 5S 48N 60N 20S 0	110E 180E 105E 135E 110E 145E	180E 135E 145E			45N 55N	50E 70E							anomaly anomaly (A1-A2) anomaly	
JUL-AUG	Mean Temp	$= -1.35 \times IOSST + 2.43 \times NIECC + 2.44 \times BSCICE$	1994-2014	APR MAR, APR APR	SST SC SIC SST	Indian Ocean northeast of China Beijing Sea North Atlantic	10S 0 40N 50N 55N 65N	90E 105E 120E 140E 180W 165W 40W 0	105E 140E 165W 0											anomaly anomaly anomaly anomaly	
15JUN ~ 29JUL	PREC * 0.43std (장마강수)	$= 1/4 (0.41 \times NASSST + 0.46 \times NPCSSST - 0.40 \times CNINCSST) + (0.49 \times NASSST - 0.49 \times NCSST + 0.33 \times BSST) + (0.57 \times NASSST + 0.33 \times NPCSSST - 0.47 \times NNPDIR) + (0.54 \times NASSST - 0.39 \times NCSST + 0.51 \times NASSST + 0.16 \times NCSST + 0.45 \times NPCSSST)$	1994-2014	6-25 APR (11-30 APR) - (22 MAR ~ 10 APR) 1-20 APR 16-30 APR 12-31 MAR 11~30 MAY 1 MAR ~ 31 MAY	SST SST SST SST SST OLR SC	North Atlantic (A1) North Pacific Change Central pacific NINO North Indian Ocean Beijing Sea Western North Pacific Eurasia (A1)	55N 60N 20N 35N 15S 10N 11N 22N 55N 65N 0N 20N 50N 60N	40W 15W 160E 210E 160W 140W 67E 85E 175E 165W 110E 140E 20E 50E	15W 210E 140W 85E 165W 140E 50E	North Atlantic (A2)	30N 45N	80W 40W							anomaly (A1-A2) anomaly trend (7간동년 변화) anomaly anomaly anomaly anomaly anomaly (A1-A2) (A1-A2)(APR) - (A1-A2)(JAN)		
AUG	PREC	$= -0.51 \times NASSST + 0.16 \times NCSST + 0.45 \times NPCSSST$	1979-2014	APR - JAN APR - MAY MAY - JUN	SST SST SST	North Atlantic (A1) Indian Ocean North Pacific Ocean (A1)					North Atlantic (A2)										A1-A2

모델의 예측성능은 각 모델의 예측 결과와 예측 target의 3분위 카테고리를 비교하여 Hit Rate, Heidke skill score (HSS), 그리고 3분위 카테고리별 Accuracy, Probability of Detection (POD), False alarm rate (FAR)를 구하는 것으로 평가하였다. Table 11은 다중 카테고리에 대한 contingency table을 나타내며, 여기서 $n(F_i O_j)$ 는 i -카테고리를 예측한 횟수와 j -카테고리로 관측된 횟수, $N(F_i)$ 는 i -카테고리를 예측한 전체 횟수, 그리고 N 은 전체 예측 횟수를 나타낸다. 3분위 예측에서 각 카테고리는 Above normal, Near normal, Below normal을 나타낸다.

Table 11 Multi-category contingency table

		Observed Category			total
		1	2	3	
Forecast Category	1	$n(F_1 O_1)$	$n(F_1 O_2)$	$n(F_1 O_3)$	$N(F_1)$
	2	$n(F_2 O_1)$	$n(F_2 O_2)$	$n(F_2 O_3)$	$N(F_2)$
	3	$n(F_3 O_1)$	$n(F_3 O_2)$	$n(F_3 O_3)$	$N(F_3)$
total		$N(O_1)$	$N(O_2)$	$N(O_3)$	N

위 테이블을 바탕으로 HR과 HSS를 아래 식과 같이 구한다.

$$HR = \frac{1}{N} \sum_{i=1}^K n(F_i O_i) \quad [19]$$

$$HSS = \frac{\frac{1}{N} \sum_{i=1}^K n(F_i O_i) - \frac{1}{N^2} \sum_{i=1}^K n(F_i) n(O_i)}{1 - \frac{1}{N^2} \sum_{i=1}^K n(F_i) n(O_i)} \quad [20]$$

Accuracy, POD, FAR은 카테고리별로 따로 계산하기 때문에 Table 12와 같이 dichotomous contingency table을 구성하고 아래 식과 같이 구할 수 있다.

Table 12 Dichotomous contingency table

		Observed Category		
		yes	no	total
Forecast Category	yes	hits	false alarms	forecast yes
	no	misses	correct negatives	forecast no
	total	observed yes	observed no	total

$$Accuracy = \frac{hits + correct\ negatives}{total} \quad [21]$$

$$POD = \frac{hits}{hits + misses} \quad [22]$$

$$FAR = \frac{false\ alarms}{hits + false\ alarms} \quad [23]$$

(2) 벤치마킹 통한 우리나라 1개월 전망 활용성 평가

ENSO-MJO의 위상 및 최근 trend 정보의 합성을 통한 3~4주 예측정보 생산을 위하여 호주 BoM에서 제공하는 ENSO 지수로써 NiNo3.4와 MJO 지수로써 RMM index를 각각 사용하였다. ENSO 지수에 대해서는 0.5 이상에 대해서는 El Nino로, -0.5 이하에 대해서는 La Nina로 -0.5~0.5에 대해서는 Neutral로서 정의하였다. 또한, MJO 강도 1.0 이상의 강한 강도에 대하여 1부터 8까지의 phase에 대해 각각 합성하였다. 따라서 ENSO-MJO 각 위상별로 24개의 경우에 대해 온도 합성도를 구하고, 이에 대해 검증하였다. 이때 ENSO 및 MJO는 서로 독립적이며, 우리나라 기온에 대해 선형적인 관계를 가진 것으로 정의하였는데, 선행 연구에 따르면 비선형성의 가정하는 것보다 샘플의 크기에 대한 이점이 더 크다고 분석된 바 있다. ENSO 와 MJO 각 위상에 대한 합성장에 대해 우리나라 온도는 가우시안 분포를 가진다고 가정하였다.

라. 현업 장기예보 지원

(1) WMO 장기예보 선도센터 운영 및 개선

(가) WMO 장기예보 선도센터 계절 예측 시스템 운영

① WMO 장기예보 선도센터 계절 예측 시스템 운영의 배경

기후예측을 위한 역학모형은 최근까지도 꾸준히 발전되어 왔고, 다양한 기관에서 역학모형을 이용하여 기후예측을 하고 있다. 그러나 역학모형 자체에 포함된 계통적 오차 또는 초기조건의 불확실성 등은 여전히 역학모형 예측성 향상의 걸림돌로 남아있다. 이러한 문제를 해결하기 위한 방법 중 하나로 다양한 역학모형에 통계적 후처리를 적용하는 다중모델앙상블(Multi-Model Ensemble, 이하 MME) 기법이 널리 사용되고 있다.

현재 ECMWF, NCEP를 비롯한 다양한 현업 기관에서 MME 기법을 활용한 계절예측 서비스를 제공하고 있다 (Palmer et al., 2004; Min et al., 2009; Wang et al., 2009; Kirtman et al., 2014). 세계기상기구 (World Meteorological Organization, 이하 WMO)에서도 이에 대한 중요성을 인식하고 WMO 전지구 장기예측자료 생산센터 (WMO Global Producing Centre for Long-range Forecast, 이하 GPC)간의 협력을 통해 국가의 장기예보 결과를 공유하고 MME 기후예측시스템을 개발하여 계절예측 성능을 향상시키고자 제 14차 WMO 기본체계위원회 (Commission for Basic Systems, CBS)에서 WMO 장기예보 선도센터 (WMO Lead Centre for Long-Range Forecast Multi-Model Ensemble, LC-LRFMME)를 승인하였다. 이에 따라 GPC 중 하나인 한국 기상청 (GPC Seoul)과 미국 기상청 (GPC Washington)이 WMO 장기예보 선도센터를 공동 운영해오고 있다. WMO 장기예보 선도센터는 각 GPC에서 생산하는 장기예보 자료를 수집하고, MME 기법을 개발하여 서비스하고, 각 GPC의 예측자료와 MME 예측자료를 일관된 형태로 제공하는 ‘one-stop shop’ 이 되는 것을 궁극적인 목표로 하여 운영되고 있다 (Graham et al., 2011).

그러나 상당한 기상·기후 업무 및 관련 행정 업무를 수행하고 있는 기상청의 특성상 WMO 장기예보 선도센터를 지속하여 안정적으로 운영하고, 특히 WMO 회원국 또는 WMO 장기예보 전문가팀 (WMO Expert Team for Extended and Long-range Forecasting, ET-ELRF)의 요구에 대응하는 등의 업무를 함께 수행하기에는 다소 간의 어려움이 따를 수 있다. 따라서 기술력을 확보한 전문기관에서 기상청을 대신하여 운영할 경우 기술적인 부분에서 전문성을 강화하는 동시에 기상청은 기획 및 국제 협력 업무에 집중하며 WMO 장기예보 선도센터의 중·장기 발전방향을 설립하는 등의 시너지 효과를 창출할 수 있기에 APCC는 WMO 장기예보 선도센터를 운영하며 관련 연구 개발을 지원하는 역할을 현재 수행하고 있다.

APCC는 지난 10여 년 간 다양한 MME 기법을 활용하여 아시아·태평양 지역에 MME 계절예측 정보를 생산하여 제공해온 전문기관으로, 2011년부터 2016년까지 APCC가 “WMO 장기예보 선도센터 운영” 사업을 지속적으로 수탁 운영하면서 기상청과의 업무 분담 및 협조가 이루어졌으며, WMO 회원국의 요구에 부합하는 고품질 서비스를 안정적으로 제공할 수 있게 되었다. 더 나아가 WMO 장기예보 선도센터의 위상을 제고하는 것에 일조하였다. 따라서 본 장을 통해 2021년 APCC가 수행한 WMO 장기예보 선도센터 운영의 전반적인 내용과 MME 시스템의 개선 사항을 정리하고자 한다.

② WMO 장기예보 선도센터 계절 예측 시스템 운영 개요

앞서 설명한 바와 같이, ‘one-stop shop’ 으로서의 WMO 장기예보 선도센터 역할을 수행하기 위해 각 GPC들로부터 기후예측자료를 수집하고 MME 예측자료를 생산하여 WMO 선도센터의 회원국에 홈페이지를 통해 디지털 자료와 그림 형식으로 제공하고 있다 (Figure 14). 그러나 각 GPC에서 생산하는 계절예측자료는 파일 형식 (Binary, GRIB1, GRIB2, NetCDF), 앙상블 수, 변수 등에서 차이가 있다. 따라서 WMO 장기예보 선도센터의 자료 교환 정책 (data exchange policy)에 따라 GPC별로 6개 변수 (2m 기온, 강수, 해수면온도, 해면기압, 850hPa 온도, 500hPa 지위고도. 단, 해수면온도의 경우는 제공되는 GPC에 한함)만을 포함하는 GRIB1 형식의 월별 3개월 앙상블 평균 자료로 표준화 하고 있다.

WMO 장기예보 선도센터의 초창기에는 11개의 GPC로부터 계절예측자료를 수집하였다. 2010년 6월에 브라질의 CPTEC (Centre for Weather Forecasts and Climate Studies, GPC CPTEC)이 참여하면서 12개 GPC의 예측자료로 다년간 운영되어 오다가 2017년 독일 기상청 (Deutsche Wetterdienst, GPC Offenbach)이 GPC가 되고, 2021년 CMCC가 14번째 GPC로 참여하면서, 현재는 총 14개의 GPC로부터 계절예측자료를 제공받고 있다(Table 13).



Figure 14. Functions of WMO LC-LRFMME.

13개 GPC의 forecast와 hindcast 자료에 대한 표준화를 완료한 후, 4개의 결정론적 MME 기법 (Simple Composite Method, SCM; Simple Linear Regression, SLR; Singular Value Decomposition, SVD; Genetic Algorithm, GA)과 확률론적 MME 기법 (Min et al., 2009)으로 매 월 3개월 계절예측자료를 생산하게 된다. Hindcast 기간은 GPC 간의 공통 hindcast 기간인 1993-2009년을 기준으로 한다. 각 기법에 대한 자세한 설명은 아래와 같다.

- Simple Composite Method (SCM)

SCM은 모든 예측 모델에 동일한 기중치를 주어 단순 평균하는 방법으로, 쉽고 간단하게 사용할 수 있다. 선도센터에서는 GPC별로 forecast에서 공통 기간인 1993-2009년에 대한 기후 값을 제거한 forecast anomaly (F'_i)를 계산하여 더한 후 GPC 개수 (N)로 나누어준다(Eq. 24). 이 기법은 현재 계절예측을 위한 여러 현업 기관에서 널리 사용되고 있다 (예를 들어, APCC; Development of a European Multi-model Ensemble System for Seasonal to Interannual Prediction project (DEMETER); North American Multi-Model Ensemble (NMME); WMO LC-LRFMME, 등) (Kim et al., 2016; Kirtman et al., 2014; Min et al., 2014; Palmer et al., 2004).

$$MME = \frac{1}{N} \sum_{i=1}^N F'_i \quad [24]$$

- Simple Linear Regression (SLR)

단순선형회귀기법을 이용한 MME는 공통 hindcast 기간에 대해 구해진 GPC별 선형회귀계수 (a_i)를 각 forecast anomaly에 곱한 후 단순 평균해주는 방법이다 (Eq. 25).

$$MME = \frac{1}{N} \sum_{i=1}^N a_i F'_i \quad [25]$$

- Singular Value Decomposition (SVD)

이 기법은 각 GPC에 해당하는 가중치를 구하기 위해서 아래 Eq. 26과 같은 SVD 방식을 사용하여 GPC 간의 교차 공분산 행렬을 풀어내고자 하였다 (Krishnamurti et al., 2000; Yun et al., 2003).

$$C_{i,j} = (UVW^T)_{i,j} = \sum_{k=1}^N w_k U_{ik} V_{jk} \quad [26]$$

이렇게 구해진 GPC별 선형회귀계수(b_i)를 forecast anomaly에 곱한 값을 아래(Eq. 27)와 같이 더해줌으로서 예측 결과를 얻을 수 있다.

$$MME = \sum_{i=1}^N b_i F_i \quad [27]$$

- Genetic Algorithm (GA)

기후 시스템은 구성 요소들 간의 내적, 외적 상호작용에 의해 비선형성, 비예측성을 갖고 있기 때문에 기존의 선형적인 통계방법으로는 예측성을 향상시키는 데에 한계가 있다. 따라서 비선형성을 고려한 MME 방법 중 최근 널리 사용되고 있는 유전 알고리즘이 WMO 장기예보 선도센터를 위한 MME 기법 중 하나로 사용되고 있다. WMO 장기예보 선도센터에서 제공하는 MME 기법 중 비선형 기법으로는 유전 알고리즘이 유일하다.

유전 알고리즘은 부모의 유전자로부터 자손의 유전자를 형성하는 유성생식과 자연환경 속의 진화원리를 흉내 내는 알고리즘이다 (Holland, 1975). 유전 알고리즘은 초기화, 적합도 평가와 재생산(선택, 교배, 돌연변이), 또 다시 적합도 평가의 4단계로 구분되는 유전 탐색 프로세스를 통해 가장 높은 적합도를 가진 (즉, 관측과의 오차가 상대적으로 적은) 가중치들만이 다음 세대 생성을 위해 선택되어 복제되는 과정을 반복하여 최적의 가중치를 찾아내는 방법이다. 계절예측에 유전 알고리즘과 SCM을 이용한 MME 기법을 비교했을 때, 유전 알고리즘을 이용한 MME가 SCM 기법의 예측성보다 더 좋다고 알려져 있기도 하다 (Ahn and Lee, 2016).

- Probabilistic Multi-Model Ensemble (PMME)

2012년 ET-ELRF 회의를 통해 APCC에서 개발된 확률론적 MME 기법이 WMO 장기예보 선도센터에 도입되었다 (Final Report of 2012 CBS/ET-ELRF meeting, <http://www.wmo.int/pages/prog/www/CBS-Reports/documents/Final-Report-ET-ELRF-March2012.pdf>). PMME 기법은 계절예측자료가 표준정규분포를 따른다고 가정한 후 앙상블 멤버들의 hindcast의 평균적인 확률분포(정규분포)에서 평균(μ)과 분산(σ)을 이용하여 33.3% ($x_a = \mu + 0.43\sigma$), 66.7% ($x_b = \mu - 0.43\sigma$)에 해당하는 두 개의 기준값을 결정하고 예측값의 확률분포를 이용하여 기후 평균적인 확률분포로부터 결정된 기준값에 따른 각 카테고리의 확률을 계산하는 방법이다(Figure 15). 이렇게 계산된 각 GPC의 카테고리별 확률값은 각 GPC의 앙상블 멤버의 제공근에 따른 가중치를 곱해주어 다중모델 앙상블 확률값을 얻게 된다 (Min et al., 2009).

WMO 장기예보 선도센터 운영을 통해 생산된 각 GPC와 MME의 예측 성능을 파악하기 위해 앞서 언급했던 6개 변수의 hindcast 및 forecast 에 대한 검증을 매 달 수행하고 있다. 예측 성능의 검증은 결정론적 예측과 확률론적 예측에 대해 수행하고 있다. (결정론적 MME의 경우 SCM에 대한 검증만 수행함). 이 중 hindcast에 대한 검증은 공통기준기간인 1993-2009년에 대해 계산된다. 검증에 사용되는 재분석 관측 자료는 forecast와 hindcast에 따라 다르며, Table 14와 15에 자세히 나타내었다.

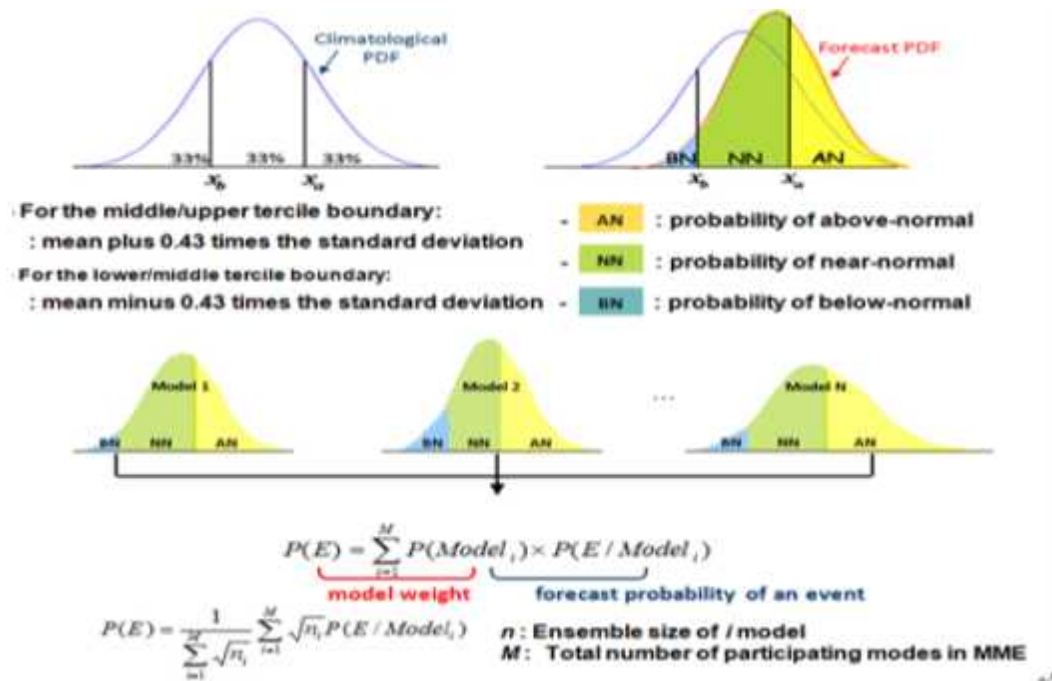


Figure 15. A parametric Gaussian fitting method for estimate of tercile-based categorical probabilities.

GRIB1으로 표준화된 GPC 자료들과 MME 예측자료는 WMO 장기예보 선도센터 홈페이지 (<https://www.wmolc.org/>)를 통해 제공된다. 관리자가 표준화된 GRIB1 자료를 홈페이지에 업로드 하면 GRIB1 자료가 자동으로 GRIB2 자료로 변환되고, 사용자는 GRIB1 또는 GRIB2 중에 선택하여 다운로드 할 수 있다. 참고로, 각 GPC의 자료정책에 따라 재배포가 금지된 경우도 있으므로 모든 GPC의 예측자료를 다운로드 받을 수 있는 것은 아니다. WMO 장기예보 선도센터 홈페이지에서 다운로드 받을 수 있는 GPC 자료는 Table 13에 제시하였다. 또한 예측자료는 그래픽으로도 제공되고 있으며, 사용자가 예측월, 변수, GPC, 지역 등을 선택할 수 있다. 특히, SCM의 경우에는 사용자가 예측기간 (1~6개월)을 선택할 수 있는 사용자 맞춤형 서비스를 제공하고 있다. 그러나 이러한 예측자료들은 WMO 회원국에만 제한적으로 제공되고 있다.

WMO 장기예보 홈페이지에는 예측자료 뿐만 아니라 결정론적 검증과 확률론적 검증 결과 도 제공한다. 당초 forecast 검증결과는 WMO 장기예보 선도센터에서 제공하고, hindcast 검증결과는 호주기상청에서 운영하는 WMO 장기예보 검증센터 (<http://www.bom.gov.au/wmo/lrfvs/>)에서 제공하였으나, 2016년부터 WMO 장기예보 선도센터에서는 forecast 뿐만 아니라 hindcast에 대한 검증결과를 함께 제공하기로 결정하였다. 따라서, 2016년 이후부터 WMO 장기예보 선도센터의 A등급과 B등급 회원에게 forecast와 hindcast 검증자료가 제공되고 있다. 한 달 동안 주기적으로 수행되는 WMO 장기예보 선도센터의 계절예측 현업에 대한 일련의 과정은 Figure 16에 간략하게 도식하여 나타내었다.

Table 13. Characteristics of seasonal forecast model from GPCs.

<2021년 09월 기준>

GPC	Beijing	Bologna	CPTEC	ECMWF	Exeter	Melbourne	Montreal	Moscow	Offenbach	Pretoria	Seoul	Tokyo	Toulouse	Washington
Institute	BCC	CMCC	CPTEC	ECMWF	UK Met Office	BoM	MSC	HMC	DWD	SAWS	KMA	JMA	Météo-France	NCEP/CPC
Country	China	Italy	Brazil	United Kingdom	United Kingdom	Australia	Canada	Russia	Germany	South Africa	Korea	Japan	France	United States
System	Coupled	Coupled	2-tier	Coupled	Coupled	Coupled	Coupled	2-tier	Coupled	Coupled	Coupled	Coupled	Coupled	Coupled
Digital data download	o	x	o	x	x	o	o	o	o	o	o	x	o	o
1)														
Data format	NetCDF	NetCDF	GRIB1	GRIB1	GRIB2	GRIB1	GRIB2	GRIB1	GRIB2	GRIB1	GRIB2	GRIB2	GRIB2	GRIB1
Forecast period	13month	6month	6month	7month	6month	6month	12month	4month	6month	9month	6month	7month	7month	9month
Ensemble size	24	50	15	51	42	11	20	20	50	40	42	51	51	40
	Hindcast													
Hindcast Period	1991-2010	1993-2016	1981-2010	1981-2016	1993-2015	1981-2018	1981-2010	1981-2010	1990-2017	1982-2009	1991-2016	1979-2014	1993-2016	1982-2010
Ensemble size	24	40	10	25	28	3	20	10	30	10	12	10	25	20
추가 변수	U850 V850	U200 V200	-	U850 V850	U850 V850	U850 V850	U850 V850	U850 V850	U850 V850	-	-	U850 V850	U850 V850	-
경로	U200 V200 FTP	U200 V200 FTP	FTP	Web	U200 V200 FTP	U200 V200 Web	U200 V200 Web	U200 V200 Web	U200 V200 FTP	FTP	FTP	U300 icfrc U200 V200 Web	U850 V850 Web	FTP
해상도	T106L26	0.5° x 0.5°, L46	T126L42	Tco319L91	N216L85	N216L85	1.4 x1.4, L79	1.40625lon, L28	T127	T42L19	N216L85	TL159L60	T359L91	T126L64

1) GPC별 자료 정책 상, GPC에서 예측자료를 직접 제공하는 것이 아닌 다른 기관 등에서 2차 제공이 가능한지에 대한 여부. x로 표시된 GPC는 WMO 장기에보 선도센터 홈페이지로부터 예측자료를 다운로드 받을 수 없음.



Figure 16. Forecast procedures at WMO LC-LRFMME.

WMO 장기예보 선도센터 자료의 검증은 WMO 장기예보 표준 검증 체계 (WMO Long-Range Forecast Standardised Verification System, WMO LRF-SVS)에 의거하여 수행되고 있다. 결정론적 예측 검증에는 아노말리 상관계수분석(Anomaly Correlation Coefficient, ACC), 평균제곱근오차(Root Mean Square Error, RMSE), MSSS와 Gerrity Skill Score (GSS)가 사용되고 확률 예측의 검증에는 Reliability Diagram, Roc Curve 및 Score, ROC map, Brier Score (BS), Brier Skill Score (BSS)가 이용되고, 자세한 내용은 부록 A에 나타내었다.

Table 14. Reanalysis data used for verification of real-time forecast.

	NCEP-DOE Reanalysis-1	CAMS OPI	OISST v2
Source	NCEP/CPC	NCEP/CPC	NCEP/CPC
Variable	50hPa GPH (gpm), Sea level pressure (hPa), 2m temperature (K), 850hPa temperature (K)	Precipitation (mm/day)	Sea surface temperature (K)

Table 15. Reanalysis data used for verification of hindcast.

	ERA-interim	GPCP	OISST v2
Source	ECMWF	NASA	NCEP/CPC
Variable	50hPa GPH (gpm), Sea level pressure (hPa), 2m temperature (K), 850hPa temperature (K)	Precipitation (mm/day)	Sea surface temperature (K)

(나) WMO 장기예보 선도센터 계절내 예측 시스템 운영

① WMO 장기예보 선도센터 계절내 예측 시스템 개발의 개요 및 참여모델 특성

극한 기후 현상 등을 보다 정확하고 상세하게 예측하기 위하여 계절 예측정보를 계절내 시간 규모로 확장하는 요구가 국제 사회에서 지속적으로 제기되고 있다. 2011년에 열린 Sixteenth World Meteorological Congress (Cg-XVI)에서는 계절내 시간 규모까지 예측자료를 제공하는 것을 포함하여 WMO 장기예보 선도센터의 역할이 확장될 수 있도록 GPC들의 지원을 요청하였다. 이후 2012년에 개최된 ET-ELRF의 전문가 회의 및 Expert Team on Operational Predictions from Sub-seasonal to Longer-Time Scales (ET-OPSLS) 아래 Task Team 3 (TT3)의 협의 등을 통해 보다 구체적인 계절내 MME 예측을 위한 계획이 수립되었다.

이러한 국제적 협의로 WMO 장기예보 선도센터의 홈페이지에서는 계절예측 자료의 MME 결과 표출뿐만 아니라 계절내 MME 예측결과를 추가로 제공하기 위한 사업을 진행하게 되었다. 2014년에는 계절내 MME 시스템에서 제공할 콘텐츠를 발굴하는 등 사전 조사를 수행하였으며, 2015년에는 3개의 GPC (ECMWF, Tokyo (JMA), Washington (NCEP))의 예측자료를 바탕으로 파일럿 시스템을 구축하였고, 홈페이지에서는 MME 예측 정보만 표출한 바 있다. 2016년도 사업에서는 MME 뿐만 아니라 각 GPC 별 예측 결과를 추가적으로 표출하여 예측자료의 분석 시 다양한 정보를 획득할 수 있도록 하였다. 또한, 2016년 4월 베이징에서 개최된 WMO 현업장기예보 전문가팀 회의 (the meeting of WMO Joint Commission for Basic Systems (CBS)-Commission for Climatology (CCI) ET-OPSLS)의 TT3 회의 결과에 따라 5개의 GPC (Beijing (CMA), Exeter (UKMO), Melbourne (BoM), Montreal (ECCC), Seoul (KMA))의 참여가 확정되었으며, 예측변수의 추가 등이 결정되었다. 2017년에는 hindcast 기간 연장과 모델 특성변경에 따른 수정, 활용가이드 및 홈페이지 안내페이지 개선, 기후값 계산방법 변경 등을 작업을 수행하였다. 2018년에는 자료수신 속도 향상을 위한 프로그램 개선과 GPC Seoul 예측자료가 안정적으로 제공되면서 MME 예측에 GPC Seoul 예측결과를 포함하였다. 2019년에는 신규 현업 서버로 시스템을 이전하였다. 2020년부터는 hindcast 공통기간이 계속 변경되는 사항에 대응하는 수정이 이루어졌으며, 2021년에도 참여모델의 개선사항을 적용하는 등 현재 개발된 내용을 안정적으로 운영하는 중점을 두었다.

계절내 MME 기후 예측자료의 생산에 필요한 각 GPC의 일별 예측자료는 현재 ECMWF Sub-seasonal to Seasonal (S2S) data portal (Vitart et al., 2017)로부터 수신하고 있다. 2019년 10월까지 Beijing과 ECMWF, Exeter, Melbourne, Montreal, Seoul, Tokyo, Washington 예측모델을 계절내 MME에 사용하였으며, 현재 Beijing과 Melbourne, Tokyo 등 3개 예측모델은 MME에 사용하지 못하고 있다. Beijing 모델은 2019년 11월부터 hindcast 기간이 2004년에서 2018년으로 변경되었으며, 그로 인해 MME 공통기간이 짧아져서 MME 참여에서 제외하였다. Melbourne 모델은 2020년 9월 25일부터 계절내 예측자료 지원 중단하였다. Tokyo 모델은 2020년 3월에 모델을 개선하였으나, hindcast 자료의 활용방법이 크게 변경되어 WMO 계절내 MME에 포함시키지 않기로 하였다.

현재 사용하고 있는 모델의 특성(2021년 10월 기준)과 사용이 중단되기 전까지 사용된 모델(Beijing과 Melbourne, Tokyo)의 특성을 아래 Table 16에 간략히 나타내었다. Table 16은 각 GPC 별로 forecast 자료를 생산하는 주기와 예측기간, forecast 앙상블 멤버의 수, hindcast 자료의 생산주기, hindcast 앙상블 멤버의 수, hindcast 수행기간을 나타낸 것이다. 계절내 MME 예측에 사용되는 모델의 자세한 설명은 ECMWF S2S data portal 웹사이트의 모델 설명 부분에서 (<https://software.ecmwf.int/wiki/display/S2S/Models>) 확인할 수 있다.

Table 16. Characteristics of GPC data for WMOLC-LRFMME subseasonal prediction.

GPC name (Center)	Forecast Frequency	Forecast Time range	Forecast Ens. Size	Hindcast Frequency	Hindcast Ens. Size	Hindcast length
Beijing (CMA)	daily	0-60 days	4	daily	4	1994-2014
ECMWF (ECMWF)	2/week (Mon,Thu)	0-46 days	51	2/week (Mon, Thu)	11	past 20 years
Exeter (UKMO)	daily	0-60 days	4	4/month (1,9,17,25)	7	1993-2016
Melbourne (BoM)	2/week (Sun,Thu)	0-62 days	33	6/month (1,6,11,16,21,26)	33	1981-2013
Montreal (ECCC)	weekly (Thu)	0-32 days	21	weekly (Thu)	4	1998-2017
Seoul (KMA)	daily	0-60 days	4	4/month (1,9,17,25)	3	1991-2016
Tokyo (JMA)	weekly (Wed)	0-33 days	50	3/month (10,20,last day)	5	1981-2010
Washington (NCEP)	daily	0-44 days	16	daily	4	1999-2010

② WMO 장기예보 선도센터 계절내 MME 예측 방법

계절내 MME 예측을 수행하기 위해서 각 GPC의 예측자료의 표준화 과정이 필요하다. Table 16에 나타난 바와 같이 각 GPC 별 예측자료는 다양한 예측시간과 해상도, 앙상블 크기, 예측주기 등을 가지고 있기 때문이다. 특히 매주 계절내 MME를 구성 하는 각 모델의 예측 시작 시간이 상이하므로 계절내 MME 예측시작 시점을 정하는 것이 중요한 이슈가 된다. WMO 장기예보 선도센터의 계절내 예측 시스템을 처음 구축할 당시에는 MME 참여모델의 선행시간 손실을 최소화하기 위해 MME 예측시작 일을 목요일로 정한 바 있다. 하지만 MME 예측의 시작이 월요일로 정하는 것이 실제 계절내 예측자료의 활용 면에서 더 필요하다고 판단되어 2016년에 예측 시작시간을 변경하였다. 따라서 WMO 장기예보 선도센터에서는 계절내 MME 예측을 월요일에 시작하도록 정하였으며 매주 1회 예측을 수행한다. 이러한 계절내 MME 예측을 위해 사용되는 각 GPC 모델의 예측시작 시간은 예측자료 수집에 걸리는 시간을 고려하여 직전 수요일에서 금요일 사이의 GPC 예측결과가 사용된다.

다만 Exeter와 Seoul 예측자료는 1회 예측 시 앙상블 멤버의 수가 4개로 매우 적으며, 개별모델의 확률예측 등을 원활히 계산하기 위해 7일간의 예측결과를 모두 사용하였다. 즉 계절내 MME에 사용되는 Exeter와 Seoul 예측자료는 MME 예측이 시작되기 2주전의 토요일부터 1주전 금요일에 예측된 자료를 평균하여 사용한다.

계절내 MME 예측을 수행하면서 또 하나의 중요한 이슈는 hindcast 자료의 선택과 모델의 기후값 계산 방법이다. Table 16에서 보이는 바와 같이 각 GPC 별로 다양한 주기와 기간의 hindcast 자료를 제공하고 있다. forecast 자료로부터 anomaly 계산을 위해서는 사전에 각 GPC 별로 기후값을 구해야 한다. 매주 예측을 수행하는 계절내 예측의 경우 hindcast 자료 또한 forecast 예측 시작날짜와 동일한 날짜의 자료가 매주 생산되는 것이 이상적이다. 하지만 일부 GPC (Exeter, Seoul)의 경우 매달 고정된 특정날짜를 기준으로 생산된 hindcast 자료를 제공한다. 이러한 GPC간의 차이점에도 불구하고 MME 예측을 위해서는 최대한 유사한 방법으로 각 GPC의 기후값을 계산해야 하며, 계절내 MME 예측에서는 forecast 시작 날짜(월, 일)와 가장 가까운 날짜의 hindcast 자료를 선택하도록 정하였다. 따라서 ECMWF, Montreal, Washington의 자료는 forecast 시작날짜와 동일한 날짜의 hindcast 자료가 선택되며, 그 외 Exeter와 Seoul의 경우 forecast 시작날짜와 가장 가까운 날짜의 hindcast 자료가 선택된다. Exeter와 Seoul 예측자료와 같이 7일간의 예측결과를 합쳐서 사용하는 경우 hindcast 자료의 선택 기준은 가장 마지막 날짜(1주전 금요일)의 forecast 예측 시작날짜로 정하였다. 또한, 기후값 계산 기간은 전체 GPC에서 공통적으로 제공되는 2000년부터 2010년까지 11년(2020년 이전의 예측자료는 1999년부터 2010년까지 12년)의 자료를 사용한다. Table 17은 계절내 MME 예측을 수행하면서 forecast와 hindcast 자료의 선택과 관련한 앞서 설명한 내용을 정리한 것이다.

Table 17. Operational setup for subseasonal MME prediction system.

GPC name (Center)	Forecast Init. Date	Forecast Time range	Forecast Ens. Size	Hindcast Init. Date	Hindcast Ens. Size	Common Hind. period
Beijing (CMA)	2 weeks ago Sat - last Fri	4(10)-45(51) days	28 (4*7)	Same date as fcst	4	2000-2010
ECMWF (ECMWF)	last Thu	5-46 days	51	Same date as fcst	11	2000-2010
Exeter (UKMO)	2 weeks ago Sat - last Fri	4(10)-45(51) days	28 (4*7)	Closest date to fcst	7	2000-2010
Melbourne (BoM)	last Thu	5-46 days	33	Closest date to fcst	33	2000-2010
Montreal (ECCC)	last Thu	5-32 days	21	Same date as fcst	4	2000-2010
Seoul (KMA)	2 weeks ago Sat - last Fri	4(10)-45(51) days	28 (4*7)	Closest date to fcst	3	2000-2010
Tokyo (JMA)	last Wed	5-32 days	50	Closest date to fcst	5	2000-2010
Washington (NCEP)	last Thu	5-39 days	16	Same date as fcst	4	2000-2010

Table 16에서 보인 바와 같이 각 GPC 모델별로 MME 예측에 사용가능한 예측결과의 길이는 4주에서 6주까지 다양하다. WMO 장기예보 선도센터 계절내 예측은 최대 6주간의 예측을 수행하고 있으며, MME 예측은 참여모델의 일관성을 유지하는 방향보다는 최대한 많은 모델의 예측결과를 사용하는 방향으로 구축을 하였다. 그 결과 2019년 11월 이전에는 4주 예측에서는 8개 GPC의 예측결과를 모두 사용하지만 6주 예측에서는 Table 18에서와 같이 5개만을 사용한다. 2020년 10월 이후로는 Table 19와 같이 3개의 모델이 추가로 줄어들어 4주 예측에 5개 모델만 참여하게 되었다.

Table 18. Participating GPCs in subseasonal MME prediction each forecast before November 2019.

Forecast Time range	Participating GPCs in subseasonal MME prediction
1~4 weeks	Beijing, ECMWF, Exeter, Melbourne, Montreal, Seoul, Tokyo, Washington
5 weeks	Beijing, ECMWF, Exeter, Melbourne, Seoul, Washington
6 weeks	Beijing, ECMWF, Exeter, Melbourne, Seoul

Table 19. Participating GPCs in subseasonal MME prediction each forecast since October 2020.

Forecast Time range	Participating GPCs in subseasonal MME prediction
1~4 weeks	ECMWF, Exeter, Montreal, Seoul, Washington
5 weeks	ECMWF, Exeter, Seoul, Washington
6 weeks	ECMWF, Exeter, Seoul

WMO 장기예보 선도센터에서는 계절내 MME 예측방법으로 SCM 방법과 PMME 방법을 사용한다. SCM 방법은 Eq. [28], Eq. [29]와 같이 각 GPC의 예측결과에 대한 간단한 산술평균 방식이지만 각 모델이 가지고 있는 계통적 오차를 효과적으로 줄여 예측성을 높이는 방법이다 (Krishnamurti et al., 2000).

$$A_i = \frac{1}{M_i} \sum_{m=1}^{M_i} (F_m - \bar{F}_i) \quad [28]$$

$$SCM = \frac{1}{N} \sum_{i=1}^N (A_i) \quad [29]$$

여기서 i 는 각 GPC를 나타내고, m 은 각 GPC 내 앙상블 멤버이며, A_i 는 각 GPC의 anomaly 앙상블 평균을 뜻한다. M_i 는 각 GPC의 앙상블 멤버 수를 나타내고, F_m 은 앙상블 멤버 각각의 개별 예측결과이며, \bar{F}_i 는 앞서 설명한 각 GPC의 기후값이다. 이렇게 구해진 SCM 결과값은 WMO 장기예보 선도센터 홈페이지를 통해 이미지화 하여 표출되거나 GRIB edition 1 파일 형식으로 제공된다.

PMME는 각 격자점 별로 Above-Normal (AN), Near-Normal (NN), Below-Normal (BN)에 해당하는 이벤트가 발생할 확률을 구한 것이며, 2 meter temperature (T2M)과 total precipitation (PREC)에 대해서만 예측을 수행한다. AN, NN, BN을 구분하는 임계값은 hindcast 결과를 바탕으로 확률밀도함수를 구하고, 함수의 면적을 삼등분 하는 지점을 값으로 한다. 확률밀도함수 fitting 시 T2M은 normal distribution를 따르고, PREC는 gamma distribution를 따르는 것으로 가정하였다. 이렇게 구해진 삼분위 지점 값을 기준으로 각 GPC의 forecast 결과가 각 category에 얼마나 포함되는지 확률을 계산하여 개별모델의 확률 예측 값이 생산된다. PMME는 Eq 30과 같이 개별모델의 확률의 평균으로 구해지며, 이때 각 모델 간 동일한 가중치를 가진다.

$$P(E_j) = \frac{1}{M} \sum_{i=1}^M (P(E_j/mdl_i)) \quad [30]$$

여기서 P 는 예측 확률이며, E_j 는 AN, NN, BN 각각의 확률을 의미한다. M 은 PMME에 참여한 GPC의 수이며, mdl_i 은 i 번째 GPC를 의미한다. 또한, $P(E_j/mdl_i)$ 는 개별 GPC의 각각의 경우에 대한 확률을 의미한다.

③ WMO 장기예보 선도센터 계절내 예측 자료수신 및 웹표출

2021년 현재 WMO 장기예보 선도센터의 계절내 예측 시스템은 시범운영 중이다. 계절내 예측시스템의 원활한 운영을 위해, APCC는 자료 수신 상태를 실시간으로 모니터링하고, 오류에 대한 대응을 지속적으로 수행하는 등 현업에 준하는 운영을 하고 있다. 먼저 시스템 운영에 기본이 되는 각 GPC의 forecast 및 hindcast 자료는 자료제공 주기에 맞춰 주기적 또는 비주기적으로 수신한다. 또한 예측성 검증에 필요한 관측 자료는 계절내 예측결과 생산에 맞춰 주기적으로 수집한다. 계절내 MME 예측 시스템에서 수신 중인 자료에 대한 보다 자세한 사항은 Table 20에 자료의 목록과 주기, 목적별로 정리하였다. 이러한 절차를 통해 수집된 계절내 예측 자료는 WMO 장기예보 선도센터 운영뿐만 아니라 APCC, 기상청, 그리고 기상과학원의 매주 1개월 전망을 위한 예측 및 사후 분석 자료로 이용되며, 계절내 MME 예측 연구에도 사용되고 있다.

Figure 17은 현재 WMO 장기예보 선도센터 홈페이지에 제공(WMO 전문가 그룹 일부만 확인가능)되고 있는 산출물을 정리한 그림이다. 추가적으로 PMME 예측정보와 DMME 예측정보 외에 개별 GPC의 예측정보 또한 MME 예측과 동일한 형식으로 제공하고 있다. 다만, 검증 정보는 hindcast MME에 대한 결과만을 제한적으로 제공하고 있다.

Table 20. Used data list for subseasonal MME prediction system.

Data Name	Variable	Download frequency	Purpose
G P C s Forecast	· Sea Surface Temperature	· weekly : ECMWF, Melbourne, Montreal, Tokyo, Washington · daily : Beijing, Exeter, Seoul	· Subseasonal MME prediction
	· 2 metre Temperature		
	· Mean Sea Level Pressure		
	· Total Precipitation		
	· Outgoing Longwave Radiation		
	· Geopotential Height at 500hPa		
	· U/V wind component at 850 hPa · U/V wind component at 200 hPa		
G P C s Hindcast	· Sea Surface Temperature	· First one time : Beijing, Tokyo, Melbourne, Washington · weekly : ECMWF, Montreal, · non periodical : Exeter, Seoul	· Anomaly and PDF calculation
	· 2 metre Temperature		
	· Mean Sea Level Pressure		
	· Total Precipitation		
	· Outgoing Longwave Radiation		
	· Geopotential Height at 500hPa		
	· U/V wind component at 850 hPa · U/V wind component at 200 hPa		
ERA-Interim daily	· 2 metre Temperature · Total Precipitation	· monthly	· Verification
N C E P Reanalysis 1	· 2 metre Temperature	· weekly	· Verification · ISO monitoring and prediction
	· Mean Sea Level Pressure		
	· Geopotential Height at 500hPa		
	· U/V wind component at 850 hPa		
	· U/V wind component at 200 hPa		
N O A A Interpolated OLR	· Outgoing Longwave Radiation	· First one time	· Verification · MVEOF mode calculation
N O A A Uninterpolat ed OLR	· Outgoing Longwave Radiation	· weekly	· ISO monitoring and prediction

	Products/Variable	Covering Periods	Charts	Verification scores
Probabilistic MME	<ul style="list-style-type: none"> Precipitation 2m Temperature 	<ul style="list-style-type: none"> Weeks 1, 2, 3, 4, 5, 6, 3-4, 5-6, 3-6 	<ul style="list-style-type: none"> Probabilistic maps 	<ul style="list-style-type: none"> ROC Curve ROC Score map Reliability Diagram
Deterministic MME	<ul style="list-style-type: none"> Precipitation 2m Temperature Mean Sea Level Pressure Geopotential Height at 500hPa 850hPa Wind 200hPa Wind 200hPa Velocity Potential 200hPa Stream Function 	<ul style="list-style-type: none"> Weeks 1, 2, 3, 4, 5, 6, 3-4, 5-6, 3-6 	<ul style="list-style-type: none"> Each variable anomaly map 	<ul style="list-style-type: none"> Pattern Correlation Coefficient Root Mean Square Error Time Correlation Coefficient
Intraseasonal Oscillations	<ul style="list-style-type: none"> MJO Need: OLR, U850, U200 BSISO Need: OLR, U850 Outgoing Longwave Radiation 	<ul style="list-style-type: none"> 42 days 	<ul style="list-style-type: none"> Hendon and Wheeler Diagram Hovmöller diagram 	<ul style="list-style-type: none"> Root Mean Square Error Correlation Coefficient

Figure 17. The variables and covering periods of graphical products for subseasonal prediction.

(2) 현업 장기예보 지원

(가) 1개월 예보

① 1개월 전망 예측시스템 운영

기상청 기후예측과는 매주 목요일에 3주에서 6주까지 주별 평균한 한반도 기온과 강수량에 대한 전망을 발표한다. 이를 위해 매주 수요일 10시에 1개월 전망 예보토의를 진행하며, APCC 기후분석과에서도 참석하여 1개월 전망에 대한 의견을 개진하고 있다. 예보토의 시 APCC는 WMO 장기예보 선도센터의 계절내 예측 모델 자료를 활용하며, WMO 장기예보 선도센터의 계절내 예측 시스템과는 별도로 우리나라 기온과 강수 예측에 맞춘 추가적인 예측 시스템을 운영하고 있다. 이러한 APCC의 1개월 전망 예측 시스템은 2017년 8월부터 운영해오고 있다.

기상청 1개월 전망 예측 지원을 위한 APCC에서는 아래 Figure 18과 같은 현업 일정에 따라 매주 1개월 예측정보를 생산하고 있다. 먼저 매주 일요일 WMO 장기예보 선도센터에서 계절내 예측자료를 수신하며, 일부 모델의 자료는 매일 또는 수시로 자료를 수신한다. 이 자료를 활용하여 WMO 장기예보 선도센터 계절내 MME 예측 시스템과는 달리 한반도 기온과 강수량 예측에 최적화된 MME 예측 및 콘텐츠를 생산한다. 또한, 기상청 1개월 전망을 위해서 보다 최근의 초기장을 사용한 ECMWF 및 GloSea5 예측 결과 및 ASOS 관측자료를 추가로 수집하고, 이 자료를 사용하여 추가적으로 다양한 1개월 전망 콘텐츠를 생산한다. 이러한 자료로부터 Figure 19와 같은 발표자료를 작성하며, 기후 예측인자의 현황과 기상모델의 예측경향 등을 종합적으로 분석하여 APCC의 1개월 전망 최종 예측 결과를 생산하고, 매주 수요일 기상청과의 화상회의 시 발표한다.

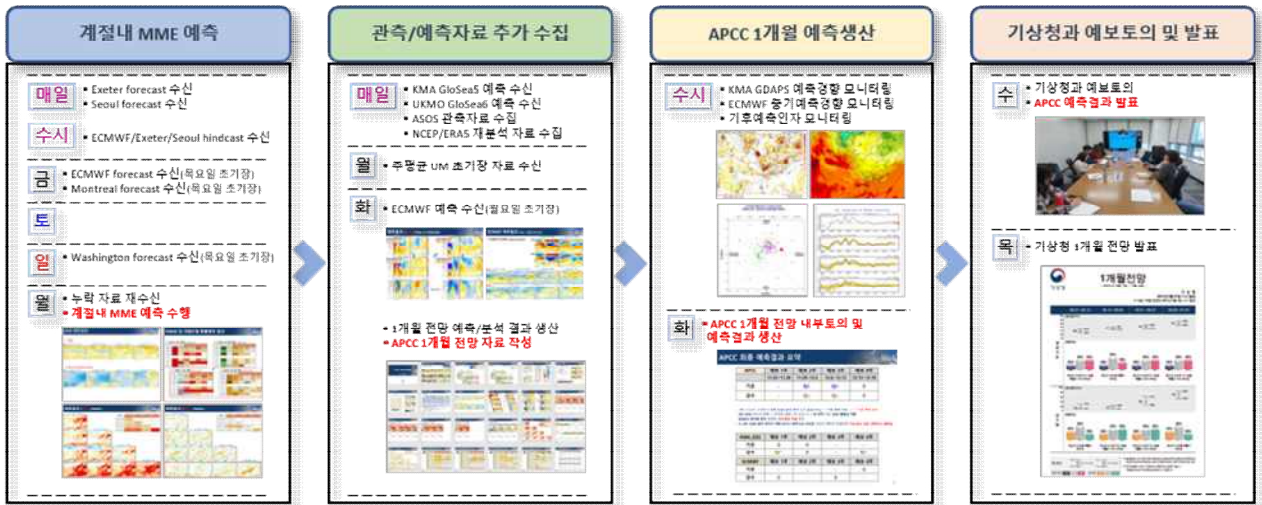


Figure 18. Operation schedule for APCC 1 month forecast.



Figure 19. Sample of APCC 1 month forecast chart.

추가적으로 1개월 전망 예측자료 중 가장 예측성이 높으며, 가장 빠르게 최신의 예측결과를 수신할 수 있는 ECMWF 계절내 예측 결과를 바탕으로 3개월 전망 또한 지원하고 있다. 현재 3개월 전망에서 사용되는 역학 모델들은 예측 초기장이 실제 예측 시작일보다 최소 20일에서 1개월 이전의 초기장 자료를 바탕으로 예측이 수행된 결과들이다. 따라서 1개월 전망에 사용하고 있는 ECMWF 계절내 예측 모델을 활용하면 보다 최근의 초기장을 반영한 모델의 예측

경향을 파악할 수 있다.

다만, ECMWF 계절내 예측결과는 총 46일 이후까지 예측결과를 제공하고 있으며, APCC 내부 3개월 예보토의가 매월 15일에서 20일 사이에 진행하므로 예보토의 전 가장 최신의 ECMWF forecast/hindcast 자료를 수신하여 활용한다면 3개월 예측 중 첫 1개월 평균 예측에만 활용 가능하다. 이렇게 ECMWF 계절내 예측결과를 사용하여 다음달 1일부터 예측 마지막 주 까지 평균한 결과를 생산하며, Figure 20의 예시에 보인 바와 같이 동아시아 영역에 대하여 500hPa 지위고도와 해면기압, 850hPa 바람장, 기온 확률 예측, 강수량 확률 예측 결과를 제공하는 콘텐츠를 제공하고 있다. 추가적으로 한반도 영역에 해당하는 5개 격자점을 평균한 기온과 강수량의 확률예측 결과 값도 동시에 제공한다. 이러한 자료는 3개월 전망 시 활용하는 예측모델의 2.5도 수평 해상도 대비 보다 고해상도의 자료를 제공하여 세부적인 기압계 패턴과 한반도 주변의 예측값을 확인할 수 있으며, 3개월 전망 예측모델 대비 최근의 기압계 변화 등을 반영한 최신 예측결과이므로 모델 예측결과의 변화 경향을 파악하는데 중요한 참고자료로 활용하고 있다.

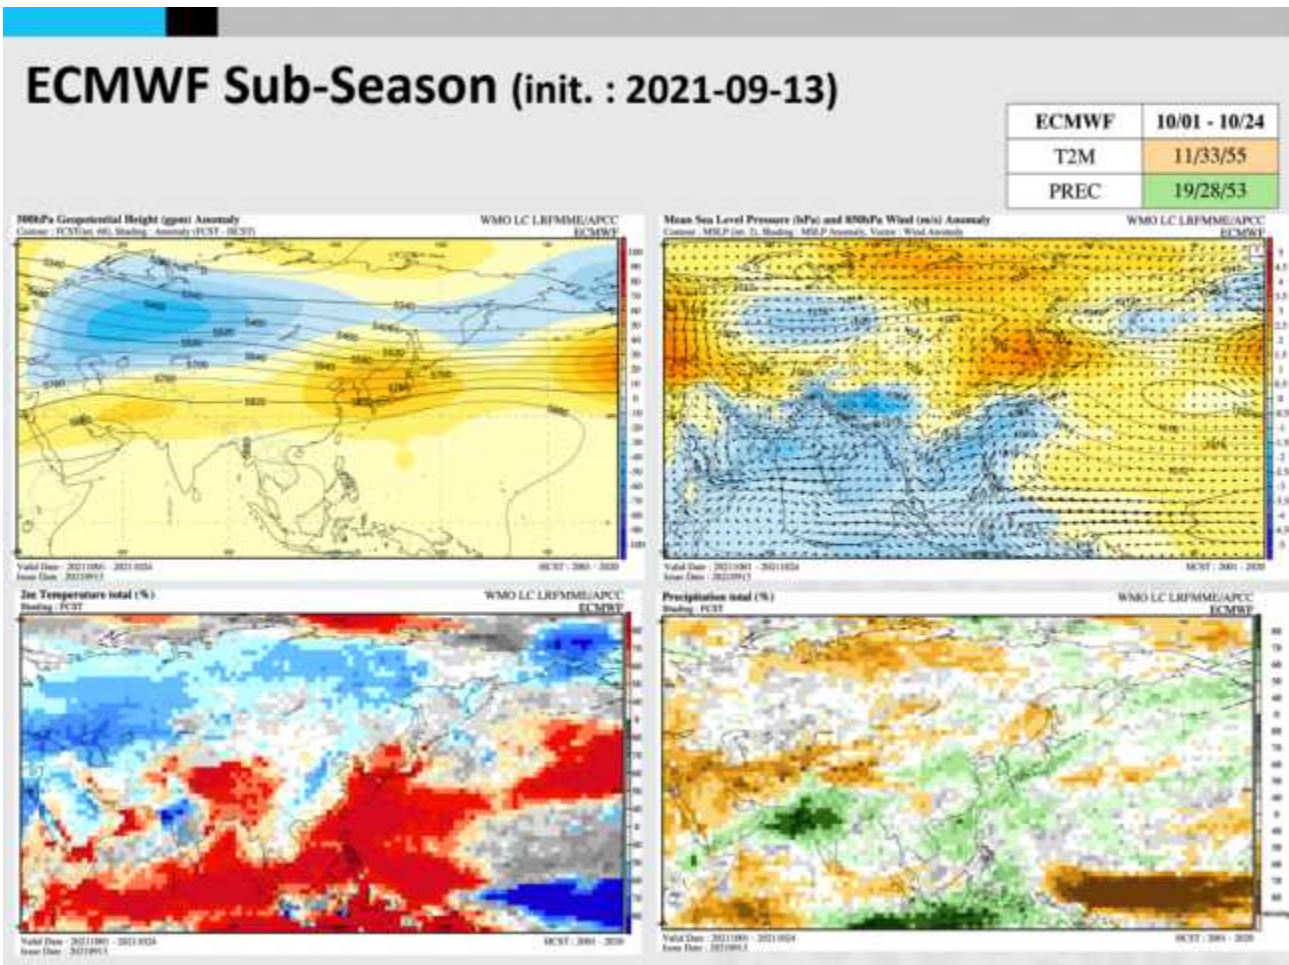


Figure 20. Sample of subseasonal model output for APCC 3-month forecast.

② 1개월 전망 예측시스템 개선

계절내 예측자료는 주기적/비주기적으로 모델의 특성이 변경되며, 계절예측과 달리 모델 간의 차이점이 매우 크다. 또한 명확한 운영의 근거가 없어서 시스템의 변경과 개선의 필요성이 항상 요구된다. 2021년에도 1개월 전망 예측 시스템을 운영하면서 모델의 특성 변화와 보다 효과적인 시스템 운영을 위해 예측 시스템 일부를 개선하였다.

먼저 모델의 기후값 계산에 사용하는 hindcast 기간을 변경하였다. 기존의 계절/계절내 예측에서는 최종적으로 MME 결과를 생산하기 때문에, 개별모델의 hindcast 기간을 동일하게 사용하여, 각각의 모델이 사용하는 기후값 기간을 일치시킨다. 2019년까지는 1999년부터 2010년까지 총 12년의 hindcast 기간을 공통기간으로 선택하여 사용하였으며, 2020년부터는 ECMWF 모델에서 제공하는 hindcast 기간이 2000년부터 2019년까지로 변경되었기에 공통기간을 1년 줄인 2000년부터 2010년으로 변경하였다. 2021년에는 또 1년이 줄어든 2001년부터 2010년까지의 공통기간을 사용해야 하지만 2021년부터는 개별모델이 가지고 있는 전체 hindcast 기간을 사용하여 각 모델의 기후값 계산에 사용하였다. 이러한 변경의 근거는 2020년 연구과제에서 분석한 MME 예측 시 공통기간 사용과 개별모델의 전체 기간 사용에 따른 예측성의 뚜렷한 감소가 나타나지 않았기 때문이다. 따라서 개별모델의 특성을 잘 반영하는 개별 모델에서 제공하는 hindcast 기간을 모두 사용하는 방향으로 변경을 하였다.

평년의 기준이 2021년부터는 1991년부터 2020년까지 30년으로 변경되었다. 그에 따라 APCC 1개월 전망 예측 시스템에서도 검증용을 위한 ERA5 자료의 기후값 계산 시 1991년부터 2020년으로 변경하였다. 또한, 기상청 1개월 전망의 기준이 되는 ASOS 자료의 기후값도 2021년 5월부터 기후값 기간이 동일하게 변경하였으며, 이때 한반도 평균의 기준이 되는 관측소 지점도 45개에서 62개로 변경되었다. APCC 1개월 전망 예측 시스템에서도 이러한 변경에 대응하여 추가 자료수집 및 시스템을 수정하였다.

3. 결과

가. 장기에보 객관화 기술개발 및 적용

(1) 기계학습 모델을 활용한 3개월 장기에보 개선

(가) 가우시안 프로세스 모델을 활용한 여름철 기온 확률예측

① 교차검증을 통한 모델 구성

우리나라 여름철 6, 7, 8월의 평균, 최저, 최고기온 확률예측에 대해 Leave-One-Out Cross Validation (LOOCV)을 통해 성능을 평가하고 모델의 조건을 선정하였다. GP-PD 모델의 경우 ISO를 선정하였고, GP-OBS의 경우 ISO, LNR, P5를 선정하였다. GP-MME의 경우 GP-OBS에 대해 선정된 조건을 그대로 이용하였다.



Figure 21. Performance of GP-PD from 34 LOOCV train-validation sets for (a) PC, (b) HSS, (c) AUC, and (d) RPSS. Adopted from Rhee and Myoung (2021).




Figure 22. Performance of GP-OBS from 34 LOOCV train-validation sets with ISO and P5 conditions for (a) PC, (b) HSS, (c) AUC, and (d) RPSS. Adopted from Rhee and Myoung (2021).

② 모델 검증

GP-PD, GP-OBS, GP-MME 모델을 2014-2020년 기간에 대해 검증하였다. GP-PD의 경우 인자도출이 1979-2016년 기간에 대해 수행되었으므로(기상청 2018) 검증기간의 성능이 실제 모델의 성능보다 우수하게 나타날 수 있다. GP-PD와 GP-OBS를 비교하면 GP-OBS가 6월과 7월에 대해 GP-PD보다 우수하게 나타났다. GP-PD의 경우 6월 TXm 예측에 대해 Proportion Correct (PC), Heidke Skill Score (HSS)에 대해 높은 성능을 보였으나 Are Under the Curve (AUC), Ranked Probability Skill Score (RPSS)에 대해서는 GP-OBS가 우수하였다. 8월에 대해서는 GP-PD가 TNm의 AUC를 제외하고는 우수하게 나타났는데, 앞서 언급한 인자의 도출기간때문일 수 있다.

GP-OBS와 GP-MME를 비교하면 특히 8월의 경우 GP-MME의 성능이 우수함을 볼 수 있었는데, 이는 선행시간이 길어 관측 기반의 입력 자료를 많이 이용하지 못하는 경우 APCC MME 등의 예측 자료의 기여가 크기 때문으로 보인다. 8월의 TMm, TNm 예측에 대해서는 GP-PD보다도 우수한 성능을 보였다.

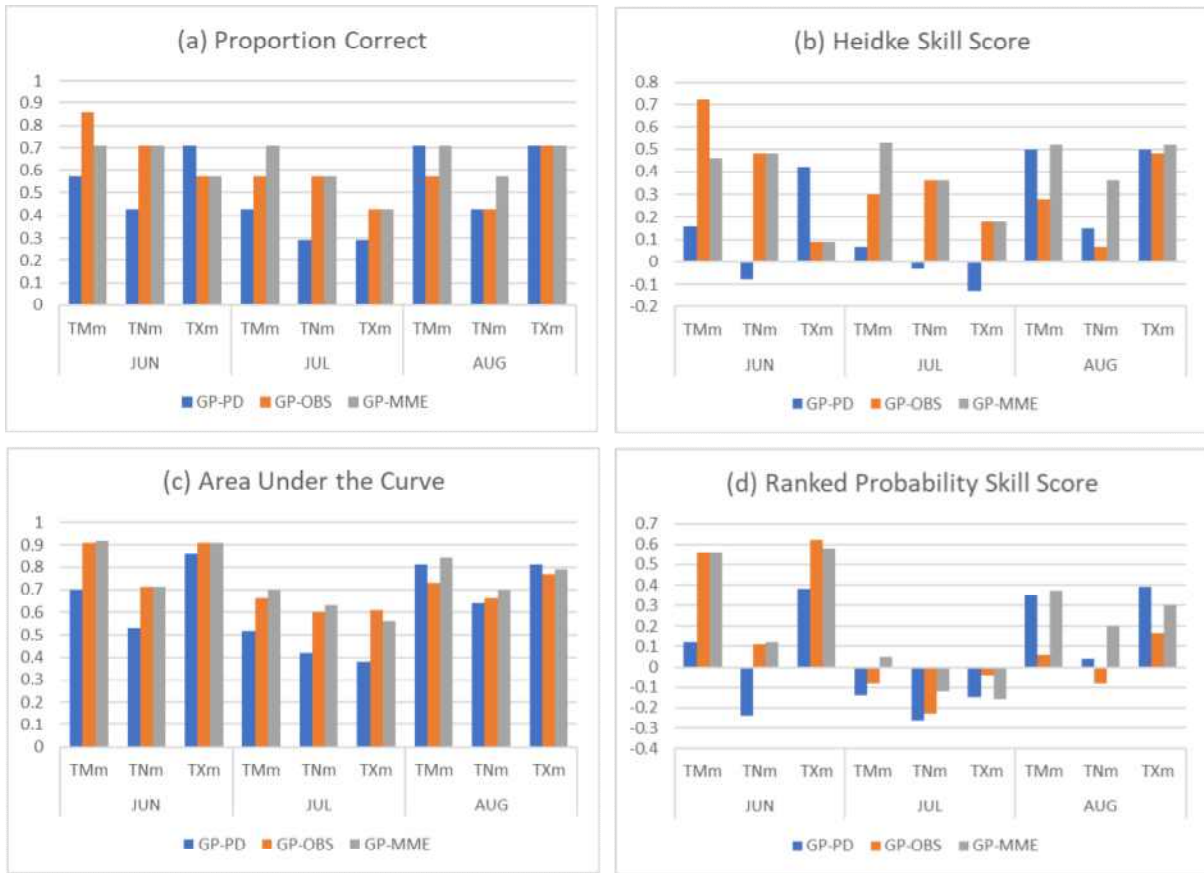


Figure 23. Performance of GP-PD, GP-OBS, and GP-MME for the test period for (a) PC, (b) HSS, (c) AUC, and (d) RPSS. Adopted from Rhee and Myoung (2021).

	YEAR	JUN				JUL				AUG			
		OBS	GP-PD	GP-OBS	GP-MME	OBS	GP-PD	GP-OBS	GP-MME	OBS	GP-PD	GP-OBS	GP-MME
TMm	2014	NN	NN	AN	AN	NN	NN	NN	NN	BN	BN	AN	NN
	2015	NN	AN	NN	NN	NN	NN	AN	NN	NN	AN	NN	NN
	2016	AN	NN	AN	AN	AN	NN	AN	AN	AN	AN	AN	AN
	2017	NN	AN	NN	NN	AN	BN	BN	BN	NN	NN	NN	NN
	2018	AN	AN	AN	AN	AN	NN	AN	AN	AN	AN	AN	AN
	2019	NN	NN	NN	AN	NN	NN	NN	NN	AN	NN	NN	NN
	2020	AN	AN	AN	AN	BN	NN	NN	NN	AN	AN	AN	AN
TNm	2014	AN	AN	AN	AN	NN	NN	NN	NN	BN	NN	AN	NN
	2015	NN	AN	NN	NN	BN	NN	NN	NN	BN	AN	AN	NN
	2016	AN	BN	AN	AN	AN	NN	AN	AN	AN	AN	AN	AN
	2017	BN	AN	AN	AN	AN	BN	BN	BN	NN	NN	NN	NN
	2018	AN	AN	AN	AN	AN	NN	AN	AN	AN	NN	NN	AN
	2019	BN	NN	NN	NN	NN	NN	NN	NN	AN	NN	NN	NN
	2020	AN	AN	AN	AN	BN	AN	NN	NN	AN	AN	AN	AN
TXm	2014	NN	NN	AN	AN	AN	NN	NN	NN	BN	BN	AN	NN
	2015	NN	AN	AN	AN	NN	AN	NN	NN	NN	AN	NN	NN
	2016	AN	NN	AN	AN	AN	NN	NN	NN	AN	AN	AN	AN
	2017	AN	AN	NN	NN	AN	NN	BN	BN	NN	NN	NN	NN
	2018	AN	AN	AN	AN	AN	AN	AN	AN	AN	AN	AN	AN
	2019	NN	NN	NN	NN	NN	NN	NN	NN	AN	NN	NN	NN
	2020	AN	AN	AN	AN	BN	NN	NN	NN	AN	AN	AN	AN

Figure 24. Tercile results of all models for the test period. Adopted from Rhee and Myoung (2021).

③ 기계학습모델을 활용한 이상기후 확률전망 생산 현업화

2021년 상반기 개발한, 모델과 관측 결합하여 입력자료 확장 객관적 인자 도출 모델(GP-MME)을 개선하여 현업 장기예보 실무지원을 위해 현업화하였다.

㉠ 현업화 개요

'21년 상반기 개발한 예측인자에 관측과 모델(APCC MME) 통합하여 활용한 모델을 현업화하였다. Rhee and Myoung (2021)의 GP-MME 모델에 해당하며 현업화를 위해 활용하는 입력변수와 목표변수를 확장하였다.

- ▷ 예측인자를 위한 입력자료를 추가(T850의 대기온도, 해수면기압)
- ▷ 목표월을 1-12월로 확장
- ▷ 목표변수에 강수(SPI1) 추가

㉡ 자료 업데이트 개선

모델의 효율적인 구동 및 자동화 준비를 위해 입력자료의 외부망 의존을 제거하도록 입력자료 중 APCC DB에서 제공하지 않는 자료에 대해 기후자료 등재/관리 검토를 요청하여 자료업데이트를 개선하였다. 입력자료 중 APCC DB에서 제공하는 자료는 APCC DB에서 입력자료수집하여 예측인자 도출하도록 코드를 수정하였으며 아래와 같이 현업 산출물을 제시하였다. 현업 산출물의 구성요소는 삼분위확률 공간정보, 지역별 삼분위확률 막대그래프, 전국 삼분위확률 막대그래프, 전국 확률밀도이다.

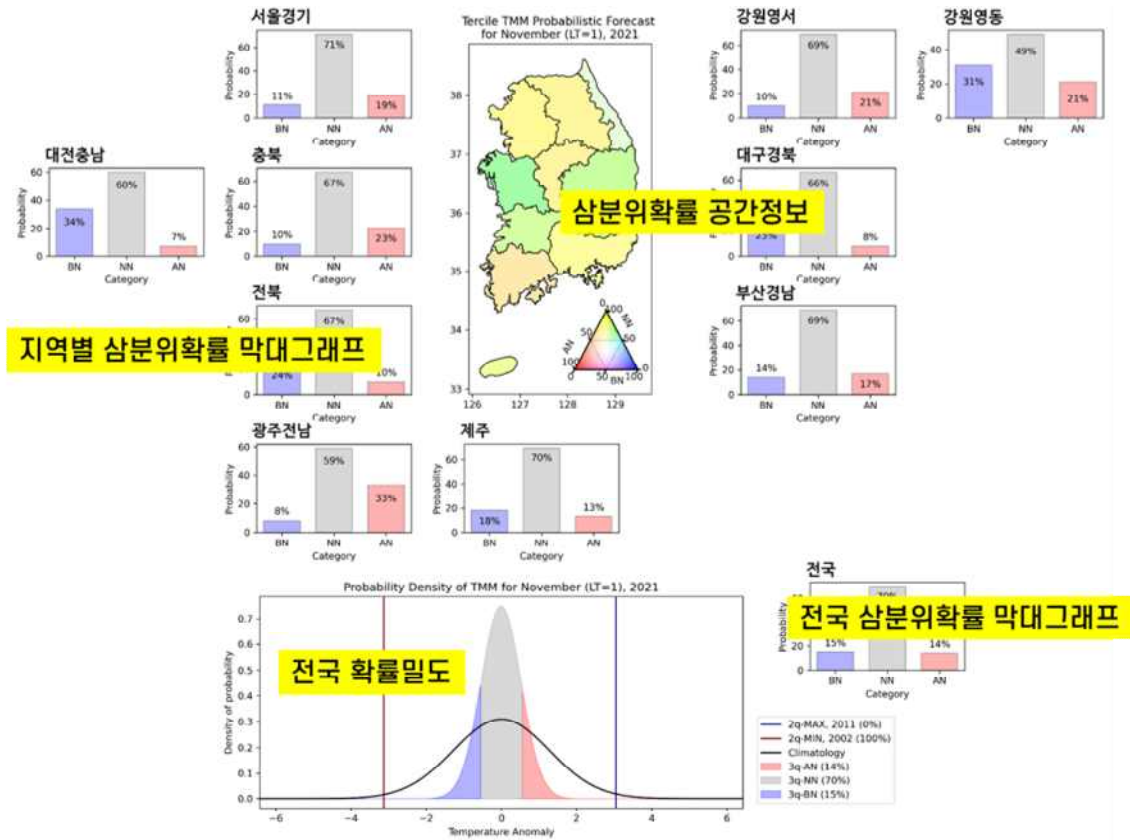


Figure 25. Operational products of Tm, TNm, TXm, and SPI1 probabilistic forecast results based on GP-MME: Example of Tm (LT1) forecasts for November, 2021.

(나) 모델 및 관측 정보를 통합한 객관적 정보결합

① 다양한 기계학습모델

㉠ 초매개변수 선정 결과

인공신경망, 랜덤포레스트, 에이다부스트, 서포트벡터회귀 각 모델에 대해 몇몇 초매개변수 조합으로 1980-2013년 기간에 대해 LOOCV를 수행하고 결과를 평균하여 성능을 검토하였으나 조합에 따라 성능의 차이가 크게 나타나지 않았다. 목표월 1-12월, 선행시간 1-3개월의 평균기온(TMm) 및 강수(SPI1을 산정하여 활용)에 대해 예측 성능 평가하였으며 전체적으로 HSS가 더 크게 나타난 경우의 초매개변수 조합을 선정하거나, 같은 경우 제한이 더 적은 쪽으로, 또는 모델 설정의 디폴트 값을 이용하였다. 여기에서 다양한 기계학습 모델 사용의 목적이 평균기온 및 강수 예측 성능을 제고하는 것이 아니라 예측 성능이 상이한 여러 모델의 객관적 정보결합을 시험하는 것임을 언급한다.

인공신경망

- 은닉층 및 은닉층 뉴런의 개수: 은닉층 1개, 뉴런 100개로 설정
- L2 페널티(정규화) 변수인 alpha: 0.01로 설정
- 고정: 활성화함수는 ReLU 함수, 학습 알고리즘은 lbfgs (Quasi-Newton 방법의 일종, 자료 크

기가 작은 경우 성능이 우수하다고 알려짐)

랜덤포레스트

- 기본학습자인 결정트리의 성장 깊이: None으로 제한 없이 성장하도록 설정
- 기본학습자 개수(n_estimators): 500개로 설정

에이다부스트

- 기본학습자인 결정트리의 성장 깊이: None으로 제한 없이 성장하도록 설정
- 기본학습자 개수(n_estimators): 500개로 설정

서포트벡터회귀

- 정규화 매개변수인 C: 디폴트 값인 1.0으로 설정
- 최대오차(epsilon): 0.1로 설정

④ LOOCV 평균한 성능평가 결과

초매개변수 산정을 위해 수행한 1980-2013 기간의 LOOCV 성능평가 결과 및 검증기간 (2014-2020)의 성능평가 결과는 나타내지 않았으며, 여기에서는 결합을 위해 최종적으로 구성된 모델의 1991-2020 기간의 LOOCV 평균한 단정예측 또는 확률예측 성능평가 결과를 살펴보았다.

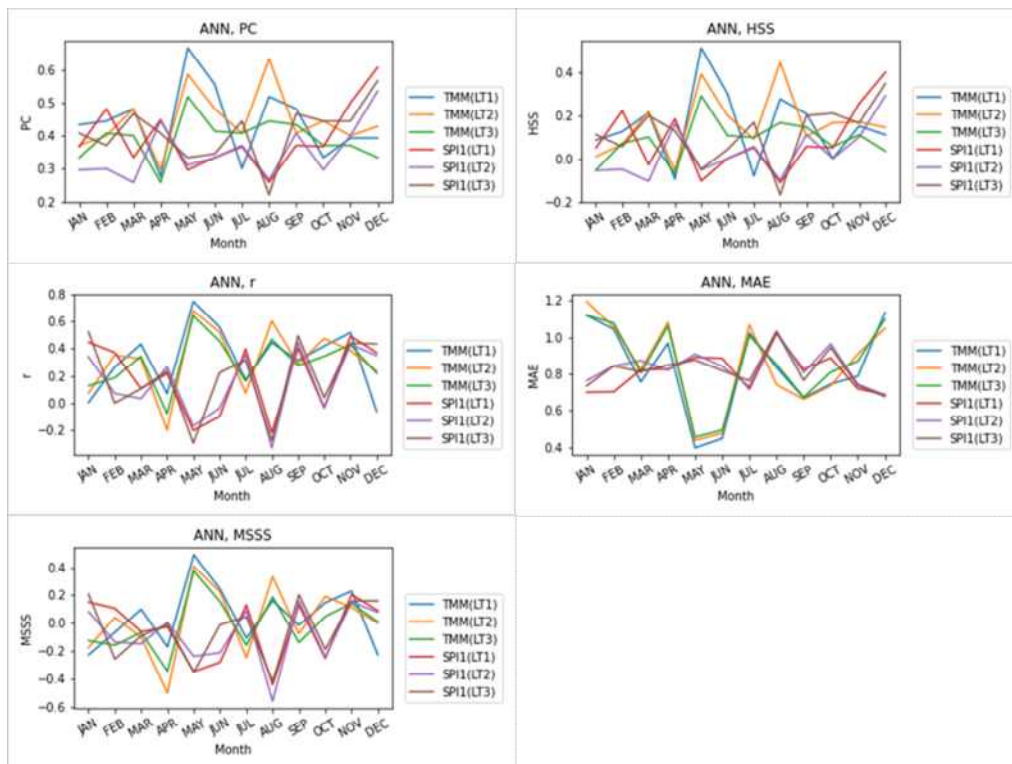


Figure 26. Performance of deterministic forecasts of ANN (LOOCV results averaged).

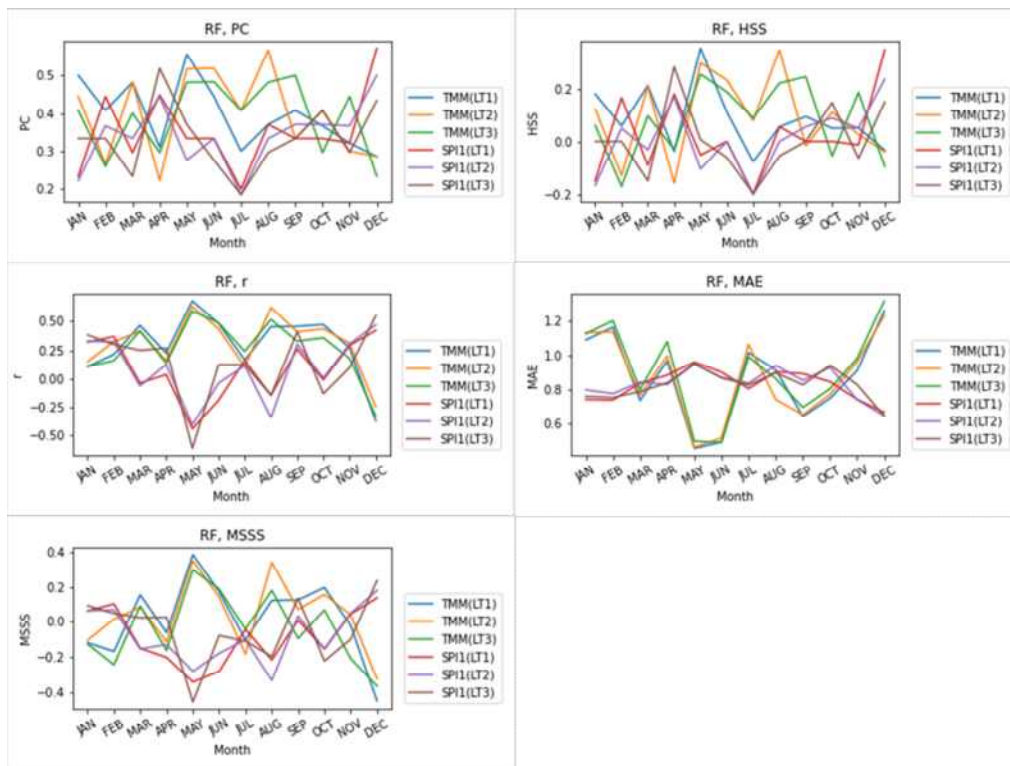


Figure 27. Performance of deterministic forecasts of RF (LOOCV results averaged).

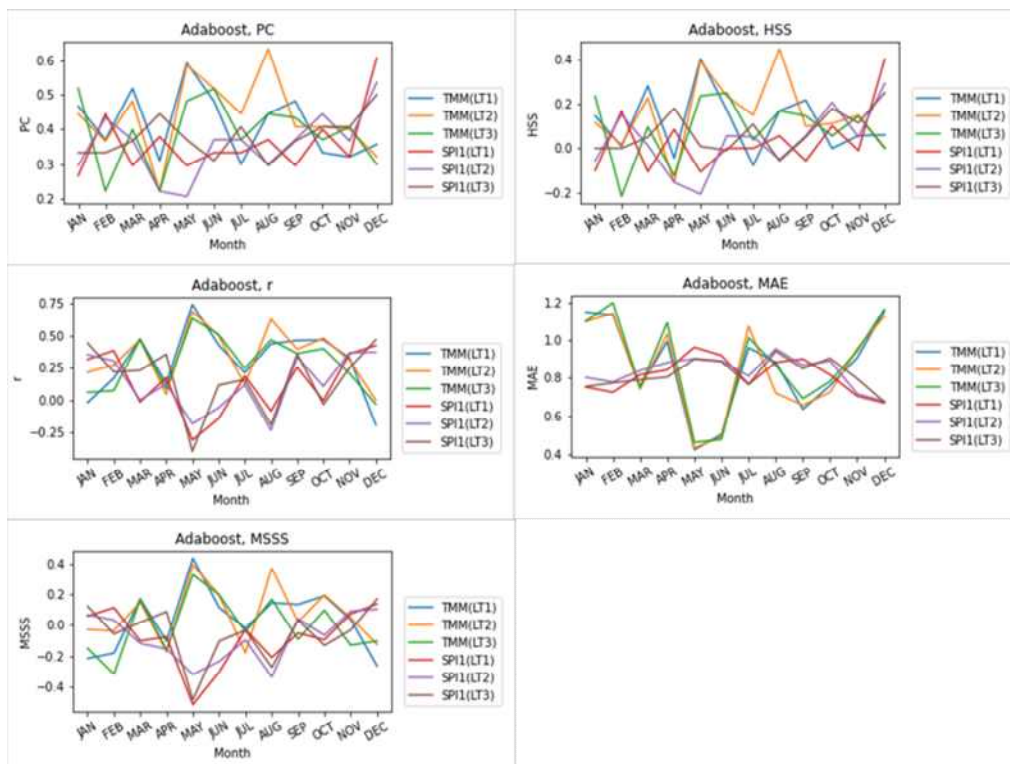


Figure 28. Performance of deterministic forecasts of Adaboost (LOOCV results averaged).

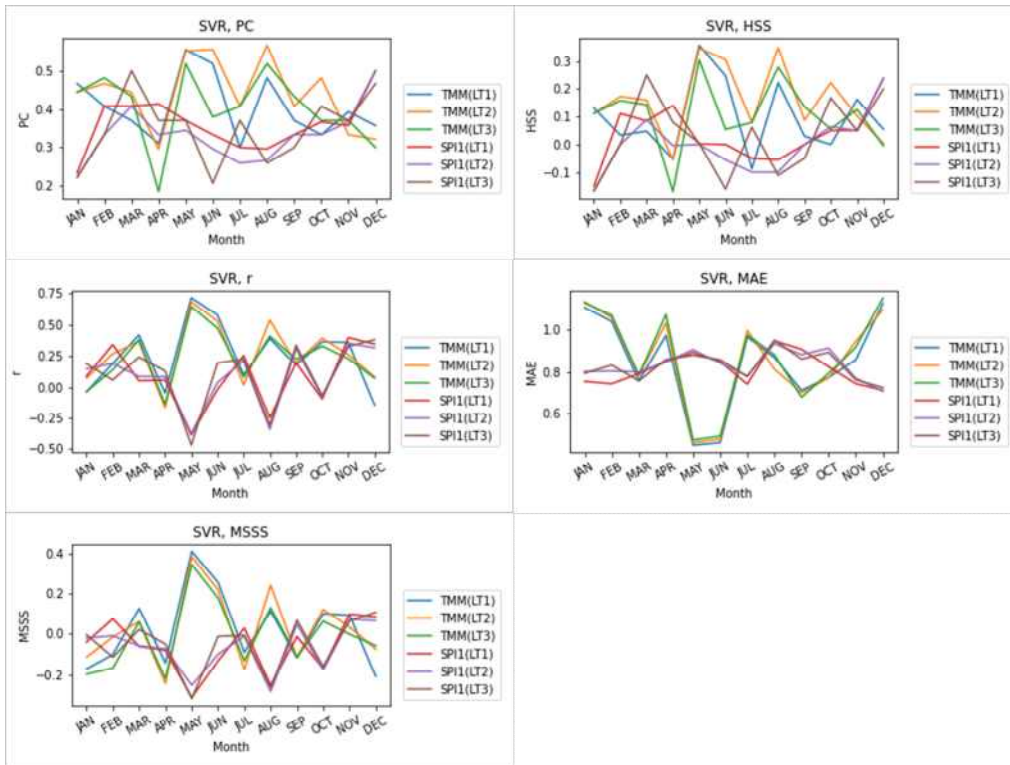


Figure 29. Performance of deterministic forecasts of SVR (LOOCV results averaged).

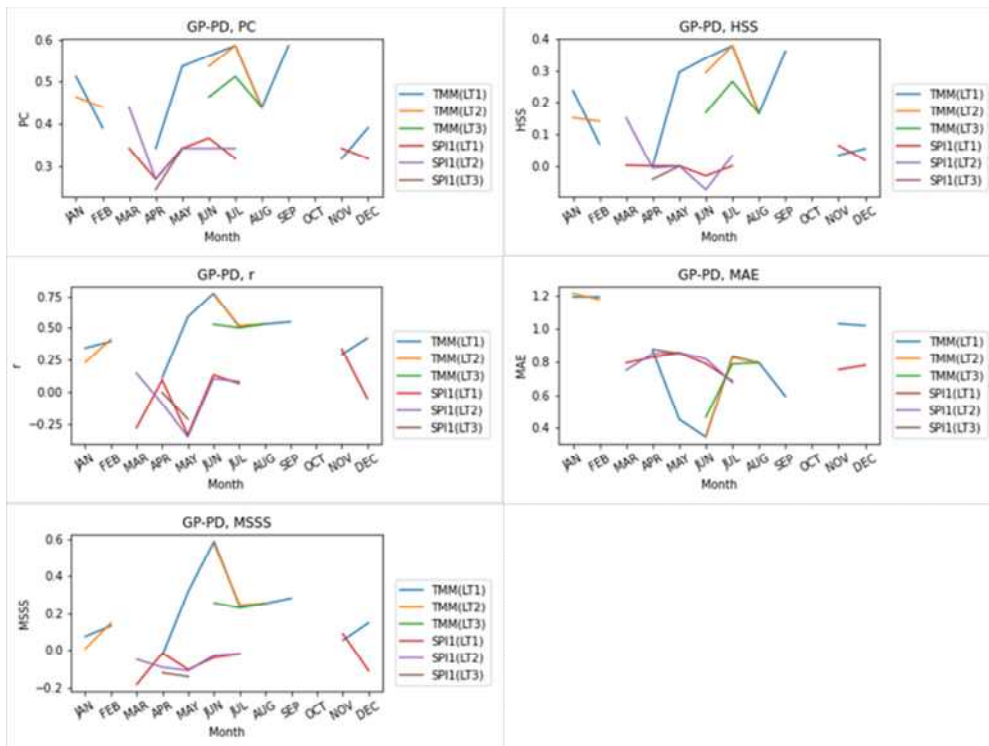


Figure 30. Performance of deterministic forecasts of GP-PD (LOOCV results averaged).

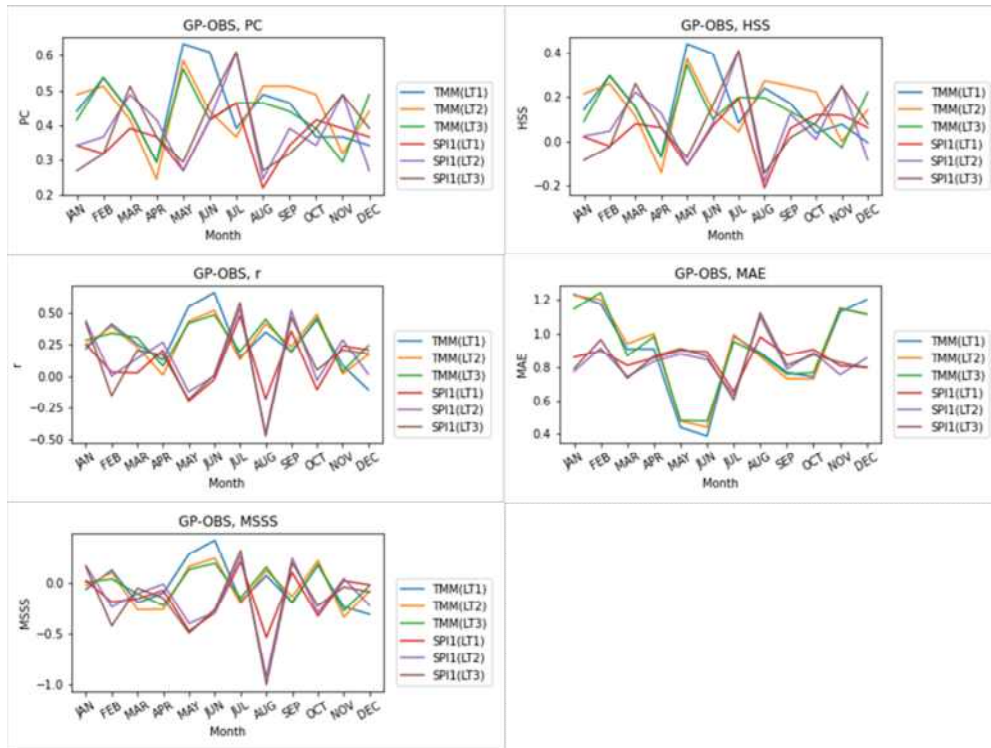


Figure 31. Performance of deterministic forecasts of GP-OBS (LOOCV results averaged).

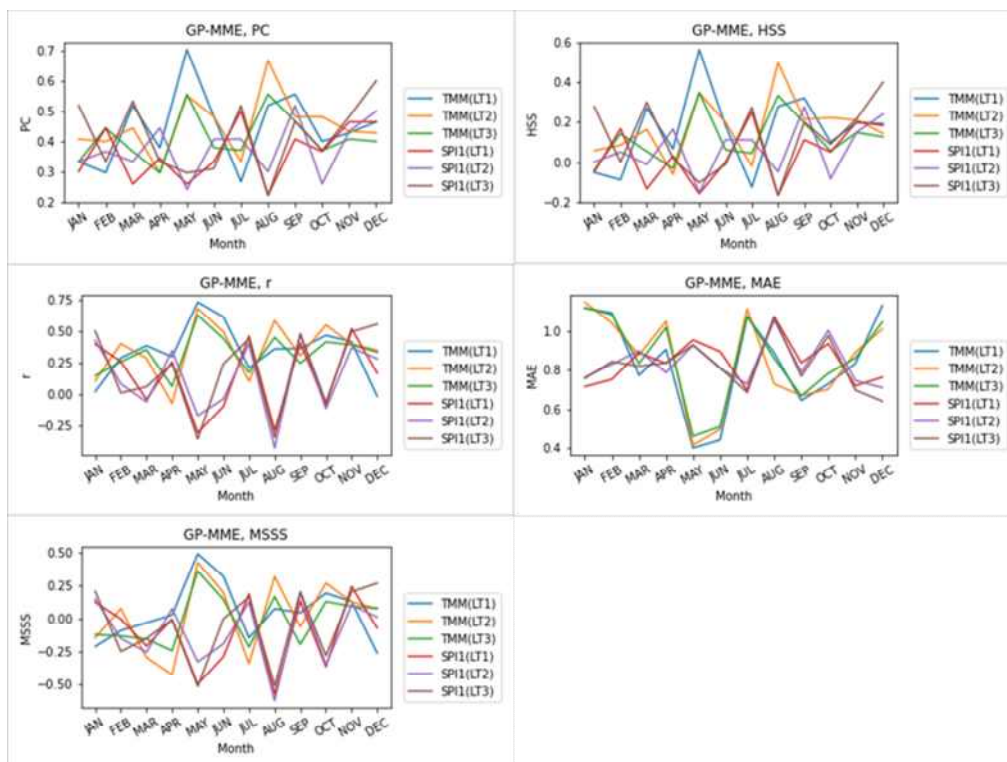


Figure 32. Performance of deterministic forecasts of GP-MME (LOOCV results averaged).

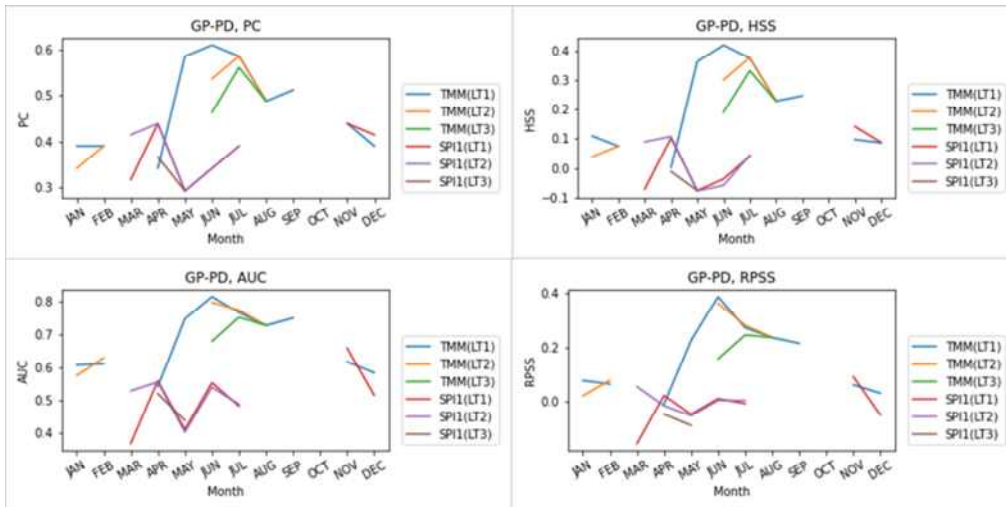


Figure 33. Performance of probabilistic forecasts of GP-PD (LOOCV results averaged).

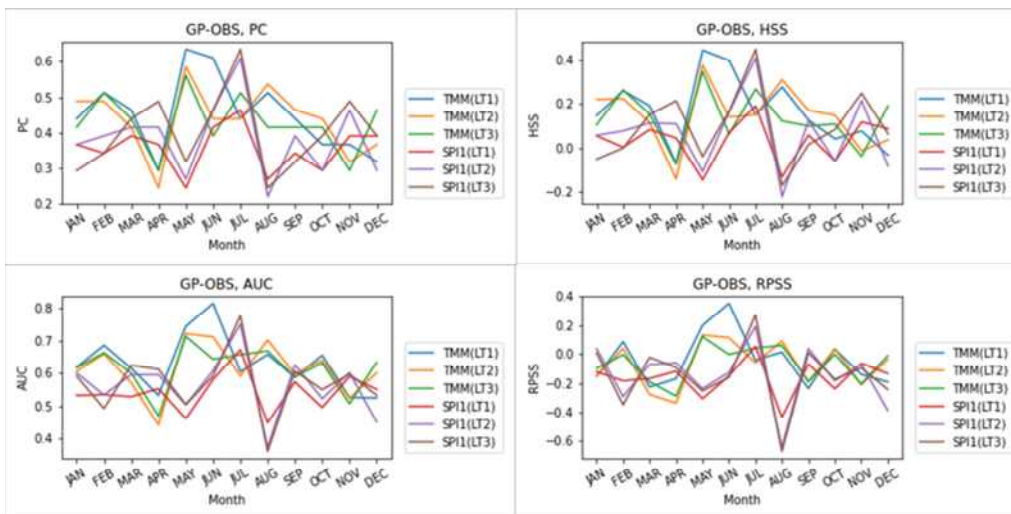


Figure 34. Performance of probabilistic forecasts of GP-OBS (LOOCV results averaged).

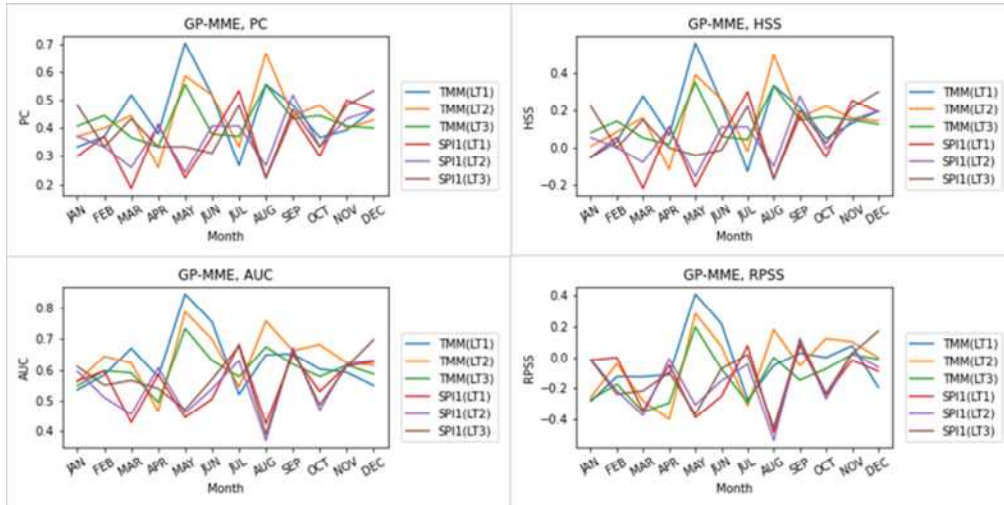


Figure 35. Performance of probabilistic forecasts of GP-MME (LOOCV results averaged).

② 다양한 개별역학모델 및 APCC MME

각 모델의 1980-2020 기간의 LOOCV 평균한 단정예측 또는 확률예측 성능평가 결과를 살펴 보았다.

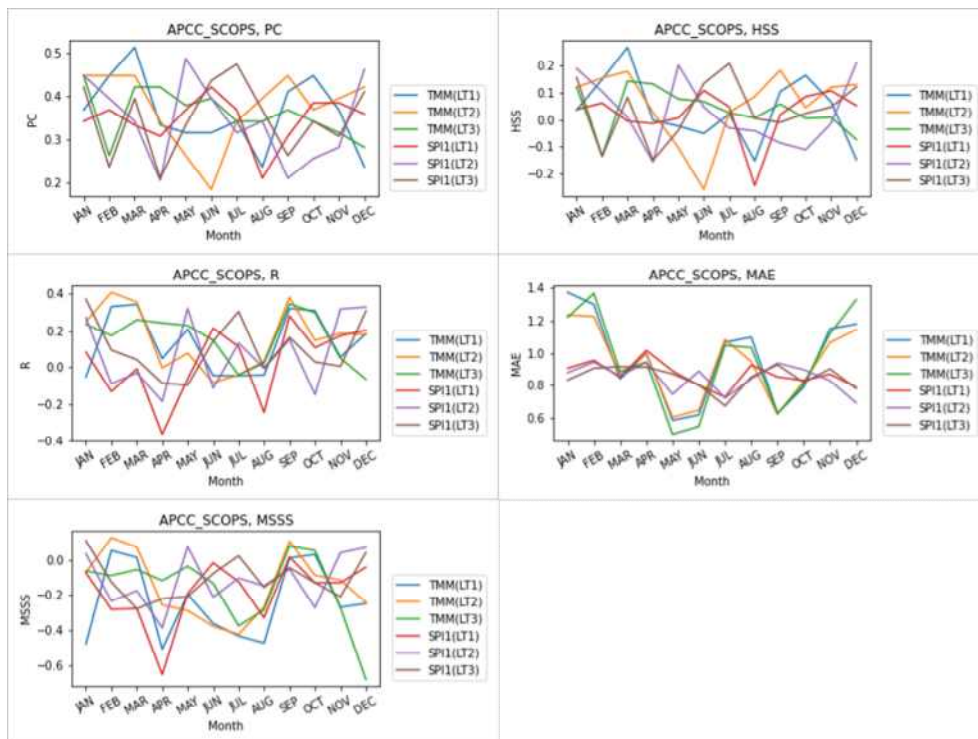


Figure 36. Performance of deterministic forecasts of APCC (LOOCV results averaged).

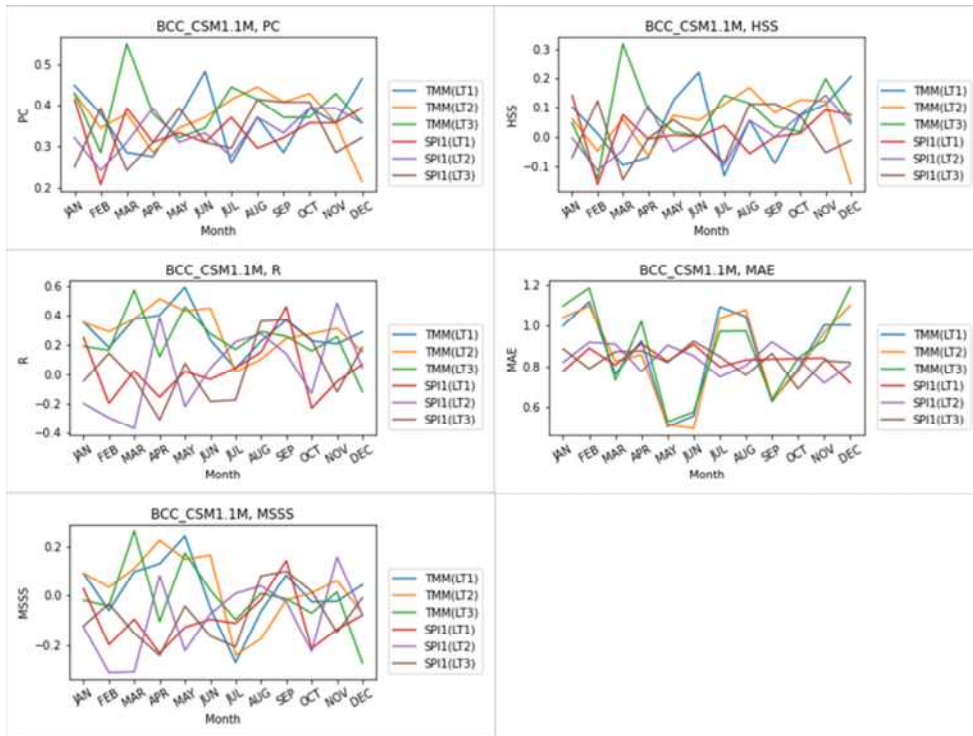


Figure 37. Performance of deterministic forecasts of BCC (LOOCV results averaged).

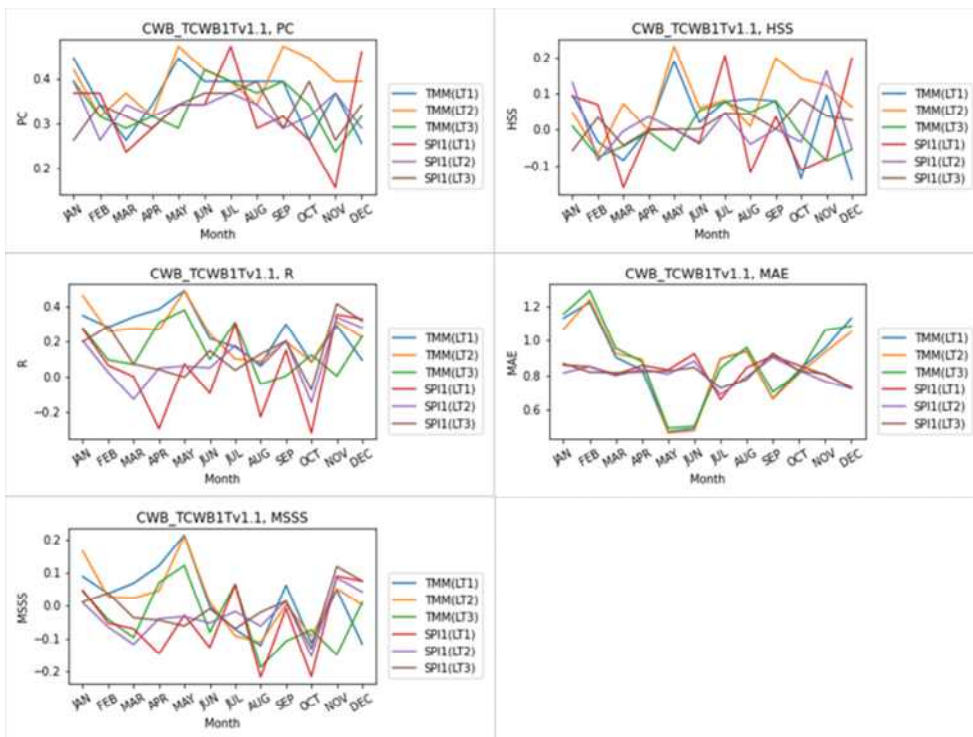


Figure 38. Performance of deterministic forecasts of CWB (LOOCV results averaged).

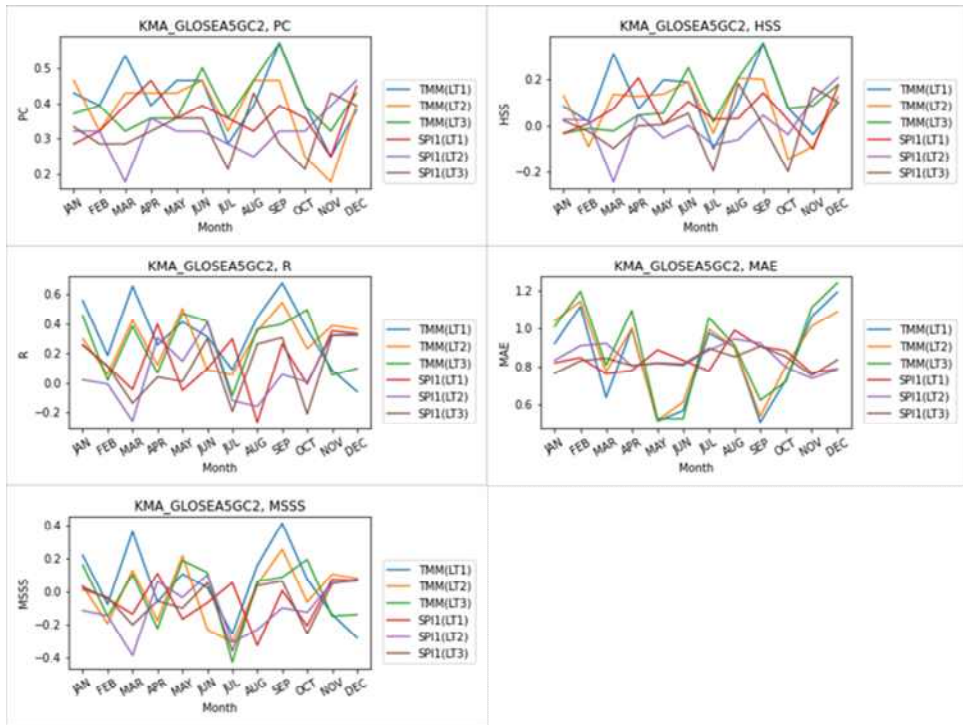


Figure 39. Performance of deterministic forecasts of KMA (LOOCV results averaged).

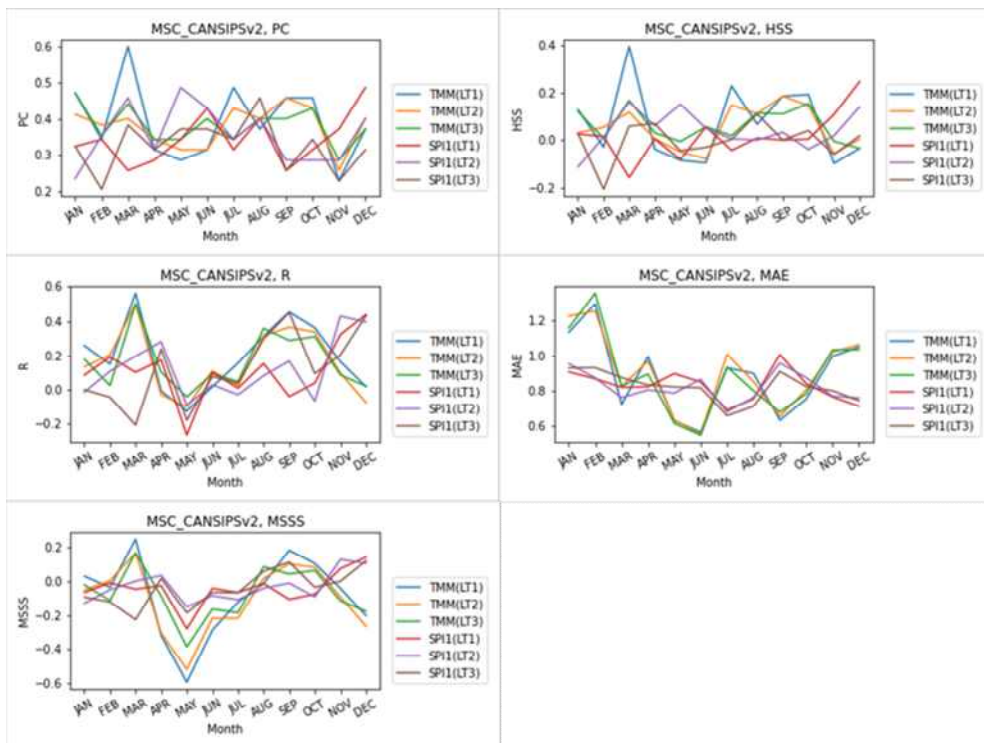


Figure 40. Performance of deterministic forecasts of MSC (LOOCV results averaged).

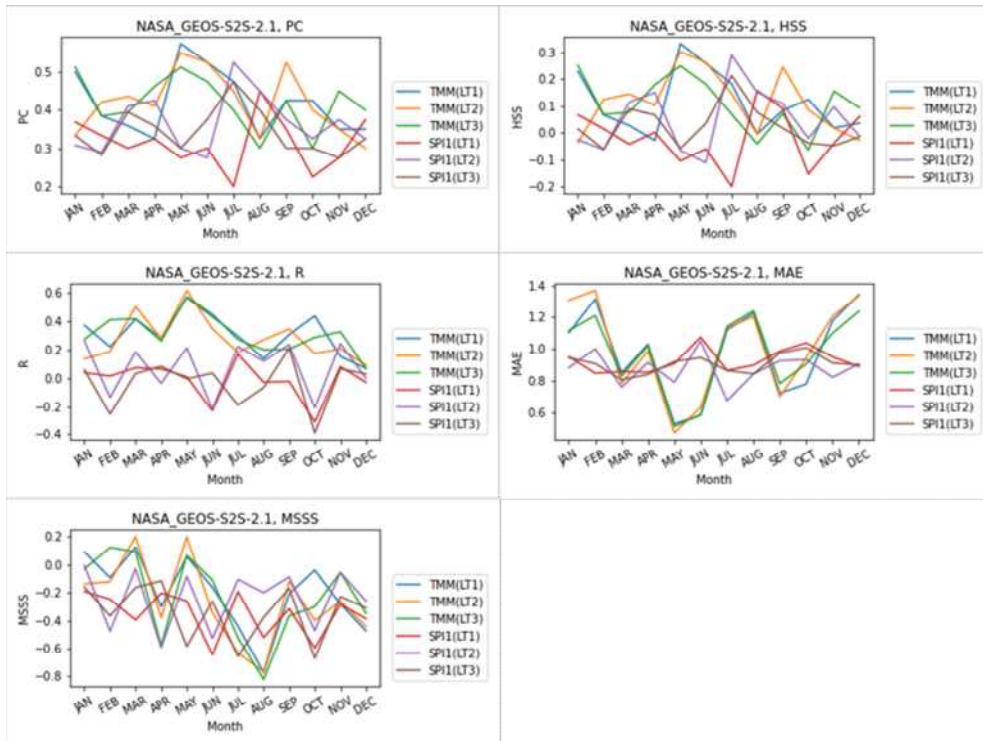


Figure 41. Performance of deterministic forecasts of NASA (LOOCV results averaged).

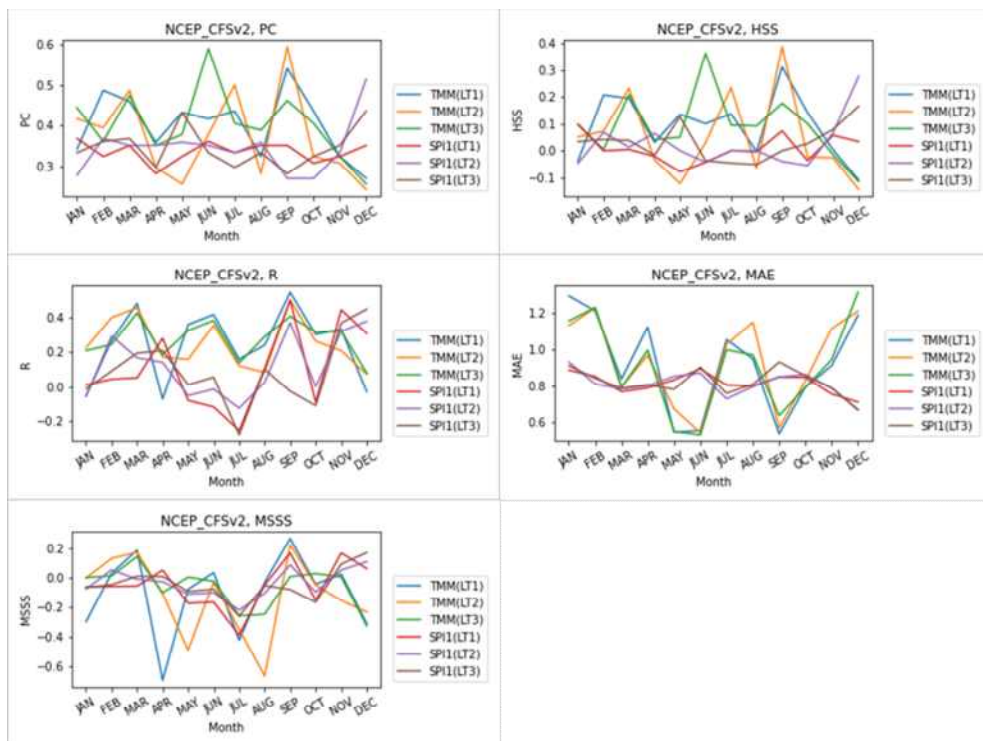


Figure 42. Performance of deterministic forecasts of NCEP (LOOCV results averaged).

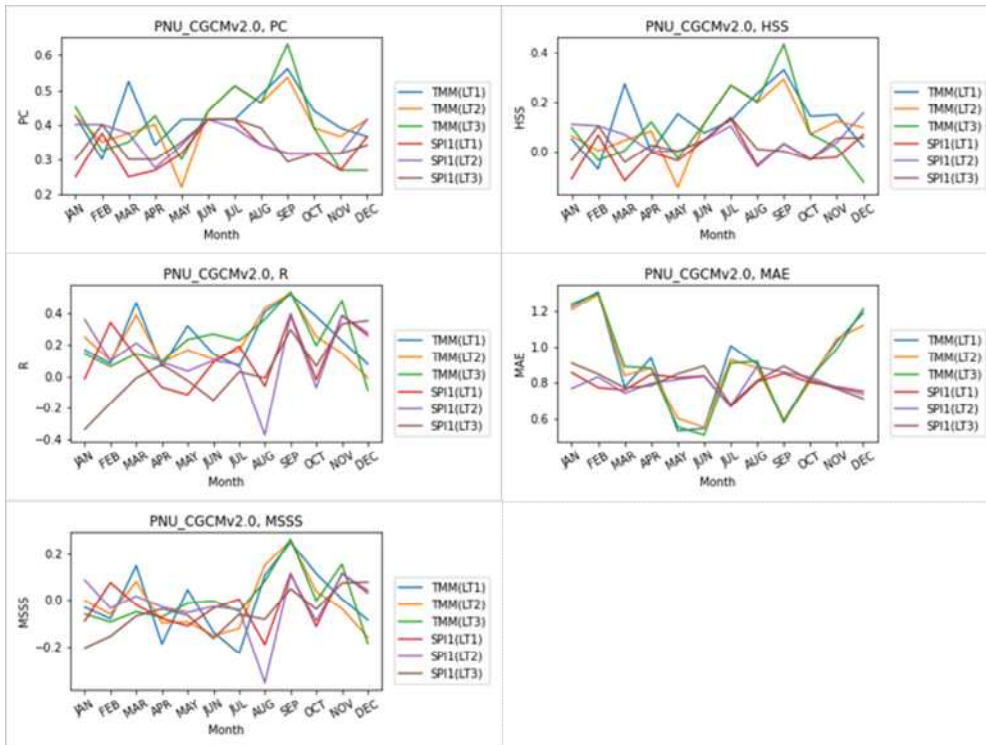


Figure 43. Performance of deterministic forecasts of PNU (LOOCV results averaged).

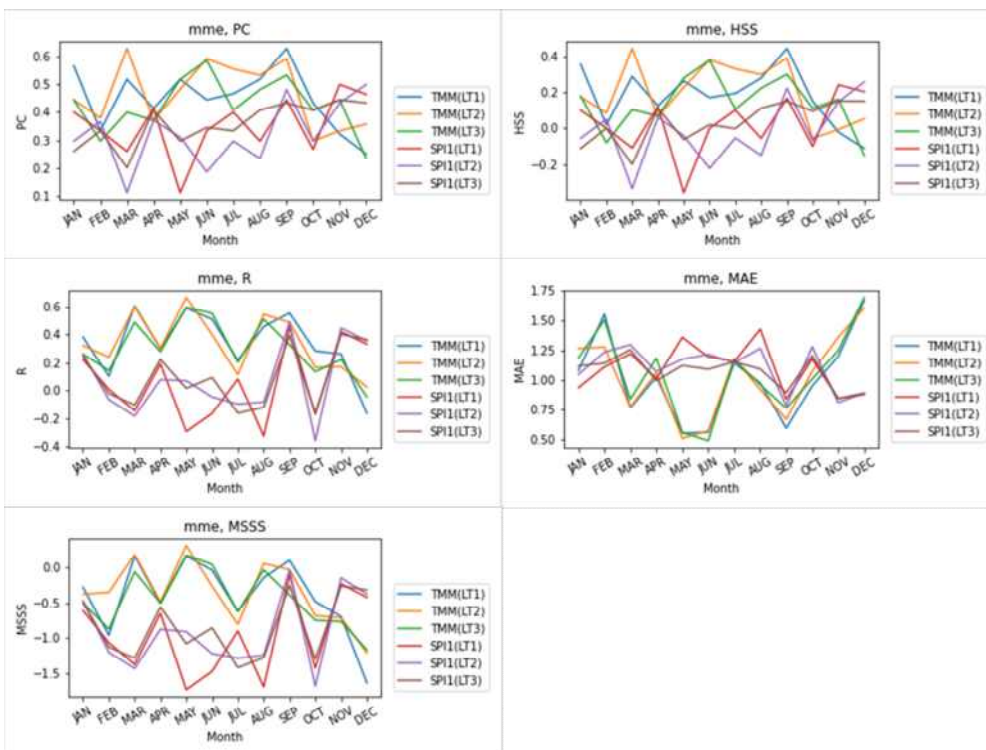


Figure 44. Performance of deterministic forecasts of APCC MME (LOOCV results averaged).




Figure 45. Performance of probabilistic forecasts of APCC (LOOCV results averaged).

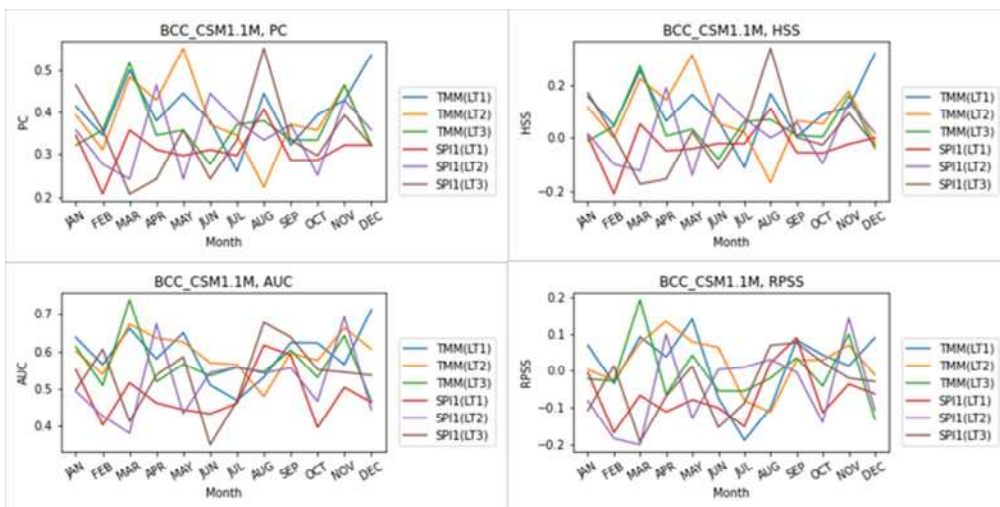


Figure 46. Performance of probabilistic forecasts of BCC (LOOCV results averaged).

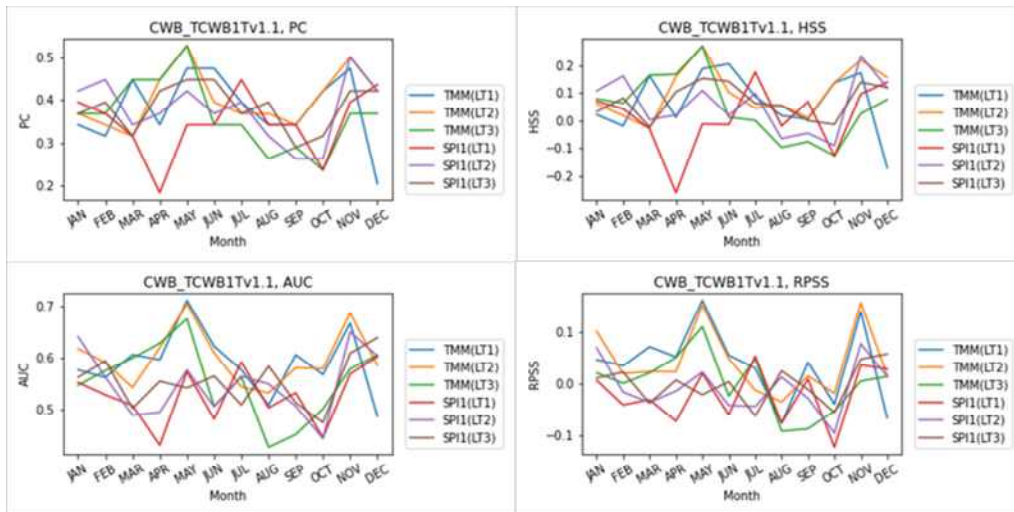


Figure 47. Performance of probabilistic forecasts of CWB (LOOCV results averaged).

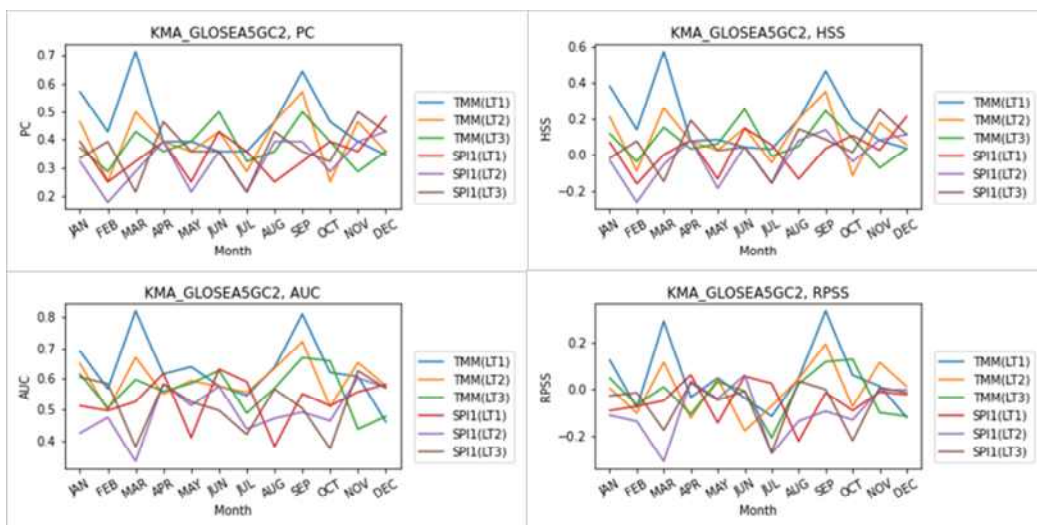


Figure 48. Performance of probabilistic forecasts of KMA (LOOCV results averaged).

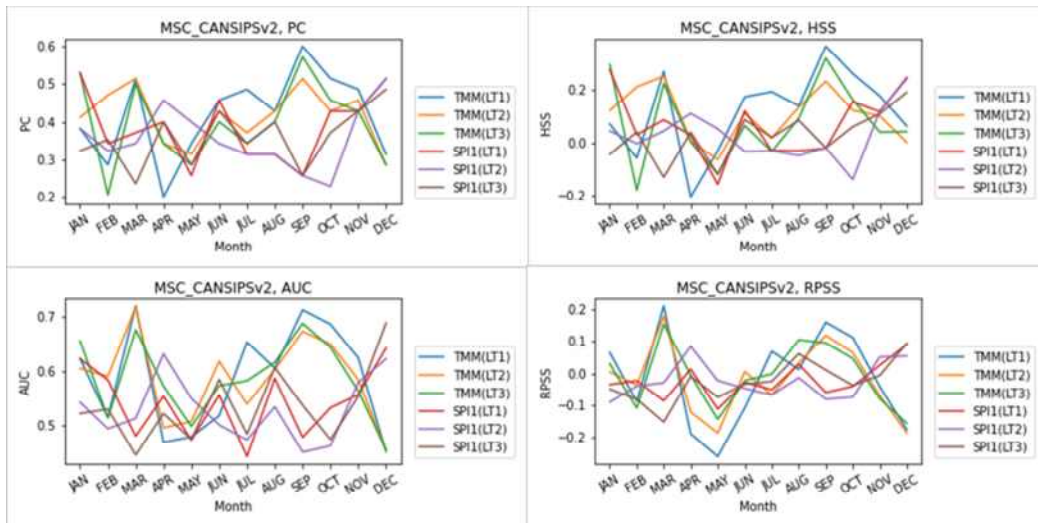


Figure 49. Performance of probabilistic forecasts of MSC (LOOCV results averaged).

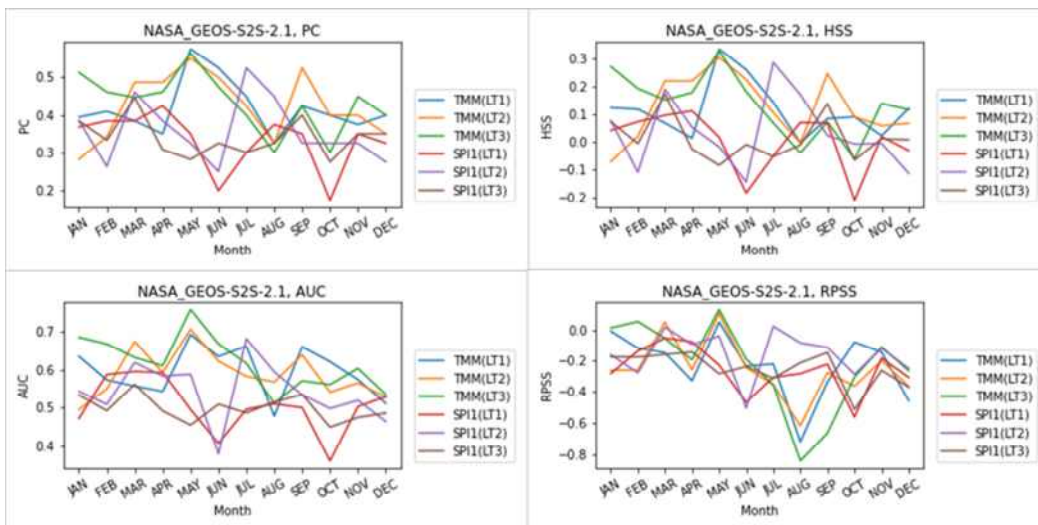


Figure 50. Performance of probabilistic forecasts of NASA (LOOCV results averaged).

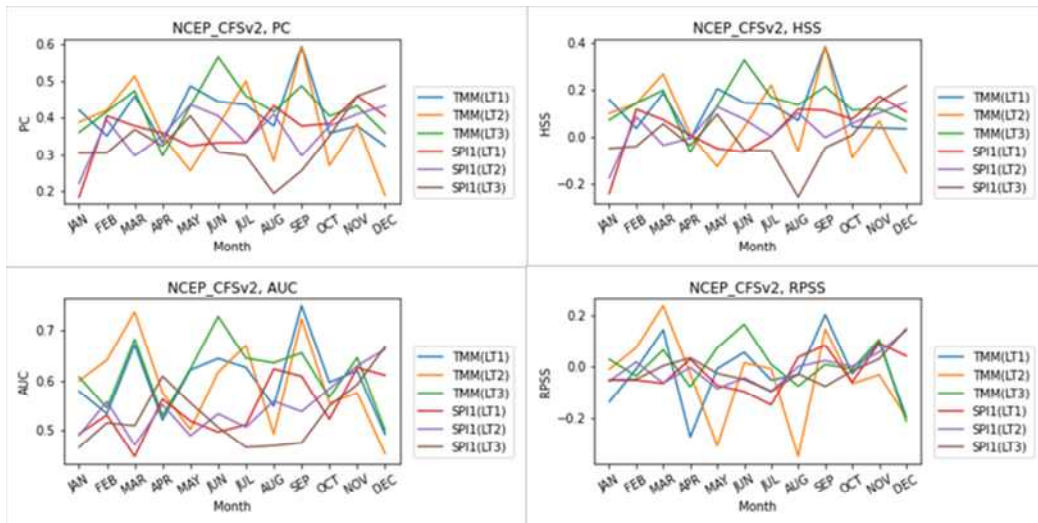


Figure 51. Performance of probabilistic forecasts of NCEP (LOOCV results averaged).

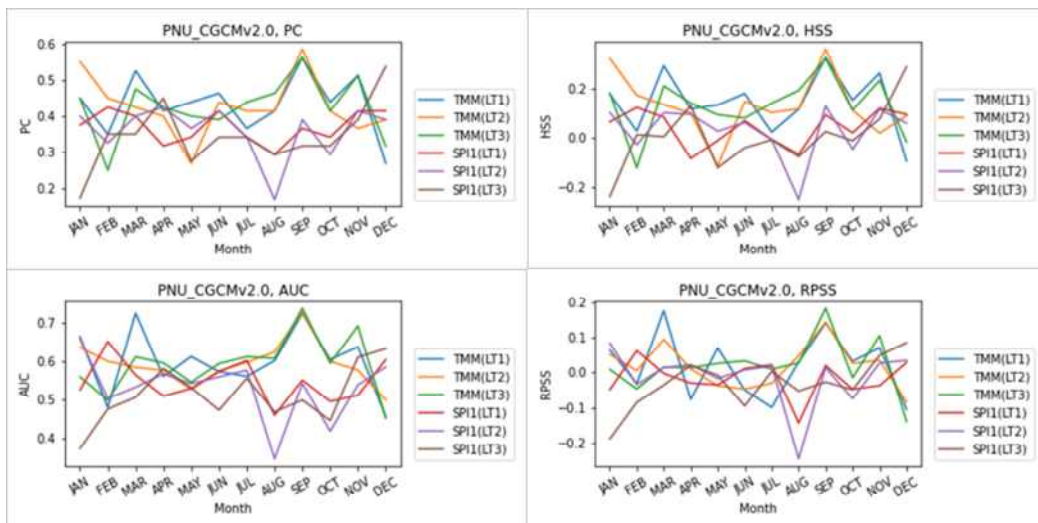


Figure 52. Performance of probabilistic forecasts of PNU (LOOCV results averaged).

③ 베이저안 모델 평균 결합 결과

단정 전망정보 객관적 결합에는 인공신경망, 랜덤포레스트, 에이다부스트, 서포트벡터회귀 네 종류의 기계학습 모델, GP-PD, GP-OBS, GP-MME의 세 가우시안 프로세스 모델, 8개의 개별역학모델과 APCC MME를 활용하였으며, 확률 전망정보 객관적 결합에는 세 가우시안 프로세스 모델과 8개의 개별역학모델을 활용하였다.

단정 전망정보 결합을 위해 각 모델에 대한 분산 및 가중치 모두 EM Algorithm을 통해 최적화하였다. 객관적 결합 모델 산출물은 여러 모델(가중치 $\geq 1e-5$)과 결합 모델의 확률 분포 및

결합 모델의 AN, NN, BN 확률로 표출하였으며 목표변수 Tm, SPI에 대해서 계절별 성능을 각 모델에 대한 Boxplot으로 나타내었다. 결합모델의 성능을 보면, 개별모델의 가장 우수한 경우보다 우수하다고 할 수는 없으나 상대적으로 안정적인 성능을 보이는 것을 알 수 있다.

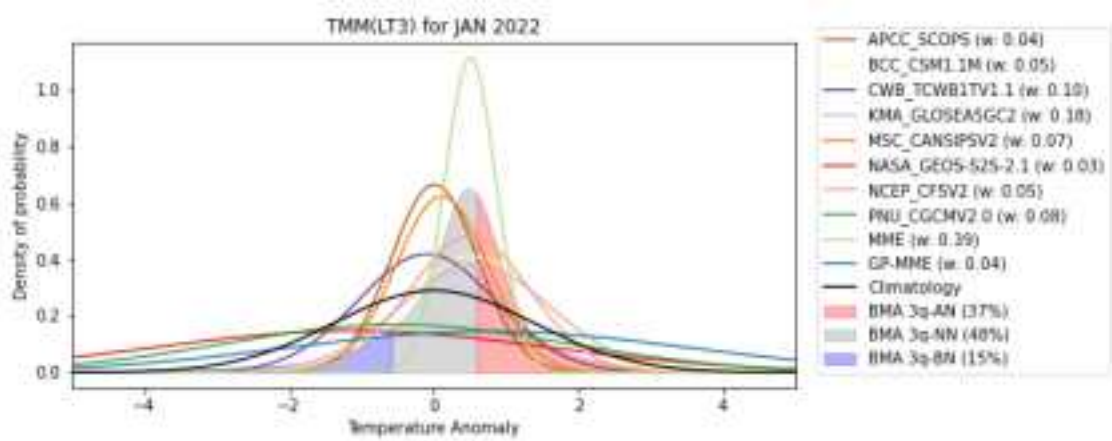


Figure 53. BMA results of deterministic forecasts: an example for Tm (LT3) forecast of January 2022.

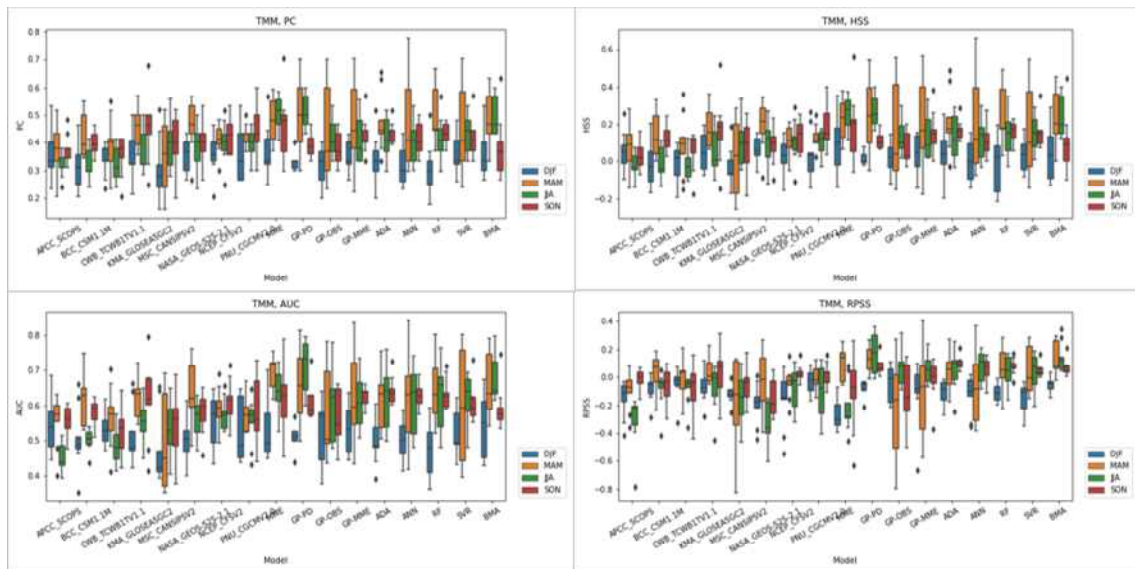


Figure 54. Boxplots of Tm forecast performance of BMA of deterministic forecasts for each season and model.

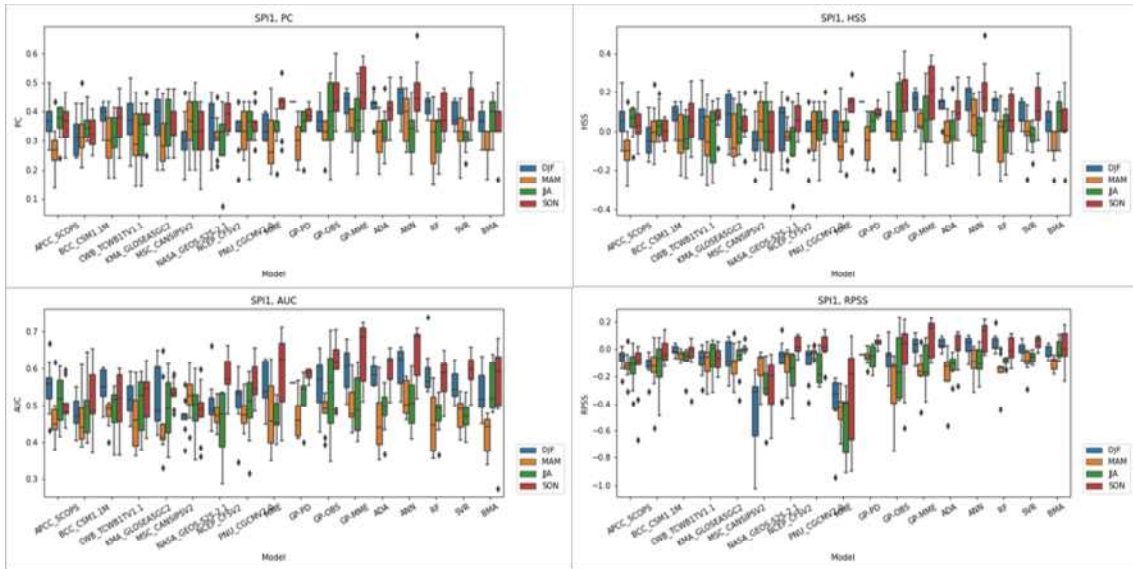


Figure 55. Boxplots of SPI1 forecast performance of BMA of deterministic forecasts for each season and model.

확률 전망정보 결합을 위해서는 각 모델에 대한 분산은 지정하거나 업데이트하지 않고 EM Algorithm을 통해 가중치만을 최적화하였다. 단정전망과 마찬가지로 객관적 결합 모델 산출물은 여러 모델(가중치 $\geq 1e-5$)과 결합 모델의 확률 분포 및 결합 모델의 AN, NN, BN 확률로 표출하였으며 목표변수 Tm, SPI1에 대해서 계절별 성능을 각 모델에 대한 Boxplot으로 나타내었다. 개별역학모델 성능의 경우 앞서 보여준 1980-2020년 기간에 대한 결과와 기간 차이로 인해 성능이 다르게 나타남에 주의할 필요가 있다.

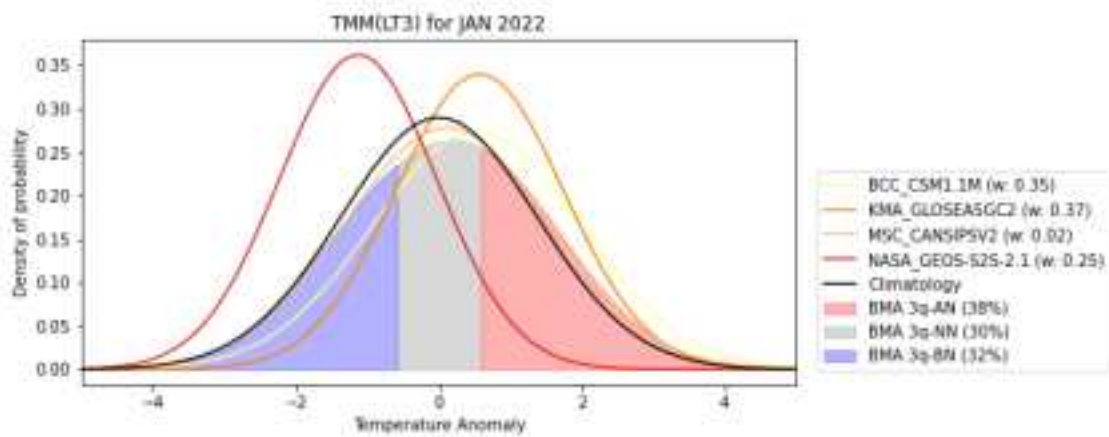


Figure 56. BMA results of probabilistic forecasts: an example for Tm (LT3) forecast of January 2022.

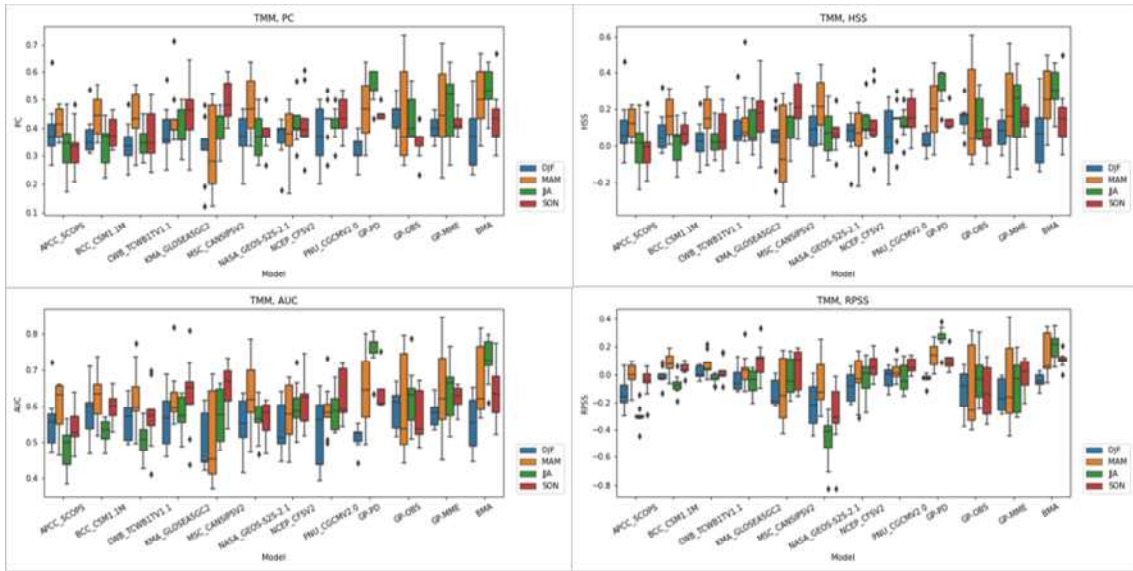


Figure 57. Boxplots of Tm forecast performance of BMA of probabilistic forecasts for each season and model.

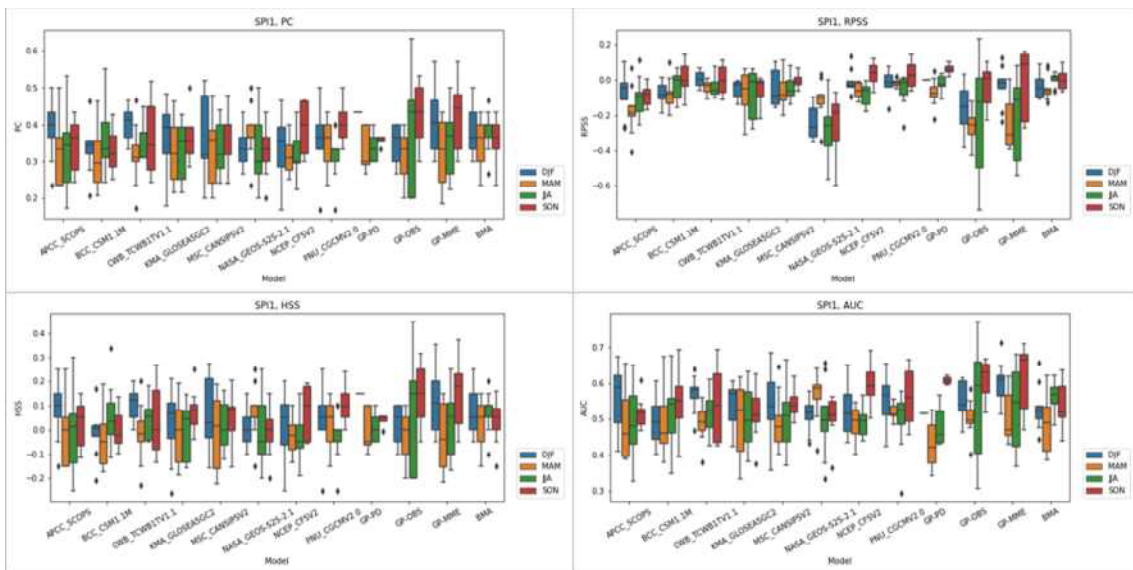


Figure 58. Boxplots of SPI1 forecast performance of BMA of probabilistic forecasts for each season and model.

④ 다중모델 슈퍼양상블 결합 결과

단정 전망정보 결합의 경우 다중회귀를 이용하여 다중회귀식의 계수 값으로 가중치 결정한다(Krishnamurti et al., 1999; Krishnamurti et al., 2000; Krishnamurti et al., 2016). 기존 연구에서는 회귀계수가 음의 값을 가지는 경우도 모두 그대로 사용하였으나 이 연구에서는 양의 값으로 강제 설정하였으며 절편의 값은 0이 되도록 설정하였다. 객관적 결합 모델 산출물은 여러 모델(가중치 $\geq 1e-5$)과 결합 모델의 단정적 결과로 표출하였다. 목표변수 Tm, SPI1에 대해서 계절별 성능을 각 모델에 대한 Boxplot으로 나타내었다.

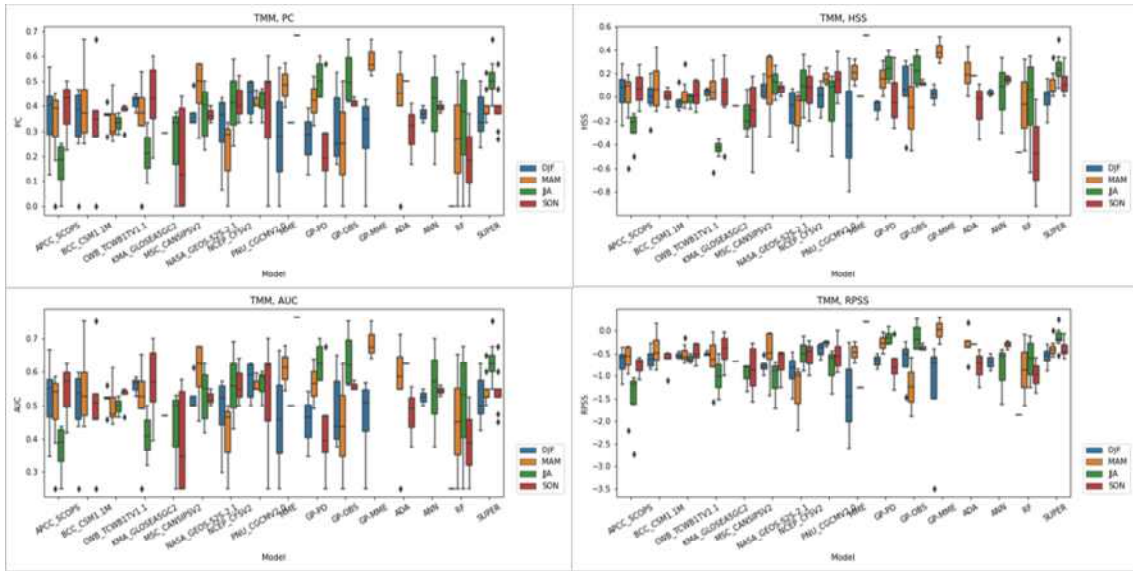


Figure 59. Boxplots of Tm forecast performance of Super-ensemble of deterministic forecasts for each season and model.

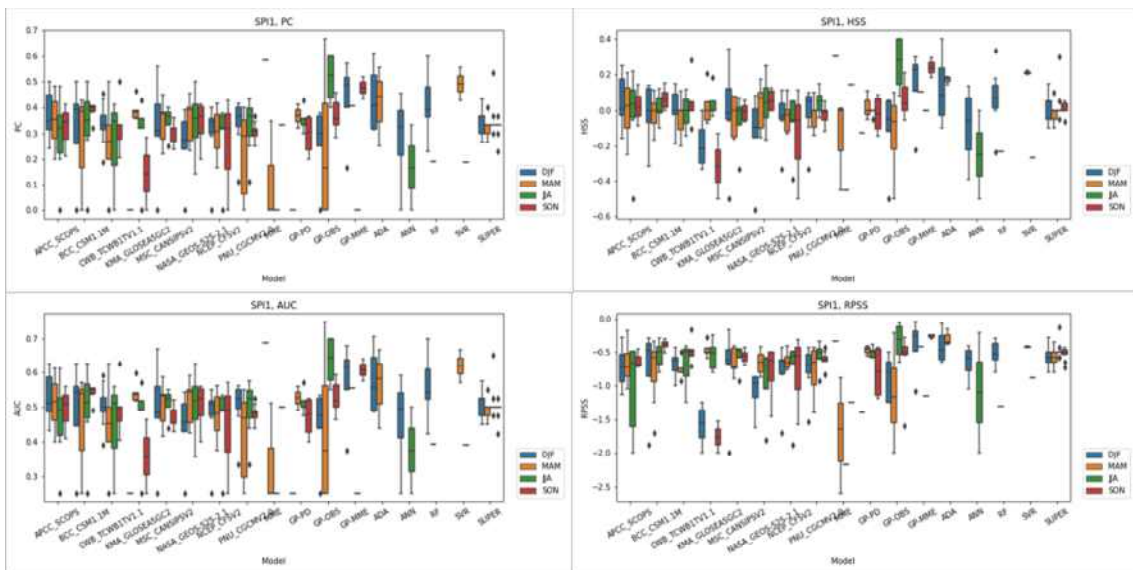


Figure 60. Boxplots of SPI1 forecast performance of Super-ensemble of deterministic forecasts for each season and model.

확률 전망정보 결합의 경우 각 모델의 Continuous Ranked Probability Score (CRPS) 값의 역수를 가중치로 사용하여 다중모델 확률분포를 얻는다(Cane et al., 2012). 목표변수 Tm, SPI1에 대해서 계절별 성능을 각 모델에 대한 Boxplot으로 나타내었다.

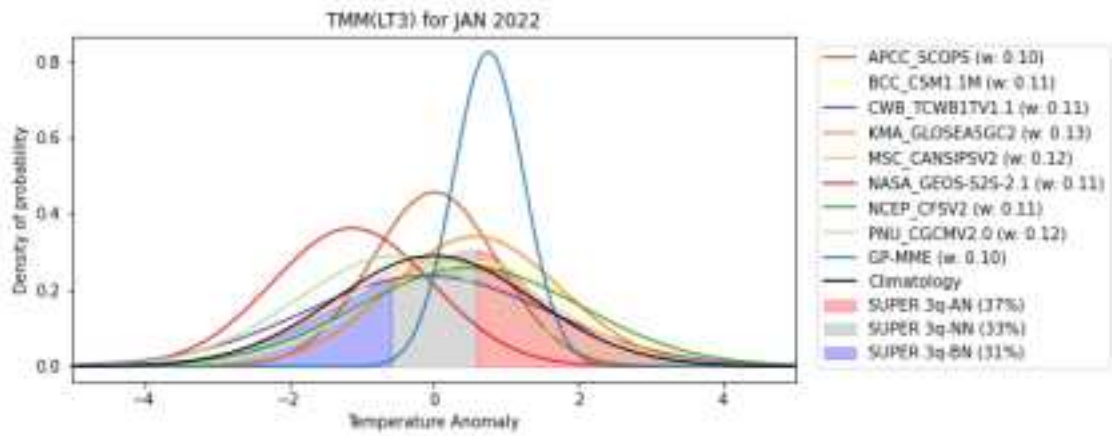


Figure 61. Super-ensemble results of probabilistic forecasts: an example for TmM (LT3) forecast of January 2022.

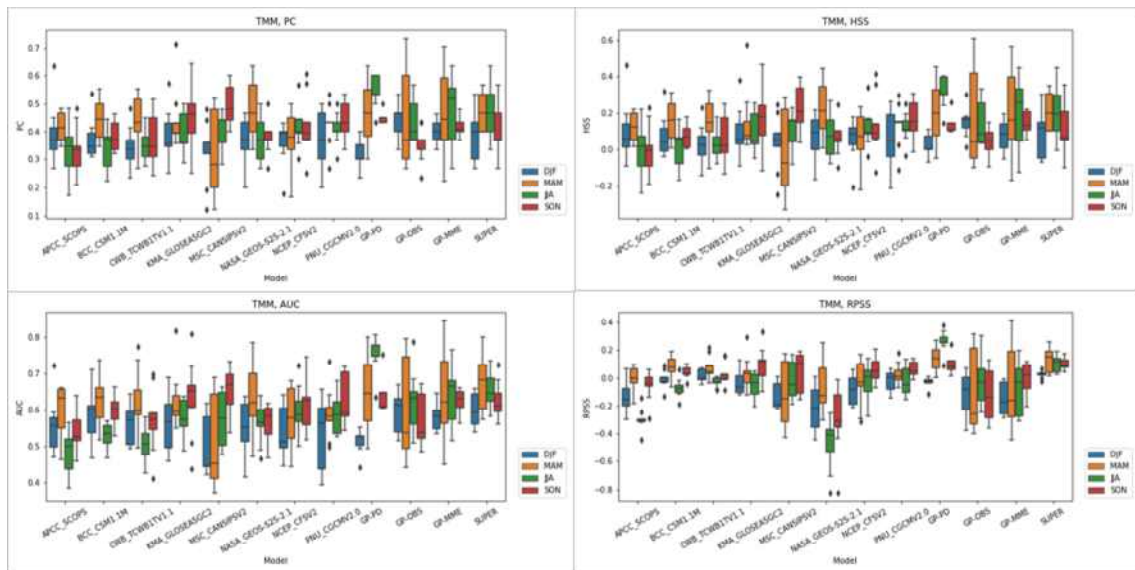


Figure 62. Boxplots of TmM forecast performance of Super-ensemble of probabilistic forecasts for each season and model.

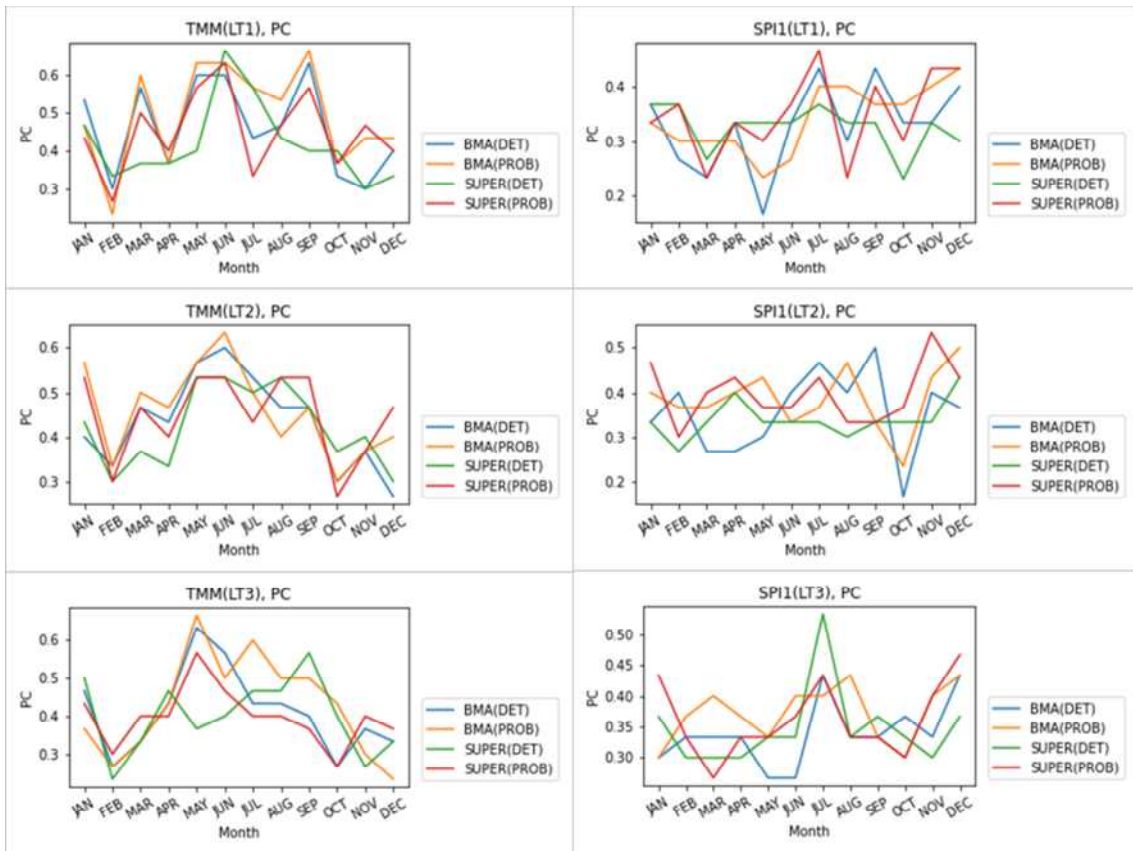


Figure 64. Comparisons of PC scores of BMA and Super-ensemble.

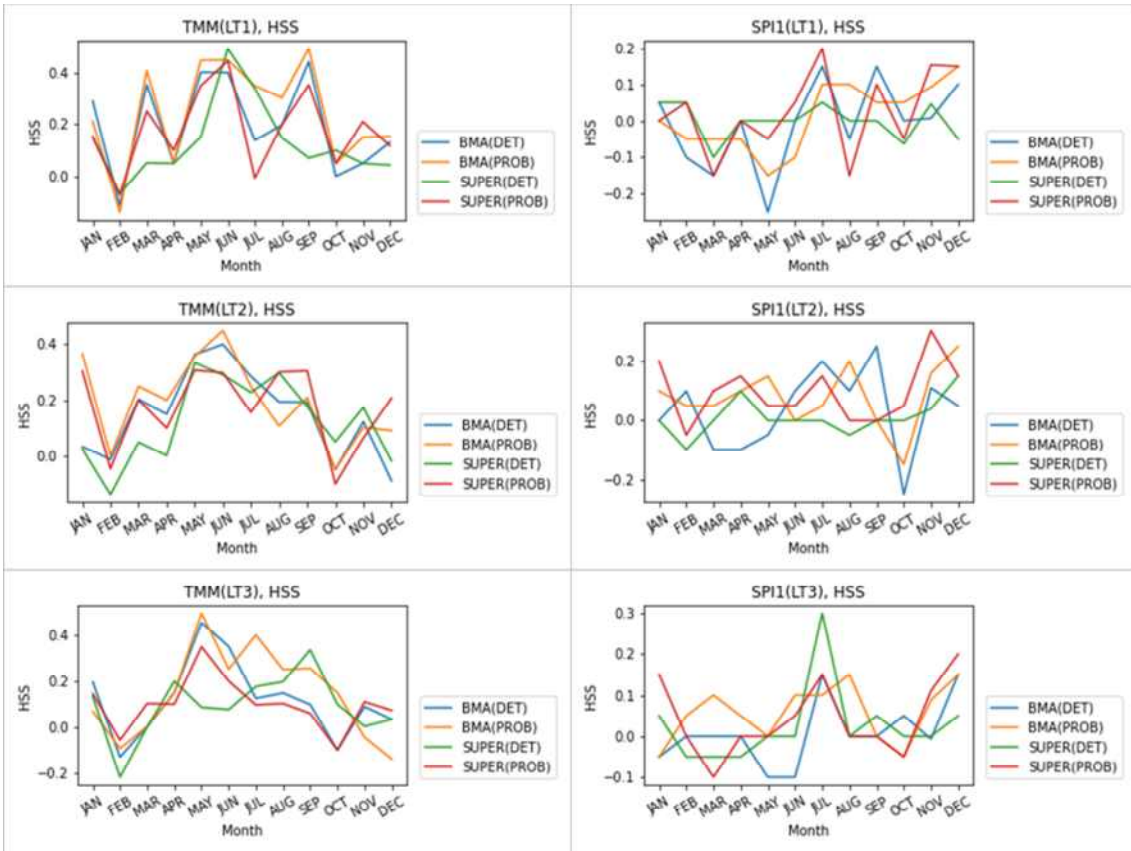


Figure 65. Comparisons of HSS scores of BMA and Super-ensemble.

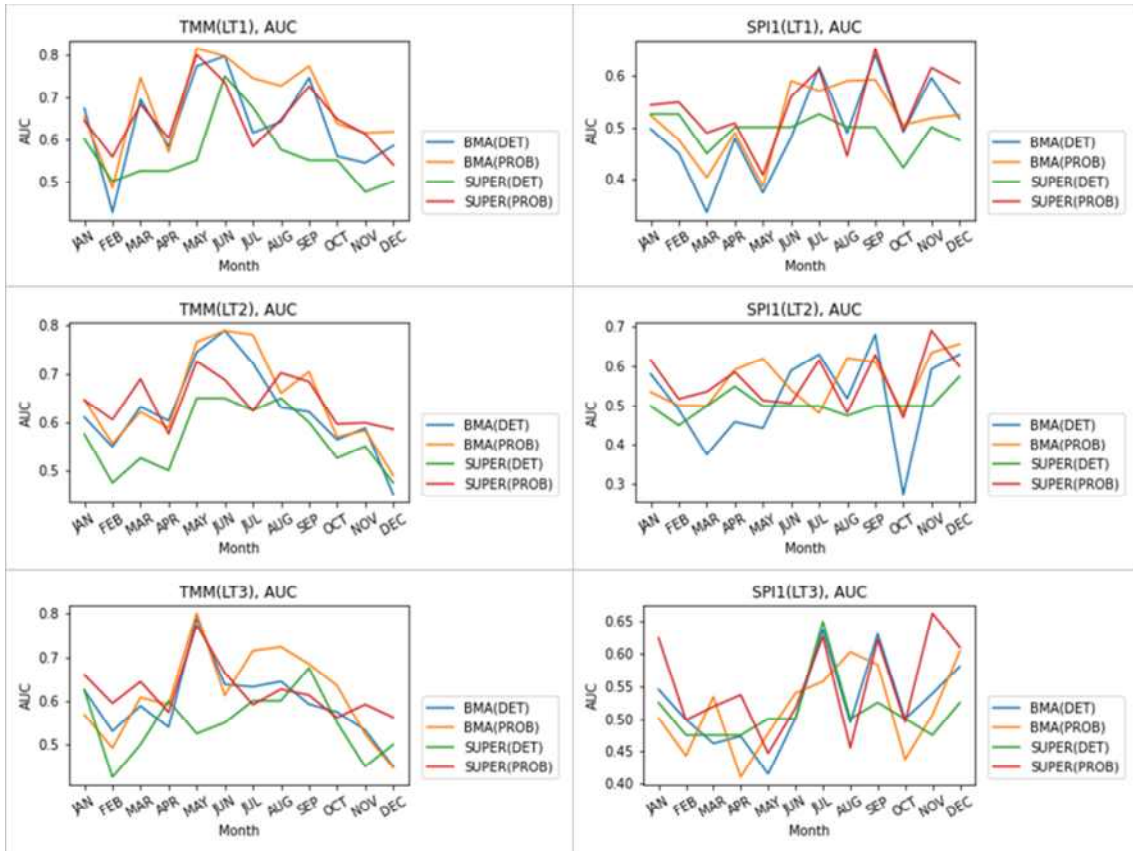


Figure 66. Comparisons of AUC scores of BMA and Super-ensemble.

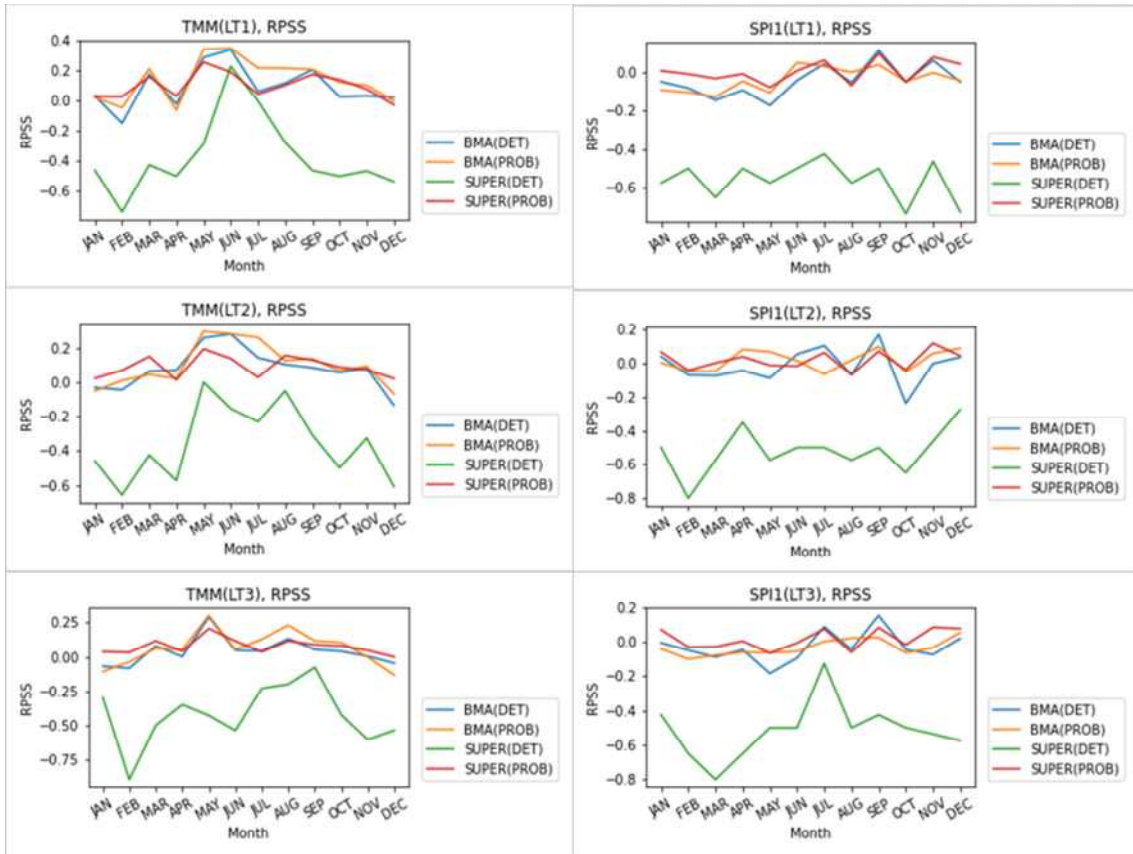


Figure 67. Comparisons of RPSS scores of BMA and Super-ensemble.

(2) 신기술을 적용한 동아시아 계절내 예측성 개선

(가) 딥러닝 모델별 실험 결과 및 평가

딥러닝 모델 실험은 ERA-5 재분석자료 중 T2M 변수를 이용하여 학습 데이터셋(Table 21)을 구축하고 5종류의 모델별에 Table 22와 같이 하이퍼파라미터(hyperparameters)와 모델 설계에 필요한 기본 조건 등을 같게 설정하고 진행하였다. 학습(training), 검증(validation), 테스트(test)에 사용된 데이터는 1950년부터 2020년까지 수집된 ERA-5 재분석자료 중에서 2001~2010년 기간의 자료를 이용하였다. 학습과 검증에는 2001~2008년까지의 데이터를 각 80%, 20%의 비율로 나누어 구축하였다. 테스트는 2009~2010년까지의 총 2년 동안의 데이터를 이용하였다.

학습 모델은 입력길이 14, 출력길이 1로 즉 14일의 데이터를 이용하여 1일을 예측하는 방법으로 설계하였다. 학습 모델을 동일한 조건에서 평가하기 위해 커널 크기는 3×3 , 활성화함수는 relu, 풀림방법은 MaxPooling, 드롭아웃은 0.5를 이용하였다. 학습에는 최대 에포크를 300으로 설정하였으며, 최저화 알고리즘은 ADAM, 학습률(learning rate)는 $1e-4$, 손실함수는 MSE(Mean Square Error)(Eq. 30)를 이용하였다. 그리고 학습 모델의 설계, 학습, 검증, 테스트, 시각화 등 각 모델의 평가를 위해 Python 3.8.11, Tensorflow 2.5.0, Matplotlib 3.4.2, Numpy 1.21.2 등 파이썬 환경에서 사용 가능한 딥러닝 프레임워크 중 하나인 구글에서 개발한 텐서플로우(Tensorflow)를 기반으로 모델을 구축하고 실험을 수행하였다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2 \quad [31]$$

여기서 y' 는 모델 예측값, y 는 참값을 의미한다.

Table 21. Summaries for training, validation, and test dataset

Name	Content
Dataset	ERA-5 reanalysis daily data
Variable Name	T2M
Training and validation period	2001 - 2008
Test data period	2009 - 2010

Table 22. Initialize values and hyper-parameters for deep learning training

Name	Content
Input data length	14
Output data length	1
Activation function	relu
Kernel size	3×3
Polling method	MaxPooling
Dropout rate	0.5
Maximum epoch	300
Optimizer	ADAM
Learning rate	$1e-4$
Loss function	MSE (Mean Square Error)

효율적인 모델 학습을 위해 tensorflow에서 제공하는 EarlyStopping, ReduceLRonPlateau 등의 콜백(callback) 함수를 이용하였다. EarlyStopping는 모니터링 대상인 손실함수 값의 변화가 일정 횟수(patience) 동안 개선이 되지 않을 경우 학습을 중단하는 콜백 함수이며, ReduceLRonPlateau는 일정 횟수(patience) 동안 모니터링 대상인 손실함수 값의 변화가 없으면 학습률(learning rate)을 사전에 정의된 방법으로 조정하여 손실함수가 최소화될 수 있도록 개선하는데 사용하는 콜백 함수이다. 본 연구에서는 콜백 함수 모두 검증 손실값(validation loss)을 모니터링 하였으며, EarlyStopping와 ReduceLRonPlateau의 patience는 각 5, 3을 설정하였

다.

사례별 학습 결과는 Figure 68과 같다. 사례 1 모델과 5 모델이 학습 과정에서 다른 사례에 비해 loss와 validation loss 간 차이가 크게 나타나는 경향이 있었으며, 사례들 중에서 사례4 모델이 가장 좋은 학습경향을 보였다.

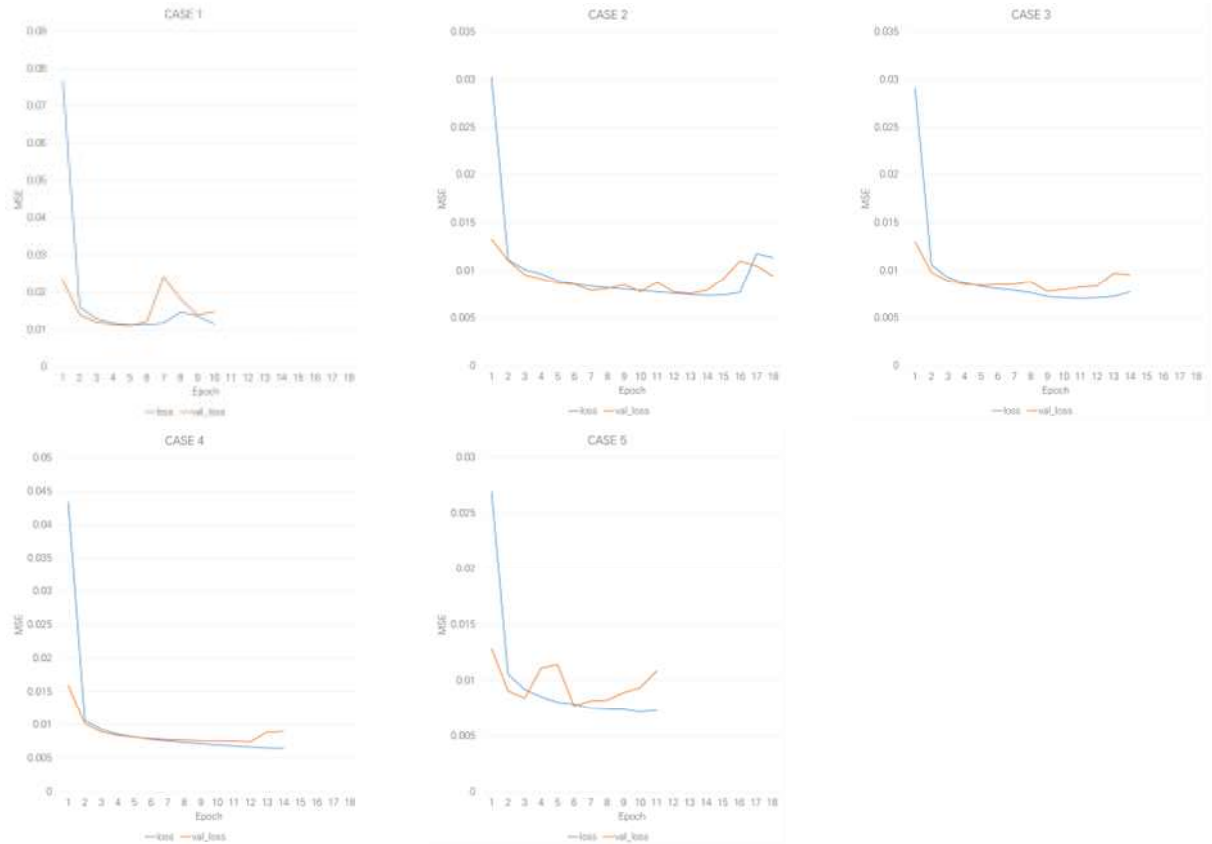


Figure 68. Training results of cases

학습된 모델을 이용하여 2009-2010년 기간의 데이터에 대해 테스트를 진행했으며 예측 결과를 ERA-5 재분석자료와 ACC 분석하였다. 분석은 분석 대상 지역을 전지구(Global)와 동아시아(EastAsia)로 구분하고 연도별, 월별, 계절별로 나누어 분석하였다. 또한 전체 기간에 대해 사례별로 분석하였다.

지역과 연도별 ACC 결과는 연도에 상관없이 사례별 예측력이 비슷한 양상을 보였으며 사례 2와 4가 좋은 결과를 보였다(Figure 69). 지역과 월별 ACC 결과에서는 주로 3월부터 9월까지의 정확도가 다른 월에 비해 낮은 정확도를 보였으며, 사례 4 모델과 5 모델이 좋은 예측결과를 보였다(Figure 70). 지역과 계절별 ACC 결과는 실험에 사용된 5 종류의 모델 모두 계절에 상관없이 모델마다 비슷한 성능을 보였으며, 사례 4 모델이 가장 좋은 예측결과를 보였다(Figure 71). 마지막으로 전체 기간에 대한 사례별 분석에서는 사례 1 모델과 3 모델을 제외한

사례 2, 4, 5 모델의 결과가 비슷한 양상을 보였으나 상대적으로 사례 4 모델이 가장 좋은 예측결과를 보였다(Figure 72). 종합적으로 판단할 때 사례 4 모델의 예측결과가 다른 사례에 비해 연도, 월, 계절 등에 상관없이 좋은 성능을 보였다. 사례 4 모델을 이용하여 현업 관점에서 활용 가능성을 보이기 위해 예측력 평가를 수행하였다. Figure 73은 참조값, 사례별 예측값, 예측값과 참조값의 편차를 지도로 표현한 그림이다. Table 23은 테스트 전체 기간에 대해 예측값과 참조값의 편차에 대한 최댓값, 최솟값, 평균, 표준편차이다. 사례별로 약간의 차이는 있으나 뚜렷하게 차이를 보이는 결과는 나타나지 않았다.




Figure 69. ACC of predictions from case models by region and year




Figure 70. ACC of predictions from case models by region and month

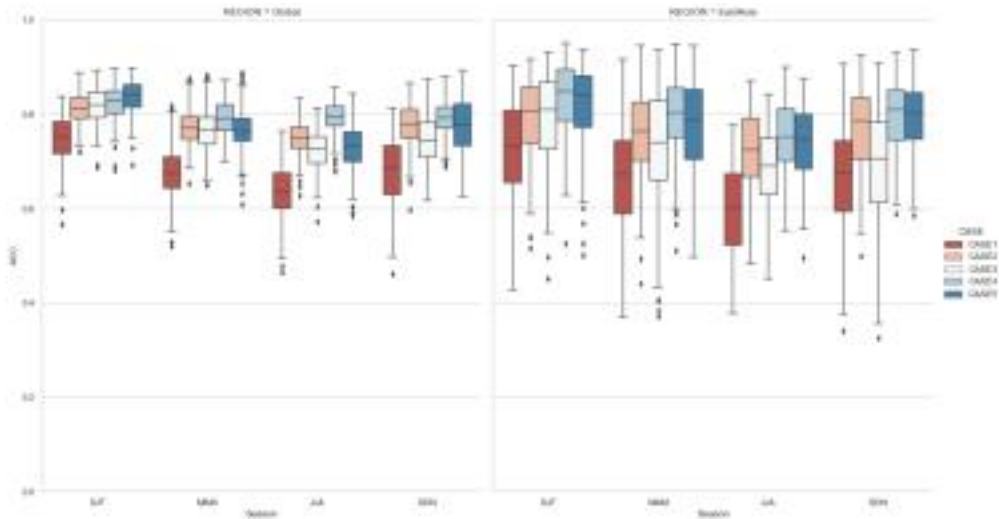


Figure 71. ACC of predictions from case models by region and season




Figure 72. Anomaly correlation coefficients(ACC) of predictions from case models by case

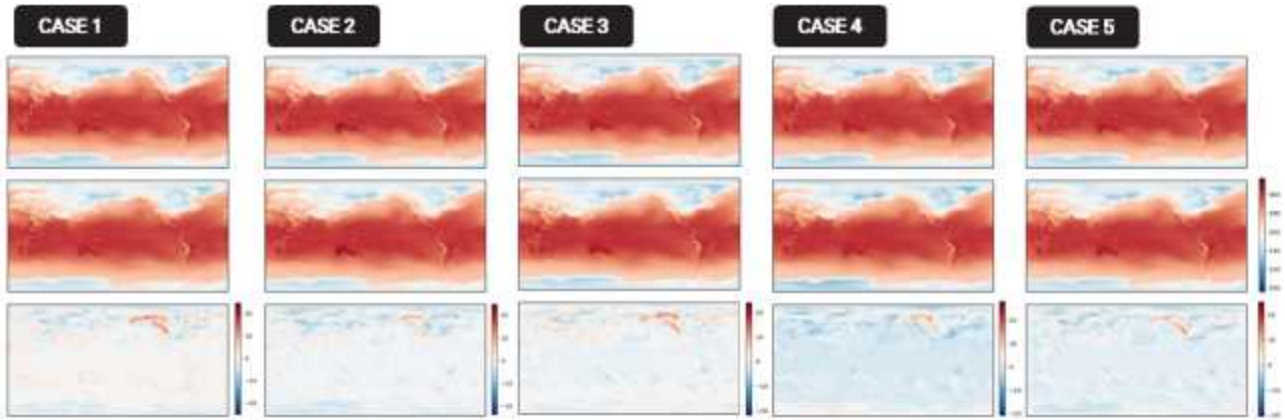


Figure 73. Maps of one prediction result of the cases (first row: ground true, second row: prediction, third row: prediction-ground true)

Table 23. Summaries of basic statistical analysis of the cases

	Case 1	Case 2	Case 3	Case 4	Case 5
Maximum	24.7481	24.7196	23.9463	27.9390	25.1415
Minimum	-25.2562	-23.7951	-22.0204	-20.9774	-20.6895
Average	-0.6036	-0.7434	0.2382	0.3562	-0.0211
Standard deviation	2.5172	1.9712	2.0766	2.2254	2.1996

(나) 현업관점에서의 1개월 전망자료 생산 테스트 및 결과

이전 사례별 실험 결과에서 가장 좋은 예측성을 보인 사례 4를 이용하여 현업관점에서 과거 데이터를 이용하여 1개월 전망자료를 생산하고 예측성을 평가하였다.

본 연구에서 개발된 딥러닝 모델은 과거 14일 자료를 이용하여 미래 1일을 예측하는 구조로 설계되었다. 현업관점에서 1개월 전망예보는 예보 생산일 기준 3-6주차를 수행한다. 본 연구에서 목표로 하는 3-4주차 예측자료 생산은 일 단위 데이터로 학습된 모델로는 28일을 예측해야 한다. 28일을 예측하는 방법은 딥러닝 모델 설계부터 28일을 직접 예측하게 방법과 사례 4와 같이 하루 단위 예측 결과를 반복하여 예측하는 방법이 있다. 본 연구에서는 Figure 74와 같이 반복 예측 방법을 이용하였으며 입력자료는 ECMWF 일단위 예보자료 1-2주 데이터를 이용하였다. 딥러닝 모델의 실제 예측은 ECWFM 일단위 예보자료 1-2주 뒤 인 3-4주차를 수행한다. 반복 예측 방법은 FIFO(Fist In First Out) 방식으로 첫 번째 예측 후 첫 번째 데이터를 삭제하고 예측한 데이터를 추가하여 새로운 입력자료를 생성하여 n번 반복 예측한다.



Figure 74. Example of rolling prediction method for predicting 14 days

현업 관점에서 1개월 전망자료 생산을 위해 사례 4 모델 구조에 1991-2020년 기후자료 (climatology data)를 디코더(decoder) 마지막 레이어의 skip connection의 입력자료로 추가하여 계절성 추세(seasonal trend)를 완화하기 위해 보완하였다(Figure 75).

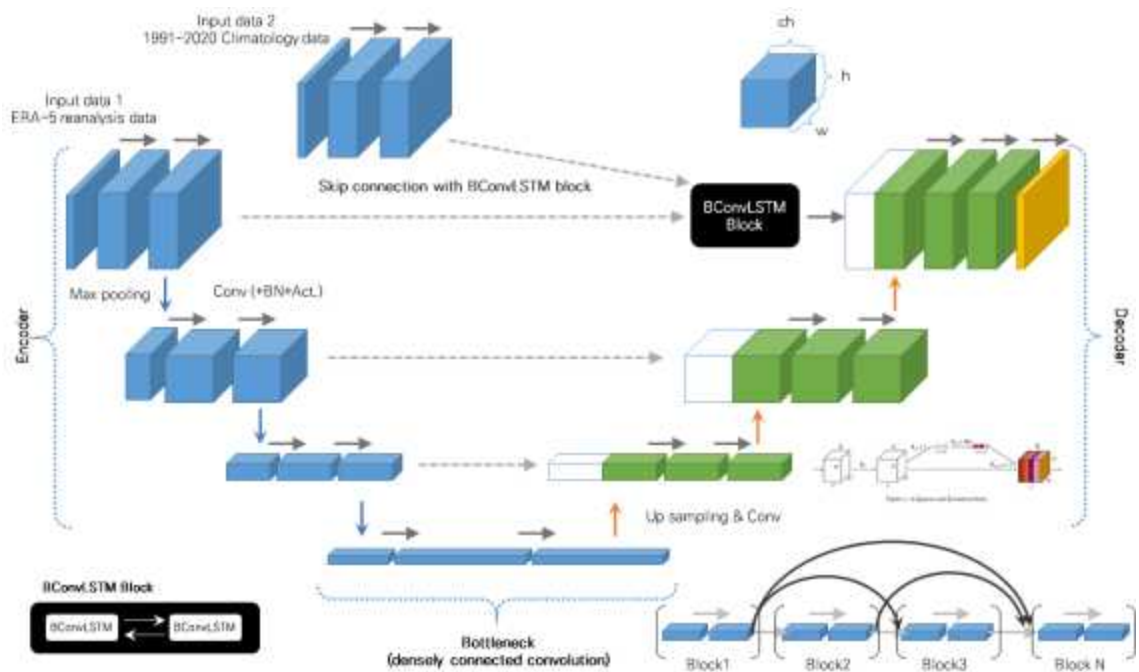


Figure 75. New case 4 model with added climatology data input data as BConvLSTM block input data of the last skip connection in the decoder part

앞서, 동아시아 계절 내 예측을 위한 딥러닝 모델 선정과는 달리 입력자료 2개를 이용하였다(Table 24). 입력자료 1은 ERA-5 T2M 재분석 일단위 자료의 78N~78S, 0~360E 영역을 이용하였고, 학습과 검증에는 2001~2010년 기간 자료를 각 80%, 20% 비율로 사용하였다. 테스트는 2011~2015년 자료를 이용하였다. 입력자료 2는 1991~2020년 총 30년 기간의 ERA-5 재분석자료를 이용하여 기후자료(climatology data)를 구축하고, +/-2일 이동평균, 5×5 영역평균 등의 데이터 필터링 기법을 적용하여 데이터 평활화(smoothing) 작업을 하였다. 그리고 현업 관점에서 활용도를 평가하기 위해 2016~2020년 ECMWF 월요일 예보자료를 이용하여 ECMWF 예보자료와 평가하였다. ECMWF 예보자료는 CF(control file) 1개, PF(Perturbed forecast) 50개 등 총 51개의 앙상블 멤버를 가지고 있다. 본 연구에서는 ECWMF 앙상블 멤버 51 개 중 CF 1개를 이용하였다.

Table 24. Input data summaries for training, validation, and test dataset

Input Data	Name	Content
1	Dataset	ERA-5 reanalysis daily data
	Variable Name	T2M
	Data Area	78N~78S, 0~360E
	Training and validation period	2001 - 2010
	Test data period	2011 - 2015
2	Dataset	ERA-5 T2M climatology data
	Data period	1991-2020
	Data filtering	+/-2 days, moving average, 5 x 5 area mean

2016~2020년 기간의 매 월요일에 생산된 ECMWF 예보자료의 T2M 변수를 이용하여 딥러닝 모델의 예측자료와 ECMWF 예보자료 간 ACC 편차를 계산하고 평균한 결과를 정리하였다(Table 25). 결과에서 양의 값을 가지면 딥러닝 모델의 예측결과가 좋은 것을 의미하며 반대로 음의 값을 가지면 ECMWF 예보자료의 예측결과가 더 좋은 것을 의미한다. 두 결과의 편차이기 때문에 양의 값을 가진다고 해서 ACC 예측값이 양의 값을 가진다는 의미는 아니다. 그러므로 양의 값은 두 비교 대상 결과에서 상대적으로 좋은 성능을 보인다는 의미이다.

예보 1주차(F1, W+3)의 DJF, JJA, MMA, SON 계절별 편차 평균은 각 -0.02594, -0.00666, -0.03622, 0.0197, 예보 2주차(F2, W+4)는 각 -0.13076, 0.00284, -0.07582, -0.00356이었으며 예보 1, 2주차 전체 평균은 각 -0.07359, -0.00234, -0.05422, 0.009127를 보였다. 실험결과 전체 기간에 대한 예측성은 ECWMF 예보자료에 비해 다소 낮지만, 계절을 고려한 평가에서는 SON 시즌은 ECWMF 예보자료에 비해 예보 1주차는 2016~2020년 모든 기간에서 좋은 성능을 보였다.

Figure 76과 77은 3, 4주의 딥러닝 모델의 예측자료와 ECMWF 예보자료 간 DJF(December, January, February), MAM(March, April, May), SON(September, October, November) 계절별 ACC 편차를 상자 수염 그림(boxplot)으로 표현한 그림이다. 예보 1주차(F1)는 계절에 따라 큰 편차 없이 예측성을 보인 반면, 예보 2주차(F2)는 두 기법 간의 예측성의 변동성이 매우 큰 것으로 나타났다.

예보 1주차를 기준으로 ECMWF 예보자료에 대비 딥러닝 기법의 예측성이 높은 상위 5위는 2020년 09월 28일, 2019년 08월 26일, 2017년 10월 2일, 2017년 4월 10일 2020년 03월 02일 순이었다(Appendix A).

Table 25. Summaries of comparison between deep learning and ECMWF prediction ACC based on ECMWF T2M forecast data every Month of 2016-2020

Forecast week	Year	DJF	JJA	MMA	SON
W+3 (F1)	2016	0.0609	-0.0128	-0.0268	0.0201
	2017	-0.1205	0.0219	-0.1013	0.0228
	2018	0.0681	-0.0057	-0.0539	0.0005
	2019	-0.0353	-0.0280	-0.0448	0.0001
	2020	-0.1029	-0.0087	0.0457	0.0550
Average		-0.0260	-0.0067	-0.0362	0.0197
W+4 (F2)	2016	-0.0884	-0.0672	-0.0338	0.0040
	2017	-0.1317	0.0992	0.0053	-0.0002
	2018	-0.0619	-0.0121	-0.0904	-0.0567
	2019	-0.2045	0.0306	-0.0801	0.0553
	2020	-0.1674	-0.0363	-0.1801	-0.0202
Average		-0.1308	0.0028	-0.0758	-0.0036

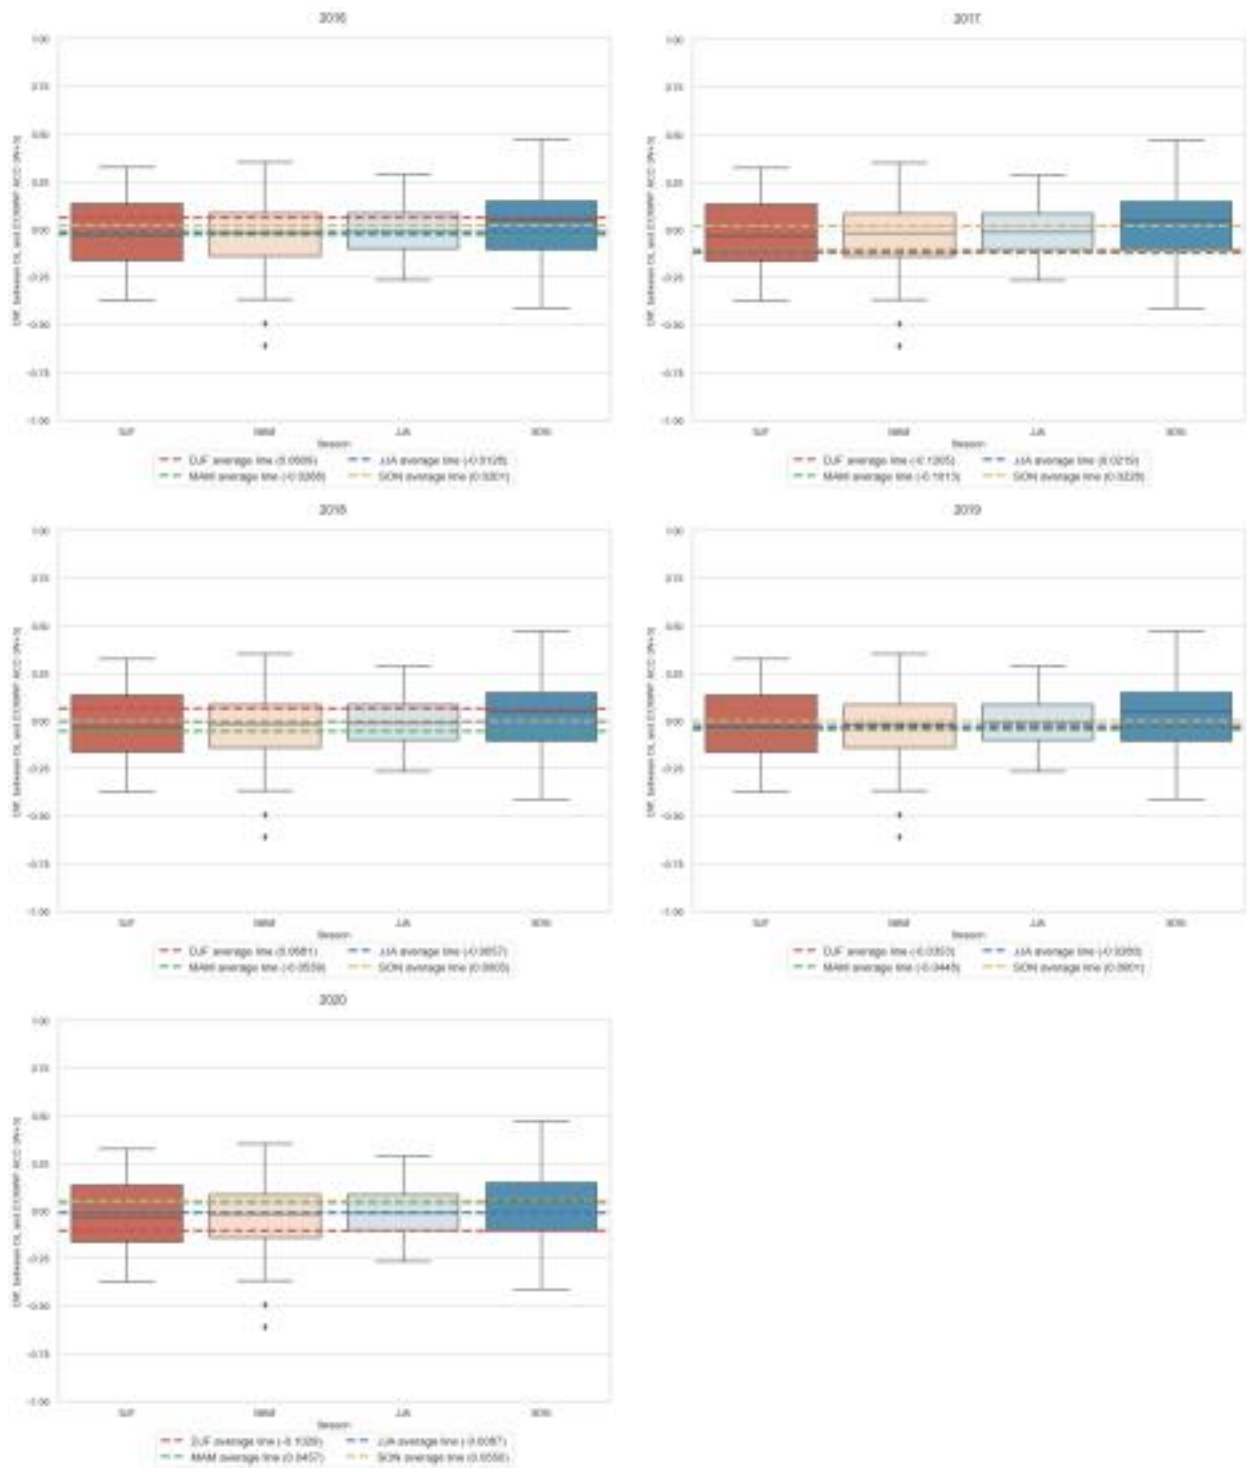


Figure 76. Boxplotting comparison results between deep learning and ECMWF prediction F1(W+3) ACC based on ECMWF T2M forecast data every Month of 2016–2020 (red dashed line: DJF, blue dashed line: JJA, green dashed line: MAM, yellow dashed line: SON)

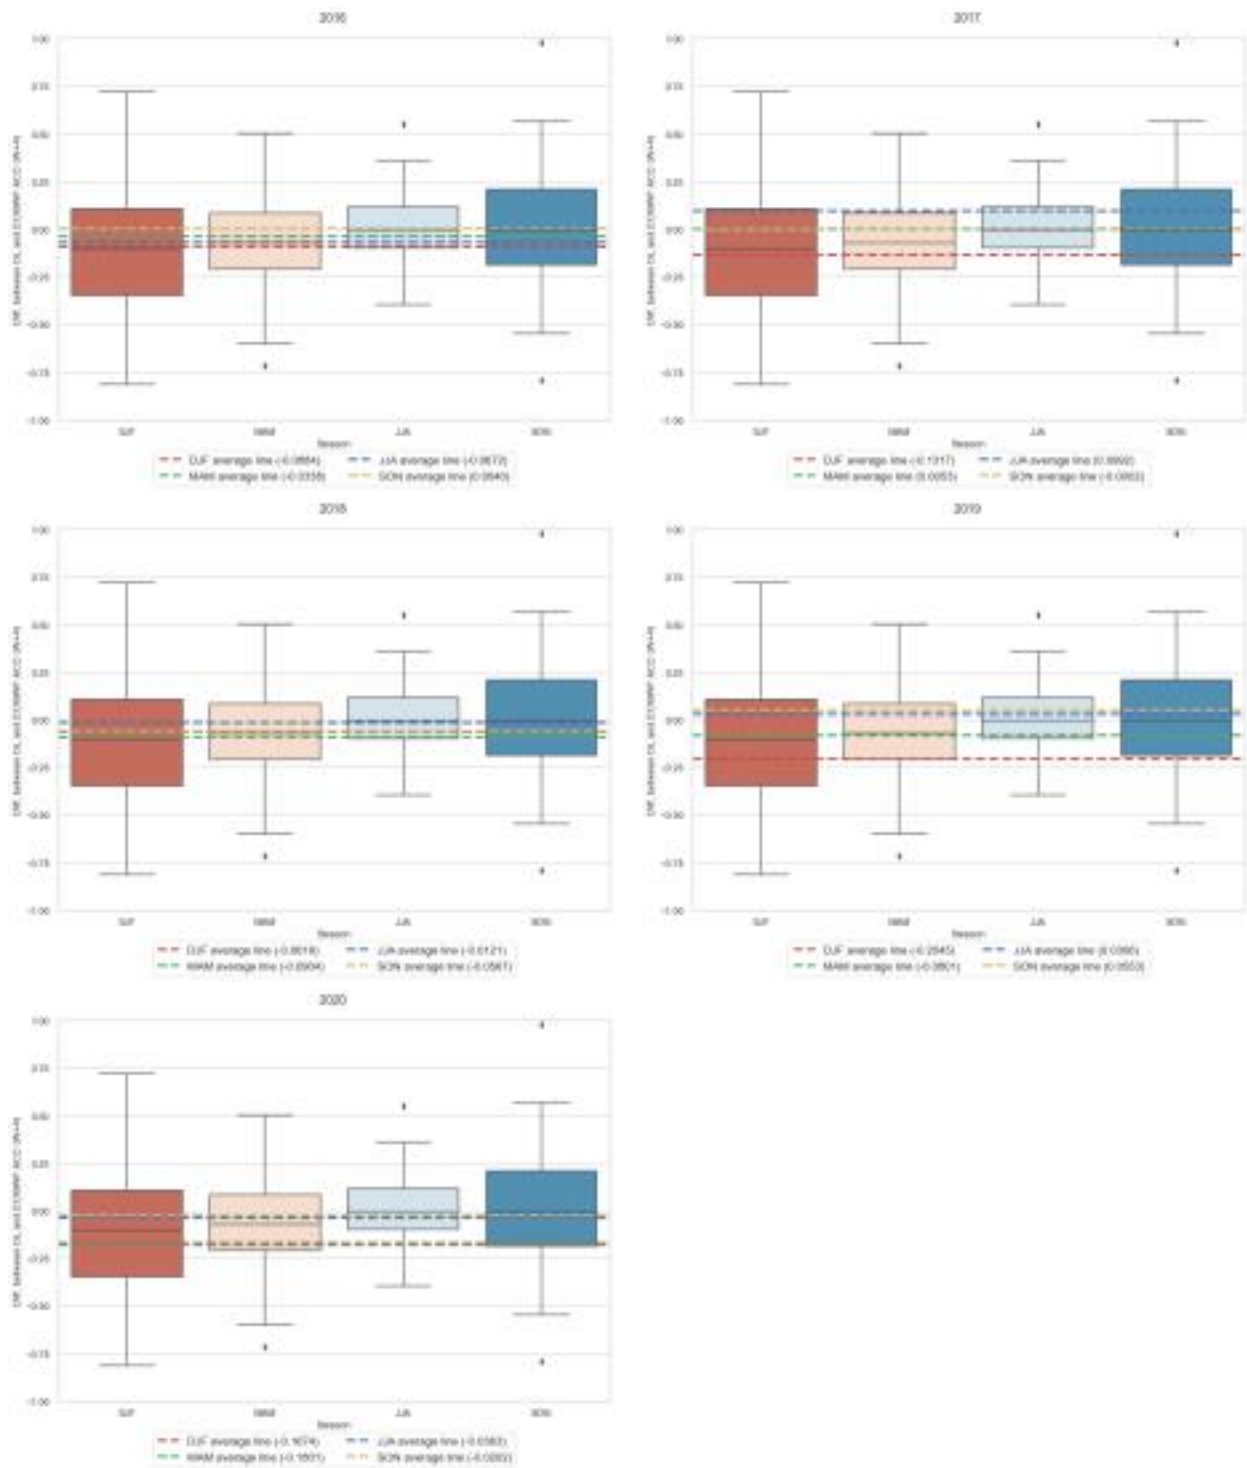


Figure 77. Boxplotting comparison results between deep learning and ECMWF prediction F2(W+4) ACC based on ECMWF T2M forecast data every Month of 2016–2020 (red dashed line: DJF, blue dashed line: JJA, green dashed line: MAM, yellow dashed line: SON)

나. 장기에보 모델정보 개선 및 적용

(1) 현업모델 편차보정을 통한 1개월 기온예보 콘텐츠 개발

(가) 국내의 유관기관 계절내 장기에보 현황

① 미국 NOAA-NCEP CPC

미국 기상청(National Weather Service, NWS)의 공식예보 체계는 0~48시간, 3~7일, 6~10일, 8~14일, 월별예보, 그리고 계절예보로 이루어져 있다. 또한 NCEP 산하의 기후예측센터(Climatic Prediction Center, CPC)는 6~10일, 8~14일, 월별예보, 계절예보를 생산하고 있다. 특히 1개월(30일) 계절내 예보를 위해서는 미국 전역의 월평균 기온과 강수에 대한 예보를 생산하고 있는데, 기온과 강수에 대한 3분위 확률정보를 제공한다(<https://cpc.ncep.noaa.gov/products/predictions/30day/>). 미국 CPC에서는 1개월 예보와 더불어 3-4주 선행한 기온과 강수에 대해서도 예측정보를 제공한다. 3-4주 예보에 대해서는 2분위 예보를 하고 있는데, 평년보다 높거나 낮을 확률이 50%로 같을 때, equal-chance로 예보한다. 특히, 기후예측에서 3-4주 예보는 예측성이 가장 낮은 기간으로 3-4주를 포함한 계절내 예측 정확도를 높이기 위한 많은 연구가 이루어지고 있다.

계절내 예측의 경우, 계절내진동(Madden-Julian Oscillation, MJO)의 활동 및 예측이 중요하다. 따라서 CPC에서는 이와 관련한 예측정보도 함께 제공하고 있다(<https://cpc.ncep.noaa.gov/products/precip/CWlink/MJO/foregfs.shtml>). MJO는 지구 장파 복사량(Outgoing Longwave Radiation, OLR)과 800hPa 및 200hPa 고도의 열대지역 바람장을 사용하여 계산한 RMM(Real-time Multivariate MJO) 지수(Wheeler and Hendon, 2004)를 통해 정의된 MJO 지수를 기반으로 예측한다. CPC에서는 앙상블 GFS 모델결과에서 예측된 RMM 지수 기반으로 +14일까지의 MJO 예측정보를 제공하고 있다. MJO에 따른 열대대류 활동의 변화의 변화는 세계 여러 곳의 기후와 밀접한 연관이 있어, 이와 관련한 많은 연구가 진행되어 왔다. 특히, 열대 대류 활동과 관련된 육지 강수에 영향을 미칠 뿐 아니라, 아시아, 호주 및 아프리카 몬순에도 영향을 미친다. 또한, 열대 저기압 활동이나 중규모 대류시스템과도 영향이 있으며, ENSO의 변동성에도 영향을 미치는 것으로 알려져 있다(Camargo et al. 2009, Chand and Walsh, 2010, Hall et al., 2001, Wheeler et al., 2009, Taraphdar et al. 2018, Li et al. 2017).

② 호주 BoM

호주 기상청은 ~36시간(단기), ~4일(중기)예보와 함께, 최고·최저기온, 강수량에 대해 주별(1주 및 2주 평균), 월별(1개월 평균), 계절별(3개월 평균) 동안의 2분위 확률 예보를 제공하고 있다. 최고·최저기온의 2분위 확률예보를 위해서는 과거 30년간의 중앙값(median)을 넘어설 확률에 대한 예측 정보를 제공하고, 강수량에 대해서는 특정 강수량 이상일 확률(예, 최소 10mm, 50mm, 100mm등)일 확률과 함께 과거 30년간의 강수량 중앙값을 넘어설 확률이 75%, 50%, 25%일때의 확률정보 등을 제공한다. 주별 예보는 1주일에 두 번, 월별, 계절별 예보

의 경우 주별로 예보자료를 제공한다(www.bom.gov.au/climate/outlooks). 예보 자료를 생산하기 위해서 영국기상청 UKMO 모델을 기반으로 자체개발한 ACCESS-S 모델을 사용하고 있다. 기후 관련 정보로는 호주 지역 기후에 가장 중요한 역할을 하는 태평양과 인도양의 해수면 온도를 포함한 엘니뇨/라니냐, 열대 모니터링으로 MJO, 열대 저기압을 제공하는 한편, Southern Annular Mode(SAM), 인도양의 다이폴 지수(Indian Ocean Dipole; IOD) 지수 등을 예측하고 있다.

③ 일본 TCC 및 JMA

일본 기후센터에서는 최고·최저기온에 대한 예보는 별도로 제공하지 않으나, 기온 및 강수, 대기 순환장 변수들에 대해 선행시간 1주(3~6일 평균), 2주(10~16일 평균), 3-4주(17~30일 평균), 1개월(3~30일 평균)장에 대한 예보를 제공하고 있다(<http://ds.data.jma.go.jp/tcc/tcc/>). 대기 순환장 변수로는 북반구에 대해서 500hPa 지위고도, 850hPa 온도, 해면기압(SLP)등을 제공하고, 북위 60도~남위 60도 및 아시아 지역에 대해서는 stream function, velocity potential, 강수, 지표기온 등을 제공하고 있다. 이러한 1개월 예측자료를 생산하기 위해서 전구 앙상블 예측 시스템(ESP)을 기반으로 하고 있는데, 대기모델(AGCM)은 JMA-GSM을 기반으로 하며, 18일 이전까지는 TL479, 18일 이후에는 TL319 모델을 사용한다.

일본 기상청(Japan Meteorological Agency; JMA)에서도 일본지역 평균기온, 강수량에 대해 일 단위, 1~2주 단위의 계절내 전망을 제공하고 있으며, 이와 더불어 1개월 전망, 3개월 전망, 이상기후 조기경보를 제공하고 있다. 특히, 1개월 및 3개월 기온, 강수, 일조량, 강설량 전망에 대해 3분위 확률예보를 제공하고 있으며, 각 지역별 확률도 제공하고 있다(<http://www.jma.go.jp/en/longfcst/>). 기온에 대해서는 평년보다 낮거나 비슷하거나, 높을 것으로 예상되는 확률값을 제공하고 있으며, 3분위 중 확률이 40% 이상인 범주를 강조해서 나타낸다. 또한, 선행시간 8일의 2주(5일 평균) 평균 기온에 대해 예측정보를 제공할 때, 기후값의 33%를 기준으로 5개의 카테고리에 대해 매우 높음, 높음, 평년 비슷, 낮음, 매우 낮음의 각 카테고리에 대해 확률정보를 제공하고 있다. 특히, 매우 높음과 매우 낮음의 경우 기후값의 10%에 해당하는 값에 대한 확률정보를 나타낸다(<http://www.data.jma.go.jp/gmd/cpd/twoweek/en/>).

④ 영국 U.K. Met Office

영국 기상청에서는 ~5일의 단기예보, 6~15일의 중기예보, 10~30일의 장기예보를 제공하고 있다. 단기예보의 경우, Met Office Global and Regional Ensemble Prediction System(MOGREPS)을 사용하고, 중기 이상의 예보는 Global Sasonal forecast system version 5(GloSea5)을 사용하여 생산한다. 6~15일 예측에는 폭우, 강풍, 고온 및 저온과 같은 이상기상 현상에 대한 위험평가를 포함하고 있고, 이때 영국 기상청 모델뿐 아니라 유럽중기기상예보센터(ECMWF)의 모델 결과 등도 함께 고려한다. 또한, 2~4개월, 3~5개월, 4~6개월의 기간에 대해 2m 기온, 500hPa 지위고도, 850hPa 기온, 전 세계 강수량, 기압, 해수면 온도 예측 결과등도 함께 제공한다. 전지구 2~4개월 2미터 온도에 대한 3분위, 5분위, 2분위 확률예보뿐 아니

라, 열대, 아시아, 북미, 남미 및 유럽 등 각 지역별 3분위 확률, 5분위 확률, 2분위 확률(중앙값 이상)에 대한 예보 결과도 함께 제공하고 있다 (<http://metoffice.gov.uk/research/climate/seasonal-to-decadal/gpc-outlooks/glob-seas-prob/>).

⑤ 한국 KMA

한국 기상청에서 제공하는 1개월 전망은 주별 기압계 동향 및 전망, 기온, 강수량등을 포함한 예측정보를 제공한다. 이러한 1개월 전망은 매주 목요일에 발표되며, 발표일로부터 3~6주간 주별 기온 및 강수에 대한 3분위 확률분포 정보를 제공한다. 확률예측값과 더불어 주별 날씨 전망, 주/지역별 평균기온 및 강수량 확률 전망을 제공한다. 또한, 3주에 대한 이상저온 및 이상고온 전망정보를 함께 제공한다. 이상기후는 기온, 강수량 등의 기후요소가 평년(1991~2020년)에 비해 현저히 높거나 낮은 수치를 나타내는 극한현상으로 이상저온은 최저·최고기온 90퍼센타일 초과범위로 정의한다. 퍼센타일은 평년 동일 기간의 기온을 비교하여 낮은 순서대로 몇 번째인지 나타내는 백분위수로 이상기후를 정의하는데 사용한다. 또한, 주간 이상기후 전망정보는 주평균 최저기온과 최고기온의 이상저온·이상고온에 대한 발생가능성(확률) 전망을 나타내고, 발생가능성 백분율이 30% 이상과 미만일 경우 각각 발생가능성을 “높음”과 “낮음”으로 제공한다. 이와 더불어 기상가뭄 현황 및 전망 정보를 함께 제공한다.

(나) 편차보정의 필요성

Figure 78은 2020년 9월 7일부터 2021년 6월 21일까지의 기상청 현업모델 예측값과 관측값의 최고, 최저, 평균기온에 대한 아노말리를 나타낸다. 전반적으로 현업모델에서는 warm 아노말리가 뚜렷하다. 관측에서도 warm 아노말리가 뚜렷하지만, 현업모델에 비해서는 아노말리가 작게 나타난다. 또한 현업모델의 아노말리는 관측의 주별 평년범위와 비슷하거나 높게 나타나므로 모델은 일관되게 평년과 비슷(near normal)하거나 높음(above normal)으로 예측하게 된다. 이는 현업 예측모델에서 나타나는 예측 아노말리의 계통적 오차이므로, 이러한 오차를 보정하여 예측을 개선할 필요가 있다.

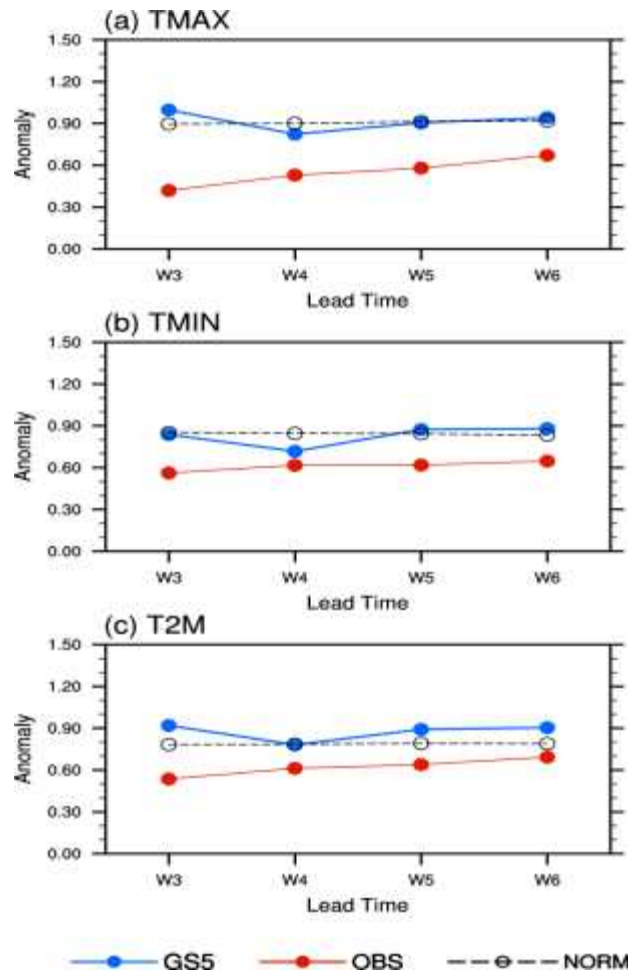


Figure 78. Time-series of GloSea5(blue) and observation(red) anomalies for (a) maximum, (b) minimum, and (c) 2-m temperature for each week from week1 to week4. The black dashed line indicates upper limit of observed normal range.

편차보정을 통해 최고, 최저, 평균기온 값을 얻게 될 경우, 기후예측모델값을 입력자료로 하는 영향모델등의 예측성 향상 등에 기여할 수 있으며, 절대값 기준의 기후지수등을 계산하는데 있어서도 활용할 수 있을 것이다. 한편, 계절내 예측모델의 편차보정을 할 때 여러 제약조건을 고려할 필요가 있다. 기후예측모델의 경우 주어진 초기장으로부터 적분시간(lead time)에 따라 오차가 표류(drift)하기 때문에, 편차보정시에는 적분시간(lead time)에 따른 오차를 고려하여 보정하여야 한다. 또한, 기후예측모델의 오차는 계절에 따라 크게 나타나는 계절성을 가지고 있으므로, 계절내 예측의 경우 적절한 time-window를 고려하여 이러한 계절적 차이를 최소화한 오차보정이 이루어져야 한다. Monhart et al. (2018)등은 유럽지역의 기온과 강수에 대한 계절내 예측성을 비교 평가하는 데 있어 지표 관측값을 사용한 오차보정과 규모축소

(downscaling)의 효과를 보인 바 있다. Orth and Seneviratne (2013)과 Bogner et al. (2018)은 수문 모델의 입력자료로 기후예측모델의 계절내 예측자료의 활용성을 보인 바 있으며, 이러한 많은 응용모델에서는 보다 나은 입력정보로서의 기후예측모델 정보의 중요성을 강조하고 있다.

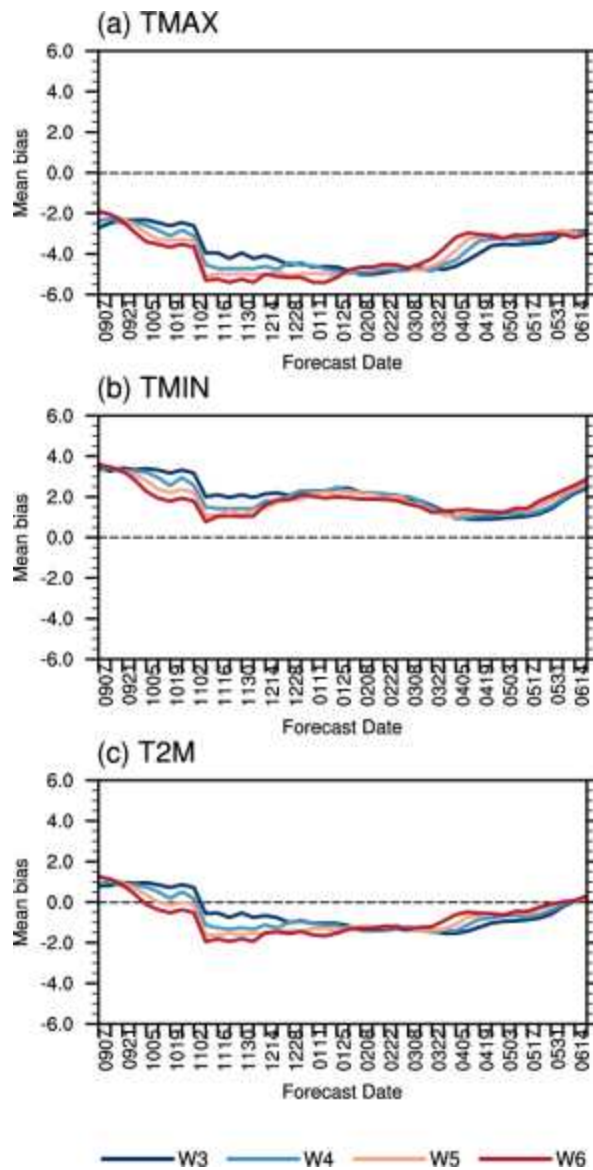


Figure 79. Bias climatology from GloSea5 for (a) maximum, (b) minimum and (c) 2-m temperature for each week from week1 to week4.

2020년 9월 7일부터 2021년 6월 21일까지의 기상청 현업모델의 최고, 최저, 평균기온에 대한 오차기후값(bias climatology)를 살펴보았다(Figure 79). 그림에서와 같이 11월 초에 오차가 급격히 변화하였는데, 이는 지면초기화의 변경으로 인한 결과로 판단된다. 이때부터 지면초기

화 간소화과정이 현업에 적용되었는데, 간소화 전에는 많은 토양수분으로 인해 일교차가 작아져 유라시아 대륙의 양의 오차를 발생시키는 경향이 있었다. 반면 간소화 후에는 토양 수분이 작아져 일교차가 커지고 때문에 양의 bias가 감소하는 경향으로 나타났다. 이러한 지면초기화 영향으로 인해 한반도 영역에 대해 최고기온은 음의 bias가 커지고, 최저기온의 양의 bias가 줄어들었다. 또한, 평균기온에서는 양의 bias가 다시 음의 bias로 나타났다.

(다) 검증 결과

① 정량적 검증: Bias 및 RMSE 비교

Figure 80은 2장 방법에서 설명한 3가지의 다른 편차보정 방법에 따른 기온값에 대한 오차를 나타낸 것이다. 최고기온의 경우 GloSea5 raw 예측의 경우 음의 bias가 뚜렷하다. 반면, 오차보정을 거친 최고기온의 경우 전반적으로 오차가 0에 가까워져 음의 bias가 보정됨을 알 수 있다. 최저기온의 경우 GloSea5 raw 예측은 양의 bias가 뚜렷하고, 오차 보정 후 이러한 양의 bias가 보정되었다. 평균기온은 최고, 최저기온에 비하면 GloSea5 raw 예측 오차가 크지 않았으며, 미미한 음의 bias를 나타낸다. 역시 오차보정 후에는 이러한 음의 bias가 보정됨을 알 수 있다. 요약하자면, 오차보정 전의 GloSea5 raw와 비교하면 오차 보정 후 오차가 보정됨을 알 수 있으며, bias 측면에서는 오차보정 방법론에 따른 차이가 크지 않음을 알 수 있다. 요약하자면, 오차보정 전 최고기온의 bias는 최저기온 및 평균기온의 bias 보다 크게 나타났는데, 오차보정의 효과도 최고기온이 가장 크고, 최저기온과 평균기온은 비슷하게 나타났다. 그리고 편차보정 후 변수와 관계없이 bias는 0에 가깝게 나타났으므로, 편차보정의 효과를 뚜렷이 알 수 있었다. 또한, lead-time에 따른 차이도 크지 않아, 편차보정의 효과가 lead-time에 관계없이 유지되는 것으로 나타났다.

Bias와 함께 평균제곱근오차(RMSE) 측면에서도 검증하였다(Figure 81). RMSE의 경우도 bias와 마찬가지로 최고기온의 편차보정 전 절대값(MABE) 오차가 크게 나타났고, 평균기온과 최저기온의 절대값 오차는 비슷한 수준으로 나타났다. 전체 예측기간에 대한 평균제곱근오차 또한, 최고기온이 가장 크고, 최저기온 및 평균기온은 비슷했다. Bias와 마찬가지로 lead-time에 따른 RMSE 감소율 차이는 크지 않은 것으로 나타났으므로 본 연구에서 제시한 편차보정 방법으로 주별 1개월 예보가 개선됨을 알 수 있다. 각 편차방법에 따른 RMSE의 변화율을 비교하였는데, 다른 편차방법과 비교해 EQM 편차보정 후 RMSE 감소율이 가장 크게 나타났다(Table 2 6). 기후예측모델의 경우 overconfident(=underspread) 경향이 뚜렷한데, 편차보정 후 RMSE의 감소로 인해 이러한 경향이 다소 감소하는 것을 알 수 있다.

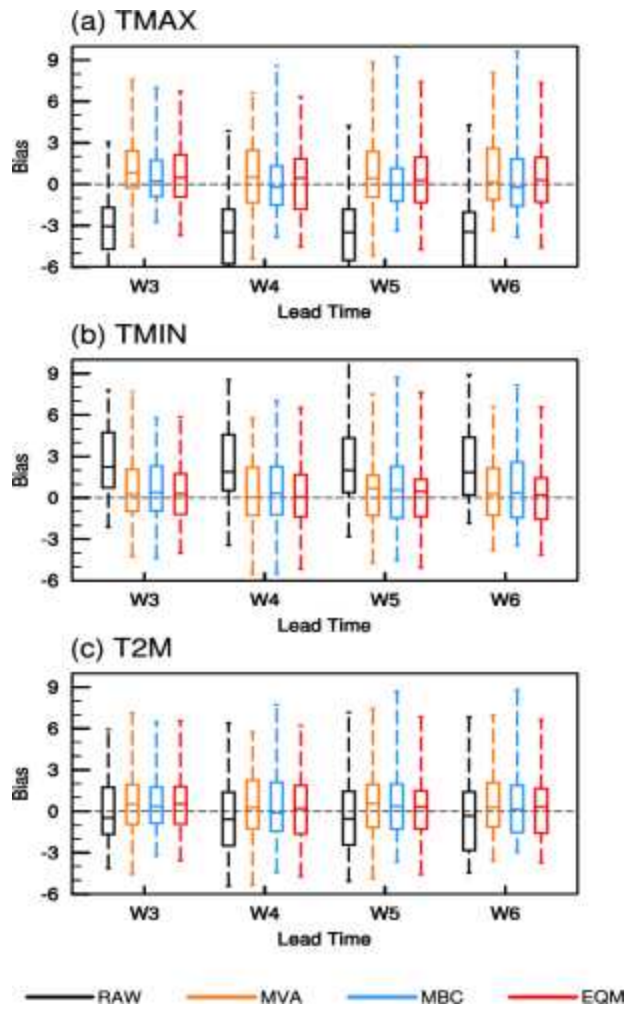


Figure 80. Box-plot of bias after bias correction for the (a) maximum, (b) minimum and (c) mean temperature or each week from week1 to week4. Black, orange, blue and red box indicate raw, MVA, MBC and EQM bias correction method.

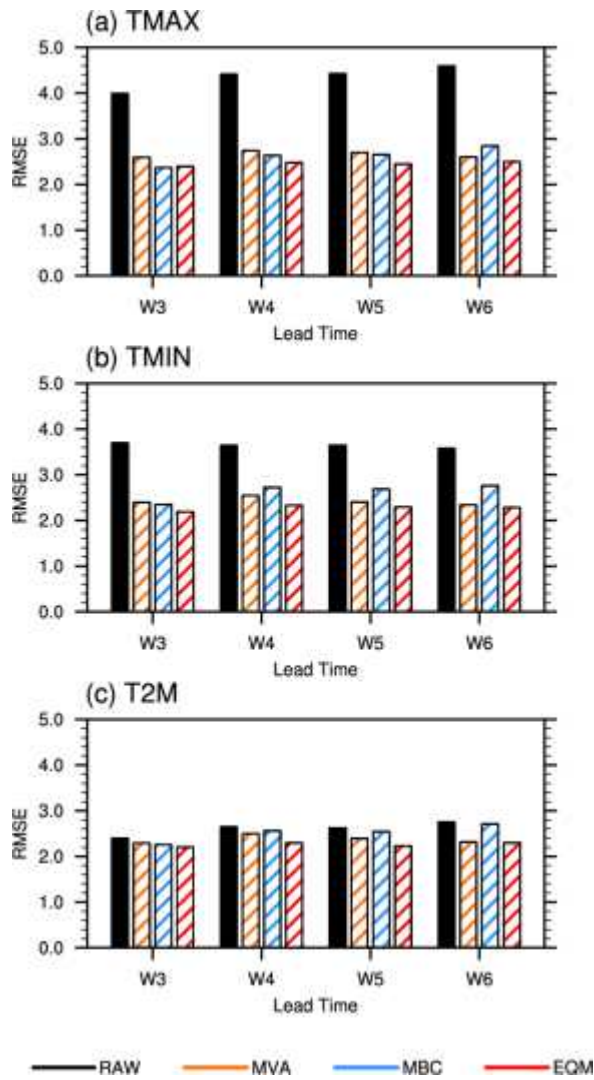


Figure 81. Comparison of RMSE after bias correction for the (a) maximum, (b) minimum and (c) mean temperature or each week from week1 to week4. Black, orange, blue and red box indicate raw, MVA, MBC and EQM bias correction method.

Table 26 Change of RMSE. The change rate is defined as the difference of RMSE from raw GloSea5 and each bias correction method. The difference is divided by the RMSE from raw GloSea5

TMAX				
	W3	W4	W5	W6
MVA	-35.1	-37.9	-39.0	-43.4
MBC	-40.8	-40.4	-40.1	-38.0
EQM	-40.1	-43.9	-44.8	-45.7
TMIN				
	W3	W4	W5	W6
MVA	-35.2	-30.1	-34.0	-34.7
MBC	-36.4	-25.2	-26.3	-22.9
EQM	-40.9	-36.0	-37.1	-36.3
T2M				
	W3	W4	W5	W6
MVA	-4.4	-5.7	-8.7	-16.1
MBC	-6.0	-3.4	-3.0	-1.6
EQM	-8.3	-13.3	-15.0	-16.6

② 정량적 검증: Categorical 예측 정확도(accuracy) 비교

앞서 정량적 검증 결과, 우리나라 최고, 최저, 평균기온에 대해 편차보정한 후 예측성이 향상됨을 알 수 있었다. 실제 예측에 있어서는 범주 예보를 하게 되므로, 이에 대한 예측성 또한 비교평가하였다. 앞서 방법론에서 설명한 바와 같이 관측값의 평년범위는 1991~2020년의 $\pm 0.43\sigma$ 범위로 정의하며, 모델의 아노말리가 평년범위의 어느 범주에 해당하는지로 예보를 한다(Figure 82). 본 연구의 예측기간동안에는 above normal이 대부분이었으며, 모델 결과 또한 above normal이 우세하게 나타났다. 때때로 나타나는 below normal의 경우, raw GloSea5 결과 뿐 아니라 편차보정 방법 결과에서도 잘 모의하지 못하는 것으로 나타났다. Figure 83은 contingency table에서 관측과 일치하는 범주를 예보한 경우의 수를 비율로 나타낸 결과이다. 값이 높을수록 범주예보의 정확도가 높은 것으로 해석할 수 있다. 전반적으로 3주-4주에 있어 편차보정 후, 예측성이 높아졌음을 알 수 있다. 또한, 예측 변수별 혹은 lead-time 별로 일정하게 뛰어난 예측성을 보이는 편차보정 방법은 없는 것으로 나타났다. 즉, lead-time 별로, 예측 변수별로 좋은 예측성을 보이는 편차보정 방법은 다르게 나타났다. 편차보정 전보다는 편차보정 후 예측성이 높아지는 것은 자명하지만, 변수별, lead-time 별로 예측성이 좋은 편차보정 방법은 다르게 나타났으므로, 실제 예보시에는 이를 고려할 필요가 있다.

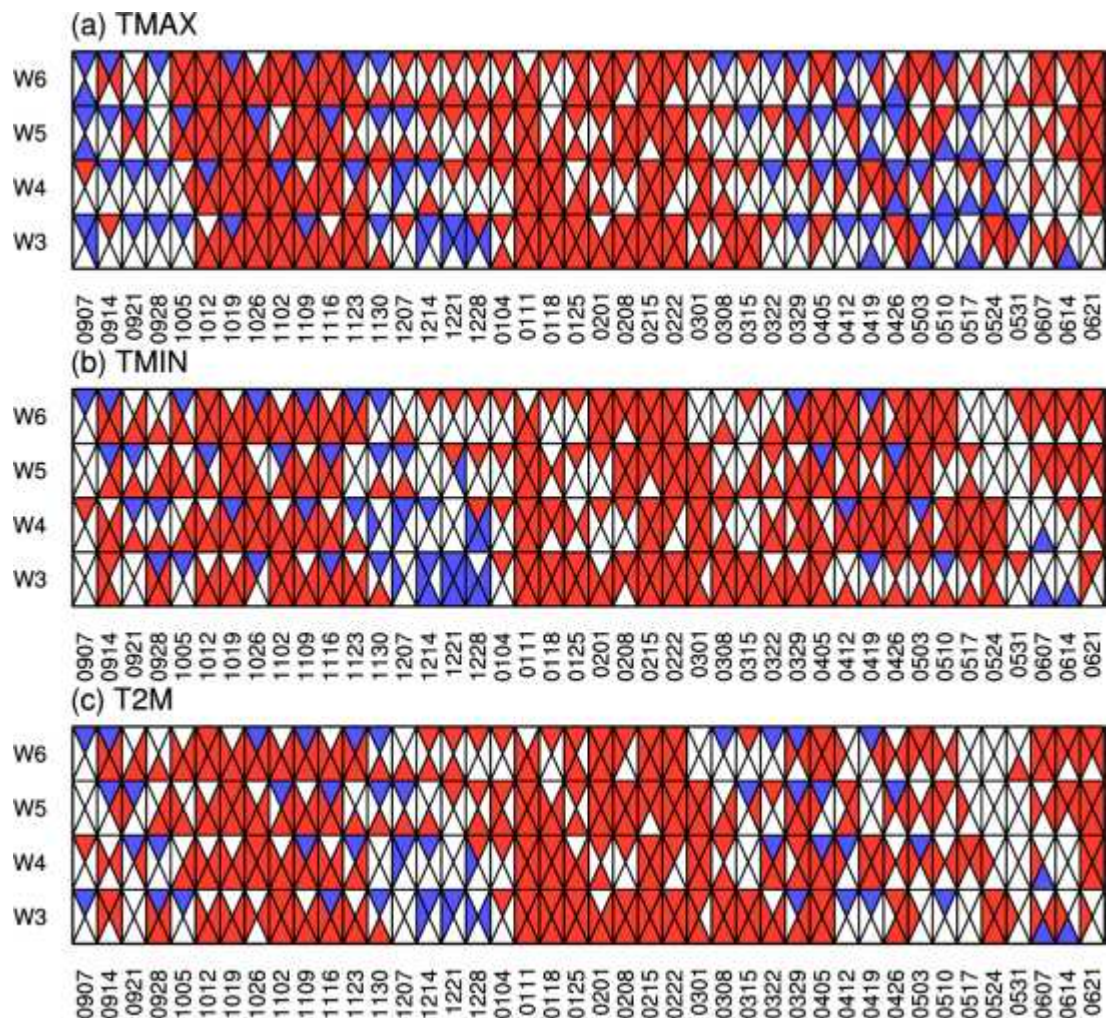


Figure 82. Categorical temperature forecasts from raw GloSea(left triangle), MBC(bottom triangle), EQM(right triangle) and observation(top triangle). Blue, white and red indicate below-, near- and above-normal values with respect to observed normal range.

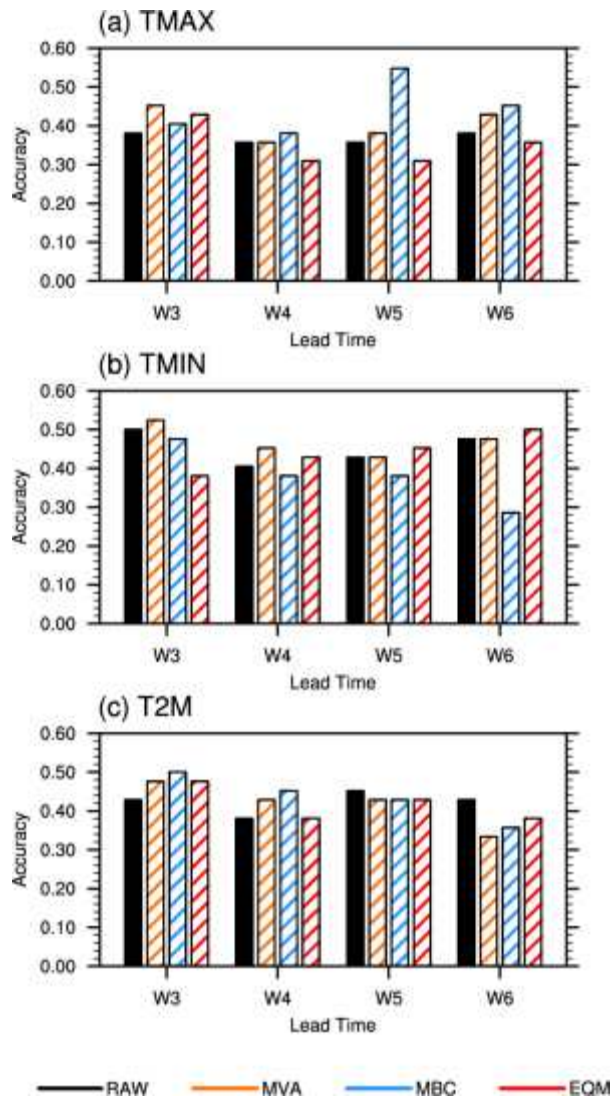


Figure 83. Comparison of accuracy in contingency table after bias correction for the (a) maximum, (b) minimum and (c) mean temperature or each week from week1 to week4. Black, orange, blue and red box indicate raw, MVA, MBC and EQM bias correction method.

(라) 예보활용 방안

① 시계열 예보

앞서 편차보정 전보다 편차보정 후 예측성이 향상됨을 알 수 있었다. 다만, lead-time별로, 예측변수별로 예측성이 좋은 편차보정 방법은 다르게 나타남을 알 수 있었다. 따라서 편차보정 결과를 예측에 활용할 수 있는 방법에 대한 고민이 필요하다. 본 연구에서는 계절내 온도 예측

을 개선하기 위해서 편차보정 결과를 사용하되, 편차보정 결과를 모두 다 고려하는 방안을 제시하고자 한다. 아래 Figure 84는 편차보정 방법에 따른 최고, 최저, 평균기온에 대한 예측 예시이다. 그림에서와 같이 편차보정 방법에 따라 온도 예측 범주가 매우 다르게 나타남을 알 수 있다. Figure 82에서와 같이 편차보정 방법에 따라 매우 다양한 결과를 보이기 때문에 이를 고려한 예측이 필요함을 다시 한 번 알 수 있다. Figure 84 사례에서는 raw GloSea5의 경우 관측의 평년범위 보다 높은 above normal을 예측한 반면, 편차보정 방법에 따라 above normal 또는 near normal 의 예측을 나타냄을 알 수 있다. 이러한 결과를 통해 현업 예보에 활용할 때, 다양한 편차보정 방법에 따른 온도 분포를 활용 할 수 있을 것이다.

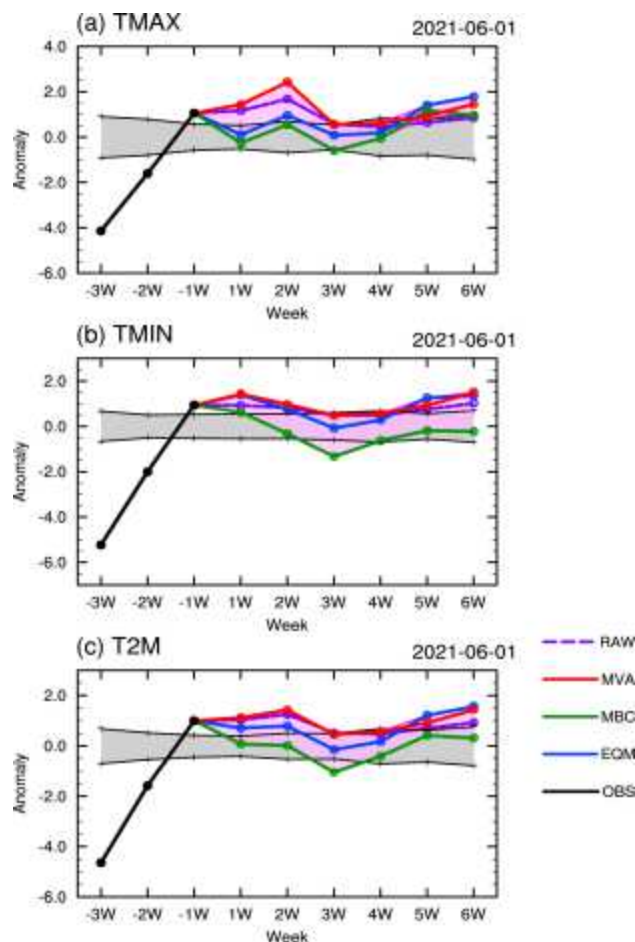


Figure 84. Time-series of bias-corrected forecasts for (a) maximum, (b) minimum and (c) 2-m temperature from week1 to week6. This forecast is displayed with the observations during the previous 3 weeks. Gray zone indicates the normal range and pink zone shows the ranges from 3 different bias correction method.

편차보정 방법에 따른 온도 분포의 평균값을 취해 범주예보를 한 결과와 raw GloSea5의 결과에 대해 contingency table의 accuracy를 검증하였다(Figure 85). 전체적으로 3주~4주에서 편차보정 결과를 활용한 경우에 예측성이 더 높음짐을 알 수 있다.

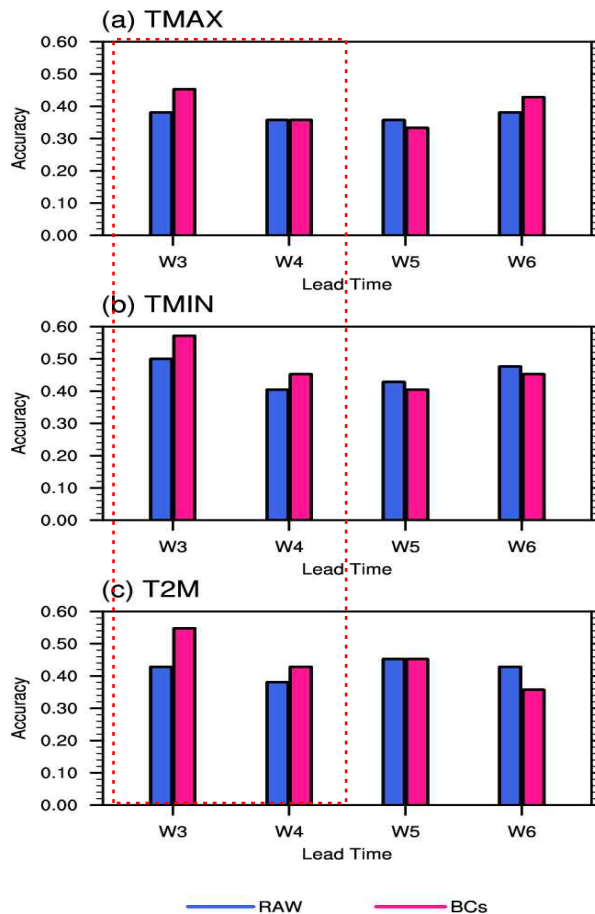


Figure 85. Comparison of accuracy from (blue) raw GloSea5 and (pink) bias correction.

② 확률예보

실제 현업 장기예보를 할 때, 범주예보뿐 아니라 확률예보 결과도 중요하다. Figure 86은 한 예로써, 예보일 2021년 6월 14일을 기준으로, 예보 3주에 대한 최고, 최저, 평균기온에 대한 3분위 확률예보 결과이다. 확률분포에서 나타나듯이, 편차보정 전 raw GloSea5의 예보의 경우 모든 변수에 대해 above normal 확률을 높게 예보하였다. 다만, MVA 편차보정에서는 유사하게 above normal을 예보하였으나, raw GloSea5에 비해 확률은 다소 낮게 예측하였다. 또한 MBC 예보에서는 오히려 below normal로, EQM에서는 평년과 비슷하게 예보하여, 편차보정 방법에 따라 확률분포값도 서로 다르게 나타남을 알 수 있어, 이를 고려한 확률예보가 필요함을 알 수 있다.

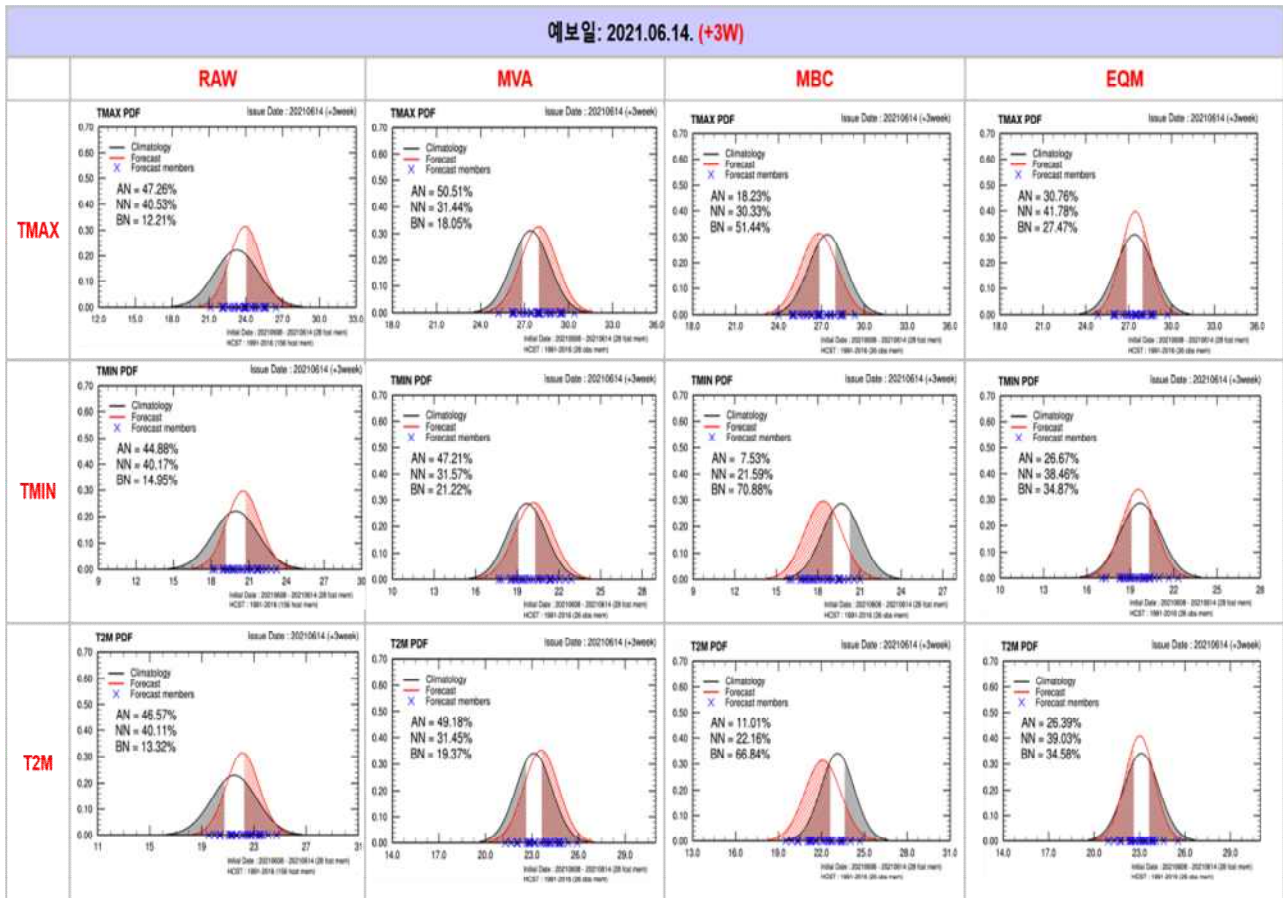


Figure 86. Week3 tercile-based probabilistic forecasts of raw GloSea5, MVA, MBC and EQM bias-corrected for (top) maximum, (middle) minimum and (bottom) mean temperature, which is forecasted at June 14, 2021.

GloSea5 예보의 각 앙상블 멤버에 대해 각기 3개의 서로 다른 편차보정 방법을 거친 결과, 3배의 앙상블 멤버를 얻게 되고, 이를 통한 3분위 확률예보가 가능하게 된다. Figure 87은 raw GloSea5와 편차보정 후 기온예보에 대한 확률분포를 나타낸다. Above normal 경향이 뚜렷한 raw GloSea5에 비해 편차보정한 결과는 평년과 비슷한(near normal) 범주의 확률이 가장 높게 모의하는 것으로 나타났다. 따라서 이러한 편차보정한 온도 예측 결과를 활용하여 예보를 개선할 수 있음을 알 수 있다. 실제 현업 예보에서는 범주 예보를 하게 되므로, 범주 예보 결과를 활용하되, 확률분포값은 참조하여 예보 시 의사결정을 내릴 수 있음을 알 수 있다.

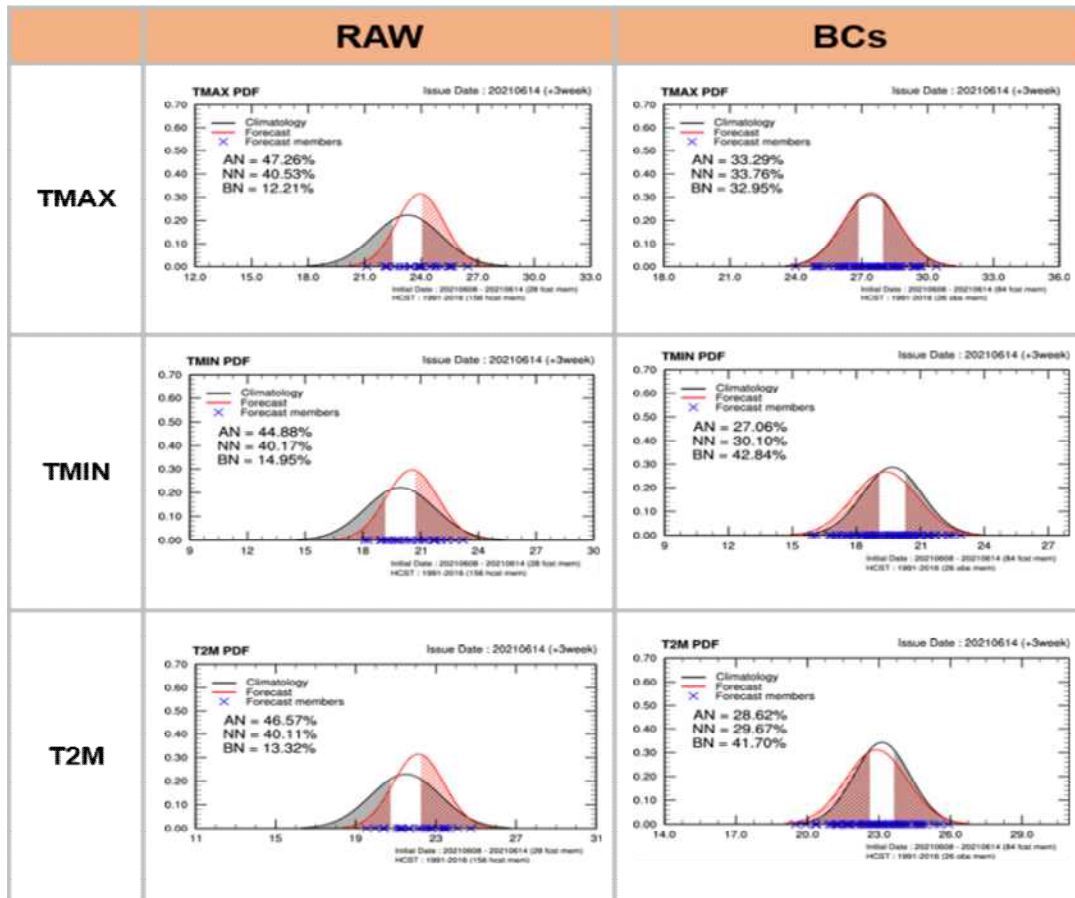


Figure 87. Week 3 tercile-based probabilistic forecast of (to) maximum, (middle) minimum and (bottom) mean temperature, which is forecasted at June 14, 2021. (Left) raw GloSea5 and (right) bias-corrected forecasts.

③ 현업화

본 연구결과는 기상청 기후예측과와의 주기적인 실무협력회의를 통해 결과를 공유하였으며, 최종 결과는 기상청 1개월 장기예보 현업에 활용되는 토대를 마련하였다. 특히, 기상청에서 수행 중이던 편차보정 관련 연구결과와 비교하여, 세부적인 방법론 비교를 통해 기존 결과보다 개선된 결과를 도출할 수 있었다. 또한 우리나라를 중심으로 최고, 최저기온에 대한 편차보정 특성을 분석한 결과로써, 기상청 기후예측과의 장기예보 서비스 개선 계획에 따라, 최고, 최저기온의 3분위 확률예측 가능성을 제시하였다. 그리고 본 연구에서 제시한 1개월 전망을 위한 편차보정 알고리즘에 따른 결과를 기후예측과에서 새롭게 구축 중인 내부시스템에 실시간 예측정보를 제공할 예정이다. 이를 통해 단정예보의 편차값을 보정하여, 최고, 최저, 평균기온 예측정확도 향상과 함께 최고, 최저기온 장기전망 서비스 개발에 기여할 수 있을 것이다 (Figure 88).

APCC의 1, 3개월 전망 기술개발 (기계학습, 통계보정) 연입화 계획
 [2021. 11. 24(수) / 기후과학국 기후예측과 박정자]

배경 및 목적

- 다양한 기후예측 인자와 기후예측모델을 활용한 기계학습모델(3개월 전망) 및 관성저로 자동화를 위한 기계기술 개발(남양/동계보정)을 통한 1개월 전망을 위해 APCC의 연구개발 현업화 추진

주요 내용

기계학습을 활용한 3개월 전망 기술 개발

- [정확도 검증] 3종류의 가우시안 프로세스 기계학습모델(GP-PD, GP-OBS, GP-MMB)을 개발하여 정확도 비교 검증(PC, HSS, ROC)
- GP-PD: 장기예보 가이드선스(III) 활용, GP-OBS: 관측자료 자체 분석 활용, GP-MMB: 기후인자를 바탕으로 MME 자료 추가 활용
- 기후인자와 MME를 동시 활용한 모델이 대체로 정확도가 높음

<모델 검증(2014-2020) (예시) ROC : 약 0.6~0.9 >

[시스템 현업화] 전국, 권역별 3분위 확률값 및 분포도 제시

<시스템 통계 그래프 예시 >

딥러닝을 활용한 1개월 전망 기술 개발

- [정확도 검증] U-Net 기법을 활용하여 동아시아 중심의 예측값을 산출하여 ECMWF 모델결과와 상대적 비교 검증(ACC 활용)

<월별 ECMWF와 딥러닝 기법 ACC(2011~2019년) >

- 기존 연확모델 대비 개선 정도가 크지 않으며, 1개월 자동생산 현업화를 위해 예측기간 및 예측영역 확대 필요
- 학습기간 및 예측영역 확대를 위한 전산자원 추가 도입 및 딥러닝 기법 개선(22.12)

통계적 편차보정을 활용한 1개월 전망 기술 개발

- [정확도 검증] 3가지 통계보정*을 통해 기후예측모델(GloSea-5CMA)의 계절적 오차 보정을 통해 RMSE 비교 분석
- * 통계보정 방식

번호	내용	출처
①	[MVA] Mean and variance adjustment 양상분 평균 및 분산을 관측과 일치	Monterey et al. (2013): Bias Adjustment and ensemble re-forecasting methods for seasonal forecasting: a comprehensive inter-comparison using the CFSv2 data
②	[MBC] Mean bias correction 편의값과 편위기후값 사이 통계산출식 보정	Guan et al. (2021): Statistical error analysis and calibration of 2-m temperature for the NCEP GFS reforecast of the atmospheric environment(2020 period)
③	[EQM] Empirical quantile mapping 관측자료 모델자료의 확률 분포 일치 보정	Monterey et al. (2013): Skill of subseasonal forecasts in Europe: Effect of bias correction and denormalizing using surface observations

3가지 방식 중 EQM방식의 편차보정이 평균, 최저, 최고기온의 RMSE 개선효과가 대체로 큼

<LEAD TIME별 편차보정을 통한 RMSE 비교 (기간: 2017~21.6.21) >

[시스템 현업화] 주변 시계열 그래프 및 확률 PDF 표준

<시스템 통계 그래프 예시 >

향후 계획

- 3개월 기계학습 및 1개월 편차보정 결과의 표준을 위한 통합(21.12~22.01)
- 예측결과 검증을 위한 시스템 자료처리 개선 및 표준(22.11)

Figure 88. A document from KMA/CPD for operational use of APCC bias correction method for the purpose of 1-month forecast(공문서: 기후예측과-2606).

(2) 여름철 계절내 진동(BSISO)를 활용한 1개월 예보 콘텐츠 개선

(가) 1개월 전망을 위한 BSISO 감시 및 예측정보 생산 시스템 구축 및 운영

아시아 여름 몬순 지역에서 발생하는 주요 계절내 변동 모드 중 하나인 BSISO에 대한 정보를 여름철 1개월 전망에 활용하고자 하였다. 먼저, 지난주 관측된 BSISO 위상 및 강도와 이

후 6주간 예측된 BSISO 위상 및 강도의 주별 변화를 한 눈에 파악할 수 있는 BSISO 위상도를 표출하였다. BSISO 지수는 주요 대류 활동 위치에 따라 각 모드별 8개의 위상으로 구별되고, BSISO1 모드의 경우 30~60일 주기를 가지고 위상 1에서부터 위상 8로 이동하면서 적도 인도양에서부터 북서태평양까지 동북진하는 반면 BSISO2 모드의 경우 더 짧은 주기로 적도인도양 및 필리핀해에서 시작하여 WNP-EA 지역까지 북서진하는 특징을 나타낸다. 또한 BSISO 위상도에 서 지수 값이 원 중심에서 바깥 방향으로 나갈수록 세기가 강해지는 것을 의미한다. 두 번째로 지난 주 동안 관측된 BSISO 지수 정보를 활용하여 재구성된 주평균 BSISO 관측 영향 편차장을 상향장파복사 및 850hPa 바람, 500hPa 지위고도, 기온 및 강수에 대해 생산하고 아시아 몬순 지역을 중심으로 표출하였다. 마지막으로 월요일 초기장의 ECMWF 예측 결과로 생산된 6주간의 BSISO 지수 정보를 기반으로 재구성된 BSISO 예측 영향 편차장을 상향장파복사 및 850hPa 바람, 500hPa 지위고도에 대해 생산하고 주평균 결과를 표출하였다. 2차원 공간장으로 표현되는 BSISO 영향 편차장을 제공함으로써 BSISO 두 개 모드가 결합되어 나타나는 대류 활동 및 지역별 대기 반응에 대한 전반적인 이해도를 높이고자 하였다. BSISO 위상도, 지난주 BSISO 관측 영향 편차장, 향후 6주에 대한 BSISO 예측 영향 편차장은 매주 화요일에 생산되어 다음 날 1개월 전망 회의에 참고자료로 사용된다. Figure 89는 매주 제공되는 BSISO 감시 및 예측 정보 중 하나이다.

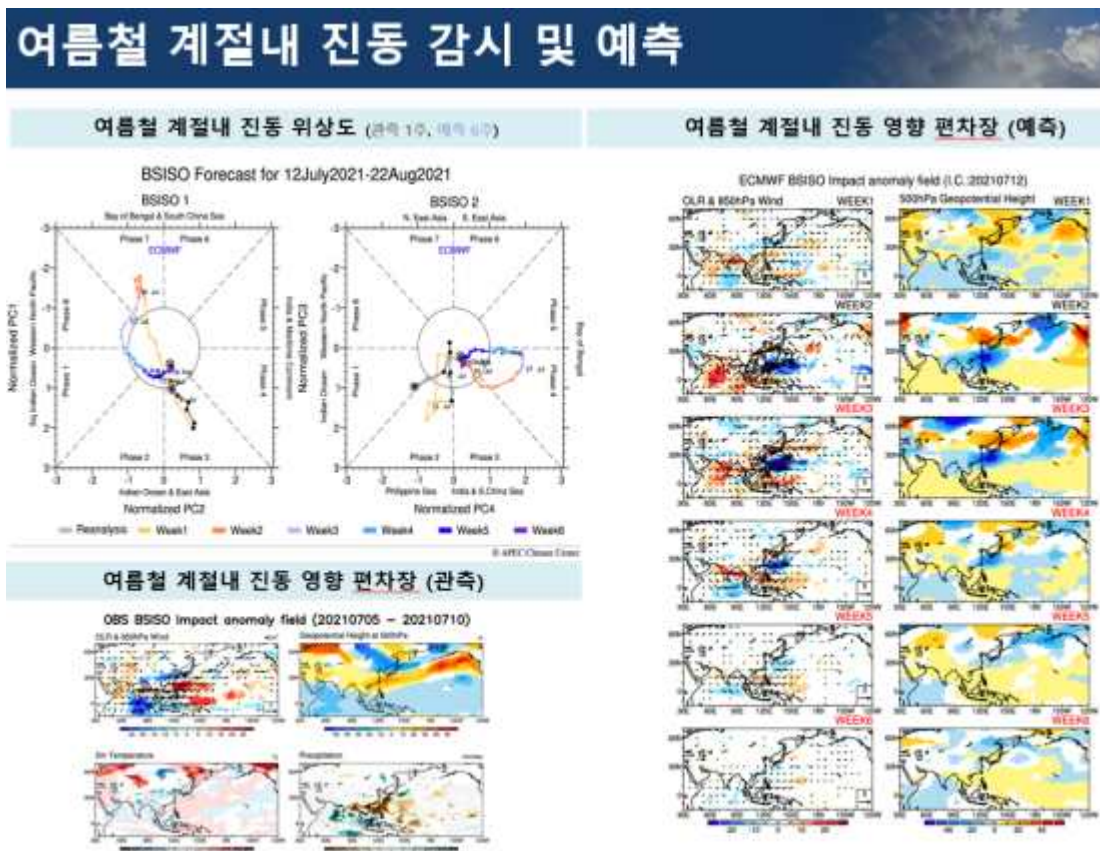


Figure 89. An example of weekly BSISO monitoring and forecast for 1-month outlook

(나) BSISO 위상에 따른 여름철 우리나라 기온 및 강수 변동 특성 분석

① 여름철 우리나라 기온 및 강수 변동에 대한 BSISO 영향 위상 선정

여름철(6-8월) 우리나라 기온 및 강수 변동에 영향을 미치는 대표 BSISO 위상을 선정하기 위한 기준으로 기온 및 강수 편차 강도와 BSISO 발생 빈도수를 고려하였으며 선정 과정은 Figure 90과 같다. 일반적으로 BSISO2 모드의 위상 전이 속도는 대략 3일 정도로 BSISO1 모드 보다 짧기 때문에 BSISO2의 위상은 진행 순서대로 두 개씩 묶어서 BSISO1 모드 1개 위상과 BSISO2 모드 2개 위상을 하나의 그룹으로 지정하였다. 총 64개의 그룹에 대해서 우리나라 평균 기온 및 강수의 장주기 성분을 제거한 계절내 편차를 산출하고 t-test를 통해 통계적으로 유의한 기온 및 강수 편차 값이 $\pm 1.5\sigma$ 이상인 그룹을 우선적으로 선별하였다. 두 번째로, 적어도 한 주 동안 전체 날수의 80% 이상 같은 위상이 발생해야 주별 기온 및 강수에 미치는 영향이 지속될 것으로 판단하여 7일 중 6일 이상 같은 위상인 주(week) 빈도수가 가장 많은 그룹을 선별하였다. 해당 그룹이 여러 개인 경우 기온 또는 강수 편차 값이 가장 큰 위상 그룹을 최종적으로 채택하였으며 기온이 높을 때, 기온이 낮을 때, 강수가 많을 때, 강수가 적을 때에 대한 총 4개의 대표 영향 위상이 선정되었다.

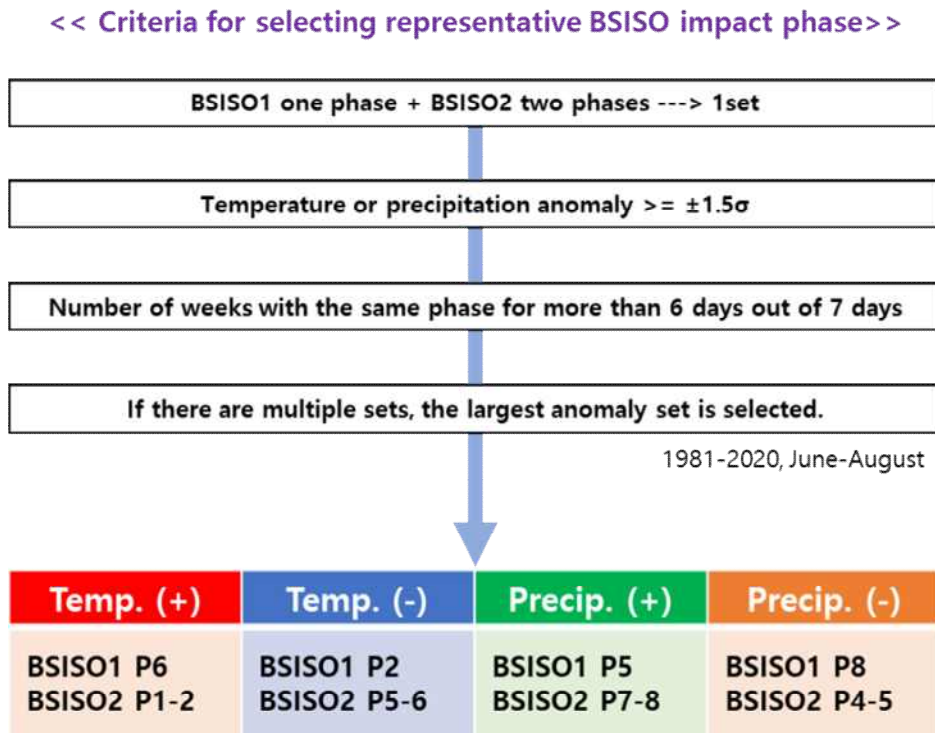


Figure 90. Schematic diagram of BSISO phase selection process affecting Korean summer temperature and precipitation variation.

BSISO1 모드의 위상 6(위상 2)과 BSISO2 모드의 위상 1-2(위상5-6)가 동시에 발생했을 때 기온이 높은(낮은) 경향을 보이고 이때의 위상 그룹을 ‘warm phase’ (‘cool phase’)로 명명

하고자 한다. 1981년부터 2020년까지 여름철(6-8월)동안 warm phase 및 cool phase는 각각 121회, 150회의 사례가 발생했다. BSISO1 모드의 위상5(위상 8)와 BSISO2 모드의 위상 7-8(위상 4-5)이 동시에 발생했을 때 강수가 많은(적은) 경향이 나타나고 이때의 위상 그룹을 ‘wet phase’ (‘dry phase’)로 명명하며 과거 40년 동안 여름철에 발생한 횟수는 총 141회, 169회이다. Warm/Cool phase 또는 Wet/Dry phase에 해당하는 위상이 7일 중 6일 이상 발생했을 때의 주평균 기온 또는 강수 편차 값을 연도별로 살펴보았다(Figure 91). BSISO warm phase가 발생했을 때 1984년 6월 셋째 주 사례와 같이 오히려 기온이 낮은 경우가 있었고, BSISO cool phase가 발생했을 때 2006년 8월 마지막 주 사례와 같이 기온이 높은 경우가 있었다. 기온에 대한 예외 사례의 경우 해당주의 BSISO 위상 및 강도 변화를 살펴보면(Figure 92) 영향 위상이 발생했지만 BSISO1 또는 BSISO2의 세력이 일주일 내내 매우 약해서 BSISO 두 개의 결합모드에 의한 대기 반응이 다르게 나타났을 것으로 보인다. 따라서 우리나라 여름철 기온 변동에 대한 BSISO 결합모드 영향력은 BSISO1 모드와 BSISO2 모드 동시에 강할 때 더 뚜렷할 것으로 추측되며 이와 관련된 추가 분석이 필요하다.

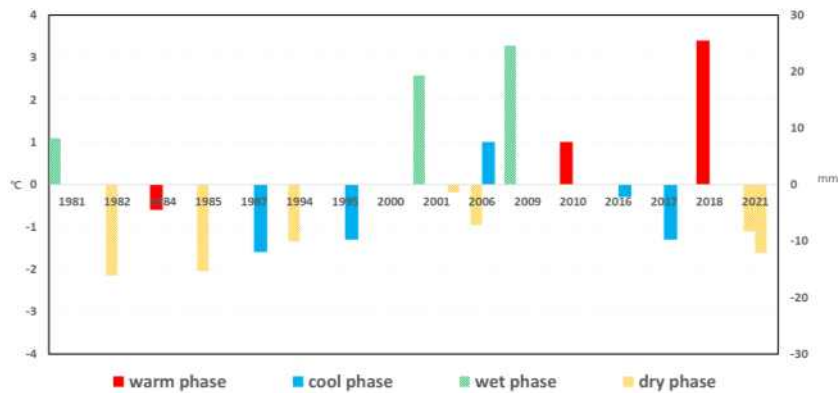


Figure 91. Time series of weekly mean Korean temperature(precipitation) anomalies for warm/cool(wet/dry) phase cases.

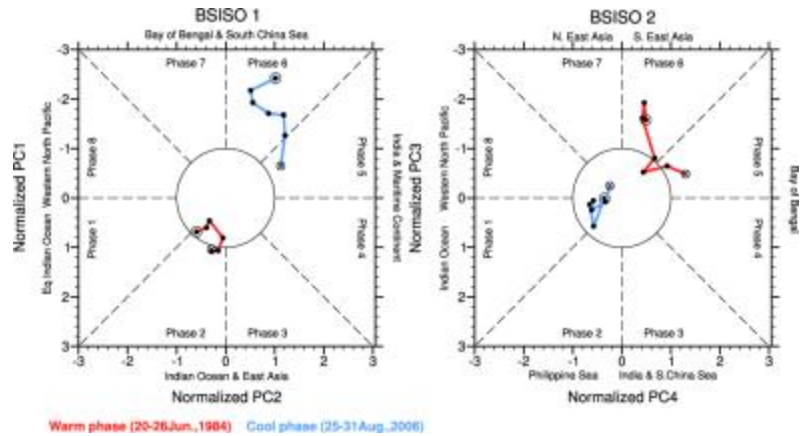


Figure 92. BSISO phase diagram of exception case for warm phase case(red) and cool phase case(blue).

② 우리나라 여름철 기온 변동에 영향을 주는 BSISO 위상 특징

Figure 93은 BSISO 결합 위상이 warm phase일 때 및 cool phase일 때의 동아시아 지역 기온 편차 합성장을 보여준다. BSISO1 모드의 위상 6과 BSISO2 모드의 위상 1-2가 동시에 발생했을 때 중국 상해지역부터 우리나라, 그리고 일본 열도까지 동아시아 지역에서 양의 기온 편차가 나타나며 우리나라 평균 기온은 평년 대비 0.7°C 높게 나타난다. 반면, BSISO1 모드의 위상 2와 BSISO2 모드의 위상 5-6이 동시에 발생했을 때 동일 지역에서 음의 기온 편차가 나타나며 우리나라 평균 기온은 평년 대비 0.6°C 낮게 나타난다.

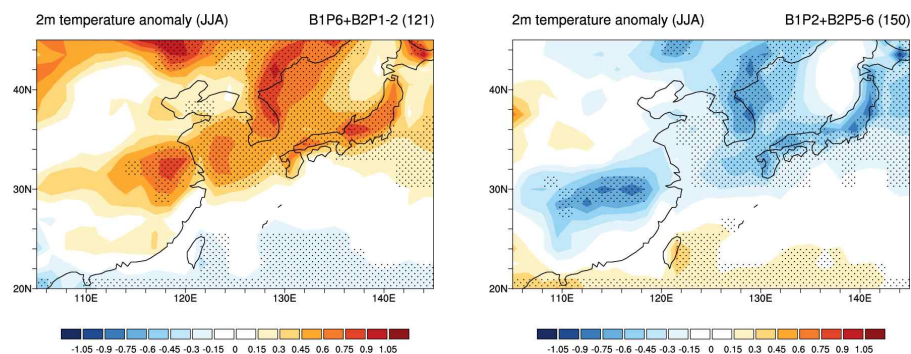


Figure 93. Composite map of 2m temperature intraseasonal anomalies for the warm phase case(left) and cool phase case(right) with respect to BSISO mode. Areas with black dots indicate statistically significant at 95% confidence level.

BSISO warm phase일 때 적도 인도양, Maritime continent 지역에서 대류 역제가 나타나고 필리핀해 부근 중심으로 대류가 강하게 발달하는 모습을 볼 수 있다(Figure 94). 아열대 서태평

양 대류 활동이 강화되면 보상하강운동으로 우리나라 주변 중위도 지역에서 대류 활동이 약화되고 고기압성 편차가 나타난다. 500hPa 지위고도 편차장에서 살펴보면 뱅갈만 지역부터 필리핀해 부근까지 음의 편차, 바이칼호부터 일본 동쪽 해상까지 양의 편차, 캄차카반도 부근에 음의 편차가 나타나면서 양의 PJ(Pacific-Japan) 패턴(Nitta, 1987)과 매우 유사한 형태로 로스비 파동 전파가 이루어짐을 볼 수 있다. 또한 200hPa 상층 지위고도의 양의 편차가 우리나라 부근에 나타나면서 상층까지 고기압성 순환 발달이 유도되며 하강운동에 의한 단열가열로 기온이 상승한 것으로 보인다. 더불어 우리나라 남동쪽에 위치한 고기압의 가장자리를 따라 불어 들어오는 남풍 계열의 바람 편차 영향으로 남쪽에서부터 유입되는 온난한 공기 또한 기온 상승에 기여하는 것으로 보인다. 반면, BSISO cool phase일 때 상향장파복사 및 중상층 지위고도 편차 합성장을 보면(Figure 95) warm phase일 때와는 반대로 필리핀해 부근에서 강한 대류 억제 구역이 나타나고 그 지역에 양의 지위고도 편차가 존재한다. 양의 지위고도 편차 영역의 북쪽인 우리나라부터 일본 동쪽 해상까지 음의 지위고도 편차가 상층까지 강하게 발달하면서 음의 PJ 패턴과 유사한 남북방향 파동형태의 순환구조를 보여준다. 우리나라 부근 상층골 발달로 인해 한기가 유입될 수 있는 경로가 마련되어 기온 하강을 유도하는 것으로 보인다.

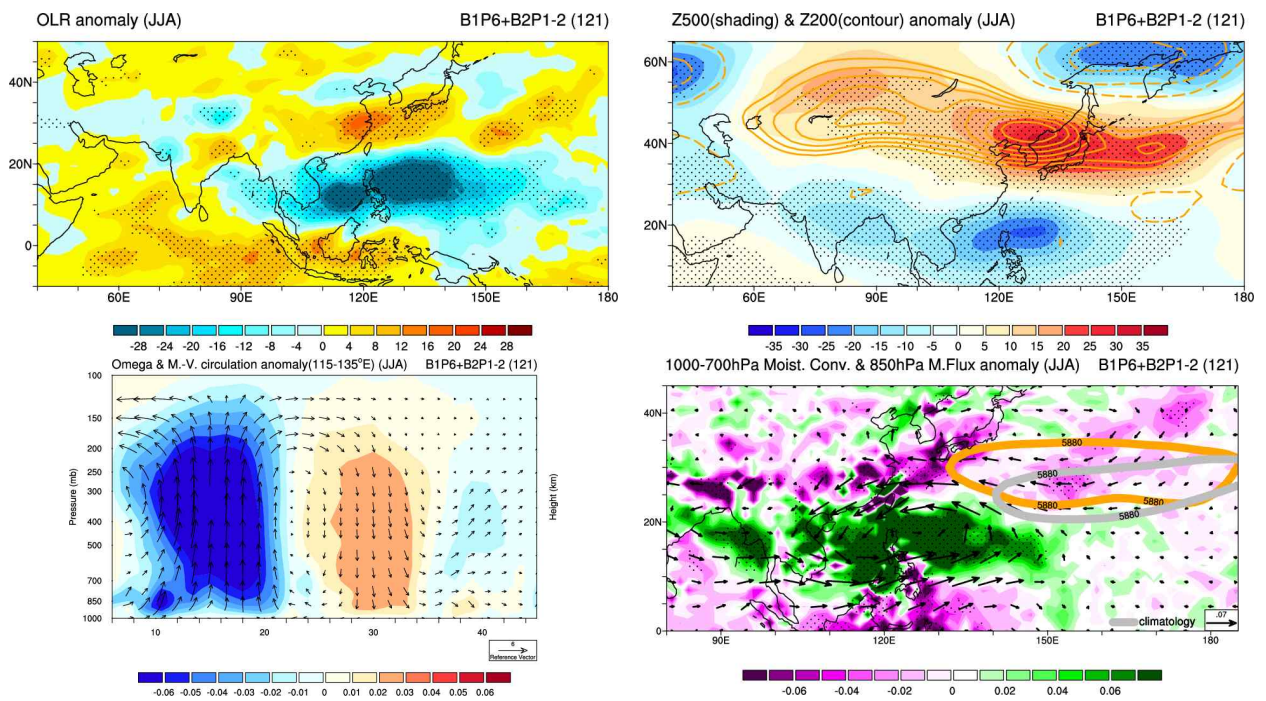


Figure 94. Composite map of outgoing long wave radiation(top left), 500hPa(shading) and 200hPa(contour) geopotential height(top right), omega(shading) and meridional-vertical circulation(bottom left), and 1000-700hPa integrated moisture convergence(shading) and 850hPa moisture flux(bottom right) intraseasonal anomalies for the BSISO warm phase case in June-August.

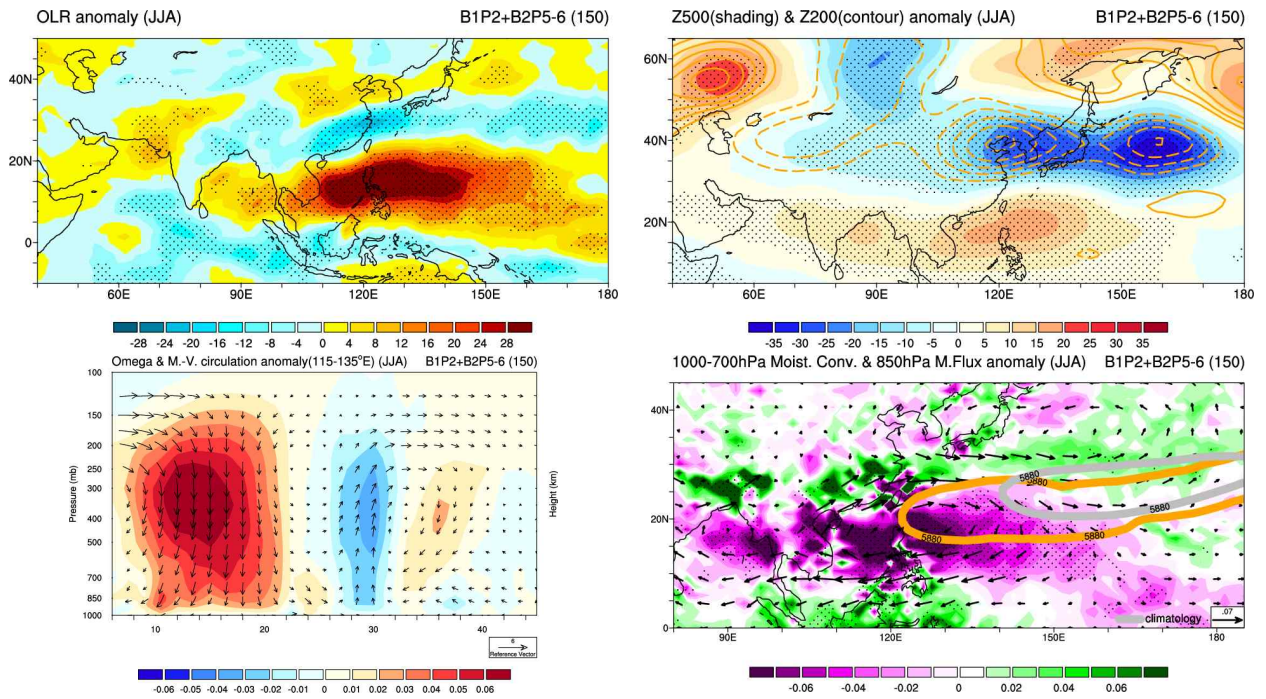


Figure 95. Same as Figure 94 except for the BSISO cool phase case in June-August.

③ 우리나라 여름철 강수 변동에 영향을 주는 BSISO 위상 특징

Figure 96은 BSISO 결합 모드가 wet phase인 경우 및 dry phase인 경우 동아시아 지역 강수 편차 합성장을 나타낸다. BSISO1 모드의 위상 5와 BSISO2 모드의 위상 7-8이 동시에 발생했을 때 중국 상해지역부터 우리나라, 그리고 일본 일부 지역까지 양의 강수 편차가 나타나며 우리나라 평균 일강수량은 평년 대비 5.2mm 많은 반면 BSISO1 모드의 위상 8와 BSISO2 모드의 위상 4-5가 동시에 발생했을 때 동일 지역에서 음의 강수 편차가 나타나며 우리나라 평균 일강수량은 평년 대비 5.8mm 적었다.

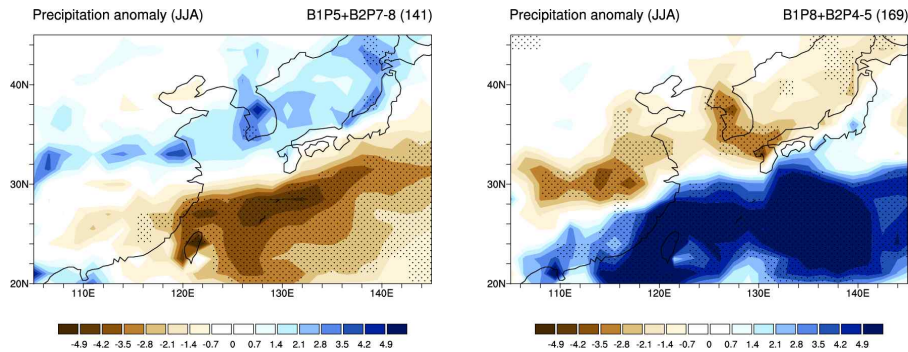


Figure 96. Composite map of precipitation intraseasonal anomalies for the wet phase case(left) and dry phase case(right) with respect to BSISO mode. Areas with black dots indicate statistically significant at 95% confidence level.

BSISO wet phase에서 나타나는 대규모 대기 순환장을 살펴보면 필리핀해 부근 대류 강화, 그 북쪽으로 일본 남쪽 해상까지 대류 억제, 우리나라 부근 대류 강화 시그널이 보인다(Figure 97). 연직속도 합성장을 우리나라 중심 경도대 (115-135°E)에 대하여 평균한 위도-기압 분포에서도 상승-하강-상승운동 구역이 대류 강화-억제-강화 구역과 일치한다. 우리나라 기온 변동에 영향을 주는 BSISO 대류 구조는 적도에서부터 북위 20도 부근까지 넓은 지역에서 상승기류(또는 하강기류) 발달 및 대류 강화(또는 억제)가 나타난다는 특징이 있는 반면에 강수 변동에 영향을 주는 BSISO 대류 구조는 좀 더 좁은 영역에서 발생하고 아열대 서태평양부터 우리나라까지 뚜렷한 삼중셀 구조가 나타나는 특징이 있다. 대류가 발달하는 필리핀해 부근에 음의 500hPa 지위고도 편차가 나타나고 우리나라 남쪽에 강한 양의 편차 지위고도가 나타나면서 고기압성 순환 편차가 유도된다. 500hPa 지위고도장의 5880gpm 선으로 표현할 수 있는 북서태평양 고기압의 경우 평년 대비 서쪽으로 확장되어 우리나라 남쪽에 위치하는 것을 볼 수 있다. 이 고기압의 가장자리를 따라 우리나라는 남서풍 계열의 바람의 영향을 받고 온난 습윤한 공기 유입이 활발해지면서 하층 수증기 수렴이 강화되는 것을 볼 수 있다. 또한 대기권 하층부터 상층까지 발달된 강한 상승운동이 북위 34도 부근에 존재하며 우리나라 강수 증가를 유발하게 된다. BSISO 활동에 의해 우리나라 강수가 적었을 때의 아시아 몬순 지역에 나타나는 대기 반응을 살펴보면(Figure 98) 많은 강수를 유발하는 패턴과는 반대의 모습을 보여준다. Maritime continent와 필리핀 남부 지역을 중심으로 대류가 약화되고 남중국해부터 일본 남쪽해상까지 대류가 강화되며 그 북쪽인 우리나라 중심으로 대류가 약화된다. 우리나라 남쪽에 형성되는 대류 강화 구역은 적도 인도양에서부터 발달한 대류가 점차 북동진하여 일본 남쪽 해상 부근까지 이동해 온 동시에 필리핀 동쪽에서 발달한 대류가 북진하면서 중첩되는 곳으로 볼 수 있다. 대류 발달 구역에서 상층까지 저기압성 순환 편차가 유도되고 이로 인해 북서태평양고기압이 평년만큼 서쪽으로 발달하지 못하고 동쪽으로 많이 수축되면서 해양으로부터 유입될 수 있는 따뜻한 수증기 공급통로 역할을 충분히 못해 주고 있다. 오히려 우리나라 남쪽에 발달한 저기압성 순환으로 인해 우리나라는 북동풍 바람 편차 영향으로 하층 수분 수렴이 억제됨을 알 수 있다. 또한, 남북-연직 순환 편차장에서도 볼 수 있듯이 북위 24도 부근에서 강한 상승기류가

형성되고 상승한 공기는 각각 남쪽 저위도와 북쪽 중위도로 침강하면서 우리나라 부근에 하강 운동을 유도하고 강수 발달을 저해하는 요소가 된다.

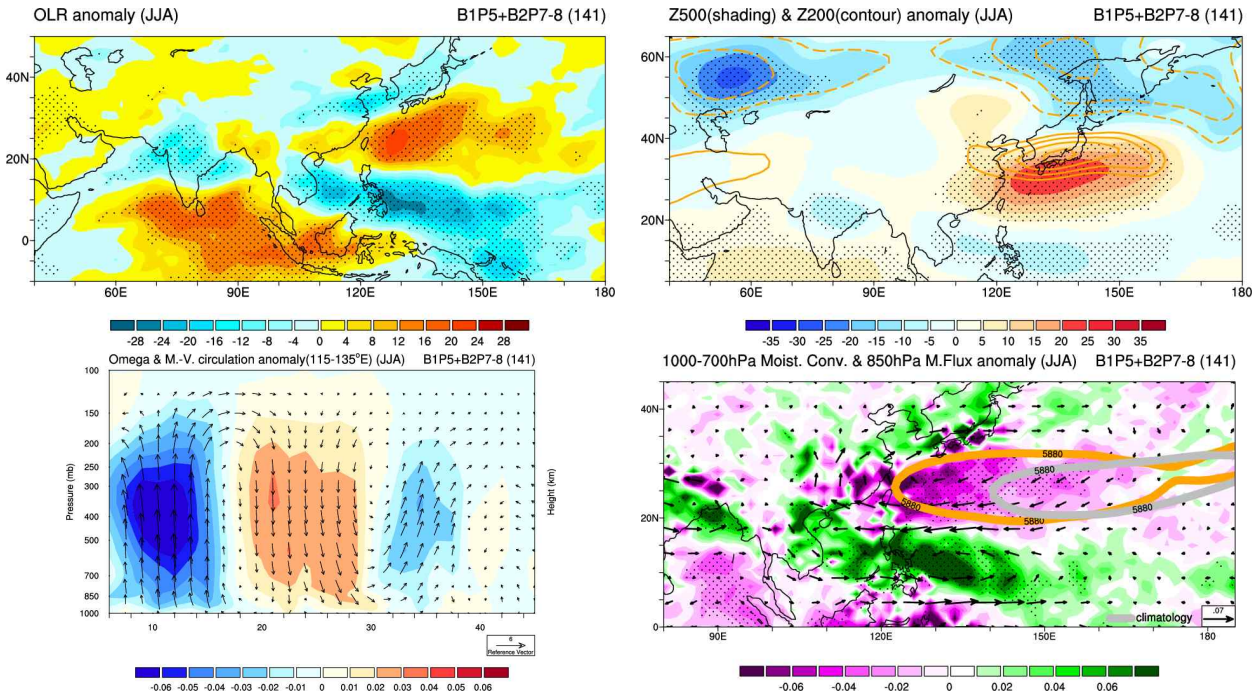


Figure 97. Same as Figure 94 except for the BSISO wet phase case in June-Aug.

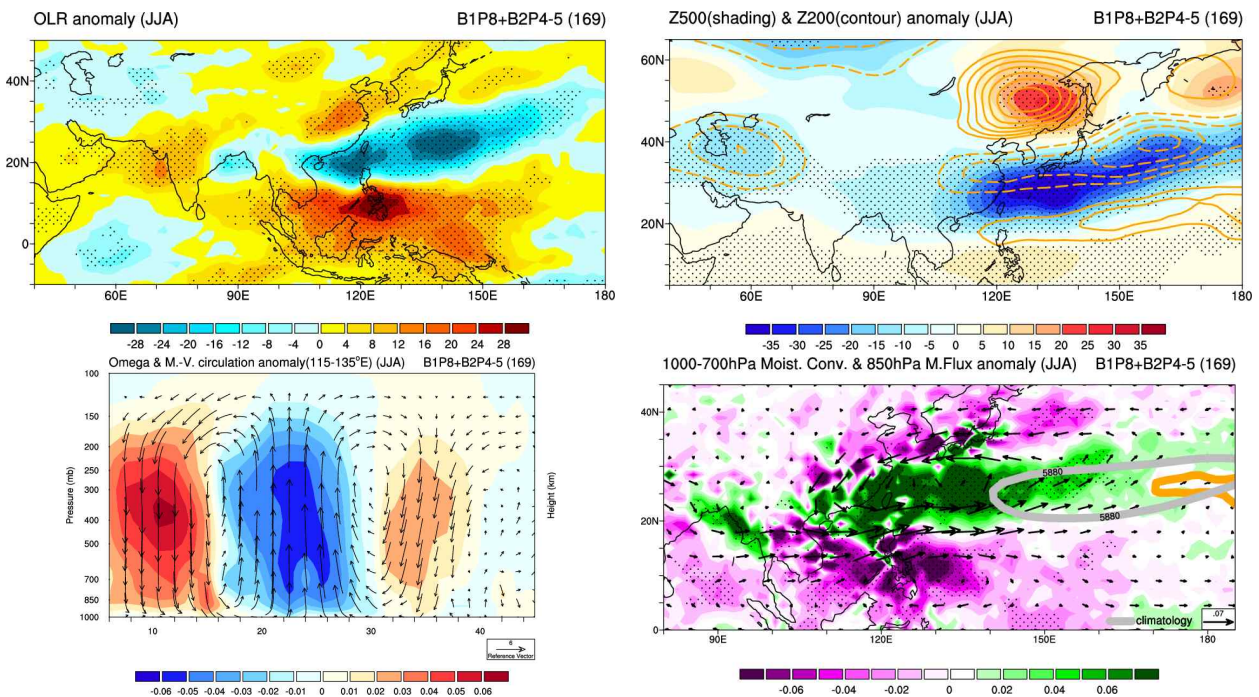


Figure 98. Same as Figure 94 except for the BSISO dry phase case in June-August.

(다) 사례 분석을 통한 BSISO 예측 영향 편차장 활용성 평가

① BSISO dry phase 발생 사례 (2021년 7월 24일~30일)

우리나라 여름철 기온 및 강수에 영향을 미치는 4개의 BSISO 결합 위상을 선정하였고 2021년 사례를 중심으로 활용 가능성을 평가해 보고자 한다. Figure 91에서 볼 수 있듯이 2021년에는 BSISO dry phase(BSISO1 Phase8+BSISO2 Phase4-5)인 주(week)가 두 번 발생했으며 두 케이스 모두 우리나라 강수가 평년대비 적었음을 확인 할 수 있었다. 그 중 7월 마지막 주 사례를 살펴보면, 일주일 동안 BSISO1 모드는 위상 8에 위치해 있었고, BSISO2 모드는 위상 4에서 5로 이동하면서 강한 강도로 매우 활발한 활동을 보였다(Figure 100). 이 기간 동안 평균된 상향장파복사 편차장을 살펴보면(Figure 99), Maritime-continent 지역에는 대류 억제, 그 북쪽으로 대류 강화, 우리나라 주변 위도대에서 대류가 약화되면서 삼중셀 구조 패턴이 나타나는데 이는 BSISO dry phase에서 나타나는 대류 패턴과 매우 유사하다. 우리나라 남쪽에서 대류가 활발히 일어나면서 저기압성 순환 편차가 유도되고 5880gpm 선으로 표현되는 북서태평양 고기압은 동쪽으로 수축되어 있는 모습을 볼 수 있다. 남쪽의 저기압성 순환의 가장자리에서 불어 들어오는 북동풍 계열의 바람이 수증기 유입 억제 역할을 함에 따라 하층 수분발산이 강화된다. 실제로 평년대비 12mm/day 강수가 적었고 BSISO 대류 활동에 의한 영향이 우리나라 부근 강수 활동이 약화될 수 있는 호조건을 형성한 것으로 보인다. 다음으로 관측에서 나타나는 7월 마지막 주 BSISO 활동 및 강수에 미치는 영향이 얼마나 잘 예측이 되었는지 살펴보았다(Figure 100,101). BSISO1 지수의 경우 3주 전과 5주 전 예측에서 한 위상 더 빠르게 이동될 것으로 보고 오히려 4주 전에 관측과 동일한 위상으로 강하게 발달할 것으로 예측하였다(Figure 100). BSISO2 지수는 5주 전부터 위상과 강도 모두 관측과 유사한 결과를 보인다. 두 개의 BSISO 모드가 결합된 예측 영향 편차장에서 우리나라 남쪽 아열대 서태평양 부근에서 대류활동이 강해지면서 저기압성 순환 편차가 유도되고 우리나라 부근에 북동풍 바람 편차가 우세함에 따라 음의 강수 편차가 나타나는 것을 확인할 수 있다(Figure 101). 비록 3주 및 5주 선행 예측에서 BSISO 강도를 과소모의함에 따라 대기 반응 시그널은 약하지만 전반적인 패턴은 잘 예측한 것으로 판단된다.

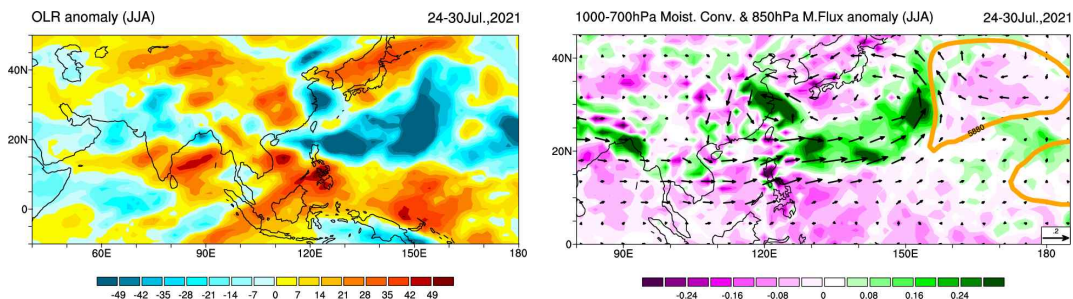


Figure 99. Weekly mean anomalies of outgoing longwave radiation(left), 1000-700hPa integrated moisture convergence(shading) and 850hPa moisture flux(right) for the period 24-30 July, 2021.

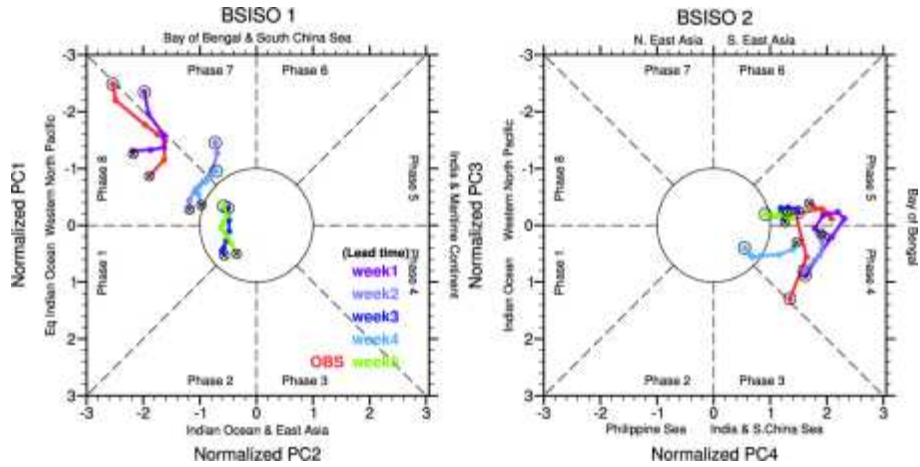


Figure 100. Phase diagram of observed (red) and predicted (purple to green) BSISO for the period 24–30 July, 2021.

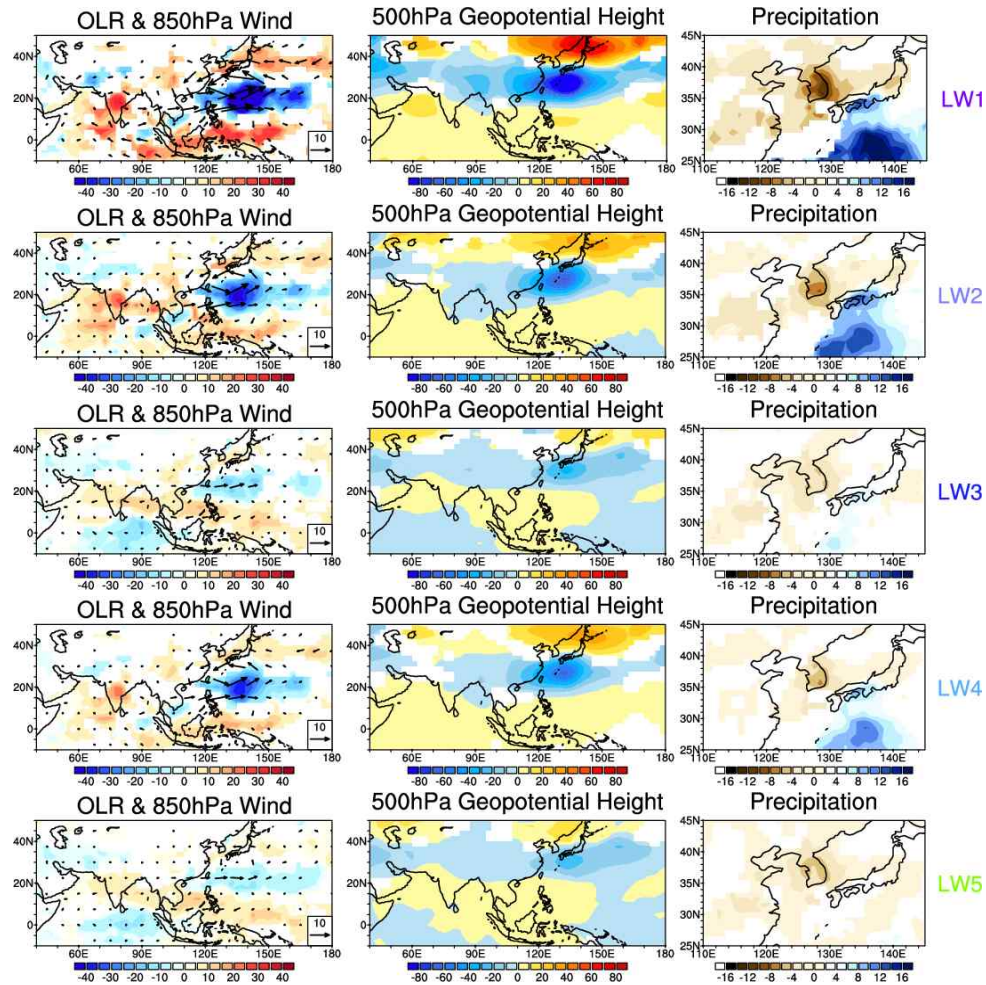


Figure 101. BSISO impact anomalies of OLR and 850hPa wind (left), 500hPa geopotential height (middle), and precipitation (right) estimated using the BSISO forecast index for each lead time.

② 10월 둘째 주 고온 발생 사례 (2021년 10월 11일~17일)

2021년 10월 둘째 주 우리나라 기온은 평년 대비 0.7℃ 높았다. Figure 102는 10월 둘째 주 평균된 500hPa 지위고도 편차장의 GloSea5 대기 초기장으로 사용되는 KMA N1280 분석장 결과(현업에서 재분석 자료의 대체 값으로 활용 중)와 500hPa 및 200hPa 지위고도 편차장의 3주 선행 ECMWF 예측 결과이다. 주평균 500hPa 지위고도 편차장을 보면 북인도양-남중국해-아열대서태평양까지 음의 편차, 그 북쪽으로 우리나라 위도대에서 양의 편차, 동유라시아 지역에 음의 편차가 존재하는 것을 볼 수 있다. 이러한 파동 패턴은 3주 선행 ECMWF 예측에서도 잘 나타나며 특히 우리나라 부근에서 200hPa 상층까지 강한 양의 지위고도 편차 중심이 모의됨에 따라 기온을 상승시킬 수 있는 대규모 기압장 패턴이 예측되었다. 그렇다면 이 기간 BSISO 활동은 어떻게 예측되었을까? 3주 선행 ECMWF BSISO 지수 예측 결과(Figure 103) BSISO1 모드는 위상 6에 위치하고 BSISO2 모드는 위상 2에서 위상 3으로 이동할 것으로 보았으며, 그에 따른 아시아 몬순 지역 영향 편차장을 살펴보면(Figure 104) 필리핀해 부근에서 대류가 발달하면서 보상하강운동으로 우리나라 부근에 고기압성 편차가 강화되고 양의 기온 편차를 유도하는 것을 알 수 있다. 즉, BSISO 대류 활동이 하나의 기후인자으로써 우리나라 주변 고압대를 형성하는데 기여하는 것으로 보이며 길게는 5주 선행 예측부터 신뢰할 만한 정보를 제공할 수 있을 것으로 기대된다.




Figure 102. Weekly mean of 500hPa geopotential height anomalies from GloSea5 atmospheric initial data(left) and ECMWF based on week-three forecasts(middle), and 200hPa geopotential height anomalies from ECMWF based on week-three forecasts(right) valid for 11-17 October 2021.

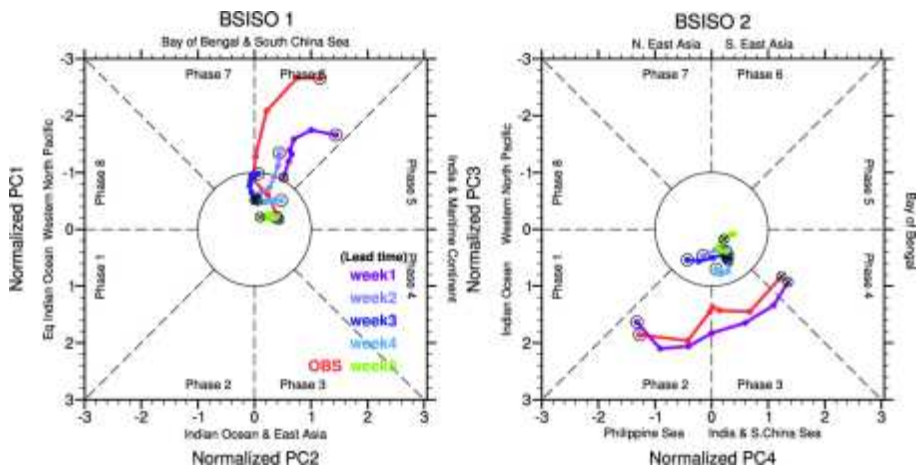


Figure 103. Phase diagram of observed(red) and predicted(purple to green) BSISO for the period 11-17 October, 2021.

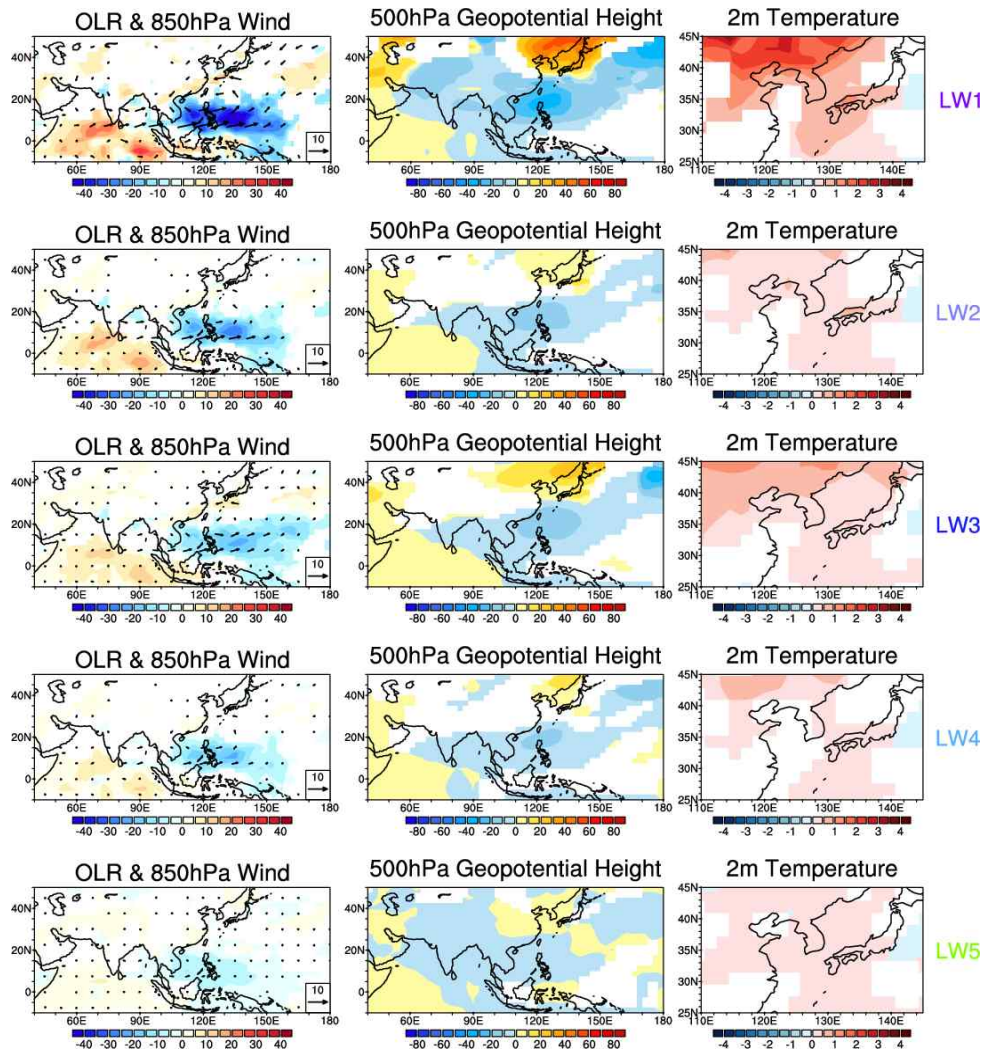


Figure 104. BSISO impact anomalies of OLR and 850hPa wind(left), 500hPa geopotential hieght(middle), and temperature(right) estimated using the BSISO forecast index for each lead time.

다. 기존 장기예보 기술의 활용가능성 평가

(1) 기존 통계모델의 예측성 및 활용성 평가

기존 개발된 통계 모델의 예측성능 변화 분석에 사용한 9개 모델에 대해 분석 기간을 2020년까지 확장하였을 때 예측성능을 Table 27에 나타내었다. HR이 0.6이상, HSS가 0.4이상인 모델을 전반적인 예측성이 있다고 판단하고, 9개 모델 중 현재까지도 예측성이 있는 모델은 7월 기온과 장마 강수 통계 모델이다. 또, 3분위 예측에 대한 예측성을 Accuracy, POD, FAR로 평가하였다. Accuracy와 POD 모두 0.6이상, FAR은 0.5 이하일 때 예측성이 있다고 판단하고 색으로 표시하였다. 마찬가지로 7월 기온과 장마 강수 모델에서 각각 Above normal과 Near

normal일 때, Above normal과 Below normal일 때 예측성이 있는 것으로 나타났다. 2월 기온 모델의 경우 Below normal을 0회 예측하면서 FAR값이 존재하지 않는다.

Table 27. Statistical models' predictability scores

통계모형	평가기간	HR	HSS	Accuracy (A/N/B)			POD (A/N/B)			FAR (A/N/B)			Predictability	비고
				A	N	B	A	N	B	A	N	B		
12월 기온	1979~2020	0.48	0.21	0.69	0.52	0.74	0.36	0.59	0.45	0.44	0.57	0.5		
1월 기온	1979~2020	0.36	0.04	0.64	0.72	0.71	0.07	0.72	0.10	0.67	0.63	0.75		
2월 기온	1979~2020	0.38	0.07	0.69	0.38	0.69	0.07	1.00	0.00	0.00	0.63			BN 0회 예측
6월 기온	1979~2020	0.50	0.25	0.67	0.52	0.81	0.44	0.56	0.50	0.42	0.59	0.38		
7월 기온	1979~2020	0.64	0.46	0.83	0.67	0.79	0.60	0.79	0.54	0.10	0.50	0.3	A/N	
8월 기온	1979~2020	0.48	0.21	0.62	0.52	0.81	0.33	0.56	0.55	0.55	0.59	0.33		
7~8월 평균 기온	1994~2020	0.44	0.17	0.70	0.52	0.67	0.57	0.27	0.80	0.56	0.33	0.67		
8월 강수	1994~2020	0.56	0.33	0.81	0.59	0.70	0.50	0.78	0.40	0.20	0.56	0.33		
장마강수	1979~2020	0.74	0.61	0.89	0.74	0.85	0.67	0.50	0.92	0.20	0.43	0.20	A/B	

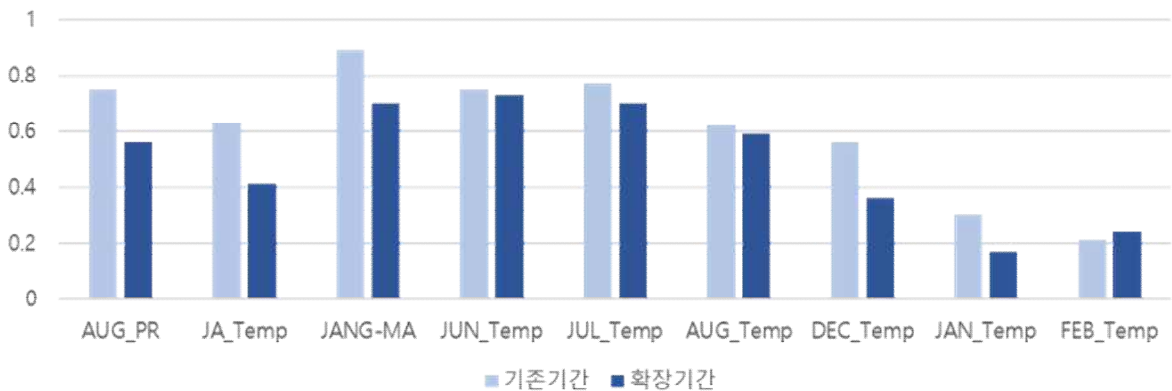


Figure 105. Changes in temporal correlation coefficient between model's prediction and the observation

통계 모델의 예측 결과와 예측 타깃의 상관성 변화를 Figure 105에 나타내었다. 기존기간은 통계 모델을 개발한 시점까지를 의미하고, 확장기간은 통계 모델 개발 이후 2020년까지를 의미한다. 겨울철 평균 기온 예측 모델에서는 12월은 0.56에서 0.36, 1월은 0.3에서 0.17로 상관성이 낮아졌고, 2월은 0.21에서 0.24로 상승하였다. 여름철 평균 기온 예측 모델에서는 6월은 0.75에서 0.73으로, 7월은 0.77에서 0.7로, 8월은 0.62에서 0.59로 상관성이 낮아졌다. 8월 강수 예측 모델은 0.75에서 0.56으로, 7~8월 평균 기온 예측 모델은 0.63에서 0.41로, 장마 강수 예측 모델은 0.89에서 0.7로 상관성이 하락하였다. 거의 모든 모델이 기간을 확장하였을 때 예측 타깃과의 상관성이 떨어지는 모습을 보인다. 예측인자별로 예측 타깃과의 상관성 변화를 살펴보

아도 기간을 확장하면 전반적으로 상관성이 떨어지는 모습이 나타나는데(Figure 106), 다음 절에서 각 모델별로 예측인자와 예측 타겟의 상관성 변화를 면밀히 살펴보고자 한다.

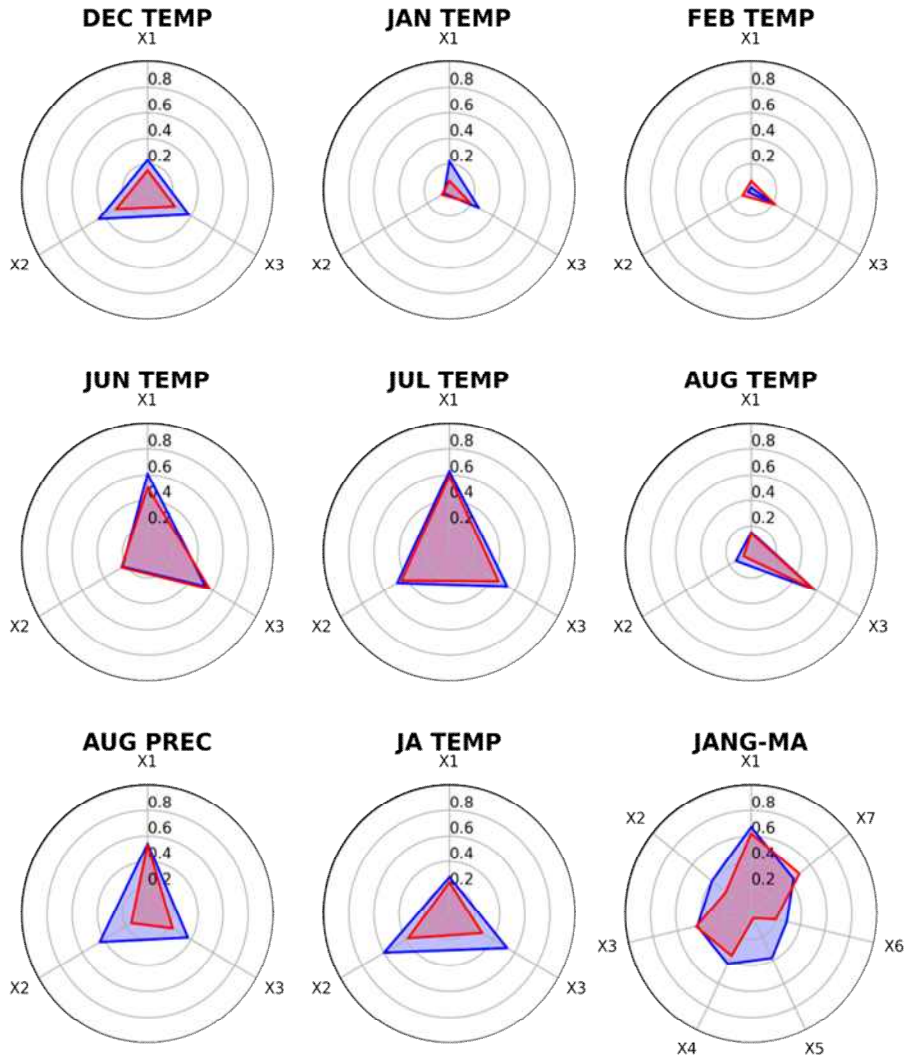


Figure 106. Changes in temporal correlation coefficient between model's predictor and the target. Blue lines denote original period, and red lines denote extended period.

(가) 겨울철 월별 기온 예측 통계모델

겨울철 월별 (12월, 1월, 2월) 기온 예측을 위한 모델로 2016년 개발되었다 (우성호, 2016). 12월은 1973~2014년, 1월과 2월 모델은 1974~2015년 기간을 training 기간으로 하고 그 이후부터 월별 기온 예측값을 생산한다. Training 기간에 대한 월별 평균 기온의 시계열을 표준화하여 $\pm 0.5^{\circ}\text{C}$ 를 기준으로 3분위 예측값을 얻을 수 있다.

이 모델은 기존 코드와 사용된 자료들에 대한 기록이 불명확하여 가용한 자료를 가지고

기존기간(1979년~2015년)에 대한 다중선형회귀분석을 통해 모델을 재구성하고 모델과 예측인자에 대한 유의성 분석 결과를 Table 28에 나타내었다. R-squared는 결정계수로 회귀식의 설명력을 나타내며, 1에 가까울수록 좋다. F-statistics는 도출된 회귀식이 적절한지를 나타내며, 0에 가까울수록 적절하다고 판단한다. Coef는 회귀계수이다.

Table 28. Statistical analysis of reconstructed wintertime(DJF) monthly temperature prediction model

모형 분석결과	12월	1월	2월
Adj. R-squared	0.26	0.01	-0.04
F-statistics	5.14*	1.12	0.52
예측인자1 Coef	0.59	0.58	0.37
예측인자2 Coef	2.27*	0.03	-0.19
예측인자3 Coef	-0.35*	-0.00	0.33

*p-value가 95% 유의수준에서 유의함

12월 기온 회귀모델은 통계적으로 유의하지만($p < 0.05$), 1월과 2월 모형은 유의하지 않았다($p > 0.05$). 모델별 예측인자의 회귀계수를 살펴보면 12월 기온 예측인자인 적도 태평양과 아열대 태평양 해수면 온도 차이의 9~10월 경향성(예측인자2)과 10월 유라시아 눈덮임 속도(예측인자3)를 제외한 나머지 예측인자는 월별 기온에 대하여 유의미한 예측인자가 아닌 것으로 나타났다($p > 0.05$).

Figure 107은 표준화된 12월 우리나라 평균 기온과 통계 모델 예측인자의 산포도와 회귀선을 나타낸다. 모델이 개발된 2015년까지의 자료(이하 기존기간)는 주황색으로, 그 이후로 2020년까지의 자료(이하 확장기간)는 파란색으로 표시하였다. 세 예측인자 모두 기간을 확장하였을 때 예측인자와 예측 타깃 사이의 시계열 상관성이 약해지는 모습을 보인다. 우리나라 12월 기온과 10월 랍테프해 해빙 간의 시계열 상관성은 기존기간에 0.23에서 확장기간에 0.15로 하락하였고, 적도 태평양과 아열대 태평양 해수면 온도 차이의 9~10월 경향성과의 시계열 상관성은 0.45에서 0.29로, 10월 유라시아 눈덮임 속도와와의 시계열 상관성은 -0.38에서 -0.25로 하락하였다. Figure 108에는 모델의 예측 결과를 파란색으로, 표준화된 우리나라 12월 기온 관측값을 하늘색으로 표시하였다. 모델이 개발된 이후인 2016~2020년 총 5회 예측 중 모델이 맞춘 횟수는 1회로 나타났다.




Figure 107. Scatter plots showing the relationship between predictors and standardized December mean temperature. Orange lines denote 1979~2015, and blue lines denote 1979~2020.

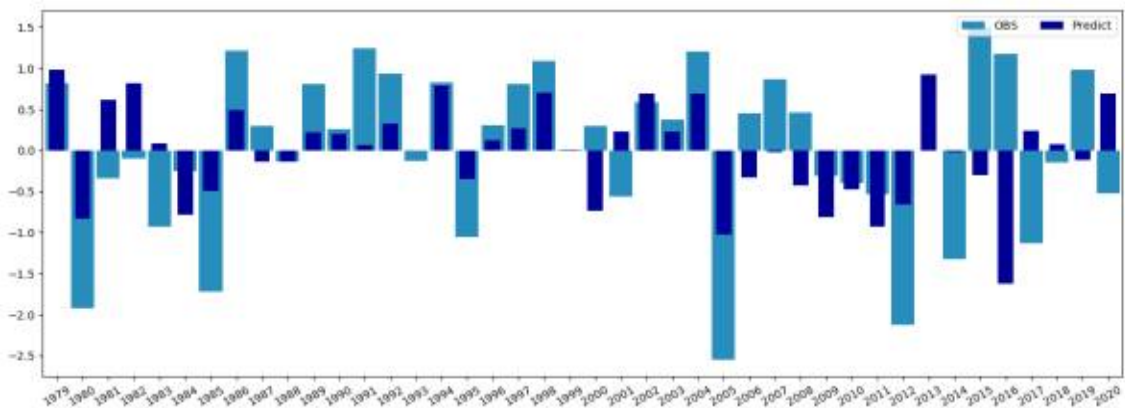


Figure 108. Bar chart showing standardized December mean temperature (skyblue) and model's prediction (blue).

Figure 109는 표준화된 우리나라 1월 평균 기온과 통계모델 예측인자의 산포도와 회귀선을 보여준다. 우리나라 1월 평균 기온과 10월 카라해 해빙의 시계열 상관성은 기존기간에 0.22에서 확장기간에 0.07로 낮아졌는데, 이는 최근 5년간 카라해 해빙이 적은 상태가 유지되었지만, 우리나라 기온 변동성에 큰 영향을 미치지 않은 것이 원인일 수 있다. 우리나라 1월 평균 기온과 10월 타미르 반도 500hPa 지위 고도의 시계열 상관성은 -0.27에서 -0.19로 하락하였고, 반대로 열대 태평양 해수면 온도 동-서 경도의 9~10월 경향성과의 시계열 상관성은 0.05에서 0.07로 상승하였다. Figure 110에 모델의 예측 결과를 파란색으로, 표준화된 우리나라 1월 기온 관측값을 하늘색으로 표시하였다. 모델이 개발된 이후인 2016~2020년 총 5회 예측 중 모델이 맞춘 횟수는 0회이다.




Figure 109. Scatter plots showing the relationship between predictors and standardized January mean temperature. Orange lines denote 1979~2015, and blue lines denote 1979~2020.




Figure 110. Bar chart showing standardized January mean temperature (skyblue) and model's prediction (blue).

Figure 111은 표준화된 우리나라 2월 평균 기온과 통계모델 예측인자의 산포도와 회귀선을 나타낸다. 우리나라 2월 기온과 바렌츠해 해빙의 상관성은 기존기간에 -0.02 에서 확장기간에 -0.07 로, 북대서양 해수면 온도의 9~10월 경향성과의 상관성은 -0.03 에서 -0.08 로, 10월 걸프만 해수면 온도와의 상관성은 0.19 에서 0.22 로 변화였는데, 예측인자와 예측 타겟의 상관성이 상승하는 모습이 나타났지만 상승 폭이 매우 작아 유의미한 변화라고 하기 어렵다. Figure 112에 모델의 예측 결과를 파란색으로, 표준화된 우리나라 1월 기온 관측값을 하늘색으로 표시하였다. 모델이 개발된 이후인 2016~2020년 총 5회 예측 중 모델이 맞춘 횟수는 2회이다.




Figure 111. Scatter plots showing the relationship between predictors and standardized February mean temperature. Orange lines denote 1979~2015, and blue lines denote 1979~2020.

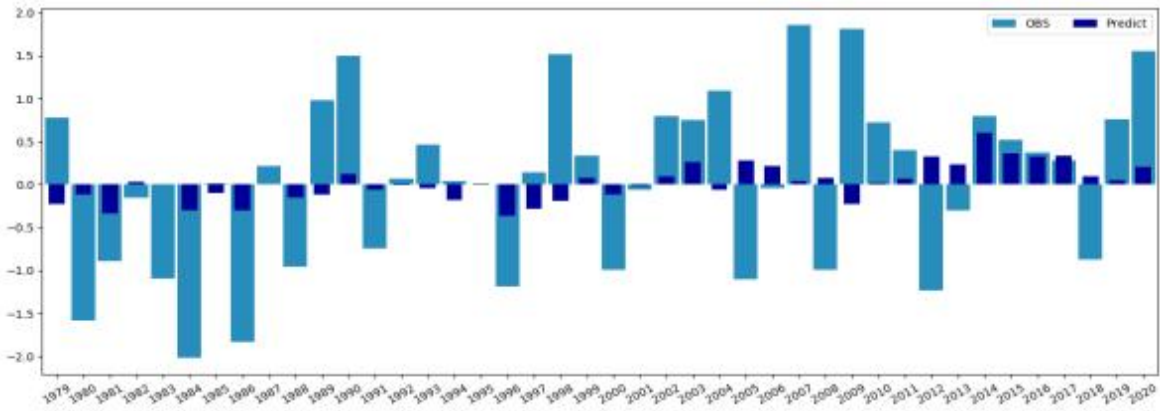


Figure 112. Bar chart showing standardized February mean temperature (skyblue) and model's prediction (blue).

(나) 여름철 월별 기온 예측 통계모델

여름철 월별 (6월, 7월, 8월) 기온 예측을 위한 모델로 2016년 개발되었으며(권민호 외, 2016), 1979~2016년의 시계열 자료를 학습하여 예측값을 생산한다. 겨울철 통계 모델과 마찬가지로 training 기간에 대한 월별 평균 기온의 시계열을 표준화하고 $\pm 0.5^{\circ}\text{C}$ 를 기준으로 3분위 예측값을 얻을 수 있다.

2017년 이후 예측값을 생산하기 위해 training 기간에 대한 예측인자의 시계열 자료를 가지고 다중선형회귀분석을 실시하여 모델을 재구성하였으며, 모델과 예측인자에 대한 유의성 분석 결과를 Table 29에 나타내었다. 세 모델 모두 통계적으로 유의하며($p < 0.05$), 6월 기온 예측인자인 3월 중국 북동부 눈덮임(예측인자1)과 1월 열대 서태평양 해수면 온도(예측인자3), 7월 기온 예측인자 전체, 그리고 8월 기온 예측인자인 2월 호주 북부 해수면 온도(예측인자3)가 각 통계 모델에 대하여 유의미한 예측인자인 것으로 나타났다($p > 0.05$).

Table 29. Statistical analysis of reconstructed summertime(JJA) monthly temperature prediction model

모형 분석결과	6월	7월	8월
Adj. R-squared	0.52	0.56	0.33
F-statistics	14.25*	16.89*	6.95*
예측인자1 Coef	0.17*	0.01*	0.10
예측인자2 Coef	0.01	0.01*	1.31
예측인자3 Coef	1.46*	0.56*	1.55*

*p-value가 95% 유의수준에서 유의함

Figure 113은 표준화된 우리나라 6월 평균 기온과 통계모델 예측인자의 산포도와 회귀선을 나타낸다. 우리나라 6월 기온과 3월 중국 북동부 눈덮임의 상관성은 기존기간에 0.61에서 확장기간에 0.50으로 감소하였고, 4월 강수량과의 상관성은 0.23에서 0.24로, 1월 열대 서태평양 해수면 온도와의 상관성은 0.53에서 0.57로 소폭 상승하였다. 산포도를 통해 최근 4년간 열대 서태평양 해수면 온도가 평년보다 다소 높은 수준이 유지되었고 우리나라 6월 평균 기온도 평년보다 높았던 사례가 지속됨을 알 수 있는데, 이로 인해 예측인자의 상관성이 높아졌을 것으로 보인다. Figure 114에 모델의 예측 결과를 파란색으로, 표준화된 우리나라 6월 기온 관측값을 하늘색으로 표시하였다. 모델이 개발된 이후인 2017~2020년 총 4회 예측 중 모델이 맞춘 횟수는 0회이다.




Figure 113. Scatter plots showing the relationship between predictors and standardized June mean temperature. Orange lines denote 1979~2016, and blue lines denote 1979~2020.

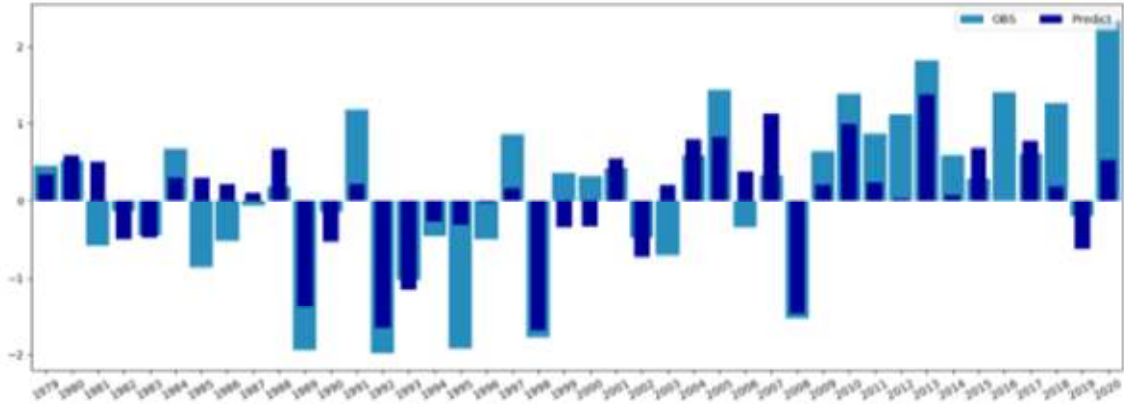


Figure 114. Bar chart showing standardized June mean temperature (skyblue) and model's prediction (blue).

Figure 115는 표준화된 우리나라 7월 평균 기온과 통계 모델 예측인자의 산포도 및 회귀선을 나타낸다. 우리나라 7월 기온과 3월 500hPa 지위고도의 상관성은 기존기간 0.63에서 확장기간 0.59로, 4월 850hPa 지위고도와의 상관성은 0.48에서 0.44로, 4월 해수면 온도와의 상관성은 0.53에서 0.45로 세 예측인자 모두 2020년까지 기간을 확장하였을 때 예측 타겟과의 상관성이 하락하였다. Figure 116에 모델의 예측 결과를 파란색으로, 표준화된 우리나라 6월 기온 관측값을 하늘색으로 표시하였다. 모델이 개발된 이후인 2017~2020년 총 4회 예측 중 모델이 맞춘 횟수는 2회이다.




Figure 115. Scatter plots showing the relationship between predictors and standardized July mean temperature. Orange lines denote 1979~2016, and blue lines denote 1979~2020.




Figure 116. Bar chart showing standardized July mean temperature (skyblue) and model's prediction (blue).

Figure 117과 118은 표준화된 우리나라 8월 기온과 통계 모델 예측인자의 산포도 및 회귀선, 그리고 모델의 예측 결과와 관측값을 보여준다. 우리나라 8월 기온과 3월 호주 북부 강수량의 상관성은 기존기간에 0.15에서 확장기간에 0.14로, 4월 유라시아 내륙지역 눈덮임과의 상관성은 0.14에서 0.07로, 2월 호주 북서쪽 해수면 온도와의 상관성은 0.58에서 0.57로 세 예측인자 모두 기간을 확장하면 상관관계가 하락하는 모습이 나타났다. 2017~2020년 총 4회 예측 중 모델이 맞춘 횟수는 1회이다.




Figure 117. Scatter plots showing the relationship between predictors and standardized August mean temperature. Orange lines denote 1979~2016, and blue lines denote 1979~2020.




Figure 118. Bar chart showing standardized August mean temperature (skyblue) and model's prediction (blue).

(다) 7~8월 평균 기온 예측 통계모델

7~8월 평균 기온 예측을 위한 모델로 2015년 개발되었다(권민호 외, 2015). 1994~2014년 기간의 예측인자 시계열을 학습하였고, 7~8월 평균 기온의 시계열을 표준화하고, 표준화된 인덱스의 ± 0.5 를 기준으로 3분위 예측값을 생산한다. 7~8월 평균 기온을 구하는 예측 식은 다음과 같다.

$$JAtemp = -1.35 * IOSST + 2.43 * NCSC + 2.44 * BSICE \quad [32]$$

위 식에서 IOSST는 4월 인도양 해수면온도 편차, NCSC는 4월 중국 북동부 눈덮임 편차, BSICE는 3~4월 평균 바렌츠해 해빙농도 편차이다. 세 예측인자에 대하여 예측 타깃과의 산포도 및 회귀선을 Figure 119에 나타내었다. 4월 인도양 해수면 온도 편차와의 상관성은 기존기간에 -0.28 에서 확장기간에 -0.24 로 낮아졌고, 4월 중국 북동부 눈덮임 편차와의 상관성도 0.6 에서 0.38 로, 3~4월 평균 베링해 해빙농도 편차와의 상관성도 0.53 에서 0.3 으로 낮아짐을 알 수 있다. 눈덮임과 해빙 예측인자는 최근 6년간 계속해서 평년보다 낮은 상태가 지속되었지만 7~8월 평균 기온은 평년과 비슷하거나 높게 나타나면서 예측인자의 상관성이 낮아지는 쪽으로 변화였다.

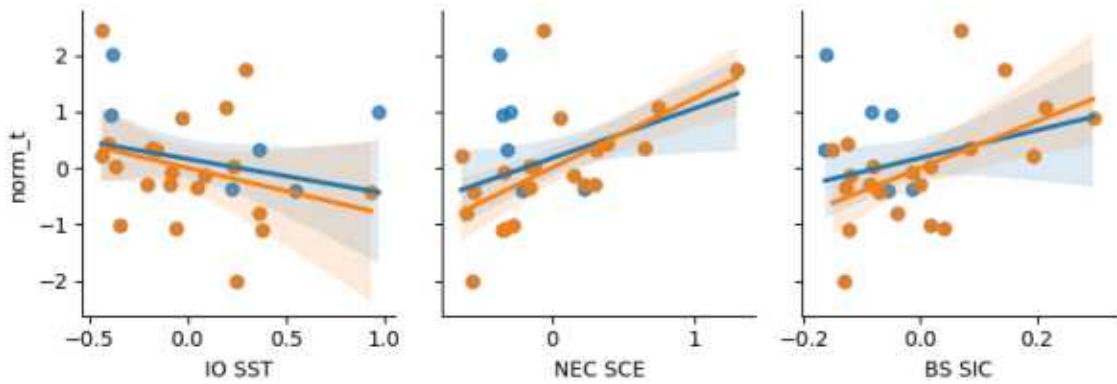


Figure 119. Scatter plots showing the relationship between predictors and standardized July-August mean temperature. Orange lines denote 1994~2014, and blue lines denote 1994~2020.

Figure 120에 모델의 예측결과를 파란색으로, 표준화된 우리나라 7~8월 평균 기온 관측값을 하늘색으로 표시하였다. 모델의 예측인 2015~2020년까지 총 6회 예측 중 모델이 맞춘 횟수는 1회이다.

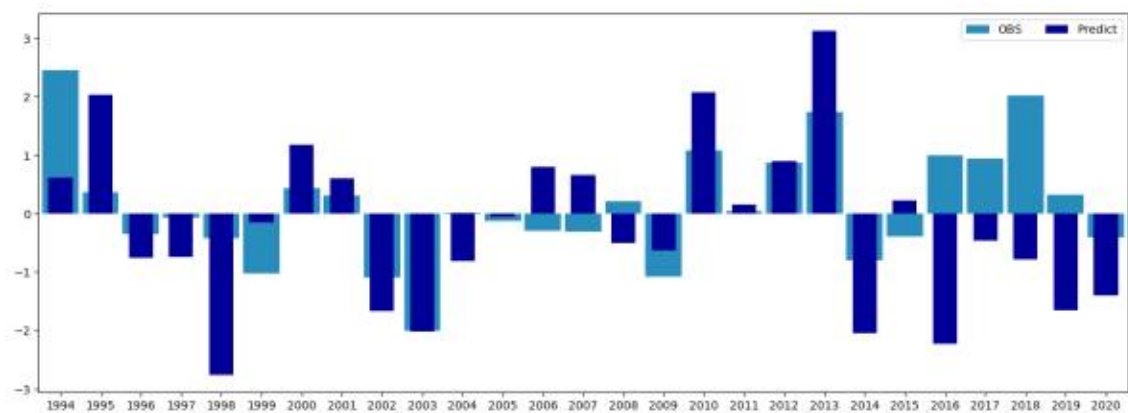


Figure 120. Bar chart showing standardized July-August mean temperature (skyblue) and model's prediction (blue).

(라) 8월 강수량 예측 통계모델

태풍에 의한 강수를 제외한 8월 평균 강수량을 예측하는 모델로 2015년 개발되었다(권민호 외, 2015). 모델의 예측 식은 다음과 같다.

$$Prec_{aug} = -0.51 * NASST + 0.16 * IOSST + 0.45 * NPSST \quad [33]$$

위 식에서 NASST는 1월과 4월 북대서양 해수면 온도의 차이, IOSST는 4~5월 인도양 SST, NPSST는 5월 북서태평양 해수면 온도이다. 세 예측인자에 대하여 예측 타깃과의 산포도 및 회귀선을 Figure 121에 나타내었다. 8월 강수량과 북대서양 해수면 온도의 상관성은 기존기간 -0.54에서 확장기간 -0.53으로 비슷하게 유지되었으나, 인도양 해수면 온도와 상관성은 0.44에서 0.15로, 북서태평양 해수면 온도와 상관성은 0.37에서 0.23으로 비교적 큰 폭으로 낮아졌다. 모델이 예측값을 생산하는 2015~2021년 중 모델이 맞춘 횟수는 3회이다(Figure 122)




Figure 121. Scatter plots showing the relationship between predictors and standardized August mean precipitation. Orange lines denote 1994~2014, and blue lines denote 1994~2020.

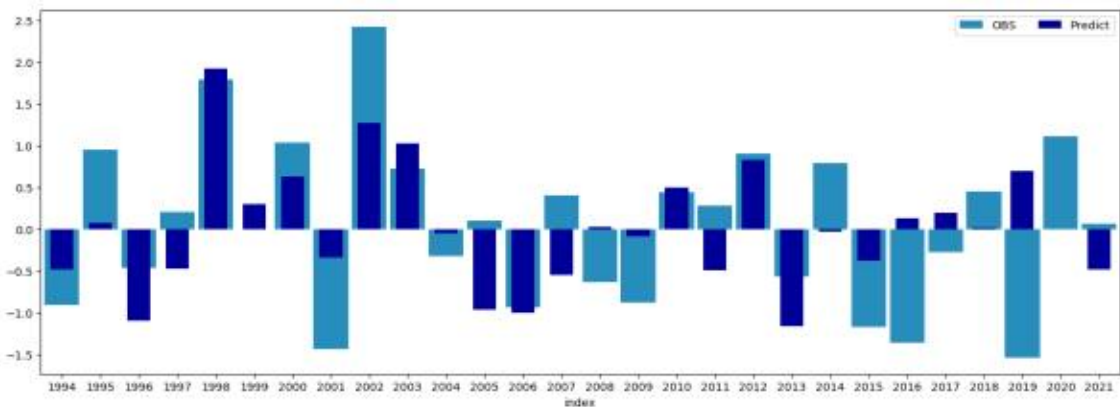


Figure 122. Bar chart showing standardized August mean precipitation (skyblue) and model's prediction (blue).

(마) 장마 강수량 예측 통계 모델

8월 강수량 예측 모델과 마찬가지로 태풍에 의한 강수량을 제외하고, 우리나라 장마 기간인 6월 15일부터 7월 29일까지의 평균 강수량을 예측하는 모델이다(권민호 외, 2014). 표준화된 장마 강수량의 $\pm 0.43 \times$ 표준편차를 기준으로 3분위 예측값을 생산하며, 모델의 예측

식은 다음과 같다.

$$\begin{aligned}
 (1) &= 0.41 \times NA_{SST} + 0.46 \times NPC_{SST} - 0.40 \times CNINO_{SST} \\
 (2) &= 0.49 \times NA_{SST} - 0.49 \times NIO_{SST} + 0.33 \times BS_{SST} \\
 (3) &= 0.57 \times NA_{SST} + 0.33 \times NPC_{SST} - 0.41 \times WNP_{OLR} \\
 (4) &= 0.54 \times NA_{SST} - 0.39 \times NIO_{SST} + 0.42 \times EUSC
 \end{aligned}
 \tag{34}$$

$$\text{장마강수} = \frac{1}{4} \times [(1) + (2) + (3) + (4)]$$

위 식에서 NA_{SST} 는 4월 6일에서 25일까지의 평균 북대서양 해수면 온도 편차의 남북 차이를, NPC_{SST} 는 북태평양지역 해수면 온도 편차의 4월 11일에서 30일까지의 평균과 3월 22일에서 4월 10일까지의 평균의 차이, $CNINO_{SST}$ 는 중태평양 해수면 온도 편차의 4월 1일에서 20일까지의 평균, NIO_{SST} 는 북인도양 해수면 온도 편차의 4월 16일에서 30일까지의 평균, BS_{SST} 는 베링해 해수면 온도 편차의 3월 12일에서 31일까지의 평균, WNP_{OLR} 은 북서태평양 OLR 편차의 5월 11일에서 30일까지의 평균, 마지막으로 $EUSC$ 는 유라시아 대륙 동부와 서부의 3~5월 평균 눈덮임 편차의 차이이다.

장마 강수량과 각 예측인자의 산포도와 회귀선을 Figure 123에 나타내었다. 장마 강수량과 NA_{SST} 의 상관성은 기존기간 0.67에서 0.62로, NPC_{SST} 와의 상관성은 0.4에서 0.26으로, $CNINO_{SST}$ 의 상관성은 -0.44에서 -0.45로, NIO_{SST} 의 상관성은 -0.43에서 -0.36으로, BS_{SST} 의 상관성은 0.38에서 0.04로, $EUSC$ 의 상관성은 0.26에서 0.2로, WNP_{OLR} 과의 상관성은 -0.43에서 -0.49로 변화하였다. $CNINO_{SST}$ 과 WNP_{OLR} 을 제외한 모든 예측 인자들의 상관성이 분석 기간을 2020년까지 늘리면서 낮아진 것을 알 수 있다. 모델이 예측값을 생산하는 2015~2021년 중 모델이 맞춘 횟수는 3회이다(Figure 124).

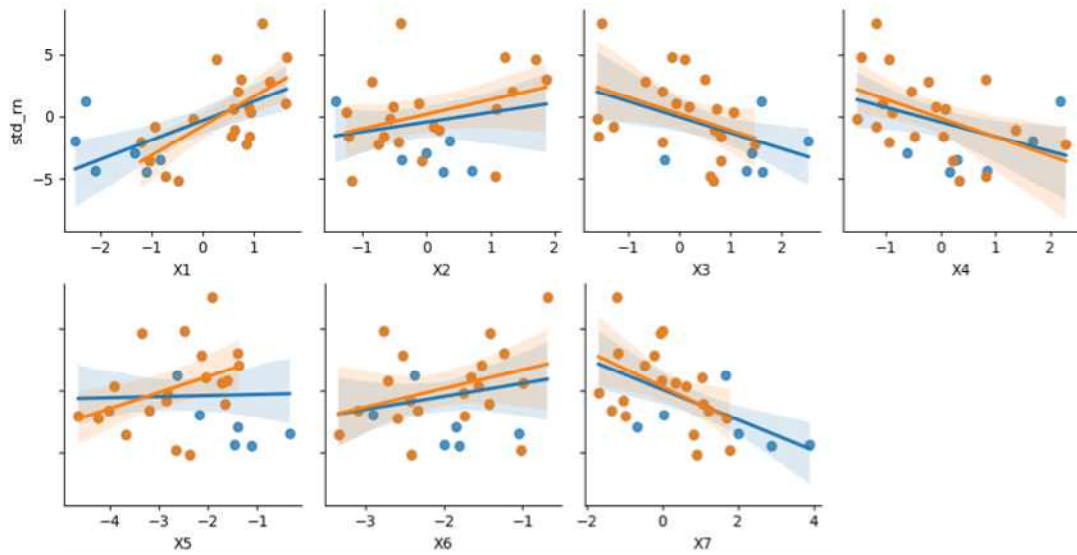


Figure 123. Scatter plots showing the relationship between predictors and standardized Chang-ma precipitation. Orange lines denote 1994~2014, and blue lines denote 1994~2020. X1 is NA_{SST} , X2 is NPC_{SST} , X3 is $CNINO_{SST}$, X4 is NIO_{SST} , X5 is BS_{SST} , X6 is $EUSC$, and X7 is WNP_{OLR} .




Figure 124. Bar chart showing standardized Chang-ma precipitation (skyblue) and model's prediction (blue).

(2) 예측인자 상관성 변화 상세 분석

앞 절에서 각 통계 모델별로 개발 이후 최근까지 예측인자와 예측 타깃의 상관성 변화를 알아보았는데, 상관성이 크게 낮아진 예측인자 들 중에서 8월 강수량 예측 통계 모델의 예측인자인 4~5월 평균 인도양 해수면 온도 편차의 상관성 변화에 대해 좀 더 자세히 살펴보았다.

봄부터 여름까지 지속되는 양의 인도양 해수면 온도 편차는 여름철 북반구 중위도 대기에 CGT 패턴을 유도할 수 있으며(Yang et al., 2009), 이에 따라 상층에서 우리나라 남쪽으로 양의

지위고도 편차, 북쪽으로 음의 지위고도 편차가 우세하고, 하층에서는 우리나라 남쪽에서 대류 억제체가 나타나 우리나라로 강수 유입을 증가하는 모습이 나타난다.

우리나라 8월 강수량과 4~5월 평균 인도양 해수면 온도 편차의 시계열 상관관계의 변화를 Figure 125에 나타내었다. 5년 이동상관계수가 2003년 이후로 감소하는 추세를 나타내고, 11년 이동상관계수는 2010년 이후 반대가 되는 것을 알 수 있다.




Figure 125. Rolling Correlation between averaged Indian Ocean SST from April to May and averaged Korea precipitation in August.

우리나라 8월 강수량과 4~5월 평균 인도양 해수면 온도 편차의 상관성이 높았던 사례(1998년, 2002년, 2020년)와 상관성이 낮았던 사례(2015년, 2016년, 2019년)를 나누어 비교해보면 우리나라 남쪽으로 하층 지위고도 편차의 패턴이 두 사례에서 반대로 나타나는 특징이 있는데, 이로 인해 상관성이 낮을 때에는 우리나라 부근으로 북풍 편차가 우세하게 되어 강수 유입이 차단되는 모습이 나타난다. 2010년을 기준으로 기간을 나누어 4~5월 평균 해수면 온도를 500hPa 지위고도, 850hPa 바람장과 강수량에 회귀분석을 적용하여도 비슷한 패턴이 나타난다(Figure 126). 2010년 이전 기간에는 4~5월 인도양 해수면 온도가 높았을 때 우리나라 남쪽으로 양의 지위고도 편차가 유의하고, 뚜렷한 고기압성 순환의 영향으로 강수 유입이 증가하는 패턴이 나타났다. 반면에 2010년 이후에는 우리나라 남쪽으로 음의 지위고도 편차가 나타나고 일본 동남쪽을 중심으로 하는 저기압성 순환이 우리나라를 덮으면서 강수 유입이 차단되는 패턴이 나타났다.

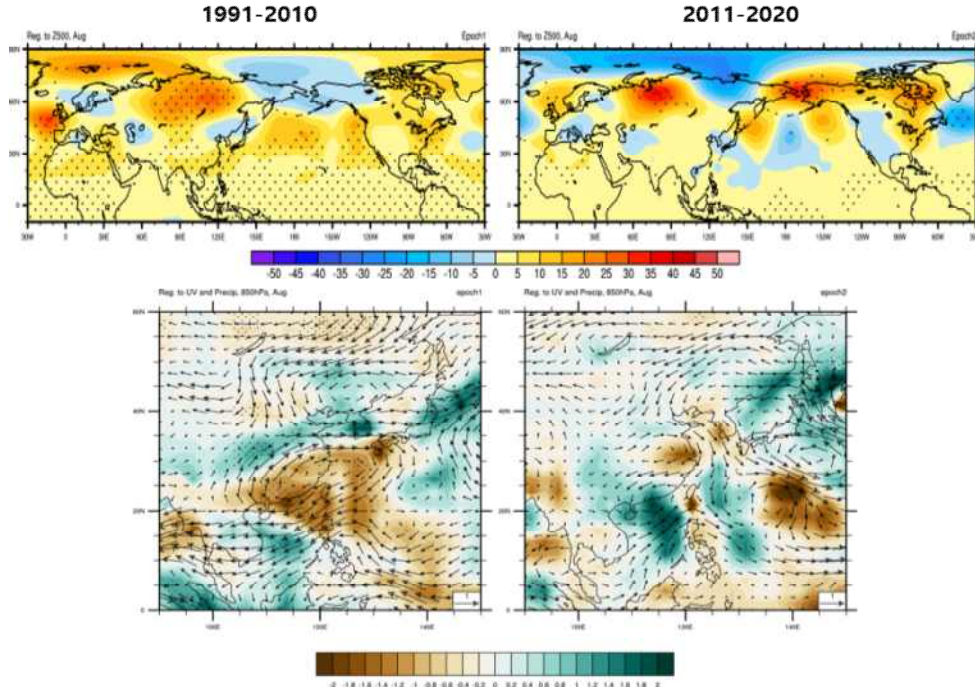


Figure 126. Regression map of April-May averaged sea surface temperature over Indian Ocean onto (upper) 500hPa geopotential height, (lower) 850hPa wind, and precipitation.

선행연구를 통해 8월 강수량과의 상관성이 변하게 된 원인을 조사해보았다. Yeo et al (2019)에서는 우리나라 강수량이 적고 북서태평양에 저기압성 순환이 발생할 때 대류권 하층에서 북서태평양에서 알래스카 방향으로 저-고-저의 wave-like 패턴이 나타나는 것을 보여주었는데, 이 패턴은 Figure 20에서 2010년 이후의 지위고도 회귀패턴과 유사하다. Yeo et al (2019)에서는 이와 같은 대기의 wave-like 패턴은 ENSO의 영향과는 관계가 없다고 밝혔기 때문에 우리나라 8월 강수량과 인도양 해수면 온도의 상관성을 변화시킨 원인에서 ENSO를 제외할 수 있다.

우리나라 8월 강수량과 인도양 해수면 온도의 상관성이 높았던 해와 낮았던 해 중 1998년(상관성이 높은 해)과 2016년(상관성이 낮은 해)의 특징적인 차이가 많은 선행연구에서 연구된 바 있다. 1998년과 2016년 모두 ENSO decaying 해이지만 대기순환장 패턴이 서로 반대되는 모습이 나타났다. 7월에 인도양에서 상승기류, 서태평양에서는 하강기류가 나타나는 모습이 두 해 모두 일치하였으나 8월로 넘어가면서 반대되는 패턴으로 변화하였다. 1998년 8월에는 7월과 비슷한 패턴이 이어지며 서태평양에서 강수가 억제되고 우리나라로 강수량이 많아지는 패턴이 나타났지만, 2016년에는 8월로 넘어가면서 인도양에서 하강기류, 서태평양에서 상승기류가 나타나면서 서태평양에는 강수가 많았고 우리나라로는 강수가 억제되는 패턴이 나타났다 (Figure 127). Chen et al (2019)은 이러한 차이가 나타난 원인으로 2016년 한 달 내내 서태평양에서 끊임없이 태풍이 발생하였음을 제시하였다. Yuan et al (2017)에서는 2016년 8월에 extreme MJO가 서태평양에서 25일간 활발하게 나타나면서 태풍 발생과 열대-아열대 순환에

영향을 줬지만, 1998년은 MJO가 인도양에서 활발하게 나타나면서 강한 서태평양 아열대 고기압에 의해 우리나라를 포함한 동중국 지역에 강수량이 많았다고 하였다. 그러나 2010년 전후 8월 일별 MJO phase의 빈도를 비교해본 결과 2010년 이전에는 phase 2가 20%로 가장 자주 나타났고, 2010년 이후에는 phase 1이 22%로 가장 자주 발생하였다(Figure 128). 따라서, 2010년 이후 회귀분석에서 특징적으로 나타났던 서태평양 저기압성 편차가 MJO에 의해 유도된 것이라고 하기에는 어려움이 있다.

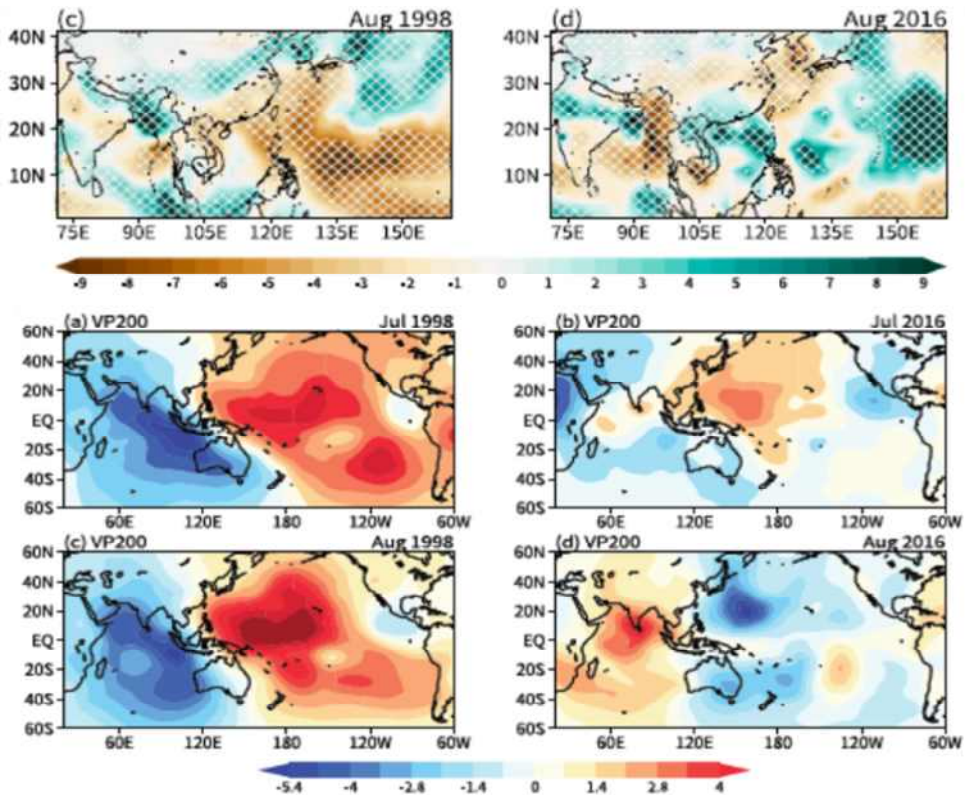


Figure 127. August precipitation and July-August 200hPa velocity potential in (left) 1998 and (right) 2016 (source: Chen et al., 2019)




Figure 128. Daily MJO phase frequency in August (Epoch1: 1991-2010, Epoch2: 2011-2020).

또 다른 연구에서는 바렌츠-카라해 해빙 편차와 동아시아 8월 강수량과의 연관성에 주목하였다. Shen et al. (2019)는 7~8월 바렌츠-카라해 해빙 면적이 감소하면 극 지역에서는 상층 발산, 카스피해 부근으로 상층 수렴이 나타나며 로스비 파동 전파를 통해 우리나라 상공으로 양의 지위고도 편차, 북서태평양과 일본 동쪽 해상에서 음의 지위고도 편차를 유도하면서 우리나라는 강수량이 적어질 수 있음을 보여주었다. 비슷하게 Du et al. (2019)에서도 봄철 바렌츠-카라해 해빙 감소에 의해 유도되는 여름철 북유럽 부근에서 기압능과, 바렌츠-카라해에서 시작되는 기압골이 함께 남동쪽으로 전파되며 중국 북동부를 중심으로 고기압성 순환이 발생하여 여름철 강수량 감소에 영향을 줄 수 있다고 하였다. 두 선행연구를 바탕으로 하여 바렌츠-카라해 해빙과 우리나라 8월 강수량의 상관성 변화를 회귀분석을 통해 살펴보았다.

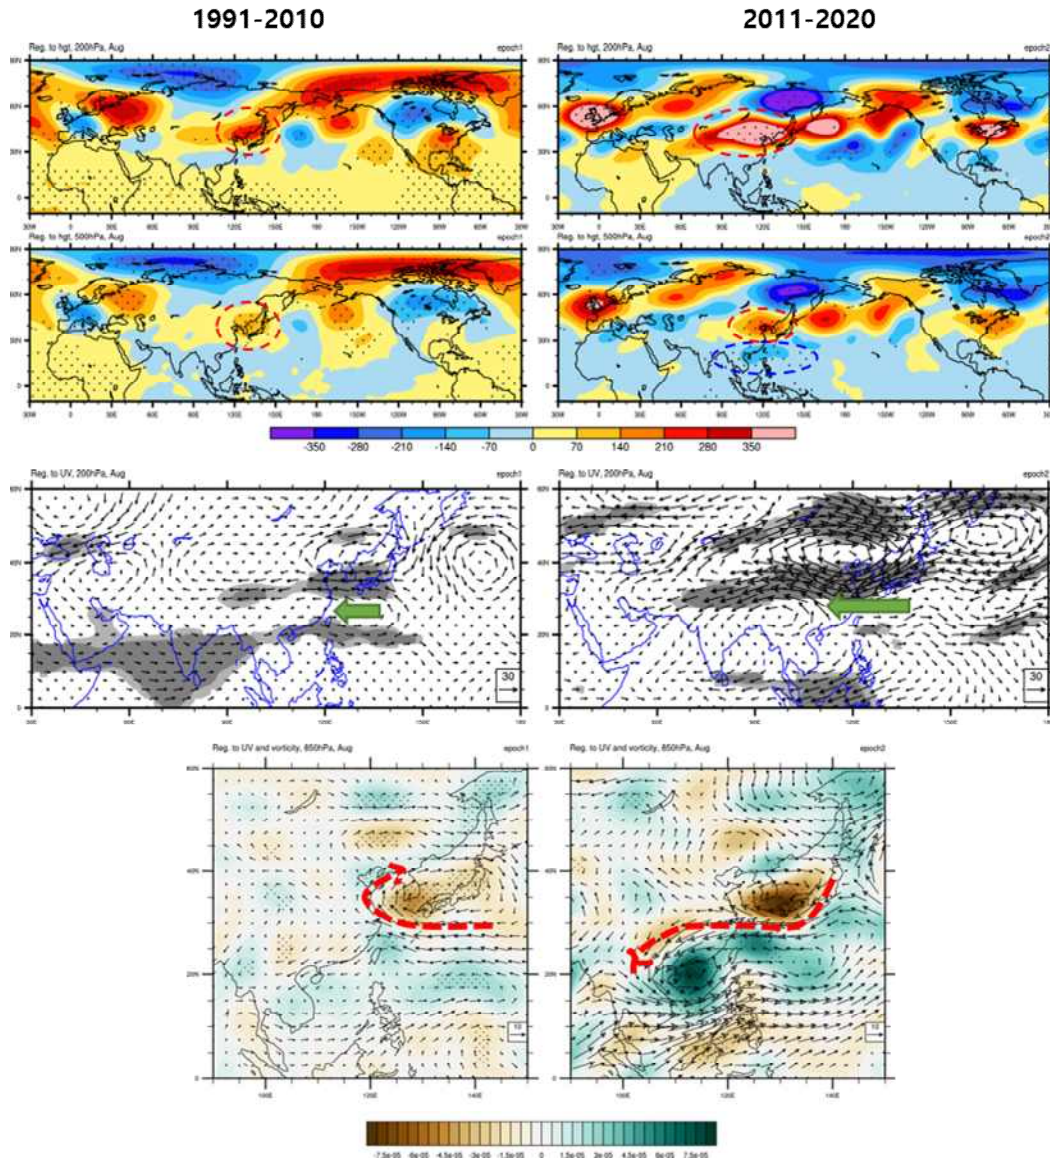


Figure 129. Regression map of Barents-Kara sea ice concentration onto geopotential height (200hPa and 500hPa), 200hPa wind, 850hPa wind and precipitation. Grey and black dots indicate significant regression coefficients at the 95% confidence levels.

Figure 129에서 두 기간을 비교해보면 200hPa 지위고도 편차장에서는 우리나라와 중국 북동부에 나타나는 양의 편차의 강도가 최근 기간에 더 강해지는 것을 볼 수 있다. 또 우리나라 상공으로 유의하게 나타나는 500hPa 양의 지위고도 편차가 최근 기간에 다소 북쪽으로 편향되고, 우리나라 남쪽으로 음의 지위고도 편차가 유의하게 나타남을 알 수 있는데, 이러한 패턴은 인도양 해수면 온도 편차와 8월 강수량의 최근 10년 회귀분석에서도 찾아볼 수 있다 (Figure 126). 최근 10년에 상하층 바람 편차의 강도가 강해졌고, 하층 바람 방향이 바뀌면서 우리나라로 수증기 유입을 차단하면서 강수량이 더 적어진 것을 알 수 있다.

비록 인도양 해수면 온도 영향의 변화에서 나타나는 바람 방향의 변화를 바렌츠-카라해 해빙의 영향으로 모두 설명하기에는 부족하지만, 일부 영향 편차장에서 비슷한 패턴이 나타나는 것을 확인하였다. 따라서 인도양 해수면 온도와 우리나라 8월 강수량의 상관성을 변화시키는 데에 바렌츠-카라해의 영향이 일부 있을 수 있다.

(2) 벤치마킹 통한 우리나라 1개월 전망 활용성 평가

(가) 우리나라 기온예보를 위한 위상정보 합성 모델 개발

① ENSO-MJO 위상정보 합성 통계모델

1개월 예보를 위해서는 현업에 활용 가능한 예측자료를 다양화할 필요가 있다. 또한 현재 역학모델에서는 대부분 편향된 예보 경향을 보이고 있으므로, 실제 예보를 할 때 제약이 된다. 따라서 1개월 예보에 대해서도 계절내 규모의 주요 기후 감시요소에 대한 대기 및 해양 변동성에 대한 정보가 필요하며, 이를 고려한 역학/통계 또는 역학과 통계모델의 정보를 함께 활용할 필요가 있다. NOAA/CPC에서는 ENSO-MJO의 위상정보의 합성을 통한 통계모델을 구축하여, 이에 대한 예측정보를 제공하고 있다(Johnson et al., 2014). 또한 MJO 위상에 따른 시간 지연 합성장을 생산하여 예측을 생산하고 있다(Baxter et al., 2014). ENSO 및 MJO는 특히 겨울철 기후예측에 가장 큰 영향을 미치는 기후인자이며, 관련한 메커니즘 등에 관해서도 많은 연구가 이루어진 바 있으므로, 이들 예측인자 정보를 활용하여 예측을 개선하고자 하는 노력이 필요하다. 이러한 노력의 일환으로 동아시아 지역에 대해 ENSO-MJO의 위상정보의 합성 통계모델을 구축하여 온도를 예측하고 이에 대한 예측정보를 제공하였다(Figure 130).

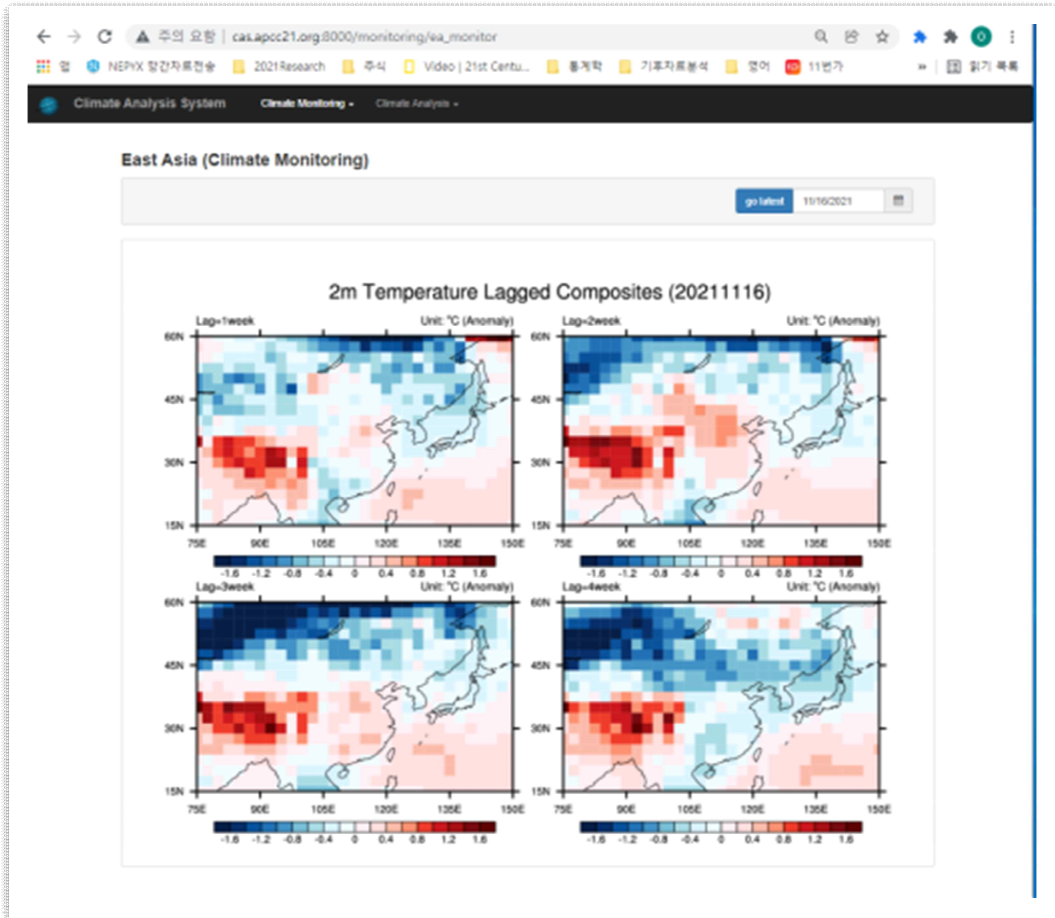


Figure 130. Time-lagged composite temperature over East Asia from week1 to week4 by utilizing the information of ENSO and MJO phases.

② 초기 MJO 위상정보에 따른 시간 지연 합성장

위상정보의 합성장을 실제 현업 장기예보에 활용하기 위해서는 우리나라 주변 온도변화에 대한 메커니즘에 대한 정보가 필수적이다. 특히, 많은 선행연구들에 따르면 우리나라를 포함한 동아시아 지역의 온도변화에 미치는 MJO의 영향은 뚜렷하다(e.g., Song et al., 2019; Seo et al., 2016; Kim et al., 2020; Yoo et al., 2018). MJO 위상이 3일 때, 우리나라를 포함한 동아시아 지역 주변 온도는 점차 상승하는 것으로 나타났다(Figure 131). 이는 인도양에 대류가 발생했을 때, local 해들리 순환을 강화시켜 북태평양지역 고기압성 순환을 유도하게 되는데, 때문에 동아시아 제트 남쪽으로 southerly divergent wind가 강화된다. 반면 동아시아 제트 북쪽으로 고층 westerly가 증가하게 되면서 동아시아 제트는 북쪽으로 이동하게 된다. 이로 인해 동아시아 기압골, 알루산 저기압 등을 약화시켜 우리나라를 포함한 동아시아 지역에 온도가 증가하게 된다. 반면, MJO 위상이 7일 때는 우리나라를 포함한 동아시아 지역 주변 온도가 점차 하강하는데, 이는 위상이 7일대와는 반대의 기작으로 동아시아 제트가 남쪽으로 이동하게 되어, 온도를 하강시키는 역할을 한다(Figure 132).




Figure 131. Weekly temperature anomalies over Korean Peninsula, conditional on the initial state of the MJO phase 3.




Figure 132. Weekly temperature anomalies over Korean Peninsula, conditional on the initial state of the MJO phase 7.

라. 현업 장기에보 지원

(1) WMO 장기예보 선도센터 운영 및 개선

(가) WMO 장기예보 선도센터 운영

WMO 장기예보 선도센터의 계절예측 현업은 앞서 언급한 바와 같이 한달에 걸쳐 수행된다. 매달 기상청 기후예측과에 WMO 장기예보 선도센터 운영에 관한 보고서를 제출하여 기상청 기후예측과와 현업 측면의 이슈에 대해 공유하고 있다. 21년에는 GPC Pretoria가 현지 시스템의 문제로 10월까지 계절예측 자료를 제공하지 않았으며, 다른 GPC의 계절예측 자료 제공일은 Table 30과 같다.

Table 30. Date of data reception from GPCs.

GPC	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV
Beijing	11	9	11	12	9	14	14	12	13	15	12
CMCC	-	-	-	-	-	-	-	-	14	13	13
CPTEC	13	10	12	12	12	9	12	11	15	15	11
ECMWF	14	14	14	14	14	14	14	14	14	14	14
EXETER	11	11	12	12	11	11	12	11	13	11	11
Melbourne	8	9	9	5	7	7	9	9	9	10	9
Montreal	5	9	9	5	10	7	9	8	9	10	8
Moscow	15	19	12	13	14	11	12	12	13	10	12
Offenbach	5	9	9	12	-	6	12	4	13	4	4
Pretoria	-	-	-	-	-	-	-	-	-	-	18
Seoul	12	18	12	13	11	8	13	10	15	12	11
Tokyo	14	14	12	12	15	18	13	14	13	13	12
Toulouse	14	14	14	14	14	14	15	14	14	14	14
Washington	12	12	12	12	12	14	13	12	13	12	12

WMO 장기예보 선도센터에 참여하는 개별 GPC와 PMME의 실시간 확률 예측 성능을 살펴보았다 (Figure 133, Figure 134). 각 카테고리별 ROC Score의 시계열 분석에 사용된 예측기간은 2017년 JFM부터 2021년 ASO이다. Figure 133과 Figure 134에서 붉은 실선은 MME를 나타내며, 각 점들은 개별 GPC를 의미한다. 파란색으로 표시된 점은 ECMWF의 예측 성능을 나타낸다. Table 31과 Table 32는 전구영역과 동아시아 영역에 대한 연도별 ROC Score의 예측성능(AN, NN, BN카테고리의 평균)을 나타내며, 전구에 비해 동아시아 영역의 예측성능이 낮게 나타난다. 2021년 전구영역의 개별 GPC와 MME의 기온 및 강수의 예측력을 살펴보면, MME는 기온의 경우 0.7, 강수는 0.58로 개별 GPC들에 비해 상대적으로 높은 ROC Score를 가진다. 개별 GPC 중 GPC Tokyo의 예측성능이 전구영역과 동아시아 영역 모두에서 높은 것으로 나타났다. 보다 상세한 분석을 통해 개별 GPC의 예측성능을 예측특성별로 평가하고 정보를 제공할 수 있다면 기상청 계절예측 정확도 향상에 기여 할 수 있을 것으로 보인다.

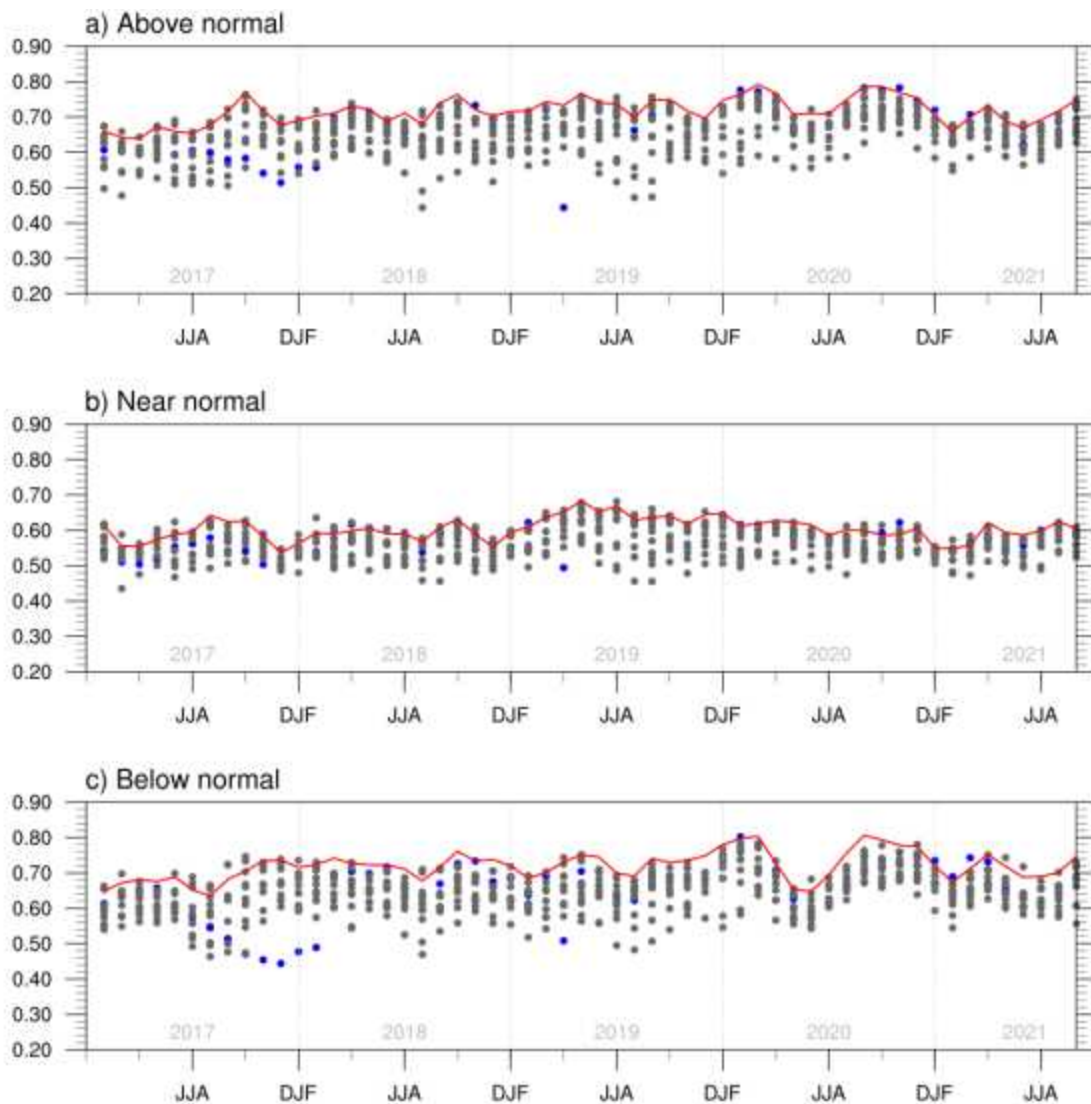


Figure 133. Relative Operating Characteristic (ROC) score aggregated over globe of probabilistic real-time forecast of 2m temperature for three terciles, i.e., a) the above normal, b) near normal and below normal for the period JFM2017-ASO2021. ROC score for PMME prediction is indicated by red line. The grey dots indicate the ROC score of the WMO LC-LRFMME individual GPCs and the blue dot indicates ECMWF.

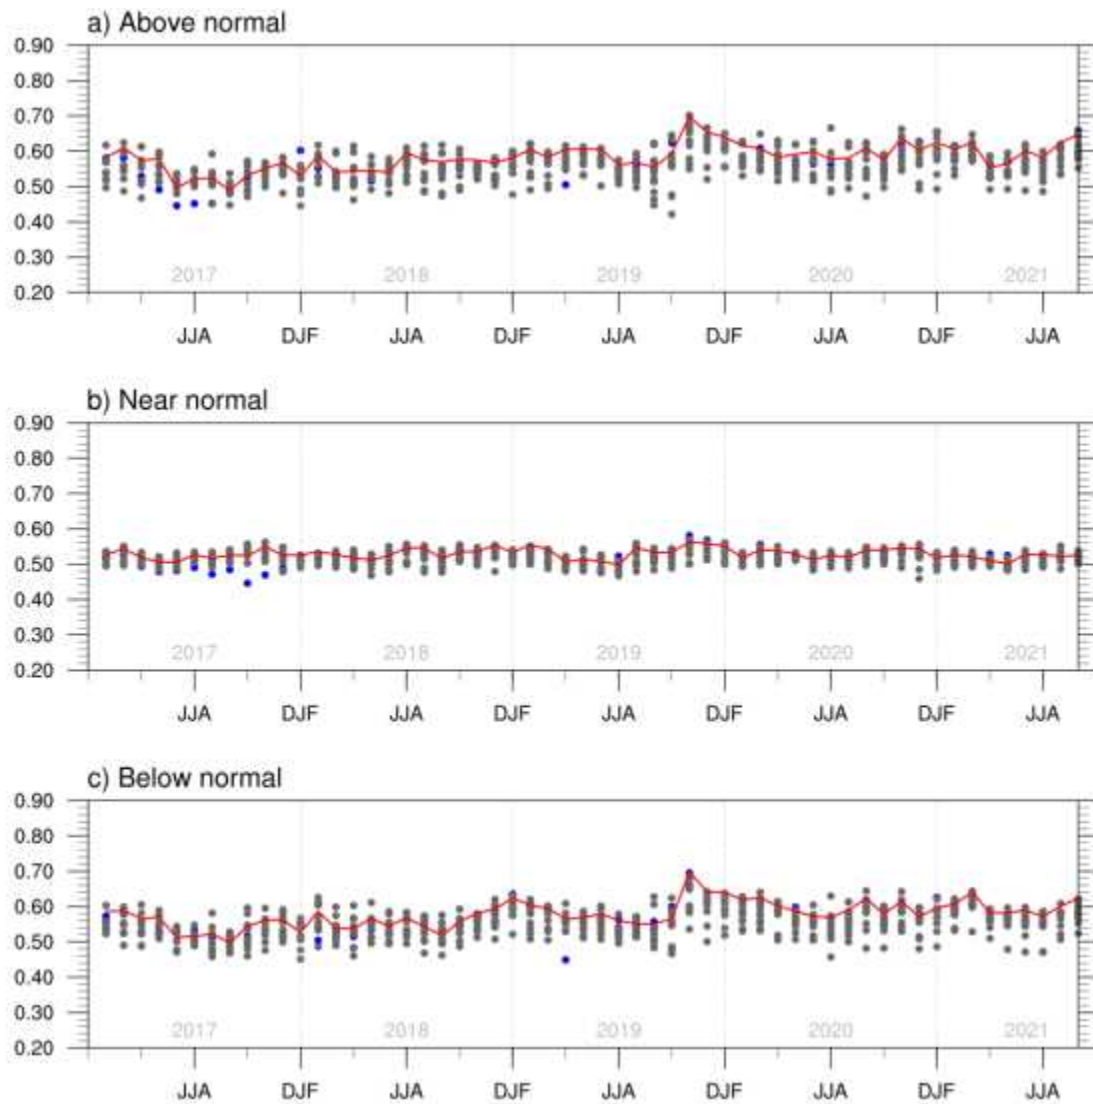


Figure 134. Relative Operating Characteristic (ROC) score aggregated over globe of probabilistic real-time forecast of precipitation for three terciles, i.e., a) the above normal, b) near normal and below normal for the period JFM2017-ASO2021. ROC score for PMME prediction is indicated by red line. The grey dots indicate the ROC score of the WMO LC-LRFMME individual GPCs and the blue dot indicates ECMWF.

Table 31. Yearly Relative Operating Characteristic (ROC) score aggregated over globe of probabilistic real-time forecast of 2m temperature and precipitation.

No.	GPC	2016		2017		2018		2019		2020	
		T2M	PREC	T2M	PREC	T2M	PREC	T2M	PREC	T2M	PREC
1	Beijing	0.58	0.52	0.58	0.51	0.62	0.53	0.65	0.54	0.64	0.53
2	CPTEC	0.56	0.52	0.55	0.51	0.57	0.50	0.56	0.51	0.60	0.52
3	ECMWF	0.65	0.57	0.56	0.52	0.65	0.54	0.66	0.57	0.68	0.57
4	Exeter	0.68	0.58	0.63	0.54	0.65	0.55	0.67	0.56	0.66	0.56
5	Melbourne	0.62	0.56	0.57	0.52	0.60	0.53	0.61	0.55	0.64	0.56
6	Montreal	0.64	0.57	0.61	0.53	0.64	0.55	0.66	0.57	0.65	0.57
7	Moscow	0.60	0.53	0.58	0.50	0.57	0.51	0.60	0.52	0.61	0.51
8	Offenbach	—	—	0.64	0.53	0.64	0.54	0.67	0.56	0.64	0.55
9	Pretoria	0.55	0.54	0.53	0.50	0.55	0.52	0.55	0.53	—	—
10	Seoul	0.68	0.58	0.63	0.54	0.64	0.55	0.66	0.56	0.65	0.56
11	Tokyo	0.69	0.59	0.66	0.55	0.66	0.56	0.69	0.59	0.69	0.58
12	Toulouse	—	—	—	—	—	—	0.68	0.56	0.65	0.56
13	Washington	0.65	0.58	0.62	0.53	0.63	0.56	0.64	0.57	0.64	0.58
	MME	0.69	0.59	0.65	0.54	0.68	0.55	0.70	0.58	0.70	0.58

- ※ Montreal : 2014JJA~2016DJF의 경우, Montreal3과 Montreal4의 ROC 평균값
- ※ Offenbach:2017SON이후자료
- ※ Pretoria:2015AMJ이후자료
- ※ Observation:PREC/CAMS-OPI,T2M/NCEP-R1
- ※ 2016OND이전은개별hindcast사용
- ※ 2016OND예측부터공통hindcast기간(1993~2009)사용
- ※ 전체기간위도별가중치적용
- ※ ROC값은AN, NN, BN의평균값을의미

Table 32. Yearly Relative Operating Characteristic (ROC) score aggregated over East Asia of probabilistic real-time forecast of 2m temperature and precipitation.

No.	GPC	2016		2017		2018		2019		2020	
		T2M	PREC	T2M	PREC	T2M	PREC	T2M	PREC	T2M	PREC
1	Beijing	0.50	0.50	0.54	0.50	0.56	0.56	0.59	0.56	0.62	0.53
2	CPTEC	0.50	0.49	0.54	0.51	0.51	0.51	0.47	0.50	0.58	0.54
3	ECMWF	0.52	0.57	0.60	0.51	0.58	0.56	0.59	0.57	0.66	0.60
4	Exeter	0.54	0.56	0.58	0.49	0.62	0.58	0.60	0.56	0.63	0.57
5	Melbourne	0.55	0.54	0.53	0.50	0.58	0.53	0.58	0.54	0.59	0.55
6	Montreal	0.49	0.57	0.54	0.50	0.59	0.57	0.57	0.55	0.59	0.58
7	Moscow	0.51	0.52	0.56	0.50	0.51	0.52	0.50	0.51	0.57	0.55
8	Offenbach	—	—	0.56	0.51	0.59	0.57	0.60	0.56	0.64	0.58
9	Pretoria	0.48	0.55	0.50	0.50	0.50	0.56	0.54	0.56	—	—
10	Seoul	0.55	0.56	0.59	0.51	0.59	0.58	0.58	0.56	0.60	0.59

11	Tokyo	0.55	0.59	0.61	0.53	0.62	0.57	0.58	0.58	0.66	0.58
12	Toulouse	-	-	-	-	-	-	0.62	0.57	0.64	0.56
13	Washington	0.56	0.56	0.58	0.50	0.59	0.58	0.61	0.57	0.63	0.61
	MME	0.54	0.57	0.59	0.51	0.61	0.58	0.60	0.58	0.67	0.61

- ※ Montreal : 2014JJA~2016DJF의 경우, Montreal3과 Montreal4의 ROC 평균값
- ※ ECMWF:2015~2016년 검증자료 생산
- ※ Offenbach:2017SON이후자료
- ※ Pretoria:2015AMJ이후자료
- ※ Observation:PREC/CAMS-OPI,T2M/NCEP-R1
- ※ 2016OND이전은 개별hindcast사용
- ※ 2016OND예측부터 공통hindcast기간(1993~2009)사용
- ※ 전체기간위도별가중치적용
- ※ ROC값은AN, NN, BN의평균값을의미

(나) WMO 장기예보 선도센터 계절 예측 시스템 개선

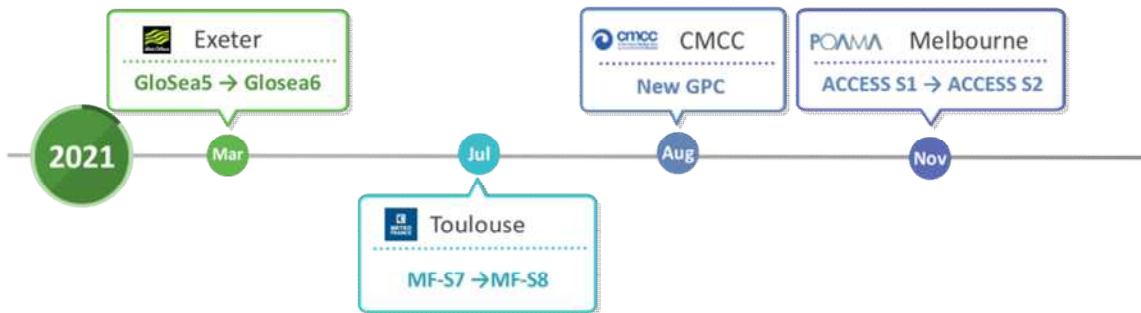


Figure 135. Improvements of operational system at WMO LC-LRFMME in 2021.

WMO 장기예보 선도센터에 참여하고 있는 GPC는 계절예측의 정확도 향상을 위해 지속적으로 계절예측시스템 개선하고 있다. 각 GPC의 계절예측시스템 개선으로 인한 예측 성능 향상은 WMO 장기예보 선도센터 다중 모델 앙상블 예측성능 향상을 기대할 수 있을 것이다. 2021년에 GPC UKMO, Toulouse, Melbourne의 계절예측 시스템이 개선되어 WMO 장기예보 선도센터 다중모델 앙상블 예측 시스템에도 반영되었다 (Figure 135). GPC UKMO는 2021년 2월부터 GloSea5에서 GloSea6로 개선되었으며, Toulouse는 7월부터 System 7에서 8으로 개선되었다. 또한 GPC Melbourne는 11월부터 ACCESS-S1에서 ACCESS-S2로 변경되어 WMO장기예보 선도센터에 반영되었다. 그리고 2021년 8월에는 이탈리아 (GPC CMCC, CentroEuro-Mediterraneosui CambiamentiClimatici)가 현업운영에 추가되어 현재 14개 GPC로부터 계절예측자료를 수집하여 MME 예측자료를 생산하고 있다. 이번 절에서는 GPC 계절예측 모델의 업데이트 현황과 GPC CMCC의 추가도입과 관련하여 수행되었던 내용을 기술하고자 한다.

① GPC 계절예측모델 업데이트 현황

GPC UKMO 계절예측 모델은 WMO 장기예보 선도센터 다중모델 앙상블 예측시스템에 2021년 2월 (2021MAM예측)부터 적용되었다. 개선된 GPC UKMO의 계절예측 모델은 기존 (GloSea5)과 동일한 Tier-2의 대기모델시스템(GloSea6)이며, GloSea5와 대기, 해양, 지면, 해빙 모델의 물리적인 세부적인 차이를 가질 뿐 해상도 등 대부분의 모델 특성은 동일하다.

GPC Toulouse는 2021년 7월 MF-S7에서 MF-S8로 계절 예측 모델이 개선되었다. 개선된 MF-S8은 기존 MF-S7와 대기모델은 동일하나 해양 모델의 공간해상도가 증가하였고, hindcast와 Forecast 앙상블 생산 방법이 ERA5를 이용한 3 lagged initialization 방법으로 변경되었다. 각 초기장별로 25, 25, 1개의 앙상블 초기장을 만들어 forecast에서는 총 51개의 앙상블을 생산한다. 상세한 개선 사항은 Table 33에서 확인 할 수 있다.

GPC Melbourne 계절예측 모델은 ACCESS-S1에서 ACCESS-S2로 변경되었으며, 2021년 11월부터 WMO 장기예보 선도센터 다중모델 앙상블 예측시스템에 적용되었다. 기존 ACCESS-S1 계절예측 시스템에서 개선된 ACCESS-S2 계절 예측 시스템은 hindcast 기간이 1990~2012년에서 1981~2018년까지 확장되어 최근의 기후변동성을 반영하고자 하였다. 대기모델의 초기장은 hindcast는 ERA-interim을 forecast는 NWP ACCESS-G자료를 이용한다. 앙상블의 개수는 기존의 11개에서 3개로 변경되었으며, 최대 6개월의 선행시간의 자료를 제공한다. 매일 hindcast 자료를 생산하는 특징을 가진다. 이에 대한 상세한 정보는 Table 34에 나타내었다.

GPC CMCC 계절예측 모델은 2021년 8월부터 WMO 장기예보 선도센터 다중모델 앙상블 예측시스템에 적용되었다. 계절예측 모델의 상세한 정보는 Table 35에 나타내었다.

Table 33. Improvements of long-range forecast system from GPC Toulouse.

	September 2018	July 2021
Is it a coupled forecast system?		Yes
Is it a Tier-2 forecast system?		No
Atmospheric model resolution	T359L91	T359L137
Ocean model (if applicable)	NEMO v3.6 , ORCA 1° grid, 75 model levels. Frequency of coupling is 3 hours	NEMO v3.6 , ORCA 1/4° grid, 75 model levels. Frequency of coupling is 3 hours
Source of atmospheric initial conditions	ECMWF operational analysis	
Source of ocean initial conditions	Mercator-ocean analysis	
If Tier-2, what is the source of SST predictions?	N/A	
Hindcast period	1993-2016	1993-2018
Ensemble size for the hindcasts	25 members	
How is the hindcast ensemble configured?	1 atmospheric condition from ERA-Interim – 1 oceanic condition from Mercator analysis, ensemble generation by stochastic dynamics technique (Batté and Déqué 2016).	3 lagged initialization (12 runs, 12 runs, 1 run), each built with 1 atmospheric condition from ERA5 and 1 oceanic condition from Mercator analysis. For the 2 first initialization dates, ensemble generation by stochastic dynamics technique (Batté and Déqué 2016). The last initialization date begins the 1st of initialization month.
Ensemble size for the forecast	51 members	
How is the forecast ensemble configured?	generated by a stochastic dynamics technique in addition to using a lagged initialization	Same method as for the hindcast. 3 lagged initialization (25 runs, 25 runs, 1 run).
Length of forecasts	7 months	
Data format	GRIB 2 or ascii for digital data Gif for graphics	
What is the latest date predicted anomalies for the next month/season become available?	8th of each month	13th of each month
How are the forecast anomalies constructed?	Departures from the model climate estimated by the hindcast integrations	
URL where forecast(maps) are displayed	http://seasonal.meteo.fr	
Point of Contact	JM Soubeyroux (Jean-Michel.soubeyroux@meteo.fr) Jacques Richon (Jacques.richon@meteo.fr) Christian Viel (Christian.viel@meteo.fr)	

Table 34. Improvements of long-range forecast system from GPC CMCC.

System name: SPS3.5	
Implemented: October 2020	
Is it a coupled forecast system?	Yes
Is it a Tier-2 forecast system?	No
Atmospheric model resolution	$\frac{1}{2}^\circ$ approximately on a cube-sphere quasi-regular grid
Ocean model (if applicable)	NEMO3.4, $\frac{1}{4}^\circ$ on a nearly isotropic, curvilinear, tri-polar grid.
Source of atmospheric initial conditions	ECMWF
Source of ocean initial conditions	Global Ocean 3D-VAR Data Assimilation System (C-GLORS)
If Tier-2, what is the source of SST predictions?	N/A
Hindcast period	24 years: 1993-2016
Ensemble size for the hindcasts	40 members
How is the hindcast ensemble configured?	Chosen at random among 120 combinations of 10 atmosphere ICs (time lagging at 12h interval), 3 land ICs (forced during previous month by ECMWF and NCEP analyses and mean of the two) and 4 ocean ICs (perturbing ocean observations)
Ensemble size for the forecast	50 members
How is the forecast ensemble configured?	Chosen at random among 270 combinations of 10 atmosphere ICs (time lagging at 12h intervals), 3 land ICs (forced during previous month by ECMWF and NCEP analyses and mean of the two) and 9 ocean ICs (perturbing ocean observations)
Length of forecasts	6 months
Data format	NetCDF
What is the latest date predicted anomalies for the next month/season become available?	10th of the month
How are the forecast anomalies constructed?	By subtracting the 24year hindcast mean
URL where forecast(maps) are displayed	https://sps.cmcc.it/
Point of Contact	Andrea Borrelli (andrea.borrelli@cmcc.it)
	Silvio Gualdi (silvio.gualdi@cmcc.it)

Table 35. Improvements of long-range forecast system from GPC Melbourne.

	ACCESS-S1	ACCESS-S2
	August 2018	Nov 2021
Is it a coupled forecast system?	Yes	
Is it a Tier-2 forecast system?	No	
Atmospheric model resolution	N216 ~ 60km horizontal and 85 vertical levels	
Ocean model (if applicable)	25km horizontal and 75 vertical levels	
Source of atmospheric initial conditions	ERA-Interim for the hindcast and operational NWP ACCESS-G for real time	
Source of ocean initial conditions	UKMO	
If Tier-2, what is the source of SST predictions?	N/A	
Hindcast period	1990-2012	1981-2018
Ensemble size for the hindcasts	11 members for each restart time for the hindcast	3 members for each restart time for the hindcast
How is the hindcast ensemble configured?	10 perturbed members and one central member to the atmospheric model	3 perturbed members and one central member to the atmospheric model
Ensemble size for the forecast	11 members for seasonal forecasts in real time	
How is the forecast ensemble configured?	10 perturbed members and one central member to the atmospheric model	
Length of forecasts	6 full months	
Data format	netcdf	
What is the latest date predicted anomalies for the next month/season become available?	Two days after the beginning of each month	
How are the forecast anomalies constructed?	Based on hindcast climatology	
URL where forecast(maps) are displayed	Poama.bom.gov.au	
Point of Contact	Dr Shuhua Li	

② GPC CMCC 자료 표준화 및 검증

GPC로부터 수신된 예측자료를 WMO 장기예보 선도센터의 계절예측시스템에 추가하기 위해서는 표준화 과정을 거쳐야 하고, 이를 위해서는 GPC CMCC 자료의 특성에 맞는 표준화 시스템이 필요하다. 표준화 과정을 거쳐 MME 예측 시스템에 포함하기 전에 GPC CMCC 계

절예측 모델 자체의 예측성을 파악하고 다른 GPC들의 예측성과 비교분석 하기 위해 다음 단계의 적합성 판정 과정을 거쳤다.

1) 표준화 코드를 통해 생산된 forecast anomaly의 공간적 패턴이 WMO 장기예보 선도센터 MME 예측장과의 유사성 판단

2) 과거 hindcast기간에 대한 타 GPC들과의 ACC를 비교하였을 때, GPC CMCC의 예측성 수준

2021년 8월에 생산된 3개월 예측자료에 대해 본 검증을 수행하여 GPC CMCC forecast anomaly 패턴과 WMO 장기예보 선도센터 MME 예측 결과의 공간적인 패턴이 유사한 것으로 보아 표준화 과정은 오류가 없이 수행되었고 (Figure 136, 137), 1993~2009기간의 여름철(JJA)과 겨울철(DJF) 동안의 기온과 강수 예측성을 WMO 장기예보선도센터 MME 예측정보와 타 GPC와 비교 해 보았을 때 GPC CMCC의 ACC는 다른 GPC와 비슷한 수준에 있다고 판단되었다 (Figure 138, 139). 이에 따라 2021년 8월부터 GPC CMCC는 WMO 장기예보 선도센터의 계절예측 현업시스템에 포함하였고, 홈페이지를 통해서 이 GPC의 예측자료를 제공하기 시작하였다.

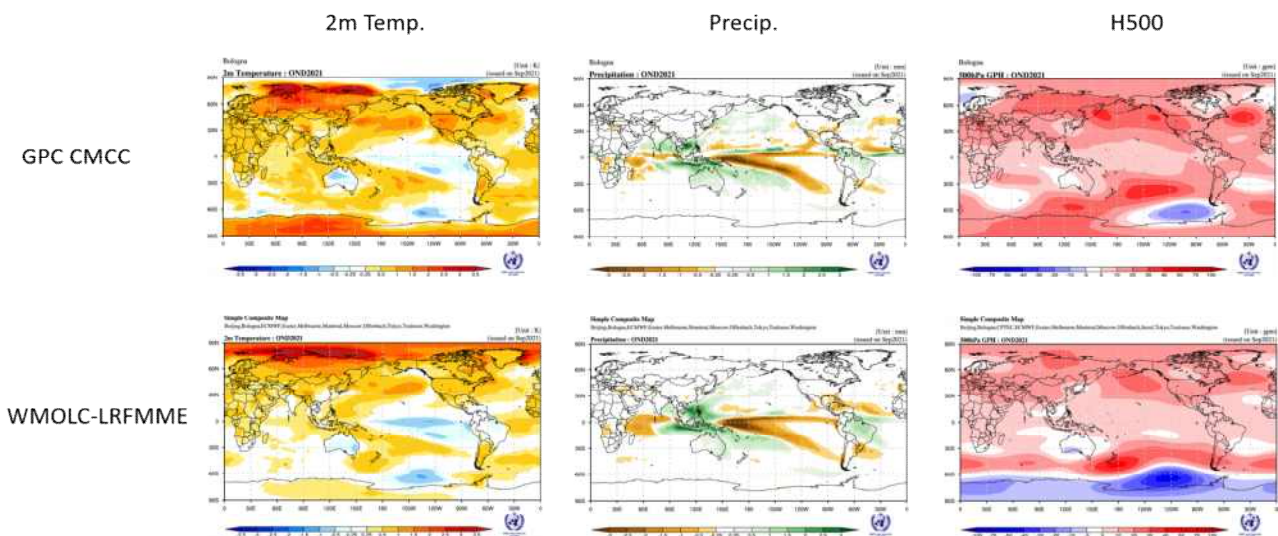


Figure 136. Deterministic forecast for OND2021 GPC CMCC and WMOLC-LRFMME.

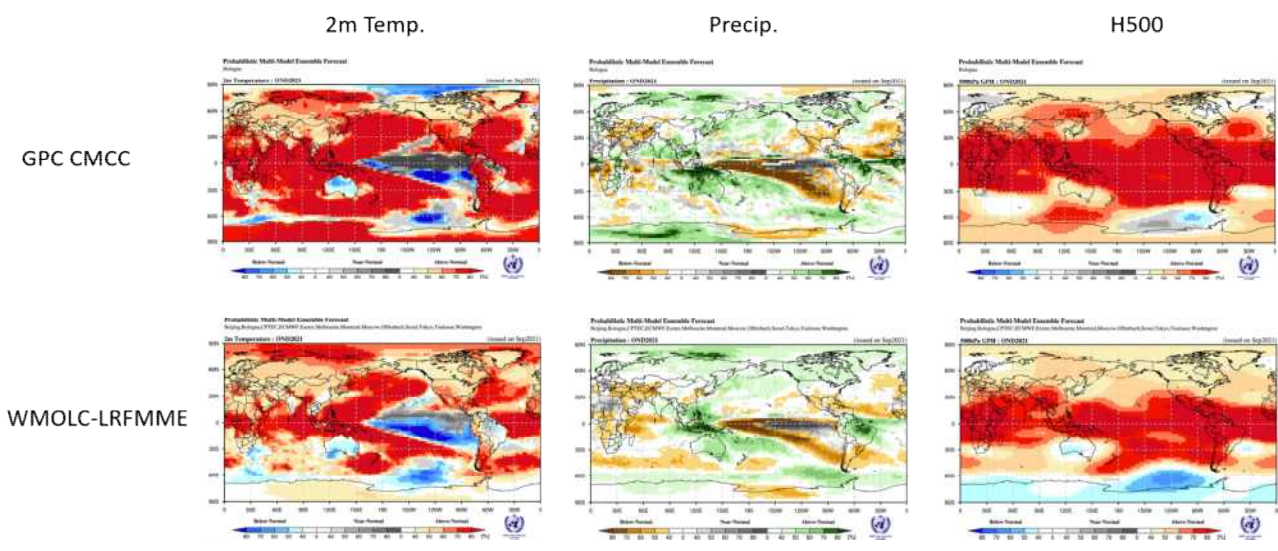


Figure 137. Probabilistic forecast for OND2021 from GPC CMCC and WMOLC-LRFMME.

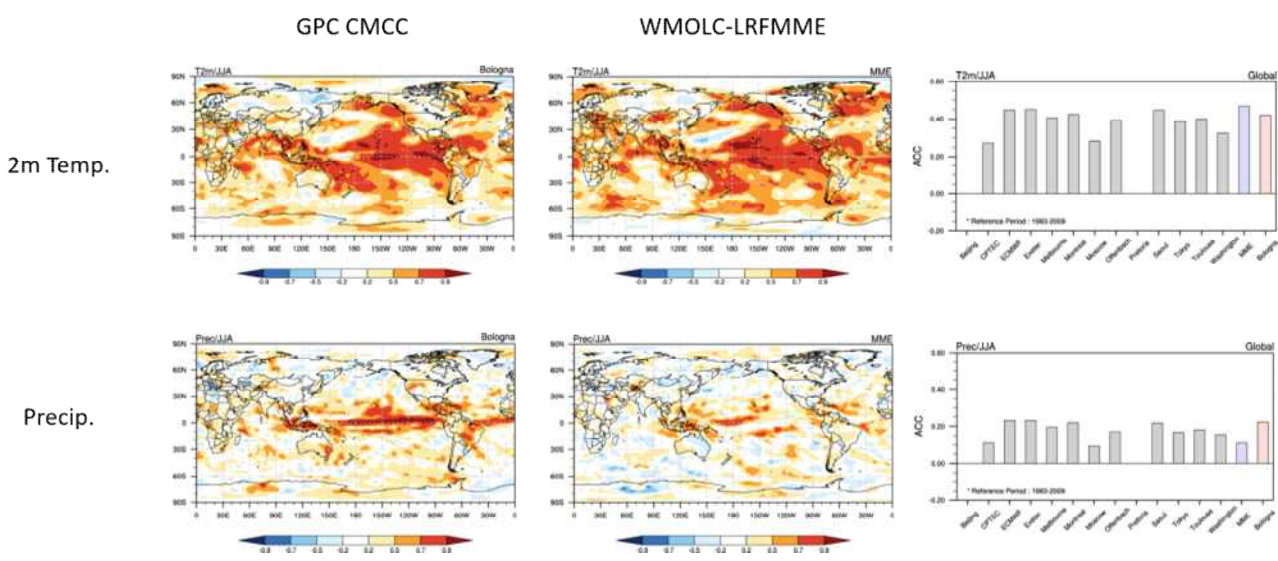


Figure 138. Anomaly correlation coefficient (ACC) for JJA forecast for the period 1993-2009.

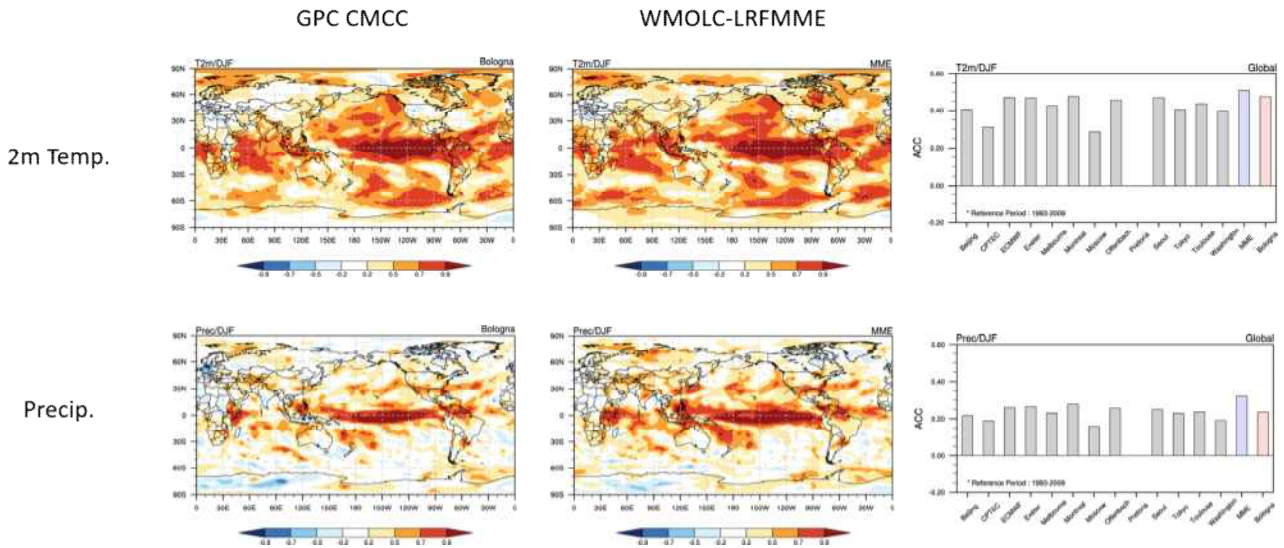


Figure 139. Anomaly correlation coefficient (ACC) for JJA forecast for the period 1993-2009.

(다) WMO 장기예보 선도센터 계절 예측 자료 제공

① 기상청 3개월 전망 지원

기상청은 현재 1개월 및 3개월 전망 발표를 통해 주별·월별 기압계 동향 및 전망, 기온 강수량 예보 등을 발표하고 있으며, 3개월 장기예보 생산을 위해 기상청 계절 예측 현업 모델 뿐만 아니라 다양한 기관에서 생산된 예측 결과를 활용하여 토의하고 있다. WMO 장기예보 선도센터에서 생산하는 3개월 MME 예측자료도 기상청의 3개월 전망을 위한 중요한 참고자료로 활용되고 있다. 따라서 WMO 장기예보 선도센터는 매월 3개월 전망 내부토의만을 위한 다양한 예측 콘텐츠(기온, 강수량, 지위고도)를 생산하여 지속적으로 제공하고 있을 뿐만 아니라 Figure 140과 같이 한반도 영역에 대한 각 개별 GPC 및 MME 예측 결과표를 생산하여 기상청의 3개월 전망 의사결정을 위해 매달 자료를 제공하고 있다. 2021년에는 GPC CMCC가 WMO 장기예보 선도센터에 추가되면서 그동안 제공되었던 Figure 140에 GPC CMCC가 추가될 수 있게 예측 결과표를 수정하여 제공하였다. 또한 2020년부터는 한반도 영역에 대한 기온, 강수량에 대한 개별 GPC 및 MME 예측 확률 그래프를 생산하여 제공함으로써 기후예측 생산을 위한 다양한 참고 콘텐츠 확대에 기여한바 있다 (Figure 141, Figure 142). 올해는 Figure 141에 한반도의 MME 예측 확률을 추가하여 예보관이 확률값을 직접적으로 확인하여 예보에 활용할 수 있도록 하였다. 또한 2021년 5월부터 기상청 기후정보포털 홈페이지 (<http://www.climate.go.kr/home/>)를 통해 WMO 장기예보 선도센터 계절예측자료가 제공되기 시작하였다.

3 month Outlook (2021Dec-2022Feb)

Issued Date : 2021.11.15

GPCs		2m Temp.						Prec.					
		Dec		Jan		Feb		Dec		Jan		Feb	
GPC	Seoul	0		+		+		0/-		0		0/-	
		EQ		50% (+)		48% (+)		48% (0)		42% (-)		47% (-)	
	Melbourne	0/+		+		+		0/-		0/-		0	
		59% (0)		49% (+)		71% (+)		51% (-)		50% (-)		EQ	
	ECMWF	-		0/+		0		0/-		0		0	
		50% (-)		41% (+)		EQ		51% (-)		EQ		EQ	
	Montreal	0		+		+		-		0/+		0/-	
		EQ		46% (+)		50% (+)		56% (-)		46% (+)		42% (0)	
	Moscow	0/+		+		0		0		0/+		0	
		48% (+)		63% (+)		42% (+)		46% (0)		47% (+)		EQ	
	CPTEC	0		0		0/+		0/-		-		0	
		EQ		41% (0)		42% (+)		48% (-)		66% (-)		43% (0)	
	Beijing	+		+		+		0		0		0	
		71% (+)		59% (+)		50% (+)		42% (0)		42% (+)		EQ	
	Toulouse	+		+		+		0/-		0		0	
		50% (+)		56% (+)		53% (+)		45% (-)		EQ		EQ	
	Washington	0/-		+		+		-		0/-		0	
		42% (-)		53% (+)		77% (+)		77% (-)		49% (-)		EQ	
Exeter	0		+		+		0/-		0		0		
	EQ		50% (+)		56% (+)		49% (-)		43% (-)		43% (+)		
Tokyo	0/-		0		0		0/-		0/-		0		
	45% (-)		EQ		EQ		46% (-)		43% (0)		EQ		
Pretoria													
Offenbach	0/-		+		+		-		0		0		
	EQ		44% (+)		50% (+)		61% (-)		EQ		EQ		
CMCC	0/+		0/+		0/+		0		0		0		
	40% (+)		EQ		EQ		40% (0)		EQ		EQ		
SCM		0		+		+		0/-		0		0	
PMME				+		+		-					
		EQ		47%		49%		49%		EQ		EQ	
Summary of GPCs except for SCM, PMME		A	2	A	9	A	8	A	0	A	0	A	0
		+N	3	+N	2	+N	2	+N	0	+N	2	+N	0
		N	4	N	2	N	3	N	3	N	7	N	11
		-N	3	-N	0	-N	0	-N	7	-N	3	-N	2
		B	1	B	0	B	0	B	3	B	1	B	0

Figure 140. Example of seasonal outlook table.

3 month Outlook (2021Dec-2022Feb)




Figure 141. Example of precipitation probability forecast based on WMO LC-LRFMME.

3 month Outlook (2021Dec-2022Feb)

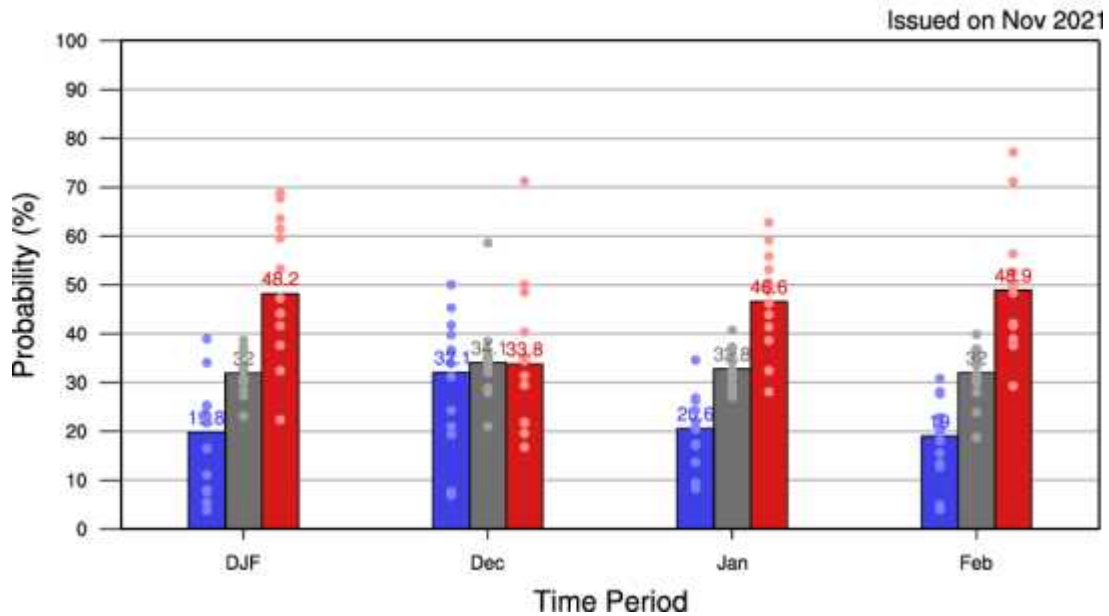


Figure 142. Example of temperature probability forecast based on WMO LC-LRFMME.

또한 WMO 장기예보 선도센터는 WMO 주관으로 지역별 기상청과 전문가들이 합의된 기후 전망을 제시하고, 이와 관련된 다양한 응용 분야 (농업, 식량안보, 수자원, 공중보건 등)의 전문가와 의견을 교환하기 위해 마련되는 다양한 지역기후포럼 (Regional Climate Outlook Forum, RCOF)에 참석한다. 기상청 기후예측과와 APCC는 RCOF회의에서 맞춤형 MME 예측자료를 제공하고 장기예보 선도센터 자료의 활용도를 향상시키고 국제 협력과 장기예보 선도센터의 입지를 강화시키기 위해 노력하고 있다. 이를 위해 2012년부터 매년 다양한 지역기후포럼에 APCC와 기상청의 기후예측과에서 참석하여 WMO 장기예보 선도센터의 MME 예측결과를 지역 전문가들과 공유하고 있으며, 2021년에는 COVID-19이 전 세계적으로 유행하면서 많은 지역기후포럼에 온라인 회의로 진행되었다. WMO 장기예보 선도센터는 총 5개의 지역기후포럼에 MME 기후 예측정보를 제공하였다 (Table 36). 상반기에는 남아시아 지역의 여름철 기후전망을 위해 개최된 SASCOF-19 (Nineteenth Session of South Asian Climate Outlook Forum)에 참석하여 WMO 장기예보 선도센터 MME 예측정보와 그동안 진행된 WMO 장기예보 선도센터의 개선사항을 발표하였다. 제19차 SASCOF는 인도기상청과 세계기상기구, 영국기상청과 Regional Integrated Multi-hazard Early-warning System (RIMES)이 공동으로 개최하였으며, 남아시아지역 9개국(Afghanistan, Bangladesh, Bhutan, India, Maldives, Myanmar, Nepal, Pakistan, Sri Lanka)의 기상청 관계자뿐만 아니라 WMO 장기예보 선도센터, International Research Institute for Climate and Society(IRI), Japan Meteorological Agency(JMA) 등이 참석하여 Asian southwest 몬순 시기의 기후전망에 대한 예측결과 및 의견을 공유하였다. 하반기에는 남아시아지역의 가을철과 겨울철 몬순을 전망하기 위한 개최된 SASCOF-20과 SASCOF-21에 직접 참여하여 발표를 진행하지는 못했지만 주최측에 WMO 장기예보 선도센터 MME 예측자료를 제공하고 이후 최종적인 기후예측전망에 대한 정보를 공유하였다. 또한 ASEANCOF-17은 WMO 장기예보 선도센터에서 직접 온라인 회의에 참석하여 WMO 장기예보 선도센터에서 생산된 MME 계절 예측정보를 발표하고 지역의 각국 기상청 참석자와 세계 유수의 계절 예측 생산 기관의 참석자와 지역의 기후전망에 대한 의견을 공유하고 계절예측 정보 활용 사례를 공유하고 의견을 교환하였다.

Table 36. The list of participating RCOF in 2021.

RCOF	Place	Date
Nineteenth Session of South Asian Climate Outlook Forum	Online	26, April
Twenty Session of South Asian Climate Outlook Forum	Online	27, September
Twenty First Session of South Asian Climate Outlook Forum	Online	25, November
Seventeenth Session of the ASEAN Climate Outlook Forum	Online	23, November

② GSCU

WMO에서는 자연재해 감소를 위해 지난 10여 년간 El Nino/La Nina Update를 발간하여 열대 태평양의 해수면 온도 변화에 관한 감시·전망 자료를 지속적으로 제공해왔다. 그러나 계절기후에 대한 보다 포괄적인 정보를 제공할 필요성이 제기되어, 제15회 세계 기상회의에서 최근 기후감시 및 예측 정보를 제공할 목적으로 GSCU (Global Seasonal Climate Update)의 발간을 결정하였다. 이를 지원하기 위해 WMO 장기예보 선도센터는 매 분기 (2월, 5월, 8월, 11월)에 기후예측정보를 생산하여 GSCU의 기본적인 초안을 제공하고 있다. GSCU 초안의 내용은 아래와 같다.

- WMO 장기예보 선도센터에서는 공통 기간에 대한 각 GPC별 예측 자료
- 결정론적 및 확률론적 MME 기법을 적용한 예측자료 및 Consistency map,
- ACC를 이용한 GPC 및 결정론적 MME의 검증 (SST, 2m 기온, 강수, 500hPa의 지위고도, 해면기압)
- ROC map, ROC curve and score, reliability diagram을 이용한 GPC 및 확률론적 MME의 검증자료를 제공(2m 기온, 강수, 500hPa의 지위고도, 해면기압)
- Nino 1+2, Nino3.4, IOD, NTA, STA 지수

2020년 10월부터는 WMO 계절예측 전문가 그룹에 제공하던 interim GSCU를 2021년에도 동일하게 제공하였으며, 매달 interim GSCU 자료 뿐만 아니라 WMO 계절예측 전문가 그룹을 지원하기 위해 WMO 장기예보 선도센터 MME에 참여하는 14개 GPC의 3개월 평균자료를 각 변수별로 생산, 제공하고 있다. 이 자료를 통해 전문가 그룹은 개별 GPC의 예측 특성을 파악할 수 있으며, 전문가 그룹에 제공되는 자료의 예시는 Figure 143에 나타내었다. 2020년 11월부터 GSCU와 interim GSCU 최종 보고서는 WMO 장기예보 선도센터 홈페이지를 통해 서비스되었으며, 2021년 1월에는 2000년의 GSCU자료를 구축하여 홈페이지에 제공하기 시작했다 (Figure 144). 최근에 발행된 GSCU 자료 서비스를 통해 과거 관측 및 기후예측 정보 유사해에 대한 전문가 의견을 사용자 그룹은 보다 쉽게 접근하여 과거 예측 및 관측정보를 비교할 수 있게 되었다. 또한 기후감시와 예측정보에 대한 전문가 의견을 포함한 계절기후에 대한 보다 포괄적인 정보를 사용자 그룹은 보다 쉽게 접근할 수 있도록 하였다.

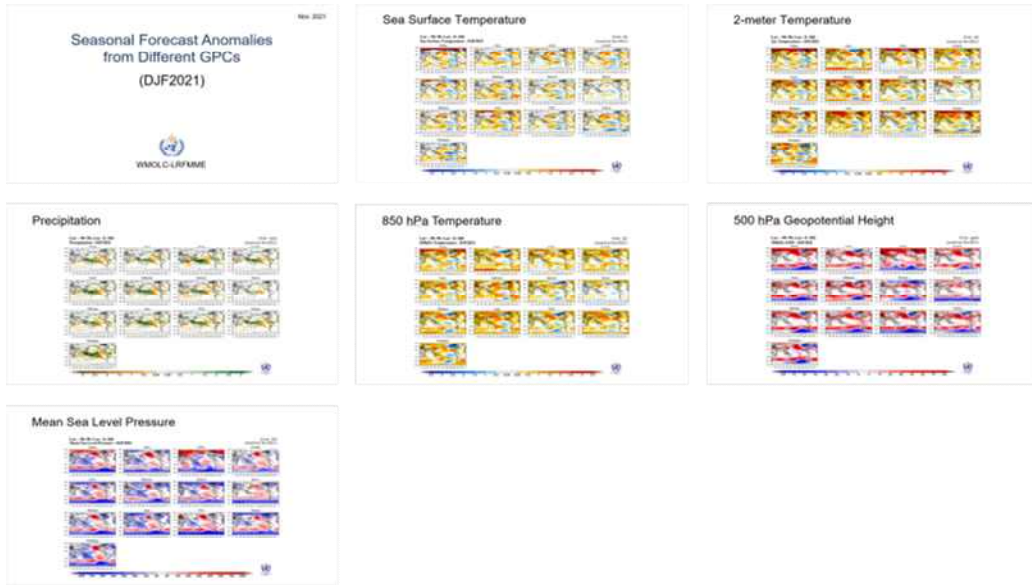


Figure 143. Example of materials for WMO expert team.

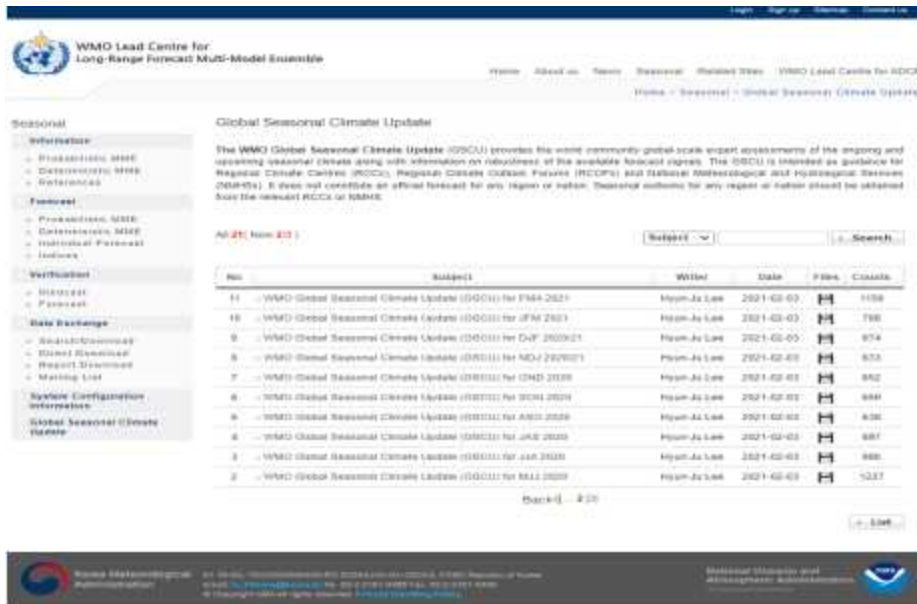


Figure 144. The bulletin board for GSCU on WMO LC-LRFMME website.

(라) 기타 기상청 기후예측과와의 협력 사항

APCC와 기상청 기후예측과 간의 원활한 업무 협력을 위해서 매월 초에 지난달 WMO 장기에보 선도센터 운영에 관한 운영 보고서를 작성하여 기상청 기후예측과 및 국립기상과학원 지구환경시스템과 및 미래전략팀에 제공하고 있다. 보고서에는 WMO 장기에보 선도센터 현업시스템 및 서버 운영상의 특이 사항, 홈페이지 이용 현황 및 WMO 장기에보 선도센터 예측자8료 제공 실적 등을 포함하고 있다. 2021년 12월 현재 WMO 장기에보선도센터 홈페이지는

총 8개국에서 총 439명의 회원이 이용하고 있으며, 2020년과 비교해 18명의 신규회원이 추가되었다. 그 중 WMO 장기예보 선도센터 홈페이지의 2021년 월별 이용 현황을 Figure 145에 나타내었다.




Figure 145. The number of monthly visitors of WMO LC-LRFMME website in 2021.

기상청에서는 「개인정보 보호법」 제 31조제2항제2호(개인정보 처리 실태 및 관행의 정기적인 조사 및 개선), 제6호(개인정보파일의 보호 및 관리·감독)에 따라 개인정보보호 수준 향상과 인식 제고를 위하여 기상청 및 산하기관의 개인정보 관리체계와 침해예방 활동 등을 주기적으로 점검하고, 개인정보처리시스템 등에 대한 접근권한이 없는자가 접근 통제 및 관리 체계 강화를 통해 개인정보 분실, 도난, 유출, 위조, 변조 또는 훼손방지를 위해 개인정보처리 시스템 접근 권한 관리 기준을 마련하여 정기적으로 점검하고 있다 (월, 분기별). 따라서 WMO 장기예보 선도센터 홈페이지의 개인정보처리시스템 접근 권한 및 사용자 정보 조회 및 변경 내역점검을 매월 그리고 반기별로 수행하여 개인정보 관리 실태를 자체적으로 점검하고 있으며 점검 결과는 기상청 기후예측과에 제공하고 있다.

또한 기상청 기후예측과와 세계기상기후의 요청에 의해 4월에 있었던 Seasonal Forecast Training for NCHM, Semi-Virtual Session에서 계절예측 정보의 효율적 사용과 예보자 역량 강화 교육 프로그램에 강의를 진행하였으며, 9월에는 WMO에서 개최한 ACP-RCC(Workshop on ACP(Africa, Caribbean and Pacific region) RCCs' Access to Data)회의에 참석하여 WMO 장기예보선도센터에서 제공하고 있는 계절 예측 정보에 대하여 발표를 진행했다.

(마) WMO 장기예보 선도센터 예측 시스템 개선 용역 사업 지원

① 목적 및 기대효과

WMO 장기예보 선도센터는 2009년 4월 한국 기상청과 미국 기상청 (GPC Washington)의 공동 운영 형태로 지정되면서 2021년 현재 전 세계 14개 GPC가 생산하는 장기 예측자료를 수집·표준화하고, 표준화된 GPC 자료 및 다중모델앙상블 (Multi-Model Ensemble, MME) 예측자료를 WMO 회원국에 제공하는 역할을 수행해 오고 있다. 현재 WMO 장기예보 선도센터 예측시스템은 자료처리 기술, 웹 시스템 기술, 데이터베이스 기술을 종합적으로 적용하여 운영하고 있으며, 사용자 맞춤형 예측정보 제공 서비스 구현, 기후 모델의 추가 등에 따른 서비스 확대, 최신 기술 적용 및 관리 방안의 개선을 통해 전 세계 WMO 회원국에 장기예보 자료를 제공하는 기본 업무를 보다 안정적으로 수행할 필요성 요구됨에 따라 2017년부터 WMO 장기예보선도센터 시스템 개선을 위한 용역과제를 기상청에서 발주하고 있으며, APCC는 WMO장기예보선도시스템 개선 용역의 실무적인 기술적 지원을 수행하고 있다. 2021년에는 “WMO 장기예보 선도센터 시스템 개선 (IV) 용역 사업이 3월부터 11월까지 약 7개월 동안 진행되었으며, 용역사업의 범위는 아래와 같이 크게 3개로 구분되어 진행되었다. 특히 올해는 WMO 장기예보 선도센터 홈페이지내에 관측기후 자료를 가시화하여 기후 예측 정보를 보다 빠르게 해석하고 판단할 수 있는 관측 정보를 제공하여 WMO 회원국에게 계절예측 서비스를 개선하였다. 또한 기존 WMO장기예보 선도센터 홈페이지에서 제공되던 검증결과에 사용되는 관측자료를 다양화하여 관측자료에 따라 달라 질수 있는 계절예측 검증결과를 관측자료별로 비교할 수 있는 페이지를 구성하였다. 보다 상세한 내용은 다음절에 서술하였다.

- WMO 장기예보 선도센터 자료생산체계 개선
- WMO 장기예보 선도센터 웹서비스 개선
- 웹서비스 속도향상을 위한 서비스 자원 및 성능 최적화

WMO 장기예보 선도센터 예측 시스템 개선 용역 사업 수행으로 WMO 장기예보 선도센터 시스템 개선에 따라 전세계 회원국 사용자에게 안정적으로 품질 높은 서비스를 제공할 수 있을 것으로 보이며, WMO 장기예보 선도센터 기후예측 자료 활용도 또한 증대시킬 수 있을 것으로 기대된다. WMO 장기예보 선도센터에 자료를 제공하는 GPC와의 국제적 협업 체계를 강화할 수 있을 것으로 기대된다.

② 사업 수행 내용

- WMO 장기예보 선도센터 자료생산체계 개선

WMO 장기예보 선도센터의 다중모델 앙상블 계절예측에 참여하는 14개국의 GPC는 각국의 스케줄을 기반으로 전지구 계절예측 모델을 변경 개선하고 있다. 따라서 이 자료를 바탕으로 운영되는 WMO 장기예보 선도센터 또한 기존의 계절예측 모델이 변경되면 자료 표준화시스템의 개선이 필요하다. 각국 GPC에서 개선된 계절 예측자료가 WMO 장기예보 선도센터에 신속하게 적용될 수 있도록 용역과제에 해당 내용을 포함하여 WMO장기예보선도센터 계절예측 정보 서비스 기능을 강화하였다. 또한 WMO 장기예보 선도센터 계절 예측자료의 검증은

WMO 장기예보 표준 검증 체계 (WMO Long-Range Forecast Standardised Verification System, WMO LRF-SVS)에 의거하여 수행하여, 기존에 홈페이지를 통해 제공되던 6개 변수에 대한 예측정보에 대한 검증결과를 Forecast와 Hindcast에 대해서만 제공하였으나, WMO 장기예보 표준 검증 체계에서는 기후지수에 대한 검증결과도 함께 제시할 것을 추천하고 있다. 따라서 본 과제를 통해 기존 홈페이지를 통해 제공하고 있는 7개 기후지수 (NINO1+2, NINO3, NINO3.4, NINO4, DMI, TNA, TSA)에 대한 Forecast와 Hindcast기간에 대한 ACC와 RMSE 검증결과를 제공할 수 있게 되었다 (Figure 146). 그리고 WMO 장기예보 선도센터에서는 제공되는 각 변수에 대한 검증 그래프는 홈페이지에서 사용자가 그림 생성을 위해 명령어를 수행했을 때 검증 Score를 계산하는 프로그램이 수행된 이후 그 결과값을 이용하여 그래프를 생성하고 있었기 때문에 홈페이지 사용자가 홈페이지상에서 그래프를 표출하기 위해서는 상당한 대기시간이 필요했다. 또한 WMO 장기예보 선도센터 관리자는 국회 및 기상청의 요청에 대응하기 위해 WMO 장기예보 선도센터 MME 및 개별모델 검증결과를 산출하는 계산 프로그램을 재수행해야 하는 번거로움이 있었다. 홈페이지 사용자의 편의성과 WMO 장기예보 선도센터 관리자의 자료 관리의 효율성을 증대시키기 위해 검증결과를 DB화하고 이를 통해 홈페이지 그래프 표출이 수행될 수 있도록 본 과업에서는 검증시스템의 개선이 이루어졌다. 이를 통해 WMO 장기예보 선도센터 사용자들이 지속적으로 요구했던 홈페이지 대기시간을 줄일 수 있게 되었다. 또한 WMO 장기예보 선도센터에 최신기술 적용을 대비하기 위해 계절 및 계절내 자료처리 뿐만 아니라 그래픽 표출 관련 python3 프로그램을 개발하여 향후 시스템 개선에 적용될 수 있는 모듈의 계산속도 등을 상호비교하였다. 이를 향후 시스템 개선을 위한 방향을 수립하는데 도움이 될 수 있을 것으로 판단된다.

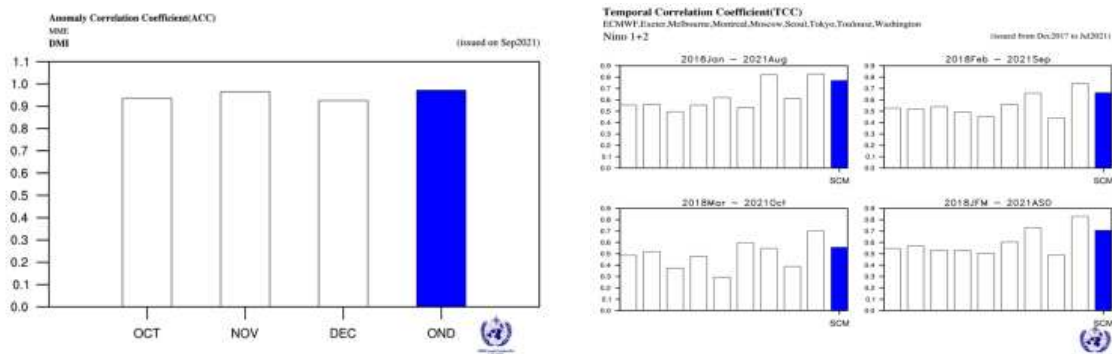


Figure 146. Verification of climate indices in WMOLC-LRFMME.

• WMO 장기예보 선도센터 웹서비스 개선

이 과업에서는 WMO 장기예보 선도센터 홈페이지내에 관측기후 자료를 가시화하여 기후 예측 정보를 보다 빠르게 해석하고 판단할 수 있는 관측 정보를 제공하여 WMO 회원국에게 계절예측 서비스를 개선하였다. 이를 위해 ERA5 재분석 자료를 수집하고, 수집된 자료를 통해 각 변수의 기후값을 계산하고 월별/계절별 편차장을 계산하여 NetCDF 형식의 디지털 자료로 저장하는 시스템을 개발하였다. 홈페이지에서 제공되는 예측정보의 선행시간과 동일하게

3개월에서 6개월까지 사용자가 편차장을 선택하여 표출할 수 있도록 하였으며, WMO 장기예보 선도센터 MME의 기후값으로 사용되는 1993-2009년까지의 기후값과 WMO에서 공식적으로 사용되는 관측의 기후기간인 1991~2010년, 그리고 과거 기후기간(1981~2010년)을 사용자가 선택할 수 있는 옵션을 제공하여 사용자 편의성을 증대시켰다 (Figure 147). 또한 다양한 검증 자료를 이용한 계절 예측 검증시스템을 개발하여 계절예측 검증 기능을 개선하였다. 기존 hindcast 검증을 위해 사용하였던 관측의 재분석장 ERA-interim이 ECMWF에서 더 이상 생산되지 않고 있으며, forecast 검증을 위해 사용하였던 NCEP1자료는 다른 재분석자료에 비해 그 정확성이 떨어지는 것으로 알려져 있다. 만약 WMO 장기예보 선도센터의 MME에 사용하는 hindcast기간이 확장된다면 기존에 사용하던 ERA-interim을 통한 검증이 불가능할 수도 있기 때문에 이에 선제적으로 대응하고 사용자에게 보다 나은 서비스를 제공할 수 있도록 하였다. 사용자는 홈페이지에서 기존 검증결과 표출 시스템과 동일한 형식의 자료를 ERA5에 대해서 검색하여 재분석자료에 따른 검증결과의 민감도를 확인할 수 있게 되었다. 기존의 WMO 장기예보 선도센터에서 제공하던 hindcast와 forecast 검증결과는 자료 수집의 용이성을 고려하여 변수별로 다른 재분석자료를 사용하였으나, ERA5의 경우 준 실시간으로 강수량, 해면기압, 2m 기온, 850 기온, 500hPa 지위고도, 해수면 온도에 대해 자료를 수집할 수 있기에 실시간 검증에 사용되지 적합한 것으로 판단하여 사용자에게 서비스할 수 있게 되었다. WMO 장기예보 선도센터 홈페이지에서 제공된 다양한 검증 자료를 이용한 계절예측 검증 결과 페이지의 예시는 Figure 148과 같다.

또한 향후 WMO 장기예보 선도센터의 개선 방향 수립을 위해 WMO 장기예보 선도센터 홈페이지 사용자 의견 및 요구 사항을 수렴하는 등 웹서비스 현황분석을 통한 개선방안을 제시하는 내용도 과업에 포함되었다. WMO 장기예보 선도센터 홈페이지의 서비스 수준을 객관적으로 진단하고 관리자가 필수 항목에 대한 웹서비스 진단 결과의 연도별 추이를 확인할 수 있는 웹페이지를 생성하였으며, 웹서비스 수준 진단 결과를 반영한 개선 방안을 제시하였다. 이를 위해 과업에서는 홈페이지 사용자 의견 및 요구사항 수렴을 위해 기존의 서비스 수준 진단 설문 항목을 재검토하여 구체적인 서비스 만족도 파악을 위해 전반적인 만족도를 묻는 항목을 포함하여 8가지 (자료 사용 목적, 이용 용이성, 콘텐츠, 메뉴 레이아웃, 웹사이트 뒤로가기 기능, 콘텐츠 일관성, 사용자 편의성) 세부 만족도를 묻는 문항을 추가하여 웹서비스 만족도 조사 항목을 개선하였다. 웹서비스 만족도 조사에서 웹서비스의 이용 용이성에 대한 만족도가 80.59점으로 만족도 항목중 가장 낮은 점수를 보였으며, 향후 WMO 장기예보 선도센터에서 개선되어야 하는 부문으로 자료의 시간해상도와 공간해상도의 증가가 필요하다는 결론을 얻었다. WMO 장기예보 선도센터 웹서비스는 웹페이지를 구성하는 콘텐츠의 소스코드 분석을 통해 서비스 속도를 개선하고, 사용자의 예측정보 사용성의 편의성을 증가시키기 위해 예측정보의 시간 해상도와 공간해상도의 증가를 검토해야 한다.

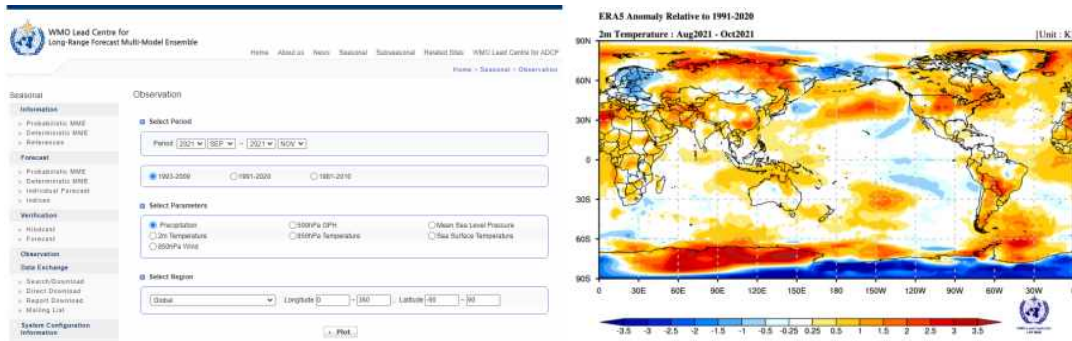


Figure 147. Observational anomaly display webpage in WMOLC-LRFMME.

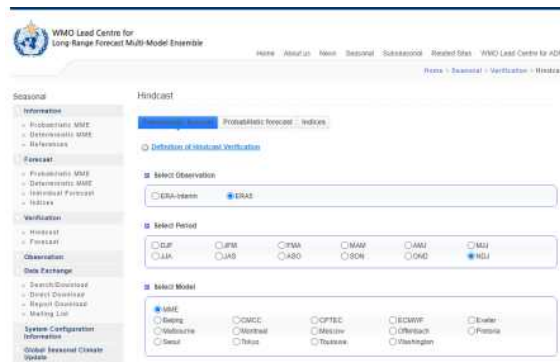


Figure 148. Verification display web page with added reanalysis data in WMOLC-LRFMME.

• 웹서비스 속도향상을 위한 서비스 자원 및 성능 최적화

WMO 장기예보 선도센터 홈페이지 서비스는 그동안 사용자들에게 웹서비스의 접근성에 있어서 가장 많은 지적을 받아왔다. 특히 작년에는 WMO 장기예보 선도센터 홈페이지의 로딩속도와 그래픽 표출 속도가 타 유수의 기후예측 전문기관과 비교해 현저히 낮아 웹서비스 속도 향상 및 웹 접근성 향상을 위해 WMO 장기예보 선도센터 홈페이지 서비스의 웹 표준에 부합하고 WBC 웹 표준 가이드 라인의 권고안에 따라 웹페이지 문법을 선언하고 선언한 문법을 올바른 방식으로 구현, 수정하였으며 여러 방면의 웹서비스 속도 향상을 위해 노력하였다. 올해 과업에서는 2020년 과업의 연장선상에서 WMO 장기예보 선도센터 웹페이지 속도향상을 위해 웹페이지의 자원 이용시 비효율적인 요소들을 검수하여 문법을 개선하고, 웹페이지를 초기에 호출할 때 불필요하거나 성능 저해 요소를 제거하였다. 웹페이지를 불러오는 시점에 불필요한 로직 또는 성능을 저해할 수 있는 코드를 삭제하거나 간소화하였으며, 사용하지 않는 자바 스크립트나 코드에 삽입된 라이브러리 등을 분석하여 코드를 삭제하였다. 이러한 과정을 통해 실제 웹페이지 로딩 시간을 단축할 수 있었으며, 사용자의 웹페이지 접근성을 향상시킬 수 있었다.

(마) 계절내 예측 시스템 운영

① 계절내 예측 모델 예측성 비교 검증 (ACC)

WMO 장기에보 선도센터에서 시범운영 중인 계절내 MME 결과에 대한 검증을 실시하였다. 검증 기간은 2016년 1월 11일부터 2021년 9월 27일 사이 총 299회 예측한 결과이며, 검증 대상은 개별 GPC 및 MME 예측 결과이다. 2020년 이후 계절내 MME에 참여하지 않는 모델들의 경우와 전체기간 중 일부 누락된 예측자료가 있는 경우에는 해당 날짜에 대한 부분만 검증에서 제외하고 분석하였다. 본 보고서에서 hindcast에 대한 검증을 제시하지 않는 이유는 각 GPC 별로 hindcast 시작 날짜가 다르며 매 예측마다 손실되는 선행시간이 변화되기 때문에 일정한 모델의 예측성을 분석하기 어렵기 때문이다. 반면 forecast 예측결과는 MME 참여를 전제로 예측에서 제외되는 초기 선행시간이 일정하고, 모델별 차이가 적기 때문에 모델별 비교 검증 방법으로 적합하다. 또한, hindcast 예측과 forecast 예측에 사용하는 모델의 초기장이 일반적으로 다르게 설정되어 두 방법의 실제 예측성의 차이가 있으며, 공통 hindcast 기간이 12년(2021년 예측은 10년)으로 짧아서 신뢰도 있는 검증결과를 보장할 수 없기 때문이다.

검증 변수는 T2M과 PREC, MSLP, Z500이며, 검증 영역으로는 Global 영역에 관한 결과만을 제시하도록 하겠다. 또한, ERA5 자료의 기후값은 계절내 예측 모델의 공통 hindcast 기간과 동일한 1999년부터 2010년까지로 정하였다. 참고로 주별 평균한 예측 결과 생산을 위해 예측 시작 기준을 월요일로 정하면서 모델의 실제 예측 시작날짜부터 약 4일 정도의 예측 선행시간 결과가 생략된 검증 결과이므로 검증 결과의 해석 시 예측성이 실제 모델의 예측성보다 낮은 값일 수 있음에 유의해야 한다.

먼저 전구영역에 대한 ACC 검증을 하였다. Figure 149는 4개 변수의 전구영역 주별 평균 예측 결과에 대한 ACC 검증 결과를 각 GPC와 SCM 예측 결과별로 검증기간 전체에 대해서 평균하여 나타낸 것이다. 변수별로 예측성을 비교해보면 일반적으로 알려진 바와 같이 PREC 변수의 예측성은 다른 변수에 비해 1주 예측에서도 ACC 값이 0.2 이상 낮게 나타났으며, 나머지 세 변수의 1주 예측 ACC 값은 0.6에서 0.8 사이로 변수에 차이 없이 비슷한 값으로 시작하였다. 그중에서도 Z500 변수가 1주 예측에서는 모델 간의 차이가 작고, 비교적 높은 값을 보였으며, SCM은 0.84, ECMWF는 0.86의 값을 보였다. 기상청의 1개월 전망에서 중요한 3주 예측 결과에 대한 ACC 검증 결과를 보면, 예측성이 비교적 우수한 Z500 변수에서 SCM은 0.29, ECMWF는 0.28의 값을 보였고, T2M 변수에서는 SCM은 0.36, ECMWF는 0.38의 값을 나타냈다. 일반적으로 Z500 변수의 예측성이 우수하다고 알려졌으나 전구 영역에 대한 3주 예측 시 변동성이 적고, 예측성이 우수한 적도 지역 해수면 온도의 영향으로 상대적으로 장기 예측에서 더 높은 예측성이 나온 것으로 분석된다.

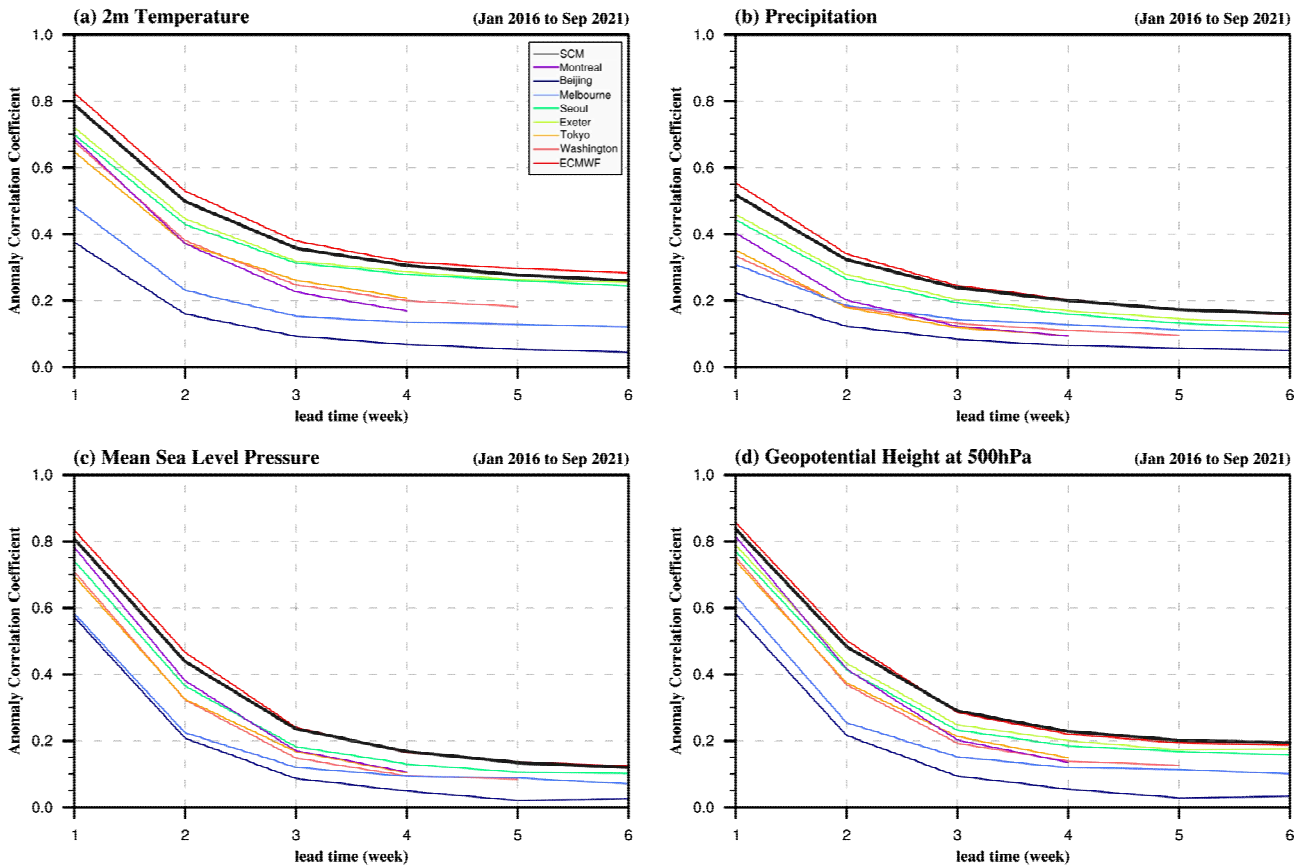


Figure 149. Anomaly correlation coefficient (ACC) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe. ACC for SCM prediction is indicated by black line.

Figure 149의 모델별 ACC 검증 결과를 비교하면, 검은색 실선으로 표시한 SCM과 붉은색 실선으로 표시한 ECMWF 예측의 ACC 검증 결과는 네 변수와 6주의 예측기간 모두에서 다른 모델에 비해 뚜렷하게 높게 나타났으며, 푸른색의 Melbourne과 남색으로 표시한 Beijing 모델은 상대적으로 낮은 ACC 값을 보였다. SCM과 ECMWF 예측 결과를 비교하면 예보 1주와 예보 2주에서는 ECMWF 예측 결과가 0.02 정도 약간 높게 나타났으며, 예보 3주와 4주에서는 비슷한 값을 보였다. 이러한 특징을 보았을 때, 3주 이상의 계절내 규모의 예측에서 예측성을 향상하기 위해서는 MME 기법을 활용하는 것도 유용하다는 것을 보여준다. 그 외 모델들의 예측 결과는 예보 1주부터 예보 6주까지 상대적으로 비슷한 수준으로 감소하는 경향을 보이는데 Montreal 모델은 다른 모델과 달리 예보 1주에서 높은 예측성을 보이다가 이후 예측 기간이 길어지면서 다른 모델 대비 예측성의 감소가 급격한 것으로 나타났다.

Figure 150과 Figure 151은 각 모델 및 변수 별로 검증기간 동안 예측성의 변화 경향을 파악하기 위해 각각 1주와 3주 예측 선행시간의 주별 평균 예측에 대한 ACC 검증 결과를 시계열로 나타낸 것이다. 주 단위로 생성되는 검증 결과를 분석에 쉽도록 해당 월별로 평균하여 시계열로 표출하였다. 월별 평균하는 기준은 검증의 대상이 되는 주 평균값의 시작일이 속하는 월을 기준으로 월별 평균을 수행하였으며, 그에 따라 4회에서 5회 예측에 대한 검증결과가 평

균되며, 시계열의 시작과 끝은 월 평균되는 검증 결과의 수가 그 보다 적을 수 있다.

Figure 150의 예보 첫째 주 예측성을 보면, 앞서 분석한 바와 같이 ECMWF의 ACC 값이 꾸준히 높은 수준을 유지하고 있으며, 모델간의 격차도 일정하게 유지되는 경향을 보여준다. 또한 강수량 변수를 제외하고는 계절적인 예측성의 특성도 뚜렷하게 나타나지는 않는다. 특히 계절 예측 모델의 예측성 변화경향 분석 시 뚜렷하게 나타나는 ENSO 발달 시기의 예측성이 높아지는 현상이 예측성이 우수한 모델에서는 잘 드러나지 않았다. 다만 PREC 변수에서 겨울철에 ACC 값이 상승하는 경향을 보이며, 예측성이 다소 낮은 모델에서 ENSO 발달 시기(특히 2020년 1월 전후)에 ACC 값이 높아지는 것을 볼 수 있다. Figure 151과 같이 예측 선행시간이 3주가 되면, SCM과 ECMWF 예측 결과가 전반적으로 가장 높은 ACC 값을 보여준다. 하지만 예측성의 변동 폭이 첫째 주보다 매우 크며 모델간의 예측성 순위 변화도 크게 나타났다. 예보 1주 예측과의 차이점은 모든 모델과 네 변수 모두에서 ENSO가 강하게 발달한 2020년 1월 전후로 예측성이 뚜렷하게 상승하는 모습을 보였다. 그리고 T2M 변수와 PREC 변수가 상대적으로 작은 값이지만 예측 기간의 변화에도 일정한 ACC 값을 유지하는 경향을 보였지만, MSLP와 Z500 변수의 ACC 값은 예측 기간에 따라 그 변화 폭이 큰 것으로 나타났다. 추가적으로 2019년 7월을 기준으로 대부분 모델에서 예측성의 다소 높아진 것으로 보이며, MSLP와 Z500 검증 값에서 북반구 봄과 가을철에 예측성이 감소하고 여름과 겨울에 예측성이 상승하는 주기성이 더욱 명확해졌다.

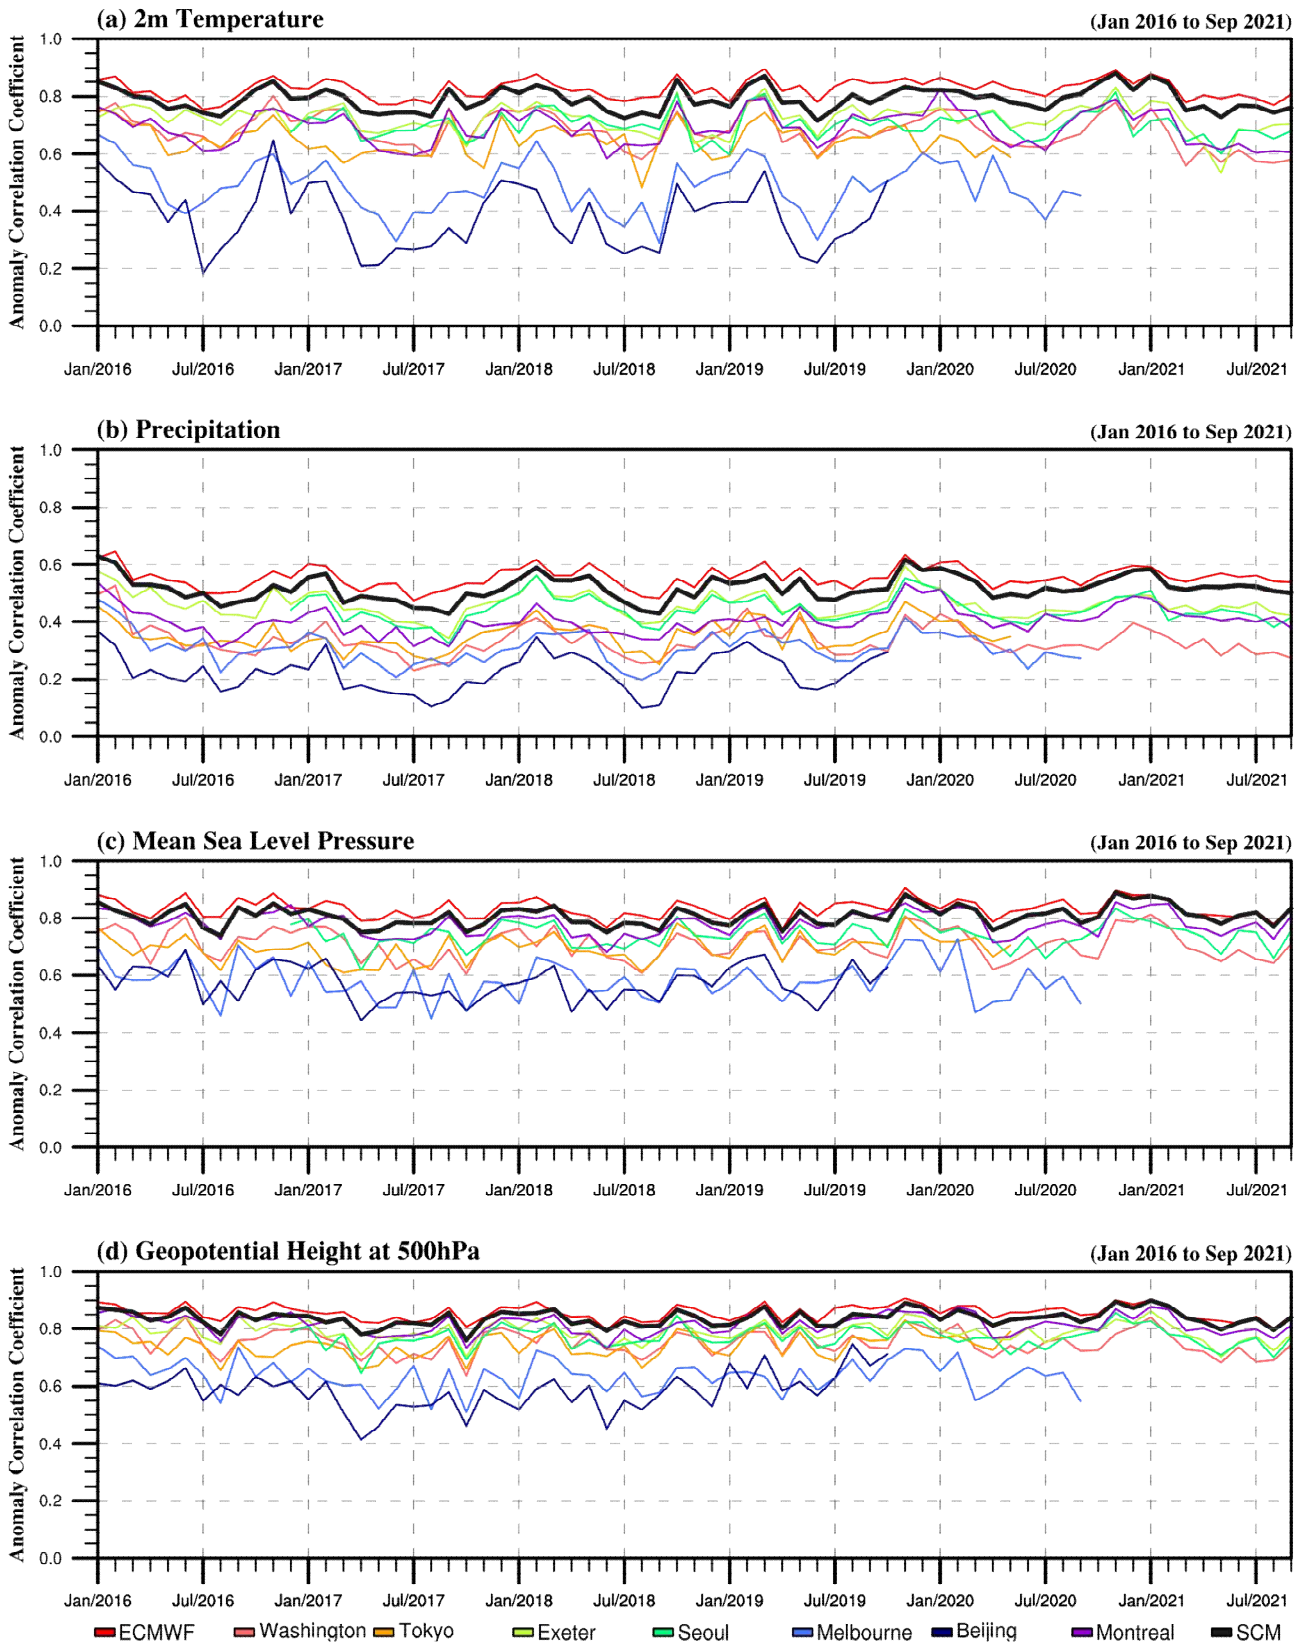


Figure 150. Anomaly correlation coefficient (ACC) of monthly averaged 1 week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe. ACC for SCM prediction is indicated by black line.

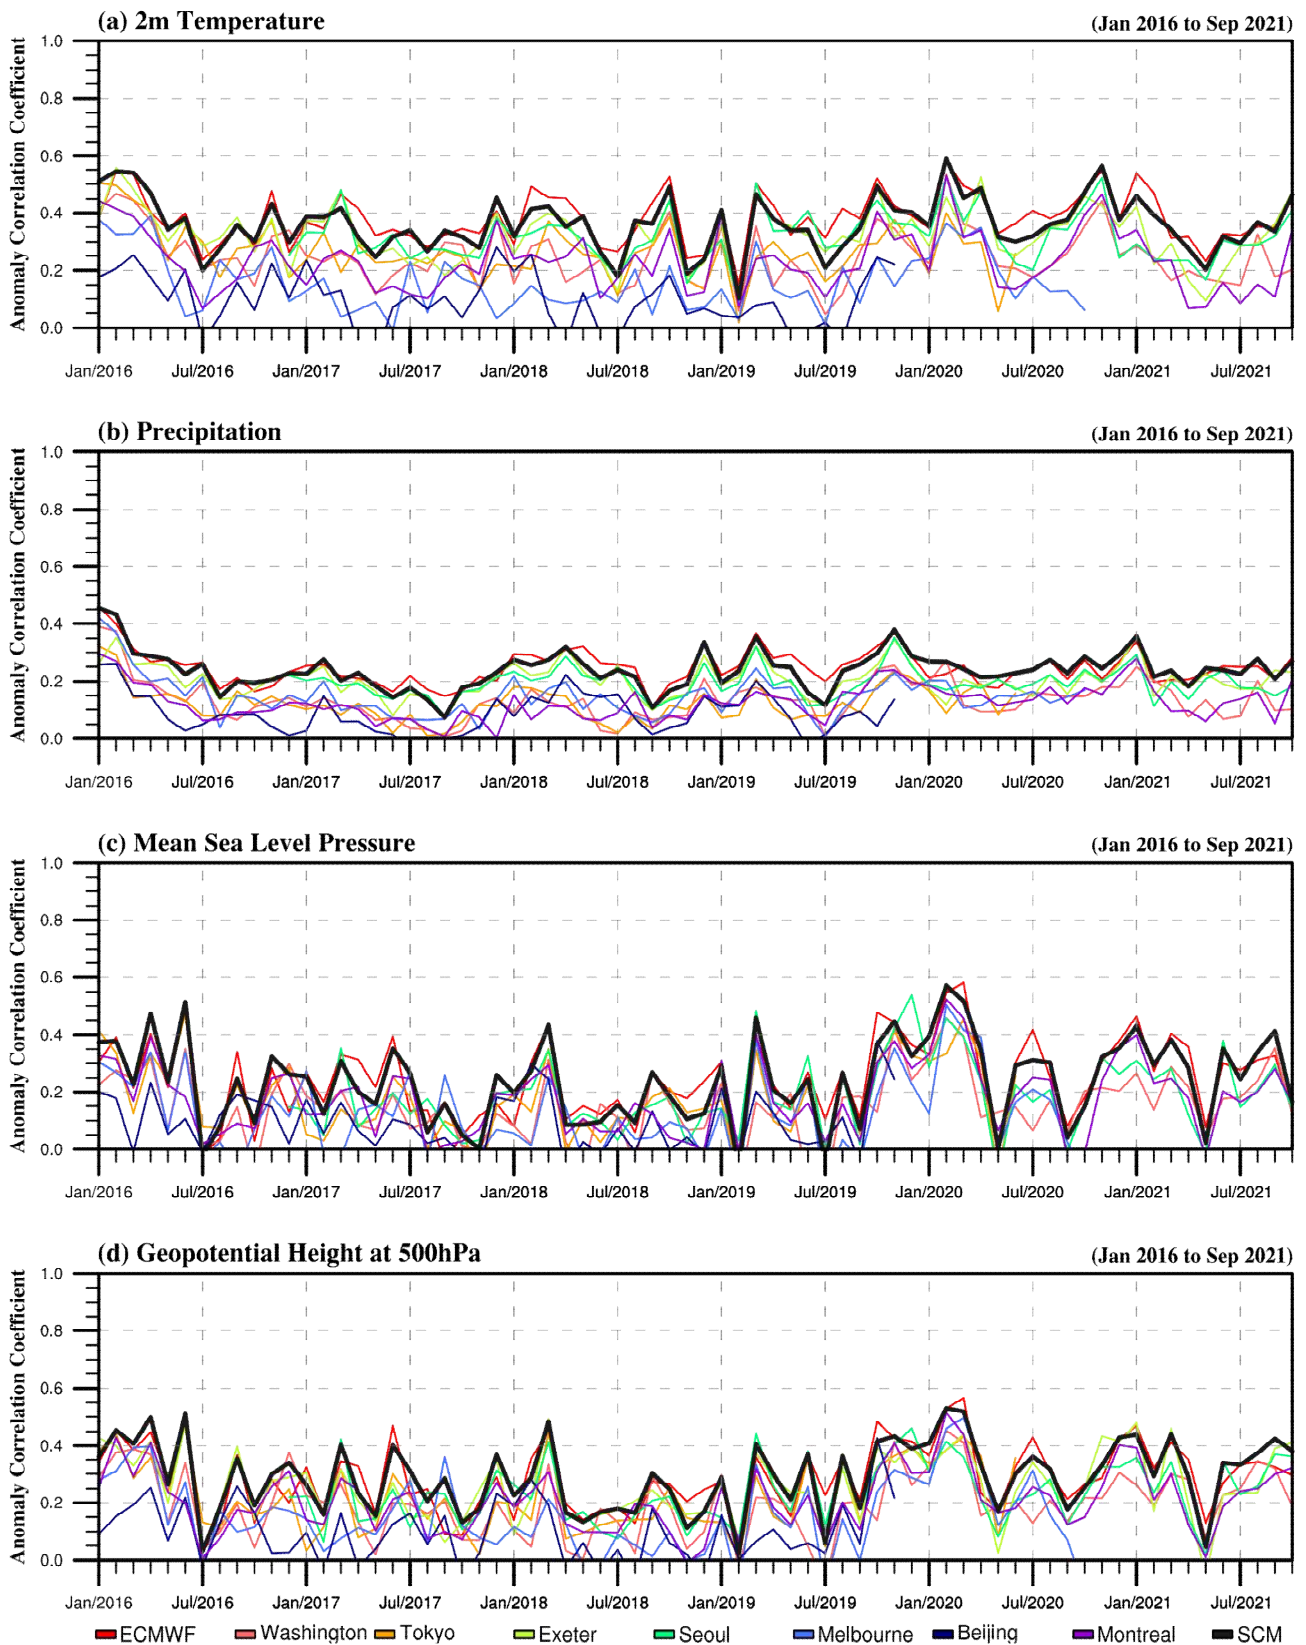


Figure 151. Anomaly correlation coefficient (ACC) of monthly averaged 3 weeks real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Oct 2021 over the globe. ACC for SCM prediction is indicated by black line.

② 계절내 예측 모델 예측성 비교 검증 (RMSE)

ACC 검증과 동일한 방법으로 전구영역에 대한 root mean square error (RMSE) 검증 결과를 4개의 변수와 각 GPC 별로 분석하였다(Figure 152). Figure 149의 ACC 검증결과를 뒤집은 것과 비슷하게 예측 초반에는 낮은 RMSE 수치를 보이며, 3주 이후의 RMSE 값이 일정한 수준에서 수렴하는 양상을 보였다. T2M과 PREC 변수에서는 SCM과 ECMWF의 ACC 값이 다른 GPC 모델들보다 뚜렷하게 낮은 값을 보였으며, MSLP와 Z500 변수에서는 그 차이가 비교적 적게 났다. T2M과 PREC, MSLP, Z500 모든 변수에서는 1주와 2주 예측에서 ECMWF 예측이 비교적 우수하였으며, SCM은 3주 이상의 예측에서 ECMWF와 비슷하거나 낮게 나타났다.

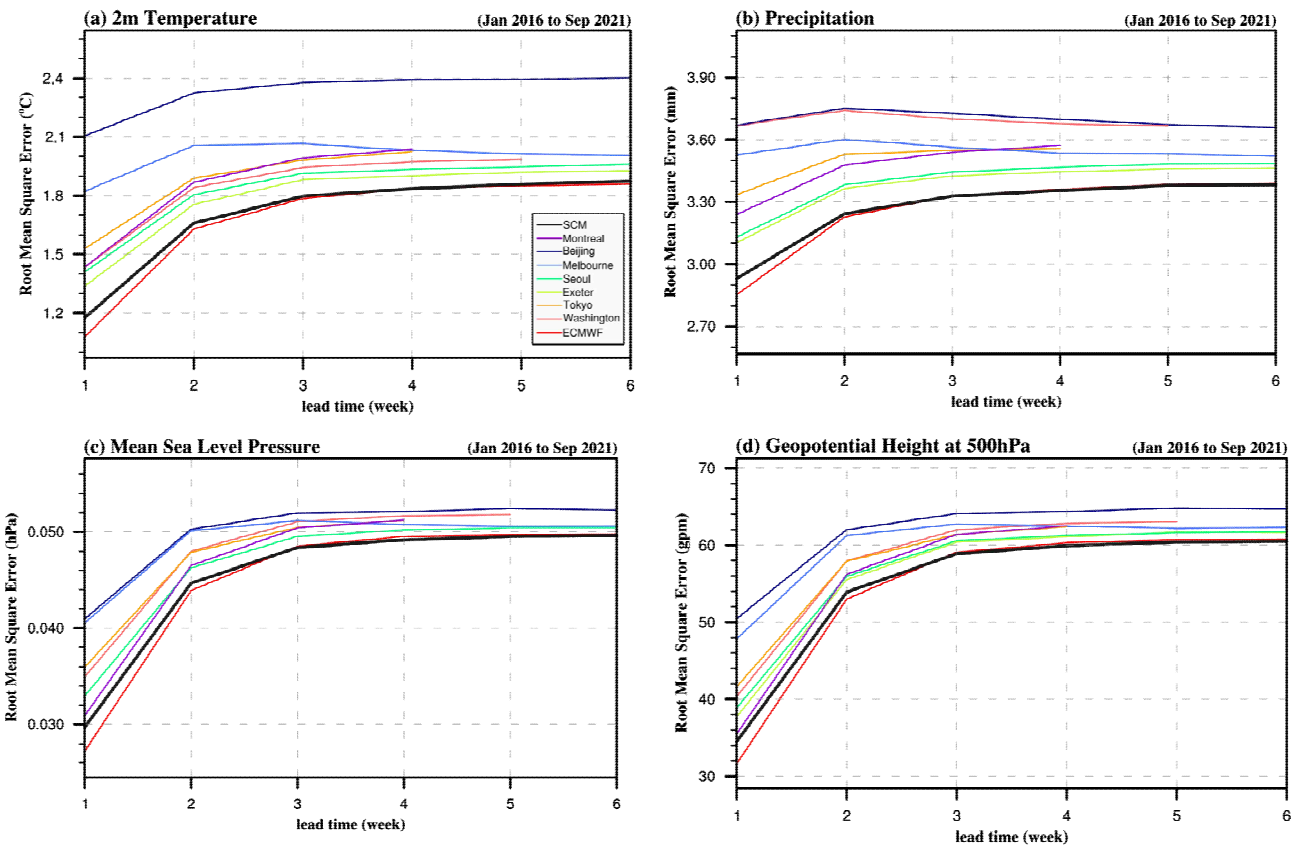


Figure 152. Root mean square error (RMSE) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe. RMSE for SCM prediction is indicated by black line.

Figure 153과 Figure 154는 각 모델 및 변수 별로 예측성의 변화 경향을 파악하기 위해 각각 1주와 3주 예측 선행시간의 주별 평균 예측결과에 대한 RMSE 검증 결과를 시계열로 나타낸 것이다. 예측결과 및 검증기준 자료처리 방법은 Figure 150과 동일하게 분석하였다. Figure 153는 1주 예측 선행시간에 대한 RMSE 검증 결과이다. T2M 변수는 북반구 겨울철에 예측성이 뚜렷하게 떨어지는 모습을 보였으며, 다른 변수에서는 계절적인 예측성의 변화는 적었다. ACC 검증과 동일하게 RMSE 값도 계절 예측규모의 검증과 달리 예보 1주에서는 ENSO

변화에 크게 영향을 받는 것으로 보기 어려웠다.

다만, 2016년 1월에는 강한 엘니뇨의 영향으로 T2M의 RMSE 값이 모든 모델에서 낮은 경향을 보였으나, PREC는 다른 기간에 비해 높은 값을 보였다. 계절예측 뿐만 아니라 계절내 규모의 예측에서도 ENSO의 변화에 따라 모델의 예측성이 차이남을 알 수 있다.

Figure 154는 3주 예측 선행시간에 대한 RMSE 검증 결과이다. 모든 변수들이 1주 예측 선행시간에 대한 결과보다 계절적인 영향을 더 받는 것으로 분석된다. T2M은 물론 MSLP와 Z500 변수에서도 북반구 겨울철에 전반적으로 RMSE 값이 높게 나타났다. 또한 예측성이 떨어지는 월에는 모든 모델에서 RMSE 값이 동시에 크게 증가하는 것을 알 수 있다. 특히 이러한 월별 변동은 MSLP와 Z500 변수에서 더욱 뚜렷하게 보였으며, 모델간의 RMSE 차이보다 크게 나타났다. 이것은 현재 계절내 예측모델의 수준에서 3주 이후의 기압계 배치에 대한 예측은 모든 모델에서 어려운 문제로 남아있음을 의미한다. 또 다른 특징으로는 1주 예측과 달리 3주 예측은 계절 예측규모와 동일하게 ENSO 변화에 예측성이 영향을 받는 것으로 분석되었다. 특히 엘니뇨가 발달한 2020년 1월은 다른 해처럼 겨울철이지만 MSLP와 Z500 예측성이 낮아지지 않았다.

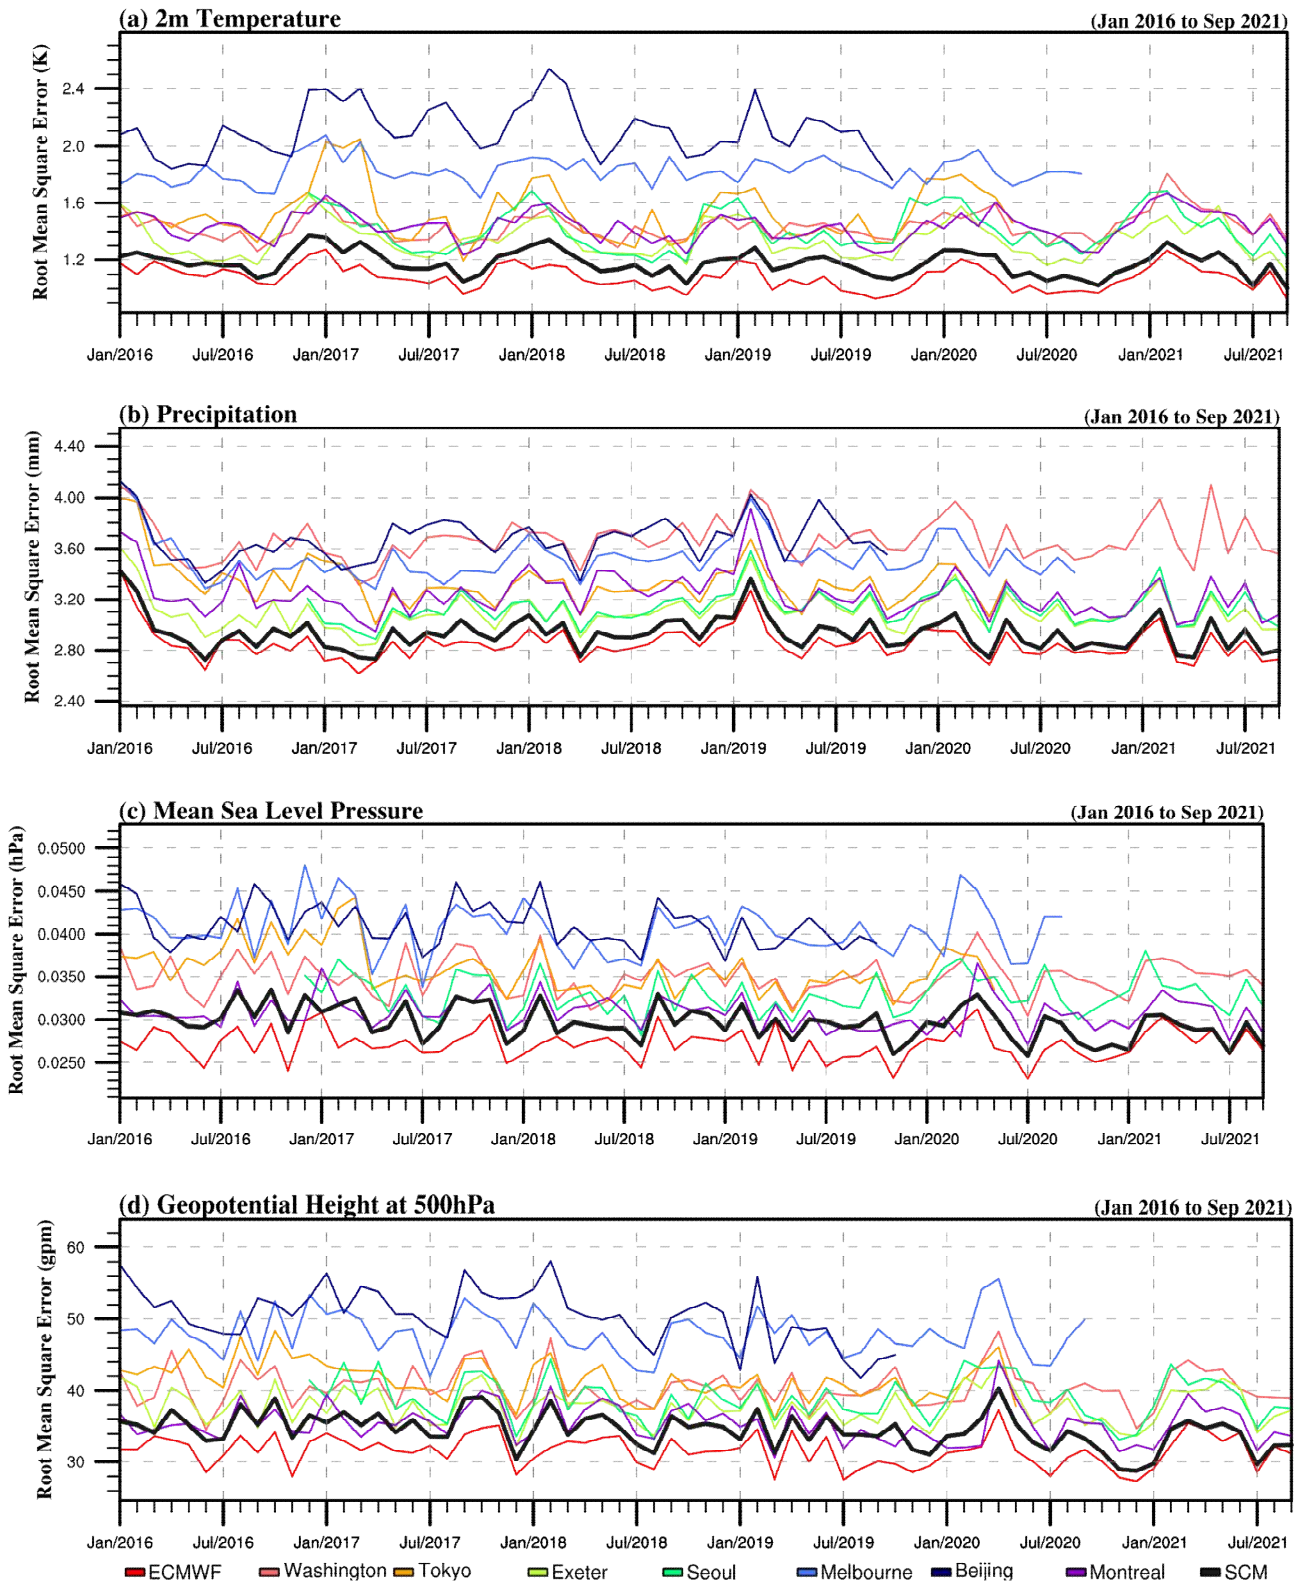


Figure 153. Root mean square error (RMSE) of monthly averaged 1 week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Sep 2021 over the globe. RMSE for SCM prediction is indicated by black line.

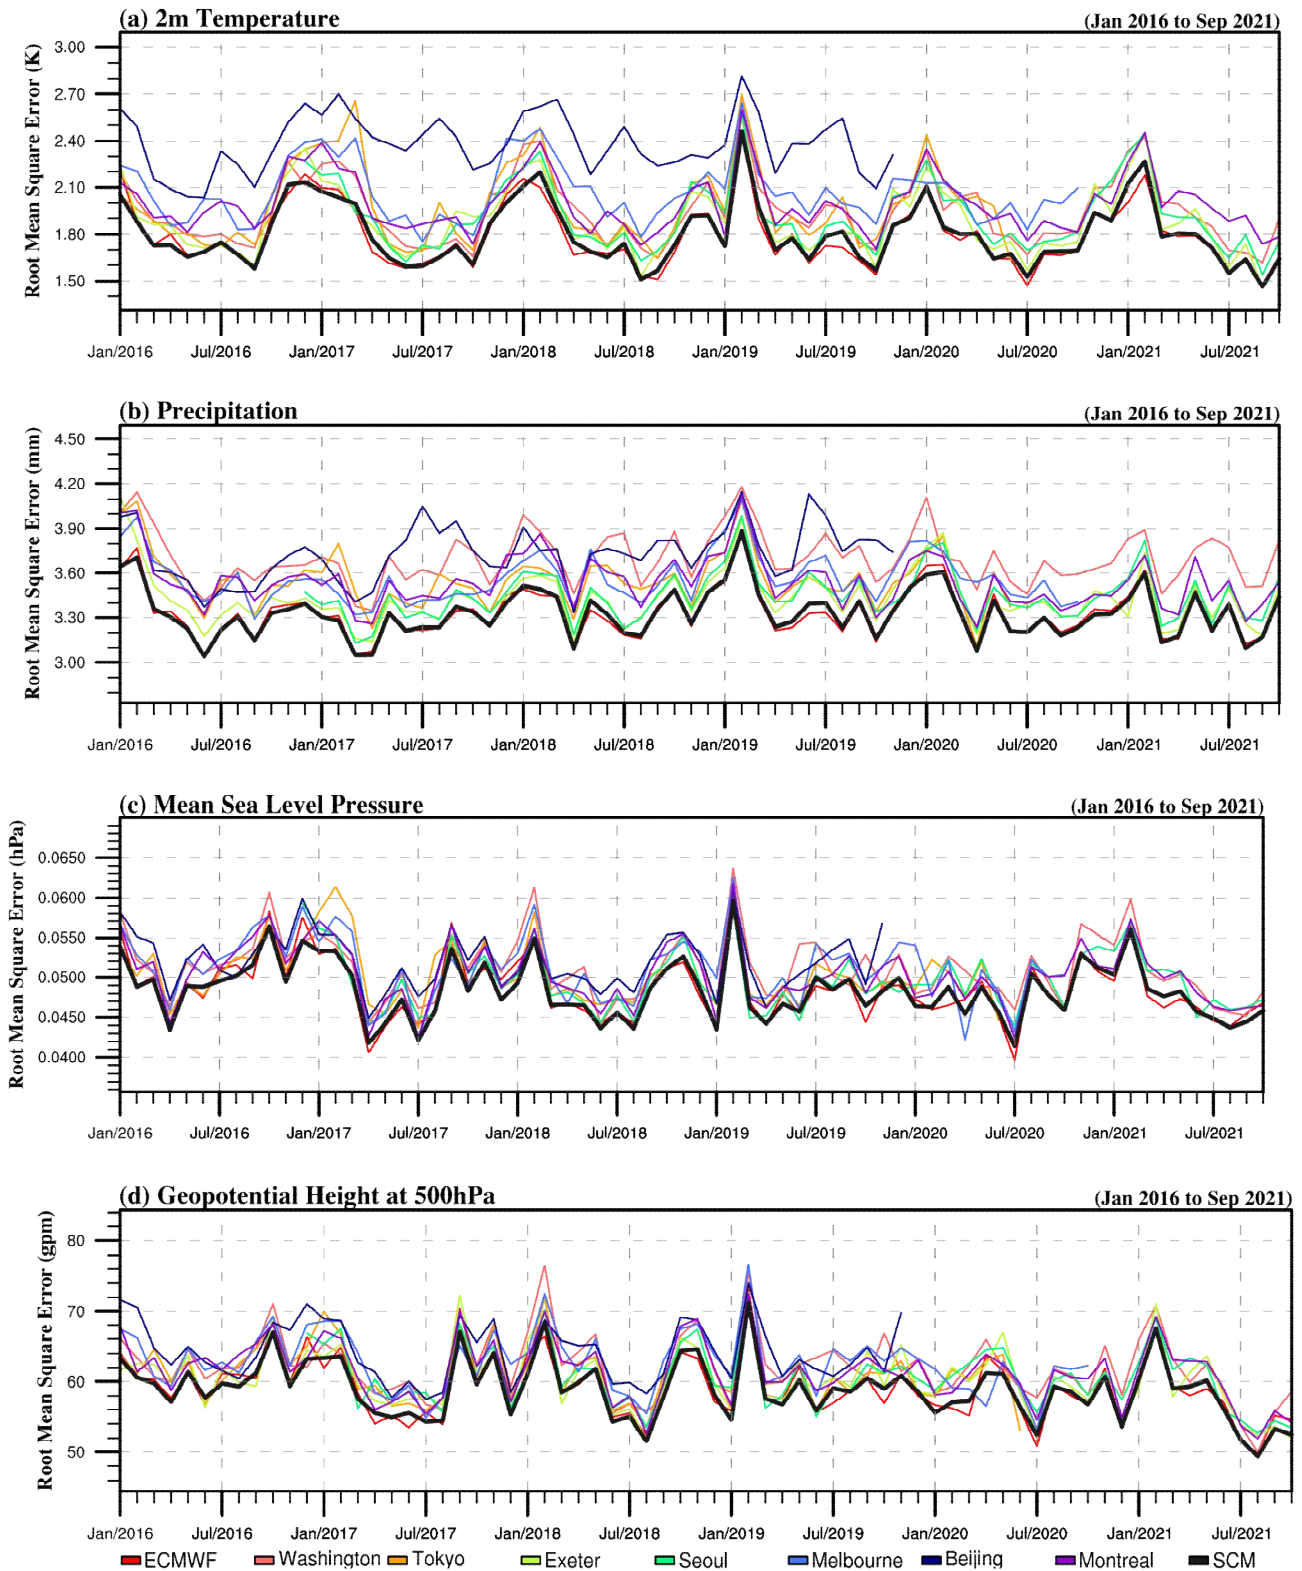


Figure 154. Root mean square error (RMSE) of monthly averaged 3 weeks real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2016 to Oct 2021 over the globe. RMSE for SCM prediction is indicated by black line.

(2) 현업 장기예보 지원

(가) 1개월 예보

지금까지 장기예보를 위한 GloSea5 및 ECMWF 개별모델 예측관련 콘텐츠는 기상청 기후 예측과에서 생산하고 PPT 형식의 파일로 제공해 주었다. 올해 하반기부터 APCC와 기상청 슈퍼컴퓨터센터를 잇는 전용 통신망 체계가 구축됨에 따라 슈퍼컴퓨터 내 자료 접근이 가능한 환경이 마련되었다. 따라서 APCC-기상청 슈퍼컴퓨터 전용 통신망을 활용하여 개별모델 고해상도 장기예보 자료를 수집하고 APCC HPC에서 장기예보 활용 콘텐츠를 자체 생산할 수 있는 시스템을 구축하였고, 매주(매월) 예측자료를 생산함에 따라 1개월(3개월) 전망 예보토의 업무에 실질적인 지원을 하고 있다. GloSea5 및 ECMWF 장기예보 자료 수집 및 콘텐츠 생산 시스템 운영에 대한 자세한 내용은 부록으로 수록하였다. APCC 자체 시스템을 운영함에 따라 상시 발생하는 문제에 즉각 대응이 가능하여 현업 업무 소요시간을 단축시킬 수 있고, 예측 원시자료에 대한 접근이 용이하여 장기예보 활용 콘텐츠 확장이 가능할 것으로 기대한다.

① ECMWF 예측 선행 시간 및 기후값 계산 방법에 따른 민감도 테스트

APCC의 1개월 전망 예측에서 사용하는 모델 자료는 기본적으로 WMO 장기예보 선도센터 계절내 예측자료를 사용한다. 이 예측자료로 바탕으로 MME 예측을 수행하며, 그러기 위해 여러 모델을 모두 수집해야 하며 일정한 시간이 소요된다. 따라서 예측기준 날짜(예측이 수행되는 주의 월요일) 보다 한주 전 목요일 전후의 초기장으로 예측이 수행된 모델 결과를 사용하게 된다. 그 결과 실제 예측이 시작하는 시점보다 4일 전의 초기장을 사용하게 되며 이는 계절내 예측 시간 규모에서 예측시간이 증가함에 따라 급격히 감소하는 예측성의 특성상 상당한 예측성의 손해로 귀결된다. 따라서 계절내 MME 예측 결과와는 별도로 최신의 초기장을 사용한 계절내 예측결과를 제공하기 위해 2020년부터 추가 자료를 수집하여 예보에 활용하고 있다.

이때 기상청 1개월 전망을 위해 추가로 수신하는 예측 모델은 ECMWF와 GloSea5이다. 이 중 가장 예측성이 우수하고 많이 활용하는 ECMWF의 예측성에 대한 두가지 민감도 테스트를 수행해 보았다. 먼저 ECMWF 초기장 변경에 따른 예측성을 비교하였다. ECMWF 계절내 예측 모델은 매주 월요일과 목요일 초기장을 바탕으로 수행하고 있으며, 목요일 초기장 예측은 기존에 계속 활용해온 자료이고, 월요일 초기장 예측은 추가로 활용하고 있는 자료이다. 월요일 초기장 자료를 1개월 전망에 활용 시 보다 최근의 정보를 사용하므로 보다 나은 예측정보를 제공할 것으로 예상되며 정량적으로 얼마나 향상되는지 분석하였다. 두 번째로 ECMWF 기후값 계산시 사용하는 hindcast 자료의 세트 수에 따른 예측성의 차이를 분석하였다.

ECMWF hindcast 기간은 20년 전부터 1년 전까지로 최근 20년간의 기간을 사용하며, 1년에 11개의 앙상블 멤버를 가지고 있다. 이렇게 forecast와 동일한 날짜의 hindcast 자료는 총 220개 멤버이며, 이를 평균하여 모델의 기후값으로 사용한다. ECMWF hindcast 또한 forecast와 동일하게 매주 월요일과 목요일을 기준으로 생산하며, forecast보다 2~3주 빠르게 자료를 제공하고 있다. 이를 활용하면 기존 대비 3배수의 hindcast 자료를 사용하여 모델의 기후값 계산에

사용할 수 있으므로 특정 이벤트의 극값에 외곡이 덜한 기후값을 생산할 수 있을 것으로 기대된다. 즉 월요일 초기장 forecast에 대응하는 hindcast는 이전주 목요일과 동일날짜 월요일, 같은 주 목요일 초기장의 hindcast를 사용하고, 목요일 초기장 forecast에 대응하는 hindcast는 같은 주 월요일과 동일날짜 목요일, 다음 주 월요일 초기장의 hindcast를 사용한다.

위와 같은 조건의 ECMWF forecast 예측성 비교 검증은 2019년 1월부터 2021년 8월까지 총 139회 예측결과에 대하여 수행하였다. 실험 ‘Thu_1set’은 목요일 초기장 forecast에 목요일 1세트 hindcast만을 사용한 기후값으로 아노말리를 계산한 실험이다. 실험 ‘Mon_1set’은 월요일 초기장 forecast에 월요일 1세트 hindcast만을 사용한 기후값으로 아노말리를 계산한 실험이다. 실험 ‘Mon_3set’은 월요일 초기장 forecast에 목요일-월요일-목요일 3세트 hindcast를 사용한 기후값으로 아노말리를 계산한 실험이다. 검증은 동아시아 영역(10-60N, 80-180E)에 대해 ACC 검증 방법과 RMSE 검증 방법으로 수행하였다.

ECMWF 초기장 변경과 hindcast 확대에 대해 ACC 검증한 결과를 Figure 155에 비교하였다. 기준이 되는 ‘Thu_1set’은 검은색 실선으로 표시하였고, ‘Mon_1set’은 파란색 실선으로 표시하였다. 모든 변경사항을 적용한 ‘Mon_3set’ 실험은 붉은색 실선으로 나타내었다. 검증은 (a) T2M과 (b) PREC, (c) MSLP, (d) Z500 총 4개 변수에 대해서 비교하였다. ACC는 4개의 변수 모두에서 동일한 경향으로 분석되었다. MME에 사용되는 기존의 ECMWF 예측 방법인 ‘Thu_1set’ 실험대비 다른 두 실험에서 뚜렷한 예측성의 상승을 보였으며, 특히 1주에서 3주까지 예측 초기의 예측성 상승이 크게 나타났다. 다만 6주 예측의 경우에는 각 실험에 따른 ACC 값의 차이가 거의 없었다. 계절내 예측의 경우 예측 초반에 급격한 예측성의 하락이 있는데 4일의 초기예측시간의 낭비를 제거한 결과 주평균한 예측에서도 1주 짧은 예측의 4/7 수준까지 ACC 값의 상승이 그대로 반영되었다.

하지만 ‘Mon_1set’과 ‘Mon_3set’ 실험 사이의 ACC 값 매우 적은 차이를 보였다. 특히 T2M은 1주부터 6주 예측까지 모든 예측 시간에 대해서 차이가 없었다. 또한 기후값 계산시 극값의 영향이 클 것으로 추정되는 PREC 변수의 경우에도 ACC 값 차이는 적었다. 상대적으로 MSLP와 Z500 변수의 4주 이후 예보에서 ACC 차이가 나타났으며, ‘Mon_3set’ 실험의 경우에 더 높은 ACC 값을 보였다.




Figure 155. Anomaly correlation coefficient of weekly mean prediction of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2019 to Aug 2021 over the East Asia.

ACC 검증과 동일한 실험 설정으로 RMSE 검증을 수행하여 Figure 156에 나타내었다. 목요일 초기장의 1세트 hindcast 자료를 사용하는 ‘Thu_1set’ 실험은 검은색 실선으로 표시하였고, 월요일 초기장 1세트 hindcast 자료를 사용하는 ‘Mon_1set’은 파란색 실선으로 표시하였다. 모든 변경사항을 적용한 ‘Mon_3set’ 실험은 붉은색 실선으로 나타내었다. 검증은 (a) T2M과 (b) PREC, (c) MSLP, (d) Z500 총 4개 변수에 대해서 비교하였다. ‘Thu_1set’ 실험 대비 월요일 초기장을 사용하는 실험은 PREC 변수를 제외하고 예보 4주까지 뚜렷한 RMSE 감소를 보였다. 하지만 PREC 변수는 4주 예측부터 실험 방법론에 따른 차이가 없으며, 다른 변수와 달리 지속적으로 RMSE 값이 증가하는 결과를 보였다. ‘Mon_1set’과 ‘Mon_3set’ 실험 간의 RMSE 검증 차이는 상대적으로 뚜렷하지 않았다. T2M의 경우 1주와 2주 예측시에 ‘Mon_3set’ 실험이 낮은 RMSE 값을 보였고, MSLP 변수와 Z500 변수 예측 4주 이후에서 ‘Mon_3set’ 실험이 보다 낮은 RMSE 값을 나타내었다.

이처럼 주별 예측 시작날짜와 모델의 초기장을 일치시킴으로써 모델 초기 4일의 예측을 낭비하지 않는 경우 예상대로 매우 큰 예측성의 이득이 있으며, 계절내 예측 시 이처럼 가장 최근의 초기장으로 예측한 모델의 결과를 기준으로 예측해야하는 당위성을 확보하였다. 반면, 실험전의 예상보다 hindcast 세트수의 증가에 대한 영향은 매우 적었다. 그 이유는 ECMWF는 1세트의 hindcast 앙상블 수가 11개로 많으며 20년의 hindcast 기간을 모두 사용하였을 시 220개의 예측결과를 활용하기 때문에 이미 충분한 자료를 확보한 것으로 보인다. 그래도 3세트의 값을 사용한 결과에서 작지만 예측성의 향상이 균일하게 보였기에 향후 현업에서도 hindcast 세트수를 3개로 늘리는 변경작업을 수행해야 할 것으로 판단된다.




Figure 156. Root mean square error of weekly mean prediction of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period Jan 2019 to Aug 2021 over the East Asia.

② 1개월 전망 추가 콘텐츠 개발

현재 제공하고 있는 계절내 MME 예측 결과의 현업 예보 활용도 향상을 위해 수시로 기상청 예보관의 의견 등을 반영한 추가 콘텐츠를 개발하고, 활용도가 떨어지는 콘텐츠는 제외하고 있다. 올해의 가장 큰 변화는 기상청 기후예측과 모델개발팀의 발표자료를 APCC 계절/계절내 예측발표 시 통합하여 발표하는 것이며, 이에 관한 내용은 부록으로 수록하였다. APCC가 생산하는 올해 추가 콘텐츠로는 기상청 예보관의 요청에 따라 PMME 예측결과의 변화 경향을 보여주는 콘텐츠를 추가하였다. 또한, ECMWF 월요일 초기장 예측자료를 자료를 활용하여 Z500 Hovmoller diagram 예측정보를 생산하고, 북반구 Z500 편차장 예측결과와 Z500, MSLP, 850hPa 바람 편차장을 동시에 비교하는 콘텐츠를 추가하였다. 마지막으로 APCC 자체 1개월 예측 결과에 추가로 예측 관련 영향 인자와 그에 대한 설명을 서술하여 제공하고 있다.

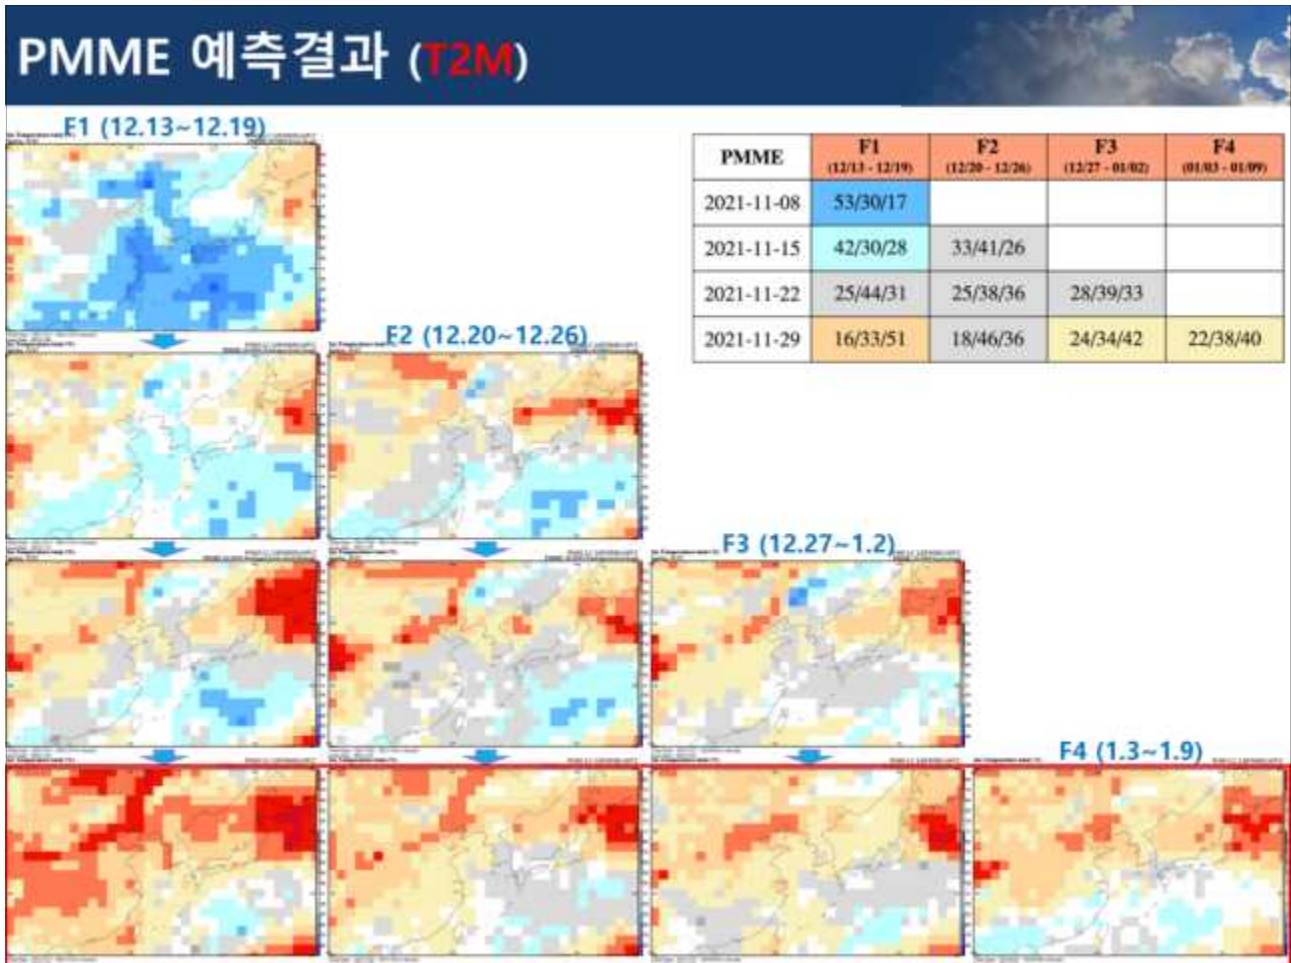


Figure 157. Sample of 1-month PMME prediction trend analysis chart.

먼저 2021년 2월부터 기온과 강수량 PMME 예측결과를 과거 4주전부터 최근 예측까지 차례로 보여주는 콘텐츠를 추가하였다(Figure 157). 모델의 예측 경향이 어떻게 변화해 왔는지에 대한 정보는 현재의 모델 예측정보가 과거부터 일관되게 예측하는 경우 더욱 신뢰할 수 있다고 판단할 수 있으며, 한 방향으로 예측 결과가 바뀌어 가는 경향이 있다면 앞으로도 같은 경향으로 바뀔 수 있다고 판단할 수 있는 근거가 된다. 이러한 정보를 더 손쉽게 파악할 수 있도록 과거 예측 결과부터 최근 예측까지 위에서 아래로 배치하며, 같은 예측대상 날짜는 동일한 선상에 배치하였다. 또한 우리나라 영역 평균한 확률값에 대한 정보도 오른쪽 위 부분에 같은 배치 방법으로 제공하였다. 해당 콘텐츠는 PMME 모델 기온과 강수량 예측 각각에 대하여 제공하고 있다.




Figure 158. Sample of Z500 Hovmoller diagram.

다음으로 ECMWF 월요일 초기장 예측자료를 자료를 활용하여 기존 Z500 변수 Hovmoller diagram 예측 콘텐츠에 예측의 변화경향을 더욱 잘 볼 수 있도록 강화하였다(Figure 158). Z500 변수는 앞선 여러 예측성 검증에서 보인바와 같이 다른 변수에 비해 예측성이 우수하며, 중위도 종관규모의 날씨 현상을 이해하는 데 가장 기본이 되는 예측변수이다. Z500 변수의 예측결과를 최대한 짧은 시간단위로 나타내기 위해 Hovmoller diagram 방식을 사용하여 시간축을 일 단위로 표출하였다. 평균하는 경도축은 126~135° E 이며, 이는 한반도를 포함하여 동쪽으로 치우친 영역이다. 이 보고서에 포함하지 않았지만 기존 연구결과에서 우리나라 평균기온과 Z500 변수의 동시상관관계를 분석하였을 때 한반도 동쪽 영역에서 높은 양의 상관관계를 보였기 때문이다. 이는 상층기압골 통과 후 하층의 대륙고기압 통과나 상층 기압능 발달 후 하층의 고기압의 영향이 우리나라 기온에 영향을 주기까지 시간지연이 있기 때문으로 분석되었다. Hovmoller diagram에서 표출하는 위도 영역은 19.5~60° N이며, 남쪽의 북서태평양 고기압의 발달과 한반도 북쪽을 통과하는 기압골을 모두 모니터링 할 수 있는 영역으로 설정하였다. 한반도에 해당하는 영역은 붉은색 실선으로 표시하여 한반도에 직접적인 영향이 신호를 쉽게 구분할 수 있도록 하였다. ECMWF 예측은 월요일과 목요일 초기장을 바탕으로 일주일에 2회 예측을 수행하며, 지난주 최종 예측과 이번주 예측사이에 한차례 예측이 추가로 존재한다. 이러한

세 번의 예측을 모두 한 장의 슬라이드에 표출 하며, 동일한 예측 시간대를 세로축에 따라 일치시켜 예측 결과 사이의 비교가 쉽게 하였고, 각 예측이 추가될 때마다 이전 예측과의 편차 값을 옆에 따로 표출한 콘텐츠로 개선하였다.

이 콘텐츠를 통해 세 번의 예측사이에 어떤 변화가 있었는지는 예보관에게 중요한 예측 인자로 활용된다. 기압골의 통과나 강한 양의 편차의 발달 등 예보 결정에 중요한 역할을 할 수 있는 신호가 세 번의 예측동안 동일하게 유지된다면, 해당 정보는 보다 높은 신뢰도를 가지면서 예보결정에 중요한 요소로 활용된다. 반면 특정 신호가 계속 변경된다면 예보관은 그 정보를 신뢰하지 못하고 다른 요소에 더 가중치를 두는 방향으로 예보를 할 것이다. 또한, 어떤 신호가 모델예측이 갱신됨에 따라 발달하거나 약화되는 추세가 일정하다면, 예보관은 그 추세가 계속 지속될 가능성이 높다고 판단하며, 가장 최근의 예측결과보다 더 가중하여 예보에 반영하는 방법으로 활용할 수 있다. 이는 모델이 현실의 기상/기후 환경의 변화를 바로 반영하지 못하고 뒤늦게 반응하는 사례가 다수 존재하였기 때문에 예보관의 경험에 따라 이 콘텐츠가 매우 유용할 수 있다.

다음으로 추가한 콘텐츠는 ECMWF Z500 예측 편차장을 ‘Polar Stereographic’ 으로 표출한 결과이다(Figure 159). 이때 예측정보는 지난주 목요일 초기장을 사용한 ECMWF 예측과 이번주 월요일 초기장을 사용한 ECMWF 주별 평균 예측결과이며, 하단에는 이 둘의 편차값을 표출하였다. 기존의 Z500 변수의 예측정보는 동아시아 영역을 중심으로 표출하였다. 하지만 우리나라 기온/강수량 예측에 중요한 기후예측 인자로 AO와 NAO 등이 널리 알려져 있으므로 해당 지역에 대한 모니터링이 필요하여 이 콘텐츠를 추가하게 되었다. 이를 통해 Z500 편차장의 패턴에 따라 AO와 NAO의 위상을 추정할 수 있으며, 유럽에서부터 진행되는 대기 중층의 파동에 대한 정보도 확인할 수 있다. 또한 앞선 콘텐츠와 마찬가지로 지난주 목요일 예측과 최신 예측 사이의 편차 값도 제공함으로써 모델 예측의 변화 경향까지 파악할 수 있도록 구성하였다.

Figure 160은 ECMWF Z500 예측 편차장에 추가로 동일시점의 상층과 하층의 예측결과를 동시에 볼 수 있도록 구성한 콘텐츠이다. 상단에는 Z200 예측 편차장을 배치하고, 하단에는 MSLP와 850hPa 바람 예측 편차장을 배치하였다. 이를 통해 상층-중층-하층의 예측결과를 동시에 보면서 입체적으로 예측결과를 분석 할 수 있다. 특히 Z200은 티벳 고기압의 발달 여부를 확인할 수 있으며, 우리나라에 고온이 지속될 수 있는 환경이 조성되는지 파악할 수 있다. 또 하층의 바람장 편차의 예측결과는 대기 하층의 수증기 수송과 밀접한 관련이 있으며, 예보관이 우리나라 강수량 예측을 위한 의사결정 시 중요한 참고자료로 활용된다.

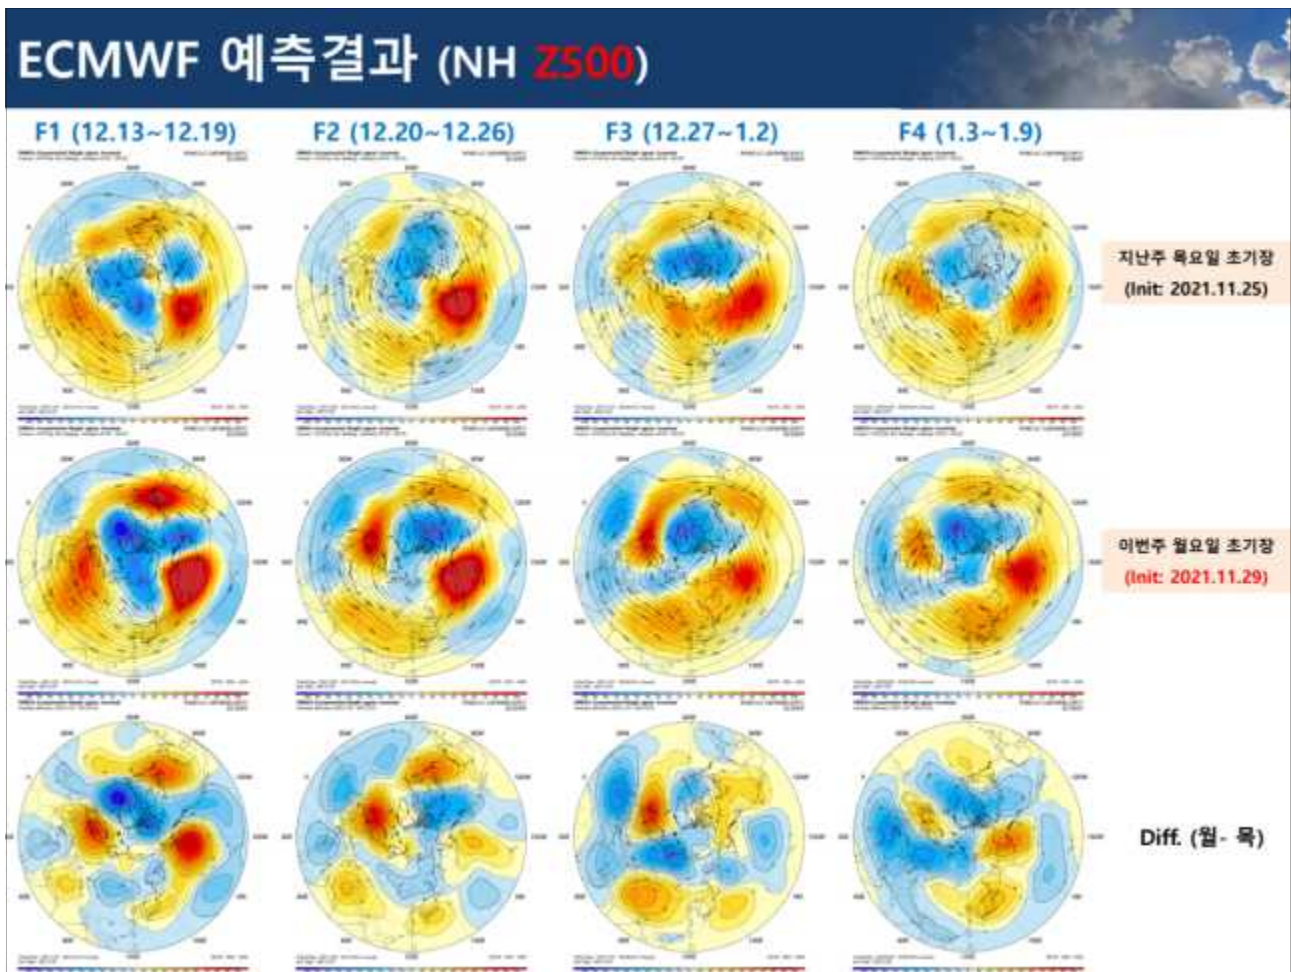


Figure 159. Sample of Z500 anomaly chart over Northern Hemisphere.

마지막으로 APCC 1개월 전망 최종 예측결과 요약 페이지를 개선하였다. 최초 WMO 계절 내 예측결과의 단순 제공으로 시작하였으며, 2020년 10월부터 모델 예측결과에 추가로 기후 예측인자 모니터링, 기상모델의 예측 경향을 종합적으로 분석하여 APCC 자체 1개월 예측결과를 생산하고 있다. 2021년 11월부터는 APCC 최종 예측결과와 함께 예측 근거에 대한 설명을 추가하였다(Figure 161). 각 예측에 대한 근거로 모델의 결과와 기후 예측인자의 동향, 중기 예측모델의 경향 등이 우리나라 기온과 강수 예측 시 ‘+’ 요인인지 ‘-’ 요인으로 작용하였는지 서술하여 기상청에서 APCC의 예측결과를 활용 시 보다 이해가 쉽고 유용하게 사용할 수 있도록 하였다. 이를 통해 기상청 1개월 전망에 더 적극적으로 지원하는 한편 APCC 내부적으로도 해당 예보 시점에 어떤 근거로 예측하였는지 명시적으로 기록을 남겨서 사후분석 시 유용하게 활용하는 자료가 될 것으로 기대한다.

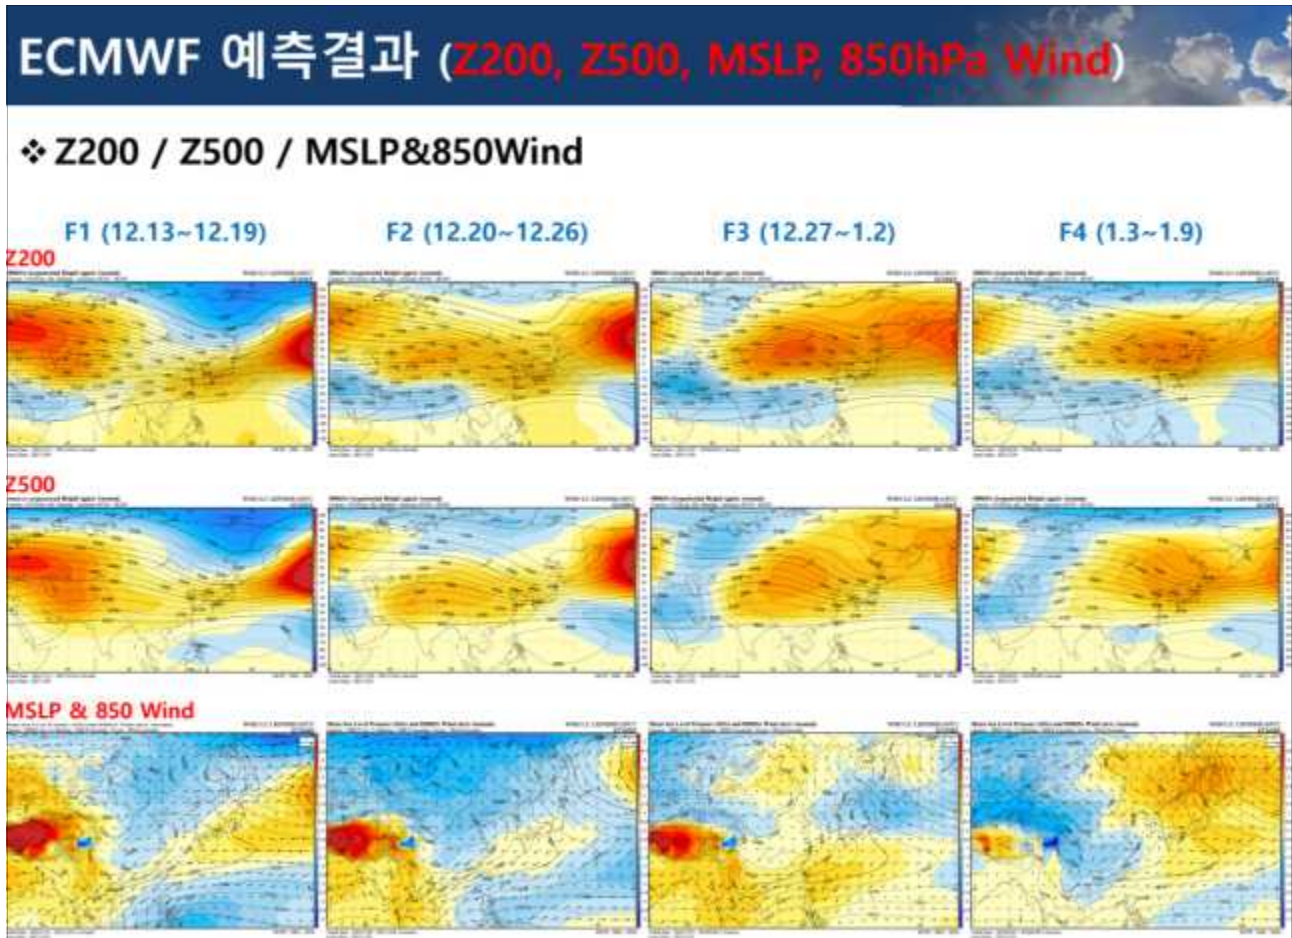


Figure 160. Sample of Z200, Z500, MSLP and 850hPa wind anomaly chart over East Asia.

APCC 1개월 전망 예측자료의 생산과 기상청에 제공하는 업무는 단순히 하나의 형식을 정하고 변화 없이 반복 작업을 수행하는 것이 아니라 앞선 설명한 사례와 같이 2021년에도 다양한 1개월 전망 콘텐츠를 추가/개선하였다. 이는 Figure 162에서 보이듯이 2021년 한해에도 발표자료가 크게 두 번 개편된 모습을 통해서도 알 수 있다. APCC 장기예보 전담팀에서는 예보관의 요구와 APCC 자체적으로 필요에 의한 다양한 콘텐츠를 적시에 추가하고, 활용성이 떨어지는 자료는 제외하면서, 최종적으로 더 나은 예측을 위한 지속적인 노력을 하고 있다.

APCC 최종 예측결과 요약

APCC	예보 1주	예보 2주	예보 3주	예보 4주
	12.6~12.12	12.13~12.19	12.20~12.26	12.27~1.2
기온	+	0/+	0/+	0/+
강수	0/-	0	0/+	0/+

- 1주: ECMWF 모델에서 강한 Z500 양의 편차 값과 ECMWF/GS5 모두 "+" 기온 예측
AO, NAO 지수가 다음주 중반 이후 상승, 예보 1주 도입 시 "+"로 변화, 필리핀 인근 대류 활동 강함
중기 예측일기도(KIM/ECMWF)의 상승골 위치는 예보 1주 시작 시 한반도 통과, 예보 1주는 한반도 남쪽 고기압
전반적으로 맑은 날씨, 상층골 발달이 약해서 강수량은 적은 경향, 비슷범위 상단 7.9mm로 "0/-" 예측
- 2주: Z500 양의 편차 경향 지속, 모델은 "+" 기온 예측. 다만 예보 2주는 다른기간 대비 Z500 편차값 작음
GS5/ECMWF "-" 강수 예측, 기온 상승과 더불어 한반도 남쪽의 고기압성 MSLP 편차
- 3~4주: 기온 상승 경향 지속, Z500 양의 편차, 모델 "+" 기온 예측
기온 상승과 함께 강수량 증가
- 모델의 급격한 예측 변화는 지난주 기온상승 등 초기장 영향보다는 열대의 대류활동(MJO)의 변화 영향으로 보임

KMA_GS5	예보 1주	예보 2주	예보 3주	예보 4주
기온	+	+	+	+
강수	0	-	-	0

ECMWF	예보 1주	예보 2주	예보 3주	예보 4주
기온	+	+	+	+
강수	-	-	-	-

21

Figure 161. Sample of final result table of APCC 1-month forecast.



Figure 162. APCC 1-month forecast presentation format. (a) Dec 2020, (b) May 2021 and (c) Sep 2021.

③ 1개월 전망 예측결과 검증

APCC는 2017년 8월부터 1개월 전망 예측시스템을 운영하면서 WMO 계절내 예측시스템 내의 다양한 예측 모델 결과를 우리나라 기온과 강수량 예측에 도움이 되는 콘텐츠로 구성하고 제공하는 역할로 출발하였다. 여기에 추가적으로 예보관의 요청에 따라 다양한 콘텐츠를 추

가로 개발하여 제공해오고 있으며, 수시로 예측결과에 대한 검증과 분석을 수행하고 있다. 2020년 10월부터는 APCC 자체 내부토의를 통해 기후예측인자와 모델 예측결과 등을 종합적으로 고려하여 APCC 1개월 예측결과를 생산하고 기상청 1개월 전망 예보토의 시 APCC의 의견을 개선하고 있다. 이렇게 예측결과를 생산한지 1년이 지나면서 그동안의 예측결과에 대한 검증을 수행해 보았다.

검증은 기본적으로 우리나라 기온과 강수량 삼분위 예측에 대한 HSS 값으로 하였으며, '0/+' 및 '0/-' 예측의 경우 삼분위로 정확히 예측하였을 때 대비 절반의 포인트만 적용하였다. 검증 기준값은 기후값 변경에 따라 두 가지가 사용되었다. 2021년 4월 이전의 경우 우리나라 ASOS 45개 지점의 평균값이며, 평년기간은 1981년부터 2010년까지이고, 2021년 5월 이후로는 62개 지점의 평균값에 평년기간은 1991년부터 2020년까지이다. 검증기간은 예측 대상날짜 기준으로 2021년 1월 4일부터 2021년 11월 8일까지 총 45회 예측한 결과이다. 검증에 해당하는 예측은 실제 1개월 전망으로 발표하는 3주부터 6주까지의 예보이다. APCC 예측과 비교한 모델의 예측 결과는 기상청 모델 개발팀에서 예측하고 있는 GloSea5와 ECMWF 예측이다. 이 두 모델은 매주 화요일 예보시점에서 가장 최근의 초기장을 활용한 모델 예측 결과이며, 여러 계절 내 예측모델 중에서도 상대적으로 우수한 예측성능을 보여주고 있다.

검증결과에 대한 해석 시 기본적으로 참고할 사항은 다음과 같다. HSS 값이 0 이상이면 유의미한 예측을 수행하고 있다고 볼 수 있으며, 모델의 hindcast 검증 결과를 참고하였을 때, 장기예보에서 0.1 값을 넘기면 비교적 우수한 예측으로 판단된다. 삼분위 예측에서 한가지 예측만 계속하면 예측 성공과 상관없이 HSS 값은 0이 된다. ECMWF 모델의 예측결과는 기상에서 기후 예측까지 가장 우수한 예측성능을 보이는 모델로 알려져 있다. 1개월 전망 시 4주에서 6주 예측은 다음 예측에서 수정이 가능한 데 반해, 3주 예측은 최종적으로 확정되는 예측이며, 중기예보와 이상기후 예측 등에 중요하게 활용되므로 1개월 전망에서 상대적으로 더 중요한 예측이라고 할 수 있다.

먼저 기온 예측 검증 결과는 Figure 163에 나타내었다. APCC는 우리나라 3주 기온 예측에서 HSS 값이 0.235로 매우 높은 값을 기록하였다. 또한, 상대적으로도 GloSea5와 ECMWF 대비 우수한 예측을 수행하였다. 3주 예측은 ECMWF 모델 결과 대비 근소한 차이로 HSS 값이 높았으며, 4주 예측에서는 ECMWF 모델의 예측이 더 높은 값을 보였다. 반면 GloSea5는 주로 '+' 예측 경향이 매우 강한 결과 3주와 4주 예측에서 음의 값을 보였다. APCC의 예측결과 중 5주와 6주는 음의 값이 나타났는데, 그 원인으로 이 시점에 대한 예측 시 모델의 예측결과 외 참고할 다른 요소가 적으며, 상대적으로 3~4주 예측에 집중한 결과로 보인다.

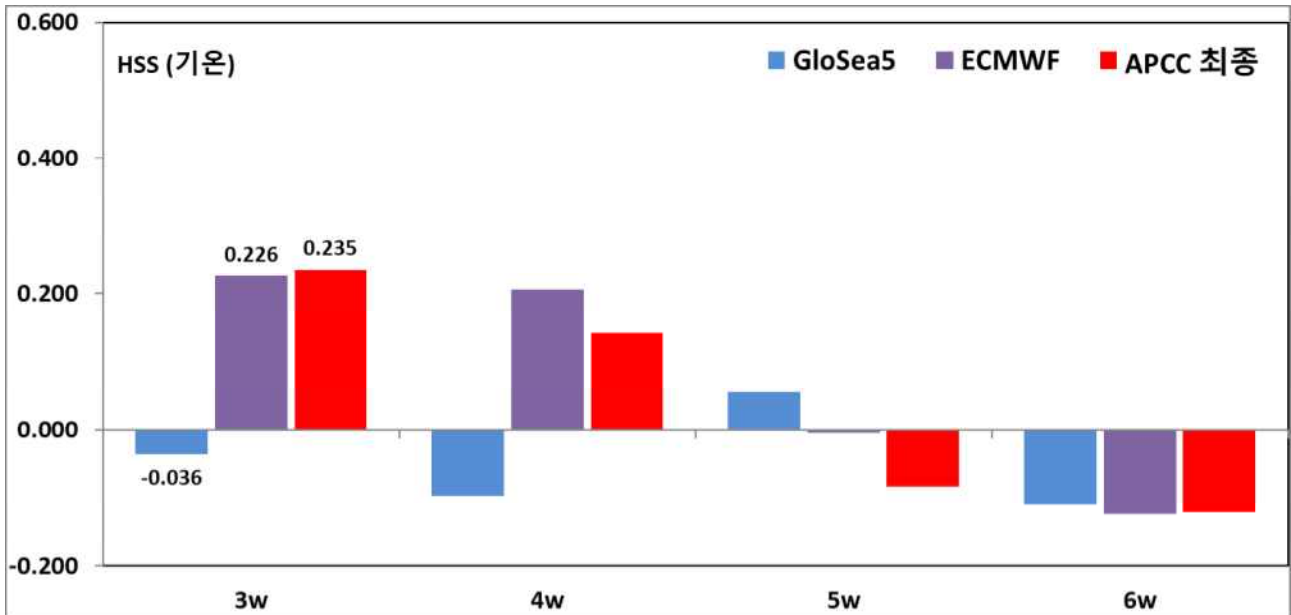


Figure 163. Heidke skill score for 2m temperature forecast of GloSea5, ECMWF and APCC from Jan 2021 to Nov 2021.

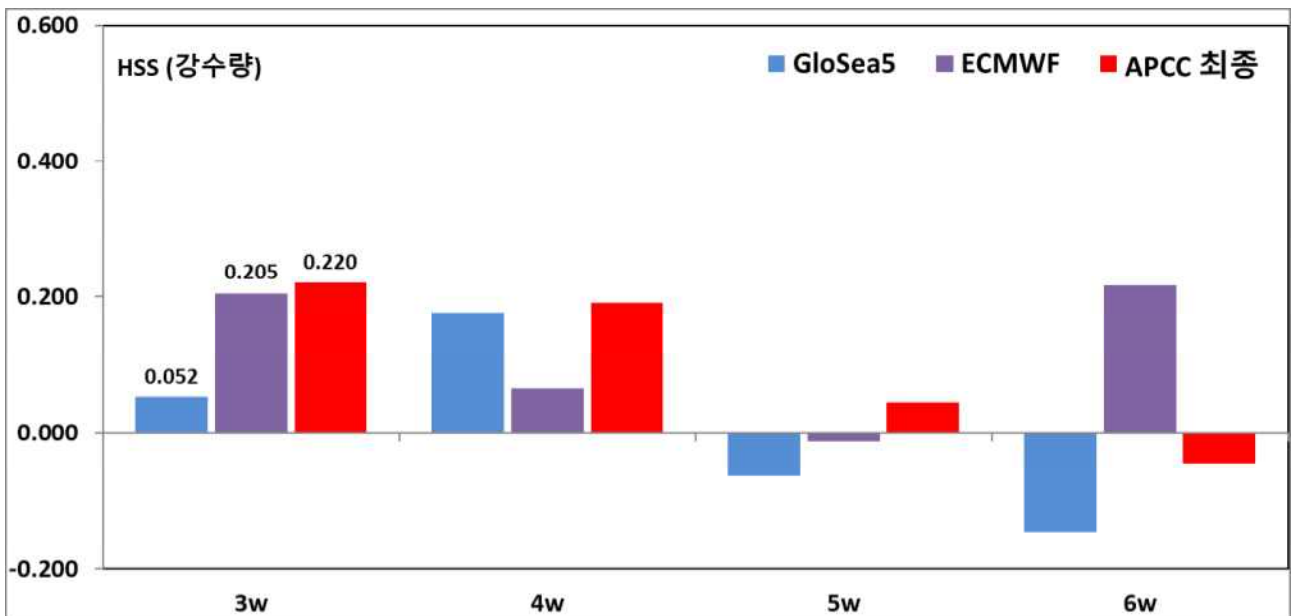


Figure 164. Heidke skill score for precipitation forecast of GloSea5, ECMWF and APCC from Jan 2021 to Nov 2021.

강수량 예측 검증 결과는 Figure 164에 나타내었다. 강수량 3주 예측에서도 APCC는 0.22라는 높은 HSS 값을 기록하였다. 상대적으로 GloSea5와 ECMWF 예측보다 높은 수치이며, 4주 예측에서도 상대적으로 가장 우수한 예측 결과를 보였다. 5주 예측에서도 양의 값을 기록하였다. GloSea5는 기온 예측과 달리 3주와 4주 예측 시 양의 값을 보였으며, 특히 4주 예측은

ECMWF 보다 높았다. APCC는 강수량 예측 시 평년 강수량의 비슷 범위를 많이 고려하였으며, 모델의 예측 변화 경향을 바탕으로 하층 기압계의 통과 시점과 특징에 대한 보정을 통해 모델 보다 우수한 예측을 수행하였다.

다음으로 검증기간 동안 실제 어떻게 예측이 수행되었으며, 시기별로 예측성의 어떤 변화를 보였는지 분석하였다. Figure 165와 Figure 166은 GloSea5와 ECMWF, APCC가 예측한 결과와 ASOS 관측값을 나타낸 표가 하단에 있으며, 상단은 12주씩 이동하며 계산한 HSS 값을 나타내었다. 그래프에서 붉은 색은 APCC이며, 파란색 실선은 GloSea5, 보라색 실선은 ECMWF이다. 그래프의 점은 앞선 6회의 예측과 이후 5회의 예측 결과를 합쳐서 12회 예측한 HSS 값을 나타낸다. 분석에는 예측 선행시간은 3주인 예측만 사용하였다.

Figure 165에서 나타낸 바와 같이 2021년의 기온 예측한 결과를 보면 APCC는 꾸준히 상대적으로 높은 HSS 값을 보였다. 다만 8월을 전후로 여름철에는 ECMWF의 기온 예측성이 우수하였다. 2021년은 1월 중순부터 3월까지 고온이 계속 지속되다가 4월부터 5월까지 나타난 비슷 또는 낮은 기온에 대한 예측이 모델과 APCC 모두 대부분 틀렸다. 또한, 8월에 발생한 낮은 기온도 예측이 어려웠다. 봄철에 기온이 급감하는 시점의 예측과 가을철에 기온이 낮아지는 추세가 이어지다 일시적으로 높아지는 시점에 대한 예측이 가장 취약한 부분으로 분석된다. 하지만 APCC는 5월과 6월의 평년과 비슷한 기온을 정확히 예측하였으며, 10월 중순부터 기온이 급감하는 시점을 정확히 예측함으로써 상대적으로 우수한 결과를 기록하게 되었다. 앞으로 보다 나은 1개월 기온 예측을 위해서는 봄철과 여름철의 기온 하강을 예측할 수 있는 기술 개발이 필요하다.

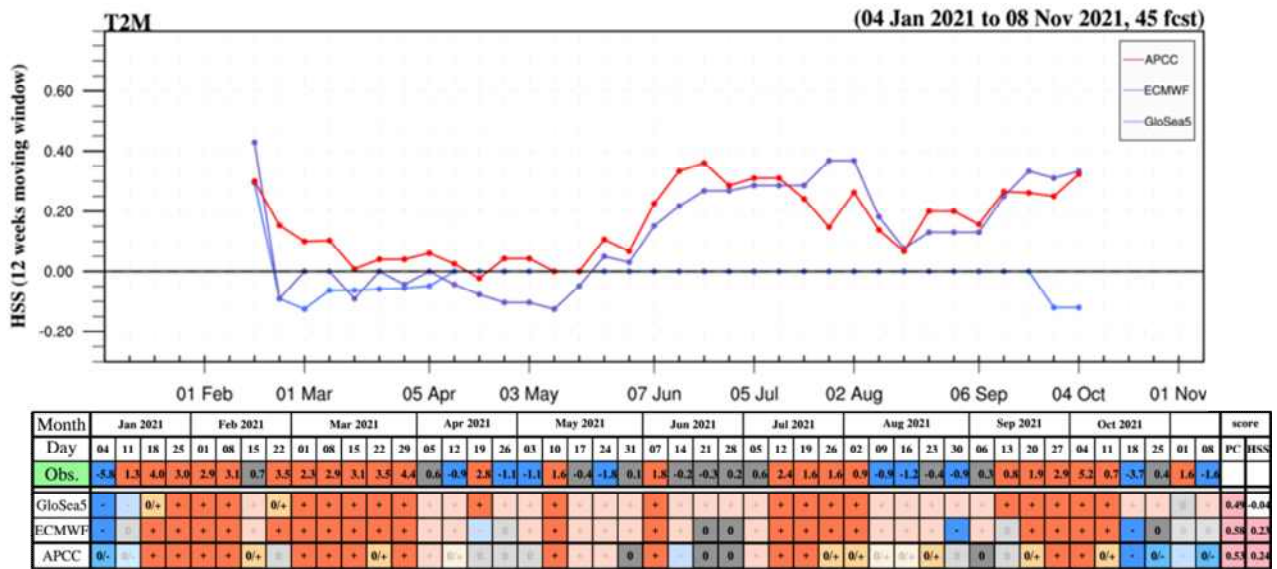


Figure 165. 12 weeks moving window Heidke skill score of GloSea5, ECMWF and APCC at temperature forecast. Table is 3 lead time forecast results.

2021년 강수량 예측에 관한 결과는 Figure 166에 나타내었다. APCC는 여름철을 제외하고 꾸준히 0.2 내외의 높은 HSS 값을 기록하였다. 반면 ECMWF는 여름철에 상당히 높은 예측성을

보였다. 이 시기에 한반도는 북쪽의 시스템에 의한 영향보다 적도의 기단과 계절내 진동의 영향을 주로 받았으며, 이 부분에서 강점을 보이는 ECMWF 모델이 2021년 여름에 매우 우수한 예측 결과를 보인 것으로 분석된다. 하지만 겨울철과 봄철에 전반적으로 강수량을 많은 경향으로 예측하였기 때문에 전 기간을 보면 APCC의 예측성이 더 높게 나타났다. 앞으로 여름철 적도의 계절내 진동이 뚜렷할 경우 ECMWF 강수량 예측 결과를 상당히 높은 가중치로 예보에 반영할 필요가 있다고 판단된다.

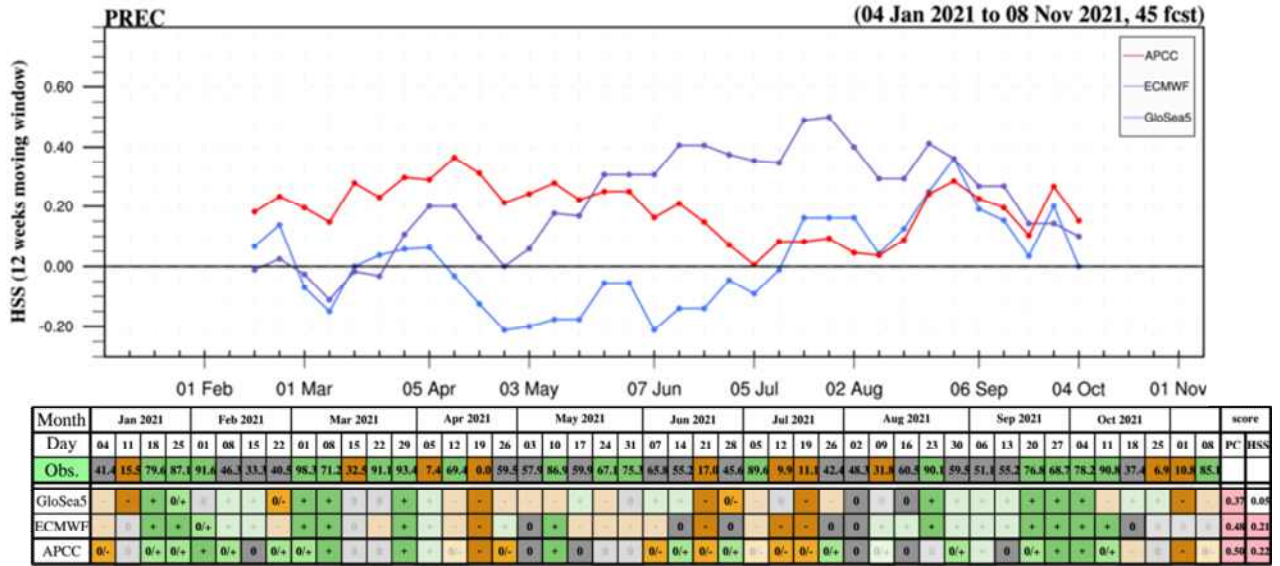


Figure 166. 12 weeks moving window Heidke skill score of GloSea5, ECMWF and APCC at precipitation forecast. Table is 3 lead time forecast results.

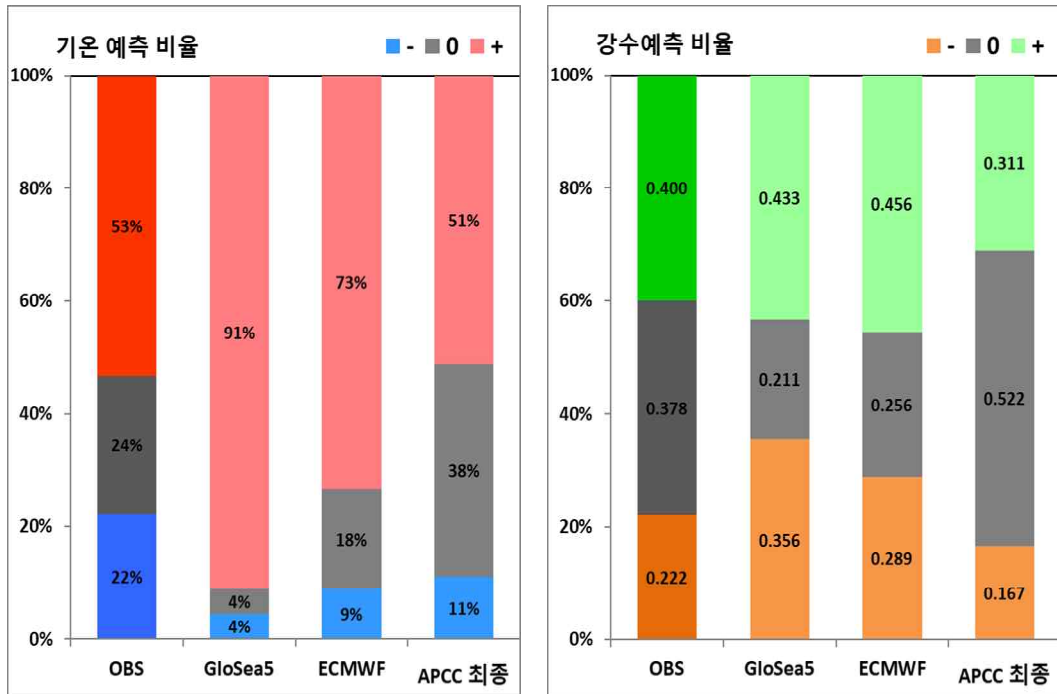


Figure 167. The ratio of above normal, near normal and below normal categorical forecast of GloSea5, ECMWF and APCC.

APCC의 3주 예측의 결과가 상대적으로 우수한 결과를 보인 점을 분석해 보면, 관측과 매우 유사한 비율로 3분위 예측을 수행한 점을 들 수 있다(Figure 167). GloSea5 기온 예측의 경우 ‘+’ 예측의 비중이 91%를 넘으며, ECMWF 조차 73%의 비중으로 ‘+’ 기온을 예측하면서 실제 53% 대비 상당히 높은 비율임을 알 수 있다. APCC는 이처럼 계절내 예측 모델이 warm bias가 매우 큰 것을 고려하여 이를 보정하여 활용함으로써 모델예측보다 나은 결과를 얻을 수 있었다. 강수량 예측의 경우에는 모델은 양 극단으로 예측하는 비율이 실제보다 큰 것을 보여준다. APCC는 이를 보완하여 중간값의 경우를 늘렸으며, 이를 통해 예측성의 향상을 가져왔다. 다만 기온과 강수량 예측 모두 APCC는 ‘0’로 예측하는 비율이 실제보다 크므로 이 부분을 조금 줄이는 방향으로 보완할 필요가 있다.

여기서 보이지는 않았지만, 기상청은 1개월 전망 예보토의 전 예측 초안을 생성하며, 예보토의 후 최종 예측을 생산하여 발표한다. 2021년의 45회의 예측에서 기상청은 예측 초안 대비 최종 예측결과에서 예측성이 상당히 개선되었다. 예보토의와 다양한 분석이 추가되어 이러한 성과를 이루었다고 볼 수 있으며, 여기에 APCC의 우수한 예측결과가 많은 도움이 되었을 것으로 판단된다.

4. 요약 및 결론

APCC는 MME 기술을 바탕으로 신뢰도 높은 기후예측정보 생산 및 서비스를 목표로 하고 있으며, 이를 토대로 기상청 현업 장기예보 생산에 지속적으로 기여하고 있다. 이와 관련하여, 본 연구에서는 APCC-기상청 협력을 통해 현업 장기예보 개선에 기여할 수 있는 연구를 수행하였다. 또한, 기후예측 전문가 그룹으로서 WMO 장기예보 선도센터를 2011년부터 계속하여 운영하고 개선하여 왔으며 이는 현업 장기예보 생산에 중요한 자료로 활용되고 있다. 2017년 장기예보 현업지원을 위한 APCC 전담팀 구성 이래, 장기예보 정확도 개선을 위한 다양한 연구가 진행되어 왔는데, 역학모형의 서태평양 대류활동 특성에 따른 우리나라 강수 예측 기법개발, 상세화 기법을 응용한 한반도 계절예측 전문가 시스템(EsPreSSO) 개발, ENSO와 AO 위상에 따른 우리나라 겨울철 주별 기온 예측기법 개발 등을 통해 우리나라 기후예측 기술 전문성 향상에 기여하였다. 그리고 2019년부터 2021년까지 5단계 아태사업을 통해 실제 장기예보 현업업무에 활용할 수 있는 결과물을 도출하였으며, 이를 통해 기상청과의 협력체계를 통해 현업 장기예보 기술개발 및 개선에 기여하고자 하였다. 또한, 지난 다년간에 개발된 기술을 현업화하여 운영함으로써 장기예보 실무 분야의 역할을 정립하고자 노력하였다.

첫째, 장기예보 객관화 기술을 개발하여 3개월 예측에 적용, 현업 장기예보를 지원하였다. 비모수 베이지안 기계학습 모델인 가우시안 프로세스 모델을 이용하여 전국 및 지역별 이상기후지수 3개월 확률전망정보를 생산할 수 있도록 하고 이를 현업화하여 매달 3개월 장기예보에 활용할 수 있도록 하였다. 기계학습 모델의 입력자료로 다양한 관측자료 뿐 아니라 관측자료가 없는 기간에 대해 역학 기후모델의 예측자료를 활용하여 모델의 성능을 개선하였다. 또한 다양한 기계학습모델 및 역학모델의 결과를 베이지안 모델 평균 및 다중모델 슈퍼앙상블 기법을 이용하여 객관적으로 결합, 보다 안정적인 전망정보를 생산하도록 하였다. 이를 통해 방대한 정보를 객관적으로 통합하여 예보관의 의사결정을 효과적으로 지원하기를 기대한다.

둘째, 동아시아지역의 계절내 예측성을 개선하기 위해 딥러닝 기법을 적용하였다. 딥러닝 학습 모델은 U-NET 아키텍처를 기반으로 Bi-direction ConvLSTM, 채널 어텐션 메커니즘(channel-attention mechanism)인 SE(Squeeze and Excitation) 블록, DenseNet(Dense Convolutional Network)의 densely connected convolutions 기법, 전이학습 등을 이용하여 5 종류를 설계하고 실험하였다. 실험 결과로 U-NET 아키텍처에 SE 블록, 채널 어텐션 메커니즘, desnely connected convolutions 기법을 적용한 사례 4의 모델이 가장 좋은 예측성을 보였다. 현업관점에서 2016-2020년 ECMWF 월요일 예보자료 토대로 사례 4 모델에 계절추이(seasonal trend)를 다소 완화하기 위해 기후자료(climatology data)를 추가 입력하도록 모델을 개선하고 실험하였다. ECWFMF 예보자료는 총 51개의 앙상블 멤버로 구성되어 있는 본 연구에서는 CF(control file) 1개만을 이용하였다. 실험결과 전체 기간에 대한 예측성은 ECWFMF 예보자료에 비해 다소 낮지만, 계절을 고려한 평가에서는 SON 시즌은 ECWFMF 예보자료에 비해 예보 1주 차는 2016-2020년 모든 기간에서 좋은 성능을 보였다. 다른 시즌에서는 ECWFMF 예보자료에 비해 ACC 예측성을 다소 낮지만 큰 차이를 보이지는 않았다. 이러한 결과는 ERA-5 재분석자료를 이용하여 학습한 딥러닝 모델이 수치예보모델(NWP, Numerical Weather Prediction) 모델인 ECWFMF와 큰 ACC 편차가 발생하지 않았다는 것은 보다 더 정교한 딥러닝 모델 설계와 최

적화를 통해 ECMWF 예보자료의 개선이 가능할 것으로 판단된다.

셋째, 기상청 현업모델 편차보정을 통하여 최고·최저기온 1개월 확률예보 방안을 제시하였다. 최근 몇 년 간 기후예측모델의 3분위 예측결과 ‘높음’의 비중이 상대적으로 높고, 기온 예측의 편의가 일정값(최고/최저/평균: -1/-4/+1)을 유지하는 경향을 보여 왔다. 따라서 이러한 기후예측모델의 단정예보의 편차값을 보정하여 평균, 최고, 최저기온 예측정확도를 향상시키는 한편, 최고, 최저기온 장기전망 서비스 개발에 기여하기 위한 연구를 진행하였다. 기후예측모델의 편의값과 편의기후값 사이의 통계산출식 개발을 통해 편차를 보정할 수 있는 방안을 개발하고, 실제예측자료를 활용하여 예측성을 검증하였다. 이 결과를 바탕으로 기온 장기전망 예측성 향상과 함께, 최고, 최저기온 장기전망 서비스 개발에 기여할 수 있으며, 특히 내년부터 기상청에서 구축중인 내부시스템을 통해 현업화하여 예측결과를 제공함으로써, 이를 통해 예보관의 의사결정을 지원하고자 한다.

넷째, 현업에 활용되고 있는 통계 모델의 예측성 변화에 대해 살펴보았다. 모델이 개발된 시점부터 최근까지 모델의 예측 인자와 예측결과, 그리고 관측값의 상관관계 변화를 비교해보면 대부분 모델이 시간이 지날수록 예측인자와의 상관성이 낮아지고, 그에 따라 예측성능도 낮아지는 것을 알 수 있었다. 통계 모델은 개발 시점에 예측 타겟과 가장 상관성이 높은 예측인자를 선별하여 구성하기 때문에, 시간이 지남에 따라 그 특성이 변화할 경우 대응하기가 어렵기 때문이다. 인도양 해수면 온도 편차와 우리나라 8월 강수량의 관계를 살펴본 결과가 좋은 예시일 수 있다. 따라서, 이미 개발된 통계 모델을 지속적으로 사용하기 위해서는 개발 이후로도 계속해서 예측인자와 예측타겟의 상관성을 모니터링 하거나, 필요한 경우 예측인자를 대체하는 등의 노력이 필요하다.

다섯째, 주요 기후 예측 인자로서 여름철 계절내 진동(BSISO) 정보를 1개월 예보에 활용하고자 하였다. WMO ECMWF 계절내 예측자료를 활용함에 따라 가장 최신날짜의 초기장으로 6주 예측이 가능해졌으며 현업화를 통한 지속적이고 일관성 있는 정보를 제공할 수 있는 체계를 마련하였다. BSISO 지수 정보뿐만 아니라 영향 편차장도 함께 제공함으로써 BSISO 대류활동이 아시아 몬순 지역의 대기에 미치는 영향 정도를 보다 직관적으로 파악 가능하다. BSISO 위상에 따른 우리나라 6~8월 기온/강수 변동 및 관련 대규모 대기 순환을 분석한 결과 1) 기온이 높은 경향, 2) 기온이 낮은 경향, 3) 강수가 많은 경향, 4) 강수가 적은 경향이 나타나는 대표 BSISO 위상군을 선정하였으며 모식도 형태로 부록으로 첨부하였다. 우리나라 강수가 적었던 7월 마지막 주와 기온이 높았던 10월 둘째 주의 두 사례 분석을 통해 BSISO 영향 편차장의 3주 선행 예측성을 살펴본 결과, BSISO 강도는 과소모의 하는 경향이나 위상 변화는 잘 모의함에 따라 우리나라 기온 및 강수 전망 시 직간접적인 활용이 가능할 것으로 기대된다.

마지막으로, WMO 장기예보 선도센터 운영 및 개선에 관한 사항을 기술하였다. WMO 장기예보 선도센터는 전 세계 14개 Global Producing Center (GPC)에서 생산되는 장기예보 자료를 수집하여 표준화하며, DMME와 PMME 기법을 적용하여 얻은 MME 계절예측 결과와 검증결과를 홈페이지를 통해 디지털 및 그래픽 형태의 자료로 WMO 회원국 및 일반 사용자에게 지속적이고 안정적으로 제공하고 있다. 2021년에는 GPC CMCC가 추가되어 회원국에게 고품질의 예측정보를 서비스하게 되었다. 그리고 WMO 장기예보 선도센터 시스템 개선 용역과제를

2018년부터 수행하여, 더욱 안정적인 시스템 운영과 사용자 맞춤형 고품질의 예측정보를 서비스하기 위해 노력하였다. 2021년에는 특히 WMO 장기예보 선도센터 자료생산체계개선, 웹서비스 개선, 웹서비스 속도향상을 위한 자원 및 성능 최적화 측면에서의 시스템 개선이 수행되었다. 또한 WMO 장기예보 선도센터의 국제적 위상 증진과 계절 예측자료의 활용성 증대, 기후 예측 예보자 역량 강화 교육 프로그램에서 강의를 진행하는 등 기후 예측자료의 활용성 향상을 위해 계속적으로 노력하고 있다. 그리고 국제적 협업 체계 강화를 위해 WMO에서 주관하는 다양한 지역 기후 포럼에 맞춤형 MME 예측정보를 제공하고 Global Seasonal Climate Update (GSCU) 발간을 지원하였으며, WMO의 계절 예측 전문가 그룹과의 지속적인 소통 하고 있다. 이와 같은 WMO 장기예보 선도센터의 국내·외 활동과 안정적인 시스템 개선 노력을 통해 WMO 장기예보 선도센터의 기후예측 자료 활용도가 향상될 것으로 기대되며, WMO 장기예보 선도센터의 국제 사회에서의 역할과 입지를 강화할 수 있을 것으로 기대된다.

WMO 장기예보 선도센터 운영과 관련하여, 2021년에도 APCC 1개월 전망 예측시스템을 운영하며, 기상청 1개월 전망 지원을 성공적으로 완료하였다. 먼저 기후값 변화와 계절내 예측 모델의 변경에 따른 수정사항을 적용하고, 예측 모델 결과의 후처리 방법에 따른 민감도 테스트를 수행하면서 예측 시스템을 개선하였다. 그리고 다양한 1개월 전망 예측 콘텐츠를 적시에 추가하면서 예보관의 수요에 대응하고, 모델 결과에 대한 분석력을 높이는 데 이바지하였다. 개선된 콘텐츠의 활용과 더불어 기후 예측인자 모니터링을 강화하고, 단기예측 결과를 활용하면서 APCC는 기후 예측모델 대비 우수한 1개월 예측을 수행하였다. 이러한 APCC의 예측결과는 예보토의 시 기상청에 1개월 전망에 반영되면서 기상청의 예측력 향상에 도움을 주었다.

사사

이 연구는 APCC의 지원을 통해 수행 되었습니다. NCEP 재분석 자료와 CPC 강수자료는 NOAA/OAR/ESRL, Boulder, Colorado, USA 의 웹사이트 (<https://www.esrl.noaa.gov/psd/>) 로부터 제공되었습니다

References

- 권민호 외 (2015). 여름철 동아시아 몬순/장마 계절예측 기술 개발에 관한 연구과제 보고서 (CATER 2012-3070)
- 기상청, 기후예측과, 2018: 기후감시 및 분석 기반의 장기예보 가이드스(III). 245p.
- 기상청. (2011). 태풍백서
- 기상청. (2012). 한반도 영향태풍 분석 보고서
- 기상청. (2013). 한반도 영향태풍 분석 보고서
- 기상청. (2014). 한반도 영향태풍 분석 보고서
- 기상청. (2015). 한반도 영향태풍 분석 보고서
- 기상청. (2016). 한반도 영향태풍 분석 보고서
- 기상청. (2017). 한반도 영향태풍 분석 보고서
- 기상청. (2018). 한반도 영향태풍 분석 보고서
- 기상청. (2019). 한반도 영향태풍 분석 보고서
- 김가영, 김해정, 오지현, 유태우, 이운영, 정여민, 정유란, 정유림, 함수련, 윤순조, 2019: 다중모델 기반 계절내 예측 활용 가이드라인 개발. *APEC기후센터 연구보고서 2019*, 184pp.
- 김해정, 정유림, 함수련, 정여민, 2018: 여름철 계절내 진동 예측 정보 시스템의 실시간 운영. *APEC기후센터 연구보고서 2018*.
- 서경환 외 (2016). 물리·역학·통계 기반 우리나라 여름철 계절 내 강수 및 기온 변동 계절예측 기술 개발 연구과제 보고서
- 김진용, 서경환. (2014). 장마강수를 위한 앙상블 통계 예측 모델 개발. *대기*, **24**(4), 533-540.
- APEC climate center. (2016). Annual report
- Azad, R., M. Asadi, M. Fathy, and S. Escalera, 2019: Bi-directional ConvLSTM u-net with densely connected convolutions. *Proc. of the IEEE/CVF Int. Conf. on Comput. Vis. Workshop (ICCVW) 2019*, 1-10. <https://arxiv.org/abs/1909.00166>.
- Ahn, J.-B., and J. Lee, 2016: A new multimodel ensemble method using nonlinear genetic algorithm: An application to boreal winter surface air temperature and precipitation prediction. *J. Geophys. Res. Atmos.*, **121**, 9263-9277, doi:10.1002/2016JD025151.
- Breiman, L., 2001: Random forests. *Machine Learning*, **45**, 5-32.

- Cane, D., S. Barbarino, L. A. Renier, and C. Ronchi, 2012: Regional climate models downscaling in the Alpine area with Multimodel superEnsemble. *Hydrology and Earth System Sciences Discussions*, **9**, 9425–9454.
- Chen, D., Gao, Y., & Wang, H. (2019). Why Was the August Rainfall Pattern in the East Asia–Pacific Ocean Region in 2016 Different from That in 1998 under a Similar Preceding El Niño Background?, *Journal of Climate*, 32(18), 5785–5797.
- Du, J., J. Berner, R. Buizza, M. Charron, P. Houtekamer, D. Hou, J. Isidora, M. Mu, X. Wang, M. Wei, and H. Yuan, 2018: Ensemble methods for meteorological predictions. U. S. Department of Commerce, National Oceanic and Atmospheric Administration (NOAA), National Weather Service, National Centers for Environmental Prediction (NCEP), NCEP Office Note 493, pp. 66. <https://doi.org/10.7289/V5/ON-NCEP-493>.
- Ebert, E. E., 2001: Ability of a Poor Man’s Ensemble to Predict the Probability and Distribution of Precipitation. *Monthly Weather Review*, **129**, 2461–2480.
- Fang, M., and X. Li, 2016: Application of Bayesian Model Averaging in the Reconstruction of Past Climate Change Using PMIP3/CMIP5 Multimodel Ensemble Simulations. *Journal of Climate*, **29**, 175–189.
- Freund, Y., and R. E. Schapire, 1997: A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, **55**, 119–139.
- Graham, R. J., and Coauthors, 2011: Long-range forecasting and the Global Framework for Climate Services. *Climate Res.*, **47**, 47–55, doi:<https://doi.org/10.3354/cr00963>.
- Hagedorn, R., F. J. Doblas-Reyes, and T. N. Palmer, 2005: The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept. *Tellus, Series A – Dynamic Meteorology and Oceanography*, **57**, 219–233.
- Hersbach, H., B. Bell, P. Berrisford, S. Hirahara, A. horányi, J. Muñoz-Sabater, J. Nicolas, C. Peubey, R. Radu, D. Schepers, A. Simmons, C. Soci, s. Abdalla, X. Abellan, G. Balsamo, P. Bechtold, G. Biavati, J. Bidlot, M. Bonavita, G. D. Chiara, P. dahlgren, D. Dee, M. Diamantakis, R. Dragani, J. Flemming, R. Forbes, M. Fuentes, A. Geer, L. Haimberger, S. Healy, R. J. Hogan, E. Hólm, M. Janisková, S. Keeley, P. Laloyaux, P. Lopez, C. Lupu, G. Radnoti, P. d. Rosnay, I. Rozum, F. Vamborg, S. villaume, and J.-N. Thépaut, 2020: The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, **146**(730), 1999–2049, <https://doi.org/10.1002/qj.3803>.
- Holland, J. H., 1975: *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*, Univ. Michigan Press, 228 pp.
- Hu, J., L. Shen, G., Sun, 2018: Squeeze-and-excitation networks. *Proc. of 2018 IEEE/CVF*

Conference on Computer Vision and Pattern recognition, UT, USA, IEEE, 7132–7141, <https://doi.org/10.1109/CVPR.2018.00745>.

Huang, G., Z. Liu, L. Maaten, and K. Q. Weinberger, 2017: Densely connected convolutional network. *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition 2017*, Honolulu, Hawaii, 4700–4708, <https://arxiv.org/abs/1608.06993>.

Hwang, J., P. Orenstein, J. Cohen, K. Pfeiffer, L. Mackey, 2019: Improving subseasonal forecasting in the Western U.S. with machine learning. *Proc. of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Anchorage, AK, USA, 2325–2335, <https://doi.org/10.1145/3292500.3330674>.

Jensen J., 2016: *Introductory Digital Image Processing: A Remote Sensing Perspective*. Pearson, 4th Edition. pp. 656.

JMA, 2013: Outline of the operational numerical weather prediction at the Japan Meteorological Agency: appendix to WMO technical progress report on the global data-processing and forecasting system (GDPFS) and numerical weather prediction (NWP) research, Accessed 12 December, 2021, https://www.jma.go.jp/jma/jma-eng/jma-center/nwp/outline2013-nwp/pdf/outline2013_all.pdf.

Jolliffe, I. T., and D. B. Stephenson, 2003: *Forecast Verification: A Practitioner's Guide in Atmospheric Science*. Wiley, 254 pp.

Kanamitsu, M., W. Ebisuzaki, J. Woollen, S.-K. Yang, J. J. Hnilo, M. Fiorino, and G. L. Potter, 2002: NCEP/DOE AMIP-II Reanalysis (R-2). *Bulletin of the American Meteorological Society*, **83**, 1631–1643, <https://doi.org/10.1175/BAMS-83-11-1631>.

Kim, G., J. B. Ahn, V. N. Kryjov, S. J. Sohn, W. T. Yun, R. Graham, and J. P. Ceron, 2016: Global and regional skill of the seasonal predictions by WMO Lead Centre for Long-Range Forecast Multi-Model Ensemble. *Int. J. Climatol.*, **36**, 1657–1675.

Kirtman, B. P., and Coauthors, 2014: The North American Multi-Model Ensemble (NMME): Phase-1, seasonal-to-interannual prediction; phase-2, toward developing intraseasonal prediction. *Bull. Amer. Meteor. Soc.*, in press.

Krishnamurti, T. N., C. M. Kishtawal, T. E. LaRow, D. R. Bachiochi, Z. Zhang, C. E. Williford, S. Gadgil, and S. Surendran. 1999: Improved weather and seasonal climate forecasts from multimodel superensemble. *Science*, **285**, 1548–1550.

Krishnamurti, T. N., C. M. Kishtawal, Z. Zhang, T. E. LaRow, D. R. Bachiochi, C. E. Williford, S. Gadgil, and S. Surendran. 2000: Multimodel ensemble forecasts for weather and seasonal climate. *Journal of Climate*, **13**, 4196–4216.

- Krishnamurti, T. N., V. Kumar, A. Simon, A. Bhardwaj, T. Ghosh, and R. Ross. 2016: A review of multimodel superensemble forecasting for weather, seasonal climate, and hurricanes. *Reviews of Geophysics*, **54**, 336-377.
- Lecun, Y., L. Bottou, Y. Bengio, P. Haffner, 1998: Gradient-based learning applied to document recognition. *Proc. of IEEE*, 86(11), 2278-2324, <https://doi.org/10.1109/5.726791>.
- Lee, H.-Y., 1994: The Nopsae, a Hoehn Type Wind over the Young Suh Region of Central Korea. *Journal of the Korean Geographical Society*, **29**(3), 266-280.
- Lee J.-Y., B. Wang, M. C. Wheeler, X. Fu, D. E. Waliser, and I.-S. Kang, 2013: Real-time multivariate indices for the boreal summer intraseasonal oscillation over the Asian summer monsoon region. *Climate Dyn.*, **40**, 493-509, <https://doi.org/10.1007/s00382-012-1544-4>.
- McClelland, J. L., D. E. Rumelhart, and PDP Research Group. 1986: Parallel distributed processing. *Explorations in the Microstructure of Cognition*, **1-2**, 216-271.
- McCulloch, W. S., and W. Pitts. 1943: A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, **5**, 115-133.
- Min, Y.-M., V. N. Kryjov, and C.-K. Park, 2009: A probabilistic multimodel ensemble approach to seasonal prediction. *Wea. Forecasting*, **24**, 812-828, doi:10.1175/2008WAF2222140.1.
- Pal, M., and P. M. Mather. 2005: Support Vector Machines for Classification in Remote Sensing. *International Journal of Remote Sensing*, **26**(5), 1007-1011.
- Palmer, T. N., and Coauthors, 2004: Development of a European Multimodel Ensemble System for Seasonal-to-Interannual Prediction (DEMETER). *Bull. Amer. Meteor. Soc.*, **85**, 853-872.
- Pan, B., G. J. Anderson, A. Goncalves, D. D. Lucas, C. J. Bonfils, and J. Lee, 2020: Improving seasonal forecast using probabilistic deep learning. <https://arxiv.org/abs/2010.14610>.
- Platt, J., 1999: Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods. In *Advances in Large margin Classifiers*, Eds, Smola AJ, Bartlett P, Scholkopf B, Schuurmans, D. MIT Press.
- Raftery, A. E., T. Gneiting, F. Balabdaoui, and M. Polakowski. 2005: Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review*, **133**, 1155-1174.
- Rayner, N. A., D. E. Parker, E. B. Horton, C. K. Folland, L. V. Alexander, D. P. Rowell, E. C. Kent, and A. Kaplan, 2003: Global analyses of sea surface temperature, sea ice, and night marine air temperature since the late nineteenth century. *Journal of Geophysical Research*, **108**, 44-66, <https://doi.org/10.1029/2002JD002670>.
- Rhee, J., and B. Myoung, 2021: Objective and probabilistic long-range forecasts of

summertime air temperatures in South Korea based on Gaussian processes.. Weather and Forecasting. In Revision.

- Ronneberger, O., P. Fischer, and T. Brox, 2015: U-Net: Convolutional networks for biomedical image segmentation. *In: Navab, N., Hornegger, J., Wells, W.M., Frangi, A.F. (eds.) Medical Image Computing and Computere-Assisted Intervention (MICCAI) 2015*, Lecture Notes in Computer Science, **9351**, 234-241, https://doi.org/10.1007/978-3-319-24574-4_28.
- Rosenblatt, F., 1957: The perceptron: A perceiving and recognizing automation (Project Para). Report No. 85-460-1. Cornell Aeronautical Laboratory, Inc., Buffalo, NY.
- Shen, H., He, S., & Wang, H. (2019). Effect of summer Arctic sea ice on the reverse August precipitation anomaly in eastern China between 1998 and 2016. *Journal of Climate*, **32(11)**, 3389-3407.
- Shi, X., Z. Chen, H. Wang, D.-Y., Yeung, W.-k. Wong, and W.-c. Woo, 2015: Convolutional LSTM network: a machine learning approach for precipitation nowcasting. *Proc. of the 28th Int. Conf. on Neural Information Processing Systems*, Montreal, Quebec, Canada, Neural Information Processing Systems, 802-810, <https://arxiv.org/abs/1506.04214>.
- Shin, J.-Y., K. R. Kim, and J.-C. Ha, 2020: Seasonal forecasting of daily mean air temperatures using a coupled global climate model and machine learning algorithm for field-scale agricultural management. *Agricultural and Forecast Meteorology*, **281**, 1-16, <https://doi.org/10.1016/j.agrformet.2019.107858>
- Simonyan, K., and A. Zisserman, 2015: Very deep convolutional networks for large-scale image tecognition. *Proc. of The 3rd International Conference on Learning Representations (ICLR2015)*, San Diego, CA, USA, 1-14, <https://arxiv.org/abs/1409.1556>.
- Van den Dool, H. M., and Z. Toth, 1991: Why do forecasts for “near normal” often fail? *Wea. Forecasting*, **6**, 76-85.
- Vitart, F., and Coauthors, 2017: The Subseasonal to Seasonal (S2S) Prediction Project Database. *Bull. Amer. Meteor. Soc.*, **98.1**, 163-173.
- Widrow, B., and M. E. Hoff, 1960: Adaptive Switching Circuits. Technical Report No. 1553-1, Stanford Electronics Laboratories, Standord, CA.
- Wobus, R., and E. Kalnay, 1995: Three years of operational prediction of forecast skill. *Monthly Weather Review*, **123**, 2132-2148.
- Yang, J., Liu, Q., Liu, Z., Wu, L., and Huang, F. (2009), Basin mode of Indian Ocean sea surface temperature and Northern Hemisphere circumglobal teleconnection, *Geophys. Res. Lett.*, 36, L19705, doi:10.1029/2009GL039559. Yeo, S. R., Kwon, M., & Lee, J. Y. (2020). The

non-linear relationship between the western North Pacific anticyclonic circulation and Korean summer precipitation on subseasonal timescales. *Climate Dynamics*, **54**(1), 525–541.

YiBo Du, Jie Zhang, Siwen Zhao et al. A mechanism of spring Barents Sea ice effect on the extreme summer droughts in northeastern China, 08 April 2021, PREPRINT (Version 1) available at Research Square [<https://doi.org/10.21203/rs.3.rs-377893/v1>]

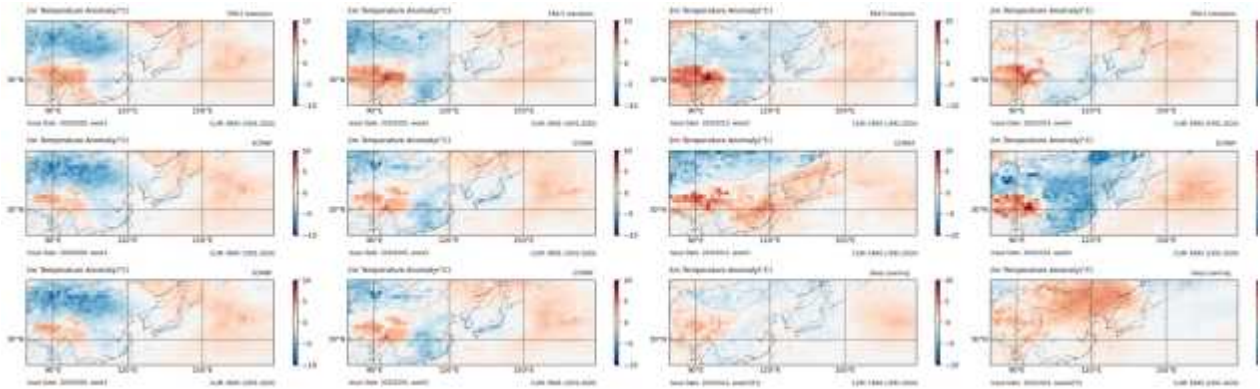
Yun, W. T., L. Stefanova, and T. N. Krishnamurti, 2003: Improvement of the multimodel superensemble technique for seasonal forecasts. *J. Climate*, **16**, 3834–3840.

Yuan, Y., Gao, H., Li, W., Liu, Y., Chen, L., Zhou, B., & Ding, Y. (2017). The 2016 summer floods in China and associated physical mechanisms: A comparison with 1998. *Journal of Meteorological Research*, **31**(2), 261–277.

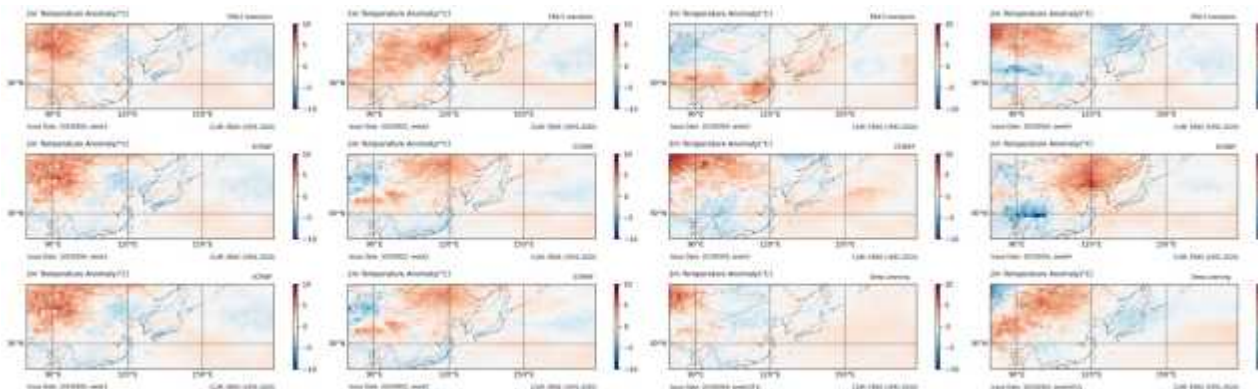
Zhang H., P.-S. Chu, L. He, and D. Unger, 2019: Improving the CPC' s ENSO Forecasts using Bayesian model averaging. *Climate Dynamics*, **53**, 3373–3385.

부록 A. 예보1주차 ECMWF 예보자료 대비 딥러닝 기법의 ACC 예측성 평가 상위 5위

Issue Date: 2020.09.28



Issue Date: 2019.08.26



Issue Date: 2017.10.02

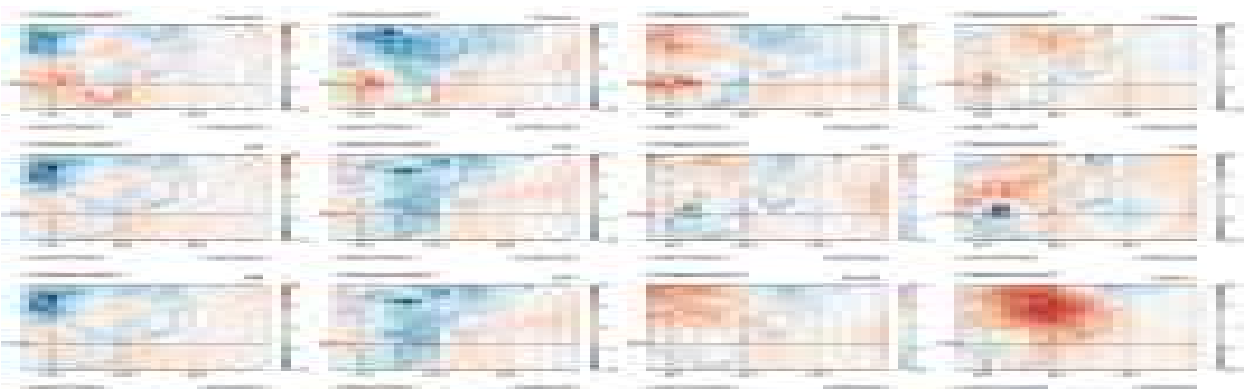
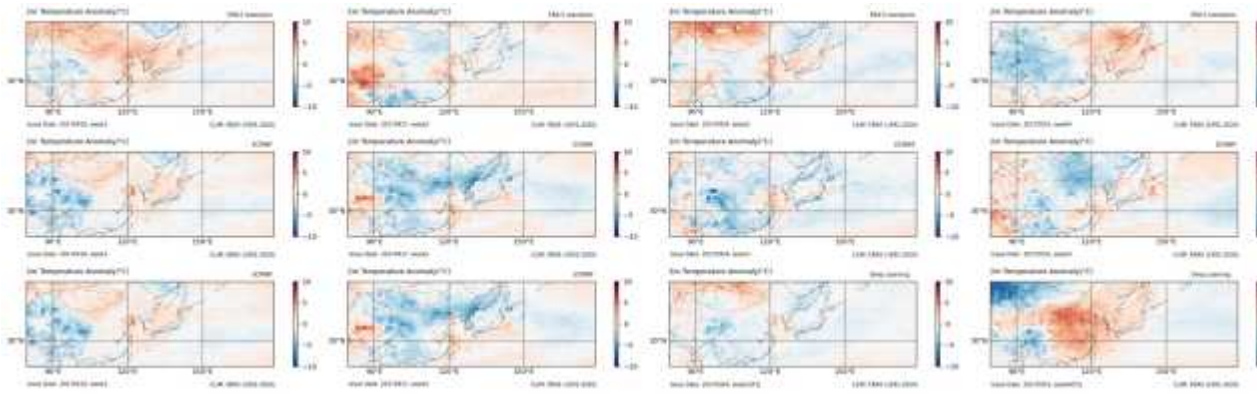


Figure A1. Comparison of ECMWF forecast (CF member) and deep learning-based forecast (first row: ERA-5 reanalysis data, second row: ECMWF forecast, third row: deep learning-based forecast)

Issue Date: 2017.04.10



Issue Date: 2020.03.02

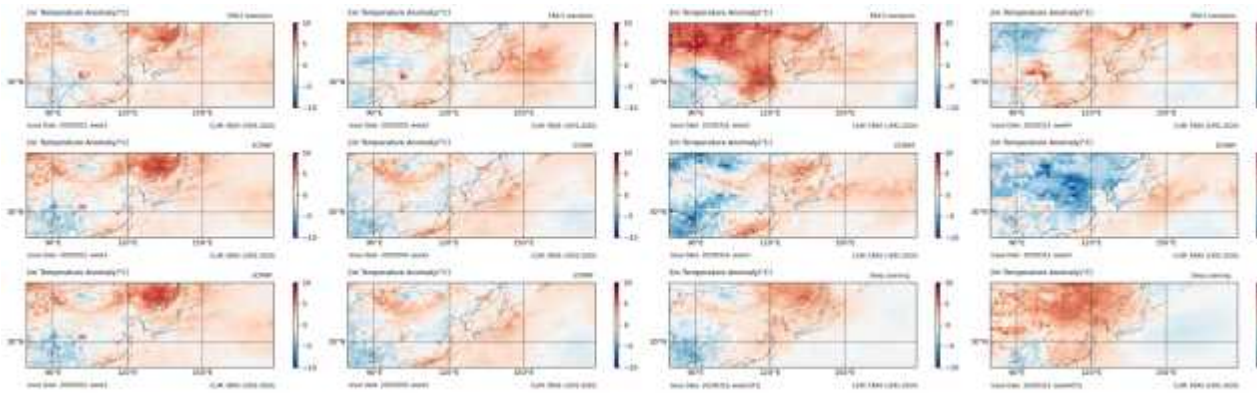


Figure A1. continue

**부록 B. GloSea5/ECMWF 장기에보 자료 수집 및 생산
시스템**

운영 매뉴얼

정유림

기후사업본부 기후분석과

2021.11.

APEC기후센터

목차

목차	i
1. GloSea5/ECMWF 예측자료 수집	1
가. 자료 개요	1
나. 자료 수집 흐름도	1
다. 프로그램 수행 방법	2
(1) 슈퍼컴퓨터 본장비 서버 주프로그램	2
(2) 슈퍼컴퓨터 공동활용분 스토리지 서버 주프로그램	3
2. 1개월 전망 콘텐츠 생산	4
가. 자료 개요	4
나. 디렉터리 구조	4
다. 자료 생산 흐름도	5
라. 프로그램 수행 방법	5
(1) 1개월 전망 콘텐츠 자료 생산 주프로그램	5
3. 3개월 전망 콘텐츠 생산	8
가. 자료 개요	8
나. 디렉터리 구조	8
다. 자료 생산 흐름도	9
라. 프로그램 수행 방법	9
(1) 3개월 전망 콘텐츠 자료 생산 주프로그램	10
Reference	12

1. GloSea5/ECMWF 예측자료 수집

가. 자료 개요

국립기상과학원에서 생산한 자료를 기상청 기후예측과에서 운영하는 확률장기예보 가이드시스템을 통해 전처리한 자료를 수집한다. GloSea5 예측자료의 경우 해상도는 N216L85, 격자 크기는 $0.83^{\circ} \times 0.56^{\circ}$ (423x325)으로 중위도에서 수평해상도는 약 50 km이다(Ham et al., 2017). 1개월 전망을 위해 사용되는 주별 앙상블 예측장(Forecast)의 경우 28개(4멤버×7일)의 앙상블 멤버가, 기후장(Hindcast)의 경우 156~234개(26년×3멤버×2~3초기날짜)의 앙상블 멤버가 사용된다. 기후장 기간은 1991년부터 2016년이다. 3개월 전망을 위해 사용되는 월별 앙상블 예측장의 경우 42개(2멤버×21일)의 앙상블 멤버가, 기후장의 경우 468~546개(26년×3멤버×6~7초기날짜)의 앙상블 멤버가 사용된다. ECMWF 모델 예측의 경우 1개월 전망에 활용되며 수평해상도는 $0.5^{\circ} \times 0.5^{\circ}$ (361×171)이다. ECMWF 예측장은 51개 앙상블 멤버가, 기후장은 660개 앙상블 멤버가 사용된다. 현재 APCC MME 계산에 사용되는 GloSea5 및 ECMWF 예측자료에 비해 고해상도이다. 1개월 전망의 경우 월요일부터 6주(예보 1주부터 4주까지 활용) 예측자료 사용하고 3개월 전망의 경우 익월부터 3개월 또는 6개월의 예측자료를 사용한다. 매주 화요일 오전에 수집되는 파일의 총용량은 대략 100MB~1GB이다.

나. 자료 수집 흐름도



다. 프로그램 수행 방법

APCC-기상청 슈퍼컴퓨터 전용 활용망을 이용하여 개별모델 예측자료를 수집하는 과정은 다음과 같다. 1) 슈퍼컴퓨터 본장비 로그인 노드(ngate)에 접속 후 해당 자료를 2) 슈퍼컴퓨터 FTP 서버(InterDM)로 ftp 전송, 3) 슈퍼컴퓨터 공동활용분 스토리지 서버(Woori)로 ftp 전송, 4) 자료 전송 노드(ScienceDMZ DTN) 서버로 접속, 5) APCC 대용량 스토리지 서버(ecoftp)로 ftp 전송을 수행하여 자료를 얻는다. 기상청 슈퍼컴퓨터에 접속하기 위해 가장 먼저 윈도우창 우측 하단에 있는 'G' 모양의 버튼을 클릭하여 NAC 서버로 로그인하는 과정이 필요하다. 접속 장애 및 서버 불안정에 따른 잦은 끊김 문제로 총 두 번의 과정으로 나누어 수집한다. 먼저, 슈퍼컴퓨터 본장비 서버에서 메인 셸 프로그램(run.ngate.csh)에서 예측 일자를 입력 후 수행하면 슈퍼컴퓨터 공동활용분 스토리지 서버까지 자료가 전송된다. 다음으로 슈퍼컴퓨터 공동활용분 스토리지 서버에 접속 후 메인 셸 프로그램(run.woori.csh)에서 예측 일자를 입력 후 수행하면 ScienceDMZ를 거쳐 APCC HPC까지 자료 전송이 완료된다. 1개월(3개월) 전망 자료의 경우 매주(매월) 월요일(셋째주 월요일) 초기장 예측값을 텍스트, 이미지, grib, nc 포맷의 파일로 매주(매월) 화요일(셋째주 화요일) 오전에 수집한다. 해당 서버 IP 주소는 아래와 같다.

1. 슈퍼컴퓨터 본장비 로그인 노드(ngate)
ngate5: 172.29.110.63
ngate6: 172.29.111.63
ngate7: 172.29.110.64
ngate8: 172.29.111.64
2. 슈퍼컴퓨터 FTP 서버(InterDM)
210.125.45.112
3. 슈퍼컴퓨터 공동활용분 스토리지 서버(Woori)
gate1: 210.125.45.110
gate2: 210.125.45.111
4. 자료 전송 노드(ScienceDMZ DTN)
dtn: 10.141.0.2
5. APCC 대용량 스토리지 서버(ecoftp)
210.117.192.2

주의사항

1~4번 서버 이용 시 보안 유지를 위해 30일 또는 60일 주기로 비밀번호 변경이 필요하다.

(1) 슈퍼컴퓨터 본장비 서버 내 주프로그램 실행

```
> cd /s4/home/apcc/sjyoon/  
> vi run.ngate.csh (예측 날짜 수정)  
> csh run.ngate.csh
```

```

#!/bin/csh

set today = `date +%Y%m%d`
echo "Today : "${today}
set fdate = `date -d "${today} -1 day" +%Y%m%d`
echo "Forecast start date : " ${fdate}
#set sdate = ${fdate}

foreach sdate ( 20210913 )
echo "Forecast start date : " ${sdate}
set dir = "/s4/home/apcc/sjyoon/"
# ===== [ Make directories at InterDM server ] =====
echo ${sdate} > mkdir.ngate.log
csh ${dir}01.mkdir.ngate.csh ${sdate} > mkdir.ngate.log
# ===== [ Transfer files from ngate to InterDM server ] =====
echo ${sdate} > transfer.ngate.log
csh ${dir}02.transfer.ngate.csh ${sdate} > transfer.ngate.log
# ===== [ Check the total number of files at InterDM server ] =====
echo ${sdate} > check.ngate.log
csh ${dir}03.check.transfer.ngate.csh ${sdate} > check.ngate.log
end

exit 0

```

(2) 슈퍼컴퓨터 공동활용분 스토리지 서버 내 주프로그램 실행

```

> cd /home/apcc/apcc06/URIM/
> vi run.woori.csh (예측 날짜 수정)
> csh run.woori.csh

```

```

#!/bin/csh

set today = `date +%Y%m%d`
echo "Today : "${today}
set fdate = `date -d "${today} -1 day" +%Y%m%d`
echo "Forecast date : " ${fdate}
foreach sdate ( 20210913 )
    echo "Forecast start date : " ${sdate}
    set dir = "/home/apcc/apcc06/URIM/"
# [ Check the total number of files at WOORI server & Transfer files to APCC server ]
    echo ${sdate} > check.transfer.woori.log
    csh ${dir}check.transfer.woori.csh ${sdate} > check.transfer.woori.log
end

exit 0

```

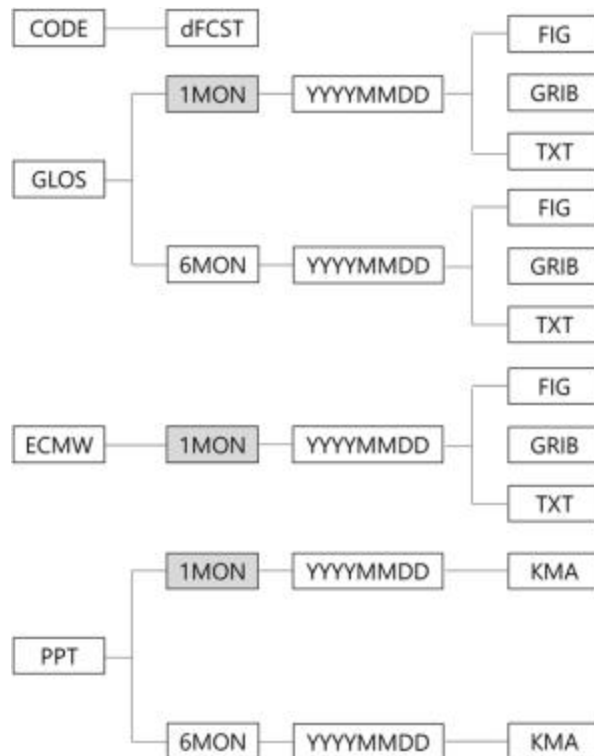
2. 1개월 전망 콘텐츠 생산

가. 자료 개요

현재 1개월 전망에 활용되는 콘텐츠는 다음과 같다. GloSea5 및 ECMWF 모델 예측 500hPa 지위고도 편차 공간장, 지난 주 우리나라 기온/강수 예측에 대한 GloSea5/ECMWF 모델의 단정예보/확률예보 사후분석표, GloSea5 모델 예측 500hPa 지위고도 편차 hovmoller diagram(time-latitude plot), 예보 1주부터 4주에 대한 GloSea5/ECMWF 모델의 우리나라 기온/강수 확률 예측값, 동아시아 지역 기온 확률 예측 공간장, 우리나라 기온 예측에 대한 probability distribution frequency(pdf) 및 강수에 대한 cumulative distribution function(cdf) 분포도이다. 확률 예측 시, 기존의 결과와 동일하게 생산하기 위해서는 기후장 앙상블 멤버수에 있어서 156~234멤버(26년×3멤버×2~3초기날짜)가 필요한데 현재 활용 가능한 자료는 78멤버(26년×3멤버)로 입력자료 및 계산 방법에서 차이가 남에 따라 기존 결과값과 자체 산출한 결과값이 다르게 나타나는 문제가 발생한다. 이를 해결하기 위해 기상청 확률장기예보 가이드스 시스템에서 기생산된 확률값으로 재구성하거나 최종 이미지 파일을 그대로 사용한다.

나. 디렉터리 구조

- 작업 경로: /lfs/data26/KMA
- 1개월 전망 콘텐츠 생산 코드 경로: /lfs/data26/KMA/CODE
- 입력자료 경로: /lfs/data26/KMA/GLOS(ECMW)/1MON/
- 출력자료 경로: /lfs/data26/KMA/PPT/1MON/



다. 자료 생산 흐름도



라. 프로그램 수행 방법

작업 디렉터리(/lfs/data26/KMA/CODE)에 있는 1개월 전망 자료 생산 주프로그램 (GLOS.ECMW.1MON.RUN.csh)에서 매주 월요일 예측 날짜를 입력 후 수행하면 출력자료 저장 디렉터리(/lfs/data26/KMA/PPT/1MON/YYYYMMDD/KMA)에 최종 이미지 파일이 저장된다.

(1) 1개월 전망 콘텐츠 자료 생산 주프로그램

```
> cd /lfs/data26/KMA/CODE
> vi GLOS.ECMW.1MON.RUN.csh (예측 날짜 수정)
> csh GLOS.ECMW.1MON.RUN.csh
```

```
#!/bin/csh
#*****
# Make 1-month outlook PPT image files
# - model : GloSea5/ECMWF (from KMA)
```

```

#      - variable : t15m(t2m), prcp
#
#                                     Y.-R.,Jung / 2021
#*****

setenv NCARG_ROOT "/app/sw/ncarg/6.1.2/intel-bin"
setenv PATH "${NCARG_ROOT}/bin:${PATH}"

set idate = "20211108"
set ghdir = "/ifs/data26/KMA/GLOS/1MON/"
set ehdir = "/ifs/data26/KMA/ECMW/1MON/"
set ptdir = "/ifs/data26/KMA/PPT/1MON/"
set codir = "/ifs/data26/KMA/CODE/"
set outdir = "${ptdir}${idate}/KMA/"
set odate = `date -d "${idate} +7 days" +%Y%m%d`
set ncldir = "${NCARG_ROOT}/bin"

mkdir -p ${outdir}
mkdir -p ${ptdir}${odate}/KMA

${ncldir}/ncl -nQ ${codir}01-1.glos.veri.table.korea.ncl start_date=${idate}
${ncldir}/ncl -nQ ${codir}01-2.ecmwf.veri.table.korea.ncl start_date=${idate}
${ncldir}/ncl -nQ ${codir}02-1.glos.fcst.F1-4.3-6wago.table.korea.ncl start_date=${idate}
# ${ncldir}/ncl -nQ ${codir}02-2.ecmwf.fcst.F1.3-6wago.table.korea.ncl start_date=${idate}
${ncldir}/ncl -nQ ${codir}03-1.glos.fcst.F1-4.table.korea.ncl start_date=${idate}
${ncldir}/ncl -nQ ${codir}03-2.ecmwf.fcst.F1-4.table.korea.ncl start_date=${idate}

set wnum = 1
foreach dd ( 7 14 21 28 )
  set bdate = `date -d "${idate} - ${dd} days" +%Y%m%d`
  # GloSea5
  set gfname = "cfpr_gskr_1mon_hano_spat_500_as_fcst_w0${wnum}_${bdate}.png"
  echo ${gfname}
  cp ${ghdir}/${bdate}/FIG/${gfname} ${outdir}
  # ECMWF
  set efname = "prod_ecmw_1mon_hano_spat_500_as_fcst_w0${wnum}_${bdate}.png"
  echo ${efname}
  cp ${ehdir}/${bdate}/FIG/${efname} ${outdir}
  @ wnum += 1
end

foreach dd ( 0 7 14 21 )
  set bdate = `date -d "${idate} - ${dd} days" +%Y%m%d`
  # GloSea5
  set gfname0 = "prod_gskr_1mon_hano_ts_500_korea_fcst_w01_${bdate}.png"

```

```

cp ${ghdir}/${bdate}/FIG/${gfname0} ${outdir}
if ( ${dd} == "0" )then
  foreach wnum ( 3 4 5 6 )
    # GloSea5
    set gfname1 = "prod_gskr_1mon_tano_pspt_2m_ea_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname1} ${outdir}
    set gfname2 = "prod_gskr_1mon_tano_pdf_2m_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname2} ${outdir}
    set gfname3 = "prod_gskr_1mon_rain_cdf_sfc_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname3} ${outdir}
    # ECMWF
    set efname1 = "prod_ecmw_1mon_tano_pspt_2m_ea_fcst_w0${wnum}_${bdate}.png"
    cp ${ehdir}/${bdate}/FIG/${efname1} ${outdir}
    set efname2 = "prod_ecmw_1mon_tano_pdf_2m_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ehdir}/${bdate}/FIG/${efname2} ${outdir}
    set efname3 = "prod_ecmw_1mon_rain_cdf_sfc_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ehdir}/${bdate}/FIG/${efname3} ${outdir}
  end
else if ( ${dd} == "7" )then
  foreach wnum ( 4 5 6 7 )
    # GloSea5
    set gfname4 = "prod_gskr_1mon_tano_pspt_2m_ea_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname4} ${outdir}
    set gfname5 = "prod_gskr_1mon_tano_pdf_2m_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname5} ${outdir}
  end
else if ( ${dd} == "14" )then
  foreach wnum ( 5 6 7 )
    # GloSea5
    set gfname6 = "prod_gskr_1mon_tano_pspt_2m_ea_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname6} ${outdir}
    set gfname7 = "prod_gskr_1mon_tano_pdf_2m_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname7} ${outdir}
  end
else if ( ${dd} == "21" )then
  foreach wnum ( 6 7 )
    # GloSea5
    set gfname8 = "prod_gskr_1mon_tano_pspt_2m_ea_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname8} ${outdir}
    set gfname9 = "prod_gskr_1mon_tano_pdf_2m_kma_fcst_w0${wnum}_${bdate}.png"
    cp ${ghdir}/${bdate}/FIG/${gfname9} ${outdir}
  end
endif
end

```

```

# Check files
set ifnum = `find ${ptdir}/${idate} | wc -l`
set ofnum = `find ${ptdir}/${odate} | wc -l`
if ( ${ifnum} == "61" && ${ofnum} == "5" ) then
    echo "    ### Success : 1month GloSea5/ECMWF PPT Image Files Creation &
Transfer Complete! ### "
    echo "    ###          Total number of files ( ${ifnum} / 61 )  "
    echo "    ###          Total number of files ( ${ofnum} / 5 )    "
else
    echo "    ### Error      : 1month GloSea5/ECMWF PPT Image Files Creation &
Transfer Failed!  ### "
    echo "    ###          Total number of files ( ${ifnum} / 61 )  "
    echo "    ###          Total number of files ( ${ofnum} / 5 )    "
endif

```

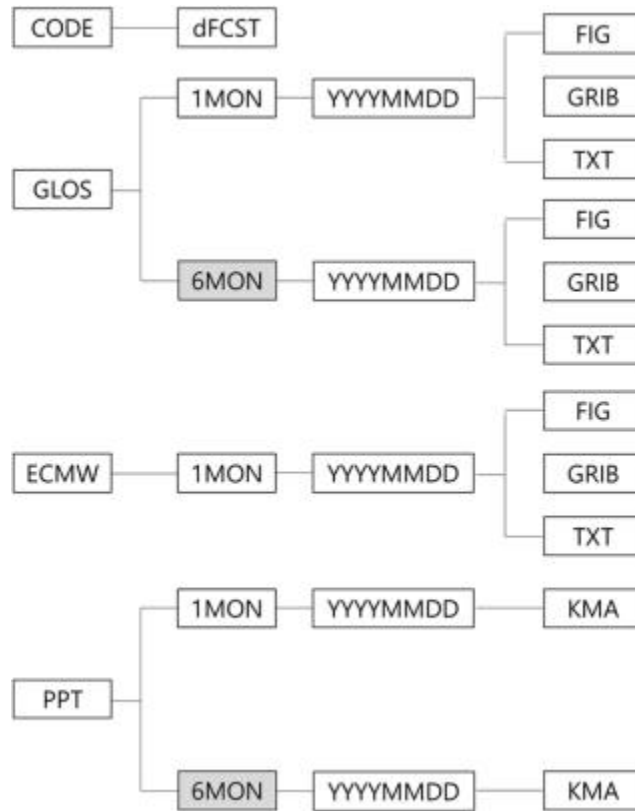
2. 3개월 전망 콘텐츠 생산

가. 자료 개요

현재 3개월 전망에 활용되는 콘텐츠는 GloSea5 모델 예측의 결과이며 내용은 다음과 같다. 3개월 예측 전지구 해수면온도 편차 및 Nino3.4 구역 평균값, 북반구 500hPa 지위고도 편차, 6개월 예측 Nino3.4 구역 해수면온도 편차 box plot(최대값, 67%, 중앙값, 33%, 평균값 분포도), 3개월 예측 동아시아 기온 및 강수 편차, 3개월 예측 우리나라 기온 및 강수 단정예보/확률예보 값, 3개월 우리나라 기온 예측에 대한 probability distribution frequency(pdf) 및 강수에 대한 cumulative distribution function(cdf) 분포도이다. 확률 예측의 경우, 1개월 전망과 동일한 문제로 확률장기예보 가이드선시스템에서 기생산된 확률값으로 재구성하거나 최종 이미지 파일을 그대로 사용한다.

나. 디렉터리 구조

- 작업 경로: /lfs/data26/KMA
- 3개월 전망 콘텐츠 생산 코드 경로: /lfs/data26/KMA/CODE
- GloSea5 예측 입력자료 경로: /lfs/data26/KMA/GLOS/6MON/
- ECMWF 예측 입력자료 경로: /lfs/data26/KMA/ECMW/6MON/
- 출력자료 경로: /lfs/data26/KMA/PPT/6MON/



다. 자료 생산 흐름도



라. 프로그램 수행 방법

작업 디렉터리(/ifs/data26/KMA/CODE)에 있는 3개월 전망 자료 생산 주프로그램(GLOS.3MON.RUN.csh)에서 예측 날짜 수정 후 수행하면 출력자료 저장 디렉터리(/ifs/data26/KMA/PPT/6MON/YYYYMMDD/KMA)에 최종 이미지 파일이 저장된다.

(1) 3개월 전망 콘텐츠 자료 생산 주프로그램

```
> cd /lfs/data26/KMA/CODE
> vi GLOS.3MON.RUN.csh (예측 날짜 수정)
> csh GLOS.3MON.RUN.csh
```

```
#!/bin/csh
#*****
# Make 3-month outlook PPT image files
#   - model   : GloSea5 (from KMA)
#   - variable : sst, t15m(t2m), prcp
#
#                                     Y.-R.,Jung / 2021
#*****
setenv NCARG_ROOT "/app/sw/ncarg/6.1.2/intel-bin"
setenv PATH "${NCARG_ROOT}/bin:${PATH}"

set idate = "20211108"
set ghdir = "/lfs/data26/KMA/GLOS/6MON/"
set ehdir = "/lfs/data26/KMA/ECMW/6MON/"
set ptdir = "/lfs/data26/KMA/PPT/6MON/"
set codir = "/lfs/data26/KMA/CODE/"
set outdir = "${ptdir}${idate}/KMA/"
set ncldir = "${NCARG_ROOT}/bin"

mkdir -p ${outdir}

ksh ${codir}dFCST/run.ksh ${idate}

${ncldir}/ncl -nQ ${codir}11.glos.dfcst.temp.prcp.3mon.table.korea.ncl start_date=${idate}
${ncldir}/ncl -nQ ${codir}12.glos.pfcst.temp.prcp.3mon.table.korea.ncl start_date=${idate}
${ncldir}/ncl -nQ ${codir}13.glos.sst.3mon.gl.plot.ncl start_date=${idate}

ksh ${codir}dFCST/run.ksh ${idate}

foreach mnum ( 01 02 03 )
  set gfname = "prod_gskr_6mon_hano_spat_500_nps_fcst_m${mnum}_${idate}.png"
  echo ${gfname}
  cp ${ghdir}${idate}/FIG/${gfname} ${outdir}
  set gfname = "prod_gskr_6mon_tano_spat_2m_ea_fcst_m${mnum}_${idate}.png"
  echo ${gfname}
  cp ${ghdir}${idate}/FIG/${gfname} ${outdir}
  set gfname = "prod_gskr_6mon_tano_pdf_2m_kma_fcst_m${mnum}_${idate}.png"
  echo ${gfname}
  cp ${ghdir}${idate}/FIG/${gfname} ${outdir}
```

```

set gfname = "prod_gskr_6mon_rain_perc_sfc_ea_fcst_m${mnum}_${idate}.png"
echo ${gfname}
cp ${ghdir}/${idate}/FIG/${gfname} ${outdir}
set gfname = "prod_gskr_6mon_rain_cdf_sfc_kma_fcst_m${mnum}_${idate}.png"
echo ${gfname}
cp ${ghdir}/${idate}/FIG/${gfname} ${outdir}
end

set gfname = "prod_gskr_6mon_oidx_nino34_fcst_m01_${idate}.png"
echo ${gfname}
cp ${ghdir}/${idate}/FIG/${gfname} ${outdir}

# Check files
set ifnum = `find ${ptdir}/${idate} | wc -l`
if ( ${ifnum} == "32" ) then
    echo "    ### Success : 3month GloSea5 PPT Image Files Creation & Transfer
Complete! ### "
    echo "    ###          Total number of files ( ${ifnum} / 32 )    "
else
else
    echo "    ### Error      : 3month GloSea5 PPT Image Files Creation & Transfer
Failed! ### "
    echo "    ###          Total number of files ( ${ifnum} / 32 )    "
endif

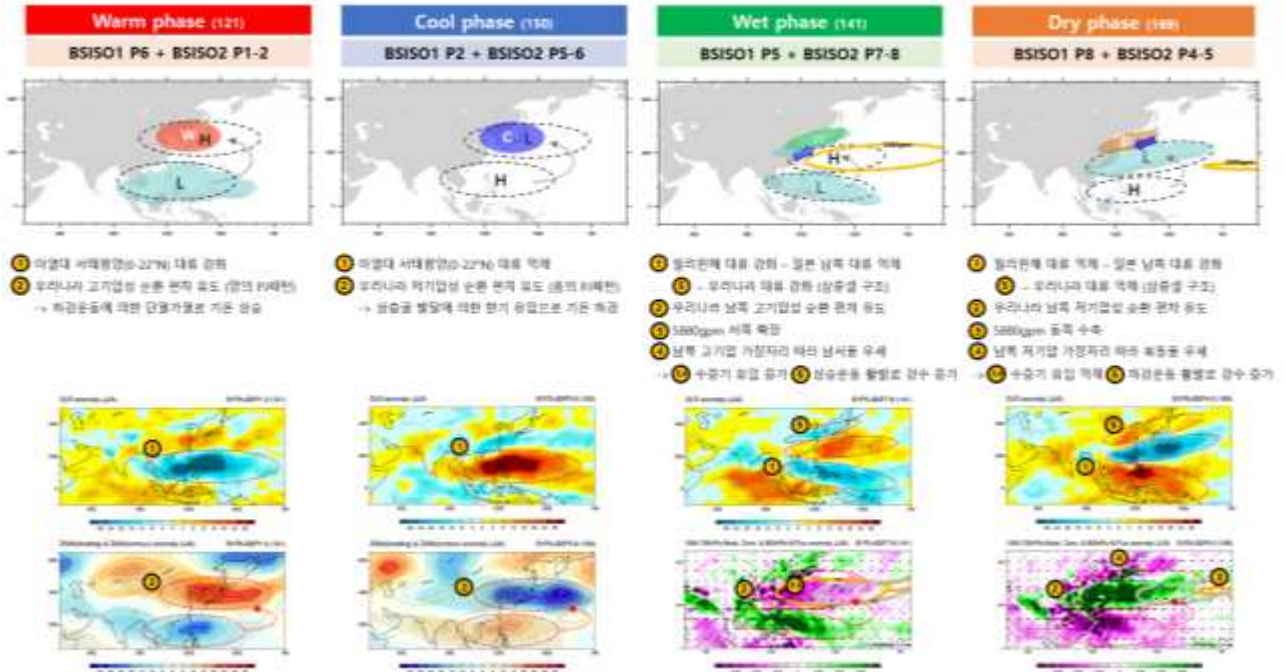
```

Reference

Ham et al., 2017: Performance Assessment of Weekly Ensemble Prediction Data at Seasonal Forecast System with High Resolution, Atmosphere. *Korean Meteorological Society* **Vol. 27**, No. 3 (2017) pp. 261–276.

부록 C. 1개월 전망 활용을 위한 관측 기반 우리나라 여름철 기온 및 강수 변동에 대한 BSISO 영향 위상 분석 Fact Sheet

BSISO 위상에 따른 여름철 우리나라 기온 및 강수 변동 Fact Sheet



부록 D. WMO 장기예보 선도센터 계절예측에 사용된 검증 기법

1. 결정론적 예측의 검증

가. Anomaly Corelation Coefficient (ACC)

아노말리 상관계수 분석은 예측 변수별 3개월 예측을 월별 및 3개월 평균에 대해 각각 계산하여 표출된다. ACC 분석은 예측과 관측의 패턴 상관분석으로서 계산방법은 아래 식 D1과 같다.

$$ACC = \frac{\sum_{i=1}^N w_i (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^N w_i (F_i - \bar{F})^2 \sum_{i=1}^N w_i (O_i - \bar{O})^2}} \quad (D1)$$

여기서 F는 예측값, O는 관측값을 의미하며 \bar{F} 와 \bar{O} 는 각각 예측값과 관측 값에 대한 시간평균을 나타낸다. ACC는 예측장과 관측장 사이의 패턴이 얼마나 유사한지 측정하는 척도로 -1~+1 사이의 값을 갖으며, 만약 ACC가 +1이라면 예측 결과가 정확함을 의미한다.

나. Root Mean Square Error (RMSE)

평균제곱근오차(RMSE)는 예측장과 관측장 사이의 오차를 나타내는 척도로, 아래 식 D2와 같이 예측값이 관측 값으로부터 갖는 오차를 곱하여 평균한 평균제곱오차를 제곱근으로 표현하며 예보의 정확성을 살펴보는 척도로 사용된다.

$$RMSE = \sqrt{\frac{1}{W} \sum_{i=1}^N w_i (F_i - O_i)^2} \quad (D2)$$

이 식에서 F는 예측값, O는 관측 값, w_i 는 위도별 가중치, W는 w 의 합을 나타내며 i 는 각 격자점을 의미한다. 만약 예측 결과가 정확할 경우 RMSE는 0이다.

다. Mean Square Skill Score (MSSS)

Mean Square Skill Score는 예측장과 관측장 사이의 변동성 오차, 예측장 자체의 오차, 예측장과 관측장 사이의 계통적 오차를 나타내는 척도이다. 예측값이 실제 관측 값으로부터 갖는 오차 특성을 종합적으로 파악할 수 있는 지표로 MSSS의 각 격자 값으로 정확도의 분포를 파악하거나 영역 평균의 시계열을 통해 정확도의 추이를 이해할 수 있고 -∞부터 +1까지의 값을 가질 수 있다. MSSS의 값이 1에 가까울수록 예측성이 뛰어난 것을 의미한다.

MSSS_j의 계산은 다음과 같은 절차를 통해 구해진다. x_{ij} 와 f_{ij} 는 격자 j의 관측 값과 결정론적 예측값에 대한 i번째의 시계열을 뜻한다. 격자점 j에 대한 over bar는 각 격자점에 대해서 총 예보기간(n개의 시계열)에 대한 시간평균을 의미한다. x_{ij} 와 f_{ij} 의 분산은 각각 아래 식 D3, 4와 같이 계산되고

$$S_{x_j}^2 = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_i)^2 \quad (D3)$$

$$S_{f_j}^2 = \frac{1}{n} \sum_{i=1}^n (f_{ij} - \bar{f}_i)^2 \quad (D4)$$

격자점 j에 대한 MSE_j와 MSE_{cj}는 각 각 아래와 같이 계산된다.

$$MSE_j = \frac{1}{n} \sum_{i=1}^n (f_{ij} - x_{ij})^2, \quad MSE_{c_j} = \left(\frac{n}{n-1} \right)^2 S_{x_j}^2 \quad (D5)$$

MSE_j는 각 격자에 대한 시계열 예보 자료와 관측 값의 차이를 제공하여 평균한 것이며 MSE_{cj}는 기후값을 예측값으로 사용할 경우 기후값 예측에 대한 mean square error를 의미한다. MSSS_j는 MSE_j와 MSE_{cj}를 이용하여 아래와 같은 식으로 계산된다.

$$MSSS_j = 1 - \frac{MSE_j}{MSE_{c_j}} \quad (D6)$$

MSSS_j는 각 격자에 대한 검증 값을 의미하므로 그 분포를 통해 모형의 지역별 예측 정확도 특성을 파악 할 수 있다.

또한 MSSS는 위상오차(Anomaly Correlation), 진폭 오차(Amplitude Error) 및 바이어스 오차(Bias Error)를 포함하는 개념이며 이는 각 각 아래의 식의 첫 3개항에 해당된다.

$$MSSS = \frac{\left\{ 2 \frac{S_{f_j}}{S_{x_j}} r_{fxj} - \left(\frac{S_{f_j}}{S_{x_j}} \right)^2 - \left(\frac{[\bar{f}_j - \bar{x}_j]}{S_{x_j}} \right)^2 + \frac{2n-1}{(n-1)^2} \right\}}{\left\{ 1 + \frac{2n-1}{(n-1)^2} \right\}} \quad (D7)$$

$$r_{fxj} = \frac{\frac{1}{n} \sum_{i=1}^n (f_{ij} - \bar{f}_i)(x_{ij} - \bar{x}_i)}{S_{f_j} S_{x_j}} \quad (D8)$$

위상오차는 분포 패턴의 상관도를 나타내며 진폭오차는 관측분산에 대한 예측분산의 비율로 표시하며 바이어스 오차는 예측값과 관측 값의 시간 평균의 차이를 나타낸다.

라. Gerrity Skill Score (GSS)

Gerrity Skill Score는 3분위 예보와 같은 카테고리 예보에서의 예측성 정도를 나타낸다. 3분위 예보의 판정분할표 (contingency table)는 Table D1과 같고 여기에 나타난 각 분위별 예보와 관측의 일치 사례수를 고려하여 GSS를 계산한다.

Table D1. 3x3 contingency table.

		Forecast			
		Below	Near	Above	Total
Observation	Below	n11	n21	n31	n•1
	Near	n12	n22	n32	n•2
	Above	n13	n23	n33	n•3
	Total	n1•	n2•	n3•	N

우선 각 카테고리에 대한 예보와 관측을 f_i 와 x_i 라 두고 n_{ij} 는 예보 I와 관측 j 카테고리에 해당되는 수를 의미한다. 각 카테고리별 빈도수의 확률을

$$P_{ij} = \frac{n_{ij}}{N} \quad (D9)$$

로 나타낼 수 있으며 예보와 관측의 각 카테고리에 대한 확률 분포는 각각

$$p(f_i) = \sum_{j=1}^3 p_{ij} = \hat{p}_i ; i = 1, \dots, 3 \quad (D10)$$

$$p(x_i) = \sum_{j=1}^3 p_{ji} = \hat{p}_i ; i = 1, \dots, 3 \quad (D11)$$

이다. 여기서 GSS의 계산은 다음과 같다.

$$GSS = \sum_{i=1}^3 \sum_{j=1}^3 P_{ij} S_{ij} \quad (D12)$$

$$S_{ii} = \frac{1}{2} \left(\sum_{r=1}^{i-1} a_r^{-1} + \sum_{r=1}^2 a_r \right)$$

$$S_{ij} = \frac{1}{2} \left[\sum_{r=1}^{i-1} a_r^{-1} - (j-1) + \sum_{r=j}^2 a_r \right] \quad (1 \leq i < 3, i < j \leq 3)$$

$$a_i = \left(1 - \sum_{r=1}^i p_r \right) / \left(\sum_{r=1}^i p_r \right)$$

2. 확률론적 예측의 검증

가. ROC Curve 및 Score

ROC는 Hit rate (HR)와 False alarm rate (FAR) 사이의 분포를 각 확률구간별로 계산하여 한 그래프에 곡선으로 나타낸 것으로 예보 오차에 민감하지 않기 때문에 신뢰도와는 무관하다.

Table D2. 2x2 contingency table.

$HR = H/(H+M)$ $FAR = F/(F+R)$		Observed	
		Yes	No
Forecast	Yes	Hit (H)	False (F)
	No	Missing (M)	correct Rejection (R)

표 D2는 적중률(Hit Rate)과 비적중률(False alarm rate)에 대한 분할 표 (Contingency table)이다. ROC는 0~1의 값을 가지고, 완벽한 예보 일 때 HR=1, FAR=0, M(missing)=0, F(false)=0 값을 가진다. ROC 곡선은 HR과 FAR 사이의 분포도로 각 확률 구간별로 두 값을 계산하여 한 그래프에 곡선으로 나타낸다. HR=1이고 FAR=0일 때가 완벽한 예보이므로 ROC 곡선이 좌측 상단으로 가까이 위치할수록 예보의 수행 능력이 좋다고 할 수 있다. 대각선은 skill 유무의 경계선으로 대각선 아래쪽으로 ROC 곡선이 위치하면 FAR가 HR보다 커지므로 예보 수행 능력이 떨어짐을 의미하고 곡선이 대각선상에 위치하면 각 예보 확률별로 HR와 FAR가 동일하므로 예보 능력이 없다고 판단한다. ROC는 곡선 아래의 면적을 구하여 예측성의 정도로 사용하며 이를 ROC score라고 하고, 완벽한 예보일 경우 ROC score는 1이고, 예보의 기술이 없을 경우의 ROC score는 0.5이다.

나. Reliability Diagram

Reliability Diagram은 예보의 신뢰도를 측정하는 척도로 각각의 카테고리 분류된 예보확률과 실제로 이벤트가 발생한 빈도를 측정하여 신뢰성을 측정한다. 다시 말해 주어진 예보 확률이 실제로 얼마나 자주 일어나는 가를 알아보는 것이다. 확률 예보를 하기 위해서는 예보 시스템의 신뢰도가 보장되어야한다. 하지만 신뢰도가 좋다고 해서 반드시 예보의 정확도가 좋아지는 것은 아니다. 완벽한 예보일 때 신뢰도는 0의 값을 갖는다. 신뢰도 그림(Reliability Diagram)의 가로축은 예보 확률 카테고리(0.0~1.0)이며, 세로축은 각 카테고리별 실제 관측된 이벤트의 확률이다. 막대그래프는 예보 확률 카테고리 내에서 집계된 전체 예보 확률 수에 대한 각각의 예보 확률 카테고리에서 집계된 확률 수의 비이다. 대각선에 가까울수록 완벽한 예측성에 가깝고, 대각선보다 위쪽에 나타나는 경우에는 과대예측 한 것이고 대각선보다 아래쪽에 나타나는 경우에는 과소예측 한 것이다.

다. Brier Score(BS)와 Brier Skill Score(BSS)

Brier score는 확률 예보의 정확도의 척도로 가장 널리 사용되는 지수이다. BS는 아래의 식과 같이 확률 오차를 제공하여 평균한 수치로 1) 신뢰도(Reliability), 2) 판별력(Resolution), 3) 불확실성(uncertainty)의 3가지 향으로 이루어진다. BS의 범위는 0에서 1이다. 만약 예보가 완벽하다면 0의 값을 가지며, 예보의 정확성이 낮을수록 큰 값을 갖는다. 신뢰도는 값이 작을수록 좋고 판별력은 값이 클수록 좋다. 불확실성은 항상 양의 값을 가지며 이 향의 영향을 완전히 제거한다는 것은 거의 불가능하다.

$$Brier\ Score(BS) = \frac{1}{n} \sum_{k=i}^I N_i (y_i - \bar{o}_i)^2 - \frac{1}{n} \sum_{k=i}^I N_i (\bar{o}_i - \bar{o})^2 + \bar{o}(1 - \bar{o}) \quad (D13)$$

위 식에서 i 는 확률예측카테고리(0.0~1.0=0~100%), n 은 전체 이벤트 수, N_i 는 각 예측 확률 카테고리별 예보 수, y_i 는 각 예측 확률 카테고리, \bar{o}_i 는 각 예측 확률 카테고리별 실제 관측된 이벤트의 빈도, \bar{o} 는 전체 확률 카테고리에서 관측된 이벤트의 빈도를 나타낸다.

Brier Skill Score는 아래와 같이 구할 수 있으며

$$Brier\ Skill\ Score(BSS) = 1 - \frac{BS}{BS_{ref}} \quad (D14)$$

여기서 BS_{ref} 는 예측변수의 기후학적 확률을 의미하고 이는 Resolution과 Reliability의 차이에 대한 Uncertainty의 비로 다시 나타낼 수 있다. 예보한 이벤트가 실제로 일어날 것인가에 대해서 예측의 기후학적 확률의 상대적인 능력을 알 수 있다. BSS 값은 $-\infty$ 에서 1까지의 범위를 가질 수 있으며 0이면 예보 능력이 없음을 의미한다.