

장기예보 개선을 위한 예측정보 통합 기반 마련

**Improved long-range forecasts through enhanced
forecast skills and integrated information**

김가은, 김옥연, 윤순조, 이성규, 임슬희, 정유림

기후사업본부 기후분석과

2022.12.

APEC기후센터

평문 초록

APCC는 지난 수년에 걸쳐 기상청과의 협력시스템을 구축하고 지원체계를 정립함으로써 현업 장기예보 정확도 향상을 위해 노력해 왔습니다. 장기예보를 위해서는 예보를 생산하기 위한 자료생산단계와 예보정보생산단계로 크게 나눌 수 있는데, 지난 수년간 APCC 장기예보 전담팀은 위 두 단계를 연결하는 다리 역할을 해왔습니다. 앞으로는 기존 APCC-기상청의 협력 체계를 바탕으로 하되, 장기예보에 있어 APCC만의 역할 영역을 더욱 확대할 필요가 있는바, 이를 위해서는 현업 장기예보 실무 예측기술을 개선하고, 이미 개발된 기술 또는 개선된 기후 정보(예측성이 좋은 정보)를 선별, 가공하여 객관화된 예측정보를 생산할 수 있는 기반을 마련하고자 합니다.

첫째, 우리나라 주변 주요 기후변동성에 대한 모델 예측 특성을 이해하고자 겨울철 동아시아지역 예측에서 중요한 강제력 중 하나인 ENSO와 그에 대한 반응이 계절안 규모에서 어떤 특성을 갖고 모의 되는지 살펴보았습니다. 모델에서는 겨울철 동안 ENSO에 대한 반응이 유사하게 이어지며 관측에서 나타나는 월별 변화를 제대로 모의하지 못했는데, 북반구 전체적인 모의 성능에 비해 동아시아 영역에서의 모의 성능은 낮게 나타났습니다.

둘째, 가속화되는 북극 온난화로 인해 장기예보 예측인자들의 적중률이 떨어짐에 따라 기존 예측인자의 활용성을 재고하고, 장기예보에 참여하는 역학 모델에서의 북극 영향에 따른 동아시아 대기 반응에 대한 정보를 제공하기 위해 북극 연직 온난화와 연관된 우리나라 겨울철 월별 기온 변동성을 조사하였습니다.

셋째, 이러한 ENSO로 대표되는 열대 저위도 영향과, 북극의 영향을 모두 고려하여 매달 APCC 모델예측 정보는 10개 이상의 모델과 300개 이상의 앙상블 멤버를 사용한 다중모델앙상블 기법으로 생산됩니다. 하지만 다중모델앙상블 기법은 반드시 우리나라에 적합한 장기예보 기법은 아닐 수 있으므로, 우리나라 장기예보 개선을 위해 더욱 적합한 모델을 선별할 필요가 있습니다. 따라서 우리나라 장기예보에 적합한 모델을 선별하는 방법을 제시하고, 이에 따른 예측성을 평가하였습니다.

넷째, 계절내 시간규모에서 우리나라를 포함한 동아시아 지역의 기후변동성에 영향을 주는 여름철 계절내 진동의 대류활동 및 원격상관 반응에 대한 ECMWF 모델의 실시간 모의 성능을 진단하고, 보다 높은 예측성을 가지는 영향정보를 선별 및 활용함으로써 3주차 예보 정확도 향상에 기여하고자 하였습니다.

다섯째, 동아시아지역 및 남한지역의 1개월 기온에 대한 확률 예측성을 높이기 위해 딥러닝 기술을 이용하여 1개월 기온 예측모델을 개발하고 확률예측 체계를 구축하였습니다. 역학모델과 딥러닝모델의 장단점을 상호보완적으로 활용한다면 보다 예측성이 높은 1개월 확률예측이 가능할 것으로 판단됩니다.

위와 더불어 기상청 1개월 전망 지원을 위해 APCC 1개월 전망 예측시스템을 구축하여 운영하고 있으며, 수시 환경변화와 예보관의 수요를 반영해 시스템을 지속적으로 개선하고 있습니다. 이렇게 개선된 예측정보와 다양한 분석자료를 활용하여 생산된 APCC의 1개월 전망 예측

결과는 여러 모델의 예측결과 대비 우수한 예측성을 보였으며, 기상청의 현업 장기예보 운영에 도움을 주고 있습니다.

Executive Summary

As a base study for the improvement of long-range forecasts skill and integration of forecast information, we analyzed models' performance of ENSO and its related atmospheric responses in intra-seasonal scale for the APCC MME individual models during winter month. Although the performance of the models' Nino index is highly correlated with the observation, models have errors in tropical sea surface temperature and precipitation responses regionally and monthly. The models show similar atmospheric response to ENSO during winter months (DJF) but not show monthly variation such as weakened western Pacific precipitation in January as in observation. The atmospheric responses to ENSO show low skill in the East Asia compared to the Northern hemisphere and the skill is lowest in February regardless of lead time. It is over estimated that the ratio of ENSO related variation to the total variation in model simulation.

We have divided arctic events into four categories on monthly time scale during the winter months and analyzed the frequency of occurrence of cold event in East Asia. Among the four categories of arctic events, we have analyzed the composite patterns of deep arctic warming and shallow arctic warming. It is found that there is high possibility of cold event during January and February when deep arctic warming occurs. Few models can predict the arctic events during the month of January and February, and also reliably reproduce the atmospheric circulation patterns when they predict the occurrence of deep arctic warming event.

For the long range forecast over Korea, the seasonal climate models have capability to simulate the impact from both higher-latitude and lower-latitude. Both Color-Polar (CP) and Warm-Tropical (MT) near Korea are considered as two important indicators that reflecting the impacts from higher and lower latitudes in the forecast. The APCC MME has capability to reasonably simulate the intraseasonal variability of CP and MT, which is also well related to the temperature and precipitation variability in Korea. Therefore, we can select the best model that well simulates the relationship the CP and MT variability with temperature and precipitation in Korea. The best model chosen which reasonably simulates the climatological feature and the relationship with CP and MT with temperature precipitation around Korea, can improve the intraseasonal predictability in Korea. The best model, which is additionally tailored over targeted area (here in Korea), can further improve the intraseasonal predictability.

As to the 1-month long range forecast, the boreal summer intraseasonal oscillation is one of the main prediction sources for the subseasonal forecast over the Asian summer monsoon region. We investigated the predictability of the real-time BSISO index and BSISO impact anomaly in the WMO S2S ECMWF model, currently participating in the 1-month forecast. The ECMWF model exhibited the BSISO prediction skill out to 3-4 weeks, but it has

weaker amplitude and slower propagation than the observation. Convective and associated circulation anomaly patterns estimated by the BSISO index can be predicted up to 3 weeks. In addition, predicted BSISO-related anomalies showed higher pattern correlation coefficients in active, warm phase, heatwave phase or dry phase cases in week 3. We confirmed the possible impact of BSISO on Changma onset/withdrawal and mean rainfall in 2022 and therefore, the BSISO impact forecast could be useful information during the monsoon season in Korea.

We developed 1-month temperature prediction model using deep learning technology and established probabilistic prediction system in order to improve the accuracy of 1-month temperature probabilistic prediction around East Asia and including South Korea. A deep learning-based prediction model was designed using bi-directional convolutional long short term memory (ConvLSTM), a channel-attention mechanism like squeeze and excitation block, etc, and was evaluated. Training dataset was built using daily ERA5 2m temperature (T2M) reanalysis data. the European Centre for Medium-Range Weather Forecasts (ECMWF) forecast data of week-1 and week-2, and a rolling prediction method for T2M prediction of week-3 and week-4 were used. After building training and validation dataset using daily ECMWF T2M reanalysis data from 1986 to 2015, we shuffled and trained the deep learning model. The predictability of the developed model was evaluated using daily ECMWF T2M reanalysis data from 2018 to 2021 in two regions, East Asia and South Korea. As evaluation methods, ROC (receiver operating characteristic) score map around East Asia and HSS (heidke skill score) in South Korea were used. As the results of ROC score map around East Asia, the predictability of the developed model was similar to the predictability of ECMWF model. On the other hand, as the results of HSS in South Korea, the probabilistic prediction of the developed model showed slightly higher predictability than that of the ECMWF model. In addition, ECMWF model and the deep learning model showed high predictability of Above Normal and Near Normal, respectively. Therefore, the deep learning-based 1-month T2M probabilistic prediction system developed in this paper can be helpful to improve the accuracy of the 1-month temperature probabilistic prediction. Also, if the advantages and disadvantages of both models are utilized for 1-month T2M prediction, it can be the possible to advance probabilistic prediction.

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 demand of operator and model characteristics. The forecast produced by APCC showed better skill than the other climate prediction models. These results were fully shared with the KMA and contributed to the improvement of KMA's 1-month forecast.

국문 요약

3개월 장기예보 개선을 위한 기반 마련으로 모델의 겨울철 계절안(월별) ENSO 모의와 그에 대한 대기 반응 모의 특성을 분석하였다. 모델의 ENSO 모의는 Nino 지수의 상관계수로써는 모의 성능을 높게 평가할 수 있으나 ENSO에 대한 반응은 관측과 차이가 있었고 관측에서 나타나는 월별 변화를 제대로 모의하지 못했다. 모델에서 ENSO와 관련된 대기 반응은 북서태평양 지역에서 고기압성 순환 반응을 모의했는데, 관측에서는 1월에 고기압성 반응이 사라지고 2월에는 한반도 북쪽으로 고기압성 반응이 나타났지만, 모델은 겨울철 내내 고기압성 반응이 이어지는 것으로 모의하는 차이가 있었다. 대기 반응의 차이는 열대 강수 반응의 차이와 관련되었으며 관측에서는 서태평양에서 1월에 강수가 약해지는 반응이 나타나지만 모델은 강수의 월별 변화를 모의하지 못했다. 모델의 대기 반응은 북반구 전반적인 모의 성능에 비해 동아시아 지역에서 모의 성능이 떨어지는 것으로 나타났다. 모델의 오차는 2월에 크게 나타났는데 선행시간과는 관계없이 모의 성능이 낮은 특징을 보였다.

3개월 전망에서 겨울철 북극 인자의 영향에 대한 정보를 효과적으로 활용하기 위해 겨울철 월별 재분석자료를 통해 북극 이벤트를 4가지로 분류하고 이벤트별로 동아시아의 저온 발생빈도를 분석하였다. 그와 함께 북극 연직 온난화의 주요 두 가지 이벤트인 깊은 연직 온난화와 얕은 연직 온난화에 대하여 합성장 분석을 통해 각 이벤트에 대한 월별 대기순환장 특성을 살펴보았다. 다음으로 모델의 4가지 북극 이벤트에 대한 예측성능과 모델이 깊은 연직 온난화를 예측할 때 북반구 지상 기온과 상층 지위고도 패턴에 대한 모의 성능을 평가하였다. 12월보다는 1월과 2월에 모델의 예측성능이 높게 나타났다. 마지막으로 2022년 초에 나타난 우리나라 기온 급강하 사례와 깊은 연직 온난화의 관련성에 대해 살펴보았다. 월별 분석으로 살펴보았을 때 1~2월 중 깊은 연직 온난화가 나타날 때 우리나라에 저온 발생 확률이 매우 높았으며, 깊은 연직 온난화로 인한 우리나라의 기온 급강하 현상은 종관규모에서 봄철까지도 나타날 수 있음을 알 수 있었다.

우리나라 기후예측을 위해서는 계절예측모델이 고위도 및 저위도로부터의 영향을 잘 모의해야 한다. 이 연구에서는 우리나라에 미치는 고위도 및 저위도로부터의 영향을 각각 반영하기 위해서 Cold-Polar (CP) 및 Warm-Tropical (MT) 기단을 고려하였다. APCC MME 참여모델은 CP 및 MT 기단의 계절안 변동성을 비교적 잘 모의하였으며, 우리나라 기온 및 강수의 계절안 변동성과도 유의한 관계를 보였다. 따라서 CP와 MT의 변동에 따른 한반도 기온 및 강수의 영향에 대해 상대적으로 관측과의 상관성이 높고, 모델 자체의 재현성도 높은 모델을 선별하였다. 결과적으로, CP와 MT로 표현되는 우리나라 기후 특성을 잘 모의하고, 이러한 기후 특성과 우리나라 기온/강수 변동성의 관계 또한 잘 모의하는 우수모델을 선정하고 이를 바탕으로 tailoring을 통한 정보를 활용할 경우, 계절안 예측성을 향상시킬 수 있음을 확인하였다.

BSISO는 기상과 기후를 이어주는 시간규모에서 발생하는 주요 변동 모드로서 여름철 계절내 예보 분야에서 중요한 예측인자 중 하나이다. 현재 1개월 예보에 활용 중인 WMO S2S ECMWF 모델에서 BSISO 재현정도를 가늠하기 위해 실시간 예측지수 모의성능을 진단해 보았다. 앙상블 평균 BSISO 예측성능은 20~30일로 대략 3~4주까지 지속되며 선행시간이 길어질수록 강도 및 이동속도를 과소모의하는 특성이 나타났다. 동아시아 지역에서 BSISO

영향편차장에서 보여지는 대류활동 및 원격상관 패턴의 3주차 모의성능은 ECMWF 총편차장 예측성과 유사한 수준으로 나타남에 따라 충분히 활용 가능성을 제시하였다. 더불어 3주차 BSISO 활동이 활발하거나 여름철 우리나라 고온, 폭염, 소우 발생에 기여하는 위상이 지속될 것으로 예측되는 경우 활용도가 더 높을 것으로 판단된다. 또한, BSISO는 올해 발생한 장마의 시작과 종료 및 평균 강수량 변동과 밀접한 관련이 있는 것으로 나타남에 따라 장마기간 예보에 참고할 수 있을 것으로 기대된다.

본 연구에서는 동아시아지역 및 남한지역의 1개월 기온확률 예측성을 개선하기 위해 딥러닝 기술을 이용하여 1개월 기온 예측모델을 개발하고 확률예측 체계를 구축하였다. 딥러닝 모델 설계는 U-NET 아키텍처를 기반으로 양방향 ConvLSTM, 채널 어텐션 메커니즘(SE 블록) 등을 활용하여 설계하고 예측성을 평가하였다. 학습자료는 일단위 ERA5 T2M(2m temperature) 재분석자료를 활용하였고, +3~4주 예측을 위해 ECMWF(the European Centre for Medium-Range Weather Forecasts) +1~2주 예측자료와 순환예측방법을 이용하였다. 학습은 1986년부터 2015년까지 총 30년의 일단위 자료로 학습 및 검증 데이터셋을 구축한 후에 데이터 셔플을 수행하고 학습에 사용하였다. 예측성 평가는 2018년부터 2021년까지의 자료를 이용하였다. 평가는 동아시아, 남한지역 등 2개 지역을 대상으로 수행하였다. 동아시아지역은 ROC(receiver operating characteristic) score map, 남한지역은 HSS(heidke skill score) 방법을 이용하였다. 동아시아지역의 ROC score map 분석결과, ECMWF 모델과 딥러닝 모델의 예측성이 비슷한 수준을 보였다. 반면, 남한지역의 HSS 분석결과, 딥러닝 모델의 예측성이 ECMWF 모델에 비해 다소 높게 나타났다. 그리고 ECMWF 예측자료는 Above Normal, 딥러닝 모델은 Near Normal의 예측성이 높았다. 그러므로 본 연구에서 제안한 딥러닝 기반 1개월 기온확률예측 체계는 1개월 기온확률 예측성을 개선하는 데 도움이 될 것으로 판단된다. 또한, 1개월 기온예측에 두 모델의 장단점을 활용하면 보다 예측성이 높은 확률예측이 가능할 것으로 판단된다.

기상청 1개월 전망 지원을 위해 APCC는 2017년 8월부터 1개월 전망 예측 시스템을 운영하고 있다. 이 시스템은 환경변화와 예보관의 수요에 따라 지속적으로 개선되고 있으며, 예측력과 모델에 대한 분석 능력이 향상되고 있다. 개선된 콘텐츠와 기후 예측인자의 적절한 활용을 통하여 2022년에도 APCC의 1개월 예측 결과는 여러 모델 대비 높은 예측성을 보였다. 이러한 APCC의 예측은 기상청과의 예보토의를 통해 충분히 공유하였고, 기상청의 장기예보 운영에 도움을 주었다.

목차

평문 초록	i
Executive Summary	iii
국문 요약	v
목차	vii
표 차례	ix
그림 차례	x
1. 서론	1
2. 방법 및 자료	4
가. 3개월 장기예보 개선	4
(1) ENSO 및 그와 관련된 계절안 규모의 대기 반응 분석	4
(2) 극지방 연직 기온분포에 따른 동아시아 기온 변동성 분석	5
(3) 우리나라 월별 기온/강수 예측성 향상을 위한 우수모델 선정 및 예측성 분석	7
나. 1개월 장기예보 개선	11
(1) BSISO 예측정보를 활용한 우리나라 1개월 장기예보 개선	11
(2) 딥러닝 기술을 활용한 1개월 기온 확률예측 시스템 구축	12
다. 국내 장기예보 전망 생산 지원	20
(1) 1개월 장기예보 시스템 운영/개선 및 신규 콘텐츠 개발	20
(2) WMO 장기예보 선도센터 계절내 예측 시스템 운영 및 개선	23
3. 결과	30
가. 3개월 장기예보 개선	30
(1) ENSO 및 그와 관련된 계절안 규모의 대기 반응 분석	30
(2) 극지방 연직 기온분포에 따른 동아시아 기온 변동성 분석	52
(3) 우리나라 월별 기온/강수 예측성 향상을 위한 우수모델 선정 및 예측성 분석	71
나. 1개월 장기예보 개선	95
(1) BSISO 예측정보를 활용한 우리나라 1개월 장기예보 개선	95
(2) 딥러닝 기술을 활용한 1개월 기온 확률예측 시스템 구축	111
다. 국내 장기예보 전망 생산 지원	125
(1) 1개월 장기예보 시스템 운영/개선 및 신규 콘텐츠 개발	125
(2) WMO 장기예보 선도센터 계절내 예측 시스템 운영 및 개선	144

4. 요약 및 결론	149
References	153
부록 A. 딥러닝 모델의 1개월 기온확률예측 사례비교	158
부록 B. 1개월 전망 검증보고서	159

표 차례

Table	page
Table 1. Description of model name and hindcast period used in this ENSO related response study. ..4	
Table 2. Description of models used in this study6	
Table 3. Categorical contingency table7	
Table 4. Global gridded datasets used to derive predictors.8	
Table 5. APCC one-tier dynamic seasonal prediction models9	
Table 6. Summary of ECMWF ERA5 reanalysis data downloaded in this study12	
Table 7. Characteristics of GPC data for WMOLC-LRFMME subseasonal prediction.24	
Table 8. Operational setup for subseasonal MME prediction system.25	
Table 9. Participating GPCs in subseasonal MME prediction each forecast before November 2019.26	
Table 10. Participating GPCs in subseasonal MME prediction each forecast since October 2020. ..26	
Table 11. Used data list for subseasonal MME prediction system.28	
Table 12. Time series correlation coefficient of 2m temperature and 500hPa geopotential height over Barents-Kara Sea between reanalysis and models.60	
Table 13. The pattern correlation coefficient for +3week forecast, evaluated from May 2016 ~ October 2021.99	
Table 14. Summaries for training, validation, and test dataset115	
Table 15. Initialize values and hyper-parameters for deep learning training115	

그림 차례

Figure	page
Figure 1. Cold-Polar (CP) and Warm-Tropical (MT) around Korea.	10
Figure 2. Example of an one-month forecasting schedule operated by the APEC Climate Center	13
Figure 3. Example of rolling prediction method for predicting 14 days	14
Figure 4. Design of the developed model in 2021	15
Figure 5. Design of new model	15
Figure 6. Production of deep learning +3~4 week forecast data using ECMWF +1~2week forecast data: (a) forecast data, (b) hindcast data	16
Figure 7. ROC curve	18
Figure 8. Calculation of HR and FAR	18
Figure 9. Design of the developed model in 2021	19
Figure 10. Summary of probability forecast results of observation and forecast, and formulas for HSS.	19
Figure 11. Operation schedule for APCC 1 month forecast.	20
Figure 12. Sample of APCC 1 month forecast charts.	21
Figure 13. Sample of subseasonal model output for APCC 3-month forecast.	22
Figure 14. The variables and covering periods of graphical products for subseasonal prediction.	29
Figure 15. Climatology of the sea surface temperature (SST) in the equatorial (5°S-5°N averaged) Pacific.	31
Figure 16. Normalized root mean square error (NRMSE) between observation and model curves in the climatology of the equatorial (5°S-5°N averaged) eastern Pacific (150~270°E) SST.	31
Figure 17. Climatology of the precipitation in the tropical (10°S-10°N averaged) Pacific.	32
Figure 18. Climatology of the precipitation in the eastern (150~90°W averaged) tropical Pacific.	32
Figure 19. Scatter plots between the temporal correlation coefficient and normalized root mean square error (NRMSE) of the Nino3.4 index.	34

Figure 20. Regressed equatorial (5°S~5°N averaged) SST anomalies onto Nino3.4 index.	35
Figure 21. Normalizes root mean square error (NRMSE) between observation and model curves in the regressed equatorial (5°S~5°N averaged) SST anomalies onto Nino3.4 index over the eastern Pacific (150~270°E).	35
Figure 22. Composites of the Nino3.4 index for the El Nino and La Nina years.	36
Figure 23. Regressed tropical (10°S~10°N averaged) precipitation anomalies onto Nino3.4 index.	37
Figure 24. Normalized root mean square error (NRMSE) between observation and model curves in the regressed precipitation anomalies onto Nino3.4 index over the tropical Pacific (100~270°E, 10°S~10°N).	37
Figure 25. Regression of (shading) 500hPa geopotential height anomalies and (contour) sea level pressure anomalies with respect to Nino3.4 index in December.	39
Figure 26. As in Figure 25 but for January.	40
Figure 27. As in Figure 25, but for February	41
Figure 28. Scatter plots between the pattern correlation coefficient (PCOR) and normalized root mean square error (NRMSE) of the 500hPa geopotential height anomalies and sea level pressure anomalies regressed onto Nino3.4 index over the Northern hemisphere (0~360°E, 20~85°N) and East Asia (110~160°E, 20~50°N).	43
Figure 29. Correlation coefficient between observation and model responses (bar and circle), and relative difference between correlation coefficients (diamond and line).	44
Figure 30. Regression of precipitation anomalies with respect to Nino3.4 index.	46
Figure 31. Composites of the precipitation anomalies over the western Pacific (WP; 110~150°E, 5°S~15°N) and the central Pacific (CP; 160~210°E, 5°S~5°N).	47
Figure 32. Multiple regression of 500hPa geopotential height anomalies with respect to precipitation anomalies over the western (110~150°E, 5°S~15°N) and central (160~210°E, 5°S~5°N) Pacific.	48
Figure 33. (a) Standard deviation of the northern hemisphere (20~85°N averaged) 500hPa geopotential height anomalies.	50
Figure 34. Scatter plots between the correlation coefficient of Korean temperature precipitation anomalies with Nino3.4 index. Each number indicates model number in Table 1. Number 12 indicates coefficient for observation.	51
Figure 35. Classified arctic events and temperature over East Asia and South Korea.	53

Figure 36. Percentage of occurrence of cold event in East Asia during each arctic event by month.	54
Figure 37. Composite maps of DAW and SAW during December.	55
Figure 38. Same as Figure 37, but for January	56
Figure 39. Same as Figure 37, but for February	57
Figure 40. Schematic diagram of (left) deep arctic warming and (right) shallow arctic warming.	58
Figure 41. Time series of standardized (top) t2m and (bottom) Z500 anomalies over Barents-Kara Sea during December.	59
Figure 42. Same as in Figure 41, but for January.	59
Figure 43. Same as in Figure 41, but for February.	60
Figure 44. Arctic events and 2m temperature anomaly over East Asia from each model and from reanalysis during January as an example.	61
Figure 45. Scatter plot of categorical predictability of arctic events by month.	62
Figure 46. Composite maps of (shade) 2m temperature and (contour) 500hPa geopotential height from reanalysis and models during December.	63
Figure 47. Same as in Figure 46, but for January.	64
Figure 48. Same as in Figure 46, but for February.	65
Figure 49 Taylor diagram of 2m temperature and 500hPa geopotential height over the northern hemisphere during deep arctic warming events.	65
Figure 50. Time series of temperature anomalies in South Korea (yellow) and sea ice extent in Barents (blue) and Kara (turquoise) from 1 January to 28 February.	66
Figure 51. Vertical distribution of temperature anomalies over Barents sea from 1 December to 28 February.	67
Figure 52. Time series of anomalies associated with deep arctic warming event: area-averaged anomalies of 500hPa geopotential height in Ural sector, SLP anomalies in the west and east of Ural sector, SAT and 500hPa temperature anomalies over Barents-Kara sea, 300hPa zonal wind anomalies at mid-latitude, and 2m temperature anomalies over South Korea.	68
Figure 53. Time series of temperature anomalies in South Korea (yellow) and sea ice extent in Barents (blue) and Kara (turquoise) from 1 March to 30 April.	69
Figure 54. Vertical distribution of temperature anomalies over Barents sea from 1 March to 30 April.	69

Figure 55. Same as in Figure 52, but for (left) March and (right) April.70

Figure 56. (Up) climatological precipitation with lower-level winds, and (down) 200hPa upper-level zonal winds and 500hPa geopotential height.71

Figure 57. Interannual variability of precipitation, climatological position of several fixed geopotential height at 500hPa, and low-level wind vectors at 850hPa for 22 years (1993-2014).72

Figure 58. Monthly interannual variability of precipitation, climatological position of several fixed geopotential height at 500hPa, and low-level wind vectors at 850hPa for 22 years (1993-2014).73

Figure 59. Summer climatological position of several fixed geopotential heights at 500hPa (contour), geopotential height deviation (shading) from its zonal mean, and wind fields at 850hPa; M1-M7 indicate each model used in this study and numbers in parentheses present pattern correlation of the climatological geopotential height deviation over the region.74

Figure 60. Summer climatological position of several fixed geopotential heights at 500hPa (contour), geopotential height deviation (shading) from its zonal mean, and wind fields at 850hPa from ECMWF.74

Figure 61. Time-series of Z500 deviation in the WNP, western ridge, strength and maximum intensity to represent the interannual WNPSH variability.75

Figure 62. Scatter plot of (a) correlation coefficients (CORR) and root-mean-square error (RMSE) for Z500 deviation in the WNP, (b) CORR and RMSE for strength, and (c) CORR for western ridge and maximum intensity to represent the interannual WNPSH variability.76

Figure 63. 500hPa geopotential height anomalies, 200hPa velocity potential, divergent wind anomalies, precipitation and 850hPa wind anomalies regressed onto the observed strength index.78

Figure 64. Anomaly correlation coefficients of precipitation in (a) MME-A and (b) MME-B. ..79

Figure 65. Selection of best model representing the WNPSH based on real-time forecasts in summer in 2022.79

Figure 66. 850hPa low-level wind, sea surface temperature and precipitation anomalies regressed onto the observed Nino3.4 index in preceding winter.81

Figure 67. The first two modes obtained by multivariate EOF analysis on the JJA 850hPa wind.81

Figure 68. Sea surface temperature, 500hPa geopotential height, precipitation and 850hPa low-level wind anomalies regressed onto the EOF1 in JJA.82

Figure 69. Sea surface temperature, 500hPa geopotential height, precipitation and 850hPa low-level wind anomalies regressed onto the EOF2 in JJA.	83
Figure 70. Signal-to-noise of SST in December (1-month lead) for individual model and MME. ...	84
Figure 71. Signal-to-noise of 500hPa geopotential height in December (1-month lead) for individual model and MME.	85
Figure 72. Ratio of predictable component of SST in December (1-month lead) for individual model and MME.	86
Figure 73. Ratio of predictable component of 500hPa geopotential height in December (1-month lead) for individual model and MME.	87
Figure 74. Anomaly Correlation Coefficient (ACC) over EA for each individual model and MME at each month (1-month lead).	88
Figure 75. Ratio of predictable component (RPC) over EA for each individual MME at each month (1-month lead).	88
Figure 76. Anomaly Correlation Coefficient (ACC) of CP and MT for each individual model and MME at each month (1-month lead).	89
Figure 77. Ratio of predictable component (RPC) of CP and MT for each individual model and MME at each month (1-month lead).	90
Figure 78. Anomaly Correlation Coefficient (ACC) of CP and MT for each individual model and MME for each lead month.	91
Figure 79. Ratio of predictable component (RPC) of CP and MT for each individual model and MME for each lead month.	91
Figure 80. Scatterplot of RPC for monthly 2m temperature forecast at 1-month lead.	92
Figure 81. Scatterplot of RPC for monthly precipitation forecast at 1-month lead.	93
Figure 82. 1-yr out cross-validated skill (ACC) for 2m temperature and precipitation at 1-3 month lead. Think red line indicates tailored forecast with best model selected.	94
Figure 83. The single-member predictability, ensemble-mean predictability, single-member prediction skill and ensemble-mean prediction skill estimate of MJO, BSISO1 and BSISO2.	96
Figure 84. Scatter plot of RMSE and Bivariate Correlation Coefficient for BSISO1 and BSISO2. ...	97
Figure 85. The amplitude error and phase error of BSISO1 and BSISO2.	97
Figure 86. The prediction skill initiated from different initial phases for MJO and BSISO.	97
Figure 87. Anomaly correlation coefficient of MJO-related(left) and BSISO-related(right) convection anomalies during the extended summer.	98

Figure 88. The mean seasonal cycle of fractional variance (%) of OLR anomaly accounted by BSISO and MJO index.	98
Figure 89. The pattern correlation coefficient and relative amplitude of OLR, 500hPa geopotential height, 850hPa zonal wind, 850hPa meridional wind anomalies associated with ECMWF (sky blue), BSISO (blue), strong BSISO (green), strong BSISO1 (orange), and strong BSISO2 (pink) over East Asia region.	101
Figure 90. The pattern correlation coefficient and relative amplitude of OLR, 500hPa geopotential height, 2m temperature, precipitation anomalies for +3week forecast during the extended summer (MJJASO), warm phase, cool phase, wet phase, and dry phase.	102
Figure 91. BSISO associated anomaly composites of warm phase case and dry phase case for +3week forecast.	103
Figure 92. Summary of skillful BSISO impact forecast with 3-weeks lead time in East Asia during boreal summer.	104
Figure 93. BSISO1 and BSISO2 phase space diagrams from June 20, 2022 to July 24, 2022.	105
Figure 94. Observed weekly mean of BSISO-related anomalies for 20~26 June and 18~24 July 2022, respectively.	105
Figure 95. Changma onset phase space diagram based on the BSISO1/BSISO2 index for each year from 1981~2016.	106
Figure 96. Composites of precipitation, OLR and 850-hPa wind, MSLP and 5,880gpm, 1000~700hPa vertically integrated moisture transport and convergence, vertical velocity and zonal wind anomalies during BSISO1 phase 5 and BSISO2 phase 7, respectively.	107
Figure 97. The variance of (a) total (b) intraseasonal (c) 30~60-day filtered (d) 10~20-day filtered rainfall anomaly during Changma.	107
Figure 98. ECMWF weekly mean of BSISO-related anomalies for 20~26 June and 18~24 July 2022 at 3-weeks lead time, respectively.	108
Figure 99. BSISO phase space diagram of heavy rain event for observation (left) and +3week forecast (right).	109
Figure 100. Weekly mean of observed BSISO-related anomalies from 8~14 August 2022.	109
Figure 101. The phase points of observation and +3week forecast for 8~14 August, 2016.	110
Figure 102. Composite anomaly map of OLR, 850hPa wind and 500hPa geopotential height for the observation and +3week forecast in BSISO1 P7.	110
Figure 103. time-series data decomposition approaches	111

Figure 104. Results of detrending and deseasonalization of ERA5 T2M reanalysis global average data	112
Figure 105. Process flowchart of removing and restoring trends and seasonality in deep learning training and inference.	113
Figure 106. Comparison of traditional approach and data shuffle approach.	113
Figure 107. Comparison of the results of data processing using traditional approach and data shuffle.	114
Figure 108. Results of deep learning training and validation losses	116
Figure 109. ROC score map around East Asia in 2018: (a) +3week, (b) +4week	117
Figure 110. ROC score map around East Asia in 2019: (a) +3week, (b) +4week	118
Figure 111. ROC score map around East Asia in 2019: (a) +3week, (b) +4week	119
Figure 112. ROC score map around East Asia in 2019: (a) +3week, (b) +4week	120
Figure 113. ROC score map around East Asia in 2018~2021: (a) +3week, (b) +4week	121
Figure 114. HSS results in South Korea in 2018~2021: (a) +3week, (b) +4week	122
Figure 115. HSS results in South Korea by year: (a) +3week, (b) +4week	123
Figure 116. Example of visualization of map charts of probability forecast results around East Asia with charts of probability forecast results in South Korea by deep learning model: (left) +3week and (right) +4week	124
Figure 117. Anomaly correlation coefficient of weekly mean prediction of (a) MSLP, (b) Z500, (c) MSLP (3set-1set) and (d) Z500 (3set-1set) for the period Jan 2019 to Nov 2021 over the East Asia.	126
Figure 118. Sample of 1-month ECMWF prediction for T2M/PREC.	126
Figure 119. Sample of verification of 1-month prediction for Z500.	128
Figure 120. Sample of 1-month SCM, Washington, and Montreal prediction for Z500.	128
Figure 121. Sample of verification of 1-month prediction for T2M and PREC.	129
Figure 122. Sample of 1-month ECMWF prediction for Tibetan/WNP High.	130
Figure 123. Regression map of (a) Z1000 and (b) MSLP during 1979~2000.	131
Figure 124. (a) Monthly and (b) daily Arctic Oscillation for the period from 1979 to 2021. ·	131
Figure 125. Verification of daily AO forecast for the period from Jan 2018 to Apr 2022. ··	132
Figure 126. Sample of ECMWF daily Arctic Oscillation forecast.	133
Figure 127. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 16~22 May 2022.	134

Figure 128. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 18~24 May 2020.	135
Figure 129. KMA ASOS precipitation data, anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 20~26 Jun 2022.	136
Figure 130. KMA ASOS precipitation data, anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 25 Jun ~ 1 July 2018.	137
Figure 131. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 8~14 Aug 2022.	138
Figure 132. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 16~22 Aug 2021.	139
Figure 133. Heidke skill score for 2m temperature forecast of GloSea, ECMWF and APCC from Jan 2022 to Oct 2022.	140
Figure 134. Heidke skill score for precipitation forecast of GloSea, ECMWF and APCC from Jan 2022 to Oct 2022.	141
Figure 135. 12 weeks moving window Heidke skill score of GloSea, ECMWF and APCC for temperature forecast.	142
Figure 136. 12 weeks moving window Heidke skill score of GloSea, ECMWF and APCC for precipitation forecast.	142
Figure 137. The ratio of above normal, near normal and below normal categorical forecast of GloSea, ECMWF and APCC.	143
Figure 138. Anomaly correlation coefficient (ACC) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period of Jan 2016~Aug 2022 around the globe.	145
Figure 139. Anomaly correlation coefficient (ACC) of monthly averaged +3week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period from Jan 2016 to Oct 2022 around the globe.	146
Figure 140. 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 from Jan 2016 to Oct 2022 around the globe.	147
Figure 141. Root mean square error (RMSE) of monthly averaged +3week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period from Jan 2016 to Oct 2022 around the globe.	148

1. 서론

APCC는 지난 수년에 걸쳐 기상청과의 협력시스템을 바탕으로 지원체계를 강화함으로써 현업 장기예보 정확도 향상을 위한 노력을 기울여 왔다. 2022~2024년의 3년에 걸친 6단계 아태 사업에서는 기존 APCC-기상청의 협력시스템을 바탕으로 하되, 장기예보에 있어 APCC만의 역할 영역을 더욱 확대할 필요가 있으며, 이를 위해서는 현업 장기예보 실무 예측기술을 개선하고, 앞서 개발된 기술 또는 개선된 기후정보(예측성이 좋은 정보)를 선별하고 가공하여 객관화된 예측정보를 생산할 수 있는 기반을 마련할 필요가 있다. 이는 장기예보 현업기관(기상청)과 장기예보 기술 등의 연구개발을 하는 여타 R&D 과제들과는 차별화되는 것으로써, 지속적인 국내 장기예보 생산 및 실무 예측기술 개선과 활용을 통해 국내 장기예보를 개선하는데 더욱 기여하고자 한다.

장기예보를 위해서는 자료생산단계(관측분석-기후모델운영-장기예보 기술개발) 및 예보정보생산단계(예보관 종합분석-서비스, 홍보)에서의 기술개발 및 개선이 필요하며, 이 둘의 연계를 통해 직접 실무에 적용하는 과정이 필요하다. 특히, 장기예보 생산을 위해서는 모델 예측정보가 필수적이며, 이를 실무에 활용하기 위한 장기예보기술을 개선할 필요가 있다. APCC MME와 기상청 현업모델의 성능은 ECMWF 모델에 버금가는 좋은 성능을 보이지만, 우리나라를 포함한 중위도 지역의 기후에 대한 정확한 장기예보는 여전히 어려우며 특히 여름철 강수의 예측성은 현저히 낮게 나타나고 있다. 특히, 계절내 예측(3주~6주) 기술개발을 통해 예측 사각지대를 해소할 수 있는 기술개발 및 개선과 함께, 우리나라 장기전망의 체계 자체에 대한 고민도 필요하다. 따라서 이 연구에서는 계절 및 계절내 장기예보 기술개선을 통한 정확도 향상과 함께, 그간의 장기예보 경험 및 (기존 관측 및 모델 자료 기반의) 산재된 정보를 통합하여, 우리나라 장기예보 시 활용 가능한 객관화된 예측정보 생산을 위한 기반을 마련하고자 한다. 이를 위하여, 2022년에는 장기예보 예측성 향상을 위한 기술을 개선하고자 하며, 관련한 연구내용을 하나씩 살펴보면 다음과 같다.

첫째, 장기예보 개선을 위해 관측 감시 정보나 역학 모델 정보 등 여러 다양한 예측정보를 하나로 통합하기 위해서는 각 정보가 가지고 있는 예측 특성에 대한 이해가 먼저 이루어져야 한다. APCC MME의 예측 성능과 예측 자료의 활용성을 평가하기 위한 연구는 기존 여러 연구에서 수행되어왔고, MME 예측 성능은 우수한 것으로 평가되어왔다 (e.g. Min et al. 2014; Sohn and Kim 2020). 그러나 기존의 연구는 대부분 3개월 평균한 예측 정보 위주로 연구가 수행되어 1개월 평균 단위의 월별 예측정보 생산에는 연구 결과를 바로 적용하기에 어려움이 있었고, 전구 예측과 비교해 우리나라를 포함한 중위도 동아시아 지역에 대한 예측성은 낮게 나타나 현업 예보에 어려움이 있다. 따라서 모델의 월별 예측정보 특성에 대한 이해를 높이기 위해 겨울철 동아시아 지역 예측에 중요한 강제력 중 하나인 ENSO와 그에 대한 반응이 월별 예측 즉 계절안 규모에서 어떤 특성을 갖고 모의 되고 있는지 살펴보았다.

둘째, APCC에서는 겨울철 3개월 전망 예측에서 우리나라 기온에 영향을 주는 예측인자로 가을철 해빙 상태를 활용하고 있다. 그러나 지속되는 북극 온난화에 따라 일부 가을철 해빙 예측인자는 겨울철 우리나라 기온과 상관관계가 낮아져 해당 예측인자의 적중률은 35% 이하로 떨어지는(여새림 등, 2021) 등 해빙 예측인자를 통한 우리나라 겨울철 기온 예측에 한계가

있음이 드러나며 예측인자의 활용성이 점점 떨어지고 있다. 선행연구에서는 모델에서 북극의 기온상승이 대류권 상층까지 깊게 나타날 때 북극 영향에 의한 중위도 대기 반응도 잘 모의될 수 있다고 하였다(Screen et al., 2012; Screen Simmonds, 2010; Coumou et al., 2018; Sellevold et al., 2016). 이러한 반응은 주로 내부변동성에 기인하기 때문에 오직 모델의 일부 앙상블 멤버만이 관측된 연직 기온분포를 잘 모의할 수 있었고(Ogawa et al., 2018; Matsumura and Kosaka, 2019; Warner et al., 2020), 결합모델(Coupled general circulation models, CGCM)이 아닌 대기대순환모델(Atmospheric general circulation models, AGCM)에서는 그 시그널이 더욱 약하게 나타난다(Cohen et al., 2020; Deser et al., 2015). APCC 3개월 전망에 활용되는 모델들이 엘니뇨-남방진동(El Nino-Southern Oscillation, ENSO)이나 인도양 양극자모드(Indian Ocean Dipole, IOD)등 열대지역에 대한 모의 성능과 그에 대한 반응을 얼마나 잘 모의하는지에 대한 정보는 있지만, 극 지역에 대한 모의 성능과 극 지역의 영향으로 나타나는 중위도의 대기 반응에 대해 분석한 정보는 거의 없다. 또한 모델들의 북극 연직 온난화에 관해 분석한 선행연구들은 대부분 겨울철 평균(DJF), 혹은 일 단위의 시간규모에서 북극 연직 온난화에 대한 동아시아 기온 변동성을 분석하여(He et al., 2020; Mori et al., 2014; Xu et al., 2021) 월별 예측정보를 생산하는 데 활용하기는 어려움이 있다. 따라서 이 연구에서는 재분석자료에서 겨울철 북극 연직 온난화와 관련된 동아시아 기온의 월별 변동성과 이를 3개월 예측에 활용 가능한지를 평가하고, APCC MME 참여모델에서 북극 연직 온난화 및 그와 관련된 대기순환장 패턴의 특성이 잘 모의 되는지 조사하고자 한다.

셋째, APCC 모델 예측정보는 10개 이상의 모델과 300개 이상의 앙상블 멤버를 사용한 다중모델앙상블 기법으로 생산된다. 하지만 다중모델앙상블 기법의 필연적으로 우리나라에 적합한 장기예보 기법은 아닐 수 있으므로, 우리나라 장기예보 개선을 위해 더욱 적합한 모델을 선별할 필요가 있다. 따라서 이 연구에서는 우리나라 장기예보를 위해 고위도 및 저위도로부터의 영향을 잘 모의하는 모델을 선별하였다. 이때, 우리나라와 기후변동과 밀접한 관계가 있는 Cold-Polar (CP) 및 Warm-Tropical (MT)에 대해 한반도 기온 및 강수와의 관계를 얼마나 잘 표현하느냐를 기준으로 하여, 모델을 선별하였다. 결과적으로는 CP와 MT로 표현되는 우리나라 기후 특성을 잘 모의하고, 기후 특성과 우리나라 기온/강수 변동성의 관계도 잘 모의하는 우수모델을 선정하고 이를 바탕으로 tailoring을 통한 계절안 예측성을 향상시킬 수 있는 방안을 제시하고자 한다.

넷째, 여름철 계절내 진동은 열대지역을 벗어나 아시아 여름 몬순과도 상호작용하기 때문에 공간구조 및 전파양상이 매우 복잡하다. 인도 몬순 지역에서 북진 또는 적도를 따라 동진하는 모드뿐만 아니라 북서태평양 몬순 지역에서 북서쪽으로 전파되는 모드가 존재한다. 북반구 여름철에 발생하는 두 개의 독립적인 계절내 진동 모드를 재현하는 Boreal Summer Intraseasonal Oscillation (BSISO) 지수 및 지수로 추정되는 영향편차장의 모의성능을 평가하고 활용가능한 정보만을 선별하고자 하였다.

다섯째, S2S 시간규모는 풍속, 온도, 대기압 등 대기 초기조건의 영향이 사라질 정도로 길고, 해양 등의 경계조건의 변동성이 영향을 미치기에는 다소 짧은 시간이다(Vitart et al. 2017). 따라서 수치모델을 이용한 1개월 예측성을 확보하는 데는 어려움이 많이 있다. 기존의 방법에서 벗어나 인공지능과 같은 새로운 방법에 대한 도입의 필요성이 대두되고 있다. 본

연구에서는 최근 인공지능 분야에서 가장 많이 활용되는 딥러닝 기법을 이용하여 1개월 기온예측모델을 개발하고자 한다. 또한, 1개월 예측모델을 토대로 기온확률예측 체계를 구축에 필요한 기법들을 개발하고 활용 가능성을 평가하고자 한다.

이와 더불어 기상청 1개월 전망 지원을 위해 APCC 장기예보 전담팀은 우리나라 기온과 강수량 예측에 최적화된 1개월 전망 예측 시스템을 운영하고 있다. 매주 계절내 예측 모델자료 수집 및 MME 계산을 수행하고, 1개월 전망 토의 시 필요한 예측 콘텐츠를 생산한다. 이를 바탕으로 내부 토의를 거쳐 최종 APCC 1개월 전망을 확정하고 기상청과의 화상회의 시 발표하고 토의한다. 2022년에도 1개월 전망 예측시스템을 지속적으로 운영하면서 이를 개선하고, 예보관의 요청 사항을 반영한 다양한 예측 콘텐츠를 추가하였다. 이 보고서에서 APCC 1개월 전망 현업시스템의 운영과 2022년 개선 사항을 설명하고, APCC 최종 예측 결과에 대한 예측성을 검증해 보았다.

2. 방법 및 자료

가. 3개월 장기예보 개선

(1) ENSO 및 그와 관련된 계절안 규모의 대기 반응 분석

겨울철 ENSO 및 그와 관련된 계절안 규모의 대기 반응 분석을 위해 계절예측 모델 자료와 관측 재분석자료를 사용하였다. 모델 자료는 APCC MME에 참여하는 개별모델에서 2021/22년 겨울철을 기준으로 가용한 모델 중 자료의 기간을 고려해 10개 모델을 선정하였고, 예측성이 높다고 알려진 ECMWF (European Centre for Medium-Range Weather Forecasts) 계절예측 모델도 함께 분석하였다. 분석 기간은 1993/94년부터 2014/15년까지 총 22년 기간의 12월, 1월, 2월이며 사용한 모델에 대한 정보를 Table 1에 정리해 나타내었다. 표에서 모델 이름별로 색을 다르게 나타내었는데 뒷장의 결과 부분에서도 동일한 색으로 나타내어 모델별로 결과를 구분할 수 있도록 하였다. APCC MME에 참여하는 모델과 ECMWF 모델 비교를 위해 MME는 ECMWF를 제외한 10개 모델의 평균을 사용하였다. 분석은 1개월 선형예측을 중심으로 하였으나 모델 평균장과 ENSO 반응 모의 성능 등은 2개월과 3개월 선형예측 결과도 함께 살펴보았다.

Table 1. Description of model name and hindcast period used in this ENSO related response study.

	Institute	Model	Ensemble size	Hindcast period
1	BCC	CSM1.1M	24	1991~2015
2	BOM	ACCESS-S2	27	1981~2018
3	CMCC	SPS3.5	40	1991~2016
4	CWB	TCWB1Tv1.1	30	1982~2019
5	JMA	MRI-CPS2	10	1980~2015
6	KMA	GLOSEA5	12	1991~2016
7	METFR	SYS8	25	1993~2016
8	NASA	GEOS-S2S-2.1	4	1981~2016
9	PNU	CGCMv2.0	35	1980~2020
10	UKMO	GLOAEA6	28	1993~2016
11	ECMWF	SEAS5	25	1993~2016

모델 자료와 비교할 관측 자료로, 대기 변수는 ECMWF에서 제공하는 reanalysis 5 (ERA5), 해수면온도(Sea surface temperature; SST)와 강수 자료는 National Oceanic and Atmospheric Administration (NOAA)에서 제공하는 Extended Reconstructed Sea Surface Temperature

(ERSST) V5, Global Precipitation Climatology Project (GPCP) version 2.3 자료를 사용했다. 재분석자료 또한 모델과 동일한 1993/94년부터 2014/15년까지 22년 기간의 자료를 사용하였다.

분석 방법으로 합성장 분석, 회귀분석 등의 통계분석 방법을 사용했다. 합성장 분석에서 사용된 엘니뇨와 라니냐 해는 NOAA CPC에서 제공하는 Oceanic Nino Index (ONI)를 기준으로 분석 기간인 1993/94년~2014/15년에서 분류하였고, 엘니뇨 7개 해 (1994/95, 1997/98, 2002/03, 2004/05, 2006/07, 2009/10, 2014/15), 라니냐 9개 해 (1995/96, 1998/99, 1999/00, 2000/01, 2005/06, 2007/08, 2008/09, 2010/11, 2011/12)를 사용하였다.

모델의 성능을 평가하기 위해 상관계수(correlation coefficient)와 평균제곱근오차(root mean square error; RMSE) 분석을 사용하였다. 상관계수 분석은 시계열 또는 공간 패턴에 적용해 유사성을 측정했으며 1에 가까울수록 모델이 관측과 유사함을 의미한다. RMSE는 모델 예측장과 관측장 사이의 오차를 나타내는 척도로 모델장과 관측장 사이의 오차를 제공하여 평균한 값을 제곱근으로 표현한다. RMSE는 변수에 따라, 분석한 월에 따라 스케일에 차이가 있기 때문에 상대적인 비교를 위해 관측의 12~2월 평균 표준편차로 나누어 정규화하여 사용하였다 (normalized RMSE; NRMSE).

(2) 극지방 연직 기온분포에 따른 동아시아 기온 변동성 분석

(가) 재분석자료 및 모델자료

재분석자료로 유럽중기예보센터(European Centre for Medium-range Weather Forecasts; ECMWF)의 ERA5(Hersbach et al. 2020) 자료와 영국 해들리센터(Hadley Centre)의 해빙과 해수면온도 자료인 HadISST v2(Rayner et al. 2003)을 사용하였다. 1979년부터 2021년까지 12월, 1월, 2월의 월 평균된 2m 기온(t2m), 500hPa 기온(t500)과 지위고도(z500), 해면기압, 300hPa 수평 바람 자료를 활용하였고, 1000hPa에서 300hPa까지 표준 기압면의 상대습도, 수직·수평 바람을 이용하여 연직 수분속(Vertically integrated moisture influx, vimf)을 계산하였다.

모델의 예측성 분석을 위해 해빙 모형의 결합 여부와 2021년에 생산된 모델의 최근 기후재현 자료 유무를 기준으로 APCC MME에 참여하는 14개 모델 중 6개를 선정하였고, 예측성이 높다고 알려져 현업 3개월 예측에서 자주 참고하는 ECMWF 모델도 함께 분석하였다. MME 참여모델의 현 기후 재현기간은 1991년부터 2010년을 사용하였고, ECMWF 모델의 현 기후 재현기간은 1993년부터 2016년까지이다. 총 7개 모델을 평균하여 1991년부터 2010년까지의 기간에 대해 MME를 생산하였으며, 각 모델에 대한 상세한 정보를 Table 2에 나타내었다.

Table 2. Description of models used in this study

Institution	Model	Atmospheric model	Ocean model	Sea Ice model	Seaiice initial condition	# of Ensemble	Hcst period used
APCC	SCoPS	ECHAM5.3	POP2.0.1	CICE4.1	forecast	10	1991-2010
JMA	MRI-CPS3	JMA-GSM	MRI. COM v4.6	Interactive sea ice model	MOVE/MRI.CO M-GE	10	1991-2010
KMA	GloSea5 GC3.2	UM8.6	NEMO v3.4	CICE4.0	UKMO ODA Reanalysis	12	1991-2010
NASA	GEOS-S2S-2.1	Post MERRA-2	MOM5	CICE4.0	GEOS ODAS	4	1991-2010
NCEP	CFSv2	NCEP GFS	GFDL MOM4	GFDL MOM4	CFSR	20	1991-2010
PNU	CGCMv2.0	CCM3	MOM3	LANL EVP	OMIP run with MOM3	35	1991-2010
ECMWF	SEAS5	IFS Cycle 43r1	NEMO v3.4	LIM2	ORAS5	25	1993-2016

(나) 북극 연직 기온분포의 구분

이 연구에서는 He et al. (2020)을 참고하여 북극 연직 기온분포를 통해 북극 이벤트를 구분하였다. 먼저 바렌츠·카라해 지역(70~80°N, 30~50°E)에서 2m 기온과 500hPa 기온의 1991~2020 기후값에 대한 편차를 구하고 전체 분석 기간(1979~2020/21)에 대하여 표준화하여 지수를 산출하였다. 북극 이벤트는 바렌츠·카라해의 상층(500hPa)과 하층(2m) 기온을 기준으로 아래와 같이 4가지로 정의하였다.

- 깊은 연직 온난화(Deep Arctic Warming, DAW):
상층과 하층 기온이 모두 표준화 지수 0.5보다 높은 경우
- 얕은 연직 온난화(Shallow Arctic Warming, SAW):
상층 기온은 표준화 지수 0.5보다 낮으나 하층 기온은 표준화 지수 0.5보다 높은 경우
- 상층 온난화(Warming aloft):
상층 기온은 표준화 지수 0.5보다 높으나 하층 기온은 표준화 지수 0.5보다 낮은 경우
- 이벤트 없음(Others):
상층과 하층 기온이 모두 표준화 지수 0.5보다 낮은 경우

북극 이벤트에 대한 동아시아의 기온 변동성 반응을 살펴보기 위해 동아시아(35~50°N, 80~130°E) 지역에 대해서도 같은 방법으로 2m 기온 지수를 산출하였다.

(다) 성능평가

모델의 북극 이벤트 예측성능은 카테고리형 이분표(Table 3)를 작성하여 정확도(Accuracy)와 Heidke skill score (HSS)를 계산하는 것으로 평가하였다. 또 모델이 깊은 연직 온난화를 예측하였을 때 모델 내에서 북반구의 대기순환장 패턴의 반응과 동아시아의 기온 변동성에 대해서는 모델의 기온과 지위고도 예측장의 관측자료 대비 패턴 상관관계와 표준편차의 비율로 평가하였다.

Table 3. Categorical contingency table

OBS Model	DAW	SAW	Warming aloft	Others
DAW				
SAW				
Warming aloft				
Others				

$$Accuracy(ACC) = \frac{1}{N} \sum_{i=1}^k n(F_i, O_i) \quad [1]$$

$$Heidke\ skill\ score(HSS) = \frac{\frac{1}{N} \sum_{i=1}^k n(F_i, O_i) - \frac{1}{N^2} \sum_{i=1}^k n(F_i)n(O_i)}{1 - \frac{1}{N^2} \sum_{i=1}^k n(F_i)n(O_i)} \quad [2]$$

(3) 우리나라 월별 기온/강수 예측성 향상을 위한 우수모델 선정 및 예측성 분석

(가) 관측 및 모델자료

① 관측자료

우리나라 기온 및 강수에 대한 관측 자료로써 재분석자료인 EMCWF의 ERA5를 사용하였다. 대기 및 해양에 대한 관측 자료로는 미국 NOAA (National Oceanic and Atmospheric Administration) NCEP (National Centers for Environmental Prediction)의 CPC (Climate Prediction Center)의 자료의 상향장파복사(outgoing longwave radiation, OLR), 500hPa 및 850hPa의 지위고도(Z500 and Z850), 해면기압(sea level pressure, SLP), 850hPa 기온(T850)의 전지구 격자자료를 사용하였다. 월별 해수면온도(sea surface temperature, SST) 자료는 NOAA의 Extended Reconstructed Sea Surface Temperature (ERSST) Version 5 자료를 사용하였다.

Table 4. 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)
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)

② 모델자료

모델의 예측성 분석을 위해 APCC MME의 SST, PRCP, Z500, T2M, T850, U200, V200, U850, V850, SLP 자료를 사용하였다. 다중 모델의 특성을 고려하기 위하여 APCC MME에 참여하는 가용한 개별모델을 모두 사용하였다. 때에 따라 차이가 있으나 통상적으로 APCC MME는 10여 개의 모델, 300여 개의 앙상블 멤버로 구성된다.

Table 5. APCC one-tier dynamic seasonal prediction models

Institution / Center	Ensemble size (F/H)	Hindcast period
APCC (Korea)	10/10	1983~2013
BCCC (China)	24/24	1991~2015
BoM (Australia)	11/27	1981~2018
CMCC (Italy)	20/20	1993~2016
CWB (Chinese Taipei)	30/30	1982~2019
HMC (Russia)	20/10	1990~2015
JMA (Japan)	50/10	1991~2020
KMA (Korea)	42/12	1993~2016
METFR (France)	51/25	1993~2016
ECCC (Canada)	10/10	1980~2020
NASA (USA)	10/4	1981~2016
NCEP (USA)	20/20	1982~2010
PNU (Korea)	35/35	1983~present
UKMO (United Kingdom)	42/28	1993~2016

(나) 여름철 북서태평양고기압 정의

우리나라 여름철 가장 큰 영향을 미치는 기후인자 중 하나는 북서태평양고기압이다. 북서태평양고기압은 여름철 폭염과 같은 기온이나 장마와 같은 강수 변동성과 밀접한 관계가 있다. 많은 선행연구에서 북서태평양고기압을 정의한 바 있는데, 여름철 북서태평양고기압의 강도(Li et al. 2021; Paek et al. 2015; Huang et al. 2020; Hong et al. 2014; Xiang et al. 2013; Liu et al. 2019), 북서태평양고기압의 가장자리 위치(Zhang et al. 2020; Lu 2001; Liu et al. 2019; He and Zhou 2014) 등이 그것이다. 이 연구에서는 북서태평양고기압의 변동성을 분석하기 위해 다양한 특징들에 대해 종합적으로 분석하였다. 기존 선행연구에 기반하여, 네 개의 지수를 사용하였다; 첫째, 500hPa 지위고도 편차로 북위 0~45도 지역의 동서방향 평균에 대한 편차의 지역(5~40°N, 110~180°E)의 평균으로 정의하였다. 둘째, 북태평양고기압의 가장자리 위치로 동경 140~160 사이에서 적도 동풍과 중위도 서풍이 만나는 평균 위도로 정의하였다. 셋째, 강도를 나타내기 위해 북쪽(20~40°N, 120~180°E)과 남쪽(5~15°N, 120~180°E)에서의 850hPa 동서바람의 차이로 정의하였다. 넷째, 최대 강도로서, 북서태평양고기압의 최대 중심 위치(10~30°N, 120~160°E)에서의 MSLP의 평균값으로 정의하였다. 특히, 북서태평양고기압의 최대강도는 여름철 아시아 몬순과 밀접한 관계가 있으며, 강한 음의 상관관계를 나타낸다.

(다) 월별 기후예측을 위한 주요 기압계 동향 정의

우리나라 기후예측을 위해서는 모델이 고위도 및 저위도로부터의 영향을 잘 모의해야 한다. 특히 우리나라 주변의 기압계 동향은 계절내~계절 규모에서 주요 기후감시 요소로 사용되므로, 이를 월별 기후예측을 위해 활용하기로 한다. 즉 고위도 및 저위도의 영향을 각각 반영하기 위해서 Cold-Polar (CP) 및 Warm-Tropical (MT) 기단을 고려하였다. CP와 MT의 위치는 다음과 같다.




Figure 1. Cold-Polar (CP) and Warm-Tropical (MT) around Korea.

(라) 모델 불확실성 정의

모델 예측성 및 불확실성을 파악하기 위한 지표로 대표적인 것이 신호대잡음비(Signal-to-Noise, S2N)이다. 이때 신호(signal)는 앙상블 평균의 연변동(분산)으로 정의하며, 잡음(noise)은 앙상블 평균에 대한 각 개별 앙상블 멤버의 분산 정도로 정의된다. 따라서 이 둘의 비율을 신호대잡음비로 정의하고, 신호가 클수록 S2N은 커지며, 반대로 잡음이 클수록 S2N은 작아진다.

또 다른 모델 불확실성 파악 지표로써 예측가능요소비(Ratio of Predictable Component, RPC)를 사용하였다. RPC는 모델 예측값과 실제 관측값의 관계(상관계수)와 모델 자체가 가지는 신호(signal)의 비율로 나타낸다. 따라서 RPC가 1일 때 완벽한 예측이 되며 RPC가 1보다 클 때는 모델의 신호가 너무 작아서 모델 자체의 예측성분이 (실제 관측보다) 낮음을 의미하며, RPC가 1보다 작을 때는 모델 자체의 예측성분이 (실제 관측보다) 크지만, 관측과의 상관계수가 낮음을 의미한다. 다시 말해 RPC가 1보다 클 때는 underconfident한 예측결과로 관측과의 상관계수는 높으나, 앙상블 평균으로 표현되는 신호에 비해 잡음이 크다는 것을 의미한다. 반대로 RPC가 1보다 작을 때는 overconfident한 예측으로, 관측과의 상관계수는 작고, 모델 예측 자체의 불확실성(spread) 자체가 충분치 않음을 나타낸다.

나. 1개월 장기예보 개선

(1) BSISO 예측정보를 활용한 우리나라 1개월 장기예보 개선

(가) BSISO 지수 및 영향편차장

WMO ECMWF 계절내 예측 모델은 2016년부터 매주 목요일 또는 월요일 초기장을 기반으로 예측자료를 생산한다. 현재 목요일 초기장 예측결과는 2017년까지, 월요일 초기장 예측결과는 2021년까지 생산되어 활용가능하다. 따라서 2016년부터 2021년까지 5월~10월 BSISO 지수 및 영향편차장에 대한 실시간예측(real-time forecast) 모의성능을 평가하였다. 먼저, 일평균 OLR 및 850hPa 동서 바람 예측값에 과거재현자료(Hindcast)의 20년 평균된 기후값 및 직전 120일 평균값을 제거하여 경년 변동과 연주기 효과를 제거한 후 아시아 몬순 지역 평균된 표준편차로 정규화한 편차값을 관측의 다변량경험적직교함수(MV-EOF) 모드에 투영하여 총 46일에 대한 예측지수를 생산하였다. 또한, 매일에 대한 위상별 관측 합성장에 예측지수로부터 얻는 위상 및 강도 정보를 결합한 영향편차장을 주평균하여 6주 예측 영향정보를 생산하였다. 재분석자료의 경우 NOAA (National Oceanic and Atmospheric Administration)의 OLR 및 NCEP/NCAR (the National Center for Environmental Prediction/National Center for Atmospheric Research) reanalysis 1의 500hPa 지위고도, 하층바람, 연직적분수분속수렴, ECMWF (the European Centre for Medium-range Weather Forecasts) ERA5 기온 및 강수가 사용되었다. ECMWF 예측자료의 기본 수평해상도는 1.5° 로 재분석자료의 수평해상도를 모델의 수평해상도로 맞추는 재격자 과정이 필요하다.

(나) 검증방법

BSISO1 모드는 다변량경험적직교함수(MV-EOF)의 첫 번째와 두 번째 모드의 주성분 시계열(PC1, PC2)로 구성되고 BSISO2 모드는 세 번째와 네 번째 모드의 주성분 시계열(PC3, PC4)로 구성된다. BSISO1 및 BSISO2 지수는 각각 단위 표준편차와 진폭이 거의 같은 정규화된 이변량 지수로써 Real-time Multivariate MJO (RMM) 지수 검증 매트릭스(Rashid et al., 2011)와 동일한 방법으로 Bivariate Correlation Coefficient (BCC), Root-mean-square error (RMSE), Amplitude error, Phase error에 대해 평가하였다. 이변량상관계수(BCC)는 관측과 예측의 공간패턴 상관계수와 동일한 개념으로 진폭 오차에는 둔감하고 위상 오차에 민감하다. BCC의 예측임계값은 0.5이며 1에 가까울수록 높은 예측성을 나타낸다. 평균제곱근오차(RMSE)는 진폭과 위상 모두 고려한 절대적인 크기 차이를 측정하는 양으로써 예측스킬 임계값은 $\sqrt{2}$ 이다. 강도(위상) 오차의 경우 양의 값은 관측보다 강하게(빠르게) 모의하고 음의 값은 관측보다 약하게(느리게) 모의함을 의미하며 0에 가까울수록 예측성이 우수함을 뜻한다. BSISO 영향편차장으로부터 재현되는 대류활동 및 원격상관의 공간적인 패턴이 관측에서 나타나는 계절내 변동 패턴을 얼마나 잘 반영하는지 알아보기 위해 두 값 사이의 공간패턴상관계수(Pattern Correlation Coefficient, PCC)를 산정하였고 1에 가까울수록 완벽한 양의 선형관계를 의미한다. 반응강도의 재현성 평가를 위해 관측의 계절내 표준편차에 대한 예측 계절내 표준편차의 비율 값으로 관측에 대한 예측 영향편차장의 상대적인 강도를

산출하였고 1에 가까울수록 관측의 완전한 변동성을 대변한다.

(2) 딥러닝 기술을 활용한 1개월 기온 확률예측 시스템 구축

(가) 기후자료

① ERA5 재분석자료

유럽중기예보센터(ECMWF, the European Centre for Medium-range Weather Forecasts)는 기존 ERA-Interim reanalysis 자료를 개선한 ERA5 reanalysis 자료를 $0.25^\circ \times 0.25^\circ$ 격자자료로 제공한다. 본 연구에서는 수집한 T2M, Z500, PREC, MSLP, TMIN, TAMX, SP, Q850, SST, V850, U850, V200, U200, OLR 자료 중에서 T2M(2 meter temperature) 자료를 이용하였다(Table 6). 자료는 6시간 단위의 자료를 일 단위자료로 변환하여 사용하였다.

Table 6. Summary of ECMWF ERA5 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 기후 평년자료

기후평년자료는 10년 단위 과거 30년 기간의 기상자료를 1월1일부터 12월 31일(윤달포함)까지 일자별로 위경도 격자별로 평균값을 계산한 자료이다. 신(新) 기후평년값은 1991년부터 2020년까지 총 30년 기간의 자료로 생산된 자료이다. 본 연구에서는 기후

평년자료를 과거 30년이 아니라 과거 15년을 기준으로 생산된 자료를 이용한다.

$$Climatology_{day, lat_i, lon_j} = \frac{\sum_{p=1}^n d_{day, lat_i, lon_j}}{n} \quad [3]$$

여기서, day 는 일자, lat_i 은 i 번째 위도, lon_j 는 j 번째 경도, d_{day, lat_i, lon_j} 은 i 번째 위도와 j 번째 경도의 총 기간 중 p 번째 day 날짜의 자료, n_{day} 는 입력자료 기준으로 과거 15년 기간의 day 날짜의 총 데이터 수이다. 2월 29일은 윤달이 포함된 해의 수에 따라 데이터 수는 달라진다.

(나) 1개월 기온 확률예측을 위한 딥러닝 모델 설계

① APEC기후센터의 1개월 기온전망 현업 운영 분석 및 모델 설계 방향

APEC 기후센터는 매주 1개월 기온예측을 위해 세계 여러 기관에서 수집한 기후자료를 이용하여 매주 기온예측에 활용하고 있다. 1개월 기온예측은 예보자료를 생산하는 주를 +1주로 하여 +3주에서 +6주 사이를 말하며, +3주는 예보 1주차에 해당한다. 예를 들어, ECMWF 예보자료가 2021년 08월 2일에 생산되었으면 예보 1주는 2주 뒤인 8월 16일이 된다 (Figure 2).

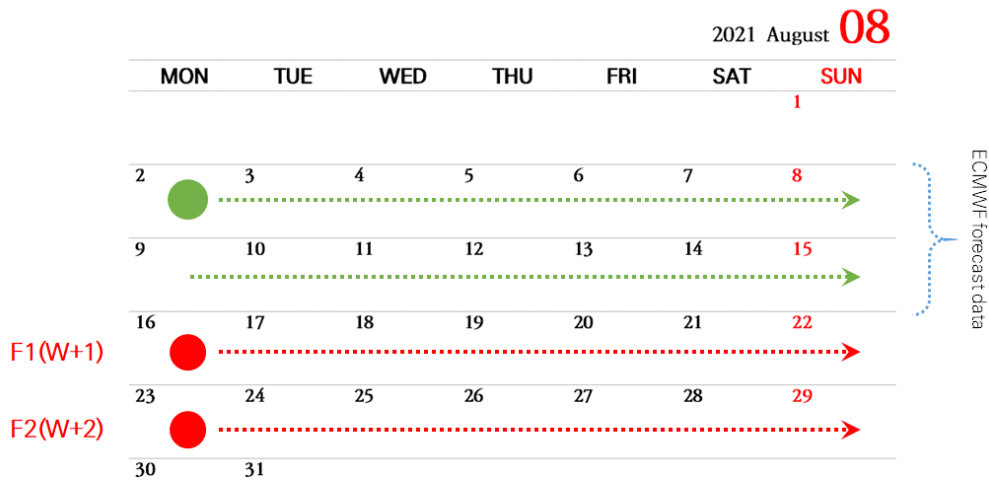


Figure 2. Example of a one-month forecasting schedule operated by the APEC Climate Center

1개월 기온예측 모델은 예보주를 기준으로 +3주~+6주 기간을 예측해야 한다. 일 단위 기준으로는 15일 이후부터 42일 사이에 해당한다. 딥러닝기법 기반 1개월 기온예측 모델을 설계하려면 42일을 예측해야하며 예측성이 낮은 +5주와 +6주를 제외한 +3주와 +4주를 예측하더라도 28일의 예측이 필요하다. Weyn et al. (2019)는 6시간 단위 데이터를 이용하여

최대 14일까지의 예측 가능성을 보였다. 본 선행연구를 토대로 최대 14일까지 예측하는 모델을 설계하고자 한다. 그러나 14일은 예보주 기준으로 +1주와 +2주에 해당하므로 실제 1개월 기간에 해당하는 +3주와 +4주는 예측하기 어렵다. 그래서 본 연구에서는 ECMWF 예측자료의 +1주와 +2주 자료를 입력자료로 활용하여 +3주와 +4주를 예측하는 방법을 선택하고 ECMWF의 +3주와 +4주의 예측성과 비교하고자 한다.

딥러닝 모델을 이용하여 14일 예측하는 방법에는 직접예측(direction prediction), 순환예측(rolling prediction) 등의 방법이 있다. 직접예측은 모델이 예측에 필요한 전체기간을 한 번에 수행하는 것이며, 순환예측은 예측값을 입력값으로 재사용하며 전체기간을 예측하는 것을 말한다. 직접예측은 필요한 예측기간만큼 한 번에 예측하여 예측오류가 누적되는 것을 방지할 수 있다. 그러나 2차원 예측에 사용하는 딥러닝 모델은 예측기간이 길어짐에 따라 시계열 자료의 시그널이 사라지는 문제가 있다. 순환예측은 예측오류가 누적되기는 하지만 직접예측모델에 비해 모델 설계가 쉽고 저사양의 하드웨어로도 학습이 용이한 장점이 있다. 또한, 예측값을 재사용하는 과정에서 별도의 추가 데이터를 입력자료로 활용할 수 있는 장점도 있다. 본 연구에서는 순환예측방법을 적용하였다(Figure 3).




Figure 3. Example of rolling prediction method for predicting 14 days

② 1개월 기온예측을 위한 딥러닝 모델 설계

본 연구에서는 2021년에 테스트한 모델 중 가장 예측성이 높았던 BCDU-Net-Depth3 + SE(Squeeze and excitation) blocks(이하 2021년 모델) 모델을 기초로 새로운 모델을 개발하였다. 2021년 모델은 Azad et al.(2019)가 제안한 모델을 기반으로 U-Net 모델의 단점인 시그널이 사라지는 현상을 개선하기 위해 실험년(1991-2020) 기준 기후평년값을 추가 입력자료로 사용하였다(Figure 4).

본 연구에서 설계한 모델은 2021년도 모델과 동일하게 일단위 입력자료의 길이는 14일, 출력자료의 길이는 1일로 설계하였다(Figure 5). 입력자료의 단위는 일단위이다. Contracting path 구간에서는 기존 Conv2D + Conv2D + BN(batch normalization) + activation으로 구성된

것을 Conv2D + Conv2D + 어텐션 블록(attention block)으로 설계하였다. 어텐션 블록은 Hu et al.(2018)이 제안한 squeeze-and-excitation networks(이하 SEblock)을 이용하였다. SEblock은 채널 어텐션 메카니즘(channel attention mechanism)을 바탕으로 설계되었으며, 채널 단위로 가중치를 부여하고 의미 있는 채널의 정보를 다음 네트워크로 넘길 수 있는 장점이 있다. Expanding path 구간은 기존 모델과 동일하게 Conv2D + Conv2D + SEblock으로 구성하였으며, Prediction 구간은 이전 모델에서는 레이어 1에서 별도의 학습 과정 없이 contractin path 구간의 레이어 1에서 넘어온 자료를 input 2 자료와 병합하여 바로 사용하였으나, 개선된 모델에서는 바로 사용하지 않고 Conv2D + Conv2D + SEblock을 두 번 거친 후에 prediction 단계로 넘어가도록 설계하였다. Prediction 단계에서는 input 2자료와 expanding path 구간을 통과한 데이터를 병합하고 Conv2D + Conv2D + SEblock + Conv2D + Conv2D 과정을 거친 후에 최종 예측하도록 하였다.

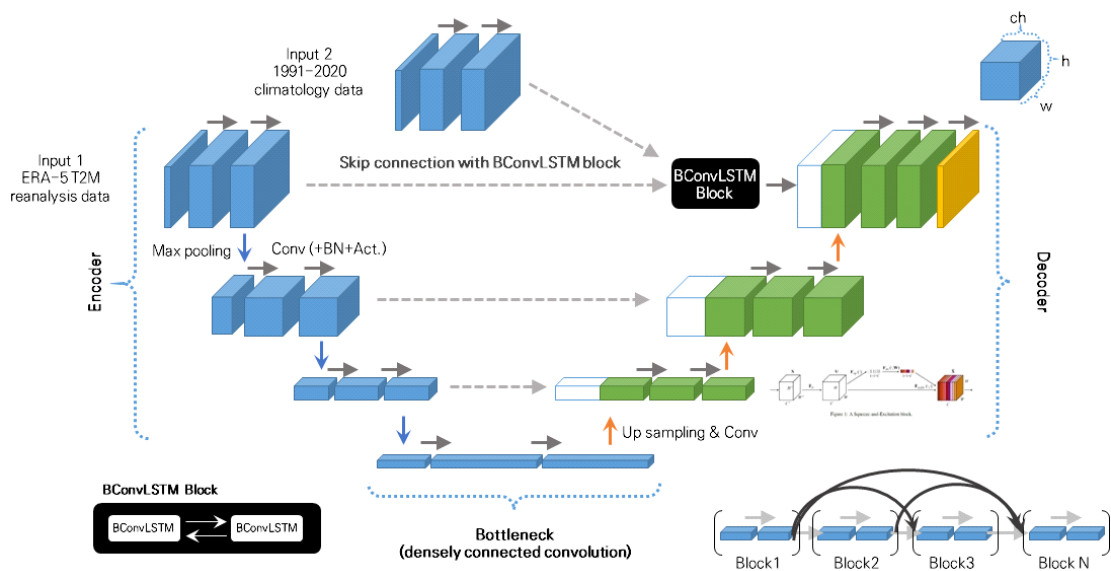


Figure 4. Design of the developed model in 2021

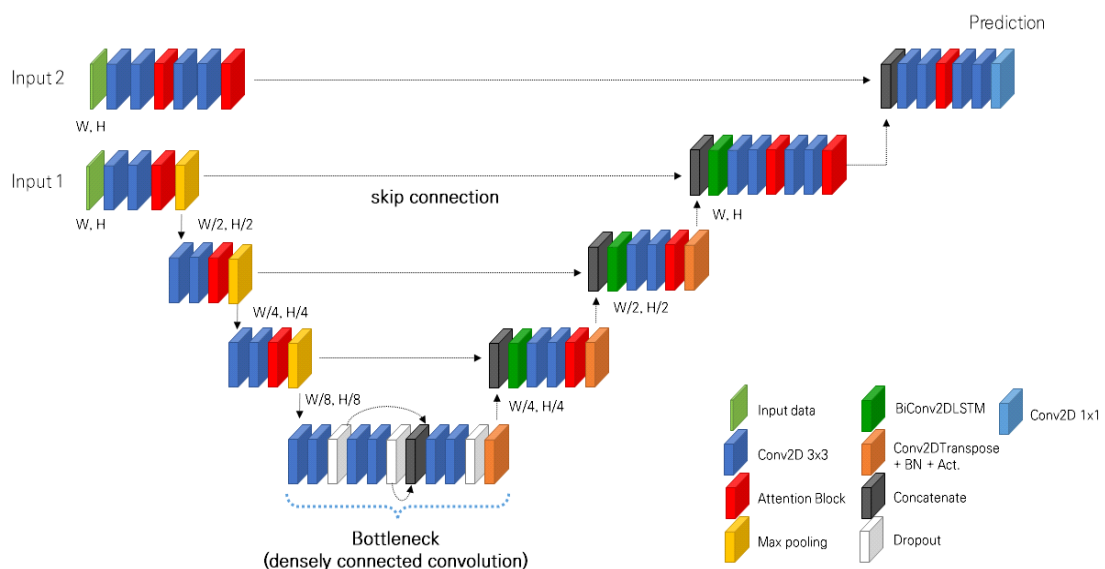


Figure 5. Design of new model

③ 1개월 기온 확률예측을 위한 앙상블자료 생산 방법 설계

확률예측은 예측 시나리오별로 예측자료가 생산되어야 가능하다. 일반적인 딥러닝 모델은 과거 데이터로 학습한 정보를 토대로 단일 시나리오로 예측하기 때문에 이러한 시나리오별 예측이 어렵다. 그러므로 본 연구에서는 ECMWF 앙상블 예보자료 +1주와 +2주 자료를 이용하여 +3주와 +4주의 기온확률예측을 하고자 한다. ECMWF 예보자료는 CF(control file) 1개, PF(perturbed forecast) 50개 자료 등 총 51개 앙상블 자료로 구성되며, hindcast 자료는 CF 1개, PF 10개 자료 등 총 11개 앙상블 자료로 구성된다. 앞서 설계된 딥러닝 모델을 이용하여 예보자료와 hindcast 자료 모두 +1~2주 데이터를 이용하여 +3~4주를 예측한다(Figure 6)

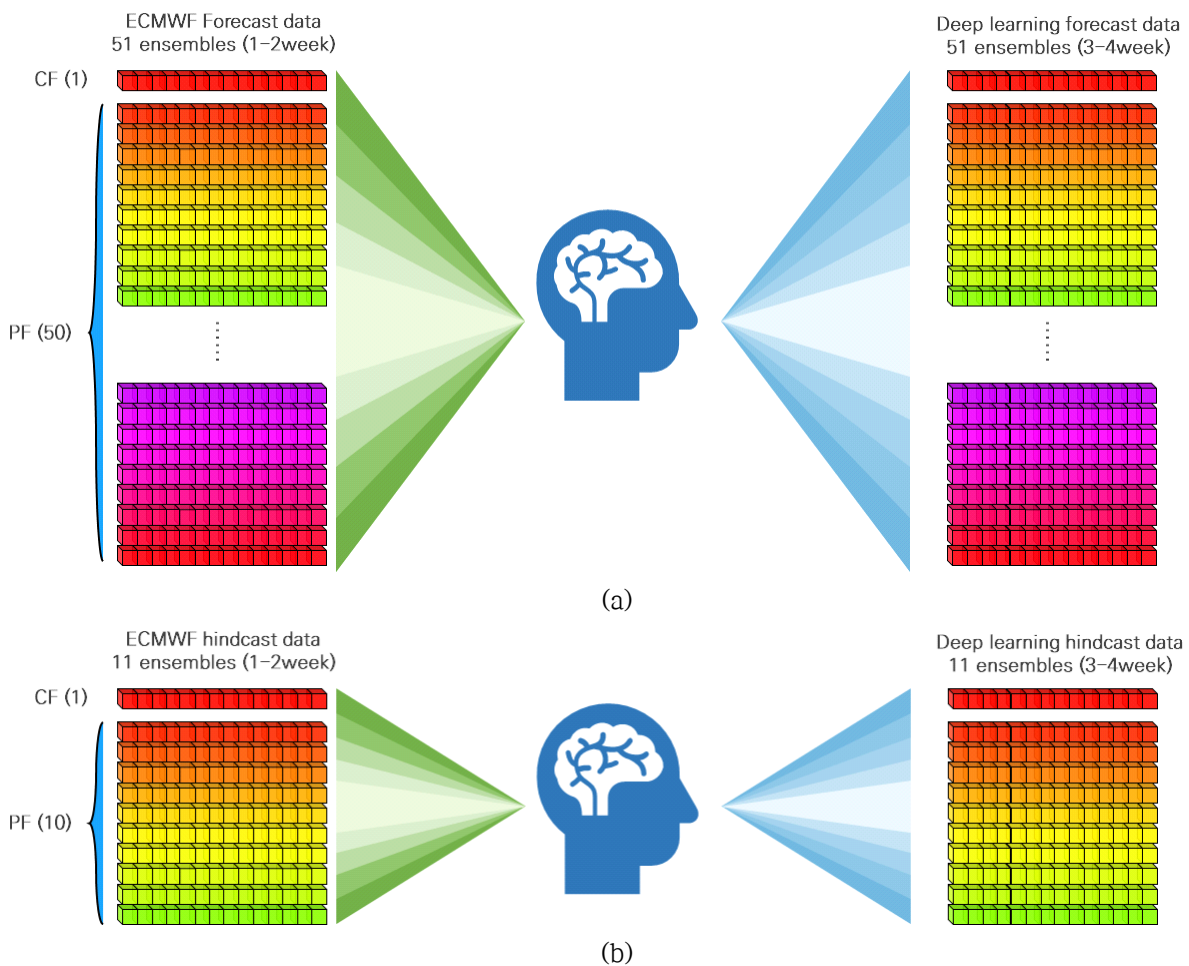


Figure 6. Production of deep learning +3~4 week forecast data using ECMWF +1~2week forecast data: (a) forecast data, (b) hindcast data

(다) 1개월 기온확률예측 및 평가방법

① 1개월 기온확률예측 방법

1개월 기온 확률예측은 예측값을 hindcast 자료의 기후평년값과 비교하여 AN(above normal), NN(near normal), BN(below normal)으로 3분위 예측 후 3분위 각 예측 수에 전체 앙상블 자료수를 나누어 각 3분위의 확률값을 활용한다. 딥러닝 hindcast 예측자료를 이용하여 격자별로 AN, BN 임계값을 계산한다. 이때, 임계값은 격자별 평균과 분산을 이용하여 CDF (cumulative normal distribution) 기법으로 계산한다.

계산된 hindcast AN, BN은 eq. 4와 5를 이용하여 격자별로 확률예측을 한다.

$$\begin{aligned}
 BN_{DL_{ens,i,j}} &= \begin{cases} 1, & \text{if } DL_{forecast} < DL_{hindcast\ climate\ BN} \\ 0, & \text{otherwise} \end{cases} \\
 AN_{DL_{ens,i,j}} &= \begin{cases} 1, & \text{if } DL_{forecast} > DL_{hindcast\ climate\ AN} \\ 0, & \text{otherwise} \end{cases} \\
 BN_{DL_{ens,i,j}} &= \begin{cases} 1, & \text{if } DL_{forecast} \geq DL_{hindcast\ climate\ BN} \\ & \text{and } DL_{forecast} \leq DL_{hindcast\ climate\ AN} \\ 0, & \text{otherwise} \end{cases} \quad [4]
 \end{aligned}$$

$$\begin{aligned}
 ANProb. &= \frac{\sum_{ens=1}^{ensemble\ count} AN_{DL_{ens,i,j}}}{ensemble\ count}, \quad NNProb. = \frac{\sum_{ens=1}^{ensemble\ count} NN_{DL_{ens,i,j}}}{ensemble\ count} \\
 BNProb. &= \frac{\sum_{ens=1}^{ensemble\ count} BN_{DL_{ens,i,j}}}{ensemble\ count} \quad [5]
 \end{aligned}$$

② 동아시아지역 1개월 확률예측 평가방법

동아시아 1개월 확률예측의 평가방법으로 각 격자별로 ROC (receiver operating characteristic) curve를 계산하고 비교 평가하였다(Figure 7과 8). ROC 평가에서는 curve 아래의 면적을 AUC (area under the curve)라고 하며 레퍼런스 라인은 0.5이다. 레퍼런스 라인을 넘어가면 예측성이 높고, 아래로 내려가면 예측성이 낮다고 평가할 수 있다. 본 연구에서는 0~1 사이를 0.1 간격으로 나누어 계산하고 합산하여 AUC를 계산하였다.

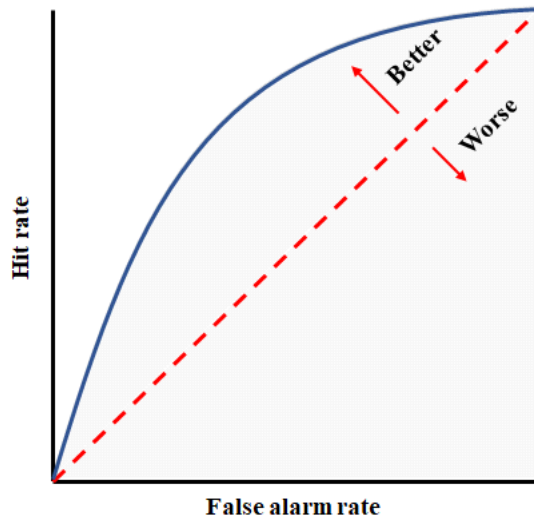


Figure 7. ROC curve

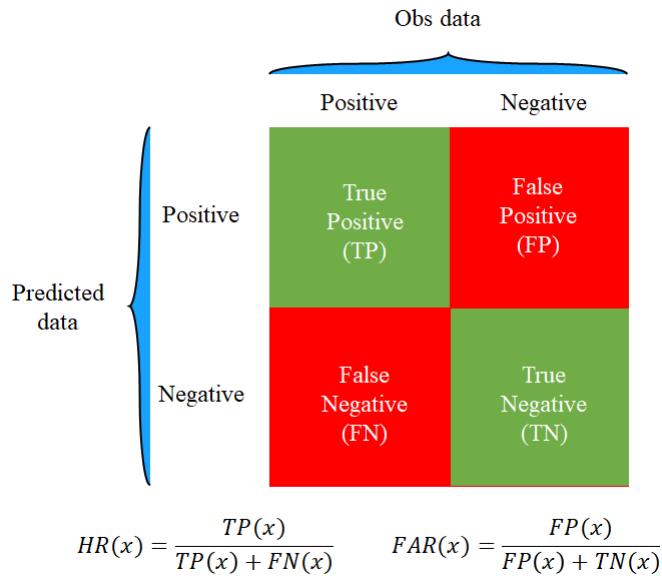


Figure 8. Calculation of HR and FAR

③ 남한지역 1개월 확률예측 평가방법

남한지역의 1개월 확률예측은 남한지역 5개 격자의 평균값을 이용하여 HSS (heidke skill score) 분석을 통해 ASOS 데이터를 기준자료로 활용하여 예측성을 평가하였다(Figure 9). 3분위 예측의 HSS 계산 방법은 Figure 10과 Eq. 6과 같다. HSS 값은 $-\infty < HSS \leq 1$ 범위이며, 0이면 랜덤모형과 같이 예측 스킬이 없음을 의미한다.




Figure 9. Design of the developed model in 2021

Forecast	Observation			
	AN	NN	BN	
AN	<i>a</i>	<i>b</i>	<i>c</i>	<i>A</i>
BN	<i>d</i>	<i>e</i>	<i>f</i>	<i>B</i>
NN	<i>g</i>	<i>h</i>	<i>i</i>	<i>C</i>
	<i>D</i>	<i>E</i>	<i>F</i>	

Figure 10. Summary of probability forecast results of observation and forecast, and formulas for HSS.

$$hit = a + e + i, \quad n = a + b + c + d + e + f + g + h + i$$

$$hitrate = \frac{hit}{n}, \quad ref = \frac{A \times B + (B \times E) + (C \times F)}{n^2}$$

$$HSS = (hitrate - ref) / (1 - ref) \quad [6]$$

다. 국내 장기예보 전망 생산 지원

(1) 1개월 장기예보 시스템 운영/개선 및 신규 콘텐츠 개발

(가) 1개월 전망 예측시스템 운영

기상청은 매주 목요일 오전에 향후 3주에서 6주 사이의 우리나라 기온과 강수량에 대한 1개월 전망을 발표한다. APCC는 이 기상청의 1개월 전망 지원을 위해 2017년 8월부터 1개월 전망 예측시스템을 운영하며, 내부 예보토의를 통해 APCC의 1개월 예측결과를 생산하고 있다. 이때 1개월 전망 예측시스템은 WMO 장기예보 선도센터의 계절내 예측 모델의 자료를 공유하지만, WMO 장기예보 선도센터 계절내 예측시스템과는 별도로 운영하고 있다. APCC 1개월 전망 예측시스템은 우리나라 기온과 강수량 예측에 맞춘 예측방법을 사용하고 예측결과를 표출하고 있다.

APCC에서는 아래 Figure 11과 같은 현업 일정에 따라 매주 1개월 예측정보를 생산하고 있다. 먼저 매주 금요일과 일요일에 WMO 장기예보 선도센터 계절내 예측시스템 현업 스케줄에 따라 계절내 예측모델의 forecast 자료를 수신하고, hindcast 자료 등은 자료가 업로드되는 시점에 맞춰 수시로 수신하고 있다. APCC 1개월 전망을 위한 추가적인 자료는 WMO 장기예보 선도센터 계절내 예측시스템과는 별도로 수신하며, 예측 검증을 위한 관측자료와 월요일 초기장의 ECMWF 예측자료 등이 해당한다. 매주 화요일 오후 누락된 자료의 재수신이 완료되면, MME 예측을 수행하고 예측 콘텐츠 이미지 생산 및 예보 발표자료 초안을 만든다. 이후 APCC 1개월 전망 내부토의를 거쳐 APCC의 최종 예보를 확정한다.

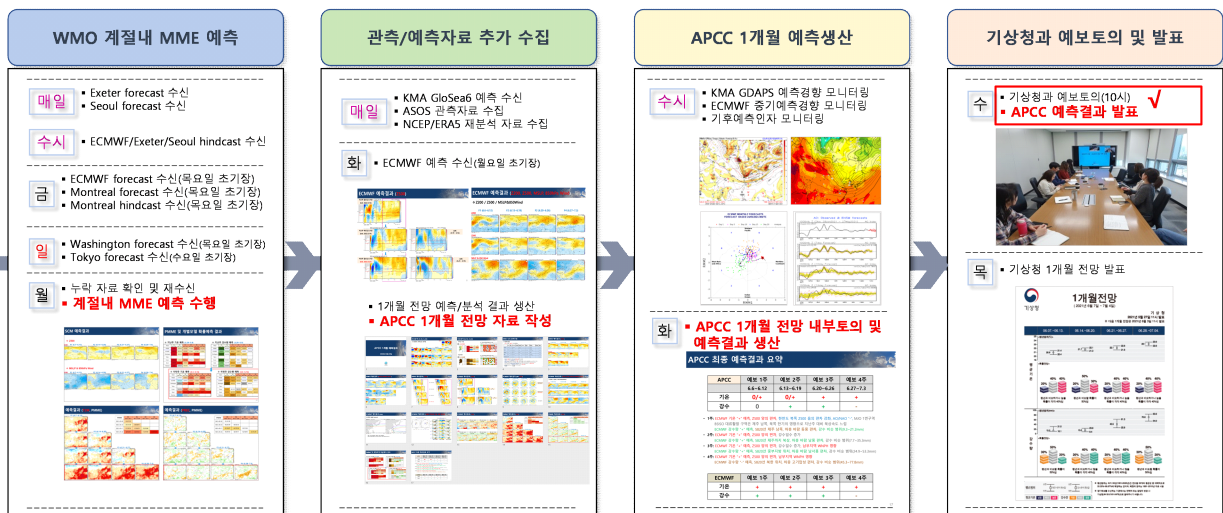


Figure 11. Operation schedule for APCC 1 month forecast.

최종 예보가 포함된 APCC 1개월 전망 발표 자료는 매주 화요일 오후 기상청에 메일로 전달하며, 매주 수요일 오전 10시에 해당 내용으로 기상청 1개월 전망 내부토의 시 발표한다. 발표 자료는 Figure 12와 같이 지난주 예측에 대한 사후분석과 MME 및 개별모델의 예측 결과,

APCC의 최종 예측 등을 포함한다.

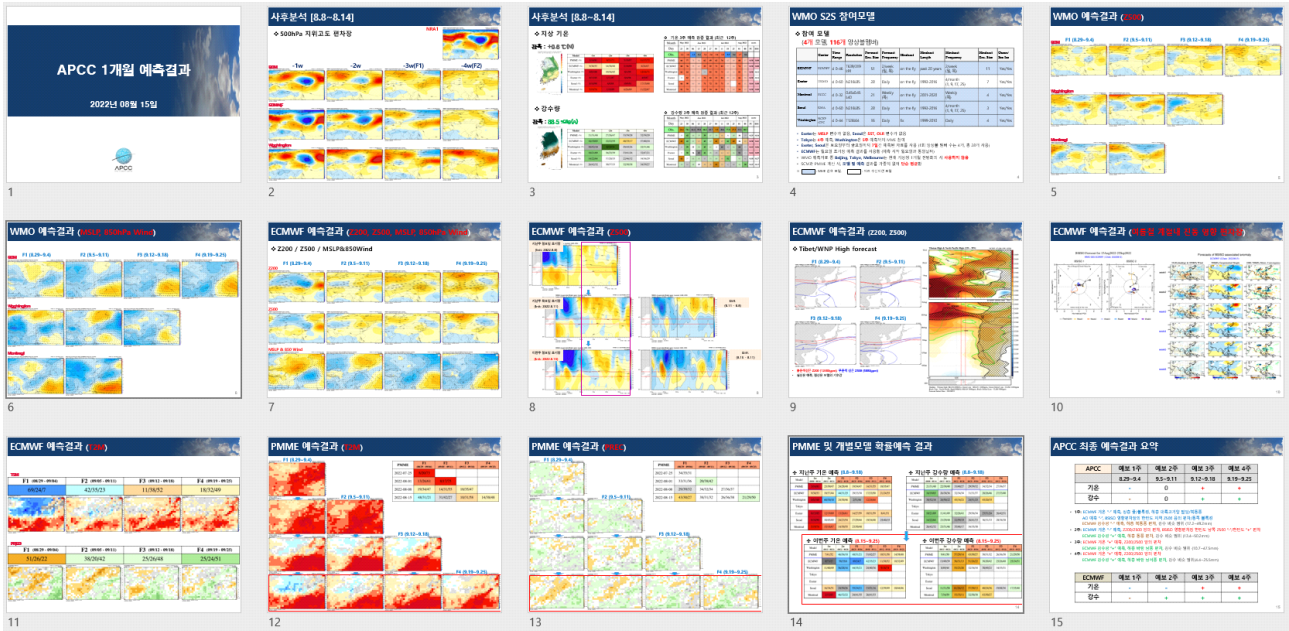


Figure 12. Sample of APCC 1 month forecast charts.

1개월 전망 예측자료 중 예측성이 가장 우수하며, 가장 빠르게 최신의 예측결과를 수집할 수 있는 ECMWF 계절내 예측을 추가적으로 활용하여 APCC 3개월 전망에 지원하고 있다. 이를 통해 역학모델이 예측하는 가장 최근의 결과를 활용할 수 있게 하였다. 단, ECMWF 계절내 예측은 최대 46일이며, APCC 내부 3개월 예보토의는 매일 15일 전후에 진행하므로 예보토의 전 가장 최신의 ECMWF 계절내 예측자료는 11일에서 15일 사이의 초기장을 사용한 결과가 된다.

Figure 13은 ECMWF 계절내 예측결과를 사용하여 다음 달 1일부터 예측 마지막 주까지 평균한 결과를 표출한 자료이며, 동아시아 영역에 대하여 500hPa 지위고도와 해면기압, 850hPa 바람장, 기온 확률 예측, 강수량 확률 예측 분포를 제공한다. 추가적으로 한반도 영역에 해당하는 5개 격자점을 평균한 기온과 강수량의 확률예측 결과값도 동시에 제공한다. 이 자료는 기존의 3개월 전망 예측모델 보다 최근의 기압계 변화 등을 반영한 최신 예측결과이므로 모델 예측결과의 변화 경향을 파악하는데 중요한 참고자료로 활용하고 있다.

ECMWF Sub-Season (init. : 2022-11-14)

ECMWF	12/01 - 12/25
T2M	47/36/17
PREC	39/37/24

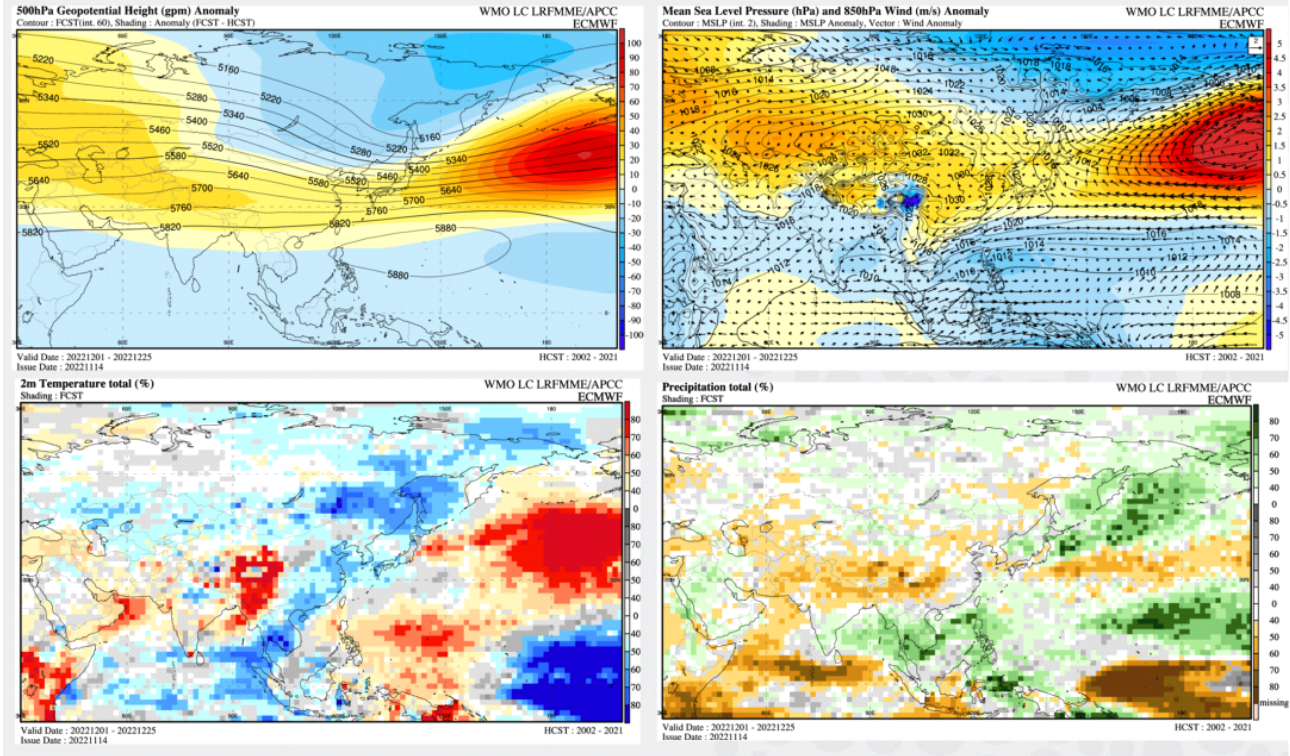


Figure 13. Sample of subseasonal model output for APCC 3-month forecast.

(나) 1개월 전망 예측시스템 개선

계절내 예측자료는 각 개별모델의 특성이 매우 다르며, 서로 다른 방식으로 예측을 수행하고 있다. 또한, 주기적/비주기적으로 모델의 특성을 변경하고 있으므로 이를 반영한 예측시스템의 변경과 개선이 꾸준히 요구되고 있다. 2022년에도 1개월 전망 예측 시스템을 운영하면서 모델의 특성 변화에 대응하고 효율적인 시스템 운영이 가능하도록 예측 시스템 일부를 개선하였다. 먼저 모델의 ECMWF 기후값 계산 방법을 변경하였다. ECMWF 계절내 예측 시 사용하는 hindcast 자료를 기존 대비 3배수로 늘리면서 보다 안정된 기후값을 사용하게 하였고, 이를 통해 예측성 향상을 도모하였다. 그리고 개별모델의 hindcast 기간이 변경된 사항을 시스템에 적용하였으며, 시스템 저장공간 확보를 위해 전처리 과정을 일부 변경하였다.

1개월 전망을 위한 신규 콘텐츠 개발도 꾸준히 진행하였다. 사후분석 결과 표출 이미지를 개선하고, ECMWF 기반의 AO daily 예측정보를 생산하는 시스템 구축하였다. Washington과 Montreal 모델의 예측결과가 활용될 수 있도록 표출 시스템에 추가하고, BSISO와 MJO 지수 예측도 계속해서 수행하였다. 추가로 딥러닝 기반 1개월 기온 확률예보의 현업화를 지원하기 위해 예측자료의 별도 전송 시스템을 구축하였다.

(2) WMO 장기예보 선도센터 계절내 예측 시스템 운영 및 개선

(가) WMO 장기예보 선도센터 계절내 예측 시스템 개발의 개요 및 참여모델 특성

WMO 장기예보 선도센터는 계절 예측 이외에도 계절내 예측에 대한 정보를 제공하기 위한 시범적인 시스템을 구축해서 운영해오고 있다. 2014년에는 계절내 MME 시스템에서 제공할 콘텐츠를 발굴하는 등 사전 조사를 수행하였으며, 2015년에는 3개의 GPC (ECMWF, Tokyo (JMA), Washington (NCEP))의 예측자료를 바탕으로 시험 시스템을 구축하였고, 홈페이지에서는 MME 예측정보만 표출한 바 있다. 2016년에는 MME 뿐만 아니라 각 GPC 별 예측 결과를 함께 표출하여 예측자료 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-OPSL)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 특성 변경에 따른 수정, 활용 가이드 및 웹사이트 안내 페이지 개선, 기후값 계산 방법 변경 등을 작업을 수행하였다. 2018년에는 자료 수신 속도 향상을 위해 프로그램을 개선하였고, 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, 2021년과 2022년에는 참여모델의 개선 사항을 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 활용 방법이 크게 변경되어 WMO 계절내 MME에 포함하지 않기로 하였다.

현재 사용하고 있는 모델의 2022년 12월 기준 특성과 사용이 중단된 모델(Beijing, Melbourne, Tokyo)은 해당 시점의 특성을 아래 Table 7에 간략히 나타내었다. Table 7은 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 portal의 모델 설명 부분에서 (<https://software.ecmwf.int/wiki/display/S2S/Models>) 확인할 수 있다.

Table 7. 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	2001~2020
Seoul (KMA)	daily	0~60 days	4	4/month (1,9,17,25)	3	1993~2016
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

(나) WMO 장기예보 선도센터 계절내 MME 예측 방법

계절내 MME 예측을 수행하기 위해서 각 GPC의 예측자료의 표준화 과정이 필요하다. Table 7에 나타난 바와 같이 각 GPC 별 예측자료는 다양한 예측시간과 해상도, 앙상블 크기, 예측주기 등을 가지고 있기 때문이다. 특히 매주 계절내 MME를 구성하는 각 모델의 예측 시작 시각이 상이하므로 계절내 MME 예측 시작 시점을 정하는 것이 중요하다. WMO 장기예보 선도센터의 계절내 예측 시스템을 처음 구축할 당시에는 MME 참여모델의 선행시간 손실을 최소화하기 위해 MME 예측 시작일을 목요일로 정한 바 있다. 하지만 MME 예측의 시작일을 월요일로 정하는 것이 실제 계절내 예측자료의 활용 면에서 더 필요하다고 판단되어 2016년에 예측 시작 시각을 변경하였다. 따라서 WMO 장기예보 선도센터에서는 계절내 MME 예측을 월요일에 시작하도록 정하였으며 매주 1회 예측을 수행한다. 이러한 계절내 MME 예측을 위해 사용되는 각 GPC 모델의 예측 시작 시각은 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 2주 전의 토요일부터 1주 전 금요일에 예측된 자료를 평균하여 사용한다.

계절내 MME 예측을 수행하면서 또 하나의 중요한 이슈는 hindcast 자료의 선택과 모델의 기후값 계산 방법이다. Table 7에서 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 시작 날짜와 동일한 날짜의 자료가 매주 생산되는 것이 이상적이다. 하지만 일부 GPC (Exeter, Seoul)의 경우 매달 고정된 특정 날짜를 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 시작 날짜와 동일한 날짜의 hindcast 자료가 선택되며, 그 외 Exeter와 Seoul의 경우 forecast 시작 날짜와 가장 가까운 날짜의 hindcast 자료가 선택된다. Exeter와 Seoul 예측자료와 같이 7일간의 예측결과를 합쳐서 사용하는 경우 hindcast 자료의 선택 기준은 가장 마지막 날짜(1주 전 금요일)의 forecast 예측 시작 날짜로 정하였다. 또한, 기후값 계산 기간은 전체 GPC에서 공통으로 제공되는 2000년부터 2010년까지 11년(2020년 이전의 예측자료는 1999년부터 2010년까지 12년)의 자료를 사용한다. Table 8은 계절내 MME 예측을 수행하면서 forecast와 hindcast 자료의 선택과 관련한 앞서 설명한 내용을 정리한 것이다.

Table 8. 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 7에서 보인 바와 같이 각 GPC 모델별로 MME 예측에 사용할 수 있는 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 구축하였다. 그 결과 2019년 11월 이전에는 4주

예측에서는 8개 GPC의 예측결과를 모두 사용하지만 6주 예측에서는 Table 9와 같이 5개만을 사용한다. 2020년 10월 이후로는 Table 10과 같이 3개의 모델이 추가로 줄어들어 4주 예측에 5개 모델만 참여하게 되었다.

Table 9. 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 10. 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. [7], Eq. [8]과 같이 각 GPC의 예측결과에 대한 간단한 산술평균 방식이지만 각 모델이 가지고 있는 계통적 오차를 효과적으로 줄여 예측성을 높이는 방법이다(Krishnamurti et al., 2000).

$$A_i = \frac{1}{M_i} \sum_{m=1}^{M_i} (F_m - \bar{F}_i) \quad [7]$$

$$SCM = \frac{1}{N} \sum_{i=1}^N (A_i) \quad [8]$$

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, \overline{F}_i 는 앞서 설명한 각 GPC의 기후값이다. 이렇게 구해진 SCM 결과값은 WMO 장기예보 선도센터 홈페이지를 통해 이미지화하여 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 삼등분하는 지점을 값으로 한다. 확률밀도함수 fitting 시 T2M은 normal distribution을 따르고, PREC는 gamma distribution을 따르는 것으로 가정하였다. 이렇게 구해진 삼분위 지점 값을 기준으로 각 GPC의 forecast 결과가 각 category에 얼마나 포함되는지 확률을 계산하여 개별모델의 확률 예측값이 생산된다. PMME는 Eq [9]와 같이 개별모델의 확률의 평균으로 구해지며, 이때 각 모델 간 동일한 가중치를 가진다.

$$P(E_j) = \frac{1}{M} \sum_{i=1}^M (P(E_j/mdl_i)) \quad [9]$$

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.

(다) WMO 장기예보 선도센터 계절내 예측 자료수신 및 웹 표출

2022년 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 11에 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 사후분석 자료로 이용되며, 계절내 MME 예측 연구에도 사용되고 있다.

Figure 14는 현재 WMO 장기예보 선도센터 홈페이지에 제공(WMO 전문가 그룹 일부만 확인 가능)되고 있는 산출물을 정리한 그림이다. 추가로 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 11. Used data list for subseasonal MME prediction system.

Data Name	Variable	Download frequency	Purpose
GPCs Forecast	<ul style="list-style-type: none"> · Sea Surface Temperature · 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 	<ul style="list-style-type: none"> · weekly : ECMWF, Melbourne, Montreal, Tokyo, Washington · daily : Beijing, Exeter, Seoul 	<ul style="list-style-type: none"> · Subseasonal MME prediction
GPCs Hindcast	<ul style="list-style-type: none"> · Sea Surface Temperature · 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 	<ul style="list-style-type: none"> · First one time : Beijing, Tokyo, Melbourne, Washington · weekly : ECMWF, Montreal, · non periodical : Exeter, Seoul 	<ul style="list-style-type: none"> · Anomaly and PDF calculation
ERA-Interim daily	<ul style="list-style-type: none"> · 2 metre Temperature · Total Precipitation 	<ul style="list-style-type: none"> · monthly 	<ul style="list-style-type: none"> · Verification
NCEP Reanalysis 1	<ul style="list-style-type: none"> · 2 metre Temperature · Mean Sea Level Pressure · Geopotential Height at 500hPa · U/V wind component at 850 hPa · U/V wind component at 200 hPa 	<ul style="list-style-type: none"> · weekly 	<ul style="list-style-type: none"> · Verification · ISO monitoring and prediction
NOAA Interpolated OLR	<ul style="list-style-type: none"> · Outgoing Longwave Radiation 	<ul style="list-style-type: none"> · First one time 	<ul style="list-style-type: none"> · Verification · MVEOF mode calculation
NOAA Uninterpolated OLR	<ul style="list-style-type: none"> · Outgoing Longwave Radiation 	<ul style="list-style-type: none"> · weekly 	<ul style="list-style-type: none"> · 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 14. The variables and covering periods of graphical products for subseasonal prediction.

3. 결과

가. 3개월 장기예보 개선

(1) ENSO 및 그와 관련된 계절안 규모의 대기 반응 분석

(가) 모델의 겨울철 열대 평균장 모의 성능

모델에서 ENSO의 영향이 어떻게 모의 되고 있는지를 살펴보기에 앞서 모델의 평균장을 살펴보았다. 여러 선행연구를 통해 대부분의 기후모델은 열대 태평양에서 동태평양의 cold tongue을 너무 차갑게 모의하고 더 서쪽까지 확장해 모의하는 것으로 알려져 있다. 이러한 해수면온도의 바이어스로 인해 모델에서는 무역풍이 중태평양에서 너무 약하고 서태평양에서는 너무 강하게 나타나며, 이는 서태평양 강수 감소와 ITCZ가 적도를 중심으로 대칭적으로 나타나는 double ITCZ 현상과도 관련된 것으로 알려져 있다 (e.g. Guilyardi et al. 2020; Li and Xie 2014). 해수면온도와 강수 평균장의 바이어스는 ENSO 자체의 특징은 물론 ENSO의 원격상관에도 영향을 주기 때문에 이러한 기후모델의 공통적인 바이어스가 계절예측 모델에서도 나타나는지 살펴보았다.

Figure 15는 중~동태평양 적도 지역(5°S~5°N)에서 평균한 해수면온도의 월별 분포를 나타낸다. 검은색으로 나타낸 관측 재분석자료에 비해 모델들은 120°W 동쪽은 관측보다 따뜻하게, 120°W 서쪽은 관측보다 차갑게 모의했으며 12월에 차이가 크게 나타났다. 예측 선행시간이 길어질수록 관측과의 차이는 증가했는데, 모델은 관측보다 해수면온도의 동서 기울기를 완만하게 모의하는 경향을 보여 대륙에 가까운 동태평양 동편은 관측보다 따뜻하고 동태평양 서편 Nino3.4 지역(170~120°W)은 관측보다 차갑게 모의했으며 선행시간이 길어질수록 이러한 경향은 증가했다. 계절예측 모델에서도 기후모델과 동일하게 동태평양을 차갑게 모의하는 경향은 있었지만 대부분 동태평양 적도 좁은 지역에서만 온도가 낮고 적도 남쪽으로는 관측보다 온도를 높게 모의했으며, 늦겨울이 될수록 선행시간이 길어질수록 동태평양 동편 지역을 오히려 관측보다 따뜻하게 모의하는 경향이 증가했다. Figure 16은 Figure 15에서의 모델과 관측의 차이를 RMSE로 나타내었는데, 대체로 1개월 선행에서는 12월의 오차가 큰 경향을 보였고 선행시간이 길어질수록 오차도 커지는 경향을 보였다. 3개월 선행에서는 2월에 오차가 가장 작은 모델들이 많았는데, 이는 2월은 관측에서 해수면온도의 동서 차이가 감소하면서 모델과의 차이가 작아져 오차가 감소하는 경향으로 나타난 것으로 보인다. ECMWF 모델은 가장 작은 RMSE를 보이며 선행시간에 관계없이 모델 중 가장 안정적으로 관측과 유사하게 적도 해수면온도를 모의하는 것으로 나타났다.

Figure 17은 열대 동인도양~동태평양에서 평균한 강수를 나타낸다. 모델은 대부분 관측보다 강수를 많이 모의했으며 특히 서태평양 필리핀 동쪽 지역 강수를 강하게 모의하는 경향을 보였다. 인도양은 남서쪽은 강수 강하게, 동인도양과 maritime continent 지역은 강수 약하게 모의하는 경향을 보여 지역별로 차이가 있었다. Figure 18은 동태평양에서 평균한 강수를 나타내는데, 대부분 모델이 적도 북쪽의 ITCZ를 관측보다 강하게 모의하였다. 모델이 강수를 강하게 모의는 하지만 패턴은 1개월 선행에서는 관측의 분포와 유사한 패턴을 보였다.

그러나 2개월 선행부터는 몇몇 모델에서 적도 남쪽에서도 강수를 강하게 모의하는 double ITCZ가 나타났으며 예측 선행시간이 길어질수록, 12월보다 1월과 2월에 이러한 경향이 더 강하게 나타났다. ECMWF 모델은 다른 모델들과 동일한 바이어스는 있었지만, 해수면온도와 마찬가지로 열대 강수도 선행시간과 관계없이 가장 안정적으로 관측과 유사하게 모의했다.

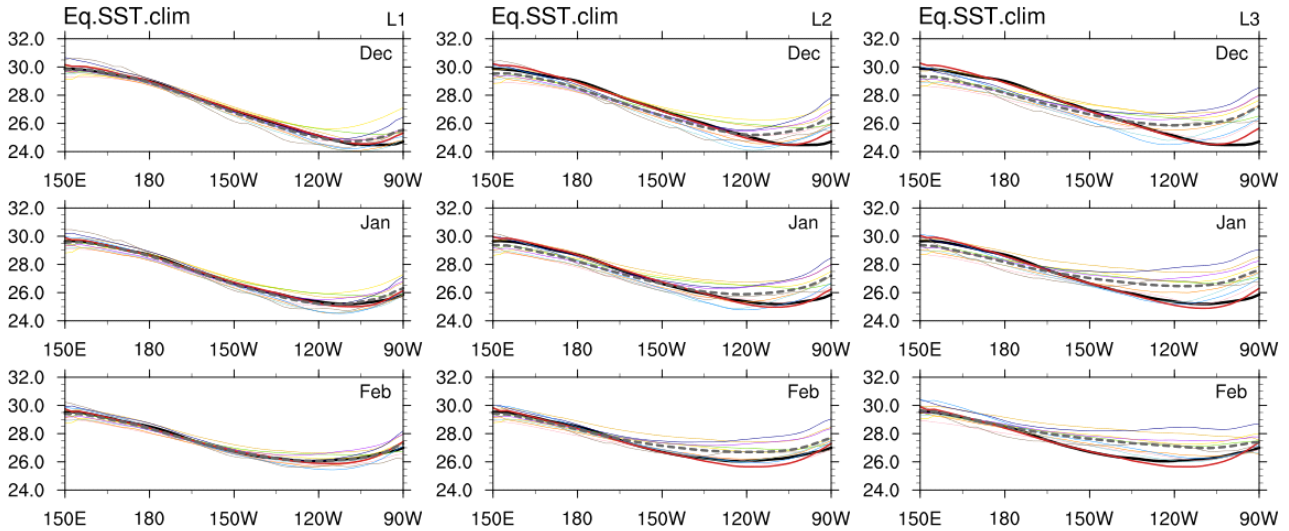


Figure 15. Climatology of the sea surface temperature (SST) in the equatorial (5°S - 5°N averaged) Pacific. Black and color solid curves show the observation and individual model. Gray dashed curve show the MME. L1, L2, and L3 indicate 1-month, 2-month, and 3-month lead.

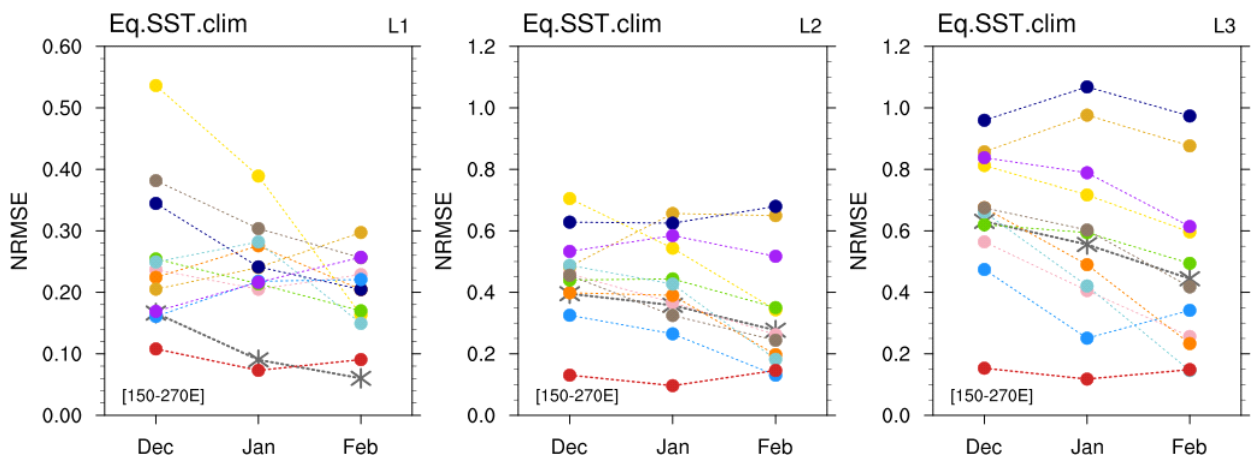


Figure 16. Normalized root mean square error (NRMSE) between observation and model curves in the climatology of the equatorial (5°S - 5°N averaged) eastern Pacific ($150\sim 270^{\circ}\text{E}$) SST.

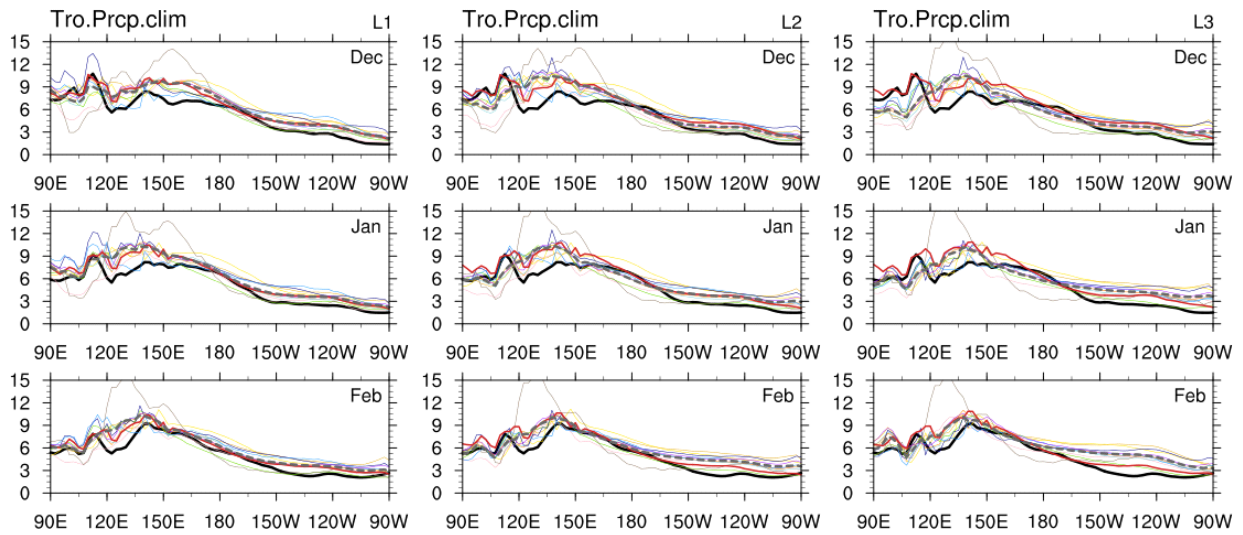


Figure 17. Climatology of the precipitation in the tropical (10°S - 10°N averaged) Pacific. Black and color solid curves show the observation and individual model. Gray dashed curve show the MME.

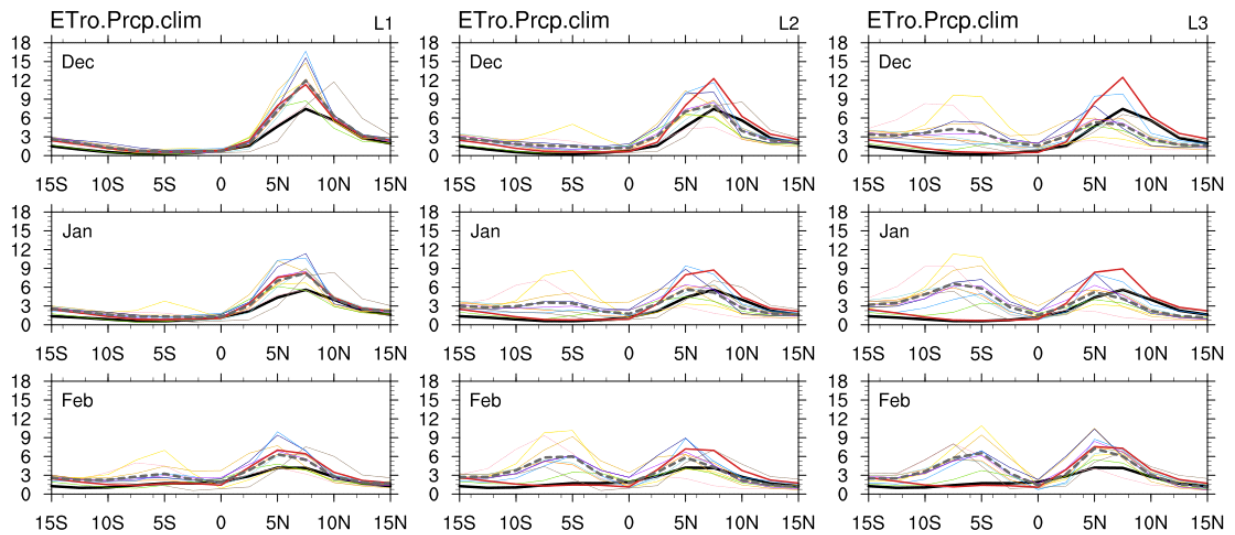


Figure 18. Climatology of the precipitation in the eastern (150°W - 90°W averaged) tropical Pacific. Black and color solid curves show the observation and individual model. Gray dashed curve show the MME.

(나) 모델의 겨울철 ENSO 모의 성능

겨울철 개별모델들의 ENSO 모의 성능을 살펴보기 위해 ENSO 지수인 Nino3.4 지수의 관측과의 상관계수와 RMSE를 살펴보았다 (Figure 19). 상관계수는 2월 KMA 한 개 모델을 제외한 모든 모델에서 12월, 1월, 2월 모두 0.9 이상의 매우 높은 양의 상관계수를 보여 관측의 변동성을 매우 잘 따라갔다. 2개월과 3개월 선행예측에서도 상관계수 0.8 이상으로 높은 양의 상관을 나타냈고 RMSE도 크게 증가하지 않았다. Nino3.4 지수로만 판단했을 때 모델들의 겨울철 ENSO 예측성은 높게 평가할 수 있겠다.

Figure 20은 Nino3.4 지수에 회귀분석한 적도 해수면온도 편차로 ENSO와 관련된 열대 해수면온도 반응을 나타낸다. 대부분 모델에서 동태평양 해수면온도 반응을 관측보다 높게 모의했으며 2월에 이러한 경향이 더 강하게 나타났다. 모델은 서태평양 해수면온도는 관측보다 높게 중태평양은 관측보다 다소 낮게 모의하는 경향을 보였으며 예측 선행시간이 길어질수록 이러한 경향은 강해지고 모델간의 차이도 증가했다. 모델의 양의 해수면온도 반응은 관측보다 더 서쪽까지 확장되어 나타나며 적도에서 더 강하게 반응이 나타났는데 이는 많은 기후모델에서 나타나는 특징과 유사했다 (e.g. Ham and Kug 2015). Figure 21은 Figure 20에서 나타낸 적도 해수면온도 반응의 관측과 모델의 RMSE를 나타낸다. 오차는 1월에 작고 2월에 가장 크게 나타났는데 선행시간이 길어질수록 대부분의 모델에서 이러한 경향이 더 잘 나타났다. 1월에 오차가 가장 작고 2월에 오차가 크게 나타난 이유로 관측에서는 초겨울에서 늦겨울로 가면서 서-중태평양 해수면온도는 점차 증가하고 동태평양 해수면온도는 감소하는 월별 변화가 있으나 모델은 이러한 변화를 잘 모의하지 못하고 겨울철 내내 해수면온도 반응이 크게 달라지지 않기 때문으로 보인다. 1개월 선행예측에서 1월보다 2월에 오차가 감소한 모델에서는 2월 동태평양 해수면온도가 1월보다 감소해 관측의 월별 변화를 잘 모의하였다.

Figure 22는 겨울철 엘니뇨 해와 라니냐 해 Nino3.4 지수 합성장을 나타낸다. 검정 실선으로 나타낸 관측지수와 비교해 엘니뇨 해 11월과 12월은 모델 평균이 관측과 유사한 것을 볼 수 있고 1월과 2월은 모델들이 관측보다 강하게 모의하는 것을 볼 수 있다. 라니냐 해는 12-1-2월 평균적으로 모델이 관측보다 음의 지수를 강하게 모의하는 특징을 보였다. 또한 관측에서는 12월에 최대에 도달한 후 1월부터 해수면온도가 감소하는 반면 모델은 1월까지 세기가 유지되다 2월에 감소하는 차이를 보였다. KMA 모델은 2월 Nino3.4 지수의 관측과의 상관계수가 다른 모델에 비해 낮았는데 2월에 해수면온도 강도가 급격히 약화 되면서 관측과의 차이가 증가했기 때문으로 보인다.

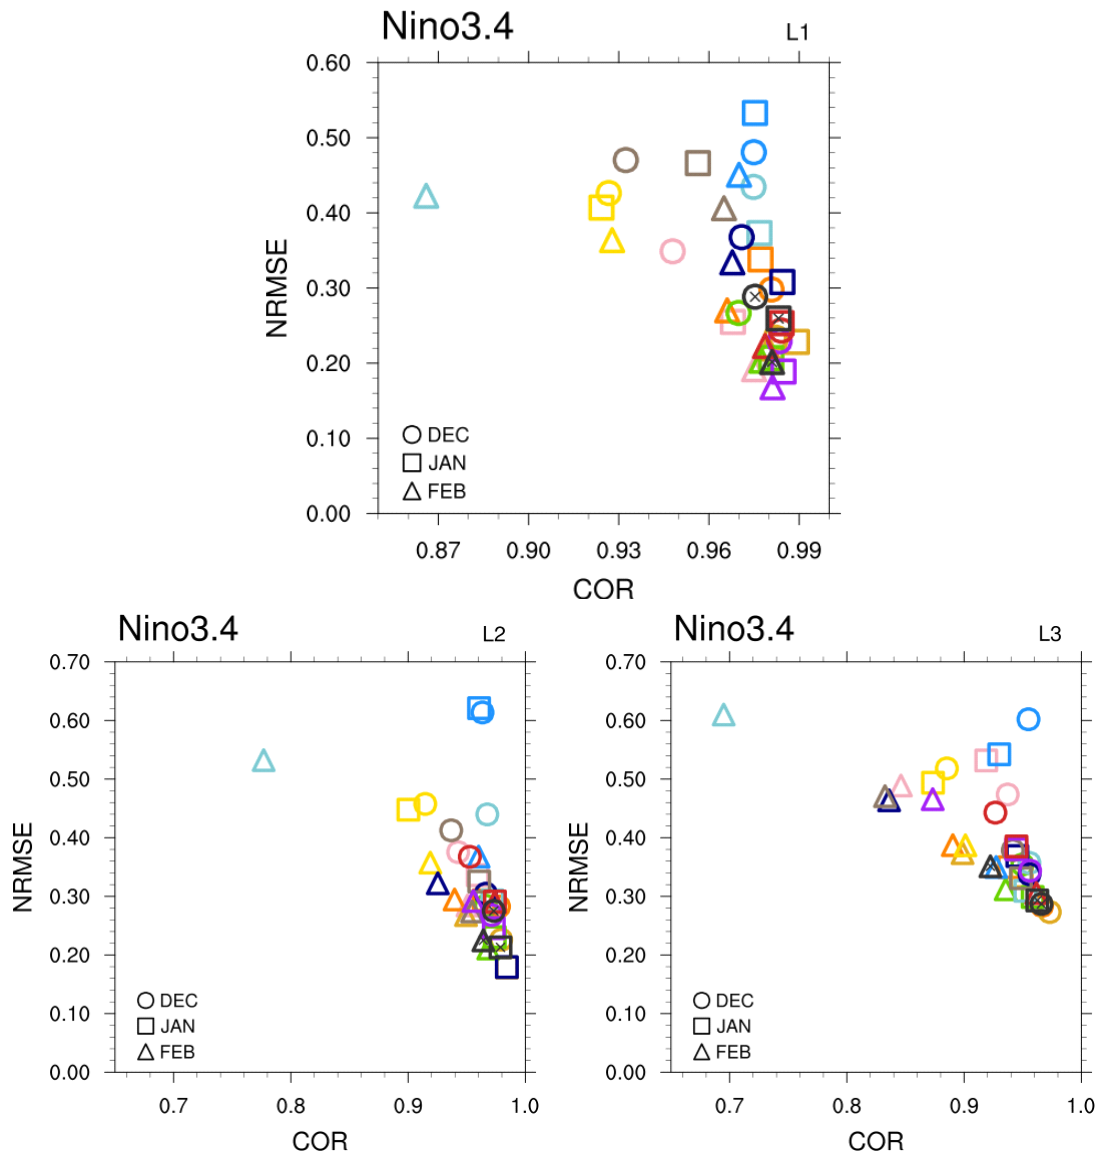


Figure 19. Scatter plots between the temporal correlation coefficient and normalized root mean square error (NRMSE) of the Nino3.4 index.

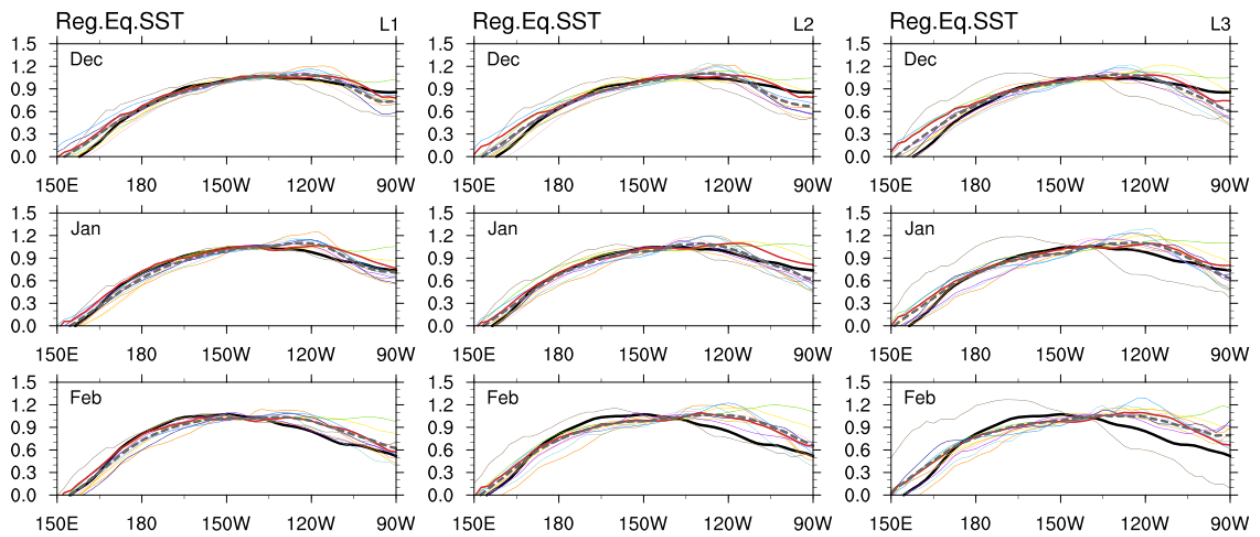


Figure 20. Regressed equatorial ($5^{\circ}\text{S}\text{--}5^{\circ}\text{N}$ averaged) SST anomalies onto Niño3.4 index. Black and color solid curves show the observation and individual model. Gray dashed curve show the MME.

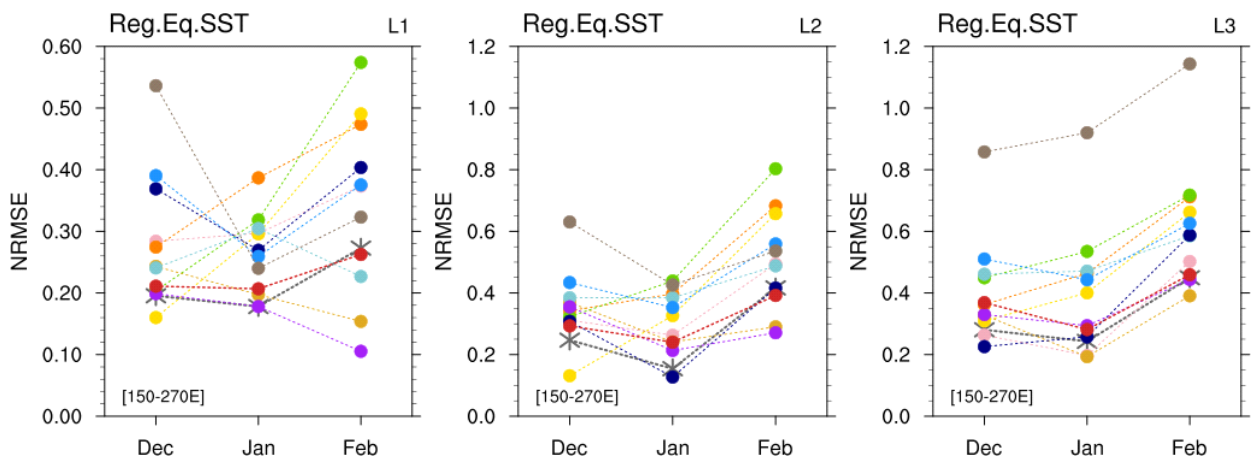


Figure 21. Normalizes root mean square error (NRMSE) between observation and model curves in the regressed equatorial ($5^{\circ}\text{S}\text{--}5^{\circ}\text{N}$ averaged) SST anomalies onto Niño3.4 index over the eastern Pacific ($150\text{--}270^{\circ}\text{E}$).

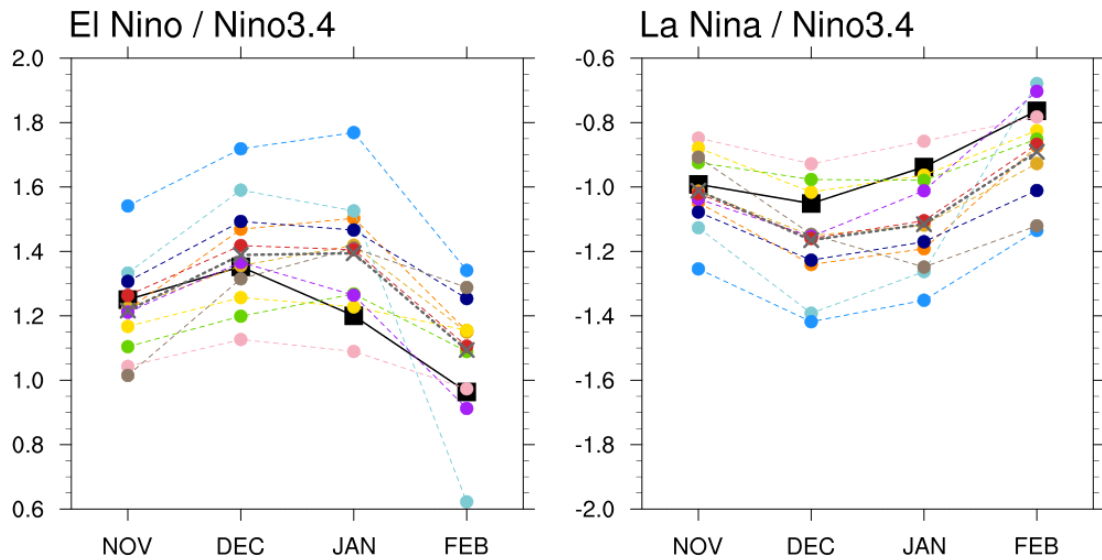


Figure 22. Composites of the Nino3.4 index for the El Niño and La Niña years. Black solid line and gray dashed line show the observation and MME respectively.

Figure 23은 Nino3.4 지수에 회귀분석한 열대 태평양 지역 강수 편차로 ENSO와 관련된 열대 강수 반응을 나타낸다. 모델 강수 반응은 동태평양에서 관측보다 다소 약하게, 중태평양 180°E 서쪽은 강하게 모의하는 경향이 있으며 최대강수의 중심이 관측보다 서쪽에서 나타나는 특징을 보였다. 모델 강수 중심의 서쪽 편향은 해수면온도 중심이 관측보다 서쪽까지 확장되어 나타난 것과 관련되어 있다. 서태평양 음의 강수는 12월에 관측보다 약했고 1월은 관측과 유사했으나 2월에는 다시 관측보다 약해지는 반응을 보였다. 관측에서는 12월에서 1월이 되면서 서태평양 강수 반응이 감소하고 2월에 다시 증가하는 변화가 나타나지만, 모델에서는 이러한 강수의 월별 변화를 제대로 모의하지 못했다. Figure 24는 열대 지역 강수 반응의 RMSE를 나타내는데 모델 대부분이 2월에 오차가 증가하는 특징을 공통으로 보였고 선행시간이 길어질수록 RMSE가 다소 증가하였으나 크게 증가하지는 않았다. ECMWF 모델은 2개월과 3개월 선행예측에서 가장 작은 오차를 보였고 PNU 모델은 중태평양 강수 반응을 과하게 모의하며 오차가 가장 크게 나타났다.

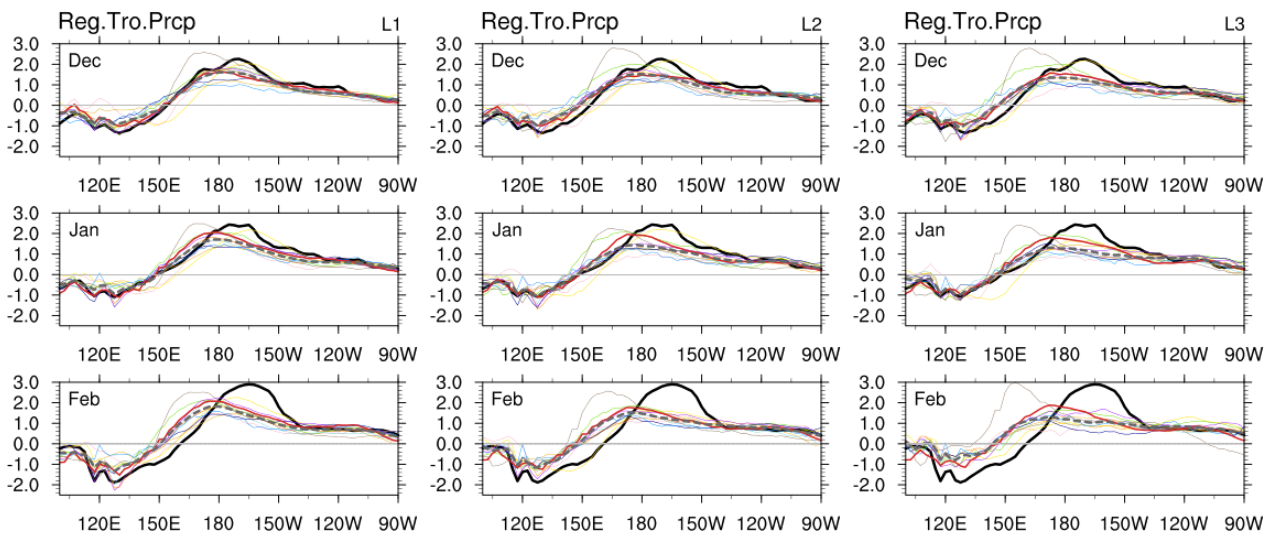


Figure 23. Regressed tropical ($10^{\circ}\text{S}\sim 10^{\circ}\text{N}$ averaged) precipitation anomalies onto Niño3.4 index. Black and color solid curves show the observation and individual model. Gray dashed curve show the MME.




Figure 24. Normalized root mean square error (NRMSE) between observation and model curves in the regressed precipitation anomalies onto Niño3.4 index over the tropical Pacific ($100\sim 270^{\circ}\text{E}$, $10^{\circ}\text{S}\sim 10^{\circ}\text{N}$).

(다) 모델의 겨울철 ENSO와 관련된 대기 반응 분석

겨울철 개별모델들의 ENSO와 관련된 원격상관 모의 성능을 살펴보았다. Figure 25~27은 Nino3.4 지수에 회귀분석한 500hPa 지위고도와 해면기압 편차로 ENSO와 관련된 대기 반응을 나타낸다. 관측에서는 ENSO에 대한 반응으로 12월 500hPa 지위고도에서 한반도부터 일본 동쪽 북서태평양 지역으로 고기압성 순환 반응이 나타나는데 선행연구에서는 이 고기압성 반응을 쿠로시오 고기압으로 정의했다 (Son et al. 2014). 해면기압에서는 필리핀 동쪽부터 북서태평양 지역으로 넓게 위치한 필리핀해 고기압 (아열대 북서태평양 고기압)이 나타났다. 쿠로시오 고기압과 필리핀해 고기압은 아노말리 형태에서 나타나는 고기압으로 기후 평균장에서는 나타나지 않는다. 엘니뇨 해 겨울에 쿠로시오 고기압이 나타나면 한반도 쪽으로 남풍 아노말리가 유도되고 한반도 남쪽 해양의 온난하고 습윤한 공기가 유입되면서 우리나라는 평년에 비해 따뜻하고 강수가 많이 내릴 수 있게 된다. 라니냐 해에는 반대로 쿠로시오 저기압이 나타나면 북풍이 강화되어 우리나라는 평년에 비해 춥고 건조한 영향을 받게 된다. 모델에서도 한반도와 일본 주변으로 고기압성 순환을 나타내며 BCC와 PNU 두 개 모델을 제외하고 쿠로시오 고기압 반응이 나타났다. 그러나 모델은 고기압성 순환의 세기가 관측보다 약하고 위치가 한반도와 일본 주변으로 한정되어 관측보다 좁은 지역에서 나타나는 차이가 있었다. 모델의 해면기압은 북서태평양 지역에서 고기압성 반응을 보여 관측과 유사해 보이나 차이가 있었다. 관측에서는 일본 동쪽으로 순압적으로 발달한 쿠로시오 고기압이 하층까지 이어진 반응으로 나타나지만, 모델은 필리핀해 고기압이 북서쪽으로 확장해 발달한 모습으로 나타나는 차이가 있었다.

1월에는 12월과 다르게 관측에서 쿠로시오 고기압이 사라지며 500hPa 지위고도는 한반도 주변으로 강한 시그널이 나타나지 않았다. 해면기압도 한반도 주변으로 고기압성 순환은 나타나지 않으며 아열대 북서태평양 지역에서 필리핀해 고기압이 북동쪽으로 확장되어 나타났다. 또한 북태평양 동편에 저기압성 순환과 북아메리카에 고기압성 순환이 위치한 PNA 패턴이 나타났는데 저기압성 순환 반응은 12월보다 남동쪽에서 강화되어 나타났다. 초겨울에 비해 늦겨울에 필리핀해 고기압과 PNA 패턴이 강화되는 것은 기존 연구에서 많이 보고되었다 (e.g. Wang et al. 2000; Wang and Fu 2000). 모델의 500hPa 지위고도는 관측과 다르게 12월과 유사한 반응이 이어졌는데 세기는 약해졌지만 한반도와 일본 주변으로 고기압성 순환을 나타냈고, 해면기압은 12월과 유사하게 필리핀해 고기압이 북동쪽으로 발달한 모습으로 나타나 관측과 유사하게 모의 되었다. 모델에서도 북태평양 동편에 저기압성 순환이 12월보다 강해지며 PNA 패턴이 강화되어 나타났는데 중심은 관측보다 북서쪽에 위치했다.

2월에 관측에서 500hPa 지위고도는 한반도 북쪽으로 고기압성 순환이 위치하고 북태평양 동쪽에 저기압성 순환이 자리잡은 쌍극 형태의 반응을 보여 1월과는 다른 반응을 나타냈는데, 모델에서는 한반도 북쪽의 고기압성 순환을 모의하지 못하고 북태평양의 저기압성 반응을 관측보다 북서쪽으로 확장되게 모의해 차이를 보였다. 해면기압도 관측은 한반도 북동쪽에 고기압성 반응을 보였으나 모델에서는 나타나지 않았다. 2월 우리나라 기온 강수와 Nino 지수와의 상관성은 과거에 비해 최근 기간에 양의 상관성이 증가했는데, 초겨울에 나타나는 쿠로시오 고기압의 영향과는 다르게 한반도 북쪽으로 나타나는 고기압성 순환과 관련된 것으로 볼 수 있다. 선행연구에서는 최근 겨울철 NPO 패턴에 공간적인 변화가 있었고

북태평양 대기와 해양의 두 번째 결합모드인 NPO/NPGO 모드가 과거보다 크게 강화되었음을 보였으며, PDO와 AMO 위상이 서로 반대일 때 대서양이 대기에 영향을 주어 워커순환을 변화시킬 수 있다고 제시하였다 (예상욱 등, 2021). 분석 기간인 1993/94~2014/15년은 음의 PDO와 양의 AMO 위상에 해당하는 시기로 열대 태평양과 대서양의 상호작용, 북태평양의 대기-해양 상호작용이 과거와 달라지면서 ENSO의 반응 또한 늦겨울인 2월에 다르게 나타난 것으로 보인다. 모델에서는 과거와 달라진 상호작용을 모의하지 못했으며 겨울철 내내 유사한 반응으로 모의해 관측과의 차이가 크게 나타난 것으로 보인다.

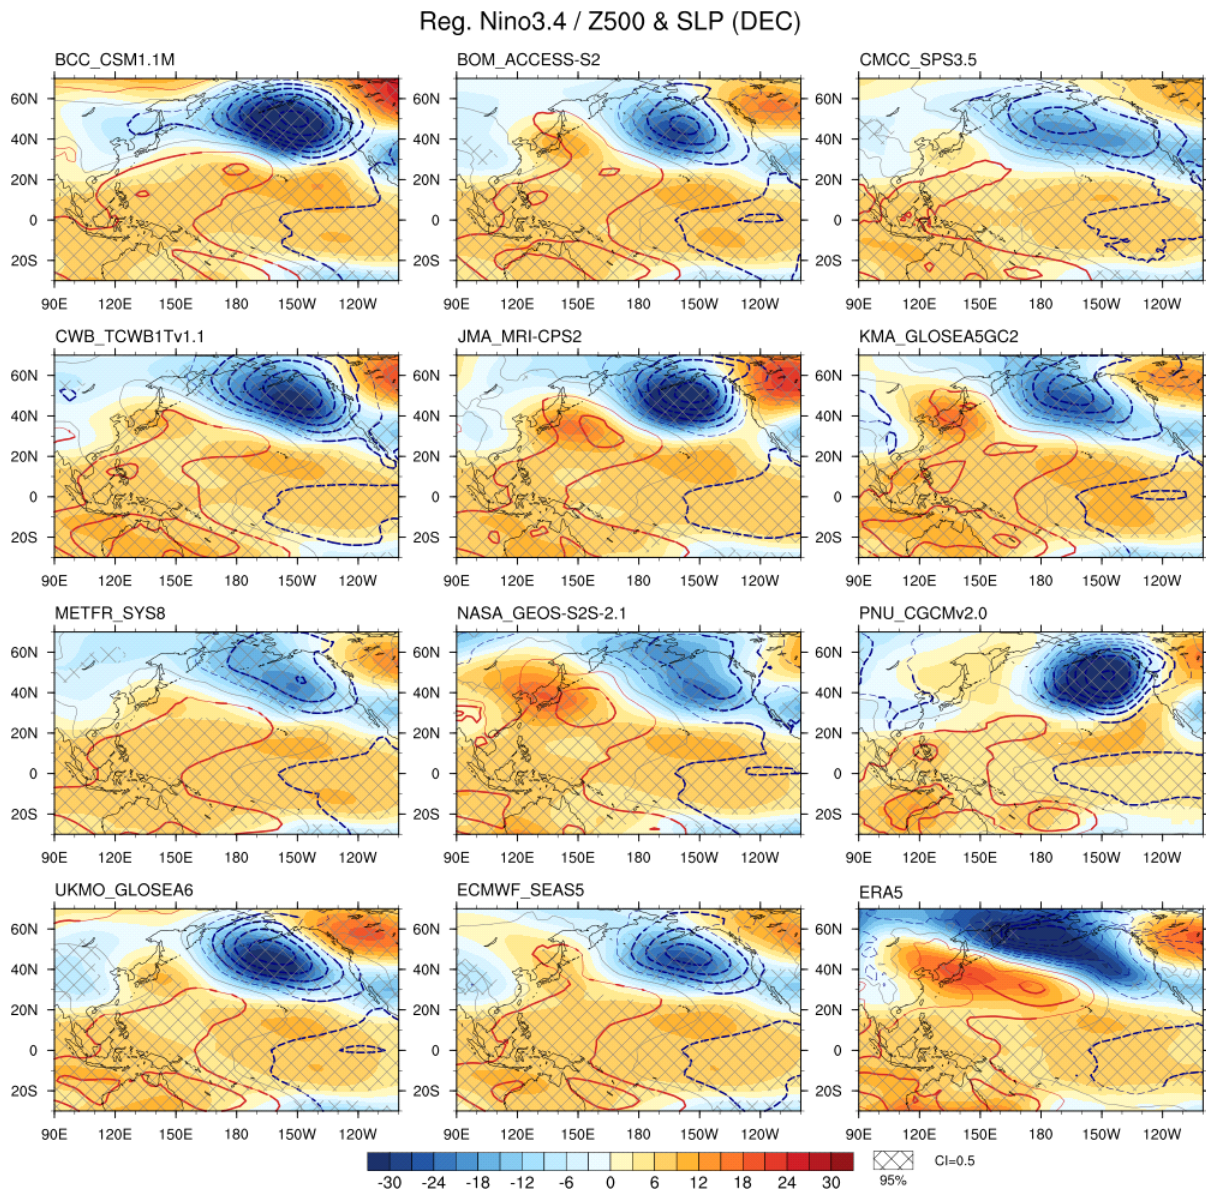


Figure 25. Regression of (shading) 500hPa geopotential height anomalies and (contour) sea level pressure anomalies with respect to Nino3.4 index in December. The diagonal and thick line indicate statistically significant at 95% confidence level.

Reg. Nino3.4 / Z500 & SLP (JAN)

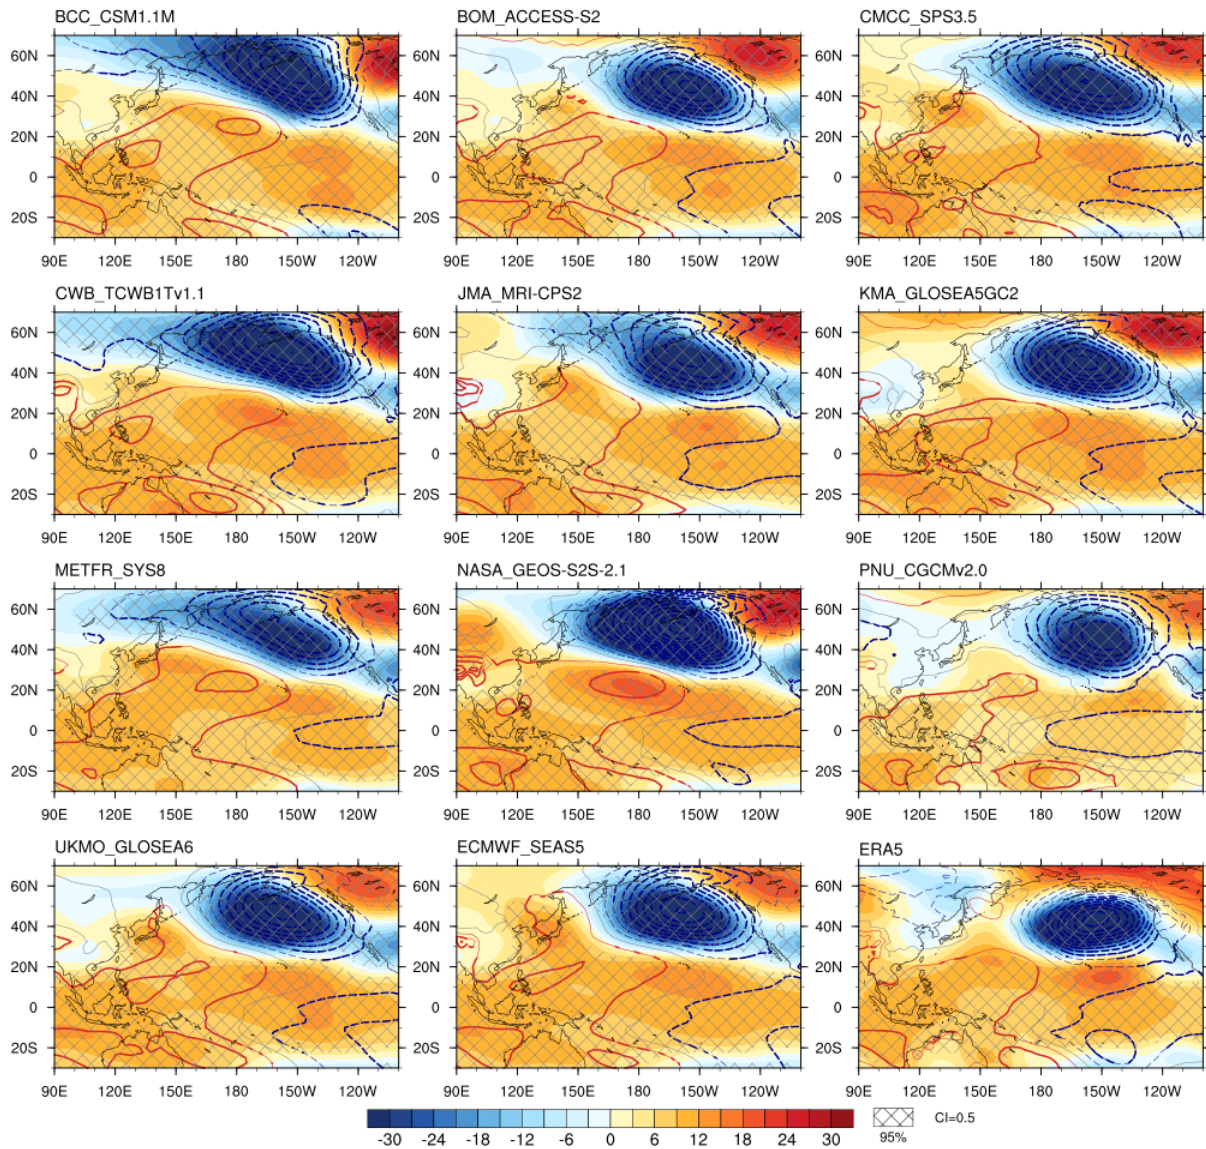


Figure 26. As in Figure 25 but for January.

Reg. Nino3.4 / Z500 & SLP (FEB)

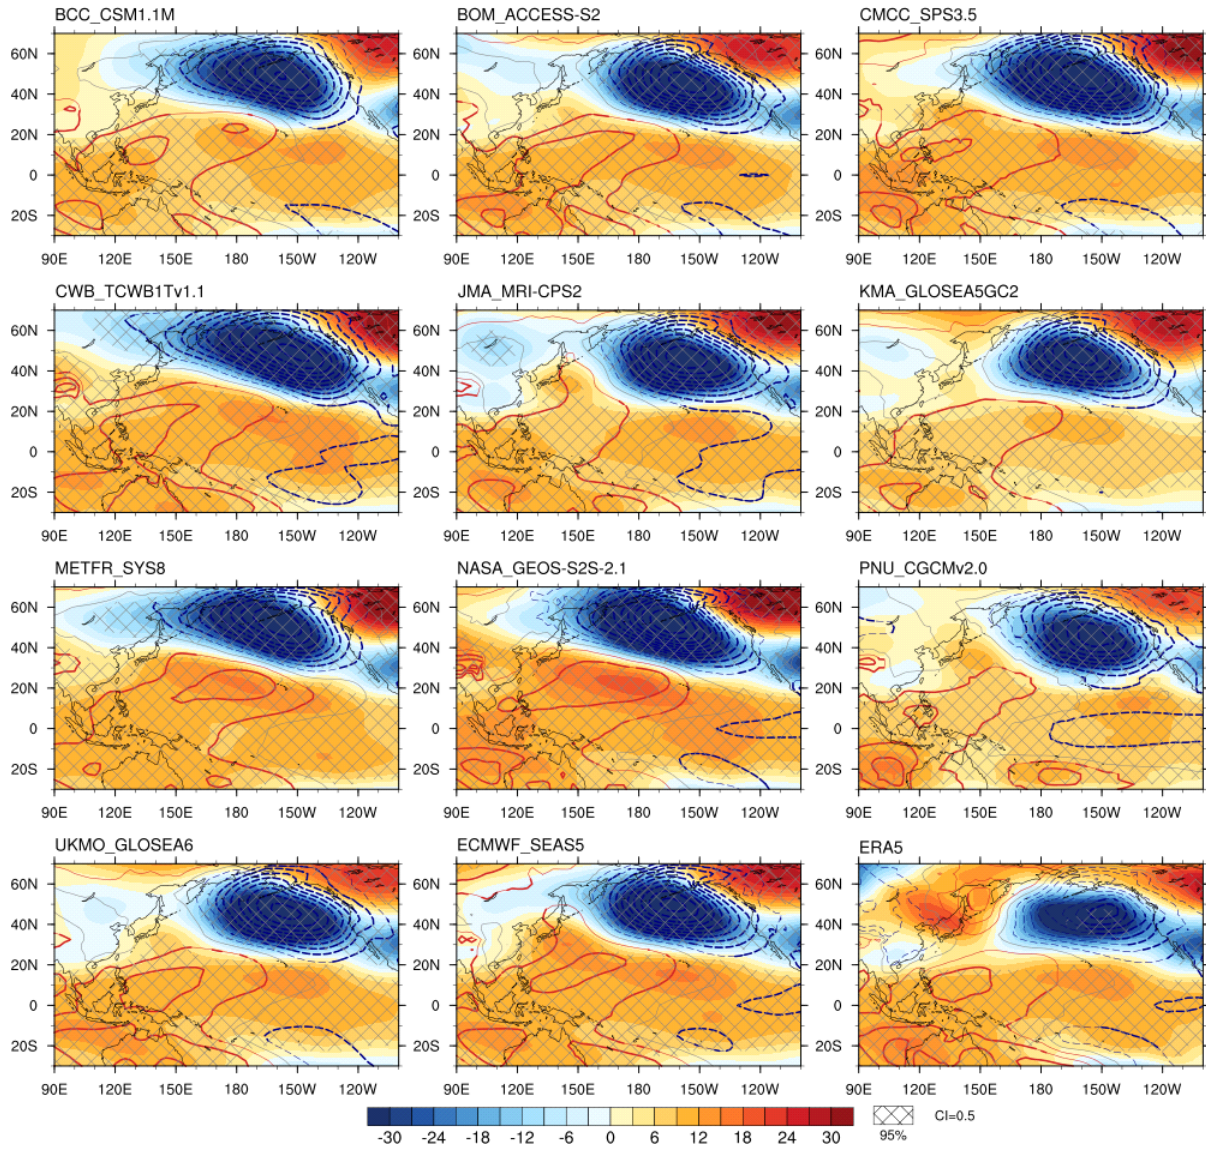


Figure 27. As in Figure 25, but for February

Figure 28은 북반구와 동아시아 지역모델 대기 반응의 RMSE와 공간 상관계수를 나타낸다. 북반구 전지역에 대한 오차는 500hPa 지위고도와 해면기압에서 12월이 가장 작고 1월, 2월 순으로 다소 증가하는 경향을 보이지만 12월보다 크게 증가하지는 않았다. 공간 상관계수는 월별 차이는 크지 않았고 약 0.4~0.8 사이에 위치해 모델들의 북반구 전반적인 모의 성능은 월에 따른 차이보다 모델간의 차이가 더 크게 나타났다. 반면에 동아시아 영역에서는 월별 차이가 크게 나타났으며 특히 500hPa 지위고도에서 큰 차이를 보였다. 500hPa 지위고도의 동아시아 영역에서의 오차는 12월과 1월은 비슷한 수준을 보였으나 2월에 크게 증가했고, 공간 상관계수는 12-1-2월 순으로 감소했는데 2월은 대부분의 모델이 음의 상관계수를 나타냈다. 2월의 큰 오차는 우리나라 북쪽 지역에서의 오차가 크게 나타난 것이 영향을 준 것으로 보인다. 해면기압은 지위고도보다 오차는 작으나 동아시아 지역 오차가 북반구 전반적인 오차에 비해 크게 증가했고 지위고도와 마찬가지로 12월과 1월에 비해 2월의 오차가 비교적 크게 나타났다. 동아시아 지역 순환장의 ENSO 반응은 관측에서는 월별로 변화가 뚜렷하게 나타났으나 모델은 12-1-2월을 유사하게 모의하며 오차가 크게 나타났고 특히 같은 1개월 선행예측임에도 불구하고 2월에 모델 오차가 크게 나타났다.

Figure 29는 ENSO에 대한 반응으로 나타나는 적도 해수면온도, 열대 강수, 북반구와 동아시아 지역 500hPa 지위고도의 관측과의 상관계수, 그리고 상관계수 사이의 상대적인 차이를 나타낸다. 상관계수간의 상대적인 차이는 두 상관계수의 차이를 빼준 값으로 나누어 각 단계를 지나면서 모델의 모의 성능이 얼마나 감소했는지를 비교하고자 하였다. 12월, 1월, 2월 모두 적도 해수면온도와 열대 강수 반응은 관측과 높은 상관성을 보였으며, 두 반응의 상관계수 차이는 작아 모델이 해수면온도와 강수는 비슷한 수준에서 잘 모의하는 것으로 나타났다. 북반구 500hPa 지위고도 반응의 상관계수는 열대 강수보다는 감소했으나 둘의 상대적인 차이는 해수면온도와 강수 반응 간의 차이에 비해 크지 않았고 개별모델들 분포도 넓지 않았다. 동아시아 500hPa 지위고도 반응은 월별 차이가 크게 나타났다. 12월에 모델은 동아시아 지역의 500hPa 지위고도 반응을 관측과 유사하게 모의하며 높은 상관계수를 보였고 MME는 오히려 북반구보다 높은 상관성을 나타냈다. 하지만 모델 간 차이는 크게 나타났다. 12월과 다르게 1월과 2월에 동아시아 지역의 모델 500hPa 반응은 관측과 차이를 보이며 상관계수가 크게 감소했고 특히 2월은 음의 상관계수를 나타냈다. 개별모델들 분포도 넓게 나타나 모델 간 차이가 크게 나타났다. 2월에 값은 작지만 양의 상관계수를 나타낸 모델은 KMA와 PNU 모델인데, 두 모델의 공간 패턴은 다른 모델과 유사했으나 한반도 북쪽에 다른 모델과 다르게 저기압성 순환이 나타나지 않으면서 양의 상관계수로 나타났다. 모델들은 공통적으로 열대 해수면온도 즉 ENSO를 잘 모의하고 ENSO에 대한 반응으로 나타나는 열대 강수와 북반구 전반적인 대기 순환장 모의 성능은 나쁘지 않았으나, 동아시아 영역에 대해서는 모의 성능이 1월과 2월에 떨어지는 것으로 나타났다. 또한 동일한 1개월 선행예측임에도 월별로 차이가 나타나는 부분은 모델의 오차가 선행시간시간뿐만 아니라 특정 월에 대해서도 의존적임을 보여주었다.

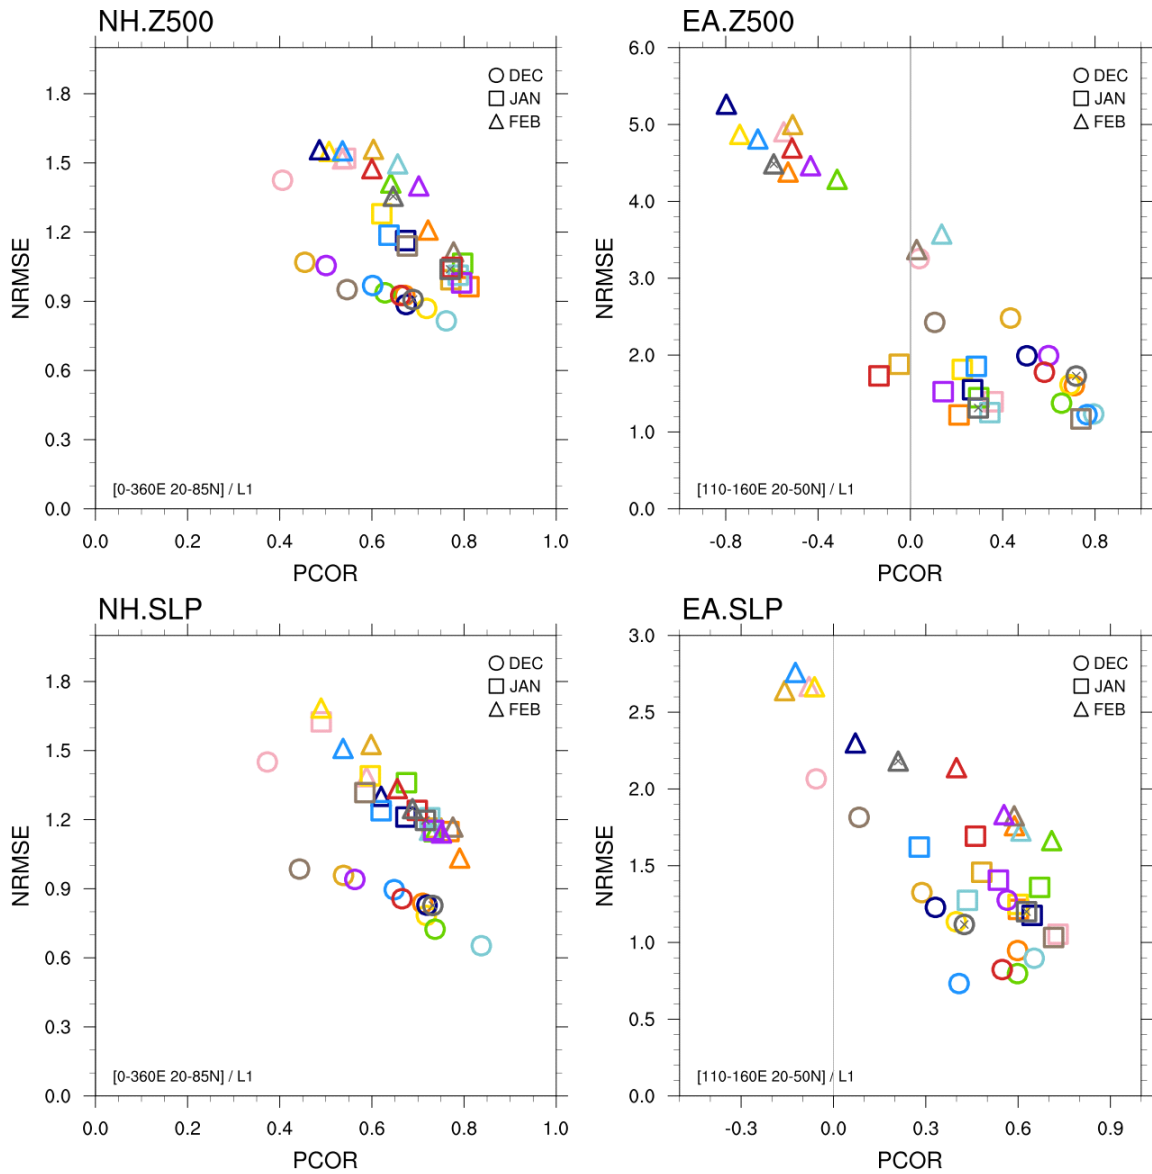


Figure 28. Scatter plots between the pattern correlation coefficient (PCOR) and normalized root mean square error (NRMSE) of the 500hPa geopotential height anomalies and sea level pressure anomalies regressed onto Niño 3.4 index over the Northern hemisphere (0~360°E, 20~85°N) and East Asia (110~160°E, 20~50°N).

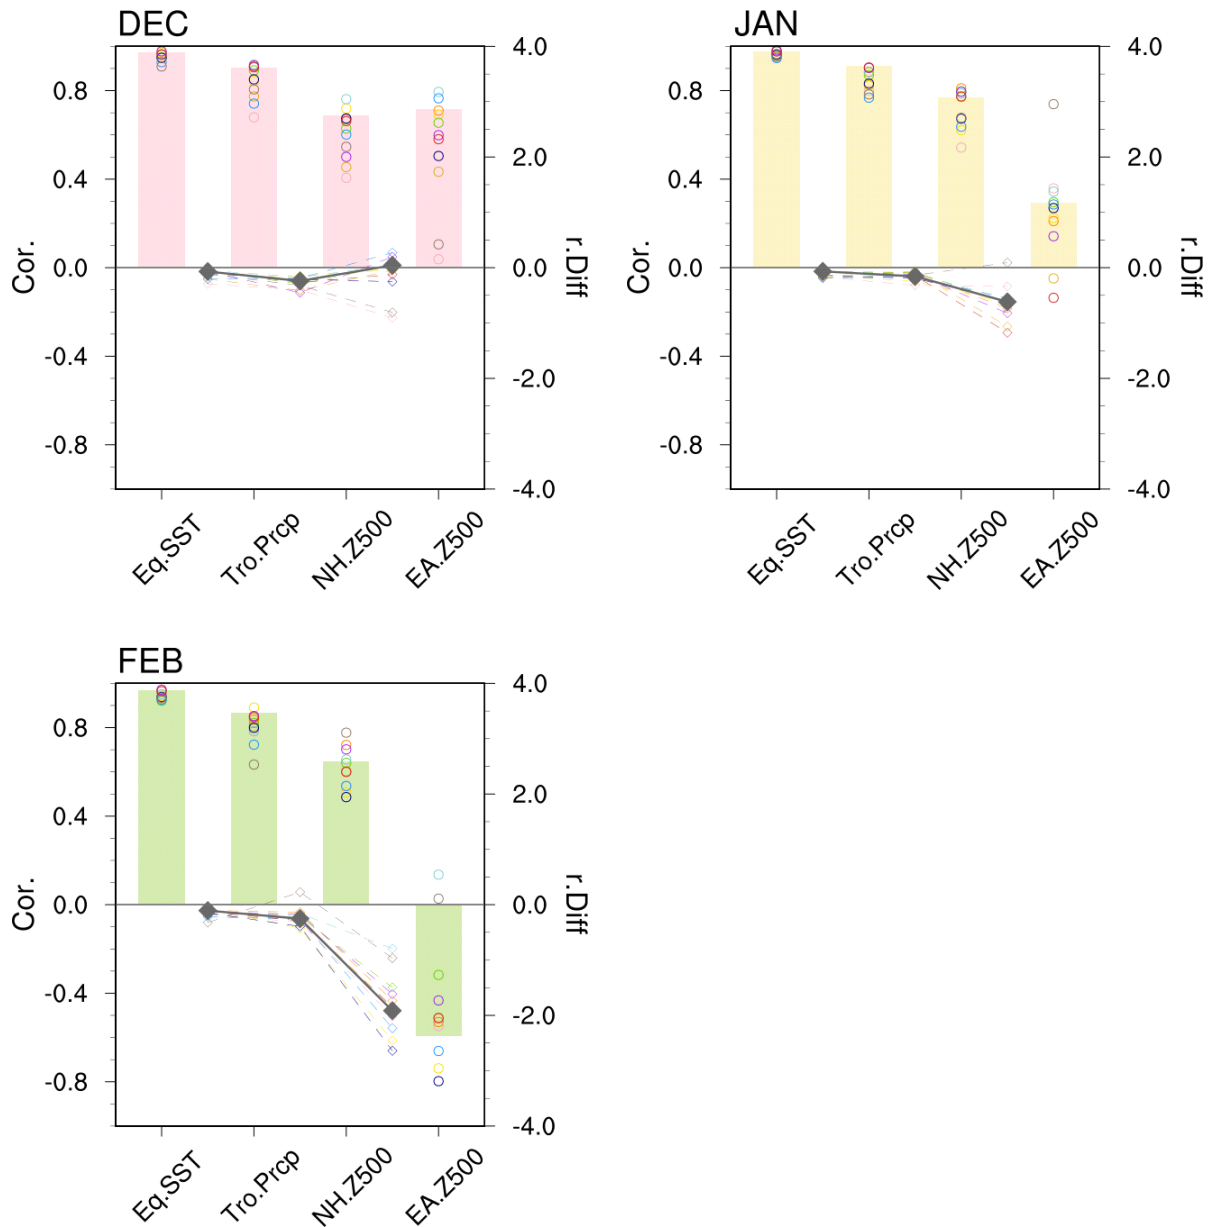


Figure 29. Correlation coefficient between observation and model responses (bar and circle), and relative difference between correlation coefficients (diamond and line). Eq.SST, Tro.Prcp, NH.Z500, and EA.Z500 indicate pattern correlation coefficient of equatorial SST anomalies (120~270°E, 5°S~5°N), tropical precipitation anomalies (100~270°E, 10°S~10°N), northern hemisphere 500hPa geopotential height anomalies (0~360°E, 20~85°N), and east Asia 500hPa geopotential height anomalies (110~160°E, 20~50°N) regressed onto Nino3.4 index, respectively. Bar and gray diamond show MME results.

1월에 12월과 다르게 쿠로시오 고기압이 나타나지 않는 원인으로 선행연구에서는 열대 강수와 관련된 원격상관 패턴의 변화 때문이라고 밝혔다 (Son et al. 2014). 쿠로시오 고기압은 서태평양 음의 강수 강제력에 의한 Gill-type 대기 반응과 로스비파 전파에 의해 중위도에 유도되는 순압구조의 고기압성 흐름으로 이해할 수 있다. Figure 30은 Nino3.4 지수에

회귀분석한 강수 편차로, 관측에서 12월과 1월의 강수 패턴은 유사한 듯 보이지만 차이가 있는데 12월에 비해 1월에는 중태평양 양의 강수는 다소 증가하는 반면에 서태평양 음의 강수는 감소한다. Figure 31은 엘니뇨와 라니냐 해 서태평양과 중태평양 강수 합성장의 시계열로 검정 실선으로 나타낸 관측에서 12월보다 1월에 서태평양 강수가 약해진 것을 볼 수 있다. 강수 약화는 라니냐 해 보다 엘니뇨 해에서 더 뚜렷하게 나타나지만 두 경우 모두 1월에는 강수 반응이 12월보다 약해졌다. 중태평양 강수는 서태평양 강수와 다르게 약해지지 않고 12월과 비슷하거나 더 강하게 나타났다. 서태평양 강수가 쿠로시오 고기압을 유도하는 것과 유사하게 중태평양 강수는 중위도에 저기압성 순환을 유도한다. Figure 32는 서태평양 강수와 중태평양 강수에 대한 다중 회귀분석으로 실선은 서태평양 강수에 대한 회귀계수이고 채색된 부분은 중태평양 강수에 대한 회귀계수를 나타낸다. 관측에서 서태평양 강수는 북태평양 고기압성 순환과 관련된 것으로 나타나는데 고기압성 순환은 1월에는 약해지고 2월에는 한반도 북쪽으로 나타났다. 중태평양 강수는 북태평양 저기압성 순환과 관련되어 있으며 북태평양 동편의 저기압성 순환과 북아메리카 고기압성 순환으로 이어지는 PNA 패턴과 관련이 높은 것으로 나타났다. 북태평양에서 두 강수 강제력에 의한 대기 순환 반응은 반대로 나타나지만 한반도 주변 지역에서는 서태평양 강수에 의한 반응이 더 크게 나타나기 때문에 12월에는 고기압성 순환이 한반도 동쪽으로 위치하게 되고 1월에는 서태평양 강수가 약해지면서 고기압성 순환도 약해지게 된다.

선행연구에서는 북서태평양과 동아시아 지역의 ENSO 강제력에 의한 원격상관의 변화를 모델에서 잘 모의하지 못함을 보인 바 있는데 (Kim et al. 2015; Kim et al. 2017), 이는 모델에서 서태평양 강수가 관측보다 약하고 강도가 1월까지 유지되기 때문이라고 밝혔다. 선행연구와 마찬가지로 APCC MME에 참여하는 개별모델과 ECMWF 모델에서도 관측에서 나타나는 원격상관 패턴의 변화를 모의하지 못하고 유사한 반응이 겨울철 세 달 내내 이어졌다. 모델 강수 반응은 관측의 월별 변화를 따라가지 못했는데, 서태평양 강수가 1월에 약화 되고 2월에 강해지는 변화를 모의하지 못했고 겨울철 내에서 강도의 큰 변화를 보이지 않아 1월은 관측보다 강수를 강하게, 2월은 관측보다 약하게 모의되는 경향을 보였다. 중태평양 강수는 2월에 오히려 관측보다 약하게 모의하는 경향을 보였다. 서태평양과 중태평양 강수의 엘니뇨와 라니냐 해 합성장에서 살펴보면 모델들은 서태평양 강수는 관측보다 약하게 모의하고 중태평양 강수는 관측보다 강하게 모의하는 경향을 보였는데 엘니뇨 해에 이러한 경향이 더 잘 나타났다. 이는 엘니뇨와 라니냐 시기 강수가 관측에서는 강도나 패턴에 비대칭성이 있지만, 모델은 관측보다 대칭적으로 모의하기 때문이다. 모델 강수의 다중회귀분석에서 서태평양 강수는 관측과 유사하게 12월 북태평양 중위도에 고기압성 순환과 관련된 것으로 나타났고 1월과 2월에도 12월보다는 약하지만 유사한 패턴으로 중위도 고기압성 순환과 관련된 것으로 나타났다. 이는 모델에서 서태평양 강수가 1월에 강도가 약화 되지 않고 12월과 비슷한 수준으로 유지되었기 때문으로 볼 수 있다. 모델에서 중태평양 강수는 북태평양 저기압성 순환과 북아메리카 고기압성 순환과 관련된 것으로 나타났다. 저기압성 순환은 관측보다 훨씬 강하고 서쪽으로 더 확장되어 나타났는데, 모델이 중태평양 강수를 관측보다 강하게 모의하는 경향이 있기 때문으로 보인다. 개별모델들마다 조금씩 차이는 있었지만 이러한 특징은 모델 대부분에서 공통으로 나타났다.

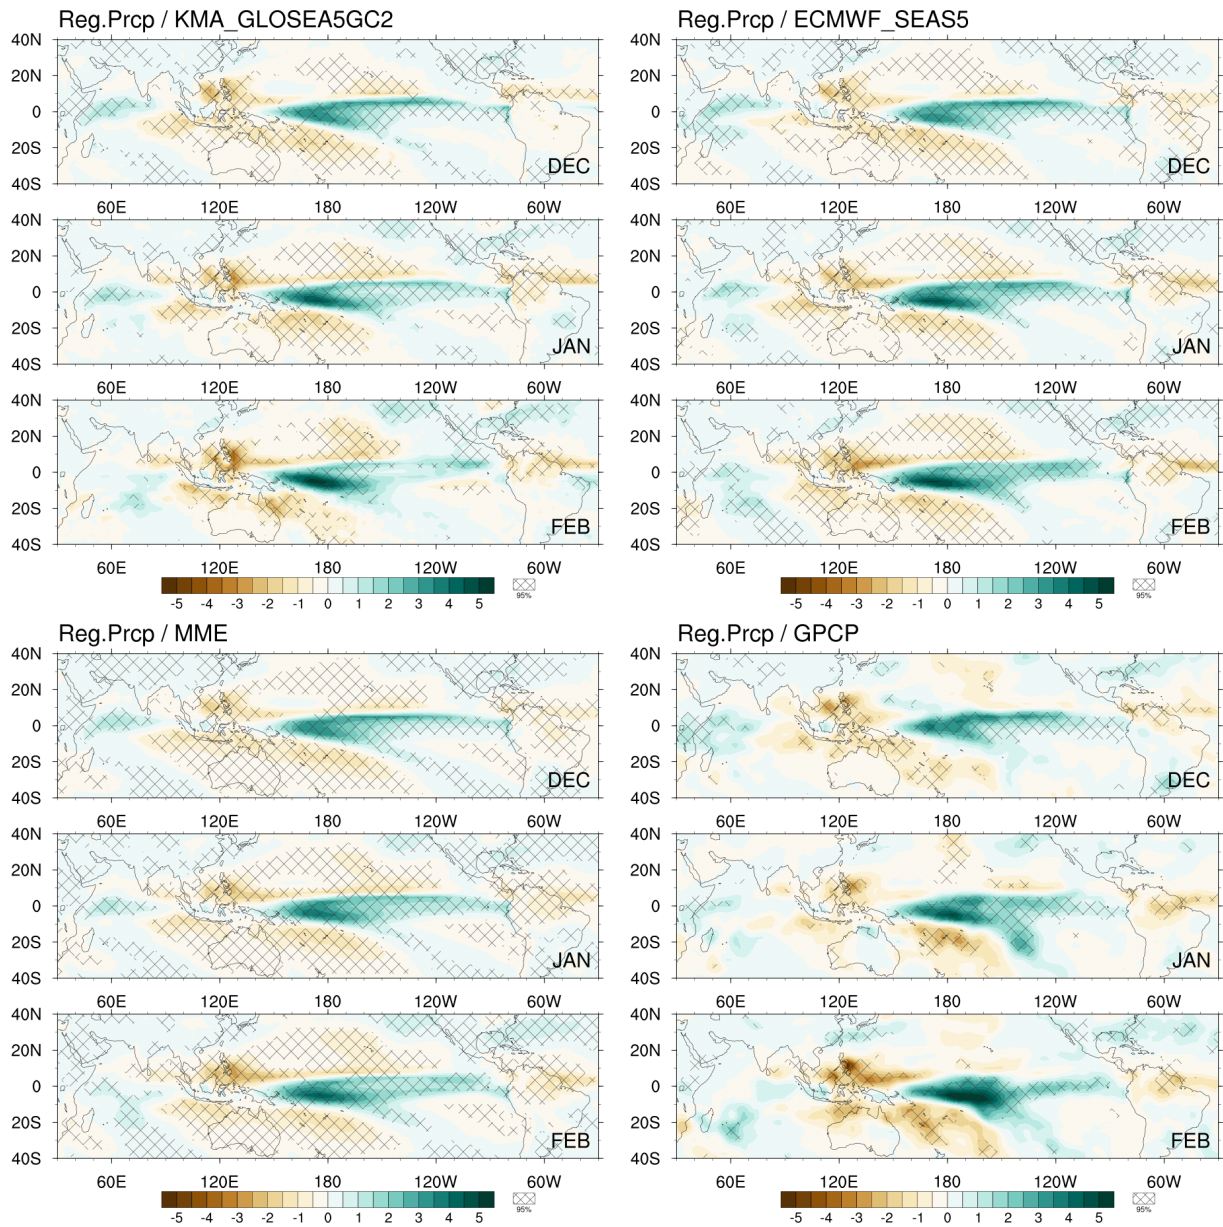


Figure 30. Regression of precipitation anomalies with respect to Nino3.4 index. The diagonal indicate statistically significant at 95% confidence level.

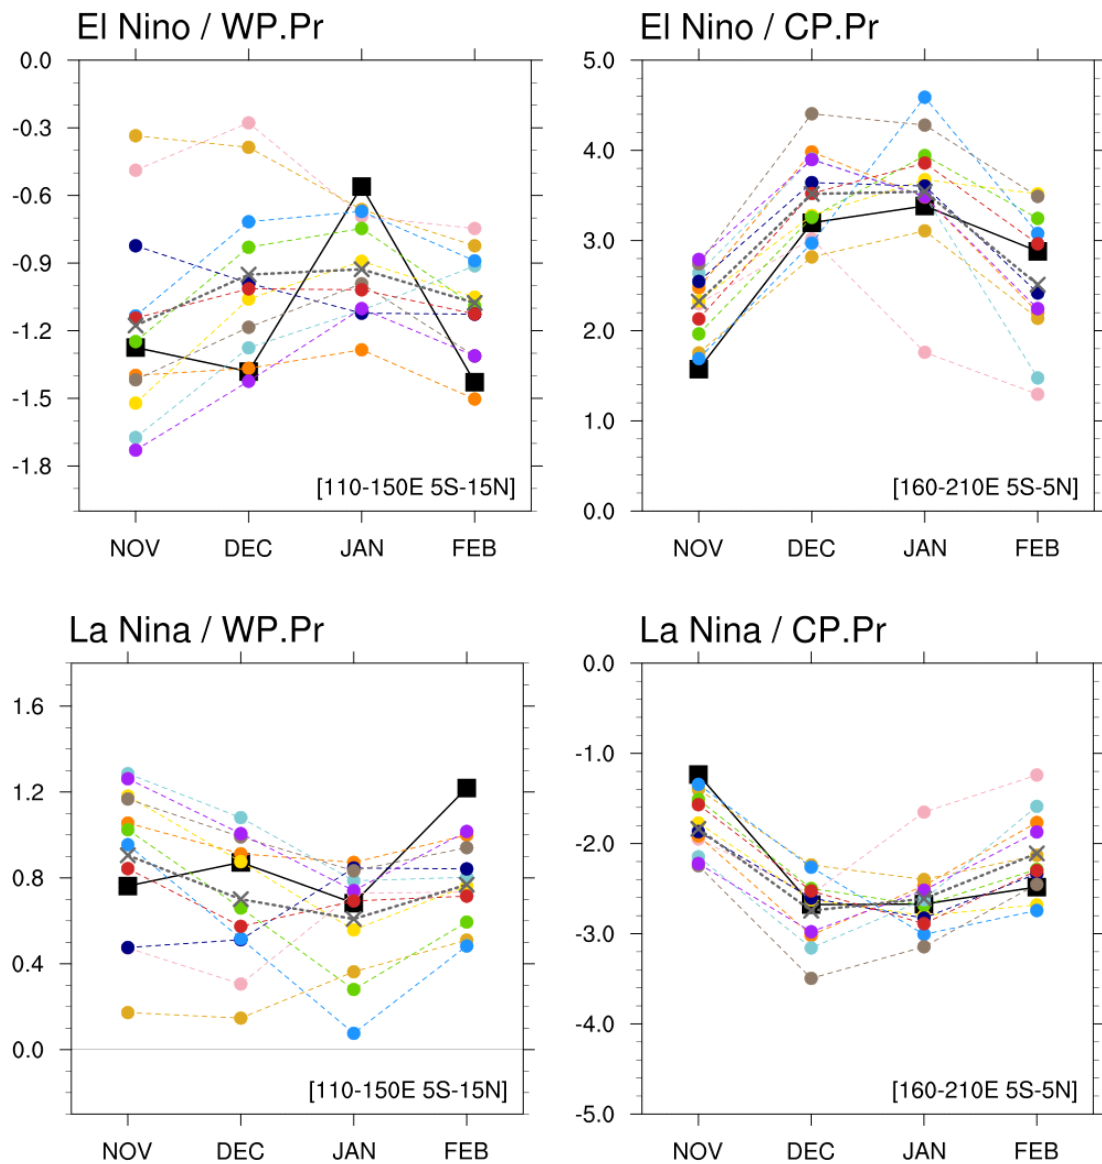


Figure 31. Composites of the precipitation anomalies over the western Pacific (WP; 110~150°E, 5°S~15°N) and the central Pacific (CP; 160~210°E, 5°S~5°N). Black solid line and gray dashed line show the observation and MME respectively.

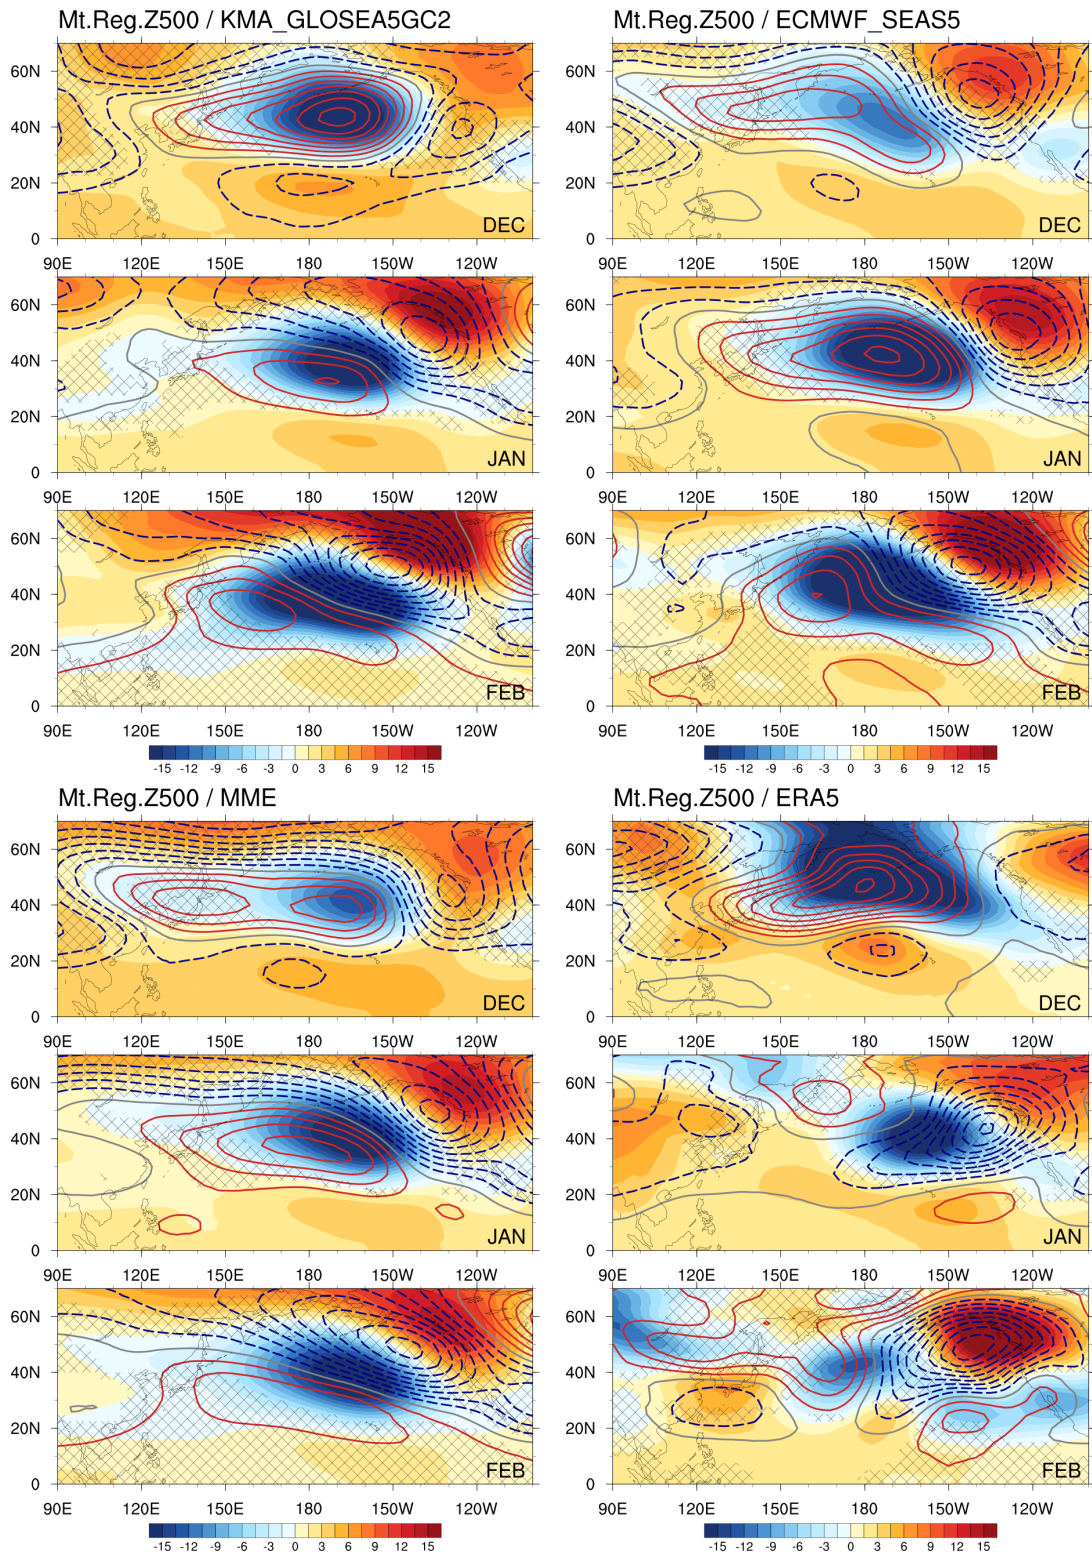


Figure 32. Multiple regression of 500hPa geopotential height anomalies with respect to precipitation anomalies over the western (110~150°E, 5°S~15°N) and central (160~210°E, 5°S~5°N) Pacific. Contour and shading show coefficients for western and central Pacific precipitation, respectively. Diagonal indicates area where the relative importance of the western pacific precipitation is greater than central pacific precipitation.

Figure 33a는 북반구 평균(20~85°N) 500hPa 지위고도의 표준편차를 경도를 따라 나타낸 것으로 지위고도의 지역별 변동성을 나타낸다. 겨울철 동안 공통적으로 약 180~160°W 부근의 북태평양 지역에서 변동성이 가장 크게 나타났고 모델에서도 이 지역의 변동성이 크게 나타났다. 월별로 살펴보면 모델과 관측의 차이는 1월과 2월에 두드러지게 나타났다. 모델이 북태평양에서 변동성이 크게 나타난 것은 관측과 유사했지만, 관측보다 좁은 지역에서 나타났고, 1월에는 중심이 관측보다 서쪽으로 치우치는 차이를 보였다. 또한 관측에서는 유라시아 대륙과 북아메리카에서도 큰 변동성을 보였으나 모델은 이들 지역의 변동성을 모의하지 못했다. 우리나라는 유라시아 대륙의 동쪽에 위치했기 때문에 대륙의 변동성은 우리나라 기온 및 강수에 영향을 미치는 중요 요소지만 모델에서는 모의하지 못하는 것으로 나타났다. 특히 개별모델에서는 어느 정도의 변동성을 모의하더라도 MME에서는 개별모델의 시그널들이 상쇄되어 사라지기 때문에 ENSO에 의한 변동성만이 큰 부분을 차지했다. 모델의 지위고도 변동성에서 ENSO와 관련된 변동성이 차지하는 비율은 2월 동아시아 부근을 제외하고 중위도 동아시아부터 북태평양까지 모든 지역에서 관측보다 크게 나타나(Figure 33b), 모델은 ENSO와 관련된 변동성을 과하게 모의하는 것으로 나타났다.

Figure 34는 관측과 모델에서 우리나라 기온 강수와 Nino3.4 지수의 상관계수를 나타낸 그림이다. 관측은 12-1-2월 기온과 강수 모두 양의 상관성을 나타냈지만, 12월 강수, 2월 기온과 강수만 통계적으로 유의한 상관성을 보였고, 1월은 기온과 강수 모두 0에 가까운 낮은 상관성을 나타냈다. 반면 모델은 12월과 1월은 두세 모델을 제외하고 관측보다 높은 상관성을 보였고 1월 강수의 경우 7개 모델에서 Nino3.4 지수와 통계적으로 유의한 양의 상관성을 나타내 관측보다 ENSO와의 관련성이 매우 높게 나타났다. 모델에서 강수가 ENSO와의 상관성이 높게 나타난 것은 하층 순환장과 관련되어 있는데 1월에 필리핀해 고기압이 관측보다 북쪽까지 확장하면서 남풍 편차의 영향을 많이 받았기 때문으로 보인다. 2월은 관측에서 기온과 강수 모두 Nino3.4 지수와 유의한 양의 상관성을 보였으나 모델은 두 개 모델만이 강수에서 유의한 상관성을 나타내 ENSO와의 관련성이 낮게 나타났다. 모델에서 모의되는 우리나라 기온과 강수 변동성 중에서 ENSO와 관련된 변동성의 비율을 관측과 비교해보면 대부분의 모델이 12월과 1월은 관측보다 크게 나타나고 2월은 작게 나타났는데, 모델에서는 ENSO의 영향이 12-1월은 관측에 비해 과하게 모의 되고 2월은 약하게 모의 되고 있음을 확인할 수 있었다.

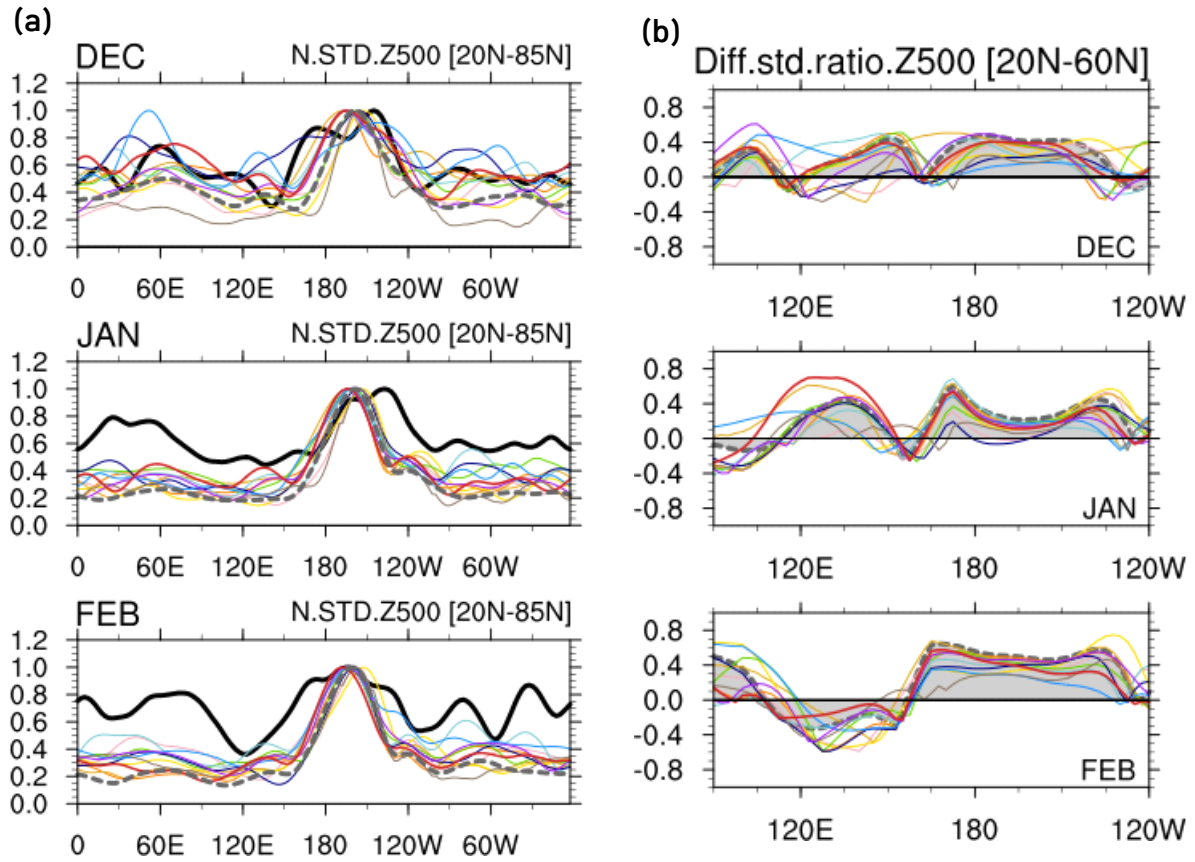


Figure 33. (a) Standard deviation of the northern hemisphere (20~85°N averaged) 500hPa geopotential height anomalies. (b) Difference of the ratio of ENSO related standard deviation to the total standard deviation for the mid-latitude (20~60°N averaged) 500hPa geopotential height anomalies between model and observation. The standard deviation in (a) is normalized by their maximum. Black and color curves show the observation and individual model. Gray dashed curve show the MME.

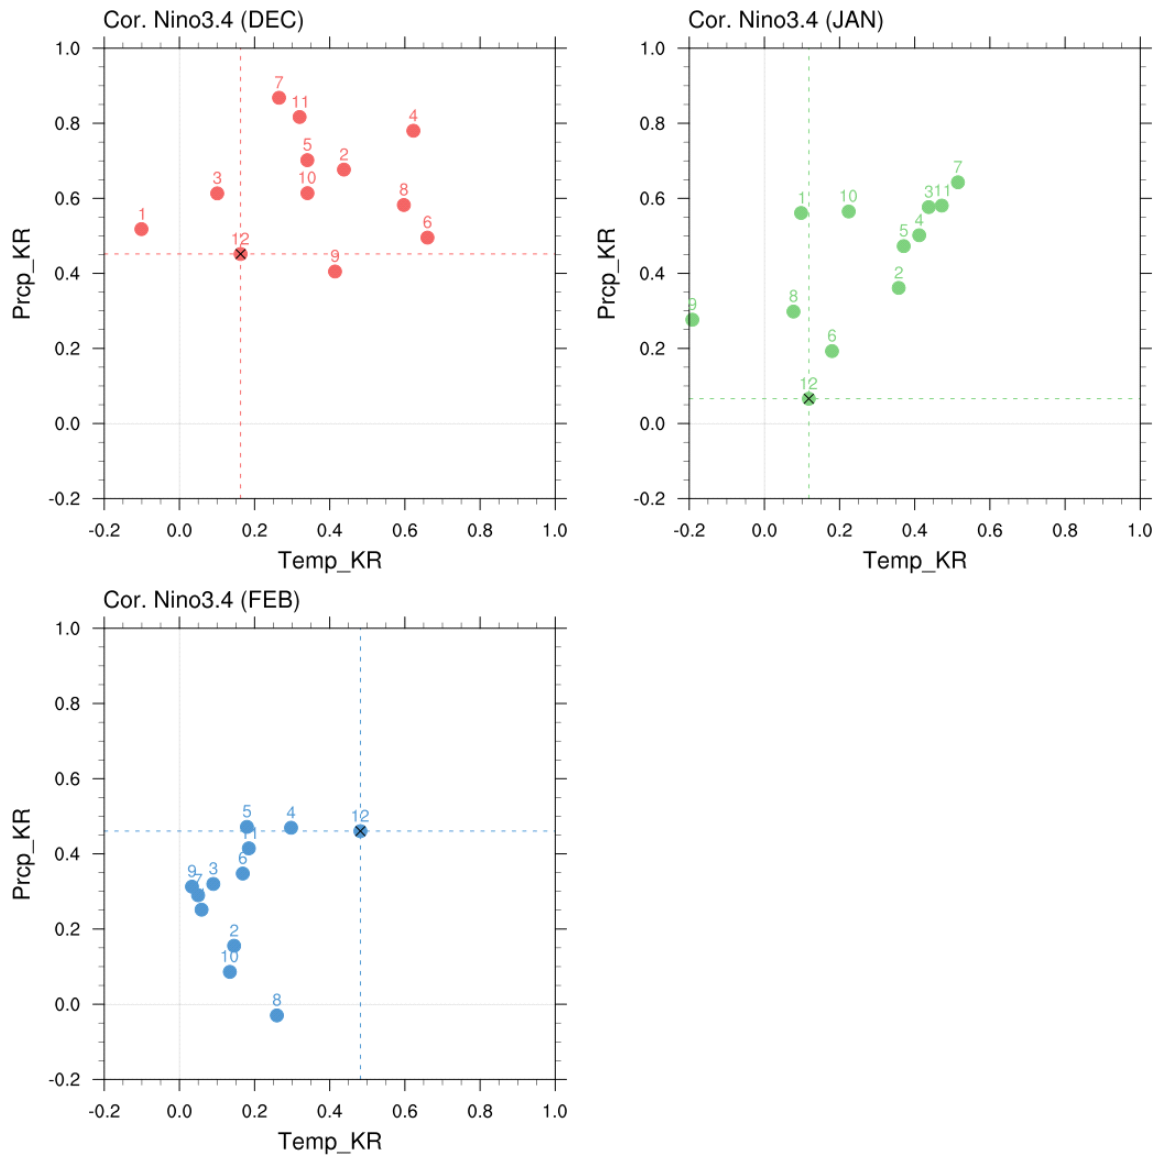


Figure 34. Scatter plots between the correlation coefficient of Korean temperature precipitation anomalies with Nino3.4 index. Each number indicates model number in Table 1. Number 12 indicates coefficient for observation.

(2) 극지방 연직 기온분포에 따른 동아시아 기온 변동성 분석

(가) 재분석자료에서 북극 이벤트와 동아시아 기온 변동성 관계

1991년부터 2021년까지 북극 이벤트와 동아시아 기온 변동 지수에 따라 월별 사례를 구분하였다(Figure 35). 각 셀 안의 어안 기호(⊙)는 깊은 연직 온난화, 점 기호(●)는 얇은 연직 온난화, 원 기호(○)는 상층 온난화, 그리고 표시되지 않은 셀은 이벤트 없음을 나타낸다. 각 셀의 왼쪽 아래 삼각형은 재분석자료에서 동아시아의 2m 기온을, 오른쪽 위 삼각형은 지상 종관기상관측(ASOS) 자료로 얻은 제주도를 제외한 전국 62개 지점의 평균기온을 표준화하여 나타내었다. 우리나라를 포함하는 동아시아 지역에 저온 편차가 나타나더라도 우리나라에는 저온 편차가 나타나지 않거나, 반대로 우리나라에만 저온 편차가 나타나는 때도 있었다.

Figure 36에 북극 이벤트별 동아시아 저온 사례의 비율을 정리하였다. 동아시아 기온은 표준화된 지수 값이 0보다 큰 경우를 ‘높음’, 0보다 작은 경우를 기온이 ‘낮음’으로 구분하였다. 12월에 깊은 연직 온난화는 10회 나타났으며 이 중 4회에 동아시아에 낮은 기온이 발생하였고, 얇은 연직 온난화는 4회 중 2회, 상층 온난화는 1회 중 1회, 북극 이벤트가 없는 16회 중 5회에 동아시아에 낮은 기온이 발생하였다. 1월에는 깊은 연직 온난화가 8회, 얇은 연직 온난화가 3회, 상층 온난화가 2회, 북극 이벤트 없음이 18회 나타났으며 각각 7회, 0회, 1회, 그리고 6회로 동아시아에 낮은 기온이 발생하였다. 마지막으로 2월에는 깊은 연직 온난화가 6회, 얇은 연직 온난화가 6회, 상층 온난화가 2회, 북극 이벤트 없음이 17회 나타났고, 각각 6회, 3회, 1회, 7회 동아시아에 낮은 기온이 발생하였다. 깊은 연직 온난화일 때 12월은 40%, 1월은 88%, 2월은 100%로 1월과 2월에 매우 높은 비율로 동아시아 저온이 발생함을 알 수 있었고, 그 밖의 이벤트는 발생빈도가 매우 적거나 동아시아 저온 발생 확률이 40% 이내로 비교적 낮은 비율로 나타났다.




Figure 35. Classified arctic events and temperature over East Asia and South Korea. Fish-eye indicates deep arctic warming, point indicates shallow arctic warming, circle indicates warming aloft, and no symbol indicates no arctic event. Lower left triangle in each cell is showing standardized 2m temperature anomalies over East Asia and upper right triangle in each cell is showing standardized ASOS temperature in South Korea.

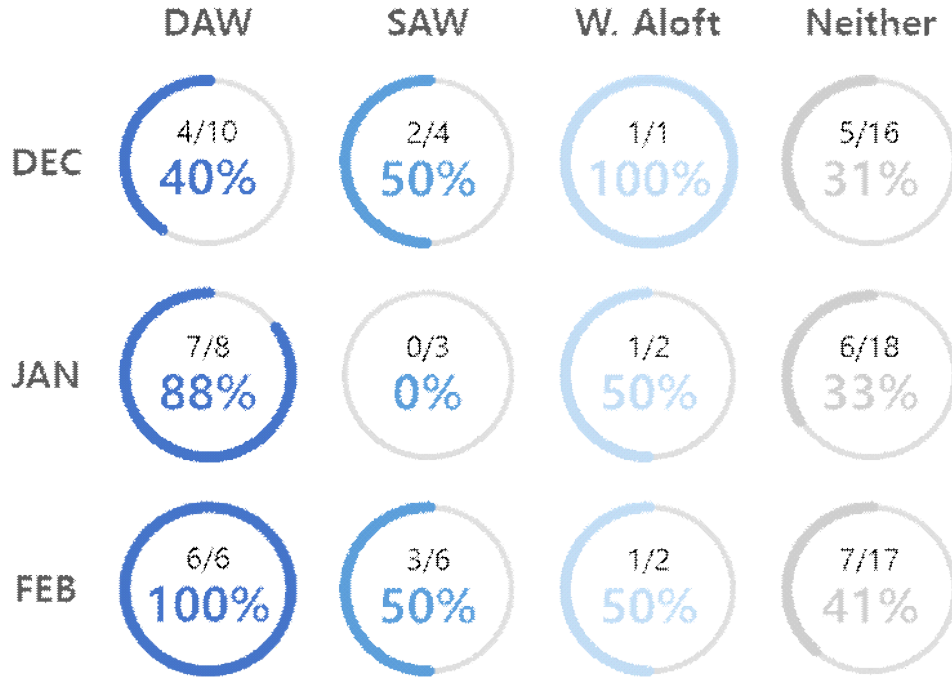


Figure 36. Percentage of occurrence of cold event in East Asia during each arctic event by month.

북극 연직 기온분포와 연관된 이벤트 중 발생빈도가 매우 적은 상층 온난화를 제외하고, 깊은 연직 온난화와 얇은 연직 온난화가 나타날 때 대기순환장 패턴에 어떤 차이가 나타나는지 살펴보았다. Figure 37~39는 깊은 연직 온난화와 얇은 연직 온난화일 때 북반구의 2m 기온과 500hPa 지위고도, 300hPa 수평 바람 편차의 합성장과 해수면온도와 연직수분속 편차의 합성장을 월별로 나타내었다.

먼저 해수면온도 패턴을 살펴보면, 12월에는 북대서양의 해수면온도 패턴의 차이가 깊은 연직 온난화와 얇은 연직 온난화를 구분하는 것으로 보인다. 깊은 연직 온난화일 때 북동대서양에서 바렌츠·카라해까지 전반적으로 평년보다 해수면온도가 높게 나타났고, 얇은 연직 온난화일 때는 북미 서안에서 평년보다 높은 해수면온도, 그린란드 남쪽으로 평년보다 낮은 해수면온도, 그리고 다시 바렌츠·카라해로 평년보다 높은 해수면온도가 나타나 대서양에서 삼극자 형태의 해수면온도 패턴이 나타났다.

반면에 1월과 2월에는 깊은 연직 온난화와 얇은 연직 온난화일 때 해수면온도 패턴에 큰 차이가 나타나지는 않지만, 12월의 얇은 연직 온난화 사례와 마찬가지로 삼극자 패턴이 나타나는 특징이 있다. 단, 깊은 연직 온난화일 때는 그린란드 남쪽의 낮은 해수면온도가 남북으로 다소 확장되어 있으며 노르웨이해부터 바렌츠·카라해로 높은 해수면온도가 뚜렷하게 나타나지만, 얇은 연직 온난화일 때는 서유럽 해안으로 높은 해수면온도가 뚜렷하고 노르웨이해 부근으로는 뚜렷한 해수면온도 편차가 보이지 않는 점이 차이가 있다.

다음으로 상층 지위고도 패턴을 비교해보면 깊은 연직 온난화일 때에는 대서양과 우랄지역에 뚜렷한 양의 지위고도 편차, 그린란드 부근과 동아시아에 음의 지위고도 편차가

나타나고 북극을 통로로 한 파동 전파 패턴이 나타난다. 얇은 연직 온난화일 때에는 우랄지역에 음의 지위고도 편차, 동아시아 부근으로 양의 지위고도 편차가 나타나고 유라시아 대륙의 북부를 가로지르며 파동이 전파되는 모습을 볼 수 있다. 그러나 12월에는 이러한 지위고도 편차 패턴의 특징이 뚜렷하게 나타나지는 않는다. 상층 수평 바람 편차는 두 경우에 모두 고기압성 편차의 중심에서 약간 남쪽으로 약화가 나타나는 특징이 있다. 따라서 깊은 연직 온난화일 때 북대서양과 유라시아 대륙의 중북부를 중심으로 상층 수평 바람 편차의 약화가 나타나고, 얇은 연직 온난화일 때는 서유럽과 동북아시아 부근으로 상층 수평 바람 편차의 약화가 나타나는 차이가 있다.

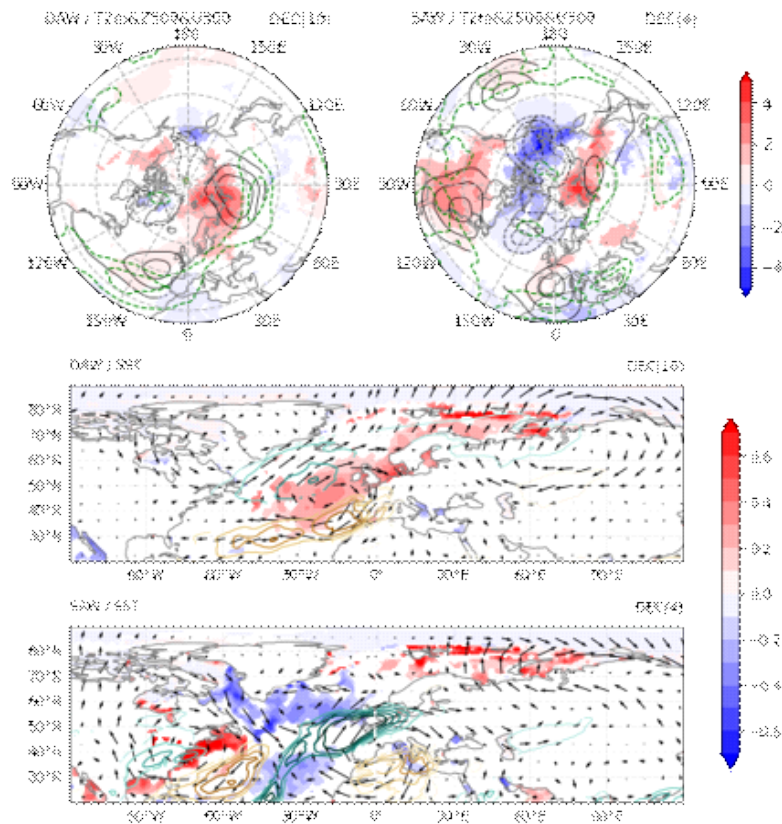


Figure 37. Composite maps of DAW and SAW during December. The first row shows the composite pattern of 2m temperature, 500hPa geopotential height, and 300hPa zonal wind. The second and third rows show the composite of sea surface temperature and vertically integrated moisture influx.

연직 수분 속 편차는 해수면온도와 상층 지위고도 편차의 상태와 연관되어 나타나며 바렌츠·카라해로 연직 수분 속의 유입은 상층 온난화를 유발하는 데 이바지한다. 깊은 연직 온난화일 때 그린란드 서쪽 부근에서 저기압성 순환, 우랄지역 부근으로 고기압성 순환이 나타나 그린란드 남쪽에서 노르웨�헤를 거쳐 바렌츠해로 수분속이 원활하게 유입되는 모습이

나타나고, 이로 인해 바렌츠·카라해의 상층 대기 온도가 높아진다. 반면 얇은 연직 온난화일 때는 유럽지역에 고기압성 순환이 강하게 발달하고 우랄지역으로는 저기압성 순환이 나타남에 따라 바렌츠해로의 수분속 유입이 원활하게 이루어지지 않아 바렌츠·카라해의 상층 대기까지 데워지지 않는다. 1월, 2월과 비교해 12월에는 유사한 바람 순환 패턴이 나타나기는 하지만 수분 유입량이 많지 않은 점이 눈에 띈다.

2m 기온의 합성장은 12월과 1월, 2월의 패턴에 차이가 두드러진다. 1월과 2월의 깊은 연직 온난화 합성장에서는 바렌츠·카라해를 중심으로 높은 기온 편차가 나타나며 중위도 유라시아 대륙과 동아시아 부근에서 낮은 기온 편차가 나타난다. 얇은 연직 온난화일 때에도 바렌츠·카라해를 중심으로 한 고온 편차가 유의하게 나타나기는 하지만 유라시아 대륙에 전반적으로 고온 편차가 동반되는 특징이 있다. 그러나 12월 합성장에서는 깊은 연직 온난화에 동반되는 유라시아와 동아시아 부근으로의 저온 편차가 유의하지 않고, 얇은 연직 온난화일 때에도 유라시아 대륙 전반에 기온 편차가 뚜렷하게 나타나지 않는다.

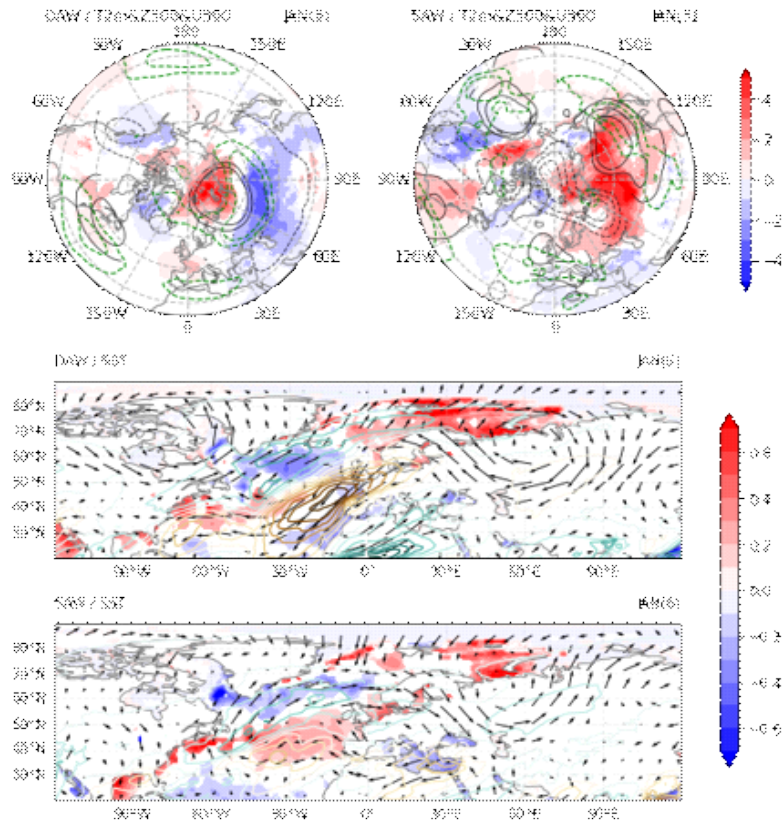


Figure 38. Same as Figure 37, but for January

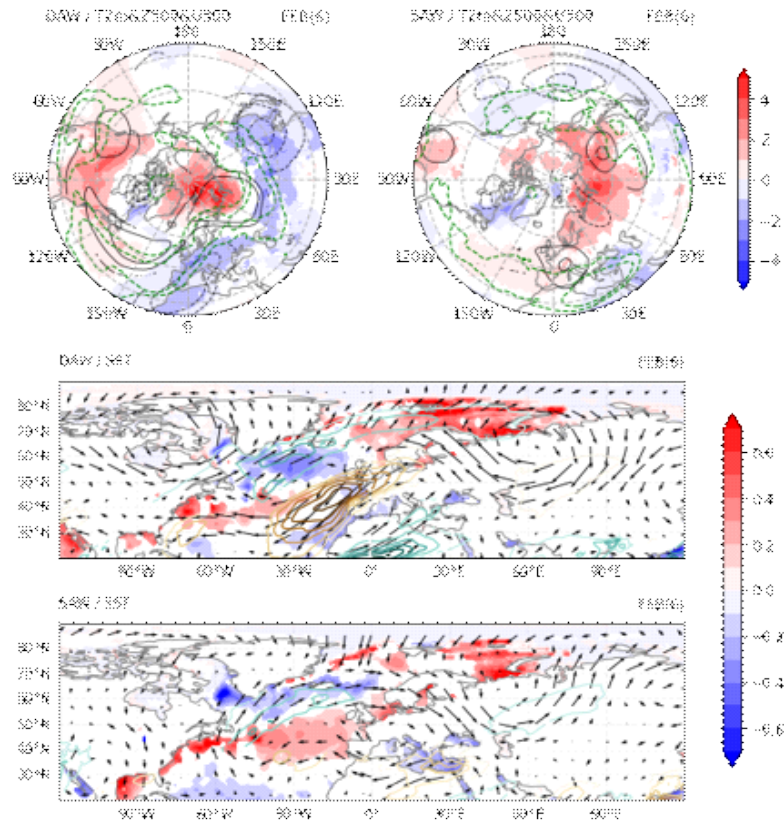


Figure 39. Same as Figure 37, but for February

깊은 연직 온난화와 얇은 연직 온난화의 월별 합성장을 분석해 본 결과 선행연구에서 밝혀진 겨울철 평균 북극 연직 온난화의 영향은 계절 내 1개월 규모에서 각각 다른 특징을 나타내었다. 특히 12월의 경우에는 북극 연직 온난화에 따른 동아시아의 기온 변동 반응이 뚜렷하지 않았으나, 1월과 2월에는 동아시아의 기온 변동 반응이 비교적 뚜렷하게 나타나기 때문에 북극 이벤트의 발생을 잘 감시하고 모델이 이벤트를 예측할 수 있다면 3개월 전망에서 겨울철 월별 기온 예측정보로 활용할 수 있을 것으로 보인다.

선행연구 결과와 합성장 분석을 통해 도출한 내용을 토대로 깊은 연직 온난화와 얇은 연직 온난화일 때 동아시아 기온이 반응하게 되는 메커니즘을 모식도로 나타내었다(Figure 40). 깊은 연직 온난화일 때는 대서양에서 동아시아로 북극을 통한 파동 전파가 나타나며 우랄지역으로 상층 고기압성 편차가 뚜렷하다. 이를 통해 바렌츠·카라해로 연직 수분속 유입이 활발해지면 상층까지 대기가 온난해지며 연직 보상 운동에 따라 동아시아 지역으로 상층에는 저기압이 나타나고 하층에는 저온 편차가 나타난다. 얇은 연직 온난화일 때는 유럽에서 동아시아로 대륙을 통한 파동 전파가 나타나며 우랄지역으로 상층 저기압성 편차가 뚜렷하게 나타나는데, 이로 인해 바렌츠·카라해로 연직 수분속의 유입이 저지됨에 따라 상층 대기로 온난한 공기가 전파되지 못하고 동아시아에 상층 고기압, 하층 고온 편차가 나타난다.

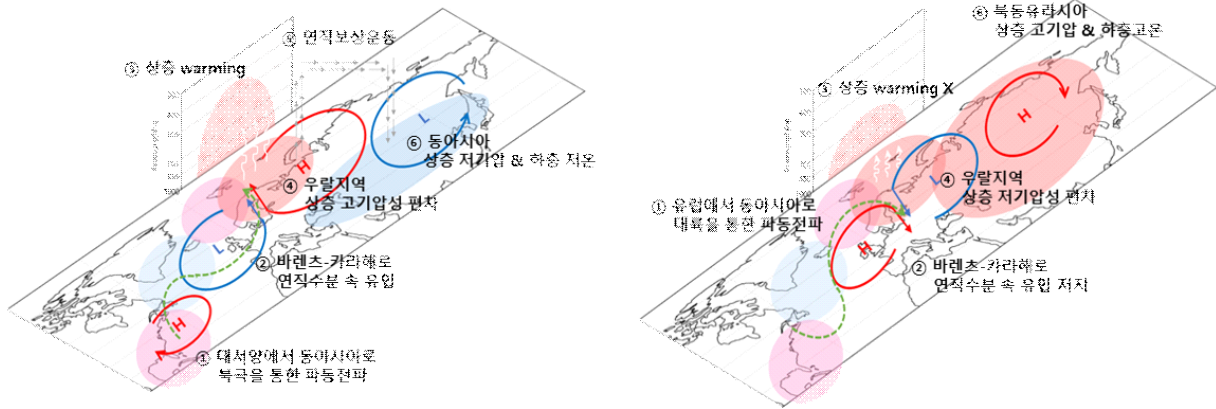


Figure 40. Schematic diagram of (left) deep arctic warming and (right) shallow arctic warming.

(나) 모델의 극지방 연직 기온 분포 및 동아시아 기온 반응 모의 성능 평가

북극 이벤트를 정의하는 데 있어 바렌츠·카라해의 500hPa 기온을 사용하였는데, 모델의 500hPa 기온 변수를 사용할 수 없는 관계로 500hPa 지위고도로 대체하여 사용할 수 있는지 살펴보았다. 재분석자료에서 생산한 바렌츠·카라해의 500hPa 기온과 지위고도 지수의 시계열 상관계수 구하였을 때, 12월은 0.69, 1월은 0.74, 2월은 0.64의 상관계수를 얻었다. 이를 통해 500hPa의 기온을 지위고도로 대체할 수 있다고 판단하고 모델 자료에서 500hPa 지위고도를 이용하여 분석을 수행하였다.

모델의 극지방 이벤트 예측성능을 알아보기에 앞서 지수를 산출할 바렌츠·카라해의 기온과 지위고도에 대한 시계열 예측성능을 살펴보았다. 검정 실선은 재분석자료, 색이 있는 실선은 개별모델, MME는 빨간색 점으로 표시하였으며, 월별로 2m 기온과 500hPa 지위고도에 대하여 표준화된 시계열 지수를 그래프를 나타내었다(Figure 41~43). 모든 월에서 2m 기온은 모델이 어느 정도 재분석자료와 비슷하게 변동 패턴을 모의하는 것으로 보인다. 그러나 상층 지위고도에 대해서는 모델들이 재분석자료에 나타나는 변동 패턴을 잘 모사하지 못하여 큰 변화폭 없이 0에 가까운 정도로 모의하는 것을 알 수 있다.




Figure 41. Time series of standardized (top) t2m and (bottom) Z500 anomalies over Barents-Kara Sea during December. Black solid lines indicate ERA5, colored lines indicate each model and red dots indicate MME.

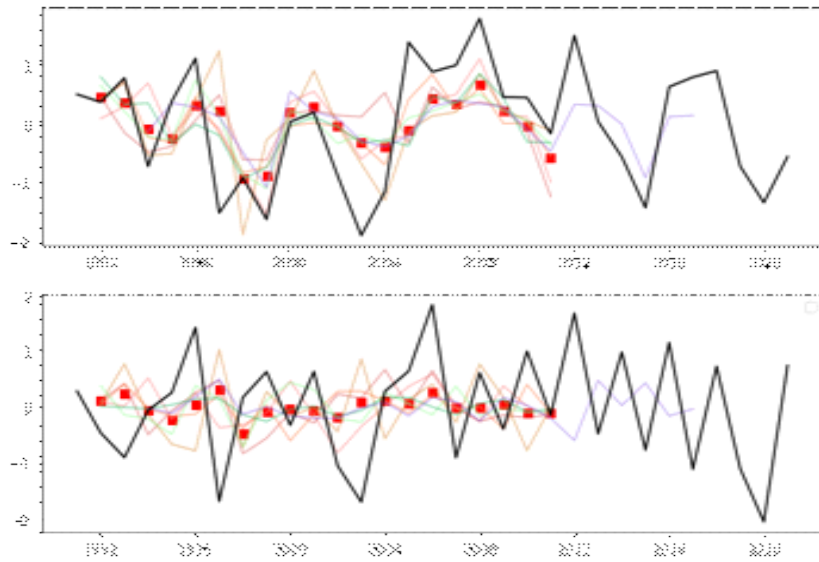


Figure 42. Same as in Figure 41, but for January.




Figure 43. Same as in Figure 41, but for February.

Table 12에 Figure 41~43에 나타난 시계열 그래프의 상관계수를 모델별로 나타내었다. 12월보다는 1월에, 1월보다는 2월에 모델들이 더 높은 상관성을 보여준다. 12월에는 2개 모델만 2m 기온과 유의한 상관계수를 나타내었고, 1월에는 6개 모델이, 2월에는 8개 모델 모두 유의한 상관계수를 나타내었다. 500hPa 지위고도에 대해서는 2m 기온에 비해 다소 낮은 상관계수를 나타내거나 되려 음의 상관계수를 나타내는데, 12월에는 모든 모델이 유의하지 않았고, 1월에는 1개 모델, 2월에는 5개 모델이 유의한 상관계수를 나타내었다. 이를 통해 모델들은 2월의 북극 이벤트를 가장 잘 모의할 수 있을 것으로 예상할 수 있다.

Table 12. Time series correlation coefficient of 2m temperature and 500hPa geopotential height over Barents-Kara Sea between reanalysis and models.

TCC	DEC		JAN		FEB	
	T2m	Z500	T2m	Z500	T2m	Z500
APCC	0.50	-0.25	0.62	0.47	0.56	0.24
JMA	0.21	0.21	0.16	-0.13	0.71	0.00
KMA	0.31	-0.05	0.78	-0.15	0.68	0.48
NASA	0.27	-0.05	0.43	-0.40	0.62	0.56
NCEP	0.31	0.01	0.70	0.03	0.60	0.56
PNU	0.65	-0.14	0.57	0.12	0.76	0.09
ECMWF	0.24	-0.19	0.65	-0.38	0.55	-0.16
MME	0.42	-0.09	0.65	-0.14	0.72	0.75

다음으로 북극 이벤트의 정의에 따라 모델 앙상블 평균에서 북극 이벤트를 월별로 Figure 44와 같이 구분하였다. ECMWF를 제외한 나머지 개별모델들은 1991년부터 2010년까지 (1월은 1992년부터 2011년까지), ECMWF는 1993년부터 2016년까지의 재현기간에 대해 분석하였으며, MME는 되도록 많은 수의 모델이 참여할 수 있는 1991년부터 2010년 (1월은 1992년부터 2011년) 기간을 사용하였다. 재분석자료와 비교해 모델 앙상블에서는 동아시아 기온 변동성이 뚜렷하게 나타나지 않는다. 북극 이벤트에 대한 동아시아의 기온 반응은 내부변동성에 의해 상당 부분 설명되는데, 같은 모델 내에서도 앙상블 멤버에 따라 반응이 다르게 나타날 수 있기 때문이다(Ogawa et al. 2018; Matsumura and Kosaka 2019; Warner et al. 2020).




Figure 44. Arctic events and 2m temperature anomaly over East Asia from each model and from reanalysis during January as an example. Reanalysis column presents the same as in Figure 35.




Figure 45. Scatter plot of categorical predictability of arctic events by month.

모델에서 구분해 낸 북극 이벤트에 대해 Table 3에 따라 ACC와 HSS를 구하여 산포도로 나타내었다(Figure 45). ACC는 0.6 이상, HSS는 0.2 이상에서 모델이 이벤트를 유의하게 구분할 수 있다고 평가할 때, 12월은 어느 모델도 북극 이벤트를 유의하게 구분해내지 못하였지만, 1월과 2월에는 KMA 모델과 MME가 북극 이벤트를 잘 구분해 낼 수 있는 것으로 나타났다.

북극 이벤트가 발생했을 때 동반되어 나타나는 북반구의 대기 반응 패턴에 대한 예측성능도 살펴보았다. 재분석자료를 통해 살펴보았을 때 깊은 연직 온난화가 발생한 1월과 2월에 가장 높은 확률로 동아시아에 한파가 나타났기 때문에, 각 모델의 전체 앙상블 중에서 깊은 연직 온난화를 모의한 경우를 모두 모아 합성장을 생산하였다(Figure 46~48). 모델들은 시기와 관계없이 깊은 연직 온난화를 예측하는 경우 북반구에 warm arctic-cold continent 패턴을 모의하는 경향이 있다. 이로 인해 12월의 경우 재분석자료에서는 바렌츠·카라해와 우랄 부근으로 하층 고온 편차와 양의 지위고도 패턴이 나타나더라도 동아시아에 뚜렷한 하층 저온 편차와 음의 지위고도 패턴이 나타나지 않았지만, 모델들은 대부분 유라시아 내륙 지역과 동아시아를 중심으로 뚜렷한 하층 저온 편차와 상층 저기압성 편차를 모의한다. MME는 전체 앙상블을 평균한 각 모델의 예측 결과를 다시 모델 간 평균하는 과정을 거치면서 내부변동성에 대한 시그널이 크게 상쇄되어 바렌츠·카라해 부근으로의 고온 편차는 남아있지만, 중위도에서는 뚜렷한 시그널이 나타나지 않는다.

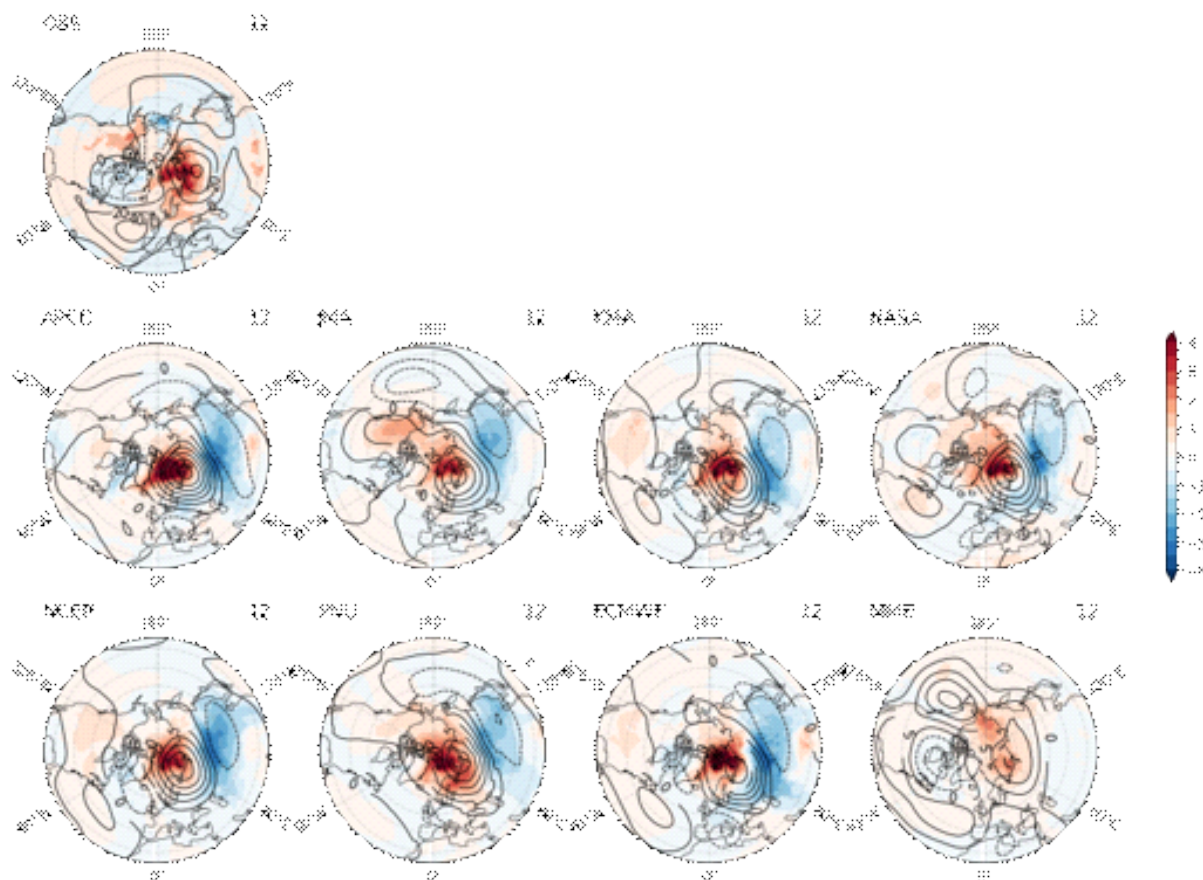


Figure 46. Composite maps of (shade) 2m temperature and (contour) 500hPa geopotential height from reanalysis and models during December.

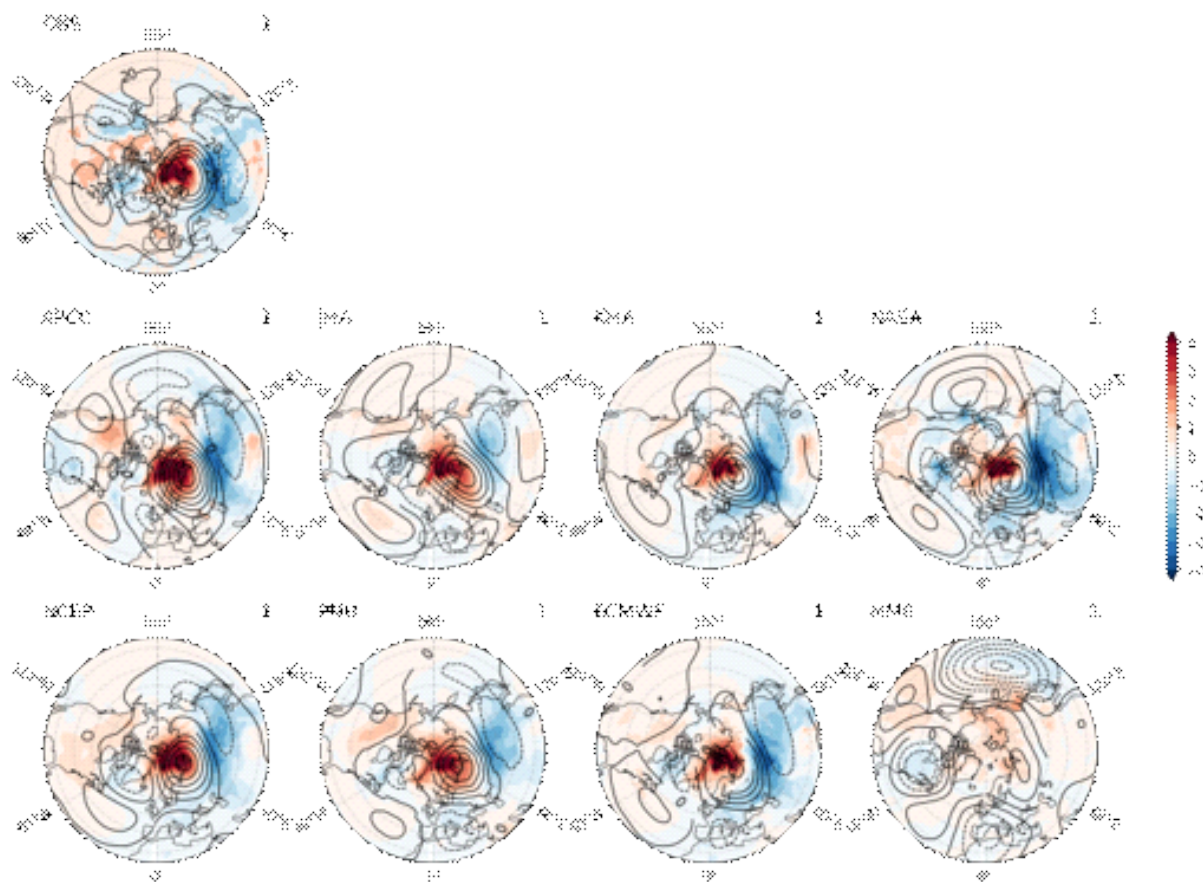


Figure 47. Same as in Figure 46, but for January.

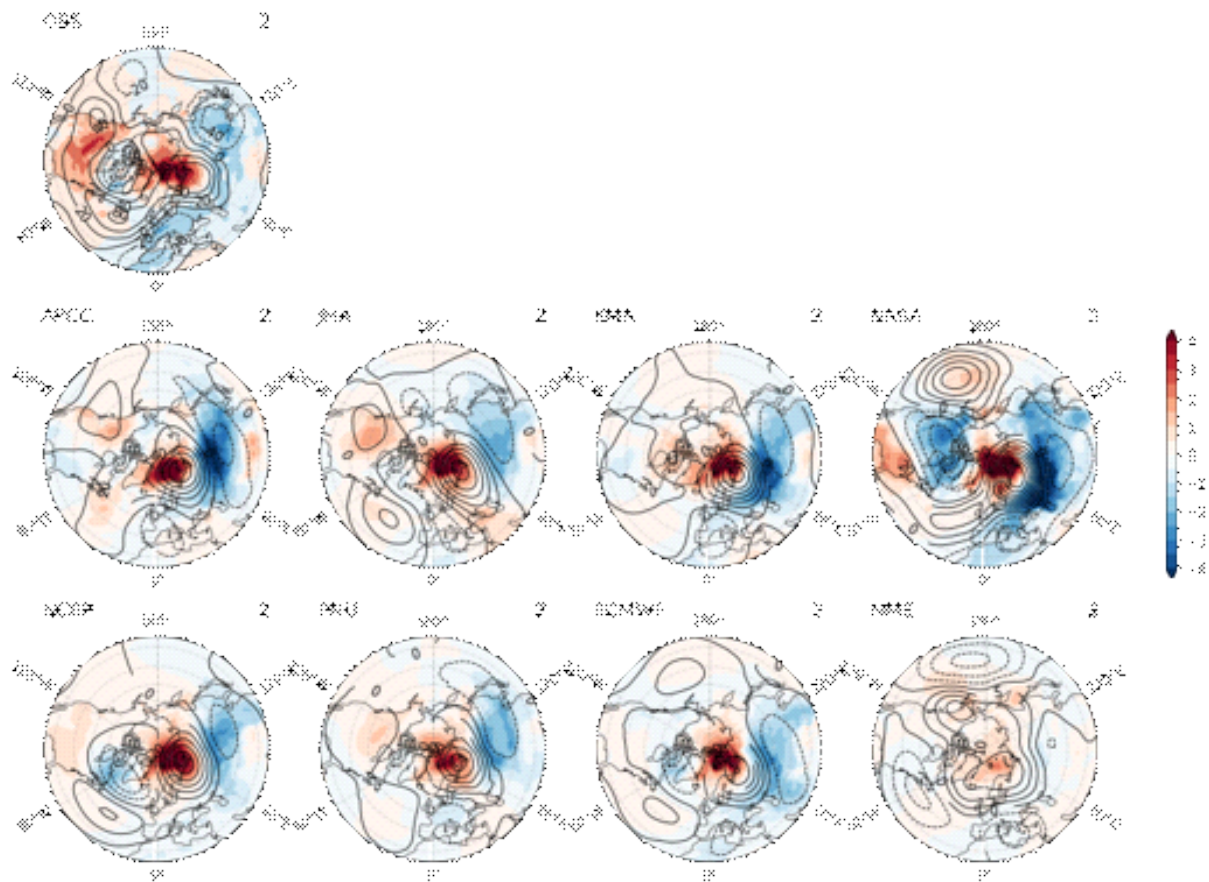


Figure 48. Same as in Figure 46, but for February.

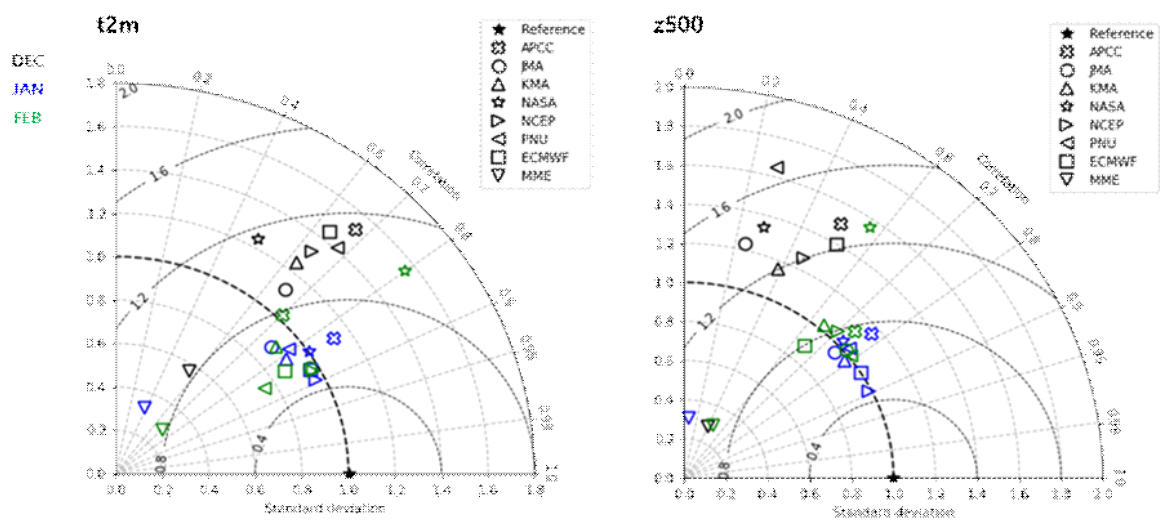


Figure 49 Taylor diagram of 2m temperature and 500hPa geopotential height over the northern hemisphere during deep arctic warming events. Black markers indicate December, blue markers indicate January, and green markers indicate February. Reference is marked as filled black star at 1.0 of standard deviation axis.

Figure 46~48을 바탕으로 북반구 2m 기온과 500hPa 지위고도 편차의 합성장에 대한 예측성능을 테일러 다이어그램으로 나타내었다(Figure 49). 기준점을 검정색 채워진 별 모양으로 표시하였고, 각 모델에 대해 12월은 검정색, 1월은 파란색, 2월은 초록색으로 표시하였다. 12월 깊은 연직 온난화 합성장 패턴에 대해 모델들은 2m 기온에서는 0.7 이하의 패턴 상관계수를 나타내었고, 500hPa 지위고도에서는 그보다 낮은 0.6 미만의 패턴 상관계수를 나타내었으며, 재분석자료 보다 높은 표준편차값을 가지며 모델 간의 차이도 다소 크게 나타난다. 다른 월에 비해 12월에 모델들의 예측성능이 눈에 띄게 낮은 이유는 모델들이 재분석자료에 나타나지 않는 warm arctic-cold continent 패턴을 나타내기 때문으로 보인다. 1월과 2월에는 12월과 비교해 성능이 높아졌는데 2m 기온의 패턴 상관계수는 1월과 2월 모두 0.7~0.9 사이에 분포하고, 500hPa 지위고도의 패턴 상관계수는 1월에는 0.6~0.8 사이, 2월에는 0.7~0.9 사이에 분포한다. 표준편차는 두 변수 모두 0.4~0.8 정도로 나타난다. 2월 예측에서 NASA 모델은 다른 모델들과 다소 동떨어진 예측성을 보인다. 2m 기온의 패턴 상관계수는 다른 모델들과 유사하지만, 표준편차가 큰 편에 속하고, 500hPa 지위고도는 다른 모델들보다 패턴 상관계수가 낮고 표준편차도 크다. MME에서는 앞서 언급한 바와 마찬가지로 깊은 연직 온난화에 따른 북반구의 대기 패턴 시그널을 잘 나타내지 못해 모든 월에서 예측성능이 낮게 나타나는 것을 볼 수 있다. 1월의 NCEP과 ECMWF가 두 변수 모두 가장 잘 예측하였고, 2월은 NCEP과 JMA가 2m 기온 패턴을 가장 잘 예측하였고, 500hPa 지위고도 패턴은 모든 모델이 비슷한 예측성능을 보인다.

(다) 종관규모에서 기온 급강하 사례 분석

He et al. (2020)에서는 지연 상관관계를 통해 종관규모에서 북극 연직 온난화와 연관된 대기순환 패턴의 변화를 제시하였다. 선행연구를 바탕으로 2022년 초 우리나라에 수일 이내 기온이 크게 떨어졌던 사례가 깊은 연직 온난화와 관련이 있는지 살펴보았다.




Figure 50. Time series of temperature anomalies in South Korea (yellow) and sea ice extent in Barents (blue) and Kara (turquoise) from 1 January to 28 February.




Figure 51. Vertical distribution of temperature anomalies over Barents sea from 1 December to 28 February.

2022년 1월 1일부터 2월 28일까지의 바렌츠해와 카라해의 해빙 면적, 우리나라 기온 관측자료를 Figure 50에 나타내었다. 1월 하순과 2월 중순에 기온이 큰 폭으로 떨어지는 시기가 있는데, 같은 기간에 바렌츠해와 카라해의 해빙 면적도 빠르게 줄어드는 것을 알 수 있다. 비슷한 시기에 바렌츠해의 기온 연직 분포를 살펴보면 하층에서부터 상층으로 양의 기온 편차가 확장하는 모습을 볼 수 있다(Figure 51). 이를 통해 이 시기에 깊은 연직 온난화가 발생했을 가능성이 있음을 확인하였고, 선행연구에 따라 관련된 대기 순환 패턴에 대한 시계열 변동을 그래프로 나타내었다(Figure 52). 보라색 실선은 우랄지역의 500hPa 지위고도 편차, 분홍색 계열 실선은 각각 우랄지역의 동쪽과 서쪽에서의 해면기압 편차, 주황색(노란색) 실선은 바렌츠·카라해의 500hPa(2m) 기온 편차, 청록색 실선은 중위도 유라시아의 300hPa 수평 바람 편차, 마지막으로 하늘색 실선은 우리나라의 지상 기온 편차를 나타낸다. 모든 시계열 편차는 표준화하여 5일 이동평균 하였다. 때에 따라 차이가 있기는 하지만 선행연구에서는 우랄지역 동쪽의 해면기압이 최성기에 달한 후에 깊은 연직 온난화가 최성기에 달하고, 그 뒤를 이어 우랄지역 서쪽의 해면기압이 더욱 강화된다고 밝혔다(Tyrlis et al. 2019). 이는 깊은 연직 온난화와 우랄블로킹이 상호 작용함을 의미한다.

1월 하순 사례에서는 바렌츠·카라해 2m 기온의 최정점이 나타나기 전에 500hPa 기온이 먼저 최정점을 나타내었고, 그 사이에 우랄지역에서 고기압성 편차가 가장 강하게 발달하였다. 바렌츠·카라해 2m 기온이 최정점에 달할 때 중위도에서 상층 수평 바람이 가장 약하게 나타났고, 그 후 수일 이내 우리나라 기온이 최하점에 달했다. 2월 중순 사례에서도 비슷한 흐름이 나타난 후에 우리나라 기온이 크게 떨어지는 것을 확인하였다.




Figure 52. Time series of anomalies associated with deep arctic warming event: area-averaged anomalies of 500hPa geopotential height in Ural sector, SLP anomalies in the west and east of Ural sector, SAT and 500hPa temperature anomalies over Barents-Kara sea, 300hPa zonal wind anomalies at mid-latitude, and 2m temperature anomalies over South Korea. Left panel is for January and right panel is for February. All indexes are calculated a 5-day moving average.

3~4월의 기온 급강하 사례에 대한 해빙 면적과 기온 편차, 연직 기온분포, 깊은 연직 온난화와 관련된 대기순환장 패턴의 흐름을 그림 53~55에 나타내었다. 3월 중순과 4월 중순에 우리나라 기온이 큰 폭으로 떨어지는 시기가 있었고, 3월 중순에는 같은 시기에 바렌츠해와 카라해의 해빙 면적도 급격하게 줄어들었다. 4월 중순에 나타난 사례에서는 바렌츠해의 해빙은 줄어들었으나 카라해 해빙 면적에는 변화가 없었다. 바렌츠해의 연직 기온 편차 분포를 살펴보면 3월 중순에 하층에서부터 강한 양의 기온 편차가 나타나고, 4월 중순에는 약한 양의 기온 편차가 하층에서 상층으로 전파되는 모습과 성층권의 강한 양의 기온 편차가 하층으로 전파되는 모습이 동시에 나타난다.




Figure 53. Time series of temperature anomalies in South Korea (yellow) and sea ice extent in Barents (blue) and Kara (turquoise) from 1 March to 30 April.




Figure 54. Vertical distribution of temperature anomalies over Barents sea from 1 March to 30 April.

3~4월 사례에서는 1~2월 사례에서 더욱 뚜렷하게 우랄지역 동쪽에서 발달한 하층 고기압성 순환이 우랄지역 서쪽으로 이동하면서 우랄블로킹이 강화되는 것을 볼 수 있다. 5일 이동평균 시계열에서 바렌츠·카라해의 상층 기온이 먼저 높아지고 난 후에 하층 기온이 높아지는 모습이 나타나고, 이어서 중위도 상층 수평 바람의 약화, 그리고 우리나라의 저온 편차가 발생하는 모습이 잘 나타났다. 3~4월 사례 분석을 통해 꼭 겨울철이 아니더라도 북극 연직 온난화로 인해 우리나라에 기온이 급격하게 떨어지는 현상이 나타날 가능성이 있음을 알 수 있었고, 이른 봄철에도 북극 영향에 의한 기온 하강에 관한 추가 연구 필요성을 시사한다.




Figure 55. Same as in Figure 52, but for (left) March and (right) April.

(3) 우리나라 월별 기온/강수 예측성 향상을 위한 우수모델 선정 및 예측성 분석

(가) 여름철 북서태평양고기압 및 기온/강수 예측

① 북서태평양고기압 경년 변동

우리나라는 여름철 몬순의 영향을 강하게 받는다. 여름철 몬순과 관련하여 열대 지역의 강한 몬순 기압골은 여름철 동아시아 몬순의 시작(onset)과 관계가 있다. 또한, 여름 몬순과 관련하여 북태평양고기압의 강도, 모양 위치는 여름철 동아시아 몬순 강수와 밀접한 관계가 있다. 아열대 장마 전선은 동아시아 여름 몬순의 계절 변화와 관계가 깊다. 그리고 상층 서풍제트의 경우 강수대의 이동과 관련이 있다 (Figure 56).

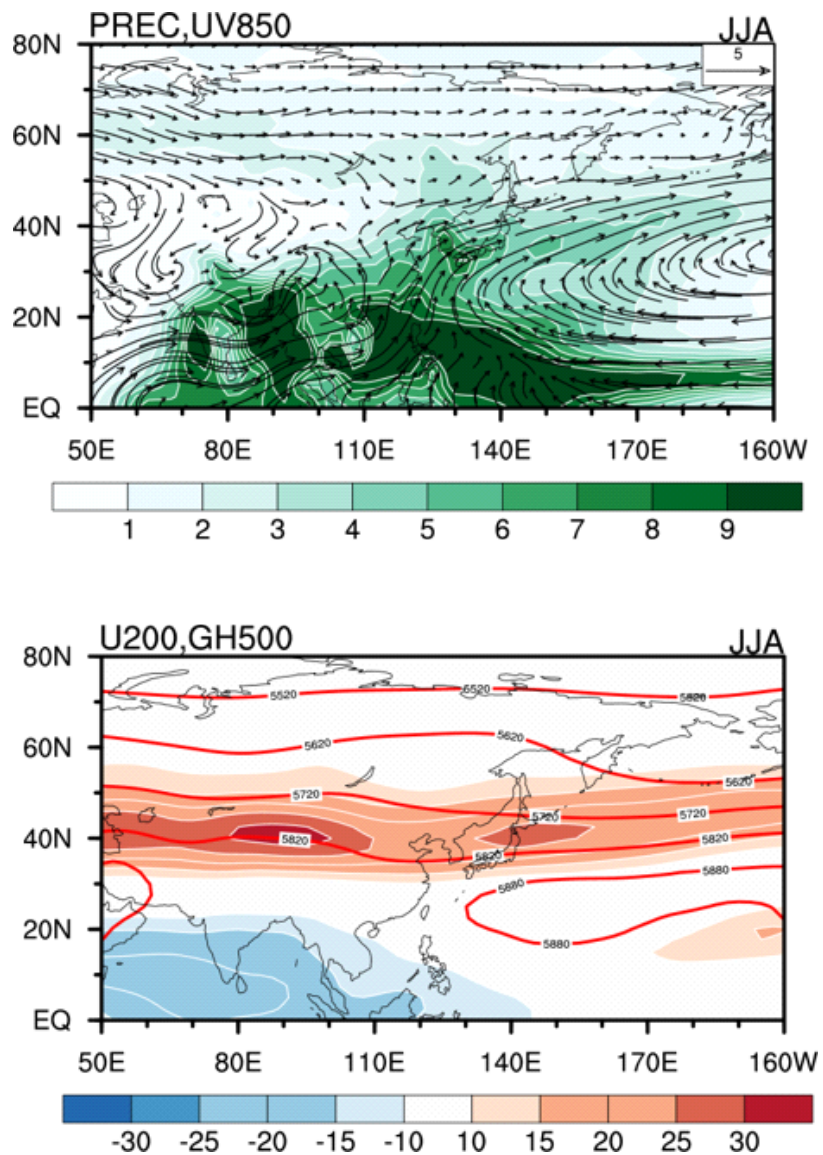


Figure 56. (Up) climatological precipitation with lower-level winds, and (down) 200hPa upper-level zonal winds and 500hPa geopotential height.

동아시아 여름철 강수량의 연변동성 및 500hPa 지위고도의 기후학적 분포를 Figure 57에 나타냈다. 강수량의 연변동성이 큰 지역이 주로 5,880gpm의 서쪽 가장자리를 따라 나타나므로, 북서태평양지역의 북서태평양고기압의 인자로 활용할 수 있음을 보여준다. 강수량 연변동성은 우리나라, 일본, 중국 서쪽 지역등 동아시아 지역에서 높게 나타난다. 따라서 북서태평양의 경년 변동은 동아시아 지역의 여름철 강수량과 밀접한 관계가 있다.

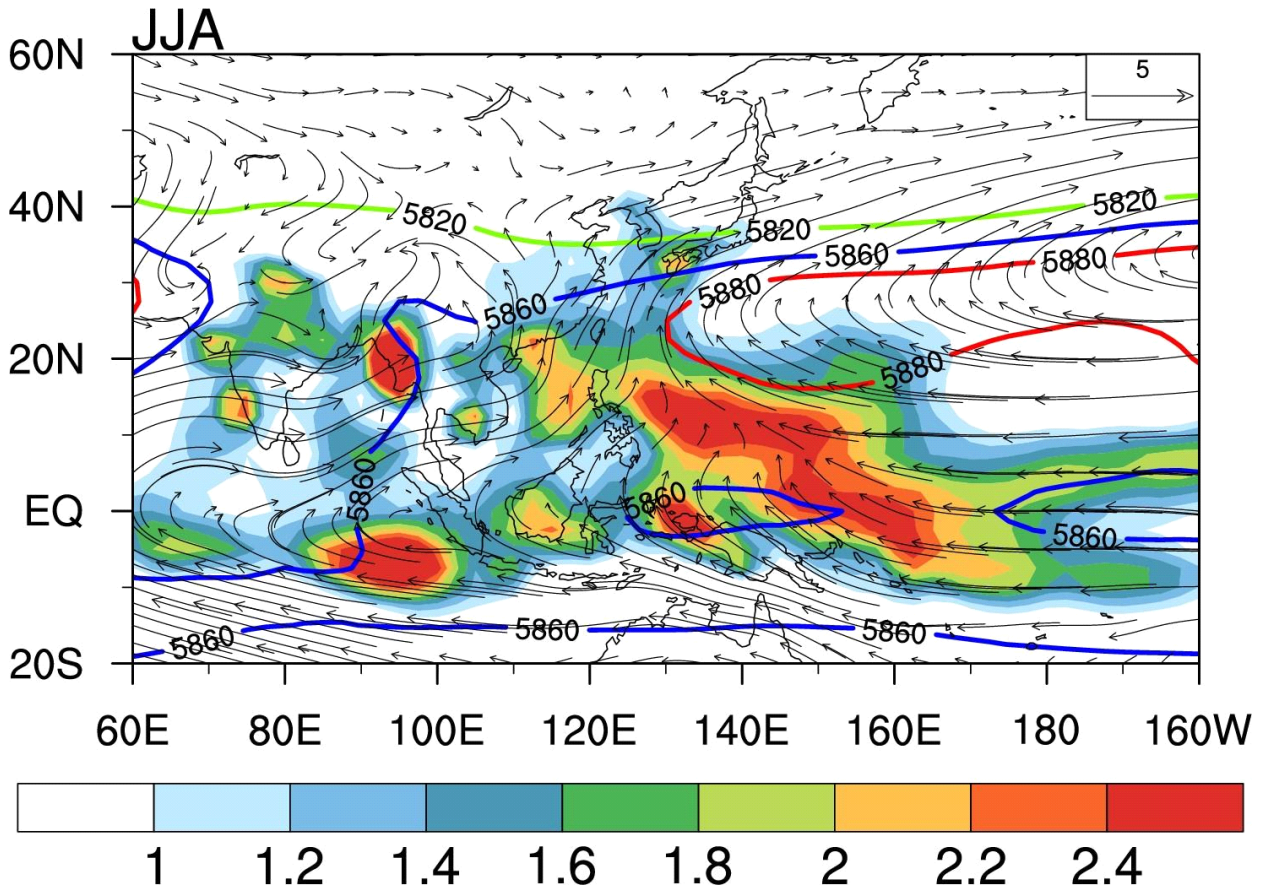


Figure 57. Interannual variability of precipitation, climatological position of several fixed geopotential height at 500hPa, and low-level wind vectors at 850hPa for 22 years (1993~2014).

Figure 58에서 보았던 강수 및 500hPa 지위고도, 850hPa의 바람장에 대해 월별 변동성도 함께 살펴보았다. 6월에는 북서태평양고기압을 나타내는 5,880gpm의 위치가 동쪽으로 수축되어 있으며, 7~8월이 되면서 점차 서쪽으로 확장한다. 또한, 7~8월에 북서태평양고기압 남서쪽 가장자리를 따라 강수 변동성이 매우 큰 것을 알 수 있다. 6~8월 여름철 평균장과 비교했을 때, 월별 강수 변동성이 비교적 큰 것으로 보이며, 특히 늦여름 강수 변동성이 매우 큰 것을 알 수 있다.

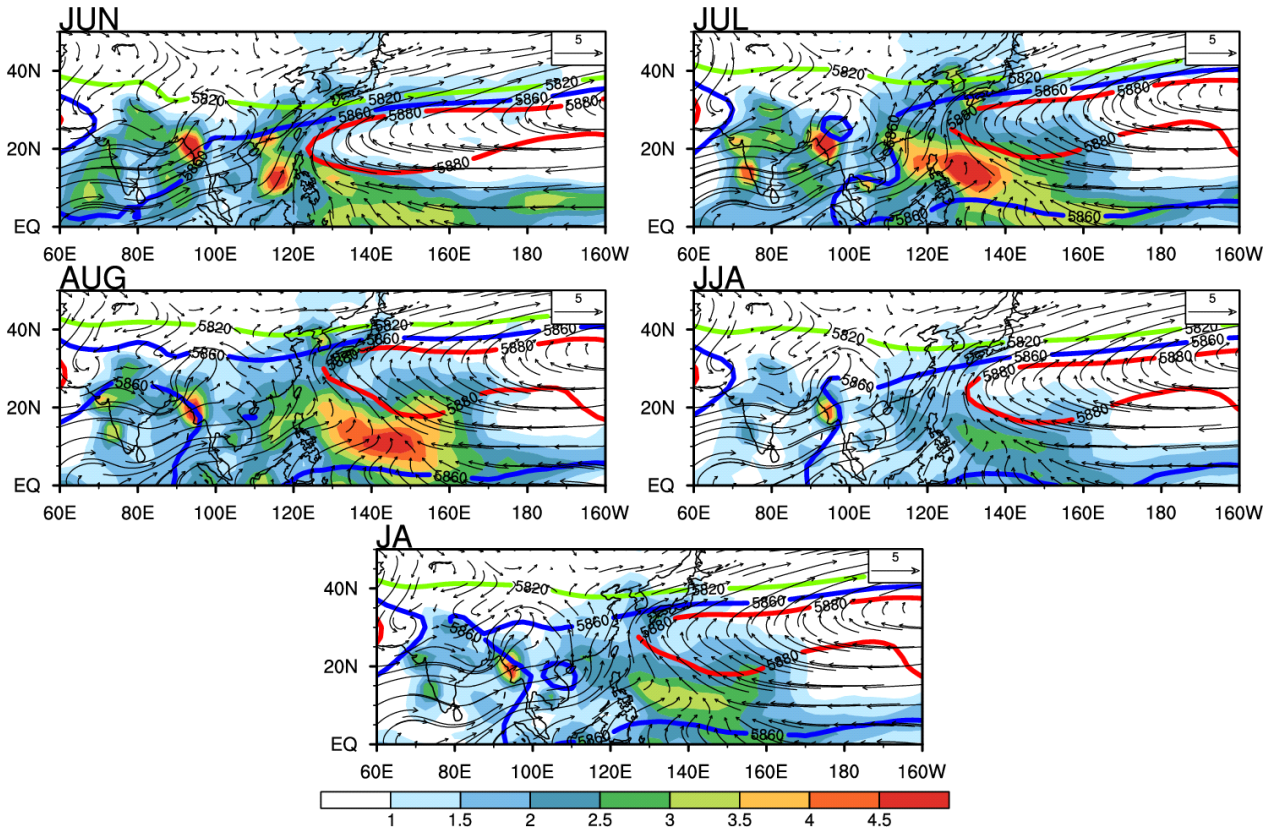


Figure 58. Monthly interannual variability of precipitation, climatological position of several fixed geopotential height at 500hPa, and low-level wind vectors at 850hPa for 22 years (1993~2014).

앞서 보았듯이 북서태평양고기압의 변동성을 표현하기 위해 500hPa의 지위고도가 중요함에도 불구하고, 어느 특정 지위고도선(예, 5,880gpm line)에 대해 모델과 관측을 직접 비교하는 것은 어렵다. 이는 대기-해양 결합모델에서의 평균적인 지위고도는 관측과 차이를 나타내기 때문이다. 따라서 이 연구에서는 0-북위 45도에 걸친 동서방향 평균한 지위고도에 대한 편차로 관측과 모델의 북태평양고기압 변동성을 비교하였다. Figure 59를 보면, M1과 M6는 서쪽으로 확장된 기후학적 지위고도 분포를 모의하는 반면, 다른 모델은 동쪽으로 수축된 지위고도 분포를 모의한다. 하지만 이러한 바이어스에도 불구하고, 500hPa 지위고도의 기후학적 편차에 대한 전체 공간 상관분포를 보면, 0.8~0.9 정도로 매우 높게 나타났다. 기후학적 분포뿐 아니라, 북서태평양고기압 중심에서 동풍으로부터 서풍으로의 하층바람장 변화도 대부분 잘 모의한다. 특히, M5 모델의 경우 북태평양 지역에서 500hPa 지위고도 및 850hPa 하층 바람장 분포를 가장 잘 모의하는 것으로 나타났다. APCC MME 참여모델의 결과를 ECMWF 모델 예측결과와 비교했을 때, 일부 모델의 경우 유사한 모의 성능을 나타내었다 (Figure 60). 이 연구에서 살펴본 대부분의 모델들은 북태평양 지역에서 500hPa 지위고도 및 850hPa 하층 바람장 분포를 어느정도 잘 모의하는 것으로 나타난바, 지위고도장 편차장을 북서태평양고기압 변동성 분석에 주요 인자로 활용하였다.

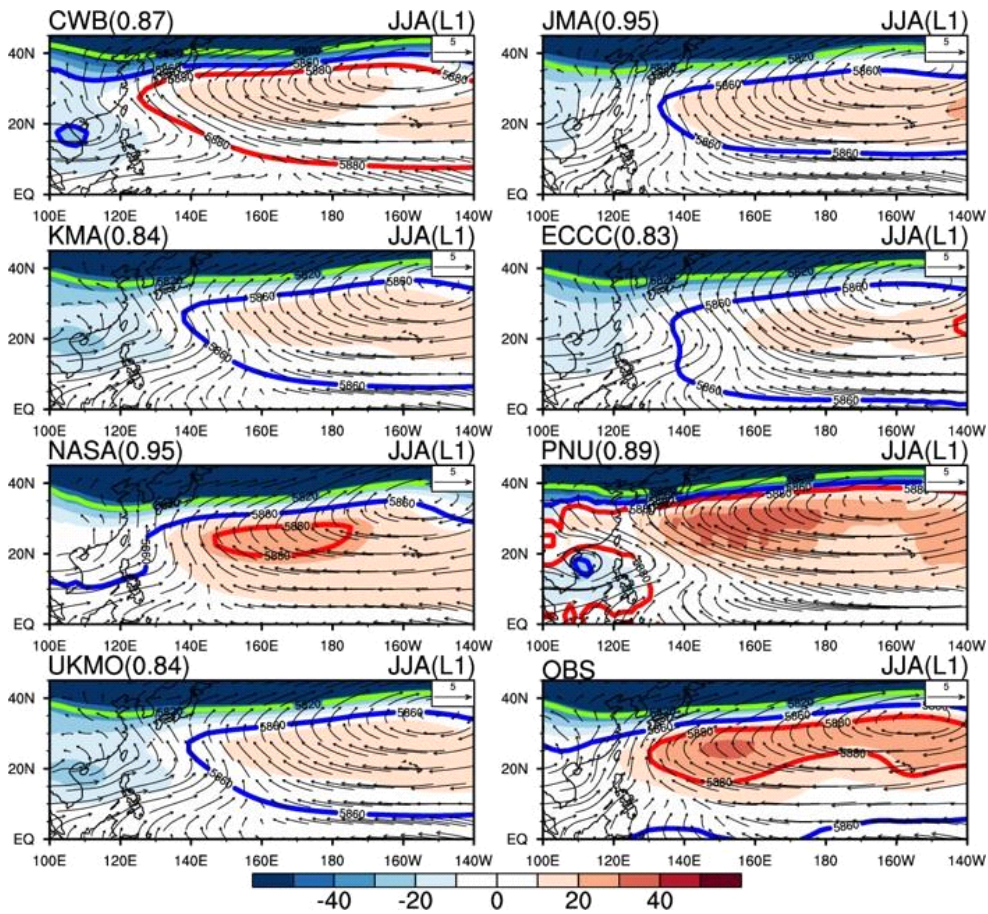


Figure 59. Summer climatological position of several fixed geopotential heights at 500hPa (contour), geopotential height deviation (shading) from its zonal mean, and wind fields at 850hPa; M1-M7 indicate each model used in this study and numbers in parentheses present pattern correlation of the climatological geopotential height deviation over the region.

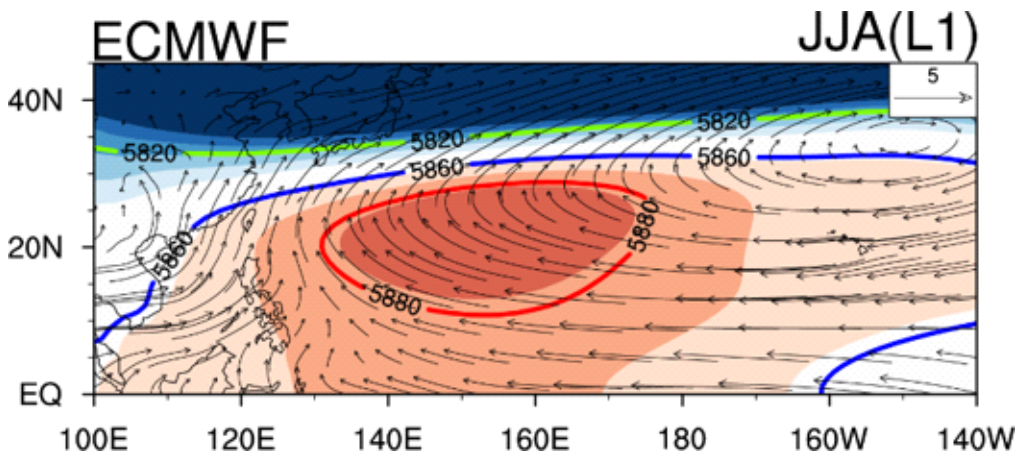


Figure 60. Summer climatological position of several fixed geopotential heights at 500hPa (contour), geopotential height deviation (shading) from its zonal mean, and wind fields at 850hPa from ECMWF.

② 북서태평양고기압에 대한 모델 재현성

앞서 살펴본 바와 같이, 모델이 북서태평양고기압 변동성을 얼마나 잘 모의하는지 분석하기 위하여, 500hPa 편차장, 북서태평양고기압 서쪽 가장자리 위치, 강도 및 최대 강도 등을 살펴보았다. Figure 61은 22년(1993~2014)의 과거재현기간(hindcast)에 대해 북서태평양고기압 재현성을 각 지수별로 살펴본 것이다. 전체적으로 각 모델은 북서태평양고기압의 강도와 최대강도를 잘 모의하는 것으로 나타났는데, 관측과의 상관계수가 0.7 이상이다. 또한 500hPa 지위고도 편차장도 비교적 잘 모의하였으며, 상관계수가 0.37~0.60로 비교적 모델간 편차가 크게 나타났다. 다른 지수와 비교해 전반적으로 각 모델은 북서태평양고기압의 서쪽 가장자리를 모의하지 못하였는데, KMA와 UKMO는 비교적 가장자리의 연변동성을 잘 모의하는 거로 나타났다. 특히, 이 두 모델에서 모의하는 북서태평양고기압의 기후학적 위도가 관측과 매우 가까운 것으로 나타나 (북위 28.3), 이것이 북서태평양고기압의 서쪽 가장자리에 대한 연변동성을 잘 모의하는 데 영향을 끼친 것으로 보인다. 북서태평양고기압의 가장자리가 어디에 위치하느냐는 동아시아 지역 및 북서태평양의 강수와 밀접한 관계가 있기 때문에, 북서태평양고기압의 서쪽 가장자리를 얼마나 잘 모의하는가는 이 지역의 여름철 강수량 예측을 향상시키는데 크게 기여할 수 있을 것이다.

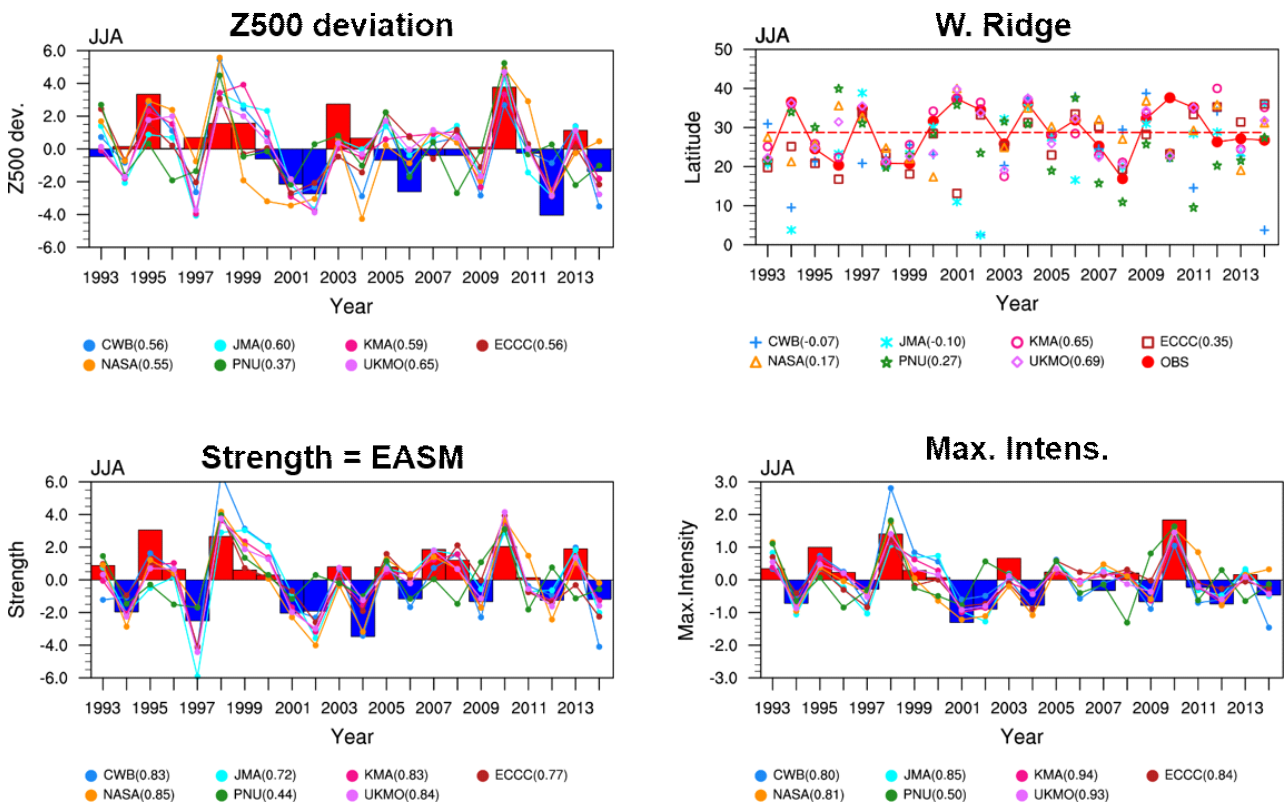


Figure 61. Time-series of Z500 deviation in the WNP, western ridge, strength and maximum intensity to represent the interannual WNPSH variability.

북서태평양고기압에 대한 모델 간 재현성을 직관적으로 비교하기 위하여, 위에서 언급한 네 가지 지수에 대한 관측과의 상관계수와 RMSE를 각각 비교하였다 (Figure 62). UKMO는 모

든 지표에서 북태평양고기압의 변동성을 잘 모의하는 것으로 나타났다 (높은 상관계수와 낮은 RMSE). 반면, PNU 및 CWB 모델의 경우 다소 CORR이 낮고 RMSE는 크게 나타나서, 예측성이 떨어지는 것으로 나타났다. 다시 말해, KMA와 UKMO 모델은 북태평양고기압에 대한 Z500 편차, 강도, 서쪽 가장자리, 최대 강도 등을 모두 잘 모의하는 것으로 나타났으며, PNU 및 CWB 모델은 그에 비해 모의 능력이 떨어지는 것으로 나타났다. KMA와 UKMO 모델은 ECMWF 보다 북서태평양고기압을 더 잘 모의하는 것으로 나타났다. 따라서 KMA와 UKMO를 MME-A, PNU와 CWB를 MME-B로 나누어 두 그룹간 변동성 오차를 파악하고자 한다.

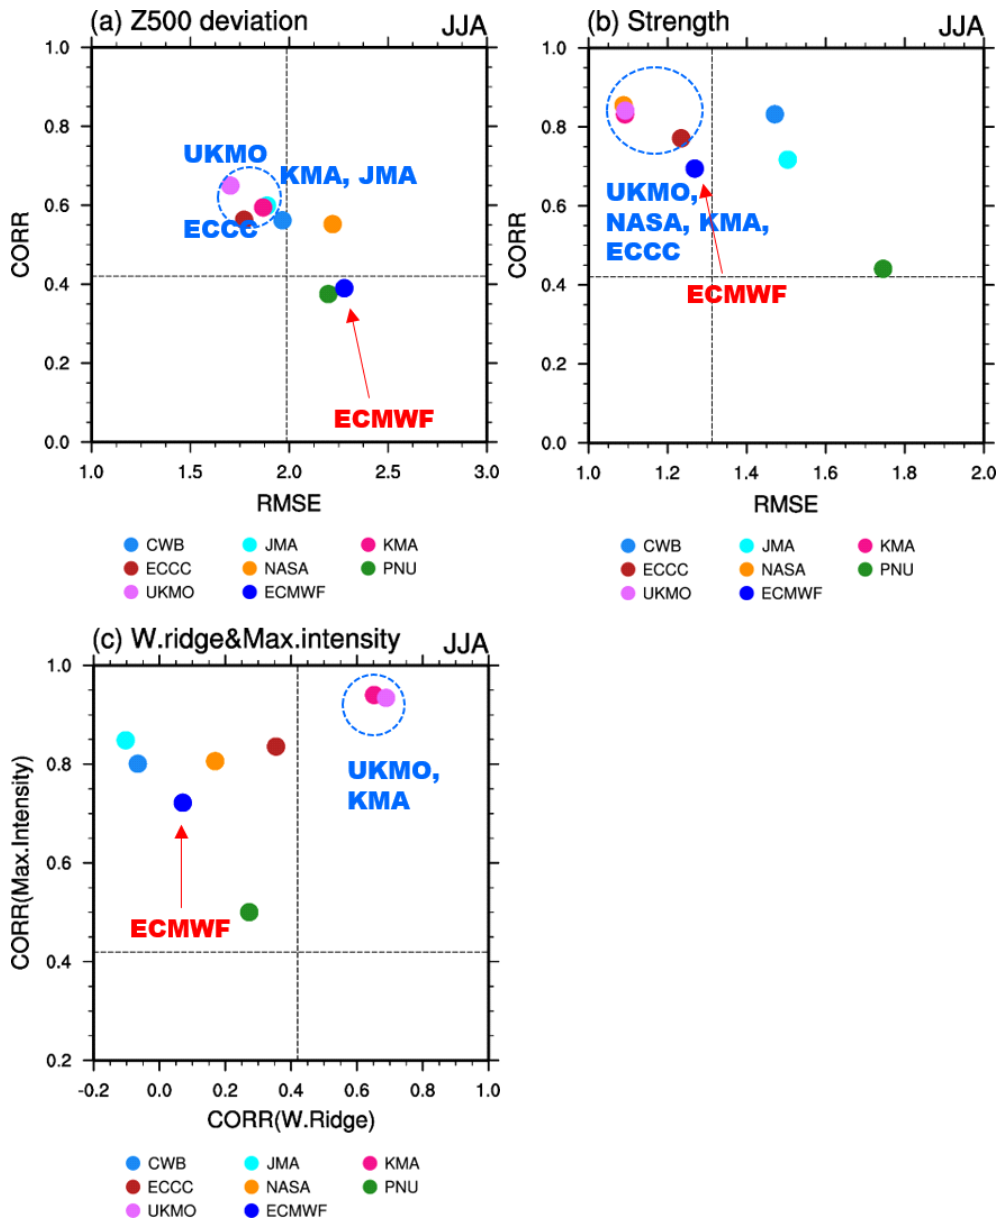


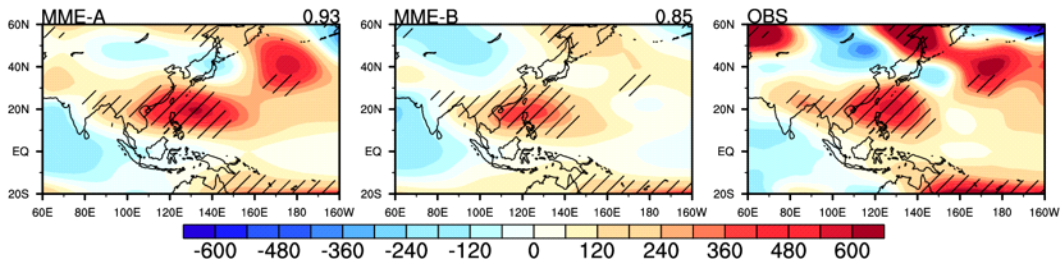
Figure 62. Scatter plot of (a) correlation coefficients (CORR) and root-mean-square error (RMSE) for Z500 deviation in the WNP, (b) CORR and RMSE for strength, and (c) CORR for western ridge and maximum intensity to represent the interannual WNPSH variability.

두 모델 그룹간 북서태평양 연변동성 모의 오차를 살펴보기 위하여, 관측 북서태평양고기압 강도 지수를 각 모델 그룹의 500hPa 지위고도, 강수, 850hPa 바람, 200hPa 속도퍼텐셜에 각각 회귀분석하였다. MME-A 그룹은 북서태평양 지역의 뚜렷한 고기압성 순환을 나타내며, 이는 관측과 매우 유사하게 나타났다. 반면, MME-B 그룹에서는 이러한 고기압성 순환이 매우 약하게 나타났다.


북반구 여름철에는 이전 겨울철 엘니뇨의 급격한 쇠퇴와 함께 동태평양 지역에 있던 상층 발산장이 사라진다. 반면, 열대 인도양에서는 상층의 강한 발산장이 나타난다. 인도양 해수면온도는 북반구 여름철 북서태평양 지역 순환과 밀접한 관계가 있다. 각 모델 그룹에서 해수면온도에 대한 워커 순환을 살펴보기 위하여 회귀분석된 속도퍼텐셜과 상층 발산장을 Figure 63과 같이 살펴보았다. MME-B 그룹과 비교해, MME-A 그룹은 관측과 더욱 유사한 크기와 강도를 나타냈다. MME-B 그룹에서의 오차가 명백한데, 이는 인도양에서는 발산장과 중앙태평양에서의 수렴장을 다소 약하게 모의하기 때문이다.

MME-A 그룹에서는 동아시아 몬순지역의 강한 남서풍이 뚜렷하게 나타났으며, 이는 관측과의 유사하다. 반면, MME-B 그룹은 동아시아지역에서 남서풍이 다소 약하게 나타났다. 또한 MME-A 그룹에서는 북서태평양지역에서의 강수 억제와 동아시아 지역에서의 강수 강화가 매우 뚜렷하게 나타났으며, 관측과도 유사하게 나타났다. 남북방향으로의 대류패턴은 지역 해들리 순환과도 밀접한 관련이 있으므로, MME-A는 북서태평양지역의 대류억제, 동아시아 지역의 대류강화의 지역 해들리 순환을 잘 모의하였다. 반면, MME-B 그룹에서는 MME-A 및 관측과 비해 지역 해들리 순환을 매우 약하게 모의하였는데, 이로 인하여 동아시아 지역의 강수 또한 약하게 모의하였다. 이러한 강수 오차는 두 모델 그룹간 강수 아노말리의 상관계수로도 확인할 수 있다. MME-A 그룹은 MME-B에 비해 동아시아 지역에서의 강수 아노말리를 더욱 잘 모의하였다 (Figure 64). 1년 교차검증한 결과 MME-A 그룹에서는 동아시아 지역 영역평균한 강수 상관계수가 0.28로, MME-B 그룹의 0.13보다 높게 나타났다. 즉, Figure 63~64를 볼 때, 북서태평양고기압의 특징을 잘 모의하는 모델을 사용할 때, 북서태평양고기압 및 이와 관련된 동아시아 지역의 강수 오차가 적게 나타남을 알 수 있다.

Z500 anomalies regressed onto the observed Strength index



200hPa velocity potential regressed onto the observed Strength index



Precipitation and 850hPa wind anomalies regressed onto the observed Strength index

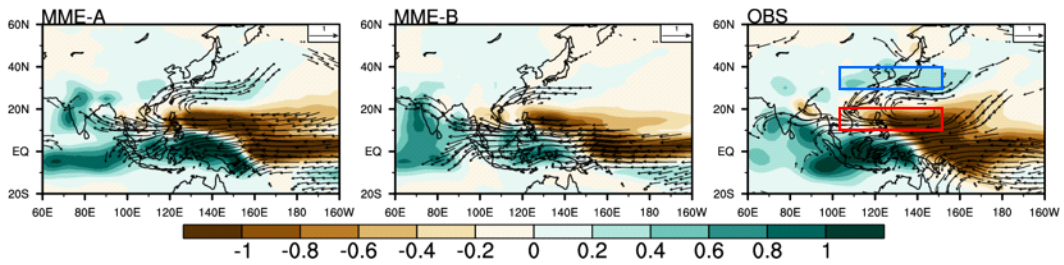


Figure 63. 500hPa geopotential height anomalies, 200hPa velocity potential, divergent wind anomalies, precipitation and 850hPa wind anomalies regressed onto the observed strength index.

Correlation of precipitation anomalies

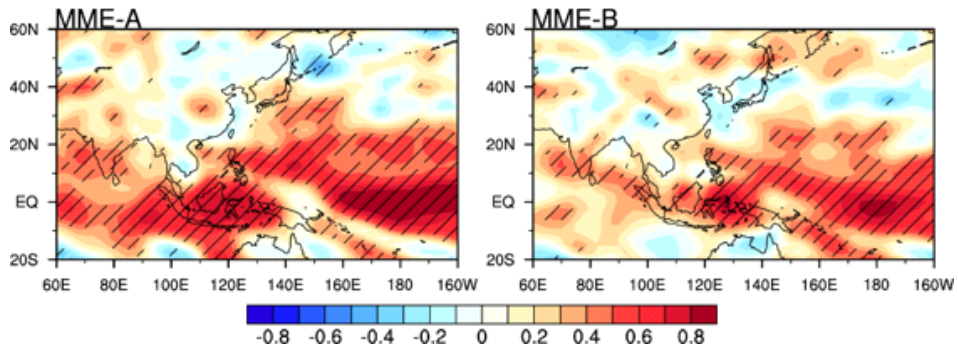


Figure 64. Anomaly correlation coefficients of precipitation in (a) MME-A and (b) MME-B.

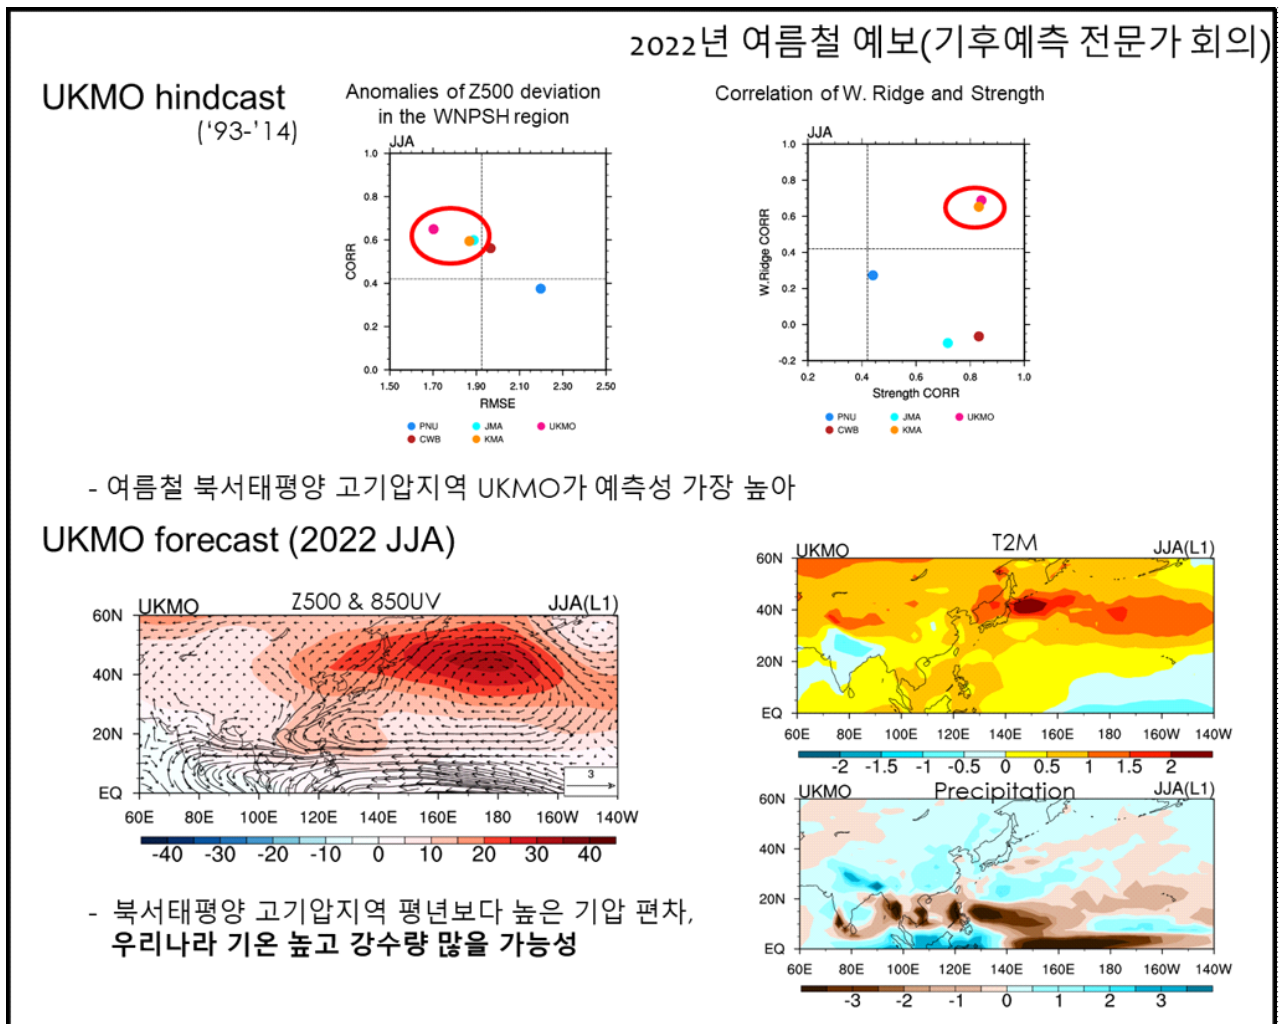


Figure 65. Selection of best model representing the WNPSH based on real-time forecasts in summer in 2022.

실제 2022년 여름철 장기예보를 위하여 실시간 APCC MME hindcast 및 real-time forecast를 사용하여 위에서 언급한 북서태평양고기압 모의 특성을 분석하였다. 그 결과, UKMO 모델의 경우 hindcast 기간(1993~2014) 동안 북서태평양고기압의 특징을 가장 잘 모의하는 것으로 나타났으며, 이를 토대로 UKMO 모델의 real-time forecast를 참조할 때 북서태평양고기압 지역은 평년보다 높은 기압 편차를 보여, 우리나라 기온은 다소 높고 강수량은 많을 것으로 예측되었다. 해당 결과는 Figure 65와 같이 2022년 여름철 예보를 위해 기후예측 전무가 회의에서 활용되었다.

기후예측에 있어 가장 중요한 예측 소스는 ENSO(El Nino-Southern Oscillation)이다. 따라서 모델의 예측 소스를 파악하기 위해 이전 겨울철 Nino3.4 지수에 회귀한 850hPa 바람장, 해수면온도, 강수 패턴 등에 대해 Figure 66과 같이 살펴보았다. MME-A 그룹의 경우 ENSO에 따른 로스비 순환으로 인하여 북서태평양 지역에 고기압성 순환이 나타났으며, 관측과 매우 유사하게 나타났다. 반면, MME-B는 MME-A 및 관측에 비해 고기압성 순환이 매우 강하게 나타나, MME-B 에서는 ENSO에 대한 영향을 매우 과하게 반영하고 있음을 알 수 있다. 이는 해수면온도에서도 유사하게 나타나는데, ENSO는 인도양 지역의 축전지효과를 통해 동아시아 지역 순환장에 영향을 미친다. MME-A 및 MME-B 모두 관측에 비해 인도양 지역 해수면온도를 매우 강하게 모의하는 경향이 있었으나, 이 또한 MME-B에서 더욱 강하게 모의하는 것으로 나타났다. ENSO에 따른 강수에서도 이와 유사하게 나타났는데, MME-A에서는 북서태평양 지역 및 동아시아 지역에서 관측과 유사한 강수 아노말리 패턴을 보였으나, MME-B에서는 인도양 지역에서는 보다 많은 강수를, 북서태평양 지역에서는 보다 강한 대류 억제 패턴을 보였다.

북서태평양고기압의 변동성을 설명하는 첫 번째 모드는 ENSO 약화와 관계된 차가운 적도 중앙태평양에 대한 로스비반응이며, 두 번째 모드는 북서태평양의 해양-대기의 양의 피드백에 의한 북서태평양고기압의 강화이다. 이를 좀 더 자세히 알아보기 위해 850hPa 하층 바람장에 대한 EOF 분석을 통해 북서태평양고기압의 주요 변동 패턴을 알아보았다. 관측 EOF1 모드에서는 전체 변동성의 42.8%를 설명하고, EOF2 모드에서는 13.2%를 설명한다. EOF1 모드에서는 북서태평양에 강한 고기압성 순환이 위치하며, EOF2 모드에서는 EOF1보다 좀 더 남쪽의 위치한 약한 고기압성 순환을 나타낸다. MME-A 및 MME-B 두 모델그룹에서도 전체적인 패턴은 비교적 관측과 유사하게 나타나는데, 관측과 비교해서 EOF1 모드가 훨씬 큰 변동성을 설명한다 (약 80%).

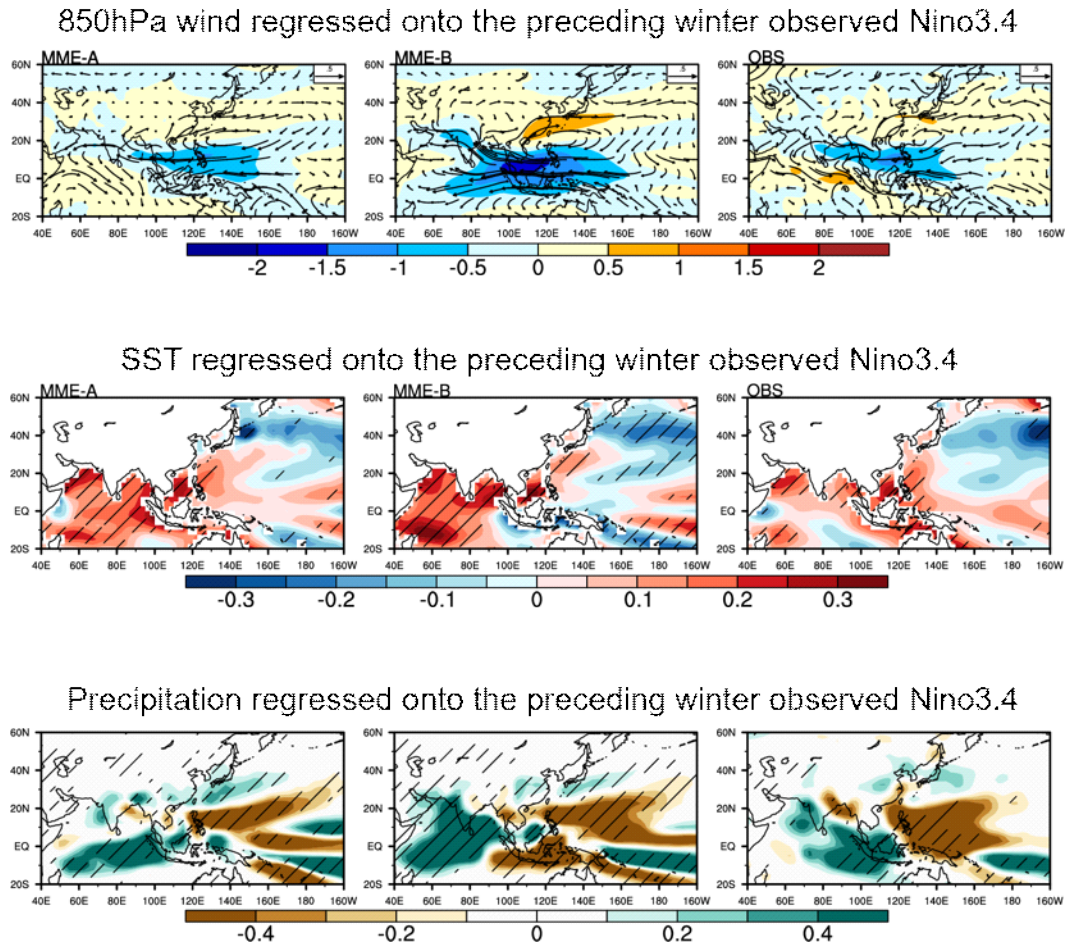


Figure 66. 850hPa low-level wind, sea surface temperature and precipitation anomalies regressed onto the observed Nino3.4 index in preceding winter.

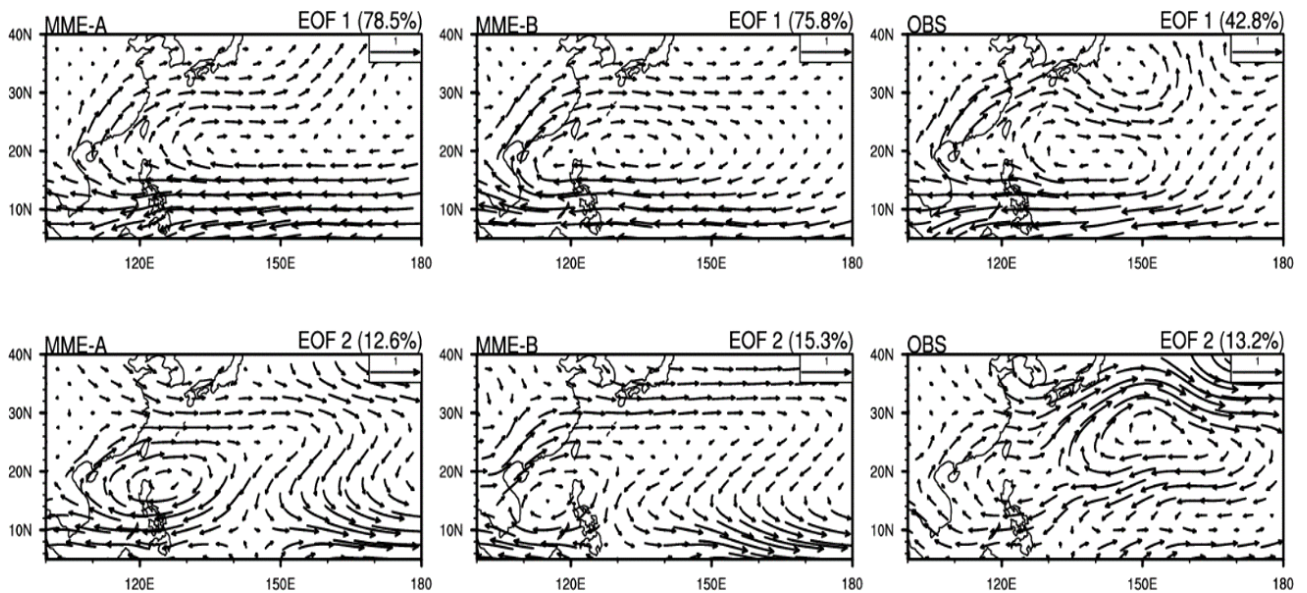


Figure 67. The first two modes obtained by multivariate EOF analysis on the JJA 850hPa wind.

모델에서 북서태평양고기압의 변동성을 모의하는 주요 소스를 알아보기 위해, 위 두 EOF 모드에 대해 해수면온도와, 500hPa 지위고도, 850hPa 바람장을 회귀분석하였다. EOF1는 전이모드(transition mode)로써 엘니뇨 쇠퇴 및 라니냐로의 전이를 나타낸다. 이와 관련된 로스비 파동 반응으로 북서태평양지역에 고기압성 순환이 매우 강해지고, 동아시아 지역에는 지역 해들리 순환에 대한 반응으로 강수가 유도된다. 전반적으로 EOF1 모드와 관련해서는 MME-A 및 MME-B 모두 잘 모의하고 있다. 다만, MME-B 그룹에서는 MME-A 그룹 및 관측과 비교해서 maritime continent에서 대류가 약하며, 이로 인해 동아시아 지역에서는 강수가 매우 약하게 나타난다. EOF2는 지속 모드(persistent mode)로써 이전 가을철부터 이듬해 여름까지 ENSO가 지속되는 패턴을 나타낸다. MME-B는 관측 및 MME-A와 비교해 ENSO 지속모드를 매우 강하게 모의하고 있는 것을 알 수 있다. 이로 인해 북서태평양 지역에 매우 강한 고기압성 순환을 유도한다. 하지만, MME-A 및 MME-B 그룹 모두 필리핀해로부터 북동쪽으로 전파되는 남북방향 파동 패턴을 모의하는 데 한계가 있기 때문에, EOF2 패턴과 관련된 동아시아 지역 강수는 매우 약하게 나타나는 것을 알 수 있다.

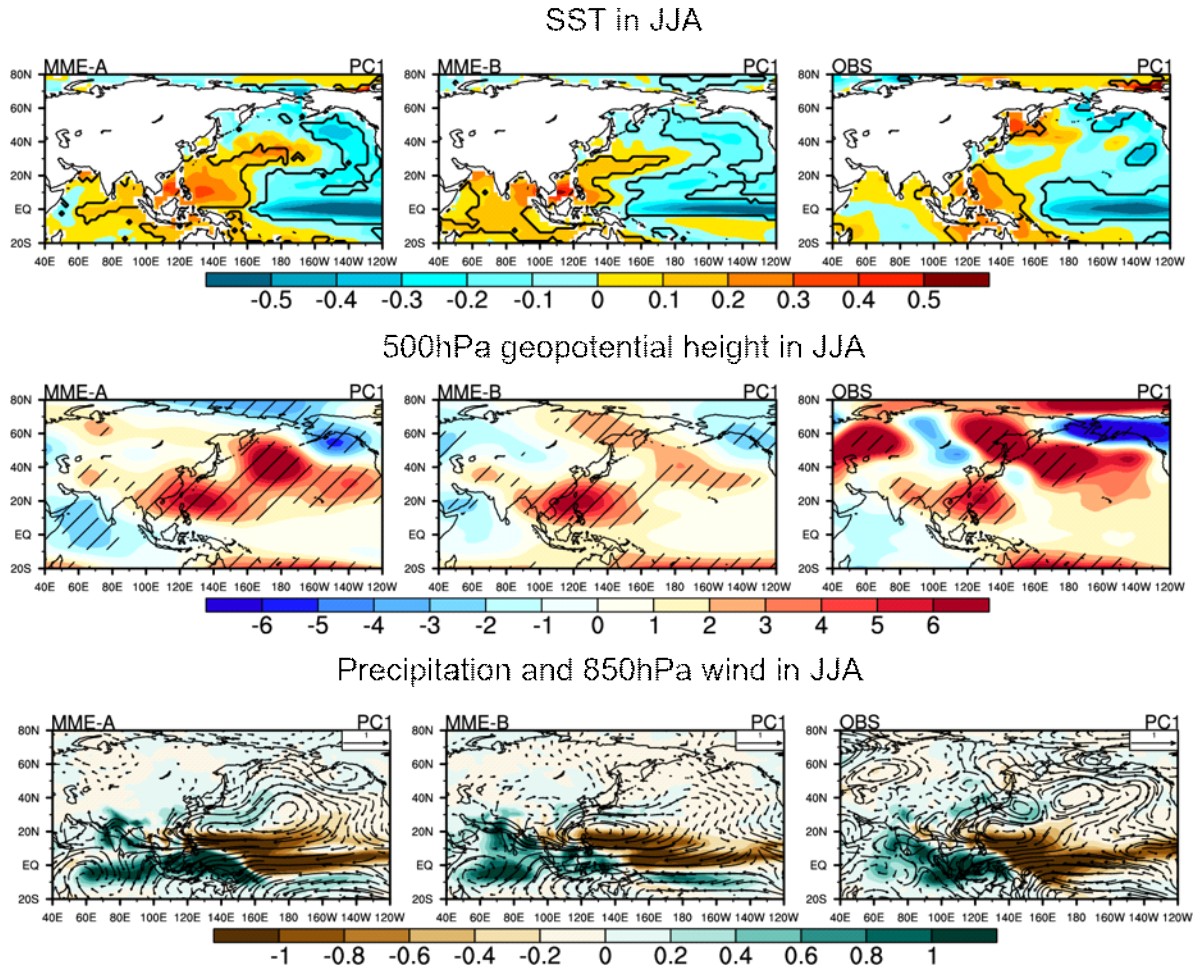


Figure 68. Sea surface temperature, 500hPa geopotential height, precipitation and 850hPa low-level wind anomalies regressed onto the EOF1 in JJA.

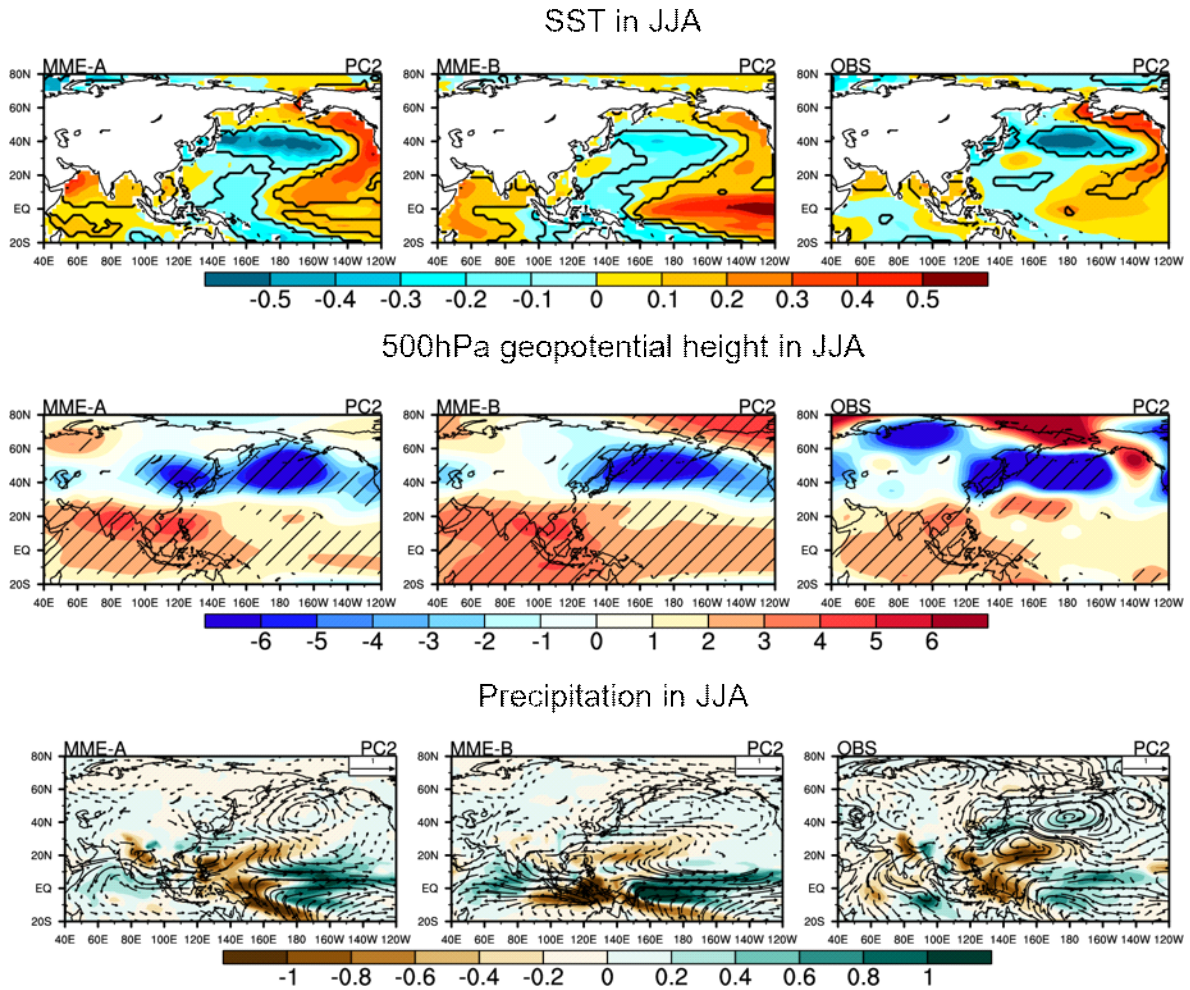


Figure 69. Sea surface temperature, 500hPa geopotential height, precipitation and 850hPa low-level wind anomalies regressed onto the EOF2 in JJA.

(나) 우수 모델 선정을 통한 우리나라 월별 기온 및 강수 예측성 향상

① 월별 모델 특성

기후예측모델의 예측성에 가장 큰 영향을 미치는 소스는 해양으로부터 온다. 때문에 해양의 예측성을 먼저 살펴보고자 한다. 일반적으로 기후예측모델의 예측성을 위해서는 관측과의 상관관계로 보게 되는데, 계절예측모델의 상관관계는 모델이 가지고 있는 신호대잡음비(signal-to-noise, S2N)로 결정된다. 또한, 상관관계는 샘플 수가 작아질수록 그 기댓값이 작아지는데, 현재 기후예측모델은 S2N 및 샘플 수의 제약 등 많은 한계를 포함하고 있다.

해양의 S2N는 비교적 높다. 즉, 기후예측모델의 해수면온도 예측성(관측과의 상관관계)은 높은 편이다. 하지만 해수면온도의 예측성이 높다 하더라도, 해수면의 영향을 받은 대기의 S2N는 급격히 낮아져서, 대부분이 noise로 나타난다. 이로 인해 기후예측모델의 기온 및

강수와 같은 예측성은 급격히 낮아진다.

S2N: SST_DEC(L1)

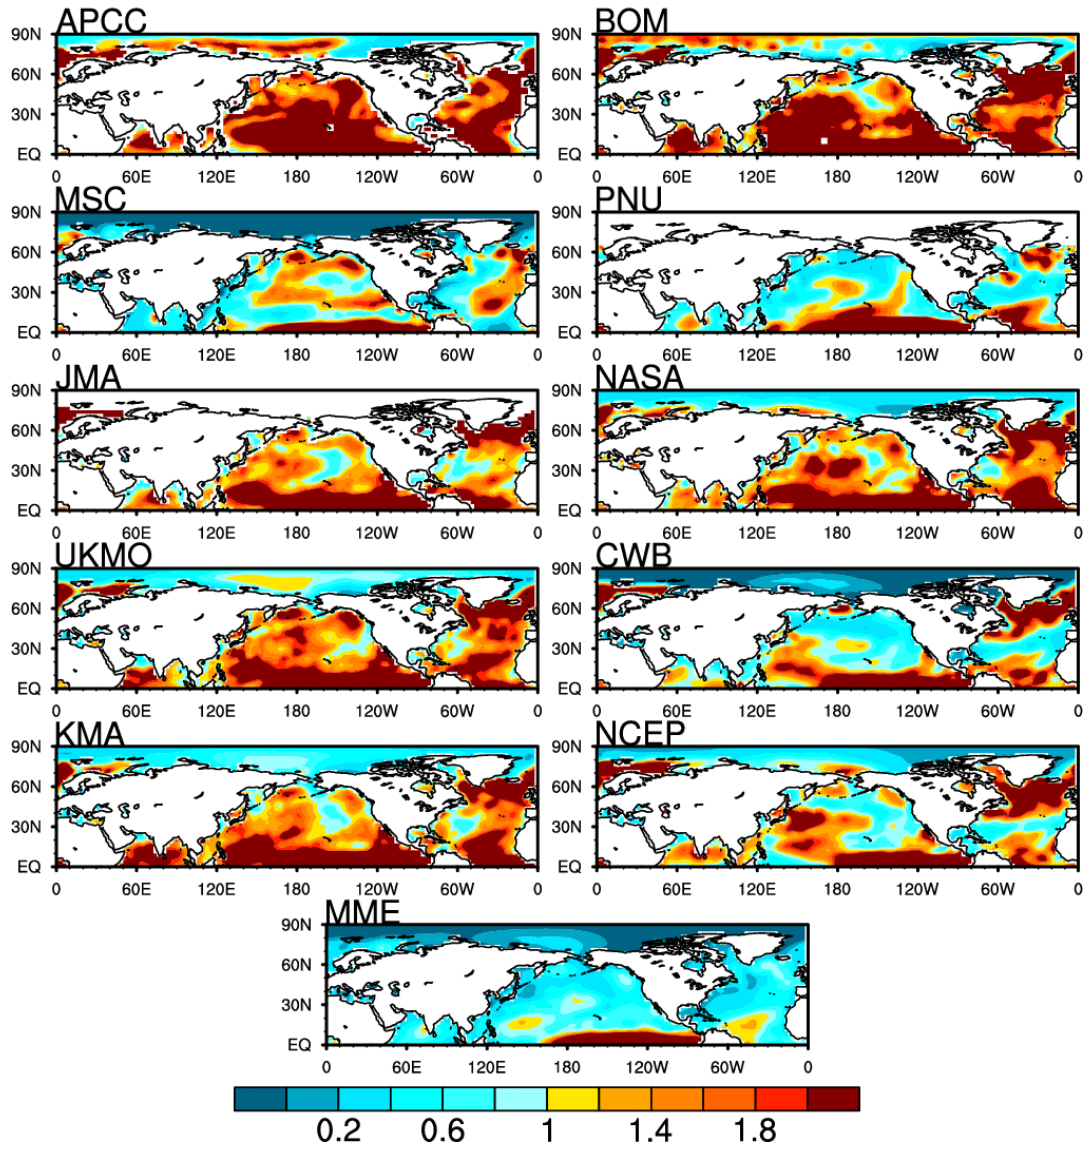


Figure 70. Signal-to-noise of SST in December (1-month lead) for individual model and MME.

S2N: Z500_DEC(L1)

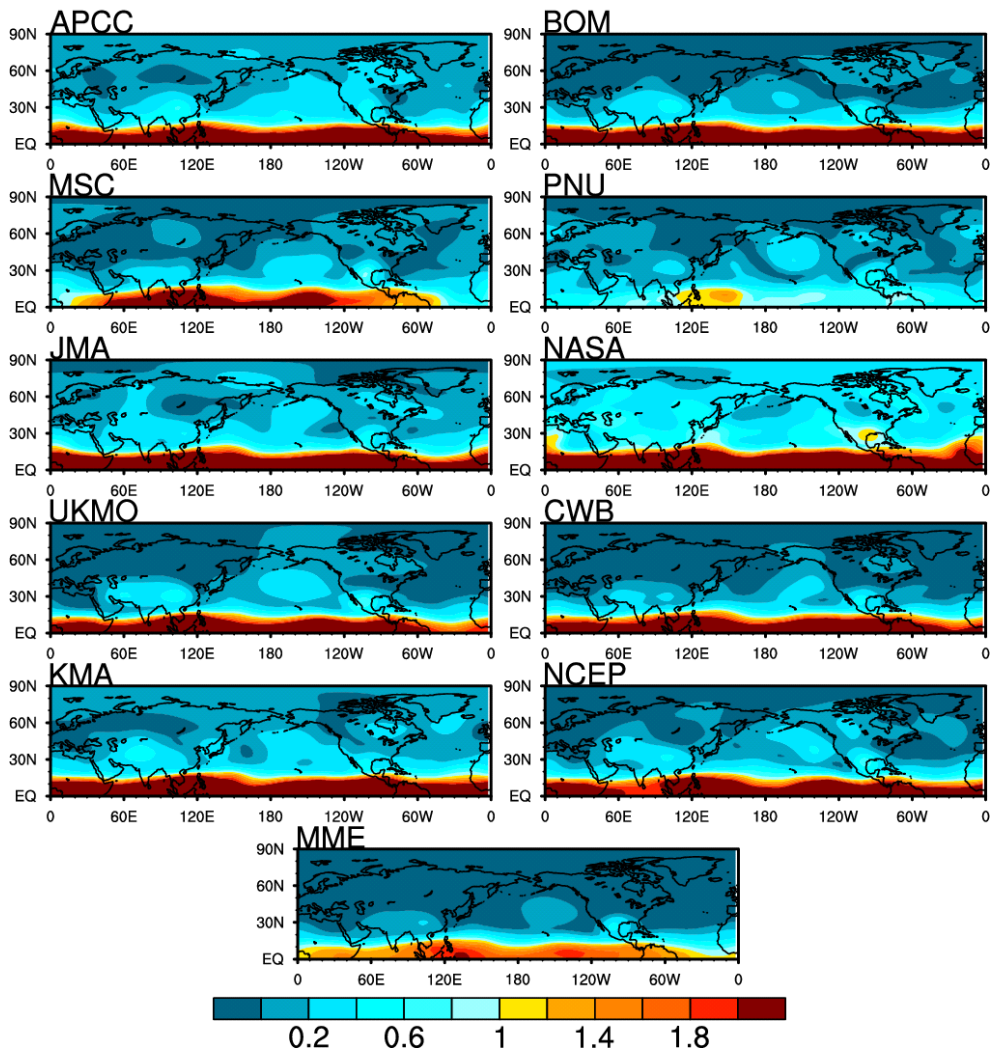


Figure 71. Signal-to-noise of 500hPa geopotential height in December (1-month lead) for individual model and MME.

모델의 불확실성을 좀 더 면밀히 살펴보기 위해 예측가능요소비(Ratio of Predictable Component, RPC)를 살펴보았다. RPC는 관측과 모델예측값과의 관계를 모델 자체에서 얼마나 잘 재현해 내는가를 설명한다. RPC가 1일 때 완벽한 예측이 되며 RPC가 1보다 클 때는 모델의 신호가 너무 작아서 모델 자체의 예측성분이 (실제 관측보다) 낮음을 의미하며, RPC가 1보다 작을 때는 모델 자체의 예측성분이 (실제 관측보다) 크지만, 관측과의 상관계수가 낮음을 의미한다. 다시 말해 RPC가 1보다 클 때는 underconfident한 예측결과로 관측과의 상관계수는 높으나, 앙상블 평균으로 표현되는 신호에 비해 잡음이 크다는 것을 의미한다. 반대로 RPC가 1보다 작을 때는 overconfident한 예측으로, 관측과의 상관계수는 작고, 모델 예측자체의 불확실성(spread) 자체가 충분치 않음을 나타낸다.

S2N에서 확인한 바와 같이, SST는 RPC가 1에 가까워 완벽한 예측에 가깝다. 하지만 해양의 영향에 의한 대기 반응으로 나타나는 500hPa 지위고도는 개별모델의 경우 RPC가

1보다 훨씬 작으며, MME는 RPC가 1보다 훨씬 크다. 또한, 계절에 따라 또는 월별로 RPC의 변동이 매우 크게 나타난다. 개별모델의 RPC가 1보다 작은 것은 모델 자체의 불확실성(spread)이 충분치 않기 때문이며, MME의 RPC가 1보다 큰 것은 모델 자체의 잡음(noise)이 너무 크기 때문이다. 더욱이 개별모델의 단점을 보완하기 위해 사용하는 다중모델앙상블(MME)의 경우, 대체로 RPC가 1보다 크다. MME의 경우 관측과의 상관계수가 높다 하더라도, 이에 비해 noise가 크기 때문에 MME 자체의 상관계수만을 믿고 모델 예측자료를 활용하기에는 한계가 있음을 나타낸다.

RPC: SST_DEC(L1)

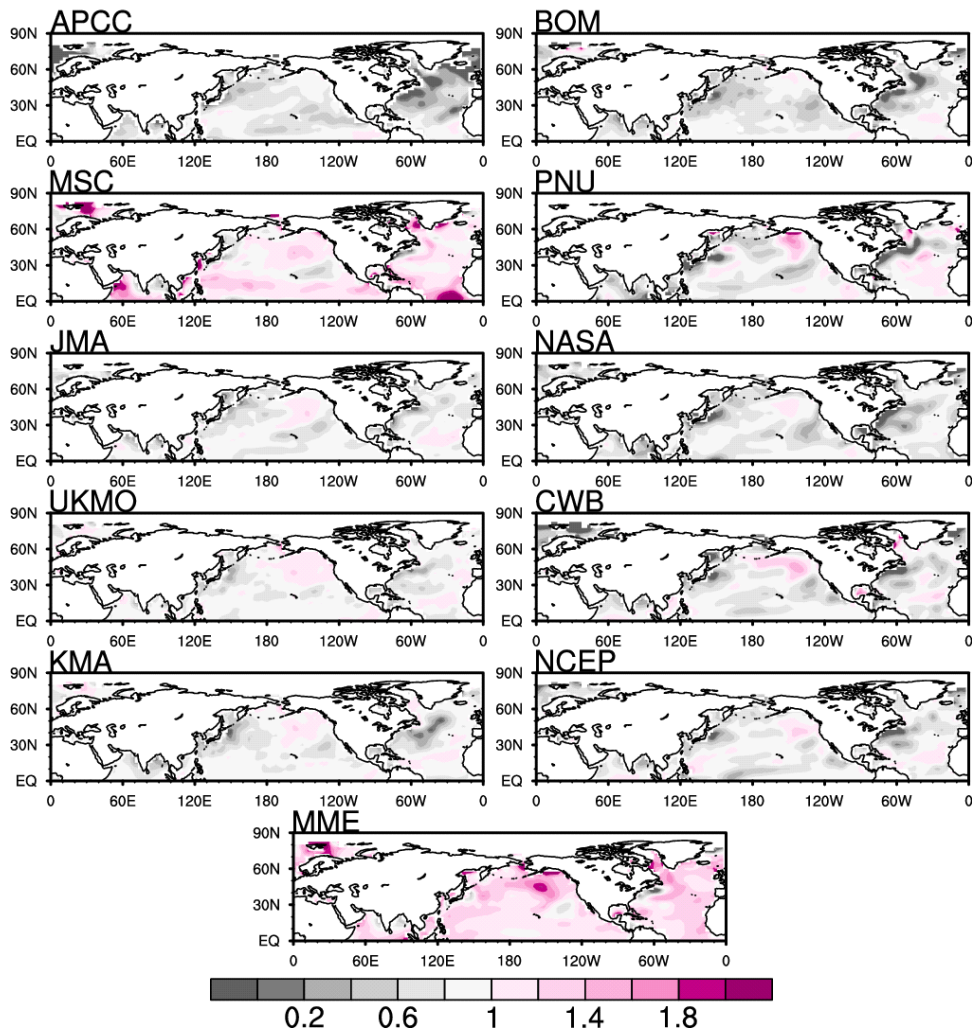


Figure 72. Ratio of predictable component of SST in December (1-month lead) for individual model and MME.

RPC: Z500_DEC(L1)

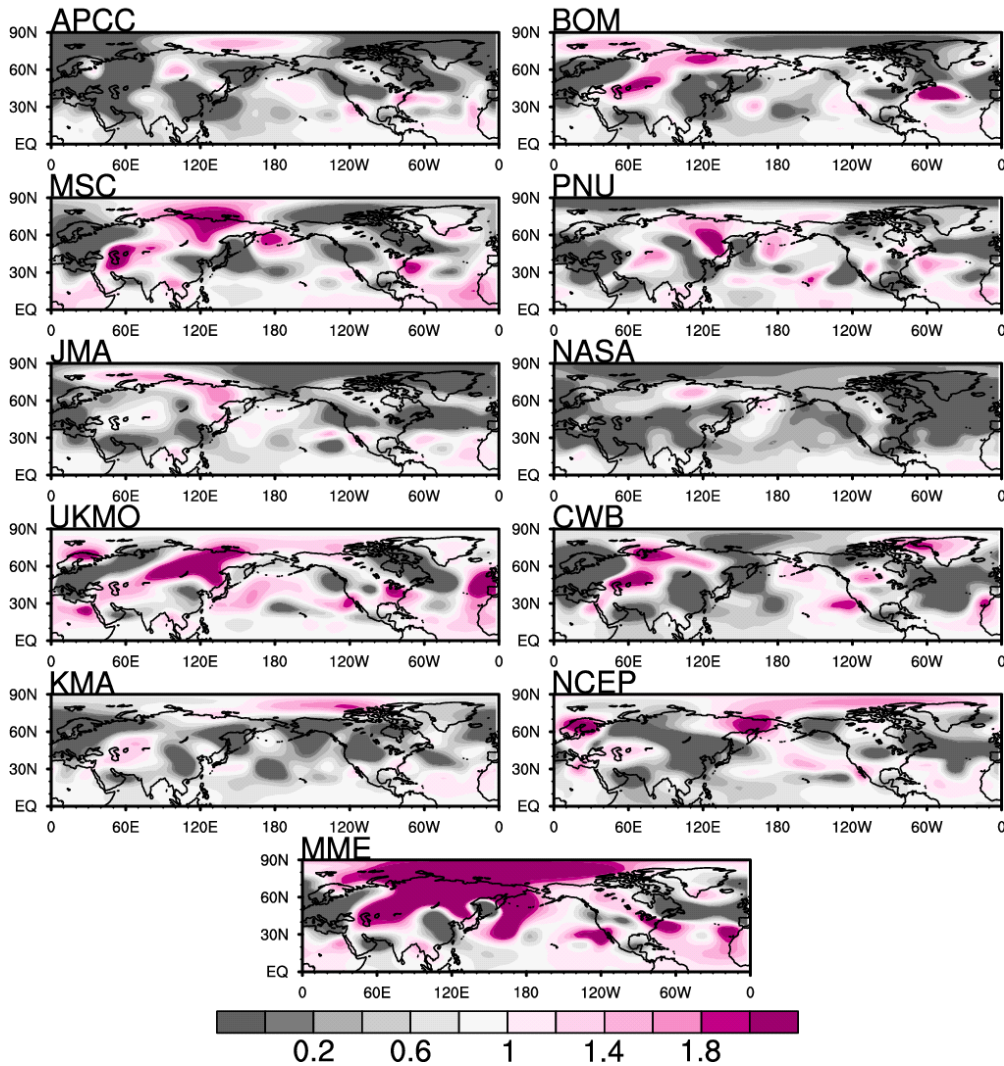


Figure 73. Ratio of predictable component of 500hPa geopotential height in December (1-month lead) for individual model and MME.

실제 3개월 장기예보를 위해서는 앞으로 3개월까지의 월별 예측자료를 생산하기 때문에, 모델의 예측성 또한 이에 준하는 시간규모에서 살펴보아야 한다. 따라서 MME를 포함한 각 개별모델에 대해 동아시아 지역에서의 월별 RPC 값을 살펴보았다. 대체로 MME는 관측과의 상관관계(ACC)가 매우 높고, RPC는 1보다 큰 경향이 강하다. 앞서 살펴본 바와 마찬가지로, MME는 상관관계가 높아 예측성이 높은듯하지만, 실제로는 noise가 매우 커, 예측성을 그 자체로 믿고 활용하기에는 한계가 있다고 하겠다. 이에 반해 개별모델의 경우, 대체로 ACC가 MME에 비해 낮은 반면, RPC는 1보다 작다. 이는 개별모델의 spread가 충분치 않아, 예측성 그 자체를 받아들여 활용하기에 제약이 있음을 의미한다.

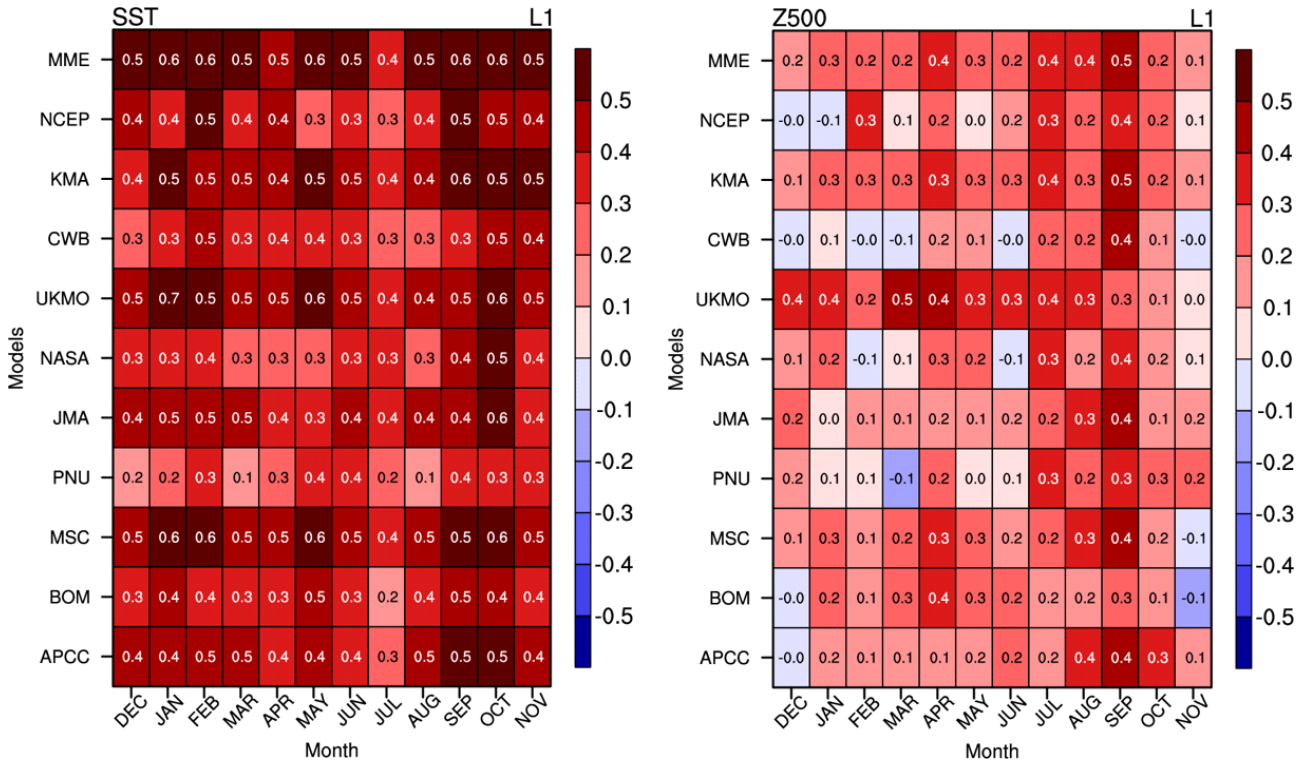


Figure 74. Anomaly Correlation Coefficient (ACC) over EA for each individual model and MME at each month (1-month lead).

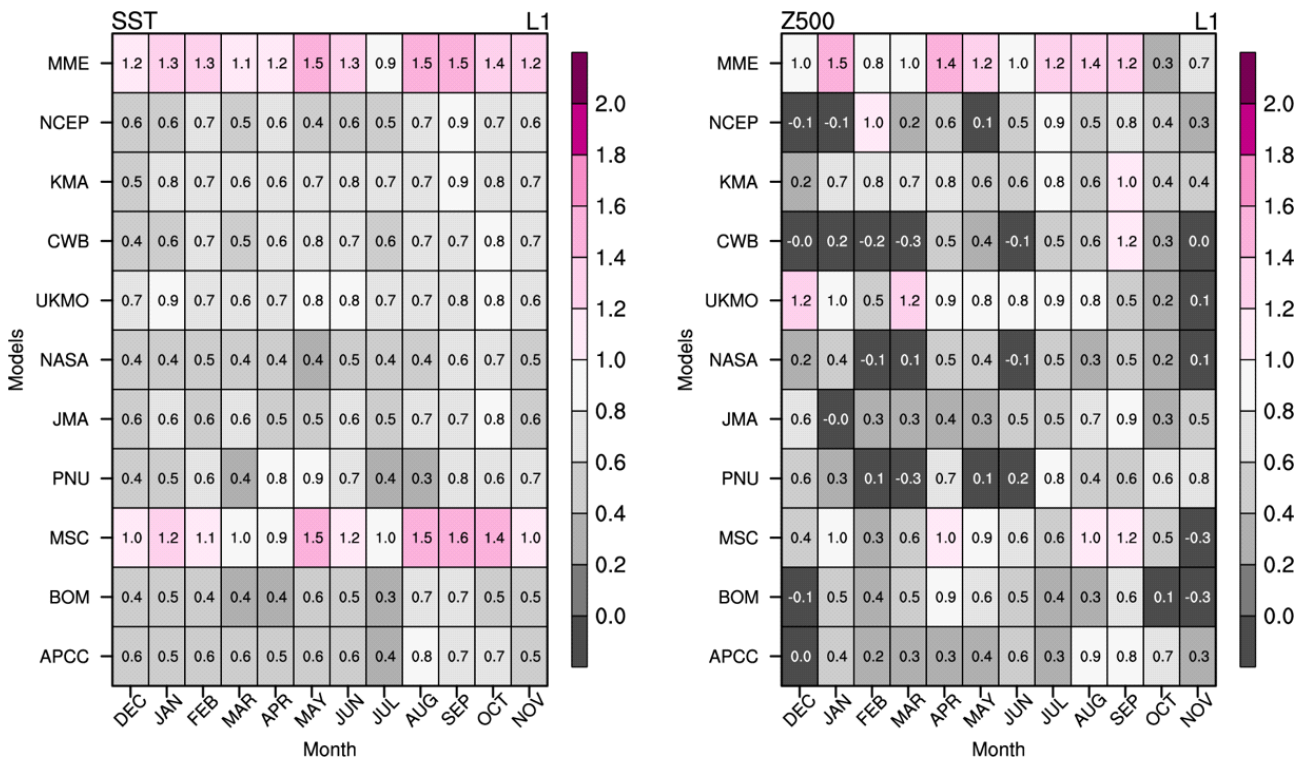


Figure 75. Ratio of predictable component (RPC) over EA for each individual MME at each month (1-month lead).

앞서 살펴보았듯이, 전지구 계절예보를 위해 생산되는 MME는 특히 우리나라와 같이 지역적 예보를 위해서는 적합하지 않을 수 있다. 때문에 지역적 특성에 맞는 최적의 모델을 선별하여 예보에 활용하는 것이 중요하다. 우리나라 기후예측을 위해서는 모델이 고위도 및 저위도로부터의 영향을 잘 모의해야 한다. 때문에 우리나라 주변의 CP(Cold-Polar), MT(Maritime-Tropical)로 대표되는 주요 기압계를 예측 요소로 활용하겠다고 언급한 바 있다. 따라서 각 모델 및 MME에 대해 CP, MT를 얼마나 잘 모의하는지 먼저 살펴보았다. 관측과의 상관계수(ACC)는 MME가 각 개별모델간 평균보다는 높게 나타나지만, 큰 차이는 보이지 않는다. 계절별, 월별로 ACC의 차이를 보이긴 하지만, 대체로 거의 모든 모델에서 잘 모의하고 있는 것으로 나타났다. MT의 경우, warm season에 비교적 예측성이 낮고, cool season에 예측성이 높게 나타났으며, 특히 8~10월에 예측성이 높았다. CP의 경우 MT에 비해 ACC는 낮은 경향이 있으나, 8월과 같은 특정한 월을 제외하고는 대체로 예측성이 높았다. 이와 관련해, RPC도 함께 살펴보았다. RPC는 개별모델의 경우 대체로 1보다 작았으며 이는 계절별, 월별로 거의 동일하게 나타났다. 하지만 MME의 경우 계절에 따라, 월에 따라 그 변동성이 매우 크게 나타났다. 이는 MME의 경우, 관측과의 상관관계가 높다고는 하나 그 예측성을 그대로 믿고 활용하기에는 한계가 있음을 다시 한번 드러낸다.

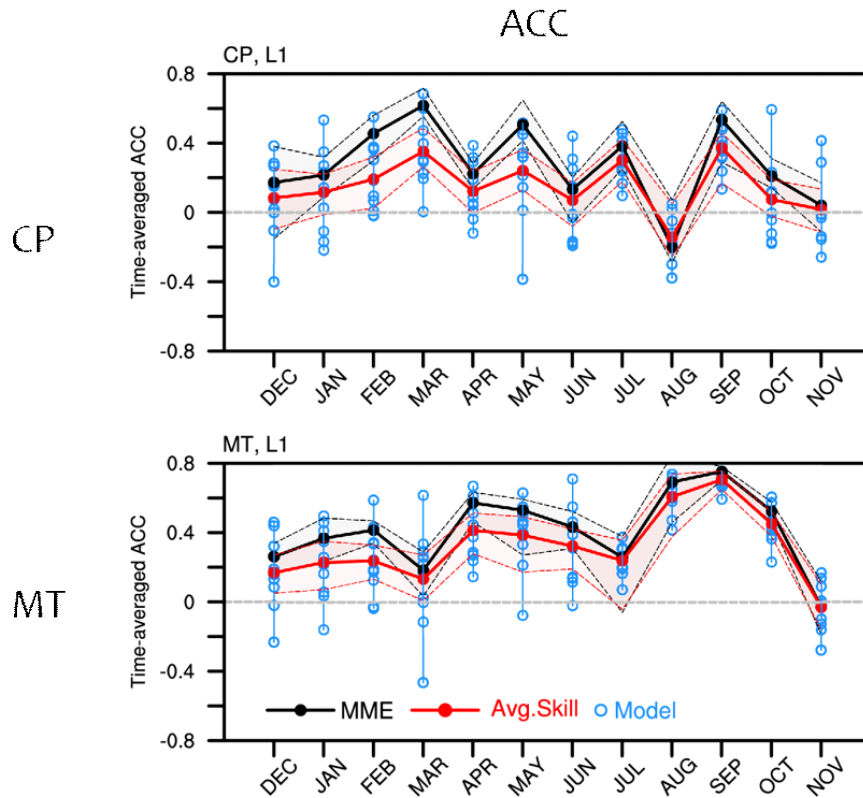


Figure 76. Anomaly Correlation Coefficient (ACC) of CP and MT for each individual model and MME at each month (1-month lead).




Figure 77. Ratio of predictable component (RPC) of CP and MT for each individual model and MME at each month (1-month lead).

앞서 살펴본 CP와 MT에 대해 선행시간(lead 1~3개월)에 따른 ACC와 RPC도 살펴보았다. 대체로 ACC는 1~2개월까지는 유사한 수준을 유지했으며, 선행 3개월에 낮아지는 것으로 나타났다. 이러한 경향은 warm season에 뚜렷하게 나타났고, cold season에는 선행시간이 길어지더라도 크게 변화하지 않는 것으로 나타났다. RPC의 경우, 선행시간에 따른 차이가 크지 않았으며, 대체로 MME에 대한 RPC 변동이 각 개별모델의 평균에 대한 RPC 변동보다 훨씬 크게 나타났다.

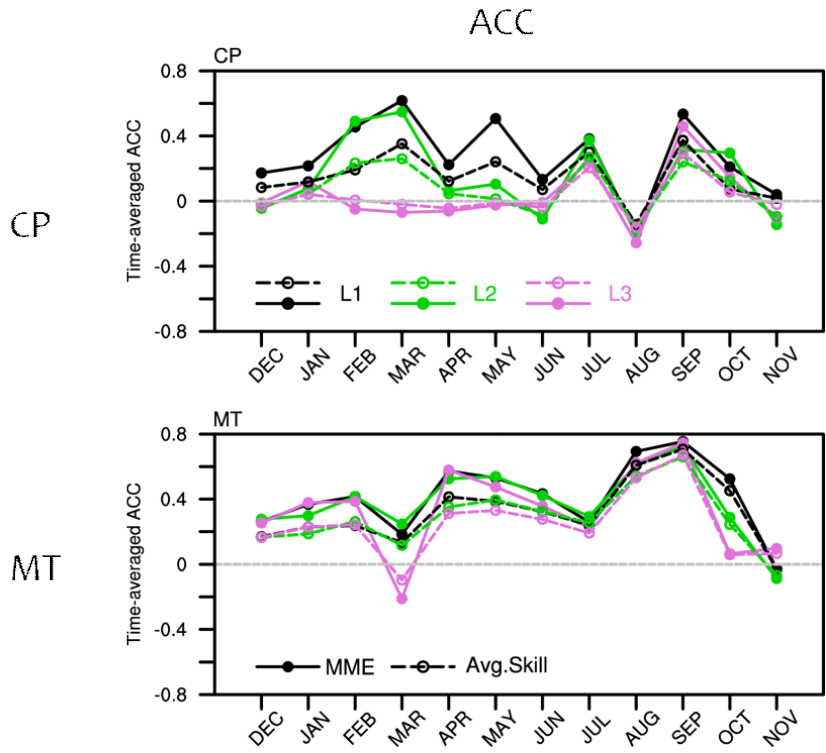


Figure 78. Anomaly Correlation Coefficient (ACC) of CP and MT for each individual model and MME for each lead month.




Figure 79. Ratio of predictable component (RPC) of CP and MT for each individual model and MME for each lead month.

CP 및 MT 변동에 따른 한반도 기온과 강수 영향에 대해 상대적으로 관측과의 ACC가 높고, 상대적으로 RPC가 1에 가까운 모델을 선별하였다. 이는 real-world에서의 변동성도 잘 모의하고, model-world에서도 신뢰할만한 변동성을 재현해 내는 것이라 간주할 수 있다. 이를 통해 모델 예측자료를 활용함에 있어 좀 더 확신을 가지고 예측할 수 있을 것이다.

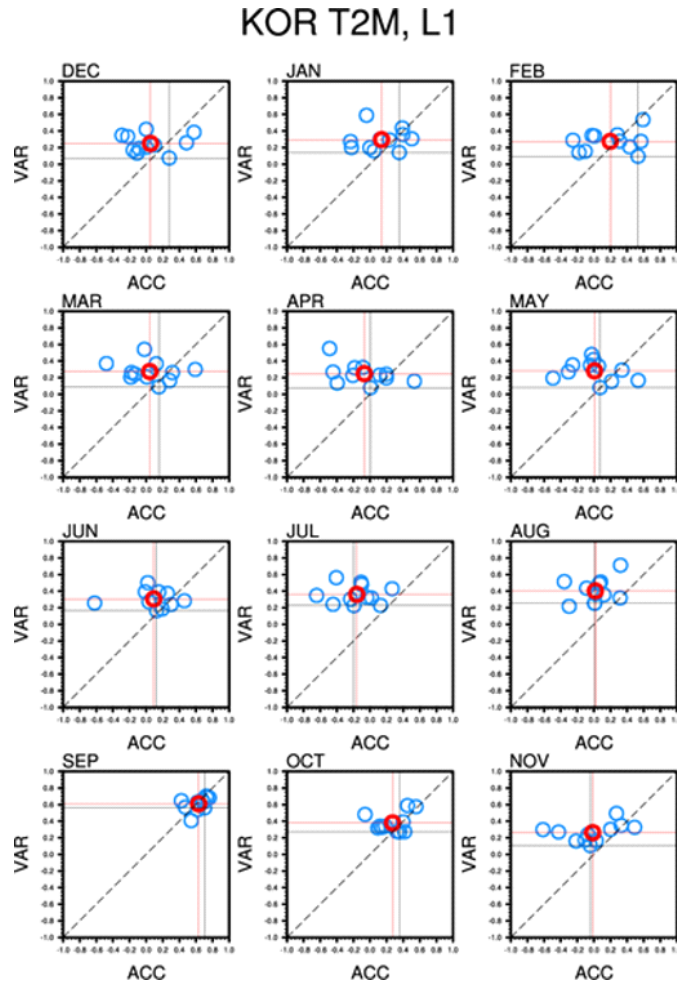


Figure 80. Scatterplot of RPC for monthly 2m temperature forecast at 1-month lead.

KOR PREC, L1

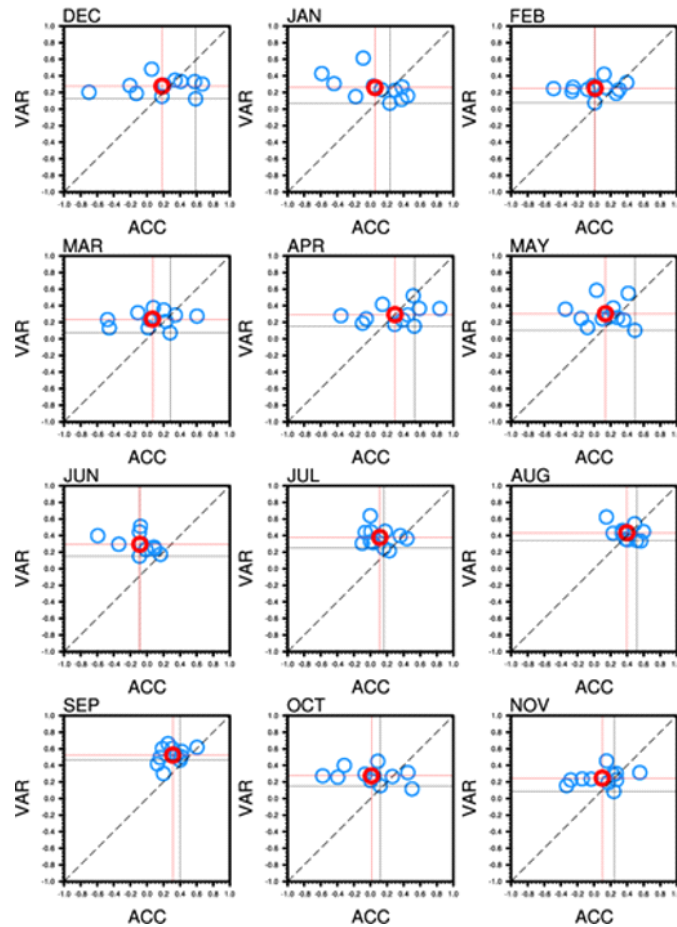


Figure 81. Scatterplot of RPC for monthly precipitation forecast at 1-month lead.

위에서 언급한 과정을 통해 계절안 규모에서의 대기순환에 대한 모델의 예측성을 살펴보았다. 또한 모델에서 계절안 규모의 대기순환과 한반도 기온 및 강수와의 관계를 어떻게 모의하는지도 살펴보았다. 그리고 최종적으로는 예측성과 신뢰성을 모두 고려한 최적의 모델 선별 과정을 통해 계절안 규모의 기온과 강수 예측성이 향상되는가를 살펴보려고 한다. 1년 교차검증 결과로 살펴볼 때, 우리나라 기후 특성을 잘 모의하는 우수모델 선정 및 tailoring 과정을 통해 계절안 예측성이 크게 향상됨을 알 수 있다. 또한 선행시간이 증가할수록 더욱 크게 예측성이 증가하는 것으로 나타나, 이러한 과정이 기후예측모델 자료를 활용한 3개월 장기예보의 예측성을 향상하는데 기여할 수 있을 것으로 보인다.

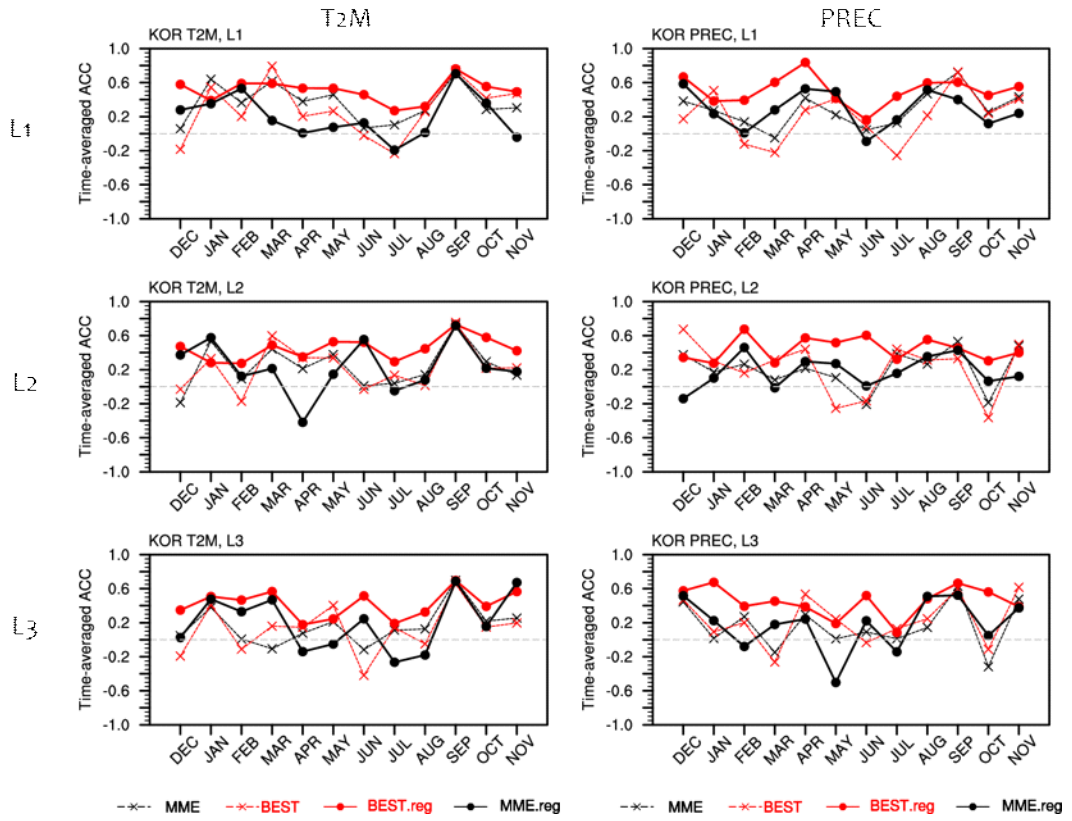


Figure 82. 1-yr out cross-validated skill (ACC) for 2m temperature and precipitation at 1~3 month lead. Think red line indicates tailored forecast with best model selected.

나. 1개월 장기예보 개선

(1) BSISO 예측정보를 활용한 우리나라 1개월 장기예보 개선

(가) BSISO 지수 및 영향편차장 예측성 분석

2016년부터 2021년까지 ECMWF 모델에서 모의되는 BSISO1, BSISO2, MJO 지수의 예측성을 파악하기 위해 전 계절(1월~12월), 여름철(5월~10월), 겨울철(11월~4월)로 나눠서 predictability 및 prediction skill을 살펴보았다(Figure 83). Prediction skill은 모델 오류를 포함하는 예측시스템에서 실제로 달성할 수 있는 예측스킬로써 관측지수와 예측지수와의 관계를 보여준다. 이론적으로 달성할 수 있는 잠재적 예측 가능성을 보여주는 이상적인 예측스킬로 여겨지는 predictability는 하나의 앙상블 멤버를 ‘perfect model or truth’ 라고 간주하고 나머지 앙상블 멤버와 비교한다. Predictability 및 prediction skill은 각각 ‘single-member method’와 ‘ensemble-mean method’로 나누어 살펴볼 수 있는데 검증방법에 대한 내용은 Kim et al.(2014)에 자세히 기록되어 있다. 앙상블 평균(ensemble-mean)으로 추정된 predictability는 계절에 상관없이 세 지수 모두 42일로 초기장 및 모델 개선을 통해 끌어올릴 수 있는 최대 예측스킬 추정치를 의미한다. Prediction skill 및 predictability 모두 단일멤버 추정값보다 앙상블 평균 추정값이 더 크다. 단일멤버로 추정된 prediction skill은 세 지수 모두 20일 채 되지 않는다. 반면 앙상블 평균값으로 추정된 prediction skill은 MJO의 경우 모든 계절에서 29~30일이고 BSISO는 여름철에 더 높은 값을 보이며 BSISO1 지수는 30일, BSISO2 지수는 20일로 나타난다. 초기진폭이 1.0 미만일 때보다 1.0 이상일 때 BSISO1 지수의 경우 prediction skill이 6일 더 길게 나타나며 초기강도가 강할수록 예측성이 높아지나 predictability는 강도에 대한 차이는 나타나지 않는다. 이러한 특성은 Lee et al.(2015) 연구 결과에서도 확인할 수 있으며 비록 과거재현자료(hindcast data) 기반으로 분석되어 실시간예측(real-time forecast) 결과와 상이할 수 있으나 ECMWF 앙상블 평균 prediction skill의 경우 강한 BSISO1일 때 32일, predictability는 38일로 유사한 결과를 보인다.




Figure 83. The single-member predictability, ensemble-mean predictability, single-member prediction skill and ensemble-mean prediction skill estimate of MJO, BSISO1 and BSISO2.

Figure 84는 Extended summer(5월~10월) 평균된 BSISO1 및 BSISO2 지수의 주별 검증 결과이다. 가로축은 평균제곱근오차(Root Mean Square Error, RMSE), 세로축은 이변량상관계수(Bivariate Correlation Coefficient, BCC)를 나타내며 RMSE는 $\sqrt{2}$ 보다 작은 경우 BCC는 0.5이상일 때 예측성이 있는 것으로 판단하였다(Rashid et al., 2011). BSISO1은 +4주, BSISO2는 +3주까지 예측성을 보이며 두 지수 모두 선행시간이 길어질수록 강도는 관측보다 약하게 이동속도는 관측보다 느리게 모의하는 특성을 보인다(Figure 85). Figure 86에서 강도와 무관하게 초기위상에 따른 겨울철 MJO 지수 및 여름철 BSISO 지수의 예측스킬의 차이를 살펴보았는데 MJO와 BSISO1의 경우 북서태평양 부근에서 대류가 강화되는 여덟 번째 위상에서, BSISO2의 경우 대류강화역이 동인도양 및 남중국해에 위치하는 세 번째 위상에서 가장 높은 예측스킬이 나타났다. Lee et al.(2015)에서도 ECMWF 모델의 예측스킬은 BSISO1 모드의 경우 위상 1과 위상 8일 때 가장 높게 나타나지만 초기 위상에 대한 계통적 의존도는 낮은 것으로 밝혀졌다.




Figure 84. Scatter plot of RMSE and Bivariate Correlation Coefficient for BSISO1 and BSISO2.




Figure 85. The amplitude error and phase error of BSISO1 and BSISO2.




Figure 86. The prediction skill initiated from different initial phases for MJO and BSISO.

BSISO에 의한 대기반응을 실시간으로 해석하는 데 있어 지수기반 정보가 가지는 약점을 보완하기 위해 개발된 여름철 계절내 진동 영향편차장을 활용하기 위한 첫 번째 단계로

관측지수로 추정되는 영향편차장이 관측의 계절내 변동성을 어느 정도 설명하는지 확인해 보았다. 보통 여름철이 되면 고수온역이 북쪽에 위치하면서 ISO 활동은 열대지역 뿐만 아니라 더 북쪽의 고위도 지역에서 최대 변동성을 가진다. Figure 87은 아시아 여름 몬순지역에서의 상향장파복사에 대한 영향편차장과 총계절내편차간의 ACC를 보여준다. MJO 영향편차장의 경우 적도에서 벗어나 더 북쪽의 대류활동을 어느 정도 모사하고 있지만 약 북위 18도 이상의 고위도에서는 0.3 이하의 상관관계를 보여준다. 반면 BSISO 영향편차장의 경우 필리핀해 부근은 0.6 이상 동아시아 지역에서는 0.4 이상의 상관관계를 가지며 WNP-EA 지역에서도 충분히 활용 가능함을 보여준다. 회색 박스로 표기된 동아시아 지역에 대해 전체 계절내 변동 중 BSISO 및 MJO 영향편차장이 설명할 수 있는 변동성을 월별로 살펴보면(Figure 88) BSISO 대류활동은 5월부터 10월까지 최대변동성을 가지며 여름철 계절내 진동의 주요 활동시기를 잘 반영함을 확인할 수 있다. 반면, 영향편차장에서 재현되는 MJO 대류활동의 경우 11월부터 3월까지 최대 변동성을 가지는 것을 볼 수 있다.

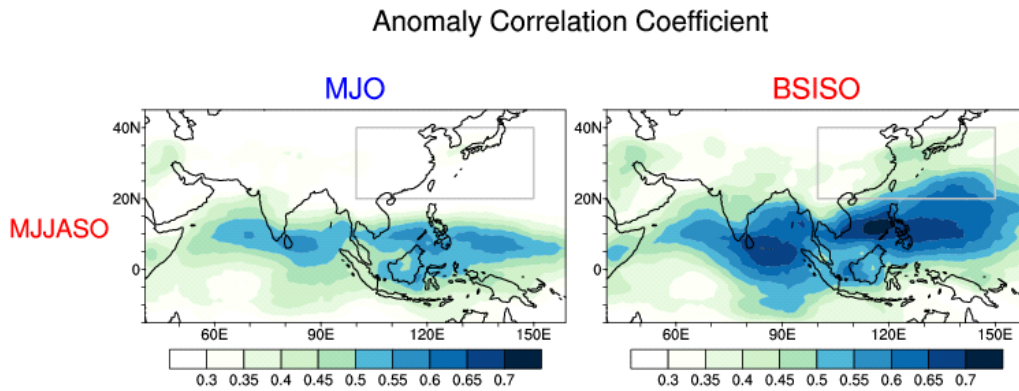


Figure 87. Anomaly correlation coefficient of MJO-related(left) and BSISO-related(right) convection anomalies during the extended summer.




Figure 88. The mean seasonal cycle of fractional variance (%) of OLR anomaly accounted by BSISO and MJO index.

다음으로 BSISO 예측 영향편차장의 패턴 및 강도의 모의 성능을 진단해 보았다(Figure 89). 먼저 우리나라와 필리핀을 포함한 남동아시아 지역(5~45°N, 100~160°E)에 대한 ECMWF

모델에서 예측된 상향장파복사, 500hPa 지위고도, 850hPa 동서 및 남북바람에 대한 영향편차장과 관측에서 나타나는 총 계절내 편차장과의 공간패턴 상관관계(Pattern Correlation Coefficient, PCC)를 주별로 산정해 보았다. Figure 89의 (a)~(d)에서 BSISO 예측 영향편차장과 관측과의 PCC는 진한 파란색으로 나타내었고 예측수준의 비교를 위해 ECMWF 총편차장 예측과 관측과의 PCC를 연한 하늘색으로 표기하였다. +1주부터 +2주까지는 ECMWF 총편차장의 PCC가 높은 값을 보이나 +3주에는 비슷한 값이 나타나고 +4주부터 BSISO 영향편차장이 더 높은 값을 보인다. 이는 ECMWF 모델의 자체 예측성이 +3주부터 급격히 떨어지는 특성이 반영된 결과로 판단된다. 1개월 전망에서 target week로 중점을 두고 있는 +3주 예측의 PCC 값만 따로 살펴보았다(Table 13). 5월부터 10월까지 여름철 평균적으로 BSISO 영향편차장의 OLR 및 Z500 공간상관관계는 0.29 및 0.27이며 다른 변수들도 ECMWF 총편차장에 대한 +3주 PCC와 유사한 값으로 ECMWF 모델과 거의 동일한 예측수준을 보여준다. 더불어 반응 강도에 대한 모의성능을 살펴보고자 관측에 대한 예측 표준편차의 비율로 ‘Relative Amplitude’ 를 정의하였고 값이 1에 가까울수록 관측과 유사한 강도를 가지는 것을 의미한다(Figure 89(e)~(h)). +1주부터 BSISO 영향편차장은 1보다 작은 값으로 약하게 반응하는 것을 볼 수 있고 +3주에는 거의 0.5 이하의 값을 가진다. ECMWF 총편차장 또한 +1주에만 1에 가까운 값을 보이나 +2주부터는 급격히 낮아지는 것을 볼 수 있다. BSISO 영향편차장의 강도는 예측된 지수의 강도에 의해 결정되므로 예측지수 자체가 과소모의하는 특성이 반영된 결과로 보인다. 또한, 예측 영향편차장을 산출하는 과정에서 전체 변동량에 대한 각 모드가 설명할 수 있는 변동량의 비율이 가중치로 들어가기 때문에 시그널이 스무딩 되는 효과가 있다.

Table 13. The pattern correlation coefficient for +3week forecast, evaluated from May 2016 ~ October 2021. The PCC for (a) ECMWF total anomaly, (b) BSISO-related anomaly, (c) strong BSISO-related anomaly, (d) strong BSISO1-related anomaly, (e) strong BSISO2-related anomaly.

	(a) ECMWF	(b) BSISO	(c) S.BSISO	(d) S.BSISO1	(e) S.BSISO2
OLR	0.29	0.29	0.51	0.45	0.38
Z500	0.31	0.27	0.52	0.41	0.33
U850	0.34	0.35	0.69	0.57	0.43
V850	0.22	0.20	0.41	0.32	0.26
T2M	0.22	0.24	0.32	0.33	0.23
PRCP	0.22	0.22	0.45	0.36	0.30

+3주에 BSISO 대류활동으로 야기되는 남동아시아 지역 대기순환 패턴 및 강도 모의성능이 ECMWF 예측과 비슷한 수준이지만 신뢰할만한 높은 값은 아니기에 BSISO 강도 및 위상에 따른 예측성도 각각 평가해보았다. 첫 번째로 +3주에 BSISO의 주평균 진폭이 1.5 이상인 경우를 ‘Strong BSISO’ 로 활동성이 강한 것으로 정의하였으며 BSISO 두 모드 동시에 강할 때(녹색), BSISO1 모드만 강할 때(주황색), BSISO2 모드만 강할 때(분홍색)로 나누어 살펴보았다(Figure 89). 세 가지 경우에 대해 모든 변수가 ECMWF 총편차장의 PCC 값보다 같거나 높은 값을 보인다. 특히 BSISO 두 개의 모드가 동시에 강할 때 OLR, 500hPa 지위고도,

850hPa 동서바람 편차장은 0.5 이상으로 높은 상관관계를 보여준다(Table 13). 두 번째로 여름철 우리나라 기온 및 강수 변동에 영향을 미치는 위상이 발생했을 때 예측성을 평가해보았다(Figure 90). +3주 예측에서 우리나라 기온을 상승시키는 데 기여하는 위상(BSISO1 위상 6 및 BSISO2 위상 1-2) 또는 적은 강수를 유발하는 위상(BSISO1 위상 8 및 BSISO2 위상 4-5)이 적어도 3일 이상 발생했을 때 PCC 값이 0.5 이상으로 여름철 평균 ECMWF 모의성능을 증가하는 결과를 나타낸다. ‘warm phase’ 일 때 ECMWF 모델에서 예측된 BSISO 영향편차장을 살펴보면(Figure 91) 아열대 서태평양에서 대류가 강화되고 우리나라 부근 고기압성 순환 편차가 유도되면서 우리나라를 포함하는 북동아시아 지역에서 기온이 상승하는 모습이 잘 나타난다. 또한 ‘dry phase’ 일 때 필리핀해 부근 대류 억제되고 일본 남쪽 해상에서 대류 강화, 우리나라 부근 대류 억제되는 삼중셀 구조의 OLR 분포를 보이면서 우리나라 남쪽으로 저기압성 흐름이 북서태평양고기압발달(북서태평양고기압 축소)되고 북동풍 및 하강운동 강화로 인해 적은 강수가 모의되는 것을 볼 수 있다. 많은 강수를 유도하는 위상(BSISO1 위상 5 및 BSISO2 위상 7-8)이 발생했을 경우 여름철 평균 ECMWF 모의성능에 약간 못 미치는 수준이지만 해당 날에 대한 ECMWF의 PCC 값보다는 모두 높게 나타나는 것을 확인할 수 있다. 반면 기온을 하강시키는데 기여하는 위상(BSISO1 위상 2 및 BSISO2 위상 5-6)이 발생한 경우는 낮은 공간패턴 상관관계를 보여준다. 반면, 강도에 대한 예측력은 +3주 BSISO 활동이 강할 때 다소 높아지기는 하나 여전히 관측보다 약한 것을 확인할 수 있다(Figure 89 e~h). 주요 영향위상에 대한 대류활동 및 대기 반응에 대한 강도는 전반적으로 과소모의 하는 경향이나 ‘dry phase’ 일 때 관측과 거의 유사하거나 조금 더 강한 반응으로 예측된다(Figure 90 e~h).

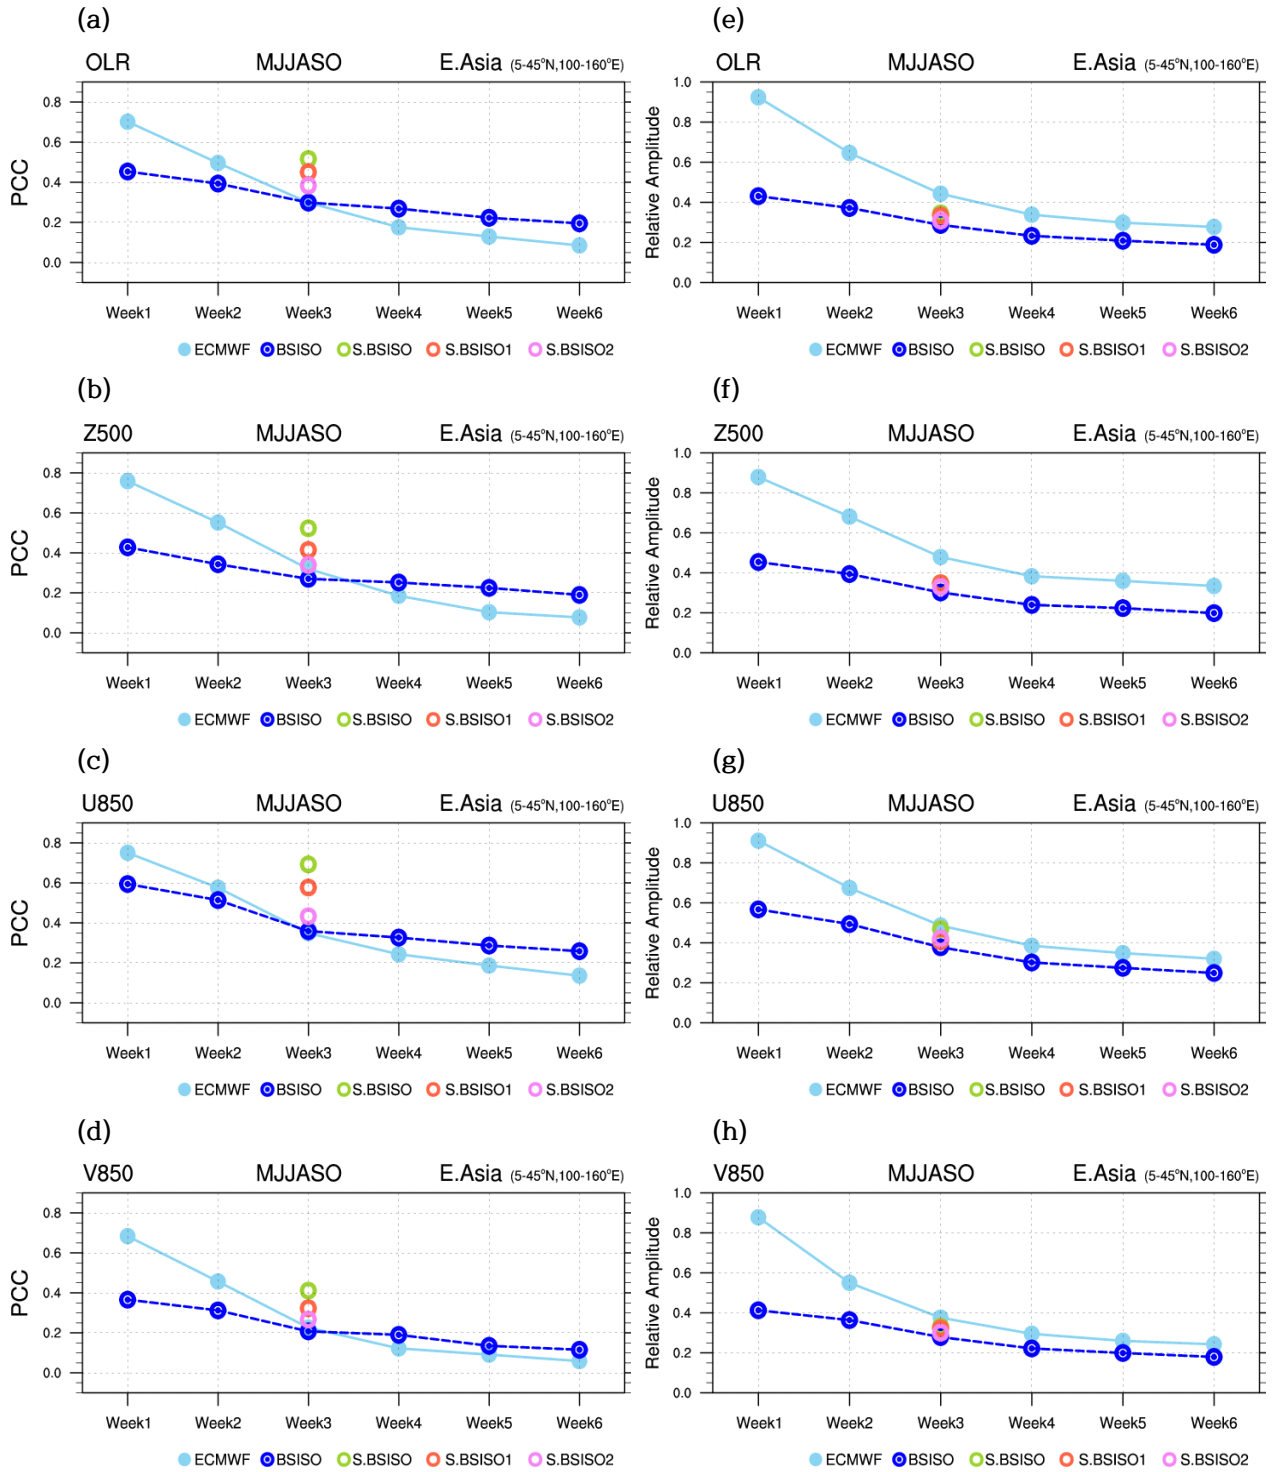


Figure 89. The pattern correlation coefficient and relative amplitude of OLR, 500hPa geopotential height, 850hPa zonal wind, 850hPa meridional wind anomalies associated with ECMWF (sky blue), BSISO (blue), strong BSISO (green), strong BSISO1 (orange), and strong BSISO2 (pink) over East Asia region.

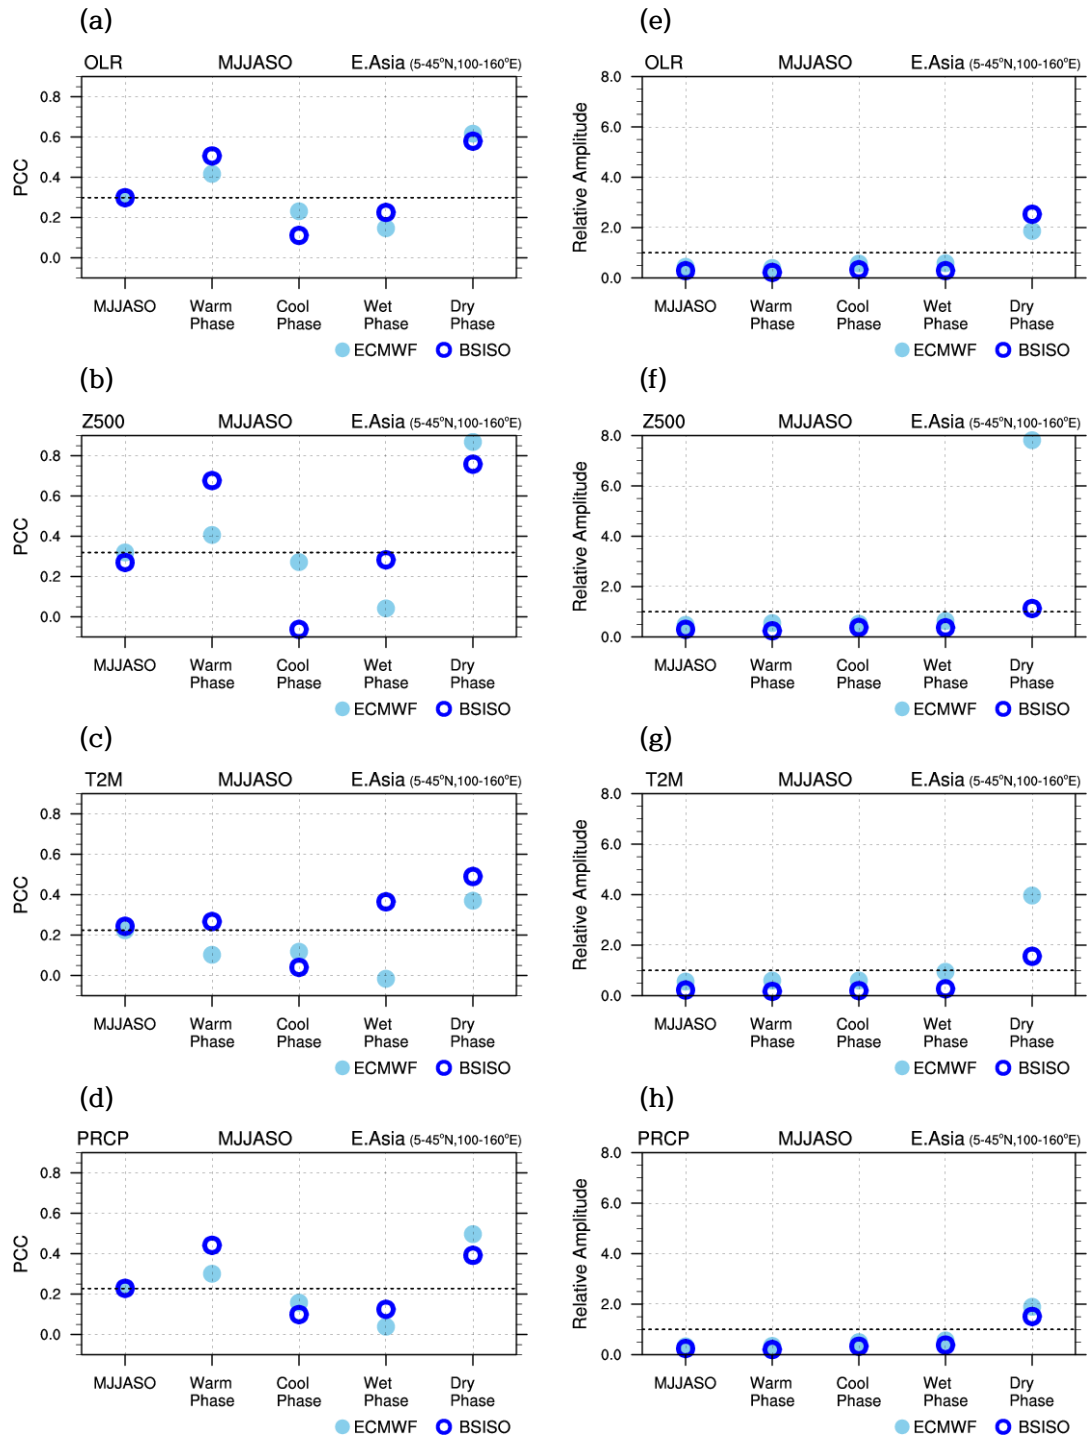


Figure 90. The pattern correlation coefficient and relative amplitude of OLR, 500hPa geopotential height, 2m temperature, precipitation anomalies for +3week forecast during the extended summer (MJJASO), warm phase, cool phase, wet phase, and dry phase. Blue open circle(sky blue filled circle) indicates the ECMWF total anomaly (BSISO-related anomaly).

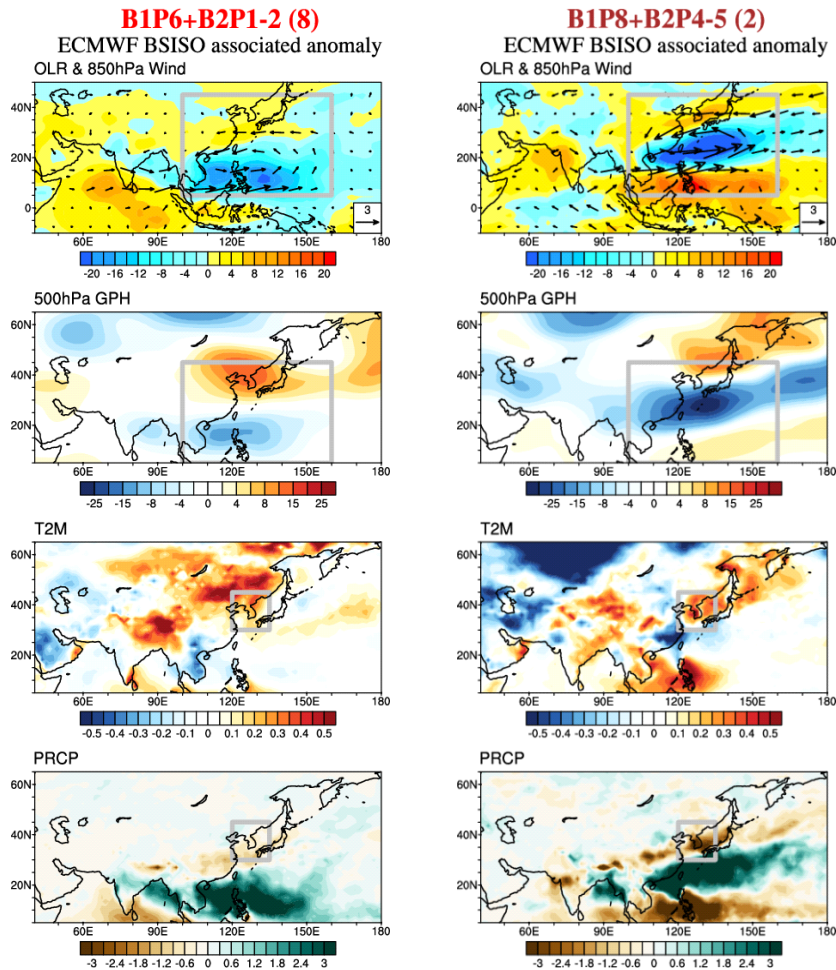


Figure 91. BSISO associated anomaly composites of warm phase case and dry phase case for +3week forecast.

지금까지 분석 결과를 바탕으로 1개월 전망 예보에서 중점적으로 보는 +3주 예측에 대한 BSISO 영향편차장의 패턴 모의성능이 높은 정보만을 선별하고자 하였다(Figure 92). BSISO 대류활동 및 우리나라를 포함한 남동아시아 지역에서의 원격상관 반응을 보기 위해 OLR 및 500hPa 지위고도 편차장을 기준으로 ECMWF 모델의 여름철 평균 PCC 값보다 큰 경우를 선정하였다. 주평균 강도가 1.5 이상일 때를 활동성이 강한 것으로 정의하였고 BSISO1 모드만 강한 경우, BSISO2 모드만 강한 경우, 두 모드 동시에 강한 경우 모두 예측성이 높게 나타난다. 또한 BSISO1 모드와 BSISO2 모드 동시상관으로 우리나라에 고온 또는 소우를 유발하는 위상이 3일 이상 발생할 때, BSISO1 모드의 위상 6 또는 위상 7(폭염 발생 확률 높음)이 4일 이상 발생할 때, BSISO2 모드의 위상 1, 위상 2, 위상 8이 4일 이상 발생할 때 높은 예측성을 보인다. 우리나라에 양의 강수 편차를 유도하는 위상(BSISO1 P5+BSISO2 P7-8)과 장마 시작과 관련 있는 BSISO2 모드의 위상7 시기 또한 ECMWF 기준 값을 능가하지 못하지만 거의 유사한 수준으로 나타나므로 예의주시할 필요가 있다.

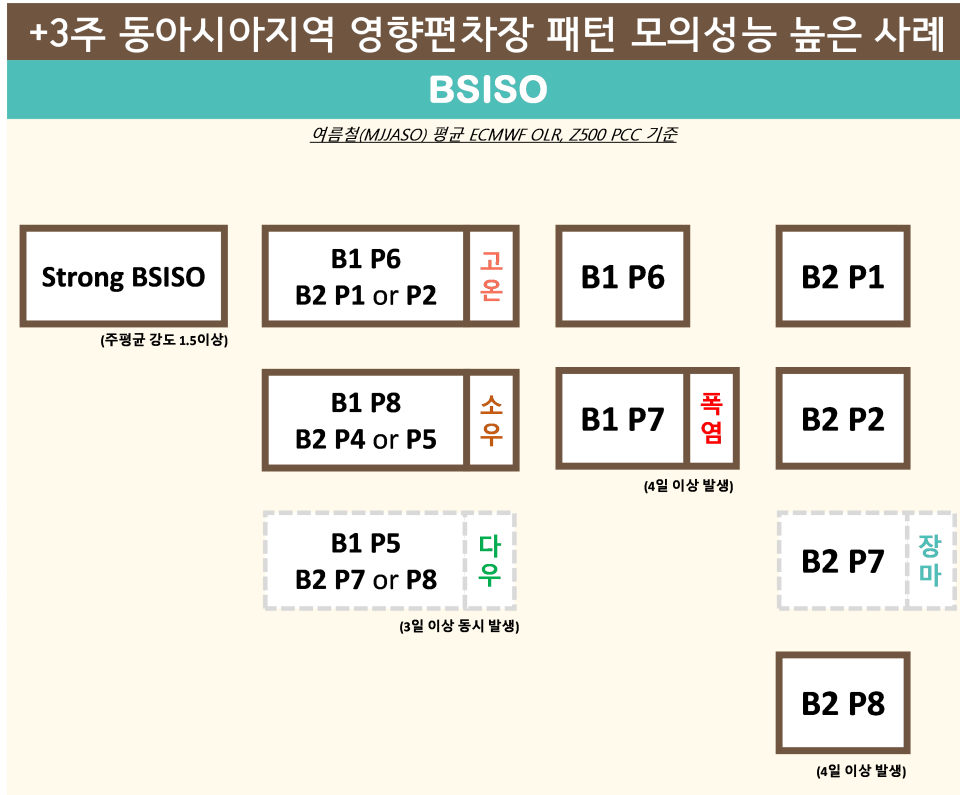


Figure 92. Summary of skillful BSISO impact forecast with 3-weeks lead time in East Asia during boreal summer.

(나) BSISO 예측정보 활용사례 분석

① 2022년 장마

2022년 장마는 6월 23일에 시작하여 7월 25일에 종료되며 전형적인 시종일을 기록하였다. 장마기간 BSISO1 및 BSISO2 활동을 주별로 나눠서 위상 및 강도를 살펴보았다(Figure 93). 평년 대비 강수 많은 시기를 파란색 계열로 평년과 비슷한 시기는 녹색 계열로, 평년 대비 강수 적은 시기를 주황색으로 표기하였다. 흥미롭게도 많은 강수량을 기록한 장마 시작시기와 종료시기에 BSISO 활동이 강했는데 BSISO1 모드와 BSISO2 모드가 거의 동일한 위치와 속도로 움직이는 모습을 확인할 수 있다. 공통적으로 BSISO2 모드는 위상 7-8에 위치하고 BSISO1 모드의 경우 시작시기에는 위상 3에 종료시기에는 위상 3에서 위상 2로 이동하는 모습을 보여준다. 장마 시작시기의 BSISO 영향편차장(Figure 94)을 살펴보면 열대 동인도양에서 대류가 강화되고 아열대 서태평양에서 대류억제역이 나타나는데 6월 하순 OLR 분포와 상당히 유사한 패턴을 나타낸다. 대류억제역이 위치하는 우리나라 남쪽 해안을 중심으로 고기압성 순환이 강화되고 이는 북서태평양고기압 확장에 기여하는 것으로 보이며 고기압 가장자리를 따라 남서풍 및 수증기 유입이 강화되면서 강수 증가를 유도하는 패턴으로 나타난다. 또한 7월 중순 장마 종료시기의 OLR 분포를 살펴보면 시작시기와 유사하나 대류강화 구역이 좀 더 서쪽에 위치하고 대류억제역도 남중국해 부근으로 이동한 모습이 나타나는데 BSISO 영향장에서도 유사한 패턴이 나타남을 확인할 수 있다. BSISO1 모드가 위상 3에서 위상 2로 이동하면서

중양인도양에서 대류가 강화되고 대류 억제구역이 남서진하면서 우리나라 남쪽에 받쳐주고 있던 고압대가 점차 물러나면서 북서태평양고기압 및 정체전선을 남하시키는 데 기여한 것으로 판단된다. 장마 시작시기 및 종료시기 모두 정체전선에 의한 강수가 발생했지만 시작시기는 중부지방을 중심으로 종료시기는 남부지방을 중심으로 비가 많이 내렸고 BSISO 활동이 북서태평양고기압 발달 및 이동에 영향을 주며 정체전선의 북상 및 남하에 일부 기여한 것으로 보인다. 또한 BSISO2 모드 영향으로 우리나라 부근으로 길게 늘어진 front-like 수평구조를 가지는 대류 발달역이 존재하며 장마 종료시기에는 좀 더 남쪽에 위치하는 것을 볼 수 있다.




Figure 93. BSISO1 and BSISO2 phase space diagrams from June 20, 2022 to July 24, 2022.

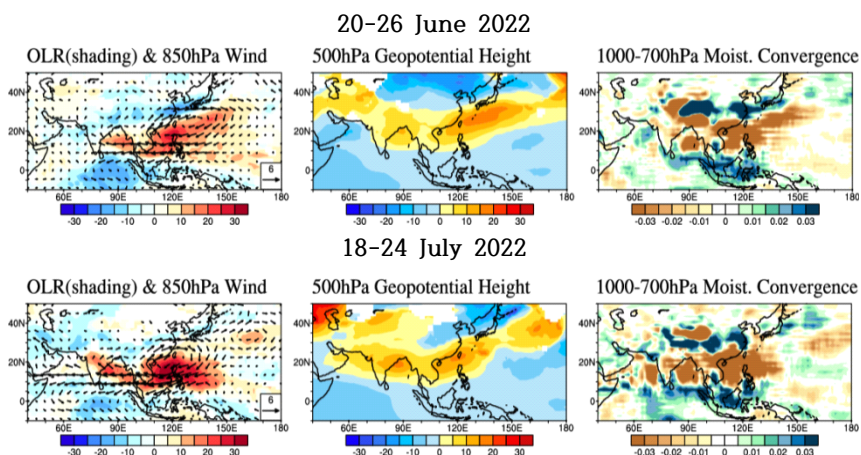


Figure 94. Observed weekly mean of BSISO-related anomalies for 20~26 June and 18~24 July 2022, respectively.

기상청 발표 기준 1981년부터 2016년까지 장마 시작일에 가장 빈번하게 나타나는 BSISO 위상을 살펴보았다(Figure 95). 주로 BSISO1 모드는 위상 5, BSISO2 모드는 위상 7에 위치할 때 장마가 시작되었으며 이는 여름철에 우리나라에 양의 강수 편차를 유도하는 위상 중 하나이고 특히 남부지역을 중심으로 강수가 많은 것을 볼 수 있다(Figure 96). 전국평균 장마기간(6/23~7/25) 관측 합성장을 살펴보면 공통적으로 아열대 북서태평양 부근에 대류가 약화되고 고기압성 순환이 강화되면서 남부지역으로 남서-북동 방향으로 기울어진 좁은밴드 형태의 대류 발달역이 존재한다. 또한 고기압성 흐름의 북쪽 가장자리로 남서풍에 의한 온난다습한 공기유입이 활발하고 심층대류 발생지역에서 연직운동 및 북쪽으로 상층제트가 강화되는 특징이 나타난다. 따라서 BSISO1 위상 5 및 BSISO2 위상 7 시기에 정체전선이 만들어지는 환경을 조성하는데 호조건이 형성된다. Figure 97은 장마기간 일강수량 편차의 총성분, 계절내성분, 30~60일 주기 성분, 10~20일 주기 성분에 대한 변동성을 보여준다. 30~60일 주기보다 더 짧은 10~20일 주기성을 가지는 BSISO2 모드가 강수 변동성에 더 많이 기여하는 것으로 보이며 장마 시기에는 BSISO1 모드보다 BSISO2 모드의 활동이 더 큰 영향을 미치는 것으로 판단된다.




Figure 95. Changma onset phase space diagram based on the BSISO1/BSISO2 index for each year from 1981~2016.

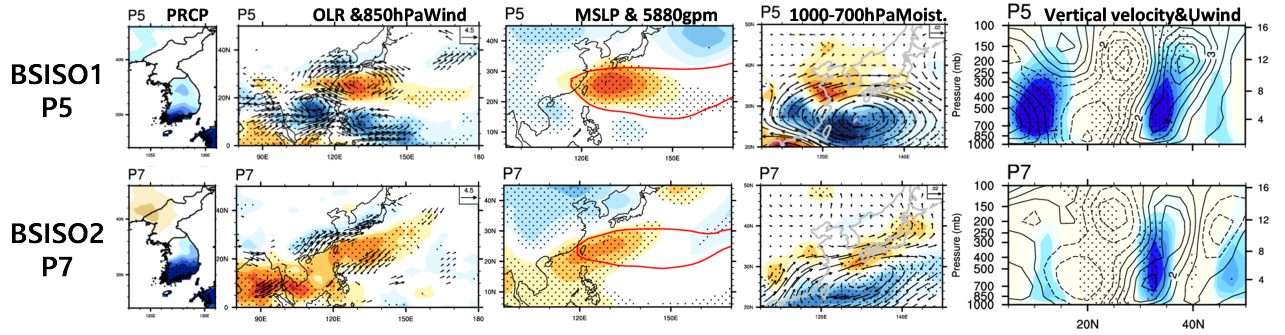


Figure 96. Composites of precipitation, OLR and 850-hPa wind, MSLP and 5,880gpm, 1000-700hPa vertically integrated moisture transport and convergence, vertical velocity and zonal wind anomalies during BSISO1 phase 5 and BSISO2 phase 7, respectively.

1981-2007 Changma season daily rainfall variance

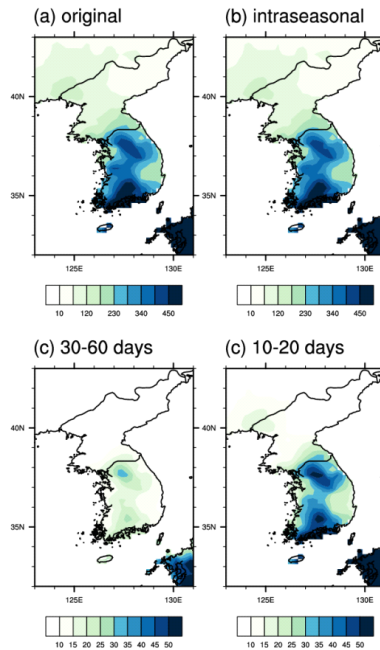


Figure 97. The variance of (a) total (b) intraseasonal (c) 30-60-day filtered (d) 10-20-day filtered rainfall anomaly during Changma.

다음으로 장마 시작시기와 종료시기에 대해 3주 전 예측된 BSISO 영향편차장을 살펴보았다(Figure 98). BSISO1 모드의 경우 한 위상 정도 느리게 이동하지만 BSISO2 모드는 위상 7에서 강하게 발달함에 따라 우리나라 남쪽 고기압성 순환 강화 및 남서풍에 따른 수분수렴이 강화될 것으로 잘 예측되었다. 반면 장마 종료 시기에는 BSISO1 모드의 경우 위상 3에서 위상 2로 이동하는 위상 및 방향은 적중했지만 강도가 너무 약하고 BSISO2 모드는 관측보다 더 빠른 속도로 이동할 것으로 모의되면서 두 모드에 의한 시그널을 감지하기 어려웠고 오히려 2주차

에 많은 강수가 유도되는 패턴으로 예측되었다.

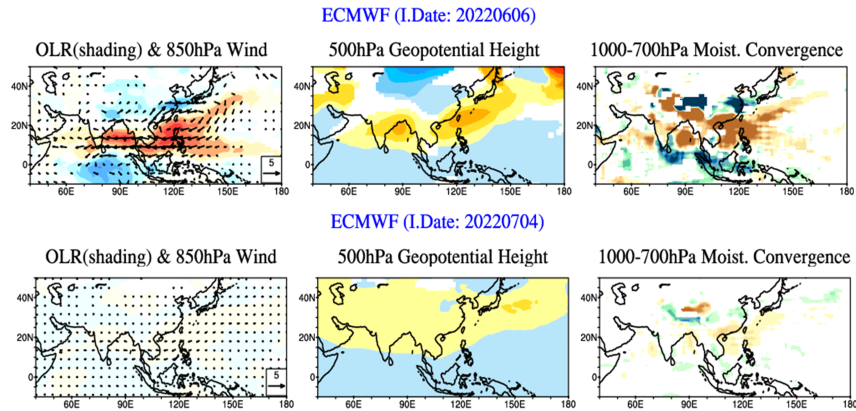


Figure 98. ECMWF weekly mean of BSISO-related anomalies for 20~26 June and 18~24 July 2022 at 3-weeks lead time, respectively.

② 2022년 8월 폭우

8월 초중순 우리나라 남쪽으로 고기압성 순환이 북쪽으로 저기압성 순환이 강화되면서 그 경계에서 발달하는 정체전선 영향으로 중부지방 중심으로 많은 강수량이 기록되었다. 8월 8일부터 14일까지 BSISO1 모드는 위상 5, BSISO2 모드는 위상 6-7에서 강하게 발달한 상태였고(Figure 99) 두 모드가 결합된 OLR 영향편차장을 살펴보면(Figure 100) 벵갈만부터 필리핀해까지 기울어진 형태로 대류가 강화되고 그 북쪽으로 대류억제역이 위치하는 모습을 볼 수 있다. 인도양과 필리핀해 부근의 대류활동은 실제 관측 패턴과도 유사한 모습이다(not shown). 그러나 500hPa 지위고도 편차장은 실제 관측 패턴과 차이가 있음을 알 수 있는데 인도-서태평양에서부터 저기압성 흐름이 강화되면서 아시아 대륙에서 북동쪽으로 파동이 전파되는 모습과는 다르게 BSISO 활동에 의한 파동 전파 반응은 좀 더 동쪽으로 치우쳐서 우리나라 남쪽으로 고기압성 흐름 일본 동쪽 해상에 저기압성 흐름이 강화되는 형태로 해양에서 나타난다. 따라서 BSISO 활동은 우리나라 북쪽의 상층골 발달과는 무관하며 오히려 일본 남쪽 해상의 고기압성 흐름 강화에 기여한 것으로 보이며 남서풍에 의한 수증기 유입이 활발해지면서 우리나라 강수 증가를 유도하는 패턴으로 나타나는 것을 확인할 수 있다. 7월 25일 월요일 초기장으로 예측된 ECMWF BSISO 위상 및 강도 분포를 살펴보면(Figure 99), BSISO1 모드는 빠른 속도로 이동하고 BSISO2 모드도 전혀 다른 위상을 모의함에 따라 3주 전 BSISO 활동에 의한 다우 가능성을 예측하기 어려웠다.

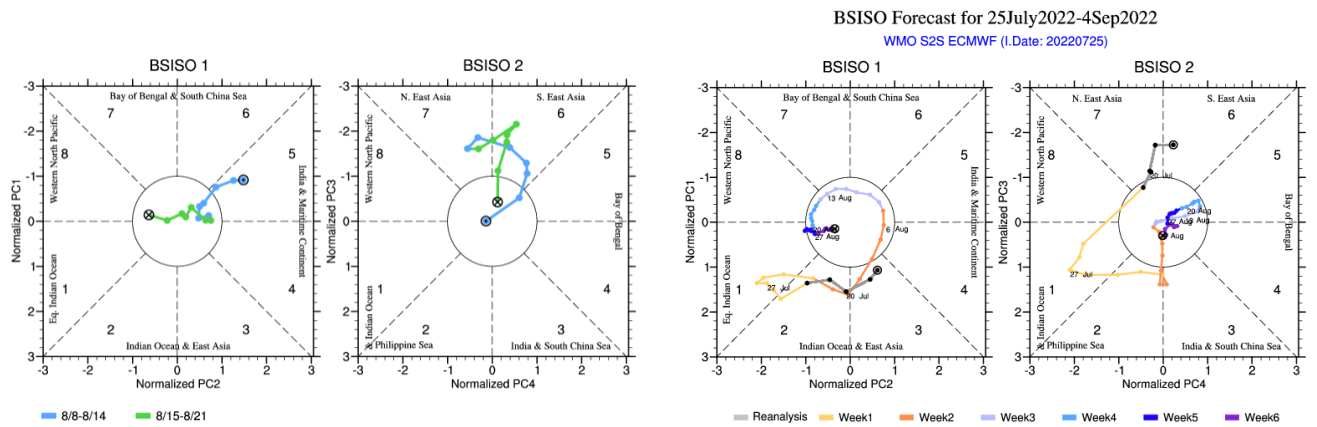


Figure 99. BSISO phase space diagram of heavy rain event for observation (left) and +3week forecast (right).

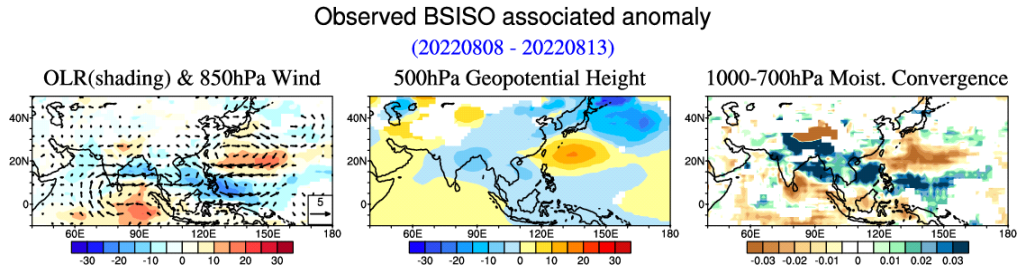


Figure 100. Weekly mean of observed BSISO-related anomalies from 8~14 August 2022.

③ 2016년 8월 폭염

2016년 8월 기온은 평년 대비 1.6°C 높았고 극심한 폭염과 열대야가 지속되었다. Lee et al.(2019)은 경년 시간규모에서 ENSO 원격상관 패턴에 의한 영향뿐만 아니라 계절내 시간규모에서 BSISO1 모드가 북서태평양 몬순 지역의 활발한 대류활동과 연계되어 폭염 발생에 기여함을 밝힌 바 있다. 따라서 8월 중 일평균 기온 편차의 최대값이 기록되는 8월 둘째주(8/8~14)에 관측되는 BSISO 활동과 3주 전 ECMWF 모델의 예측결과를 살펴보고자 한다. 8월 8일부터 14일까지 주평균 기온은 2.8°C 높고 강수량도 10퍼센타일로 매우 적었다. BSISO2 모드는 약한 진폭으로 위상 1-2에, BSISO1 모드는 강한 진폭으로 위상 7에 위치하였는데(Figure 101) BSISO1 위상 7 시기에 아열대 서태평양 부근에서 대류활동이 활발한 반면 인도 및 동아시아 지역에서는 고기압성 순환과 함께 대류활동이 약화되는 특성을 가진다. BSISO1 모드는 일주일 내내 위상 7에 위치하면서 아열대 북서태평양 지역에서 대류를 발달시키고 양의 Pacific-Japan(PJ) 원격상관이 발생되어 동아시아 지역에 강화된 고기압성 흐름이 우리나라 기온상승에 기여한 것으로 보인다. BSISO1 모드 위상 7-8일 때 고기압 편차가 우리나라 부근에 자리잡을 경우 단일 하강에 의한 기온상승으로 폭염 발생 가능성을 보여주는 연구 결과(Hsu et al., 2017)도 있다. 3주 전 ECMWF 모델에서 BSISO1 모드가 강한

강도로 위상 7에서 지속될 것으로 보면서 관측과 유사한 패턴으로 모의함에 따라 고온 가능성을 보여주고 있다. 2016년부터 2021년까지 +3주 BSISO1 모드 위상 7이 4일 이상 발생할 때 예측성을 살펴보면(Figure 102), 관측에서 나타나는 남동아시아 지역의 대류활동 및 기압패턴을 잘 모의하고 500hPa 지위고도 및 기온의 경우 0.4 이상의 높은 공간패턴 상관관계를 보이면서 우리나라 고온 또는 폭염 예측 시 활용도가 높을 것으로 기대된다.

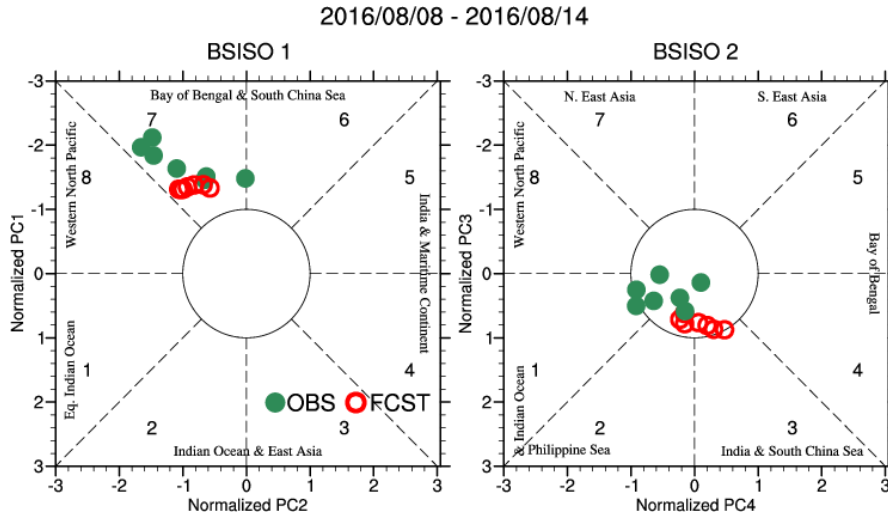


Figure 101. The phase points of observation and +3week forecast for 8~14 August, 2016.

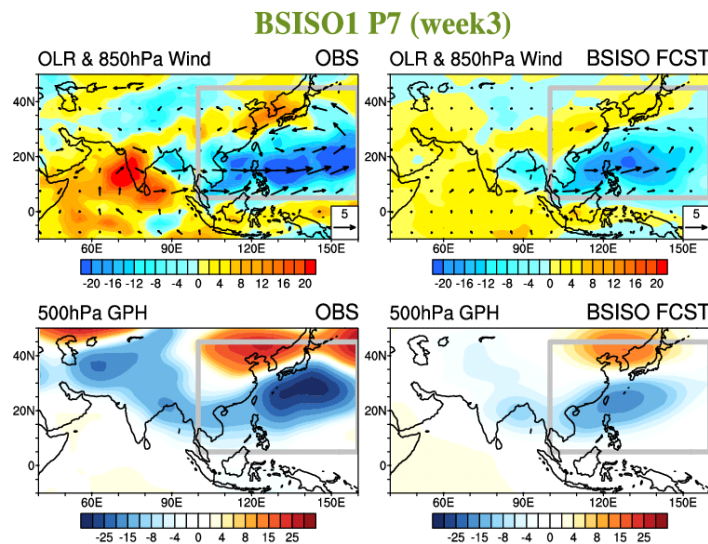


Figure 102. Composite anomaly map of OLR, 850hPa wind and 500hPa geopotential height for the observation and +3week forecast in BSISO1 P7.

(2) 딥러닝 기술을 활용한 1개월 기온 확률예측 시스템 구축

(가) 1개월 기온예측 딥러닝 모델 실험 및 결과 분석

딥러닝 모델의 실험은 ERA5 재분석자료 중 6시간 단위의 T2M 변수자료를 이용하여 일 단위 자료로 변환 후에 사용하였다. 시계열 자료를 학습데이터로 이용할 때는 시계열 자료의 정상성(stationarity)이 중요하다. 정상성은 데이터에 추세, 계절성, 수준(level) 등의 시계열 성분이 없는 데이터를 말한다. 시계열 성분 제거기법에는 선형회귀, 이동평균 등 추세-주기 제거방법, 기후평년값을 이용한 계절성 제거 방법 등이 있다(Figure 103).

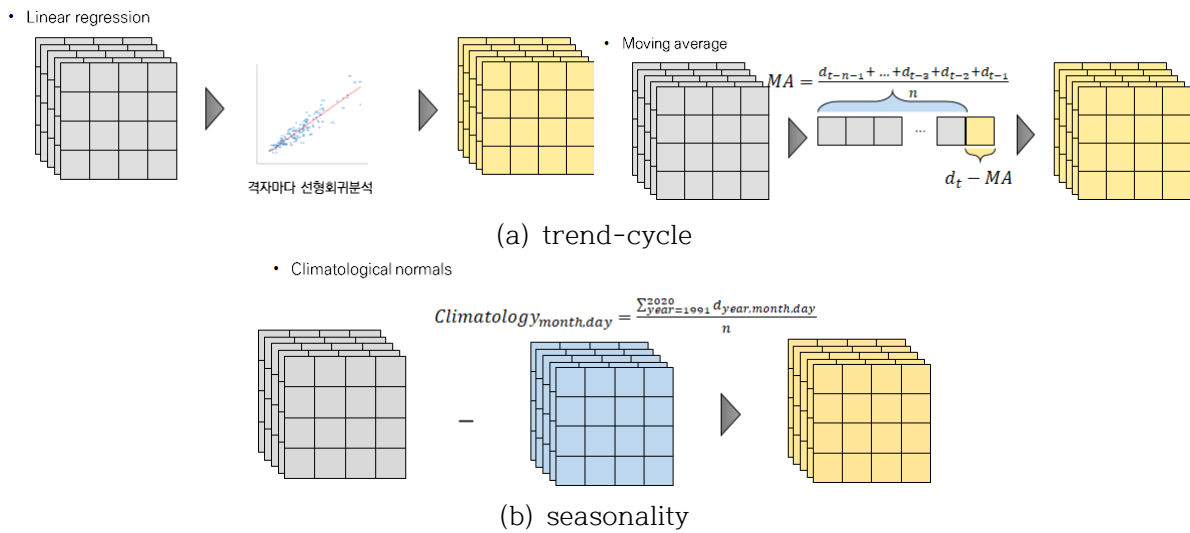


Figure 103. time-series data decomposition approaches

Figure 104는 원본 데이터에서 추세-주기 제거, 계절성, 추세-주기와 계절성을 모두 제거한 결과를 보여준다. 원본 데이터에서는 추세, 계절성이 뚜렷하게 나타난 반면, 선형회귀와 이동평균 기법에서는 추세가 거의 나타나지 않았다. 기후평년값을 이용한 계절성 기법에서는 추세-주기는 그대로지만 계절성은 뚜렷하게 사라졌다. 추세-주기와 계절성 제거 기법을 모두 적용한 경우에는 추세, 계절성 모두 사라진 것을 볼 수 있다.

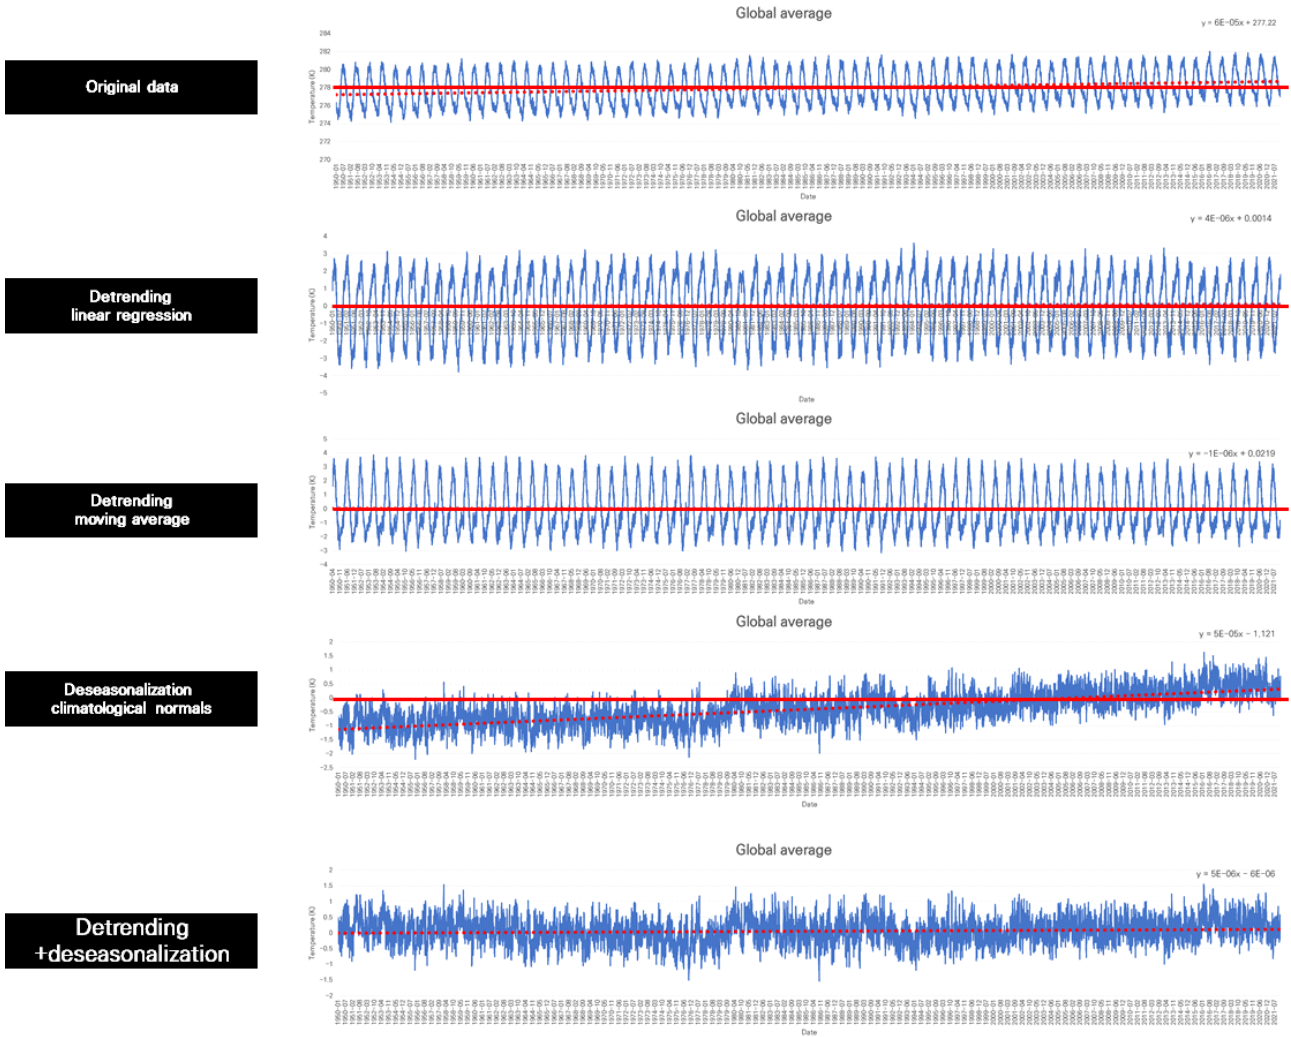


Figure 104. Results of detrending and deseasonalization of ERA5 T2M reanalysis global average data

그러나 딥러닝 학습(training)과 추론(inference) 과정에서 이러한 방법을 활용하는 데는 매우 복잡한 데이터 처리 과정이 필요하다(Figure 105). 특히 본 연구에서는 순환예측기법을 이용하기 때문에 전체 프로세스가 더 복잡해지는 문제가 있다. 따라서 입력자료의 데이터셋을 구축하는 단계에서 적용할 수 있는 데이터 셔플 기법을 이용하여 정상성 시계열 자료 확보를 시도하였다.

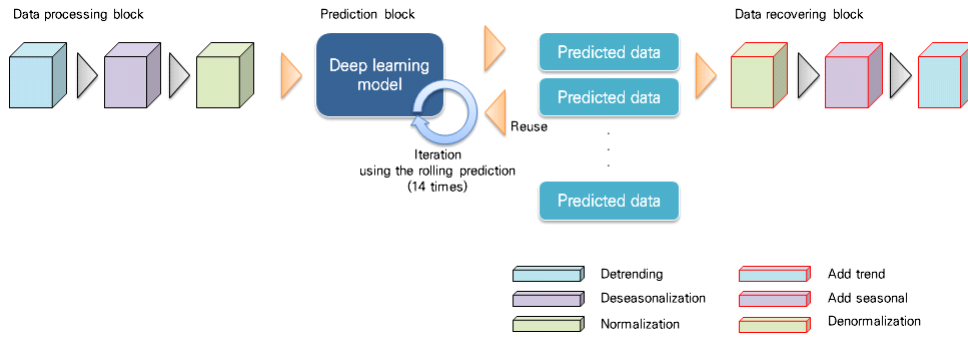


Figure 105. Process flowchart of removing and restoring trends and seasonality in deep learning training and inference.

전통적인 딥러닝 학습에서는 전체 데이터를 학습, 검증, 테스트로 데이터셋을 나누어 구축한다. 데이터 셔플은 테스트 데이터셋은 그대로 두고 딥러닝 모델 학습에 사용되는 학습과 검증 데이터셋 구축 후 순서를 섞은 후에 각 비율로 나누어 사용한다(Figure 106). 데이터 셔플 전과 후를 비교하면 셔플 후에 기존 추세-주기 방법과 계절성 방법을 제거했을 때보다 오히려 정상성이 뚜렷하게 나타난다(Figure 107). 데이터 셔플은 학습데이터셋 구축 과정에서 한 번만 수행하면 되기 때문에 기존의 방법에 비해 추론 과정을 설계하기 쉽고 정상성 데이터 확보도 용이한 장점이 있다.




Figure 106. Comparison of traditional approach and data shuffle approach.




Figure 107. Comparison of the results of data processing using traditional approach and data shuffle.

딥러닝 모델의 실험은 데이터 셔플이 수행된 데이터셋을 이용하여 학습하였다. 입력자료 1은 ERA5 T2M 재분석자료를 학습과 검증에 1986년부터 2015년까지 총 30년 기간의 데이터를 셔플링한 이후에 사용하였다(Table 14). 학습과 검증자료의 비율은 70%와 30%이다. 입력자료 2는 입력자료의 날짜 기준으로 과거 15년 기간의 기후평년값을 이용하였다. 예를 들어, 입력자료가 2020년 12월 27일, 12월 28일, 12월 29일, 12월 30일, 12월 31일, 2021년 1월 1일, 1월 2일, 1월 3일, 1월 4일, 1월 5일, 1월 6일, 1월 7일, 1월 8일, 1월 9일로 구성되어 있다면 2020년 기간은 2005년부터 2019년까지 자료로 계산한 기후평년값을 이용한다. 그리고 2021년 기간은 2006년부터 2020년까지 자료로 계산한 기후평년값을 이용한다. 테스트 데이터는 2018년부터 2021년까지 기간의 데이터를 이용한다. 2016년과 2018년은 남한지역 비교대상 자료인 ASOS 데이터로 계산한 결과가 없어서 평가기간에서 제외하였다.

학습모델은 입력자료 길이 14, 출력자료 길이 1, 활성화함수는 relu, 커널크기는 3×3, 풀링 방법은 MaxPooling, 드롭아웃은 0.5, 최대 에포크는 300, 옵티마이저는 ADAM, 학습률은 1e-4, 손실함수는 MSE(Mean Square Error)를 이용하였다(Table 15). 연구환경은 Python 3.8.11, Tensorflow 2.5.0, Matplotlib 3.4.2, Numpy 1.19.5, Pandas 1.4.0 등으로 구성된 파이썬 환경을 구축하고 딥러닝 모델 설계, 테스트, 평가 등을 수행하였다.

Table 14. Summaries for training, validation, and test dataset

	Name	Content
Input 1	Dataset	daily ERA5 reanalysis data
	Variable Name	T2M
	Train/Validation ratio	70% / 30%
	Training and validation period	1986 - 2015
	Test data period	2018 - 2021
Input 2	Dataset	daily ERA5 reanalysis data
	Variable Name	T2M
	Climate average period	15 years

Table 15. Initialize values and hyper-parameters for deep learning training

Name	Content
Input data length (#1, #2)	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)

딥러닝 모델의 학습 결과로써, 학습 손실값은 약 0.002, 검증 손실값은 약 0.0034에 수렴하였으며 학습 손실값이 검증 손실값을 교차하며 하락하였다. 에포크에 따른 학습과 검증 손실값의 수렴정도를 봤을 때 모델이 안정적으로 학습이 된 것으로 판단된다. (Figure 108).




Figure 108. Results of deep learning training and validation losses

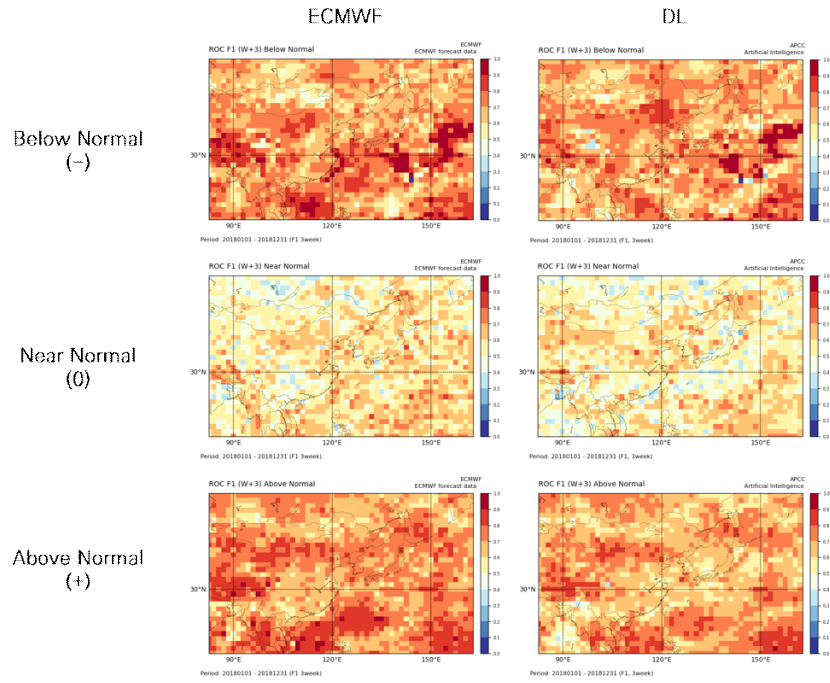
(나) 1개월 기온 확률예측 및 평가

① 동아시아 지역 1개월 확률예측 결과 및 평가분석

테스트 기간인 2018년부터 2021년까지의 ECMWF 예보자료와 hindcast자료를 이용하여 예측자료를 생산하고 확률예측을 수행하였으며, 동아시아 지역의 ROC score map을 작성하고 비교하였다. ROC score가 0.5를 기준으로 빨간색일수록 예측성이 높고, 파란색일수록 예측성이 낮음을 의미한다. Figure 109~112는 2018년부터 2021년까지 년도별 ROC score map 분석 결과이다. ECMWF에 비해 딥러닝 모델이 above normal의 예측성이 다소 낮게 나타났다. 이는 딥러닝 모델이 above normal을 예측하는 확률이 상대적으로 낮다는 의미로, 즉, 기온상승을 과대추정하지 않는 것을 의미한다. 그러나 최근 이상고온 현상이 자주 발생하는 상황에서 딥러닝 모델이 이러한 현상을 상대적으로 덜 모의함으로써 이상고온과 같은 현상은 낮은 예측성을 보일 수 있다. 전반적으로 +3주와 +4주 예측성은 비교대상 모델인 ECWFM과 비슷한 양상을 보였다. 이는 딥러닝 모델이 학습이 잘 되었음을 의미한다. 전체기간의 ROC score map은 +3주는 비슷한 예측성을 보였고 +4주는 딥러닝 모델의 예측성이 다소 높은 경향을 보였다(Figure 113).

2018

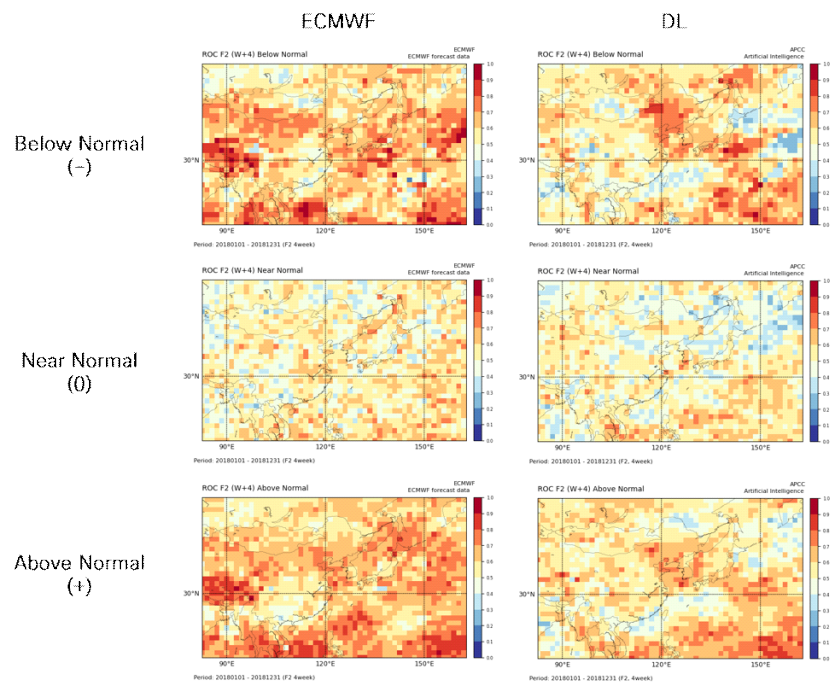
F1 (+3week)



(a)

2018

F2 (+4week)

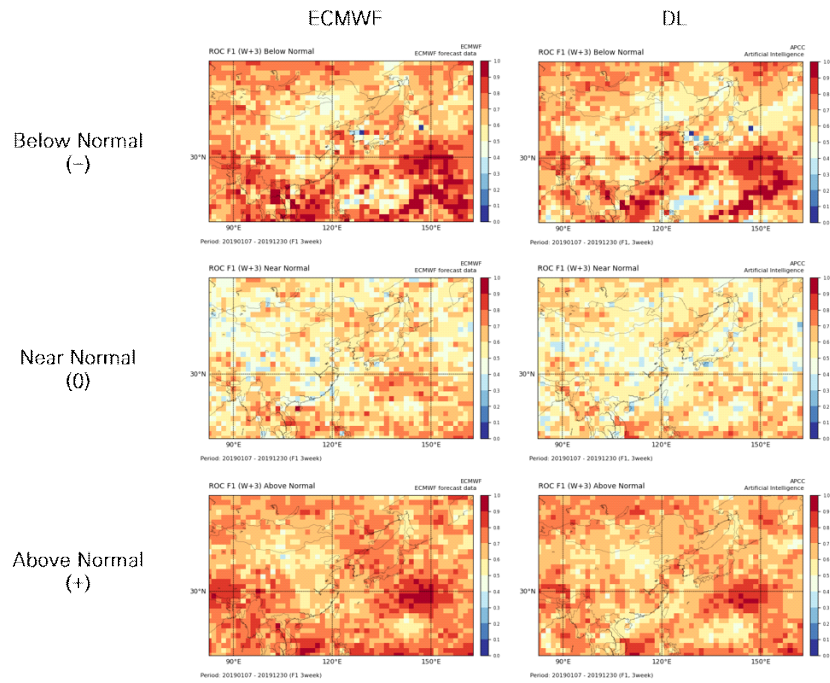


(b)

Figure 109. ROC score map around East Asia in 2018: (a) +3week, (b) +4week

2019

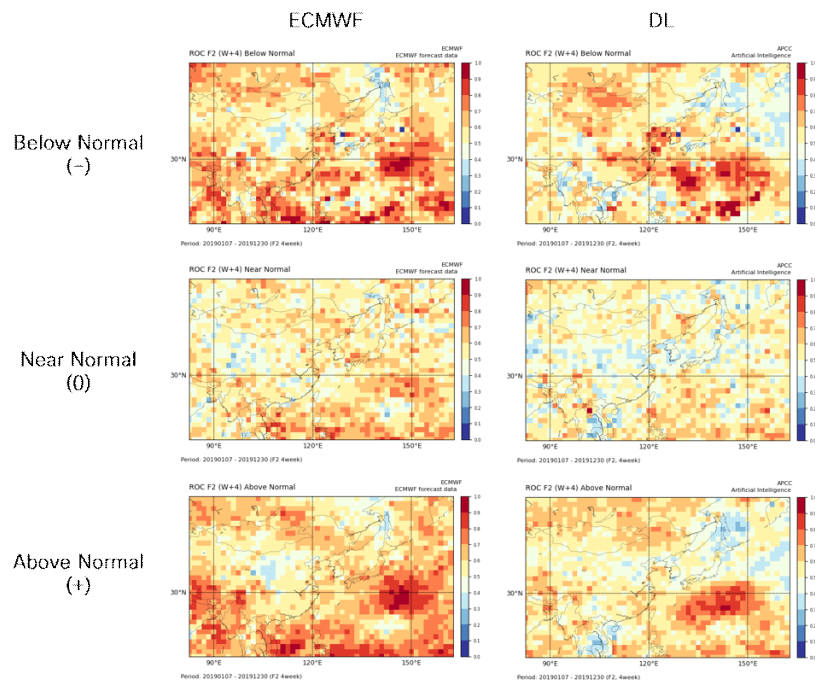
F1 (+3week)



(a)

2019

F2 (+4week)

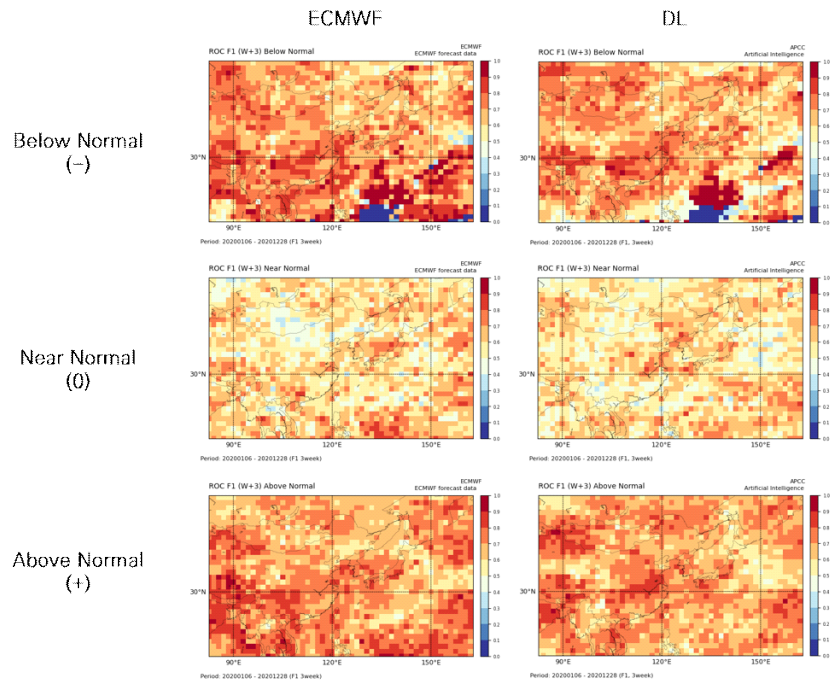


(b)

Figure 110. ROC score map around East Asia in 2019: (a) +3week, (b) +4week

2020

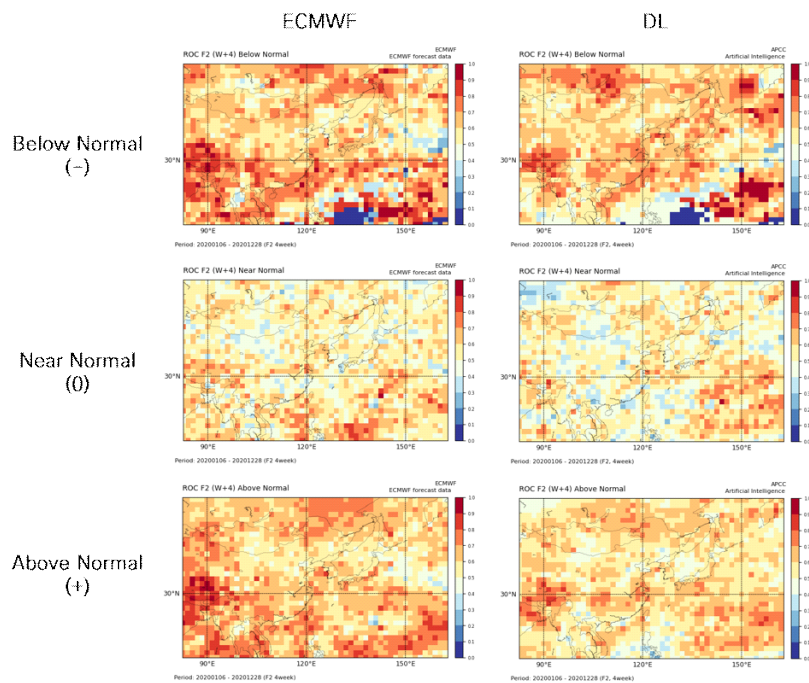
F1 (+3week)



(a)

2020

F2 (+4week)

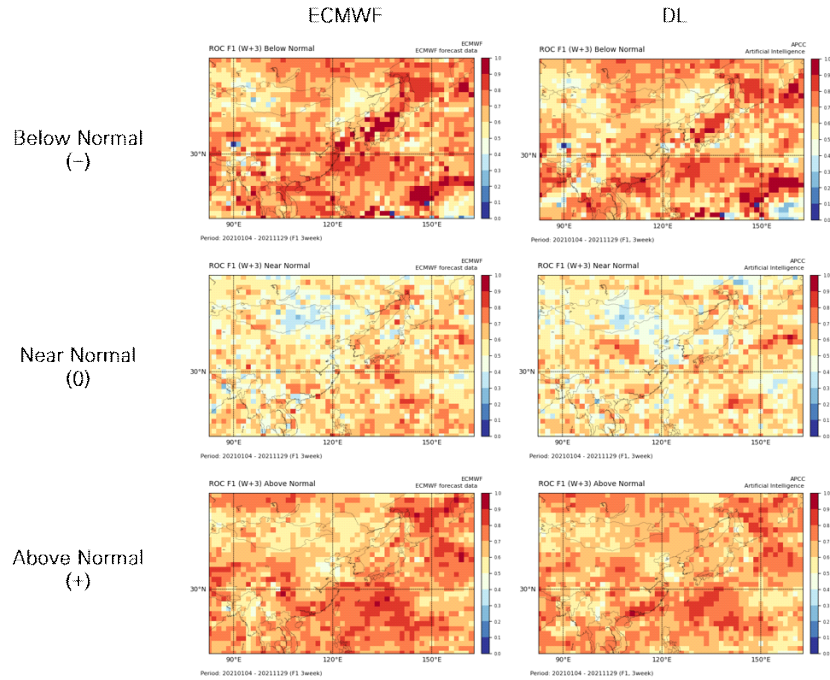


(b)

Figure 111. ROC score map around East Asia in 2019: (a) +3week, (b) +4week

2021

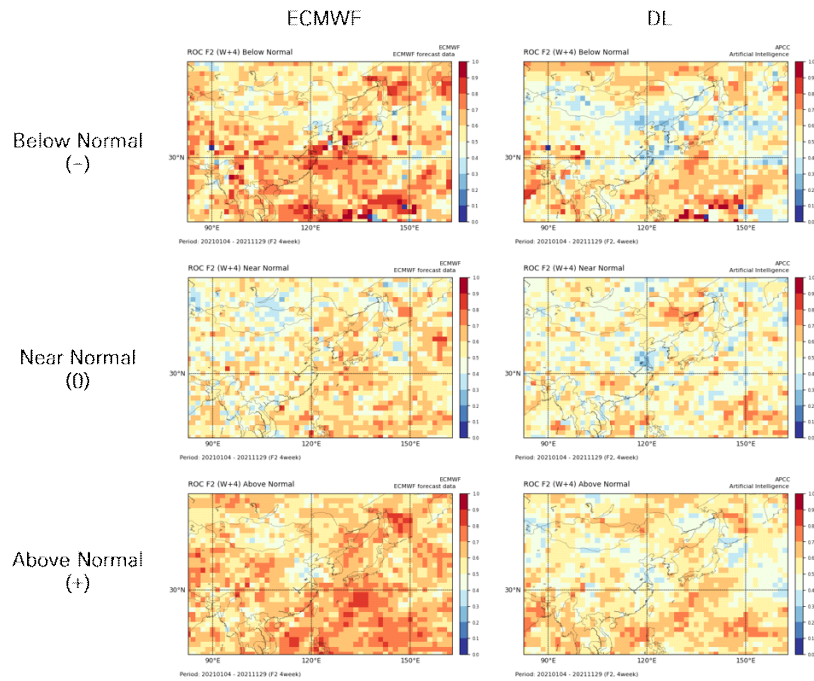
F1 (+3week)



(a)

2021

F2 (+4week)

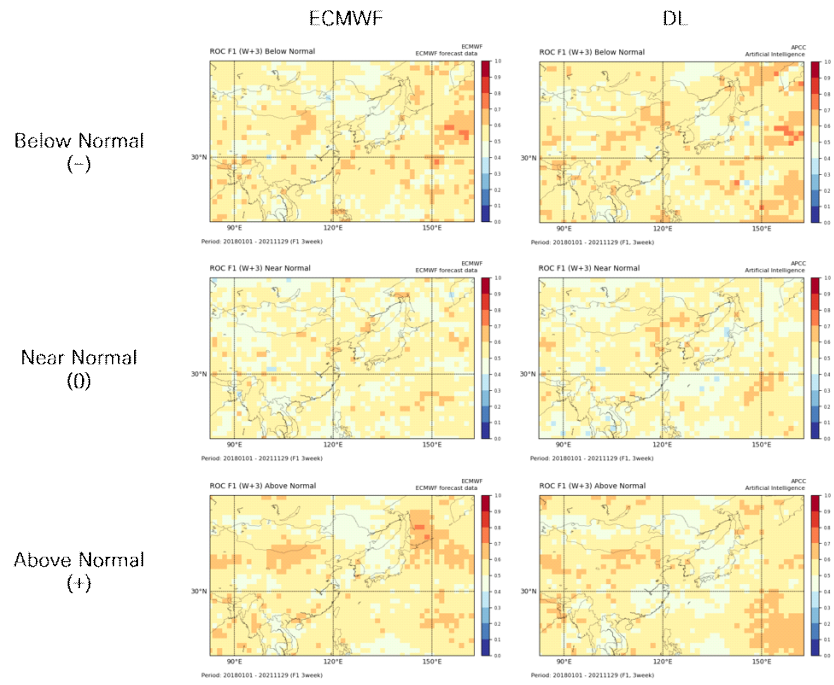


(b)

Figure 112. ROC score map around East Asia in 2019: (a) +3week, (b) +4week

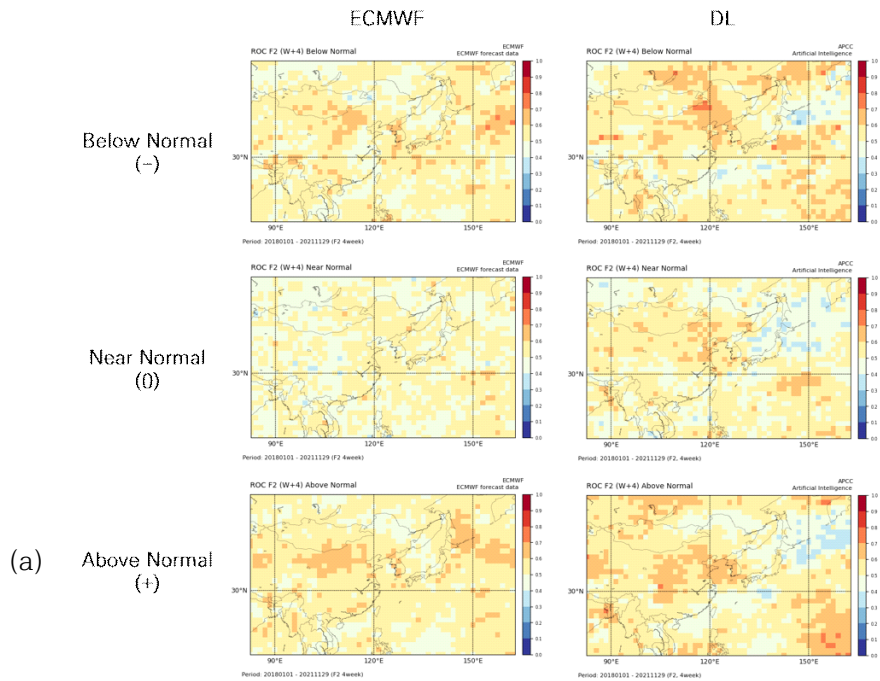
2018-2021

F1 (+3week)



2018-2021

F2 (+4week)



(b)

Figure 113. ROC score map around East Asia in 2018~2021: (a) +3week, (b) +4week

② 남한지역 1개월 기온 확률예측 결과 및 평가분석

남한지역 1개월 기온 확률예측은 ECWFM과 딥러닝 모델에서 예측한 확률값을 종관기상관측(ASOS, Automated Synoptic Observing System) 자료에서 산출한 below normal, near normal, above normal을 기준값으로 하여 비교하였다. 2018년부터 2021년 전체기간에서 비교 대상인 ECMWF보다 +3주와 +4주 모두 약간 높은 예측성을 보였다. +3주는 +0.0087, +4주는 +0.0089를 보였다(Figure 114).






Figure 114. HSS results in South Korea in 2018~2021: (a) +3week, (b) +4week

각 연도별 HSS 분석 결과, +3주에서는 딥러닝 모델이 2019년을 제외한 2018년, 2020년, 2021년에도 다소 높은 예측을 보였으며, +4주에서는 2019년 와 2020년을 제외한 2018년도와 2021년에서 다소 높은 예측성을 보였다(Figure 115). 특히 연도별 HSS 분석에서 2019년도의 경우에는 다른 년도에 비해 상당히 낮은 예측성을 보였다. 이러한 결과는 ECMWF 예보자료 +1-2주 데이터를 기반으로 +3-4주 예측성을 높이는 본 연구의 특성으로 인해 발생한 것으로 판단된다. 지도학습(SL, supervised learning)을 이용하여 개발한 딥러닝 모델은 학습에 사용된 데이터의 분포나 패턴을 벗어나는 이상치(outlier)에 가까운 데이터가 입력자료로 들어오면 예측성이 떨어지는 현상이 발생한다. 딥러닝 모델에서도 GIGO(garbage in, garbage out) 현상이 발생할 수 있다. Appendix A는 딥러닝 모델의 1개월 확률예측을 ERA5 재분석자료를 이용한 아노말리 자료, ECWFM 확률예측자료 등과 비교한 사례이다.



(a)



(b)

Figure 115. HSS results in South Korea by year: (a) +3week, (b) +4week

(다) 동아시아 지역 및 남한지역 1개월 기온 확률예측 결과 시각화

동아시아 지역과 남한지역의 1개월 기온 확률예측 결과는 Figure 116과 같이 시각화하였다. 동아시아 지역의 지도 그래프는 격자별로 3분위 확률예측 결과 중에서 가장 높은 예측을 보이는 값의 표현이 필요하다. 3분위 결과를 하나의 그래프로 표현하기 위해 격자별로 가장 높은 값을 제외한 나머지 값을 제외하는 시각화 과정에서 제외하는 방법을 이용하였다. 각 3분위 데이터를 개별로 중첩하여 하나의 동아시아지역 확률예측 지도를 작성하였다. 남한지역의 확률예측 결과는 막대차트로 표현하였다. 지역별로 표현된 시각화

결과를 하나로 통합하여 동아시아 지역의 기후패턴과 남한지역의 예측결과를 동시에 확인할 수 있도록 하였다.

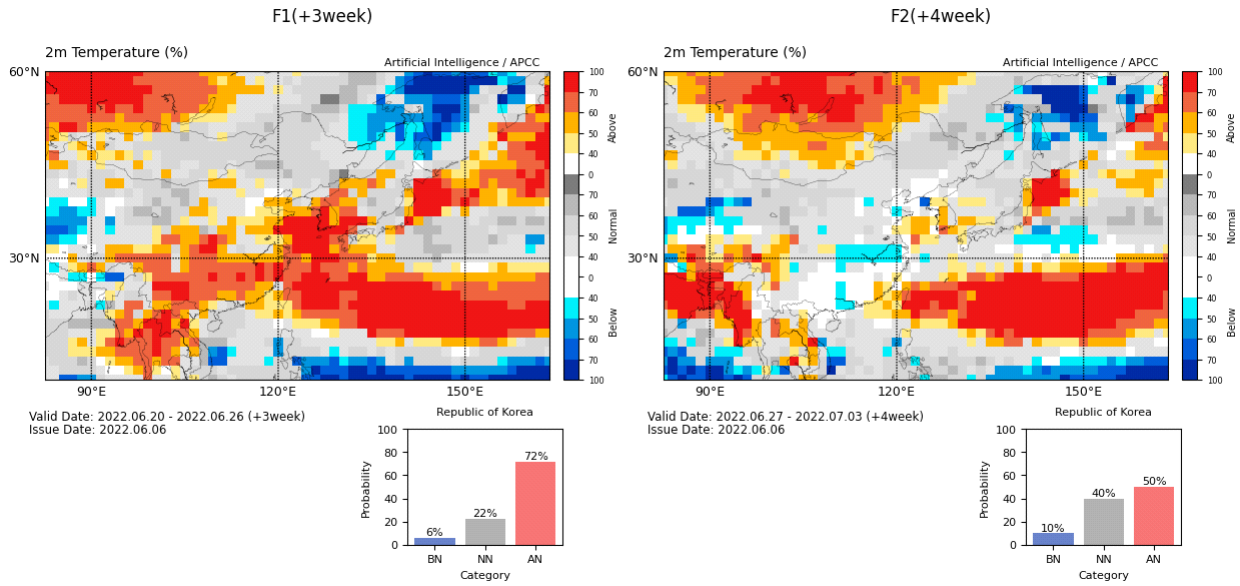


Figure 116. Example of visualization of map charts of probability forecast results around East Asia with charts of probability forecast results in South Korea by deep learning model: (left) +3week and (right) +4week

다. 국내 장기예보 전망 생산 지원

(1) 1개월 장기예보 시스템 운영/개선 및 신규 콘텐츠 개발

(가) 1개월 전망 발표자료 개선

① ECMWF hindcast 적용 방법 개선 현업화 완료

1개월 전망 예측성 향상을 위해서 다양한 연구를 수행 중이며, 그중 가장 기본이 되는 점은 계절내 예측 모델 자체의 예측성 향상이다. 하지만 APCC는 1개월 전망에 사용되는 여러 모델을 직접 개선할 수 없으므로 우리나라 기온/강수량 예측에 적합한 모델 후처리 방법을 개선해 나가고 있다. APEC기후센터 연구보고서(김가은 등, 2021)에서 ECMWF 기후값 계산 시 사용하는 hindcast 자료의 수에 따른 예측성의 차이를 분석한 바 있으며, 이때 유의미한 예측성 상승을 보인 결과를 2022년에 현업화 하였다.

ECMWF 계절내 예측은 매주 월요일과 목요일 기준으로 예측을 수행하고 있으며, 현재 APCC는 매주 이 두 예측 결과를 모두 수신하여 1개월 전망에 사용하고 있다. ECMWF는 forecast와 동일한 날짜의 hindcast 자료를 제공하고 있으며, 11개의 앙상블 멤버로 최근 20년의 기간에 대한 예측을 제공한다. 기존에는 forecast와 동일한 날짜의 hindcast만을 사용하여 모델의 기후값을 만들었으나 forecast 기준 날짜 전후의 날짜에 해당하는 hindcast 자료를 포함하는 방법으로 확장하였다. 그럼으로써 특정 이벤트의 극값에 왜곡이 덜한 모델의 기후값을 생산할 수 있으며 이를 활용한 예측결과가 더 우수한 것으로 분석되었다.

현업화에 앞서 기존 연구 결과에 예측기간을 확장하여 추가적인 검증을 수행하였다. ECMWF forecast 예측성 비교 검증을 2019년 1월부터 2021년 11월까지 총 148회 예측결과에 대하여 수행하였다. 실험 ‘Mon_1set’은 월요일 초기장 forecast에 동일한 날짜의 1세트 hindcast만을 사용한 기후값으로 아노말리를 계산한 실험이며, 실험 ‘Mon_3set’은 월요일 초기장 forecast에 목요일-월요일-목요일 3세트 hindcast를 사용한 기후값으로 아노말리를 계산한 실험이다. 검증은 동아시아 영역(10~60°N, 80~80°E)에 대해 ACC 검증 방법을 사용하였다.

ECMWF hindcast 확대에 따른 ACC 검증 결과를 Figure 117에 비교하였다. 기준이 되는 ‘Mon_1set’은 검은색 실선으로 표시하였고, 현업에 사용할 변경 사항을 적용한 ‘Mon_3set’ 실험은 붉은색 실선으로 나타내었다. 검증은 MSLP와 Z500 변수에 대하여 수행하였으며, 예측 선행시간의 변화에 따라 ACC 값의 변화를 표시하였다. ACC는 2개의 변수 모두에서 예측시간에 따른 비슷한 감소 경향을 보였으나 Z500 변수의 예측성이 더 우수하였다. 두 가지 실험 방법에 따른 차이를 보면(Figure 117(c), (d)), ‘Mon_3set’ 방법이 비교적 우수하였으며, 특히 Z500 변수에서는 +2주 예측 시점부터 상대적으로 예측성이 높아진 것을 보여주었다.




Figure 117. Anomaly correlation coefficient of weekly mean prediction of (a) MSLP, (b) Z500, (c) MSLP (3set-1set) and (d) Z500 (3set-1set) for the period Jan 2019 to Nov 2021 over the East Asia.

ECMWF 예측결과 (T2M)

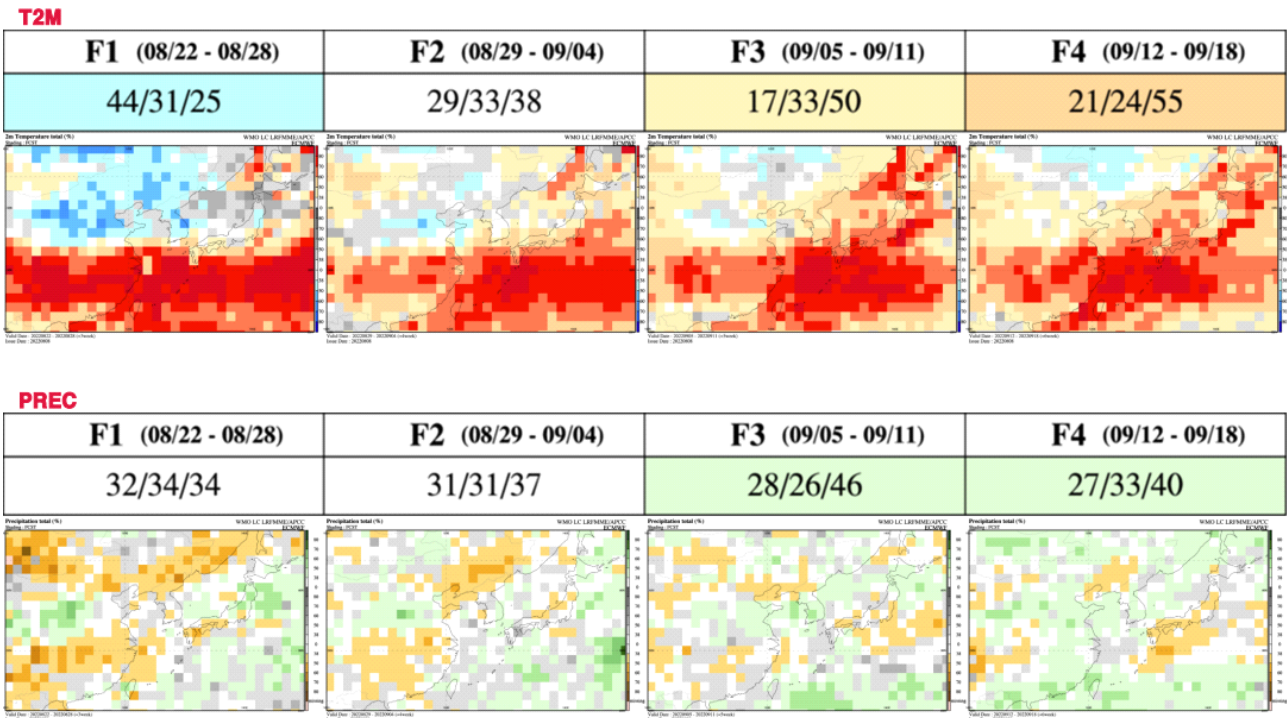


Figure 118. Sample of 1-month ECMWF prediction for T2M/PREC.

이러한 결과를 바탕으로 APCC 1개월 전망 예측시스템에서는 ECMWF 예측을 수행할 때 hindcast 자료는 3배수로 늘려서 활용하는 방법으로 개선하였다. 변경된 사항은 2022년 2월부터 현업에 적용되었으며, 기존 ECMWF 예측결과 및 MME 예측도 새로운 방법으로 변경하여 재계산하였다.

ECMWF 예측 방법론의 변경과 더불어 예측결과 발표자료의 표출 부분도 일부 수정을 하였다. Figure 118과 같이 ECMWF 기온과 강수량 확률예측결과 값을 한 페이지에 같이 표출하였으며, 동아시아지역의 확률예측 분포와 우리나라 영역 평균값을 같이 나타내었다. 우리나라 영역 평균값 중 가장 높은 확률에 따라 표의 색상은 자동으로 변경하여 제공한다.

② Washington/Montreal 예측자료 추가 및 최근 예측결과 검증 표출방법 개선

1개월 전망 시 사용하는 모델 중 GloSea 계절 모델의 분석은 기상청에서 중점적으로 담당하기로 하며, APCC는 ECMWF와 다른 계절내 예측모델을 보다 자세히 분석하기로 협의한 바에 따라 1개월 전망 발표자료를 크게 수정하였다. 그에 따라 ECMWF 예측자료 표출을 강화하였으며, 개별모델 예측 결과로 Washington 모델과 Montreal 모델의 결과를 추가하였다.

지난주 평균의 날씨에 대한 모델의 예측이 어떠하였는지 비교하기 위해 Z500 편차장 예측결과를 1주 전에서 4주 전까지 결과를 나열하여 보여주고 있다.(Figure 119). 이때 제공하는 모델을 SCM과 ECMWF, Washington 모델로 하였다. Z500 편차장 예측결과 표출과 MSLP 편차장과 850hPa 바람 편차장 표출 결과는 SCM과 Washington, Montreal 모델의 결과를 같이 보여주며(Figure 120), ECMWF는 별도의 페이지에서 표출하도록 구성하였다.

계절내 예측모델의 우리나라 기온과 강수량 확률 예측결과에 사후분석 페이지를 강화하였다. Figure 121에 보인 바와 같이 지난주 우리나라 기온과 강수량 주평균 값을 PMME와 각 개별모델이 4주전부터 어떻게 예측해왔는지 나타내었다. 이를 통해 지난주 기온, 강수량에 대한 각 모델의 예측성을 비교해보고, 예측 선행시간 감소에 따라 예측 경향이 어떻게 바뀌었는지 특성을 알 수 있도록 하였다. 또한 각 모델의 최근 12주간의 기온과 강수량 3주 전 예측을 표에 나열하고, 해당 기간에 대한 검증값을 표시하여 각 모델의 예측성을 비교해 볼 수 있도록 구성하였다.

사후분석 [8.1~8.7]

❖ 500hPa 지위고도 편차장

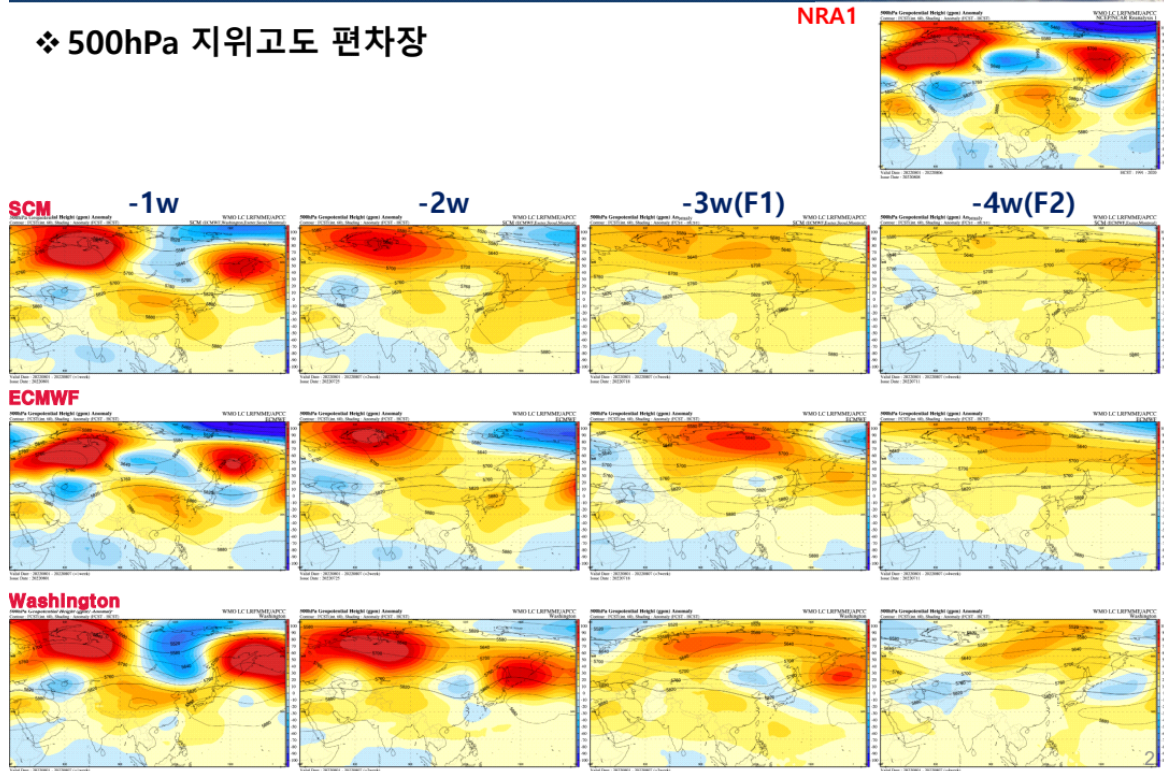


Figure 119. Sample of verification of 1-month prediction for Z500.

WMO 예측결과 (Z500)

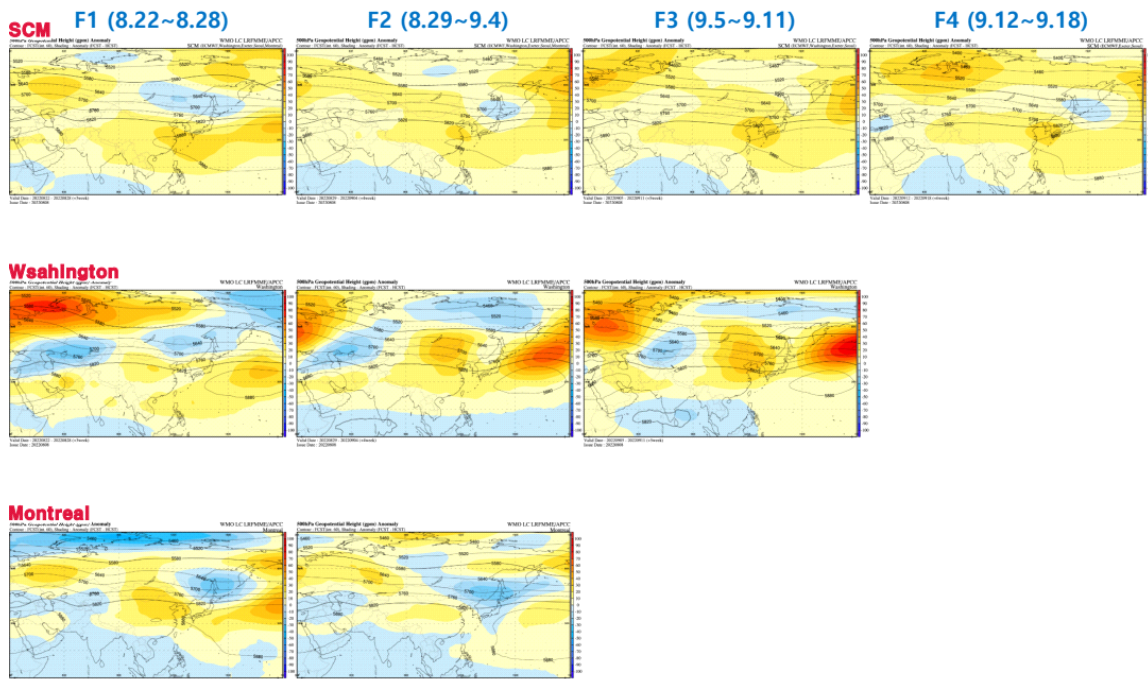



Figure 120. Sample of 1-month SCM, Washington, and Montreal prediction for Z500.

사후분석 [8.1~8.7]

❖ 지상 기온

관측 : +1.7 °C(A)




Model	-1w	-2w	-3w	-4w
PMME (%)	0/8/92	5/13/82	12/20/68	15/30/55
ECMWF (%)	0/20/80	2/15/84	7/19/74	7/23/69
Washington (%)	0/0/100	0/0/100	5/10/85	11/39/50
Exeter (%)	0/9/91	9/19/71	11/24/66	20/29/51
Seoul (%)	0/2/98	3/12/85	18/21/61	
Montreal (%)	0/10/90	10/19/70	18/28/54	22/29/50

❖ 기온 3주 예측 검증 결과 (최근 12주)

Month	May 2022			Jun 2022				Jul 2022				score		
	16	23	30	06	13	20	27	04	11	18	25	01	PC	HSS
Obs.	1.4	2.2	1.0	-1.5	-0.2	3.2	3.6	3.6	1.0	-0.9	0.6	1.7		
PMME	40	66	77	70	46	62	69	62	76	65	60	68	0.67	0.00
ECMWF	41	80	76	39	42	55	55	71	83	57	68	74	0.58	-0.11
Washington	51	64	64	64	46	52	81	91	71	68	44	85	0.58	-0.11
Exeter	42	38	83	89	42	78	82	51	84	80	64	66	0.50	-0.20
Seoul	34	66	90	84	48	71	72	51	71	48		61	0.64	-0.10
Montreal	66	81	74	72	52	67	54	46	73	75	64	54	0.67	0.00

❖ 강수량

관측 : 53.2 %ile(N)



Model	-1w	-2w	-3w	-4w
PMME (%)	19/39/42	26/37/37	27/36/36	34/30/35
ECMWF (%)	9/60/31	27/35/38	35/36/29	40/31/29
Washington (%)	19/30/51	25/54/21	20/44/36	48/20/32
Exeter (%)	19/37/44	36/27/36	24/51/26	26/34/40
Seoul (%)	30/28/42	21/35/44	24/31/44	
Montreal (%)	18/40/42	20/34/46	34/20/46	25/35/40

❖ 강수량 3주 예측 검증 결과 (최근 12주)

Month	May 2022			Jun 2022				Jul 2022				score		
	16	23	30	06	13	20	27	04	11	18	25	01	PC	HSS
Obs.	0.0	24.1	70.1	61.4	59.4	68.2	65.7	5.5	38.6	77.9	27.5	53.1		
PMME	46	35	42	44	39	39	47	39	46	36	40	36	0.33	0.04
ECMWF	39	42	42	41	43	45	43	41	45	41	42	36	0.67	0.52
Washington	58	46	59	35	58	45	62	38	42	40	64	44	0.50	0.24
Exeter	44	35	50	36	42	42	48	40	62	42	46	51	0.50	0.24
Seoul	37	42	37	68	44	45	51	60	40	52		44	0.18	-0.21
Montreal	53	38	44	40	35	40	38	41	55	43	40	46	0.25	-0.14

3

Figure 121. Sample of verification of 1-month prediction for T2M and PREC.

③ Tibetan/WNP 고기압 표출방법 개선

APCC에서는 여름철 우리나라 폭염 예측에 중요한 인자로 알려진 티벳 고기압과 북서태평양고기압의 예측정보를 6월에서 8월까지 한시적으로 1개월 전망 발표 시 제공하고 있다. 기본적으로 ECMWF의 Z200 변수와 Z500 변수의 편차장 예측정보를 제공하고 있지만, 기상청 예보관의 요청에 따라 날씨 예측에서 중요한 인자로 사용하는 Z200의 12,480gpm과 Z500의 5,880gpm 위치 예측정보를 제공한다.

2022년에는 기존 예측정보 표출방식에서 가독성을 높이는 방향으로 개선하고, 일단위 예측정보를 제공하기 위한 Hovmoller diagram 예측 콘텐츠를 추가하였다. Figure 122 예시와 같이 왼쪽에는 주별로 12,480gpm과 5,880gpm 예측위치를 표출하였으며, 오른쪽에는 티벳 고기압과 북서태평양고기압의 확장과 수축에 대한 일단위 예측정보를 표출하였다. 오른쪽의 Hovmoller diagram에는 과거 4주간의 관측값을 함께 표출하여 최근의 기압계 변화경향도 함께 분석할 수 있도록 하였다.

ECMWF 예측결과 (Z200, Z500)

❖ Tibet/WNP High forecast

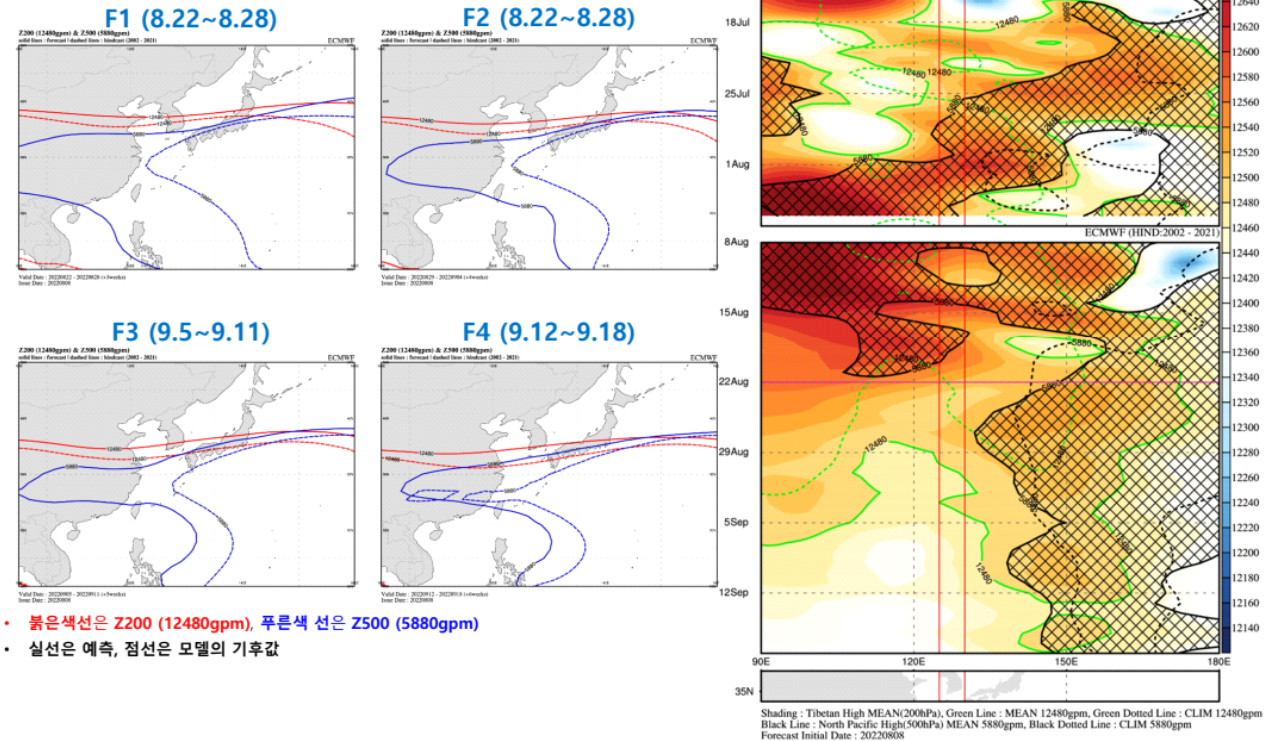


Figure 122. Sample of 1-month ECMWF prediction for Tibetan/WNP High.

④ Daily AO index 예측 생산

북극진동(Arctic Oscillation; AO)은 APEC기후센터 연구보고서(여새림, 2016)과 장기예보 가이드스(기상청, 2022)에서 보인 바와 같이 동아시아의 겨울철 기온과 상관성이 매우 높은 기후인자 중 하나이다. AO 지수에 따라서 북극의 한기가 어떻게 중위도에 남하하여 한파를 유발하는지 역학적으로 설명이 잘 되어 있으며, 특히 단기예측에서 이를 예보에 잘 활용하고 있다. 다만 역학 모델이 가지고 있는 고위도 기압계 예측성의 한계로 AO의 예측성 또한 장기예측에 활용하기에 예측 기간의 한계점을 가지고 있다. 그럼에도 불구하고 우리나라 1개월 전망의 대상 기간은 ECMWF 계절내 모델이나 GloSea 모델의 예측 기준 날짜로부터 14일 이후부터 시작하므로, 계절내 예측모델로 AO 지수를 예측해 보았으며, 1개월 전망에 활용하는 방안을 모색해 보았다.

미국 National Oceanic and Atmospheric Administration (NOAA)의 Climate Prediction Center (CPC)에서 제공하고 있는 AO 관측 및 예측자료를 검증 기준값으로 정하였으며(https://www.cpc.ncep.noaa.gov/products/precip/CWlink/daily_ao_index/ao.shtml), 관측 자료로 NCEP Reanalysis 1(NRA1)과 2(NRA2)를 사용하였다. AO 예측에는 Z1000 변수를 실시간 수신할 수 없는 관계로 ECMWF 모델의 MSLP 변수를 사용하였다. Figure 123은 CPC에서 AO

지수 예측 때 사용하는 Z1000 변수의 leading EOF regression map과 이번 연구에서 사용할 MSLP 변수로 변경하여 계산한 leading EOF regression map을 비교하여 보았다. Figure 123(b)와 같이 NRA1 자료의 MSLP 변수를 사용하였을 때도 Z1000 변수 대비 매우 유사한 패턴을 보여주고 있음을 확인하였다.

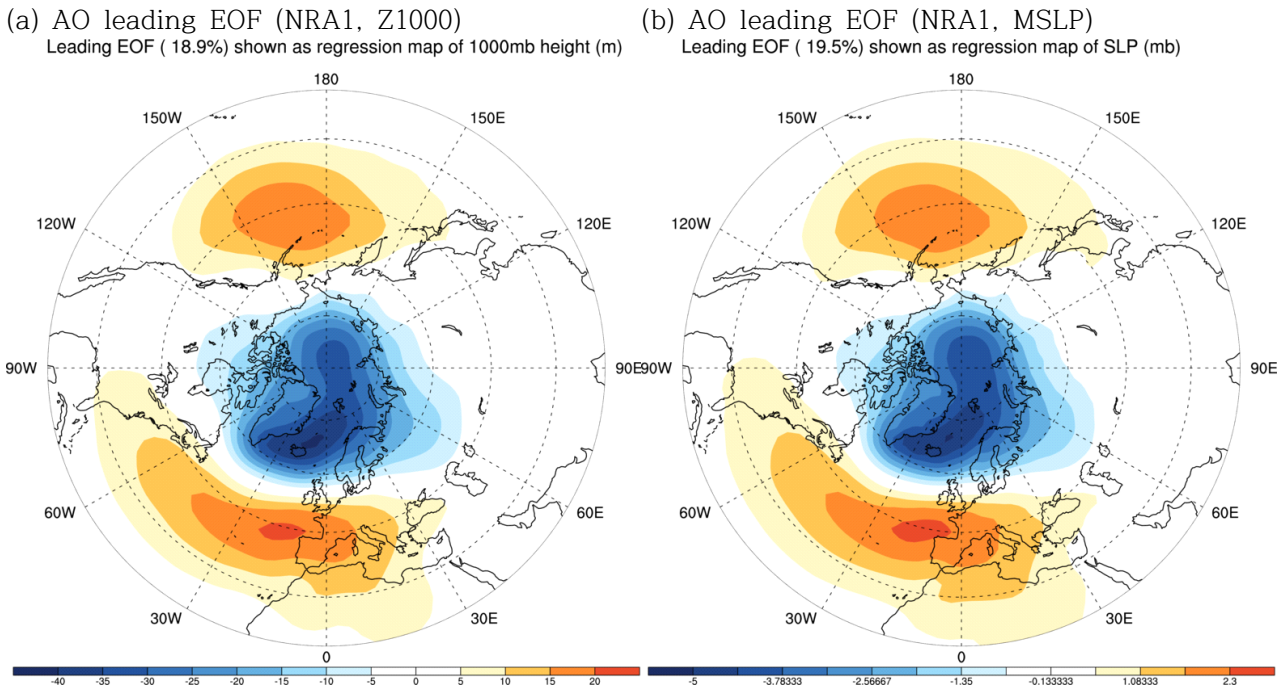


Figure 123. Regression map of (a) Z1000 and (b) MSLP during 1979~2000.

추가로 CPC에서 제공하는 Monthly AO와 daily AO와 APCC에서 이번 연구에서 NRA1과 NRA2 자료의 Z1000/MSLP 변수 각각에 대하여 계산한 지수값을 비교해보았다(Figure 124). 모든 경우에서 AO 지수는 매우 비슷한 값을 보였으며, NRA1 자료의 MSLP 변수를 사용한 경우에도 Monthly AO 및 Daily AO 모두 상관계수가 0.99이며, RMSE 값은 Monthly AO의 경우 0.09, Daily AO의 경우 0.24의 값을 보였다.




Figure 124. (a) Monthly and (b) daily Arctic Oscillation for the period from 1979 to 2021.

NRA1 자료의 MSLP 변수를 사용한 leading EOF를 기준으로 ECMWF 계절내 모델의 MSLP 예측결과를 사용한 46일 예측 daily AO 지수를 생산하였다. 아래 Figure 125는 2018년부터 2022년 4월까지 223회 예측한 AO 지수에 대한 예측 선행 시간 별 TCC (Figure 125(a)), RMSE (Figure 125(b)) 검증값이다. ECMWF 앙상블 멤버 한 개만을 사용하여 예측한 AO 지수는 검은색 실선으로 표시하였으며, 51개 앙상블 멤버가 예측한 AO 지수 평균값은 붉은색, 51개 앙상블 멤버가 예측한 AO 지수의 중앙값은 파란색 실선으로 표시하였다. 평균과 중앙값 모두 유사한 예측성을 보여서 AO 지수의 평균값을 예측에 사용하는 것으로 선택하였다. ECMWF daily AO 지수 평균값 예측은 21일 예측까지 TCC 값이 0.5 이상을 보였다. 기상청 1개월 전망에서 필요한 3주 예측 기간까지 TCC 값이 0.5 이상임으로 현업에 유용하게 활용할 수 있을 것으로 판단하였다.

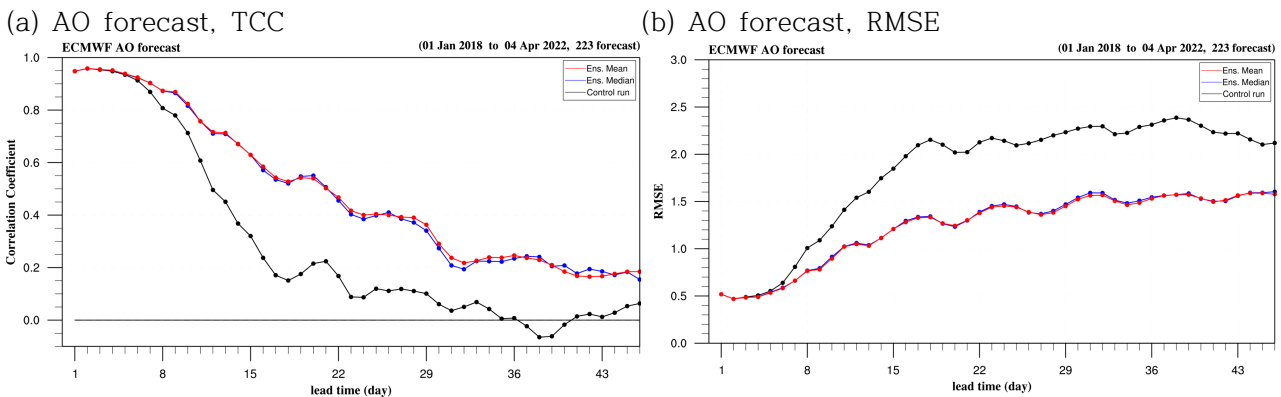


Figure 125. Verification of daily AO forecast for the period from Jan 2018 to Apr 2022.

Daily AO 예측결과는 아래의 Figure 126과 같은 양식으로 1개월 전망 회의 시 활용하고자 한다. 발표자료 좌측 상단에 daily AO 예측결과를 표출하며, 이때 NRA1 자료로 계산한 최근 24주간의 AO 지수값도 같이 표시하여 최근의 AO 지수값의 변화경향을 알 수 있도록 하였고, 예측부분에서는 ECMWF 각 앙상블 멤버가 예측한 모든 값을 노란색 선으로 표시하면서 평균값은 붉은색 선으로 함께 표시하였다. 그 아래로 7일과 14일, 21일 예측시점에서의 AO 지수 예측성 검증결과를 표시하였으며, 우측에는 북반구 Z500 편차장 예측 중 3주 예측 결과를 보여줌으로써 AO 지수와 연계된 북반구 기압계 패턴을 확인해 볼 수 있도록 구성하였다.

ECMWF 예측결과 (AO)

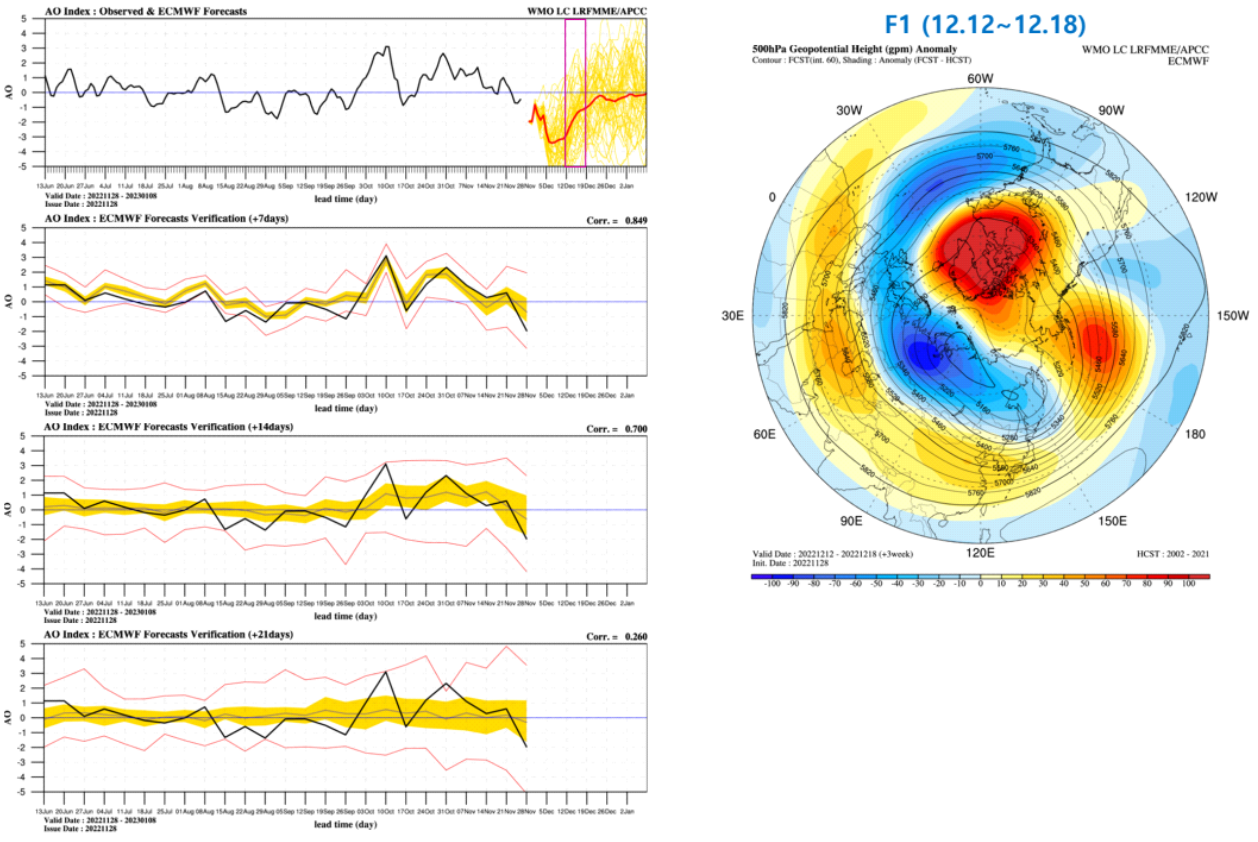


Figure 126. Sample of ECMWF daily Arctic Oscillation forecast.

(나) 1개월 전망 검증보고서 작성

APCC의 1개월 전망 예측경험을 축적하고 향후 예보토의 시 참고자료로 활용하기 위하여 극한 기후나 특이 사례에 대한 검증보고서를 작성하였다. 검증보고서는 해당 사례에서 우리나라의 주별 평균한 기온/강수량과 기압계 분포에 대한 설명과 3주전 모델 예측이 어떠하였는지를 포함하며, 과거 유사 사례에서의 예측과 비교하며 향후 활용 가능성에 관한 내용을 담았다. 올해는 5월의 고온현상과 6월 장마시작, 8월의 폭우에 대하여 분석해보았다(부록B).

① 5월 고온현상에 대한 예측 검증

2022년 5월 중순부터 바이칼호 부근 상층 기압능이 3주간 정체하며, 우리나라 주변 Z500은 음의 편차를 보인 반면 MSLP는 양의 편차, 하층 바람은 서풍 편차가 나타났다(Figure 127(a), (c)). 5월 16일 해당 주 초반에 북쪽 골의 영향은 일시적이었으며, 이후 맑은 날씨가 지속되면서 기온이 상승하였다. 3주전 ECMWF 모델은 우리나라 부근 Z500을 음의 편차로, MSLP는 양의 편차로 잘 예측하였으며, 상층 기압골이 주 초반에 영향을 줄 것으로 잘

예측하였으나, 우리나라 주평균 기온은 평년과 비슷한 정도로 예측하였다(Figure 127(b), (d)).

Figure 128은 위 사례와 같이 5월 중순 Z500 편차장에서 바이칼호 부근에 기압능이 위치하고, 한반도 주변으로 음의 편차가 발생한 사례이다. 다른 점은 MSLP 편차장이 반대로 시베리아 지역으로 양의 편차, 우리나라 주변으로 음의 편차가 나타났다(Figure 128(c)). 3주전 ECMWF 모델은 한반도 남동쪽의 북서태평양고기압이 평년보다 발달하여 한반도에 영향을 주며 상층의 북쪽 골의 영향을 적게 예측하고, 그로 인해 우리나라 기온이 높을 것으로 보았다. MSLP는 한반도 주변으로 음의 편차가 강한 것으로 잘 예측하였지만, Z500과 마찬가지로 남쪽의 고압대를 과대모의 하면서 강수대의 위치를 실제보다 북쪽에 모의하였고, 우리나라 강수량을 평년보다 많을 것으로 예측하였다.

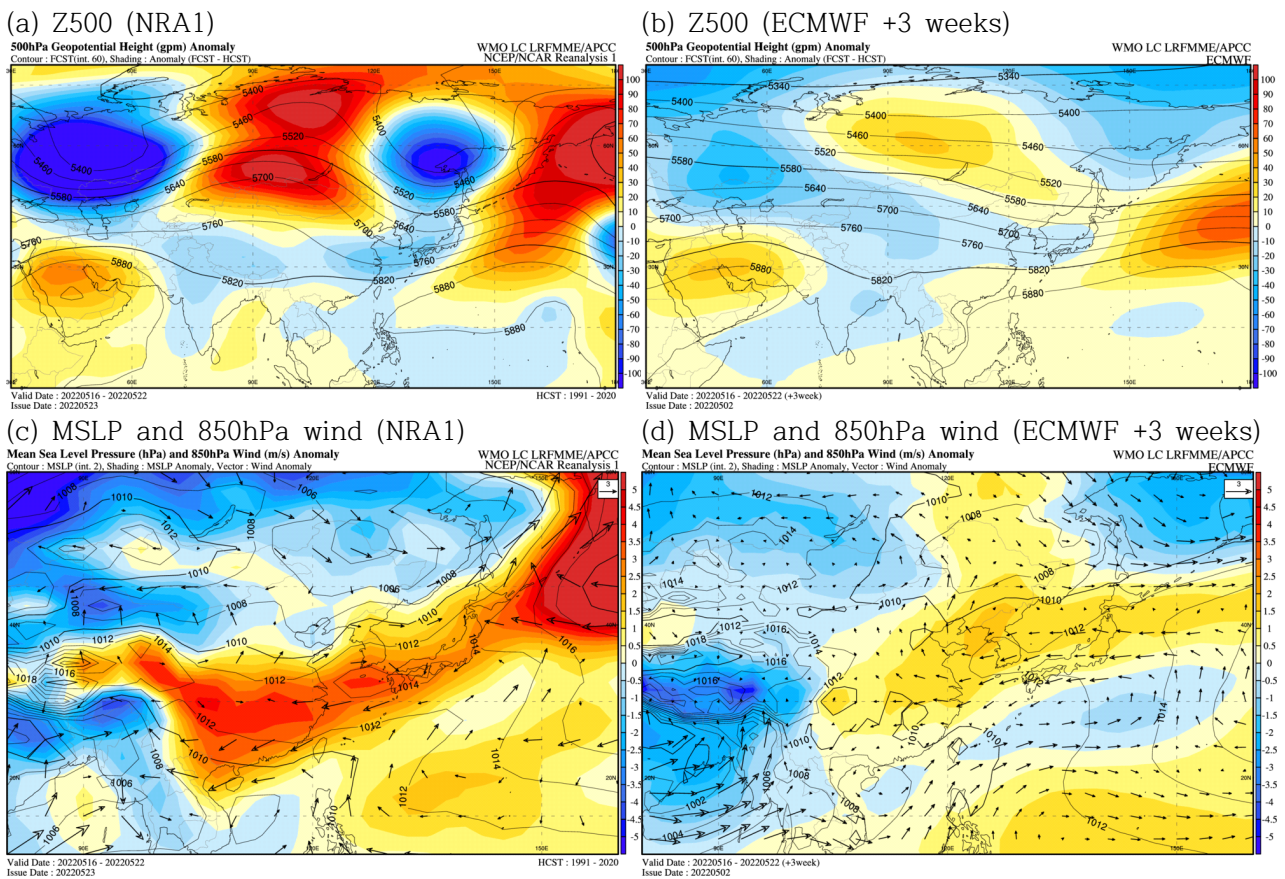
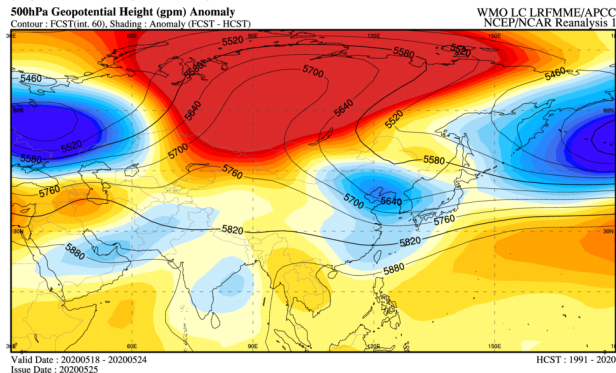


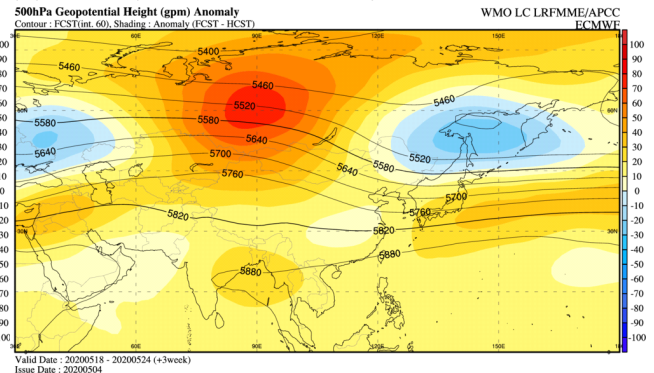
Figure 127. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 16~22 May 2022.

두 사례를 보았을 때 일반적으로 우리나라 기온예측에 활용하는 Z500의 편차장 분석과 이를 통해 얻은 상층골과 북서태평양고기압의 영향 만으로 5월의 기온 예측을 하는 것은 실패할 가능성이 있다. 반면, MSLP와 850hPa 바람 편차장은 이번 사례들에서 기압계 패턴의 예측성도 비교적 우수하였고, 우리나라 기온 예측에 더 많은 부분을 설명해 주었다. 그러므로 이 시기의 기온 예측 시 MSLP와 850hPa 바람 편차장 예측결과도 중요한 요소로 활용해야 한다.

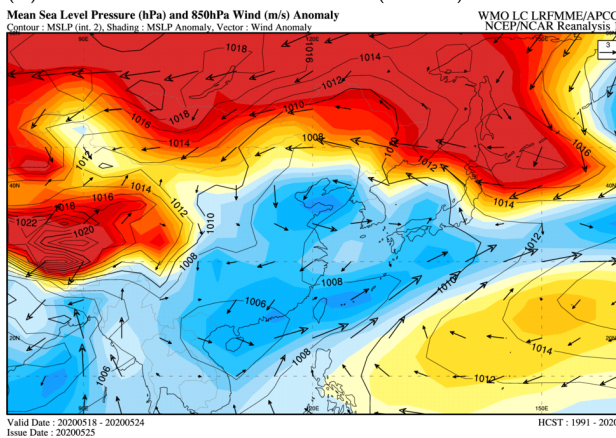
(a) Z500 (NRA1)



(b) Z500 (ECMWF +3 weeks)



(c) MSLP and 850hPa wind (NRA1)



(d) MSLP and 850hPa wind (ECMWF +3 weeks)




Figure 128. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 18~24 May 2020.

② 장마 시작 예측에 대한 검증

2022년 6월 20일 기준의 해당 주평균 재분석자료를 보면, Z500은 한반도 북쪽으로 기압골이 통과하면서 만주지역으로는 음의 편차, 한반도 주변으로는 평년보다 북상한 북서태평양고기압의 영향으로 양의 편차가 나타났다(Figure 129). MSLP 또한 우리나라는 강한 음의 편차값이며, 일본 열도 부근까지는 강한 고기압성 편차값을 보였다. 이처럼 우리나라는 북쪽골과 남쪽 고압대의 경계에 위치하면서 850hPa 바람 편차는 매우 강한 남서풍 편차를 보였고, 2022년은 6월 23일 장마 시작과 함께 기온이 평년보다 3.2°C 높았다. 3주전의 ECMWF Z500 예측을 보면 한반도 북쪽의 기압골을 약하게 모의하였지만, 우리나라 남부지역에 위치한 5,820gpm과 규슈 남쪽 해안까지 북상한 5,880gpm 선을 매우 잘 예측하였다(Figure 129(b)). 또한 MSLP와 850hPa 바람편차장 예측결과도 재분석자료와 비슷한 패턴으로 잘 예측하였다.

2018년 6월 25일 기준의 주평균 재분석자료에서도 위 사례와 유사한 패턴이 나타났었다(Figure 130). 한반도 북쪽으로 기압골이 통과하며, 우리나라 남쪽 부근에는 평년 대비 강하게 발달한 고기압이 위치하면서 우리나라 지역은 강한 850hPa 바람 편차가 나타났다. 이 경우에도 ECMWF는 북쪽 골을 다소 약하게 모의하는 경향을 보였지만

전반적으로 850hPa 바람 편차는 유사하게 예측하였다.

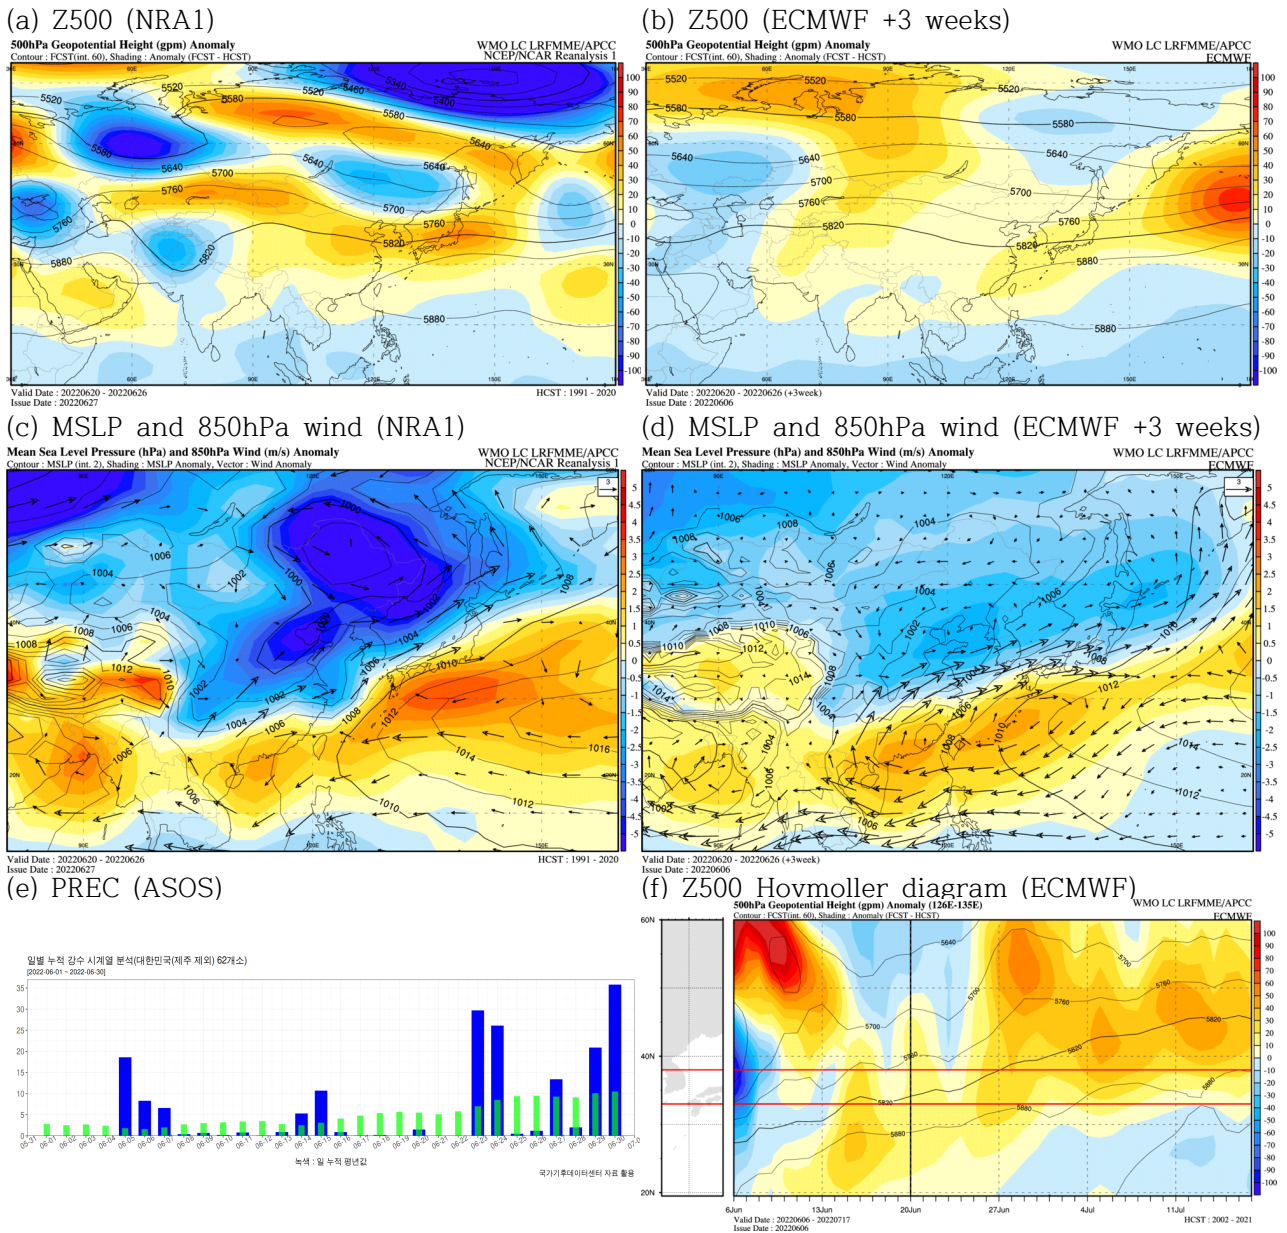


Figure 129. KMA ASOS precipitation data, anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 20~26 Jun 2022.

ECMWF 예측결과가 위 두 사례에서처럼 5,820gpm 선이 점진적으로 북상하는 경우, Figure 129(f)와 Figure 130(f)의 Z500 Hovmoller diagram 예측결과와 5,820gpm 선이 우리나라 남부지역(북위 35°)에 위치하는 시점이 장마의 시작과 일치하였다. 그리고 이렇게 남서기류의 유입이 강하면서 비가 많이 내리는 경우 일사 차단 영향으로 기온이 하강하기보다 온난이류에 따른 기온상승이 더 큰 영향을 준 것을 알 수 있다.

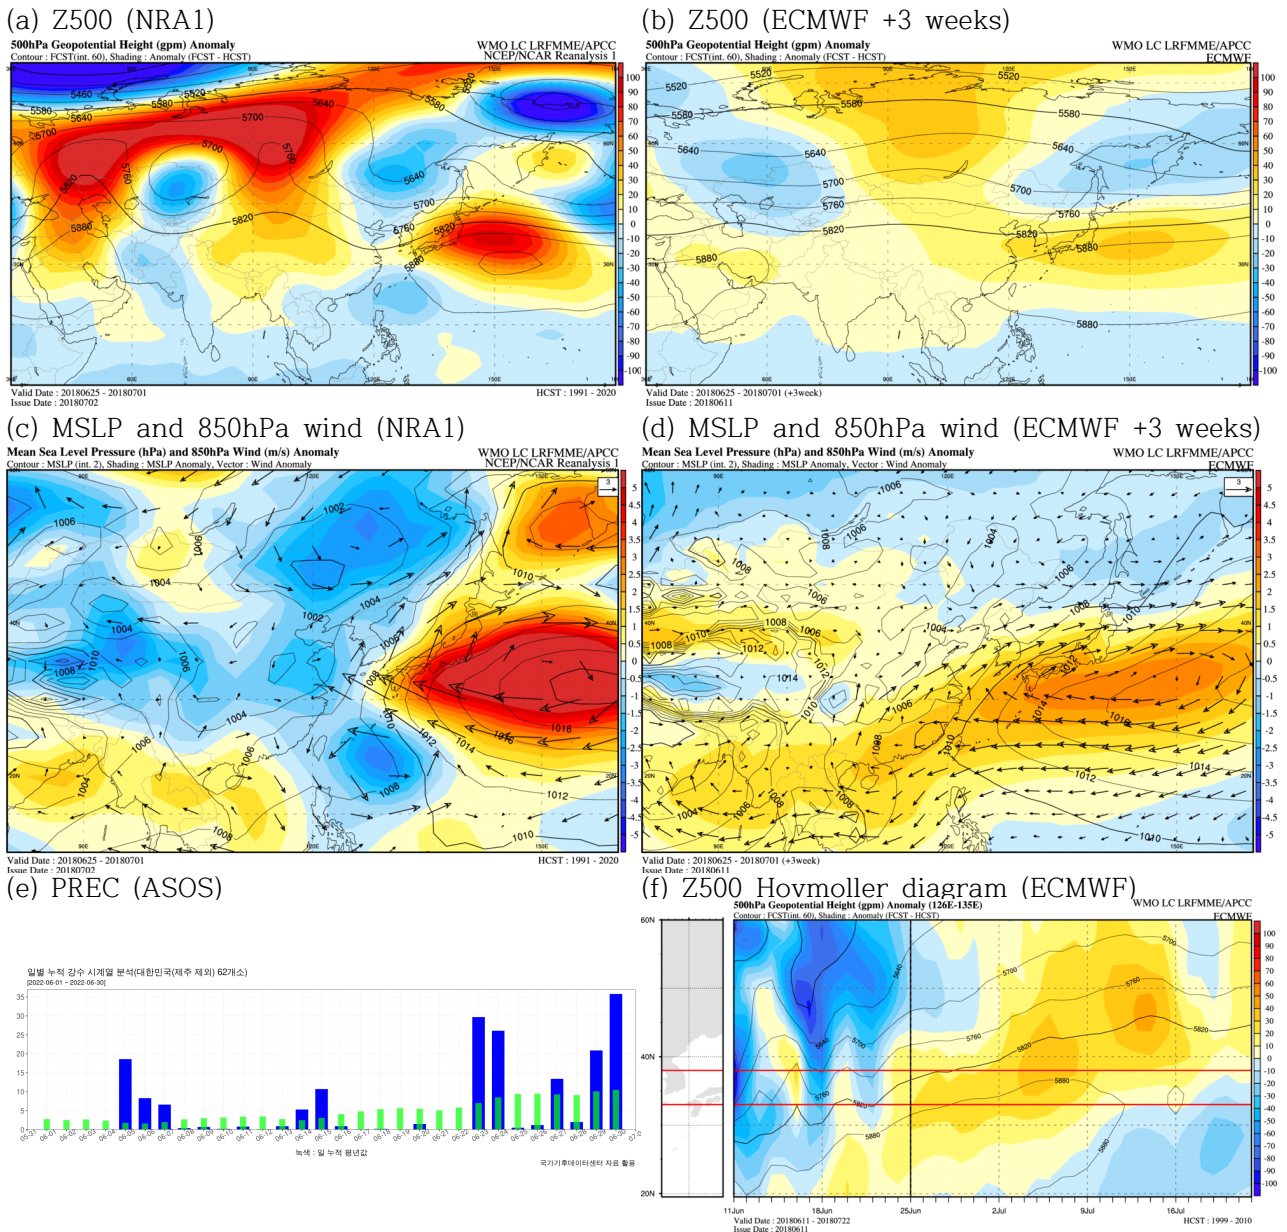


Figure 130. KMA ASOS precipitation data, anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 25 Jun ~ 1 July 2018.

③ 8월 집중호우 발생에 대한 예측 검증

2022년 8월 8일 기준의 해당 주평균 재분석자료를 보면, Z500은 북인도양-남중국해 부근 음의 편차, 티벳부근 양의 편차, 만주부근 음의 편차, 캄차카반도 부근 양의 편차로 파동 전과 패턴이 나타났다(Figure 131). 하층의 경우 앞서 분석한 장마 시작 시점과 같이 우리나라 북쪽의 기압골 통과와 남쪽의 강한 고기압성 편차 경계에서 남서풍 매우 강했다. 우리나라는 Z500 변수의 5,880gpm과 5,820gpm 선 사이에 위치하면서 중부지방 중심으로 정체전선 형성되어 집중호우가 발생하였으며, 일시적인 기온 하강이 나타났다.

다만 ECMWF 모델은 우리나라 북쪽으로 발달하는 상층 골을 전혀 예측하지 못하고

북태평양 고기압이 확장하여 강한 고압대 영향을 받을 것으로 예측하였다. 또한 양의 MSLP와 대기 하층의 고기압성 바람편차값을 예측하면서 기온이 높고 강수량이 적은 날씨를 예상하면서 예측이 틀렸다.

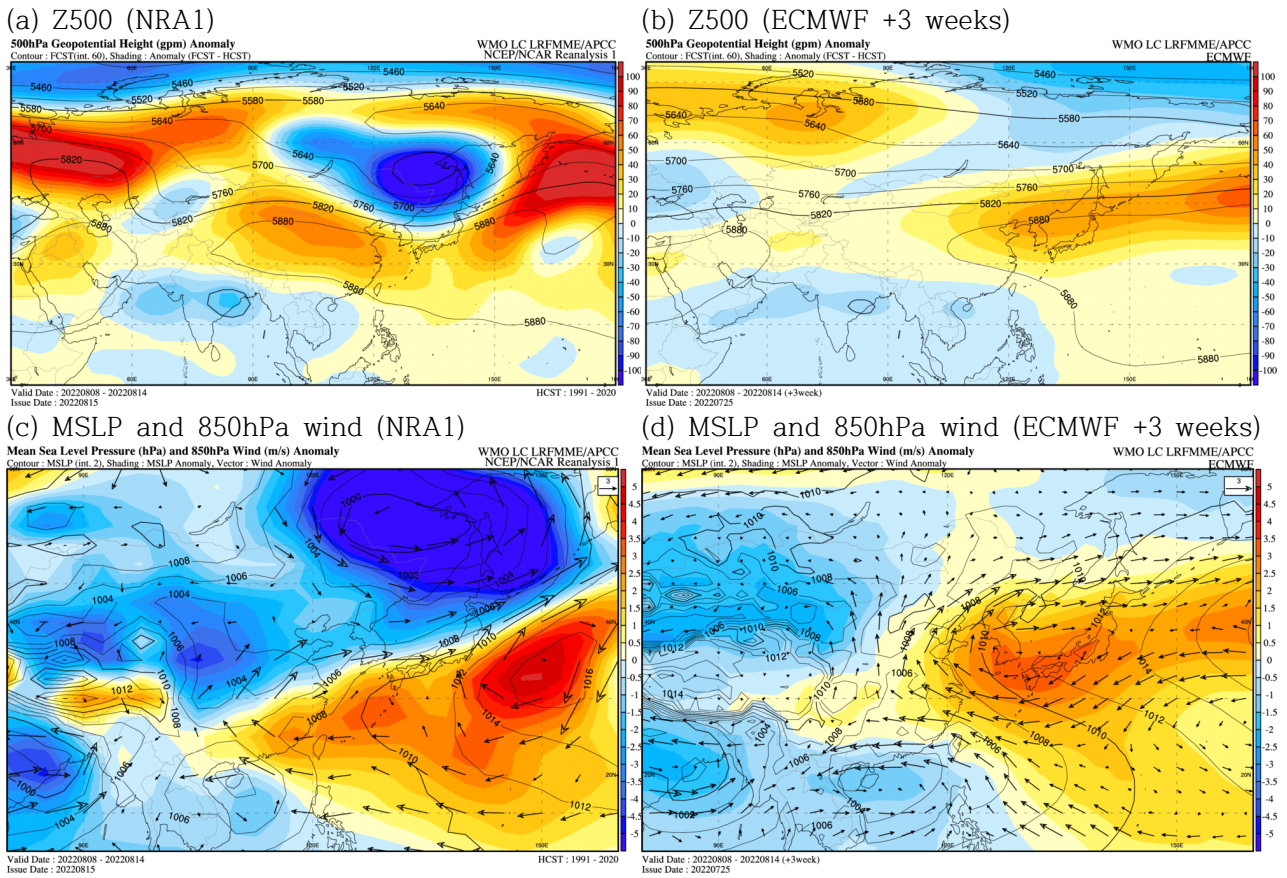


Figure 131. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 8~14 Aug 2022.

2021년 8월 16일 기준 주평균 값에서도 한반도 북쪽에서 유입되는 찬 공기가 남쪽에 위치함 북서태평양고기압과 만나면서 전선을 형성하고 강한 강수를 유발하였다(Figure 132). 이 경우에서도 ECMWF는 3주전 예측에서 북서태평양고기압의 확장으로 한반도는 대기 상하층 모두 고압대의 영향을 받으며, 고온 건조한 날씨를 예측한 바 있다. 이처럼 ECMWF 모델은 8월에 한반도 북쪽을 지나는 상층 기압골을 잘 모의하지 못하는 경향이 있으며, 북서태평양고기압을 과대모의 하는 경향을 자주 보이므로 1개월 전망 예측 시 주의가 필요하다.

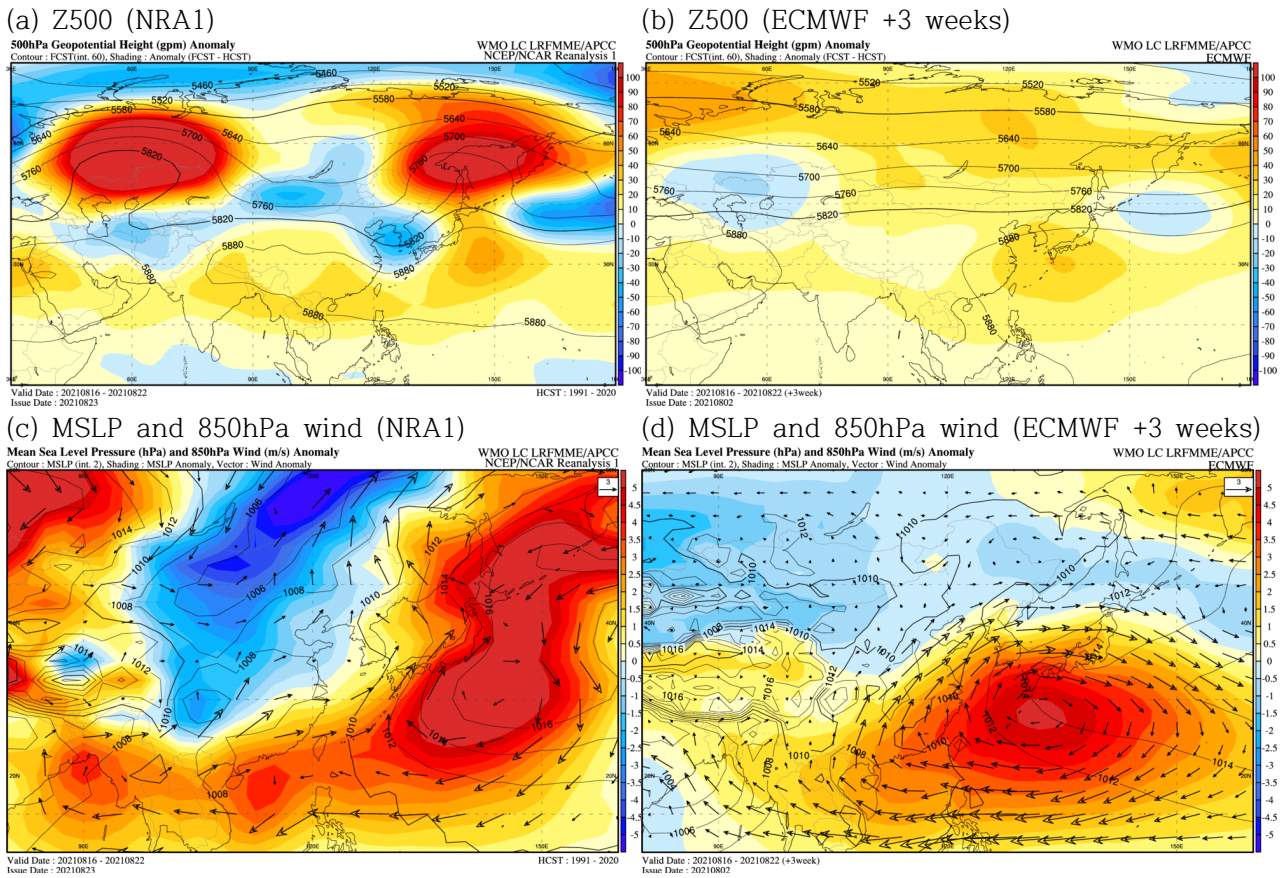


Figure 132. Anomaly map of NCEP reanalysis 1 and ECMWF +3week forecast for 16~22 Aug 2021.

(다) 2022년 1개월 전망 예측결과 검증

APCC는 국내 1개월 전망 지원을 위해 계절내 예측모델을 활용한 예측시스템을 운영하고 있다. 이를 통해 우리나라 주평균 기온과 강수량 예측에 도움이 되는 콘텐츠를 매년 추가적으로 개발하며, 예측결과에 대한 검증과 분석을 수행한다. 2020년 10월부터는 APCC도 자체 내부토의를 통해 기후예측인자와 모델 예측결과 등을 종합적으로 고려한 1개월 예측결과를 생산하고, 기상청 1개월 전망 예보토의 시 발표하고 있다.

APCC의 2022년 1개월 예측결과에 대한 검증을 수행하였으며, 비교군으로 우리나라 기상청의 GloSea 모델과 ECMWF 모델의 예측결과를 사용하였다. 모델은 기온과 강수량이 평년대비 “낮음” / “비슷” / “높음” 3분위 예측을 수행하지만 기상청과 APCC의 예보관 예측은 “비슷하거나 낮음” 과 “비슷하거나 높음” 예측이 추가된다. 이 경우는 3분위 예측으로 정확히 맞췄을 때 비하여 절반의 포인트만 적용하여 검증하였다. 검증 방법은 기온 예측의 경우 모델은 매우 높은 비율로 평년보다 높다고 예측하는 경향이 있으므로 HSS 방법을 선택하였다.

검증 기준값은 2021년 5월 이후로 변경된 기후값 계산 방식에 따라 제주 지역을 제외한 우리나라 ASOS 62개 지점의 평균값을 사용하였으며, 평년기간은 1991년부터 2020년까지이다.

검증기간은 3주 예측의 대상날짜 기준으로 2022년 1월 17일부터 2022년 10월 31일까지 총 42회 예측한 결과이다.

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, 장기에보에서 0.1 값을 넘기면 비교적 우수한 예측으로 판단된다. 삼분위 예측에서 한가지 예측만 계속하면 예측 성공과 상관없이 HSS 값은 0이 된다. 1개월 전망 시 +4주에서 +6주 예측은 다음 예측에서 수정이 가능한 데 반해, +3주 예측은 최종적으로 확정되는 예측이며, 중기에보와 이상기후 예측 등에서 중요하게 활용되고 있다.

기온 예측 검증 결과는 Figure 133에 나타내었다. 우리나라 +3주 기온 예측의 HSS 값을 보면, APCC의 예측이 0.29로 매우 높은 값을 기록함과 동시에 다른 모델 대비해서도 가장 우수하였다. 반면 GloSea 모델의 +3주 기온 예측은 HSS 값이 0이며, 이는 GloSea 모델이 매우 높은 비율로 기온이 높다고 예측한 결과이다. +4주 기온 예측은 모두 0 또는 음의 값을 기록하며 예측성이 낮았고, +5주는 0.1 내외로 모두 비슷한 예측성을 기록하였다. +6주 예측의 경우 다시 APCC의 HSS 값이 상대적으로 높은 값을 기록하였다.

+3주 예측까지는 ECMWF 모델의 HSS 값에서 나타나듯이 계절내 모델의 예측성이 확보되는 기간이며, 여기에 더해 AO와 BSISO, MJO 등 예보토의 시 참고하는 기후 예측인자가 활용 가능한 예측성을 보인다. 또한 예측성이 높은 단기예측 모델의 결과를 통해 +3주 초반의 날씨 경향을 유추할 수 있기에 우수한 예측이 가능하게 하였다. 하지만 +4주 예측의 경우 활용가능한 기후예측인자가 적으며, 역학 모델 자체의 예측성이 가장 낮아지는 시점이므로 전반적으로 낮은 HSS값을 기록하였다.




Figure 133. Heidke skill score for 2m temperature forecast of GloSea, ECMWF and APCC from Jan 2022 to Oct 2022.




Figure 134. Heidke skill score for precipitation forecast of GloSea, ECMWF and APCC from Jan 2022 to Oct 2022.

강수량 예측 검증 결과는 Figure 134에 나타내었다. 강수량 +3주 예측에서는 APCC와 GloSea, ECMWF 모두 0.11에서 0.13까지 비슷한 HSS 값을 보였다. +4주와 +5주 강수량 예측에서는 GloSea의 HSS 값이 가장 높았으며, 이는 2021년에 이어서 꾸준히 높은 결과를 기록하고 있다. APCC는 +3주 예측 이후 매우 낮은 HSS 값을 보였으며 이 부분에 있어서 예측성 향상을 위한 노력이 더 필요할 것이다.

다음으로 검증기간 동안 실제 어떤 예측을 하였으며, 시기에 따른 예측성의 변화를 분석하였다. 여기서는 지면 관계상 +3주 예측에 관한 결과만 제시하였다. Figure 135와 Figure 136은 2022년에 GloSea5와 ECMWF, APCC가 예측한 결과를 12주씩 이동하며 계산한 HSS 값을 꺾은선 그래프로 표시하였으며, 그 하단에는 각 예측 시점마다 ASOS 관측값과 각각의 예측값을 표로 정리하였다. HSS 그래프에서 붉은색은 APCC이며, 옅은 회색은 GloSea, 검은색은 ECMWF이다. 그래프의 점은 해당 시점과 앞선 6회의 예측, 이후 5회의 예측 결과를 합쳐서 12회 예측한 HSS 값을 나타낸다.

Figure 135에서 나타낸 바와 같이 2022년의 기온 예측한 결과를 보면 APCC는 7월을 제외하면 전반적으로 꾸준히 다른 모델 대비 높은 HSS 값을 보였다. 특히 2월부터 5월 말까지는 한차례를 제외하고 모든 예측에서 절반 또는 완벽한 예측을 보였다. 2월 중순의 기온 하강을 포함하여 고온이 지속되는 3월과 4월, 5월에 기온이 일시적으로 평년과 비슷한 정도로 하강하는 시점을 정확히 맞추었다. 반면, GloSea 모델과 ECMWF 모델은 이 부분을 맞추지 못하였다. APCC는 8월 말과 9월 10월의 기온 예측도 매우 성공적으로 수행하였으며, 이 시기의 ECMWF도 비교적 높은 예측성을 보였다.

2022년의 기온 예측이 어려웠던 기간은 6월 초반과 7월 말에서 8월 중반까지 장마 전후의 기후적으로 고온 건조한 시기에서 나타났다. 실제 2022년에는 이 시점에 기온이 하강하거나 평년과 비슷한 사례가 많았으나, 계절내 예측모델은 계속해서 북서태평양고기압의 발달과 그로

2022년 강수량 예측에 관한 결과는 Figure 136에 나타내었다. APCC는 4월에서 7월 말까지 HSS 값이 0.3을 넘는 매우 높은 수준의 강수량 예측을 하였다. 반면 2~3월과 7~10월 사이의 기간동안 강수량 예측을 실패한 사례가 많았다. 2022년 전반기는 강수량이 많거나 적은 경우에도 “비슷하거나 많음” 또는 “비슷하거나 적음”으로 예측하였으며, 후반기에는 강수량이 평년과 비슷한 사례가 많았음에도 불구하고 양극단으로 예측하면서 틀렸다. 특히 7월에서 9월 사이에 집중호우에 대한 예측이 실패하였으며, 계절내 예측모델 또한 동일하게 사전에 탐지를 못 하였기에 향후 이를 개선하기 위한 연구가 필요한 부분이다.

2021년과 달리 2022년에 ECMWF는 8월에서 10월까지 3개월간 강수량 예측이 성공하는 사례가 3회뿐으로 매우 낮은 예측 성공률을 보였다. 2021년 ECMWF는 이 기간에 BSISO 영향 편차장과 유사한 편차장을 예측하였고, 이는 적도에서 전과되는 요소에 의한 영향이 강했음을 의미한다. 반면 올해는 한반도 북쪽을 통과하는 상층 골의 영향을 자주 받으면서 두 기단의 경계에서 좁은 영역에 많은 강수량을 보이는 전선형 강수 형태가 주로 나타나며 장기예보에서 맞추기 어려운 사례가 많았다.




Figure 137. The ratio of above normal, near normal and below normal categorical forecast of GloSea, ECMWF and APCC.

APCC의 기온 예측 결과가 상대적으로 우수한 이유를 분석해 보면, 관측과 매우 유사한 비율로 3분위 예측을 수행한 점을 들 수 있다(Figure 137). GloSea 모델의 기온 예측은 ‘평년보다 높음’ 예측의 비중이 80%를 넘으며, ECMWF 또한 67%의 비중으로 ‘평년보다 높음’ 기온을 예측하면서 실제 41% 대비 상당히 높은 비율임을 알 수 있다. APCC는 이처럼 계절내 예측 모델의 warm bias를 충분히 고려하여 예측에 반영하며, 다른 기후 예측인자와 모델의 예측 경향이 어떻게 변화하는지를 지속해서 모니터링하고, 이를 종합적으로 취합한 예측결과를 생산 함으로써 보다 높은 예측성을 보일 수 있었다.

(2) WMO 장기예보 선도센터 계절내 예측 시스템 운영 및 개선

(가) 계절내 예측 모델 예측성 비교 검증 (ACC)

WMO 장기예보 선도센터에서 시범운영 중인 계절내 MME 결과에 대한 검증을 시행하였다. 검증 기간은 2016년 1월 11일부터 2022년 8월 15일 사이 총 345회 예측한 결과이며, 검증 대상은 개별 GPC 및 MME 예측 결과이다. 2020년 이후 계절내 MME에 참여하지 않는 모델들의 경우와 일부 예측자료가 일부 누락된 경우에는 누락된 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 작기 때문에 모델별 비교 검증 방법으로 적합하다. 또한, hindcast 예측과 forecast 예측에 사용하는 모델의 초기장이 일반적으로 다르게 설정되어 두 방법의 실제 예측성의 차이가 있다. 그리고 공통 hindcast 기간이 계속 변경되고, 그 기간도 12년에서 9년으로 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.

Figure 138은 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 +1주에서 +3주 예측기간동안 상대적으로 낮게 나타났으며, 나머지 세 변수는 +1주 예측에서 예측성이 높은 모델의 경우 ACC 값이 0.8 부근으로 매우 높았다. 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 0.30, ECMWF는 0.29의 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 해수면온도의 영향으로 T2M 상대적으로 장기 예측에서 더 높은 예측성이 나온 것으로 분석된다.

Figure 138의 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 +1주와 +2주에서는 ECMWF 예측 결과가 0.02 정도 약간 높게 나타났으며, +3주와 +4주에서는 비슷한

값을 보였다. 이러한 특징을 보았을 때, +3주 이상의 계절내 규모의 예측에서 예측성을 향상하기 위해서는 MME 기법을 활용하는 것이 예측오차를 줄이는 데 유용하다는 것을 보여준다.

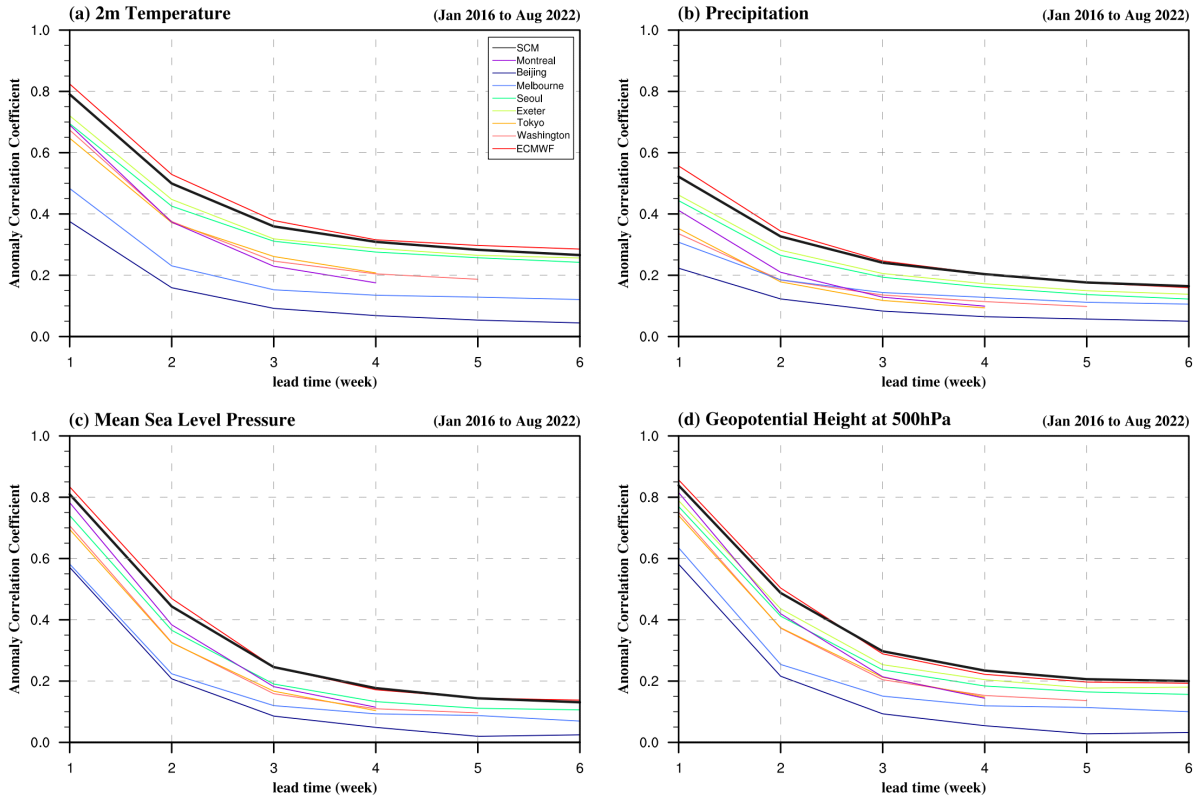


Figure 138. Anomaly correlation coefficient (ACC) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period of Jan 2016~Aug 2022 around the globe. ACC for SCM prediction is indicated by black line.

각 모델 및 변수별로 검증기간 동안 예측성의 변화 경향을 파악하기 위해 각 3주 예측 선행시간의 주별 평균 예측에 대한 ACC 검증 결과를 시계열로 나타내 보았다(Figure 139). 이때 주 단위로 생성되는 검증 결과를 분석에 쉽도록 해당 월별로 평균한 값을 시계열로 표출하였다. 월별 평균하는 기준은 검증의 대상이 되는 주 평균값의 시작일이 속하는 월을 기준으로 월별 평균을 수행하였으며, 그에 따라 4회에서 5회 예측에 대한 검증결과가 평균되며, 시계열의 시작과 끝은 월평균되는 검증 결과의 수가 그보다 적을 수 있다.

+3주 예측의 ACC 값은 SCM(검은색 선)과 ECMWF(붉은색 선) 예측이 전체기간에 걸쳐 비교적 높은 예측성을 보이며, 그 다음으로 Exeter(연두색 선)와 Seoul(초록색 선) 예측이 우수하였다. 모든 모델과 네 변수 모두에서 2020년 1월 전후로 예측성이 뚜렷하게 상승하는 모습을 보였으며 비교적 높은 값을 유지하였다. 그리고 T2M 변수와 PREC 변수가 상대적으로 작은 값이지만 예측 기간의 변화에도 일정한 ACC 값을 유지하는 경향을 보였고, MSLP와 Z500 변수는 ACC 값이 예측 기간에 따라 변화 폭이 큰 것으로 나타났다.

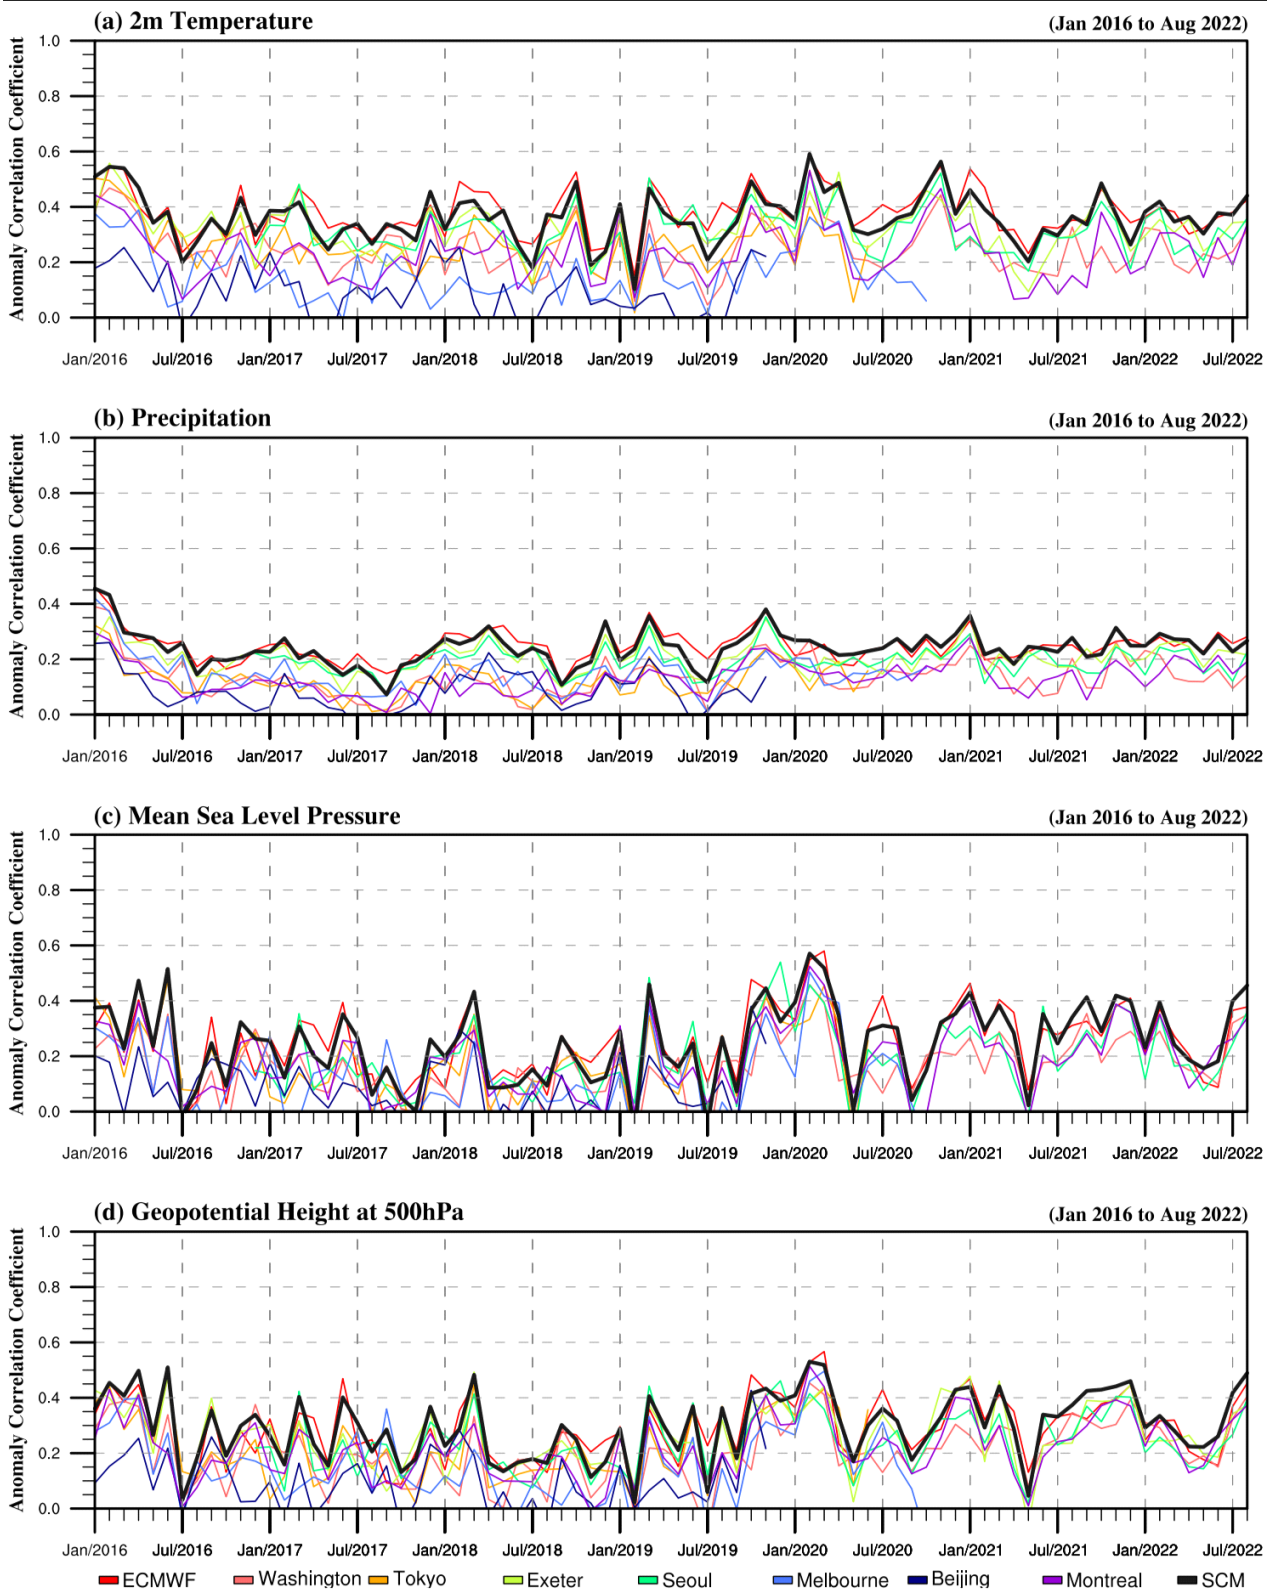


Figure 139. Anomaly correlation coefficient (ACC) of monthly averaged +3week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period from Jan 2016 to Oct 2022 around the globe. ACC for SCM prediction is indicated by black line.

(나) 계절내 예측 모델 예측성 비교 검증 (RMSE)

ACC 검증과 동일한 방법으로 전구영역에 대한 RMSE 검증 결과를 4개의 변수와 각 GPC 별로 분석하였다(Figure 140). Figure 138의 ACC 검증결과를 뒤집은 것과 비슷한 모습으로 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 낮은 값을 보이면서 상대적으로 정확한 예측을 하였다.

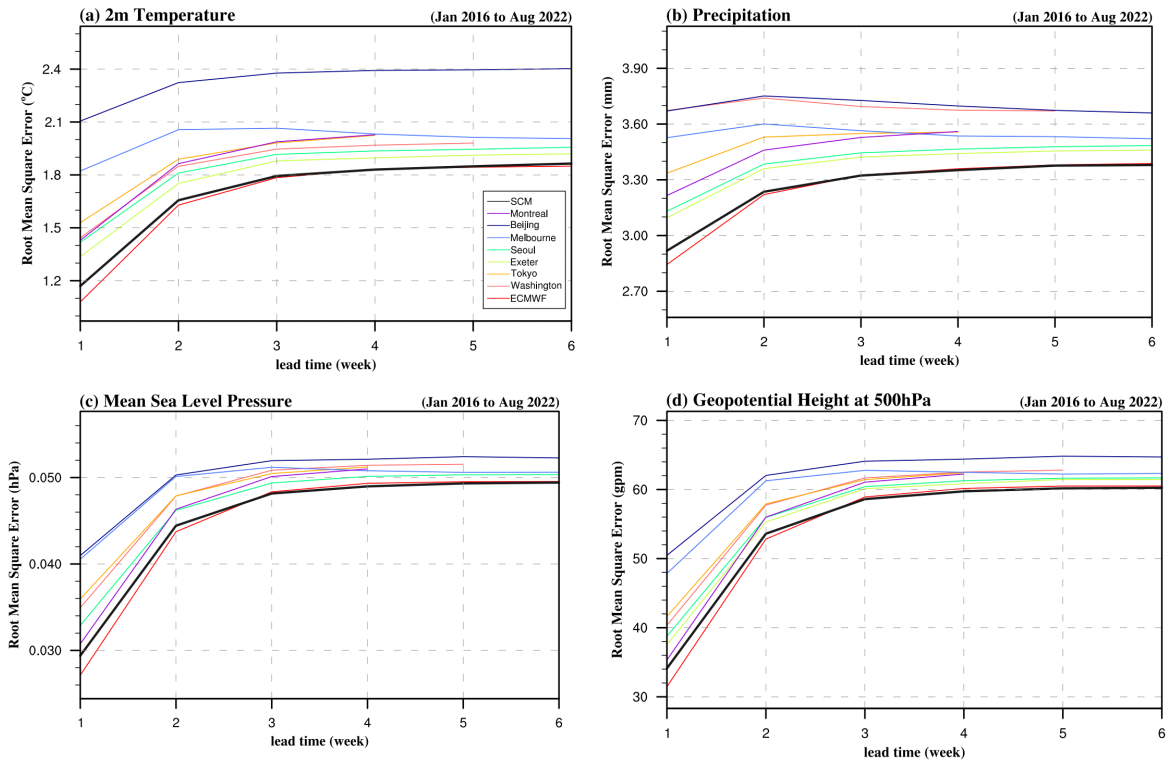


Figure 140. Root mean square error (RMSE) of weekly mean real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period from Jan 2016 to Oct 2022 around the globe. RMSE for SCM prediction is indicated by black line.

각 모델 및 변수별로 예측성의 변화 경향을 파악하기 위해 3주 예측 선행시간의 주별 평균 예측결과에 대한 RMSE 검증 결과를 시계열로 나타내었다(Figure 141). 예측결과 및 검증기준 자료처리 방법은 Figure 139와 동일하게 분석하였다. 모든 변수들이 계절적인 영향을 많이 받으면서 주기성을 띠고 있으며, ACC 검증과 마찬가지로 2020년부터 동일 시즌대비 예측성이 점차 향상되는 경향을 보이고 있다. 계절별로 보면 북반구 겨울에 해당하는 기간동안 예측성이 떨어지며, 이때는 개별모델 모두 예측성이 낮으며, 여름 시기에는 모델간의 예측성

차이가 커진다.

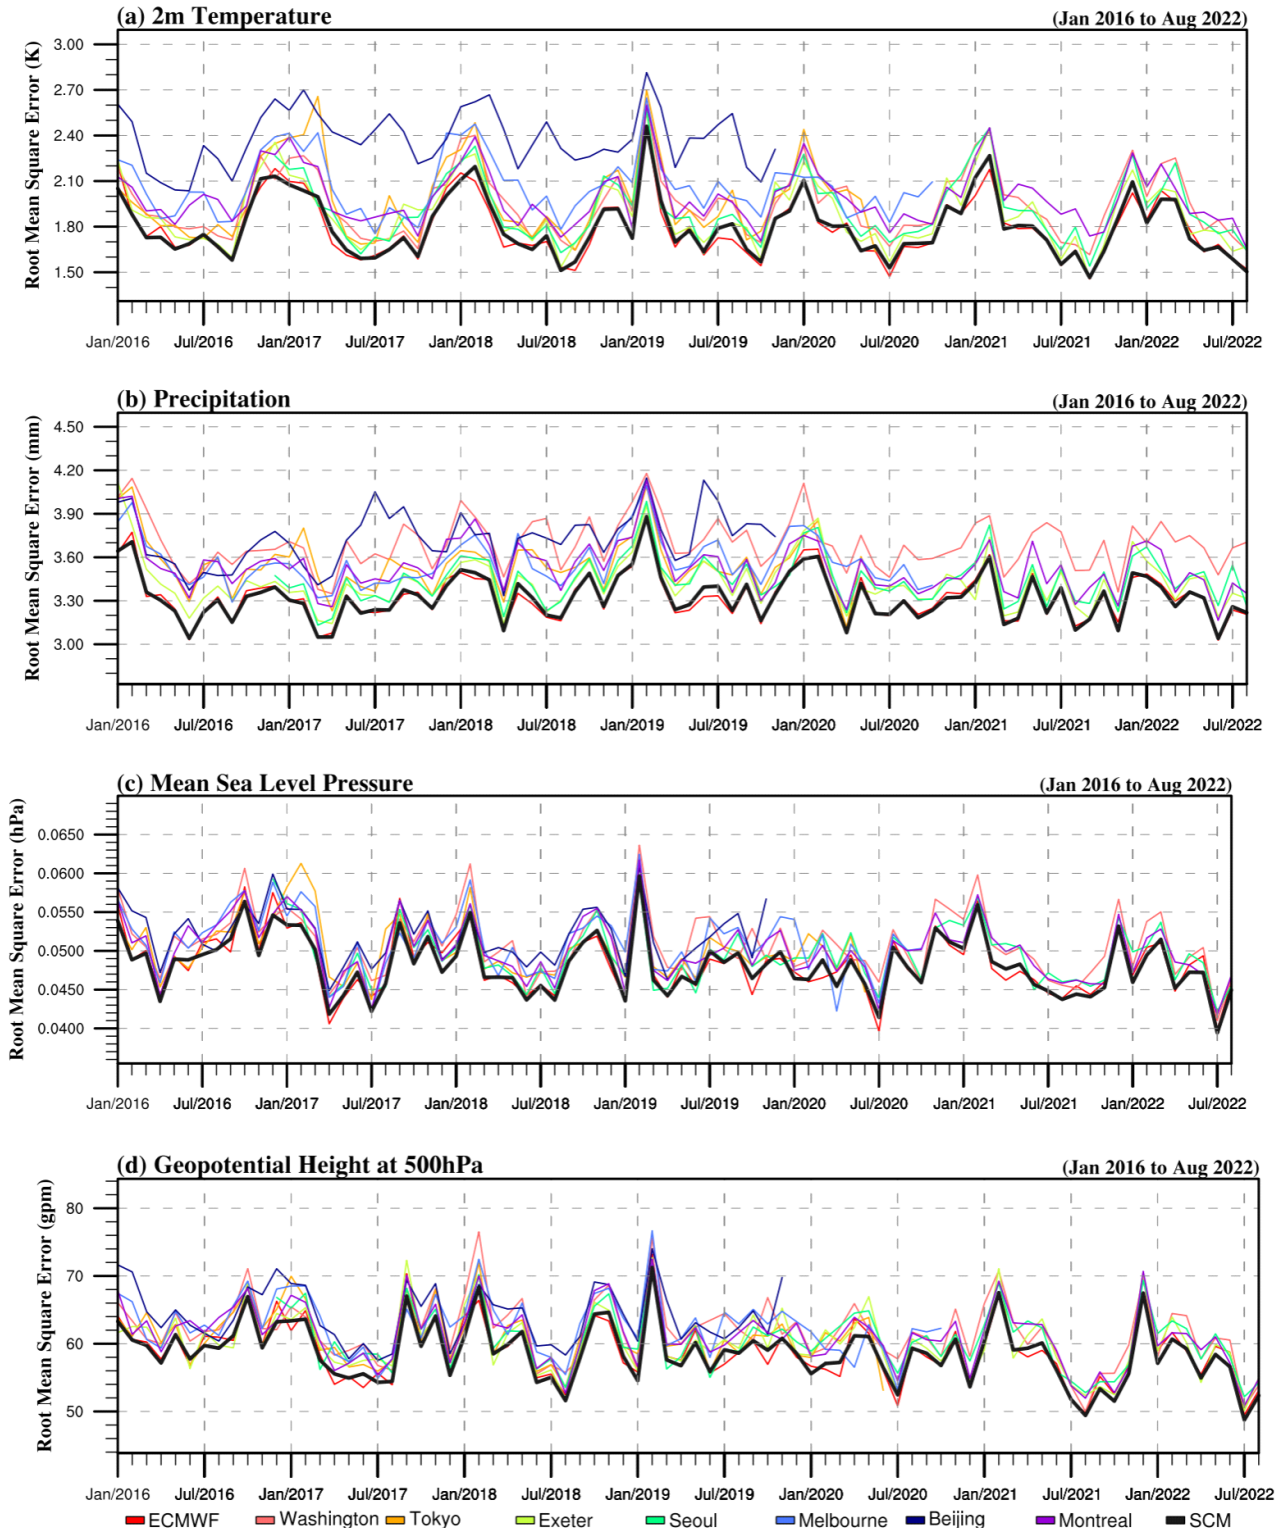


Figure 141. Root mean square error (RMSE) of monthly averaged +3week real-time subseasonal forecast of (a) T2M, (b) PREC, (c) MSLP and (d) Z500 for the period from Jan 2016 to Oct 2022 around the globe. RMSE for SCM prediction is indicated by black line.

4. 요약 및 결론

APCC는 지난 수년에 걸쳐 기상청과의 협력시스템을 바탕으로 지원체계를 강화함으로써 현업 장기예보 정확도 향상을 위한 노력을 기울여 왔다. 2022~2024년의 3년에 걸친 6단계 아태사업에서는 기존 APCC-기상청의 협력시스템을 바탕으로 하되, 장기예보에 있어 APCC만의 역할 영역을 더욱 확대할 필요가 있으며, 이를 위해서는 현업 장기예보 실무 예측기술을 개선하고, 앞서 개발된 기술 또는 개선된 기후정보(예측성이 좋은 정보)를 선별하고 가공하여 객관화된 예측정보를 생산할 수 있는 기반을 마련할 필요가 있다.

장기예보를 위해서는 자료생산단계(관측분석-기후모델운영-장기예보 기술개발) 및 예보정보생산단계(예보관 종합분석-서비스, 홍보)에서의 기술개발 및 개선이 필요하며, 이 둘의 연계를 통해 직접 실무에 적용하는 과정이 필요하다. 특히, 장기예보 생산을 위해서는 모델 예측정보가 필수적이며, 이를 실무에 활용하기 위한 장기예보기술을 개선할 필요가 있다. APCC MME와 기상청 현업모델의 성능은 ECMWF 모델에 버금하는 좋은 성능을 보이고 있지만, 우리나라를 포함한 중위도 지역의 기후에 대한 정확한 장기예보는 여전히 어려우며 특히 여름철 강수의 예측성은 현저히 낮게 나타나고 있다. 특히, 계절내 예측(+3~6주) 기술개발을 통해 예측사각지대를 해소할 수 있는 기술개발 및 개선과 함께, 우리나라 장기전망의 체계 자체에 대한 고민도 필요하다. 따라서 이 연구에서는 계절 및 계절내 장기예보 기술개선을 통한 정확도 향상과 함께, 그간의 장기예보 경험 및 (기존 관측 및 모델 자료 기반의) 산재된 정보를 통합하여, 우리나라 장기예보 시 활용가능한 객관화된 예측정보 생산을 위한 기반을 마련하고자 하였다. 이를 위하여, 2022년에는 장기예보 예측성 향상을 위한 기술을 개선하고자 하였다.

첫째, 3개월 장기예보 개선을 위한 모델 예측 특성 분석에서 겨울철 월별 ENSO 모의와 그에 대한 대기 반응의 모의 특성을 살펴보았다. 모델의 ENSO 모의 성능은 Nino3.4 지수로는 관측과 매우 높은 상관성을 보였고 월별로 모의 성능 차이가 크지 않았다. 지역별로는 동태평양과 서태평양은 관측보다 해수면온도 반응을 높게 중태평양은 다소 낮게 모의하는 경향을 보였으며, 월별로는 관측에서 나타나는 늦겨울이 될수록 서태평양과 중태평양에서 해수면온도가 증가하고 동태평양은 감소하는 해수면온도 반응 변화를 잘 모의하지 못했다. 모델의 ENSO와 관련된 열대 강수 반응은 양의 강수 중심을 관측보다 서쪽에서 모의했으며 서태평양 음의 강수의 월별 변화를 제대로 모의하지 못했다. 모델의 대기 반응은 북반구 전반적인 모의 성능에 비해 동아시아 영역에서의 모의 성능이 낮았다. 모델에서 12월 서태평양 강수와 관련된 북서태평양 지역의 고기압성 순환 반응을 모의했으나 관측보다 약하게 모의하였고, 관측에서는 1월에 고기압성 반응이 사라지고 2월에 한반도 북쪽으로 고기압성 반응이 나타났지만, 모델은 12월과 유사한 반응이 1월과 2월에도 이어지며 큰 차이를 보였다. 모델에서 중태평양 강수와 관련된 북태평양 저기압성 순환은 잘 모의했지만 관측보다 강하고 서쪽으로 확장되어 나타났다. 모델 대기 반응의 차이는 열대 강수 반응과 관련되어 있는데, 모델에서는 관측과 다르게 서태평양 강수가 1월에 약화되는 월별 변화를 모의하지 못했고, 중태평양 강수는 다소 강하게 모의했다. 이러한 특징은 개별모델들마다 약간의 차이는 있었지만 공통적으로 나타났다. ECMWF 모델은 해수면온도와 강수 모의에서 APCC MME 참여모델들보다 관측과의 차이를 대체로 작게 모의했고 선행시간과 관계없이 가장 안정적으로

관측과 유사하게 모의하는 특징을 보였으나, 동아시아지역 대기 반응에서는 다른 모델과 마찬가지로 오차가 크게 나타났다. 모델들의 오차는 2월에 크게 나타났는데 선행시간과는 관계없이 2월의 모의 성능이 낮게 나타나 모델 오차가 선행시간 뿐 아니라 예측 월에 따라서도 달라질 수 있음을 나타냈다. 모델은 전체 변동성 중 ENSO와 관련된 변동성이 매우 큰 부분을 차지하고 있으며 대륙의 변동성을 제대로 모의하지 못했다. ENSO 강제력이 전구 계절예측 측면에서는 모델 예측성을 높이는데 많은 부분 기여하지만 동아시아 지역 계절안 예측에서는 열대 해양으로부터의 영향뿐만 아니라 유라시아 대륙에서 넘어오는 대기 변동성 또한 우리나라에 큰 영향을 주기 때문에 예측성 향상을 위해서는 모델 예측 특성을 파악하고 이를 바탕으로 관측 정보 또는 모델 예측정보 보정 등을 통해 정보를 보완해 나가는 것이 필요하겠다.

둘째, 겨울철 월별 재분석자료를 통해 북극 이벤트를 4가지로 분류하고 그중 깊은 연직 온난화가 발생할 때 동아시아의 1월과 2월에 저온 발생빈도가 높음을 알 수 있었다. 1월과 2월의 해수면온도 편차의 패턴에서 대서양에서 삼극자 패턴을 나타내는 데에 공통점이 있었지만 깊은 연직 온난화는 대서양에서 극지역으로의 연직수분속 유입이 높은 경우에 잘 발생하며 우랄지역에 강한 고기압성 순환이 나타나 중위도 대서양에서 동아시아로 극지방을 통해 파동이 전파되는 모습을 나타냈다. 반면에 얕은 연직 온난화의 경우 우랄지역에 저기압성 순환과 함께 유라시아 대륙을 가로지르는 방향으로 파동이 전파되는 모습을 나타냈다. 다음으로 모델에서의 북극 이벤트에 대한 예측성을 평가하고, 깊은 연직 온난화를 예측할 때 북반구 지상기온과 상층 지위고도 패턴에 대한 모의 성능을 평가하였다. 이벤트에 대한 예측성은 KMA와 MME가 우수하게 나타났고, 깊은 연직 온난화에 대한 대기 반응은 1월과 2월에 모델들이 어느 정도 잘 모의하는 것으로 나타났다. 하지만 MME는 대기 반응 패턴에 대한 모의 성능이 매우 낮게 나타났다. 2022년 초에 나타난 기온 급강하 사례와 깊은 연직 온난화의 관련성에 대해 살펴보았다. 선행연구에서 나타난 패턴과 유사하게 바렌츠·카라해의 기온과 중위도 대기순환장의 패턴 등이 깊은 연직 온난화와 관련되어 있음이 확인되었고, 이러한 현상은 종관규모에서 겨울철뿐만 아니라 봄철까지도 나타날 수 있다.

셋째, 실제 2022년 여름철 장기예보를 위하여 실시간 APCC MME hindcast 및 real-time forecast를 사용하여 위에서 언급한 북서태평양고기압 모의 특성을 분석하였다. 그 결과, UKMO 모델의 경우 hindcast 기간(1993~2014) 동안 북서태평양고기압의 특징을 가장 잘 모의하는 것으로 나타났으며, 이를 토대로 UKMO 모델의 real-time forecast를 참조할 때 북서태평양고기압 지역은 평년보다 높은 기압 편차를 보여, 우리나라 기온은 다소 높고 강수량은 많을 것으로 예측되었다. 해당 결과는 2022년 여름철 예보를 위해 기후예측 전무가 회의에서 활용되었다. 한편, 계절안 규모에서의 대기순환에 대한 모델의 예측성을 살펴보았다. 또한 모델에서 계절안 규모의 대기순환과 한반도 기온 및 강수와의 관계를 어떻게 모의하는지도 살펴보았다. 그리고 최종적으로는 예측성과 신뢰성을 모두 고려한 최적의 모델 선별 과정을 통해 계절안 규모의 기온과 강수 예측성이 향상되는가를 살펴보았다. 1년 교차검증 결과로 살펴볼 때, 우리나라 기후 특성을 잘 모의하는 우수모델 선정 및 tailoring 과정을 통해 계절안 예측성이 크게 향상됨을 알 수 있다. 또한 선행시간이 증가할수록 더욱 크게 예측성이 증가하는 것으로 나타나, 이러한 과정이 기후예측모델 자료를 활용한 3개월 장기예보의 예측성을 향상시키는데 기여할 수 있을 것으로 보인다.

넷째, 관측된 BSISO 위상과 강도로 추정되는 영향편차장은 5월부터 10월까지 열대지역 뿐만 아니라 WNP-EA 지역에서도 대류활동의 계절내 변동성을 잘 재현하는 것을 확인하였다. 또한 WMO S2S ECMWF 모델의 3주 전 예측된 BSISO 영향편차장 예측성 평가 결과 상향장파복사, 500hPa 지위고도, 850hPa 바람에 대한 공간패턴 상관관계는 ECMWF 총편차 예측과 비슷한 수준이며 전반적으로 관측보다 약한 대기반응이 나타나는 특성을 보였다. BSISO 지수의 예측스킬은 +3~4주까지 나타나며 선행시간이 길어질수록 강도 및 위상전이 속도는 과소모의 하는 경향이 있다. +3주 예측에서 BSISO 두 모드의 강도가 강한 경우, 여름철 우리나라 기온 상승 및 폭염 또는 적은 강수를 유도하는 위상이 3일 이상 발생할 것으로 예측되는 경우 남동아시아 지역의 대류활동 및 연관된 대기순환 패턴을 잘 모의하는 것으로 나타났다. 또한 최신사례분석을 통해 BSISO 모드가 특정 위상에서 우리나라 주변 대기순환 패턴변화에 영향을 미칠 수 있음을 확인하였다. 2022년 장마기간 중 평년대비 강수가 많았던 시작/종료 시기와 8월 초순 호우시기에 BSISO 활동은 매우 활발하였다. 공통적으로 BSISO 대류활동이 아열대 서태평양 지역에 고기압성 흐름을 유도하고 남서풍으로 인한 수증기 유입이 강화되면서 우리나라 강수를 증가시키는 패턴이 나타났다. 특히, BSISO2 모드가 6-8번 위상에 위치하면서 길게 늘어진 밴드구조의 심층대류가 우리나라 부근에 위치하였고 장마 시작일에는 BSISO2 모드의 위상 7의 영향이 큰 것으로 나타났다. 반면 2016년 8월 둘째 주와 같이 BSISO1 모드가 위상 7에서 지속되며 강화되는 시기에는 북서태평양몬순 지역에서 대류활동이 활발하고 우리나라 부근 고기압성 흐름을 발달시켜 폭염 발생 가능성이 높아진다. 이와 같은 결과를 토대로 영향력과 예측성을 모두 고려하여 선별된 BSISO 예측정보를 활용하여 1개월 전망 예보토의 시 예보관 의사결정에 많은 도움을 줄 수 있을 것으로 기대된다.

다섯째, 동아시아지역과 남한지역의 1개월 기온확률예측을 개선하기 위해 딥러닝 기법을 이용하여 예측모델을 설계하였다. 또한 개발된 예측모델을 이용하여 확률예측기법을 개발하고 연구지역을 대상으로 확률예측결과를 비교 평가하였다. 딥러닝 모델은 U-NET 아키텍처를 기반으로 채널 어텐션 매커니즘(channel-attention mechanism)인 SE(Squeeze and Excitation) 블록을 도입하였다. 그리고 입력 길이는 14일, 출력 길이는 1일로 설계하였다. 딥러닝 모델의 학습자료는 1986년부터 2021년까지의 6시간 단위 ERA5 T2M 재분석자료를 일 단위 자료로 변환하고 사용하였다. 학습과 검증자료는 1986년부터 2015년까지 총 30년, 평가자료는 2018년부터 2021년까지 총 4년을 이용하였다. 시계열자료의 정상성 확보를 위해 학습과 검증자료에만 데이터 셔플 기법을 적용하였다. 15년간의 기후평년자료를 추가입력자료로 활용하여 U-Net 모델의 단점을 개선하고자 하였다. 확률예측은 개발된 예측모델을 토대로 ECMWF 51개 앙상블 +1주와 +2주 예보자료를 입력자료로 사용하여 +3주와 +4주의 기온을 예측하였다. 그리고 동일한 방법으로 ECMWF 11개 앙상블 hindcast 자료를 입력자료로 사용하여 +3주와 +4주 예측을 수행하고 딥러닝 예측모델에 적합한 hindcast 자료를 생산하였다. 확률 예측은 ECMWF 51개 앙상블 자료와 hindcast 11개 앙상블 자료를 이용하여 수행하였다. 확률예측결과로써, 동아시아 지역 ROC score map 분석에서는 ECMWF와 비슷한 예측성을 보였지만, 남한지역 HSS 분석에서는 ECMWF 예측결과와 비교하여 +3주 예측 시 2018년 +0.0463, 2019년 -0.058, 2020년 +0.0324, 2021년 -0.0488, +4주 예측 시 2018년 +0.0774, 2019년 -0.088, 2020년 -0.0082, 2022년 +0.1133으로 다소 높은 예측성을 보였다. 특히, ECMWF

예보자료는 above normal에서 높은 예측성을 보인 반면, 딥러닝 모델은 near normal의 예측성이 높게 나타났다. 그러므로, 딥러닝 모델 기반의 1개월 확률예측모델과 ECMWF 예측모델의 장단점을 고려하여 현업에 활용하면 보다 높은 정확도의 확률예측이 가능할 것으로 판단된다.

마지막으로, 2022년에도 APCC 1개월 전망 예측시스템 운영을 통하여 기상청 1개월 전망을 성공적으로 지원하였다. APCC 1개월 전망 예측시스템은 지속적으로 개선하고 있으며, 2022년에는 ECMWF 모델의 기후값 계산 방법을 변경하고, 시스템 자원을 효율적으로 사용하기 위해 전처리 계산 방법의 수정이 있었다. 또한 ECMWF 기반의 AO daily 예측 정보를 생산하는 시스템 구축하고, Washington과 Montreal 모델의 예측결과가 활용될 수 있도록 표출 시스템에 추가하였다. 개선된 콘텐츠와 기후 예측인자의 적절한 활용을 통하여 2022년에도 APCC의 1개월 예측 결과는 여러 모델 대비 우수한 예측성을 보였다. 이러한 APCC의 예측은 기상청과의 예보토의를 통해 충분히 공유하였고, 기상청의 장기예보 운영에 도움을 주었다.

References

- 기상청, 2022: 2021년 기후감시 및 분석기반의 장기예보 가이드스. 119p.
- 김가은, 김옥연, 윤순조, 이성규, 이진영, 이현주, 정유림, 2021: 현업 장기예보 정확도 향상을 위한 장기예보 지원체계 정립. APEC기후센터 연구보고서 2021.
- 여새림, 2016: 장기예보 정확도 향상을 위한 다양한 기후 요소와 우리나라 기후의 관련성 분석. APEC기후센터 연구보고서 2016.
- 여새림, 김선태, 명복순, 임슬희, 한정민, 이은정, 2021: 기후감시 및 분석체계 구축을 통한 이상기후 대응 역량 강화. APEC기후센터 연구보고서 2021.
- 예상욱 등, 2021: 대양간 상호작용 및 변동에 기인한 한반도 기후예측 기술개발. *기상청 기상지진 See-At 기술개발 연구 최종보고서*
- 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>.
- Cohen, J., X. Zhang, J. Francis, T. Jung, R. Kwok, J. Overland, T. J. Ballinger, U. S. Bhatt, H. W. Chen, D. Coumou, S. Feldstein, H. Gu, D. Handorf, G. Henderson, M. Ionita, M. Kretschmer, F. Laliberte, S. Lee, H. W. Linderholm, W. Maslowski, Y. Peings, K. Pfeiffer, I. Rigor, T. Semmler, J. Stroeve, P. C. Taylor, S. Vavrus, T. Vihma, S. Wang, M. Wendisch, Y. Wu, and J. Yoon, 2020: Divergent consensuses on Arctic amplification influence on midlatitude severe winter weather. *Nature Climate Change*, **10**(1), 20-29. <https://doi.org/10.1038/s41558-019-0662-y>
- Coumou, D., G. di Capua, S. Vavrus, L. Wang, and S. Wang, 2018: The influence of Arctic amplification on mid-latitude summer circulation. *Nature Communications*, **9**(1), 2959. <https://doi.org/10.1038/s41467-018-05256-8>
- Deser, C., R. A. Tomas, and L. Sun, 2015: The role of ocean-atmosphere coupling in the zonal-mean atmospheric response to Arctic sea ice loss. *Journal of Climate*, **28**(6), 2168-2186. <https://doi.org/10.1175/jcli-d-14-00325.1>
- Francis, J. A., and S. Vavrus, 2012: Evidence linking Arctic amplification to extreme weather in mid-latitudes. *Geophysical Research Letters*, **39**, L06801. <https://doi.org/10.1029/2012GL051000>
- Guilyardi, E., A. Capotondi, M. Lengaigne, S. Thual, and A. T. Wittenberg, 2020: ENSO modelling: History, progress and challenges. El Niño Southern Oscillation in a Changing Climate, Geophys. Monogr., Vol. 252, *Amer. Geophys. Union*, 199-226, <https://doi.org/10.1002/9781119548164.ch9>

- Ham, Y.-G., and J.-S. Kug, 2015: Improvement of ENSO Simulation Based on Intermodel Diversity. *Journal of Climate*, **28**(3), 998–1015. <https://doi.org/10.1175/JCLI-D-14-00376.1>
- He, C., and T. Zhou, 2014: The two interannual variability modes of the western North Pacific subtropical high simulated by 28 CMIP5-AMIP models. *Climate Dynamics*, **43**, 2455–2469. <http://doi.org/10.1007/s00382-014-2068-x>
- He, S., X. Xu, T. Furevik, and Y. Gao, 2020: Eurasian cooling linked to the vertical distribution of Arctic warming. *Geophysical Research Letters*, **47**, e2020GL087212. <https://doi.org/10.1029/2020GL087212>
- Hersbach, H., B. Bell, P. Berrisford, S. Hirahara, A. horányi, J. Moñoz-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>.
- Hong, C. C., T. C. Chang, and H. H. Hsu, 2014: Enhanced relationship between the tropical Atlantic SST and the summertime western North Pacific subtropical high after the early 1980s. *Journal of Geophysical Research-Atmospheres*, **119**(7), 3715–3722. [doi:10.1002/2013JD021394](https://doi.org/10.1002/2013JD021394)
- Hsu, P. C., J. Y. Lee, K. J. Ha, and C. H. Tsou, 2017: Influences of boreal summer intraseasonal oscillation on heat waves in Monsoon Asia. *J. Climate*, **30**, 7191–7211, [doi:10.1175/JCLI-D-16-0505.1](https://doi.org/10.1175/JCLI-D-16-0505.1).
- Hu, J., L. Shen, and 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, Z., W. Zhang, X. Geng, and F.-F. Jin, 2020: Recent shift in the state of the western Pacific subtropical high due to ENSO change. *Journal of Climate*, **33**(1), 229–241. [doi:10.1175/JCLI-D-18-0873.1](https://doi.org/10.1175/JCLI-D-18-0873.1)
- Kim, H. M., P. J. Webster, V. E. Toma, and D. Kim, 2014: Predictability and prediction skill of the MJO in two operational forecasting systems. *J. Clim.*, **27**, 5364–5378.
- Kim, S., H. S. Kim, S. K. Min, H. Y. Son. D. J. Won, H. S. Jung, and J. S. Kug, 2015: Intra-winter atmospheric circulation changes over East Asia and North Pacific associated with ENSO in a seasonal prediction model. *Asia-Pacific J. Atmos. Sci.* **51**(1), 49–60. <https://doi.org/10.1007/s13143-014-0059-9>

- Kim, S., H. Y. Son, and J. S. Kug, 2017: How well do climate models simulate atmospheric teleconnections over the North Pacific and East Asia associated with ENSO?. *Clim. Dyn.* **48**, 971–985. <https://doi.org/10.1007/s00382-016-3121-8>
- Krishnamurti, T. N., C. M. Kishtawal, Z. Zhang, T. LaRow, D. Bachiochi, C. E. Williford, S. Gadgil, and S. Surendran, 2000: Multimodel ensemble forecasts for weather and seasonal climate. *J. Climate*, **13**, 4196–4216.
- Lee J. Y., H. J. Kim, and Y. R. Jung, 2019: Influence of Boreal Summer Intraseasonal Oscillation on the 2016 Heat Wave over Korea. *Atmosphere. Korean Meteorological Society* Vol. 29, No. 5 (2019) pp. 627–637.
- Lee S.-S., B. Wang, D. E. Waliser, J. M. Neena, and J.-Y. Lee, 2015: Predictability and prediction skill of the boreal summer intraseasonal oscillation in the Intraseasonal Variability Hindcast Experiment. *Clim. Dyn.*, **45**, 2123–2135.
- Li, G., and S. P. Xie, 2014: Tropical Biases in CMIP5 Multimodel Ensemble: The Excessive Equatorial Pacific Cold Tongue and Double ITCZ Problems. *Journal of Climate*, **27**(4), 1765–1780. <https://doi.org/10.1175/JCLI-D-13-00337.1>
- Liu, Y., Z. Ke, and Y. Ding, 2019: Predictability of East Asian summer monsoon in seasonal climate forecast models. *International Journal of Climatology*, **39**(15), 5688–5701. [doi://10.1002/joc.6180](https://doi.org/10.1002/joc.6180)
- Lu, R., 2001: Interannual variability of the summertime North Pacific subtropical high and its relation to atmospheric convection over the warm pool. *Journal of the Meteorological Society of Japan. Ser. II*, **79**(3), 771–783. [doi:10.2151/jmsj.79.771](https://doi.org/10.2151/jmsj.79.771)
- Matsumura, S., and Y. Kosaka, 2019: Arctic–Eurasian climate linkage induced by tropical ocean variability. *Nature Communications*, **10**(1), 3441. <https://doi.org/10.1038/s41467-019-11359-7>
- Min, Y. M., V. N. Kryjov, and S. M. Oh, 2014: Assessment of APCC multimodel ensemble prediction in seasonal climate forecasting: Retrospective (1983–2003) and real-time forecasts (2008–2013). *J. Geophys. Res. Atmos.*, **119**(21), 12132–12150. <https://doi.org/10.1002/2014JD022230>
- Mori, M., Y. Kosaka, M. Watanabe, H. Nakamura, and M. Kimoto, 2019: A reconciled estimate of the influence of Arctic sea-ice loss on recent Eurasian cooling. *Nature Climate Change* **9**, 123–129. <https://doi.org/10.1038/s41558-018-0379-3>
- Ogawa, F., N. Keenlyside, Y. Gao, T. Koenigk, S. Yang, L. Suo, T. Wang, G. Gastineau, T. Nakamura, H. N. Cheung, N. E. Omrani, J. Ukita, and V. Semenov, 2018: Evaluating impacts of recent Arctic sea ice loss on the northern hemisphere winter climate change. *Geophysical Research Letters*, **45**, 3255–3263. <https://doi.org/10.1002/2017GL076502>

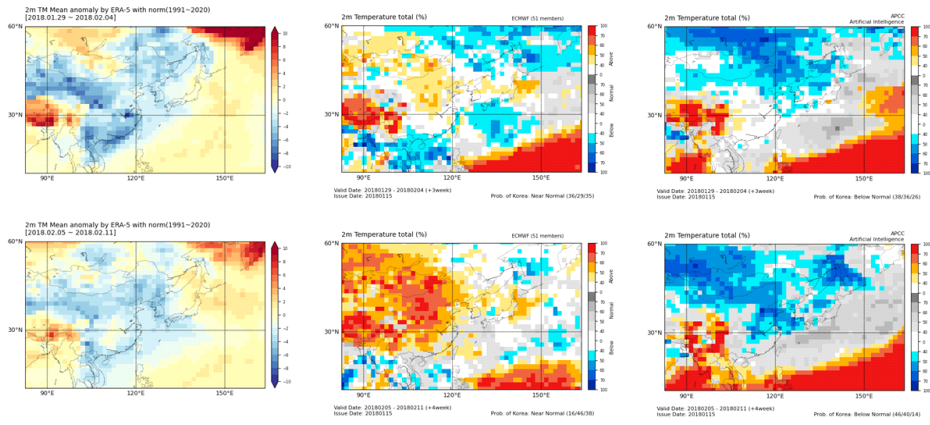
- Paek, H., J. Y. Yu, J. W. Hwu, M. M. Lu, and T. Gao, 2015: A source of AGCM bias in simulating the western Pacific subtropical high: different sensitivities to the two types of ENSO. *Monthly Weather Review*, **143**(6), 2348–2362. doi:10.1175/MWR-D-14-00401.1
- Rashid, H. A., H. H. Hendon, M. C. Wheeler, and O. Alves, 2011: Prediction of the Madden–Julian oscillation with the POAMA dynamical prediction system. *Climate Dyn.*, **36**, 649–661, <https://doi.org/10.1007/s00382-010-0754-x>
- 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, *J. Geophys. Res.*, **108**, 4407, <https://doi.org/10.1029/2002JD002670>
- Screen, J. A., and I. Simmonds, 2010: The central role of diminishing sea ice in recent Arctic temperature amplification. *Nature*, **464**(7293), 1334–1337. <https://doi.org/10.1038/nature09051>
- Screen, J. A., C. Deser, and I. Simmonds, 2012: Local and remote controls on observed Arctic warming. *Geophysical Research Letters*, **39**, L10709. <https://doi.org/10.1029/2012GL051598>
- Sellevoold, R., S. Sobolowski, and C. Li, 2016: Investigating possible Arctic–midlatitude teleconnections in a linear framework. *Journal of Climate*, **29**(20), 7329–7343. <https://doi.org/10.1175/Jcli-D-15-0902.1>
- Sohn, S. J., and W. M. Kim, 2020: Toward a better multi-model ensemble prediction of East Asian and Australasian precipitation during non-mature ENSO seasons. *Sci. Rep.* **10**, 20289. <https://doi.org/10.1038/s41598-020-77482-4>
- Son, H. Y., J. Y. Park, J. S. Kug, J. Yoo, and C. H. Kim, 2014: Winter precipitation variability over Korean peninsula associated with ENSO. *Climate Dynamics*, **42**(11–12), 3171–3186. <https://doi.org/10.1007/s00382-013-2008-1>
- Tyrlis, E., E. Manzini, J. Bader, J. Ukita, H. Nakamura, and D. Matei, 2019: Ural blocking driving extreme Arctic sea ice loss, cold Eurasia, and stratospheric vortex weakening in autumn and early winter 2016–2017. *Journal of Geophysical Research: Atmospheres*, **124**, 113313–11329. <https://doi.org/10.1029/2019JD031085>
- Vitart, F. et al., 2017: The subseasonal to seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, **98**(1), 163–173. <https://doi.org/10.1175/BAMS-D-16-0017.1>
- Wang, B., R. Wu, and X. Fu, 2000: Pacific–East Asian teleconnection: how does ENSO affect East Asian climate?. *Journal of Climate*, **13**(9), 1517–1536. [https://doi.org/10.1175/1520-0442\(2000\)013<1517:PEATHD>2.0.CO;2](https://doi.org/10.1175/1520-0442(2000)013<1517:PEATHD>2.0.CO;2)

- Wang, H., and R. Fu, 2000: Winter monthly mean atmospheric anomalies over the north Pacific and north America associated with El Nino SSTs. *Journal of Climate*, **13**(19), 3435–3447. [https://doi.org/10.1175/1520-0442\(2000\)013<3435:WMMAAO>2.0.CO;2](https://doi.org/10.1175/1520-0442(2000)013<3435:WMMAAO>2.0.CO;2)
- Warner, J. L., J. A. Screen, and A. A. Scaife, 2020: Links between Barents–Kara sea ice and the extratropical atmospheric circulation explained by internal variability and tropical forcing. *Geophysical Research Letters*, **47**, e2019GL085679. <https://doi.org/10.1029/2019GL085679>
- Weyn, J. A., D. R. Durran, and R. Caruana, 2019: Can machines learn to predict weather? Using deep learning to predict gridded 500-hPa geopotential height from historical weather data. *J. Adv. Model. Earth Syst.* **11**(8), 2680–2693, <https://doi.org/10.1029/2019MS001705>.
- Xiang, B., B. Wang, W. Yu, and S. Xu, 2013: How can anomalous western North Pacific subtropical high intensity in late summer? *Geophysical Research Letters*, **40**(10), 2349–2354. doi:10.1002/grl.50431
- Xu, X., S. He, Y. Gao et al., 2021: Contributors to linkage between Arctic warming and East Asian winter climate. *Climate Dynamics*, **57**, 2543–2555, <https://doi.org/10.1007/s00382-021-05820-x>
- Zhang, P., Y. Wu, I. R. Simpson, K. L. Smith, X. Zhang, B. De, and P. Callaghan, 2018: A stratospheric pathway linking a colder Siberia to Barents–Kara Sea sea ice loss. *Science Advances*, **4**(7), eaat6025. <https://doi.org/10.1126/sciadv.aat6025>

부록 A. 딥러닝 모델의 1개월 기온확률예측 사례비교

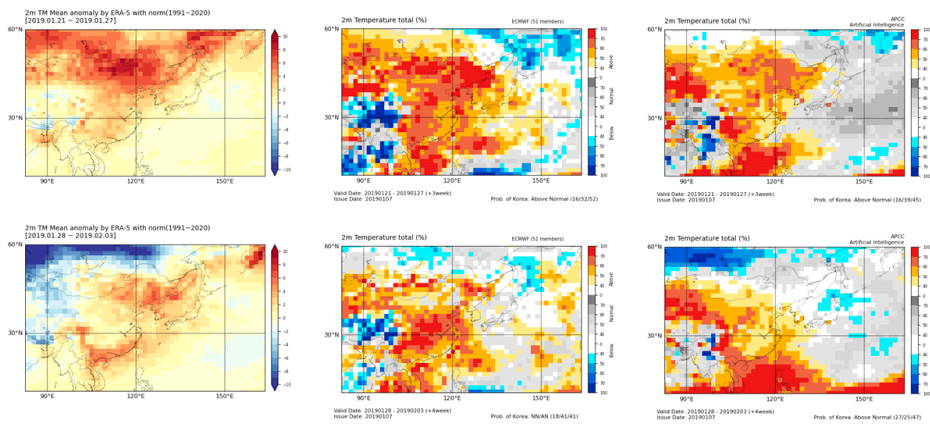
Issue date: 2018.01.15

	ASOS	ECMWF	DL
F1 (+3w)	-	0	-
F2 (+4w)	-	0	-



Issue date: 2019.01.07

	ASOS	ECMWF	DL
F1 (+3w)	+	+	+
F2 (+4w)	+	+	+



Issue date: 2020.03.02

	ASOS	ECMWF	DL
F1 (+3w)	+	+	+
F2 (+4w)	+	+	+

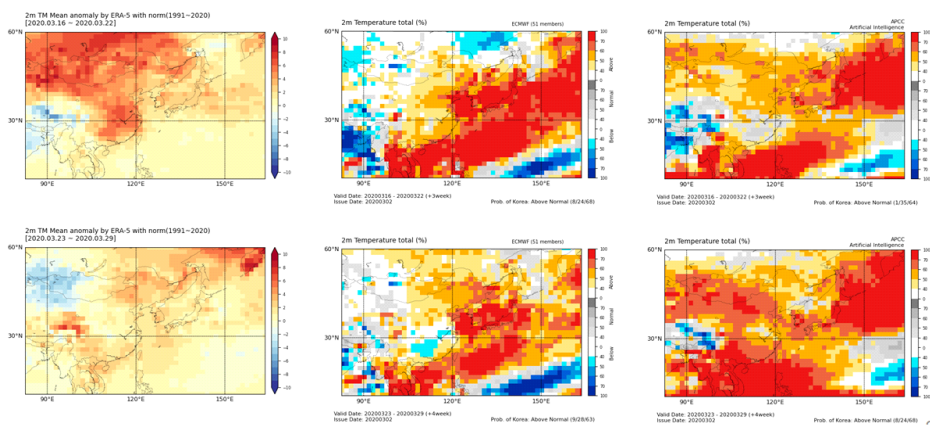


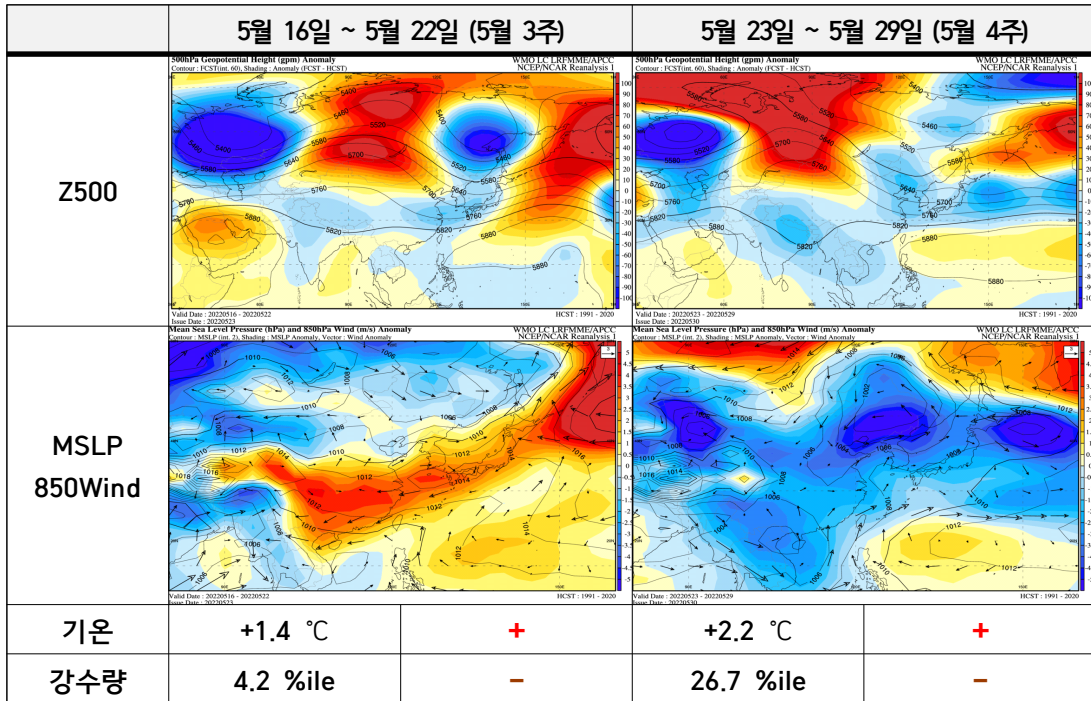

Figure A1. Comparison of 2m TM mean anomaly by ERA5 reanalysis data with norm(1991~2020), ECMWF probability forecast and deep learning-base probability prediction (first row: +3week, second row: +4week, first column: ERA5, second column: ECMWF, third column: deep learning model)

부록 B. 1개월 전망 검증 보고서

APCC 1개월 전망 검증 보고서 (2022년 5월)

【 2022. 8. 4.(목) / 기후분석과 】

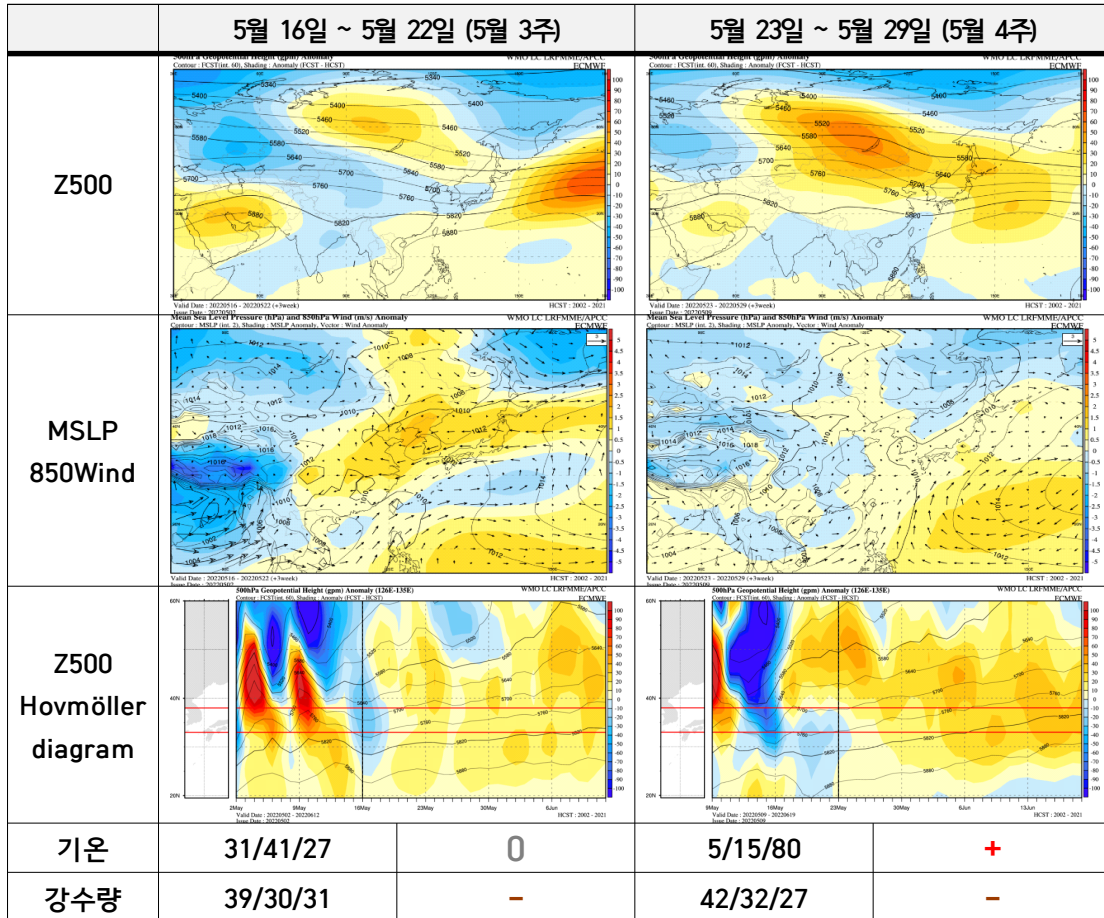
□ 우리나라 기온/강수량 현황 및 대기 순환장 특징



- 5월 중순부터 바이칼호 부근 상층 기압능이 3주간 정체, 우리나라 주변 Z500 편차장은 음의 값을 보였지만 우리나라 기온/강수량은 평년보다 높고, 건조하였음
 - 3주 : 우리나라 주변 Z500은 음의 편차인 반면 해면기압은 양의 편차, 하층 바람은 서풍 편차값을 보였음. 주 초반 북쪽 골의 일시적인 영향 후 맑은 날씨가 지속되면서 기온 상승이 나타남
 - 4주 : 우리나라 주변 Z500 과 해면기압은 모두 음의 편차이지만, 하층의 저기압성 편차의 중심이 우리나라 북쪽에 위치하면서 우리나라는 남서풍 편차값을 보였음. 북쪽 골이 한차례 통과하였으나 강수량은 적었으며, 정체하지 않고 빠르게 지나가

면서 기온의 하락폭은 적었음, 대부분의 날에 맑고 기온이 크게 상승함
 ※ 5월 중순부터 BSISO1 약화되고 BSISO2 P5로 지속되면서 한반도 남쪽 저기압성
 순환 편차, 북동풍 바람 편차에 의한 연직수분속 수렴 약화됨

□ ECMWF 대기 순환장 및 기온/강수 3주 전 예측 결과



- 바이칼호 부근 상층 기압능의 발달과 우리나라 주변 MSLP 예측이 비교적 정확함
 - 3주 : 우리나라 부근 Z500 음의 편차, MSLP 양의 편차, 상층 기압골 발달은 주 초반에 영향 줄 것으로 잘 예측하였으나, 우리나라 기온은 과소모의
 - 4주 : 우리나라 부근 Z500/MSLP는 양의 편차, 주 초반에 남쪽골의 영향을 받을 것으로 예측함. 우리나라 부근 기압계는 관측보다 양의 편차로 과대모의 하였으나, 우리나라 기온/강수량 예측은 적중함
- ※ 관측과 유사하게 5월 중순부터 BSISO1 약화되고 BSISO2 Phase5-6에서 발달하면서 한반도 남동쪽 부근 저기압성 순환, 북풍 또는 북동풍 바람편차, 연직수분속 수렴 약화되면서 적은 강수에 기여할 것으로 예측

□ 과거 사례 [2020. 5. 18~24.]

	관측 (NCEP1, ASOS)		ECMWF 3주 전 예측	
Z500				
MSLP 850Wind				
기온	-1.8 °C	15/34/51	+	
강수량	60.0 %ile	26/28/46	+	

- Z500 편차장의 패턴이 이번 사례와 일치하였으나 우리나라 기온/강수량은 평년보다 낮고, 평년보다 높았으며, 모델의 예측이 실패한 사례
 - Z500 편차장의 패턴(우랄산맥 부근 음의 편차, 바이칼호 양의 편차, 우리나라 부근 음의 편차)은 유사하나, MSLP 편차장에서 우리나라 주변으로 저기압성 편차가 더 강하게 나타남
 - ECMWF 3주전 예측에서 Z500/MSLP 편차장의 예측은 정확하였으나 상층골과 하층 저기압의 영향을 과소모의하여 기온을 높게 예측함

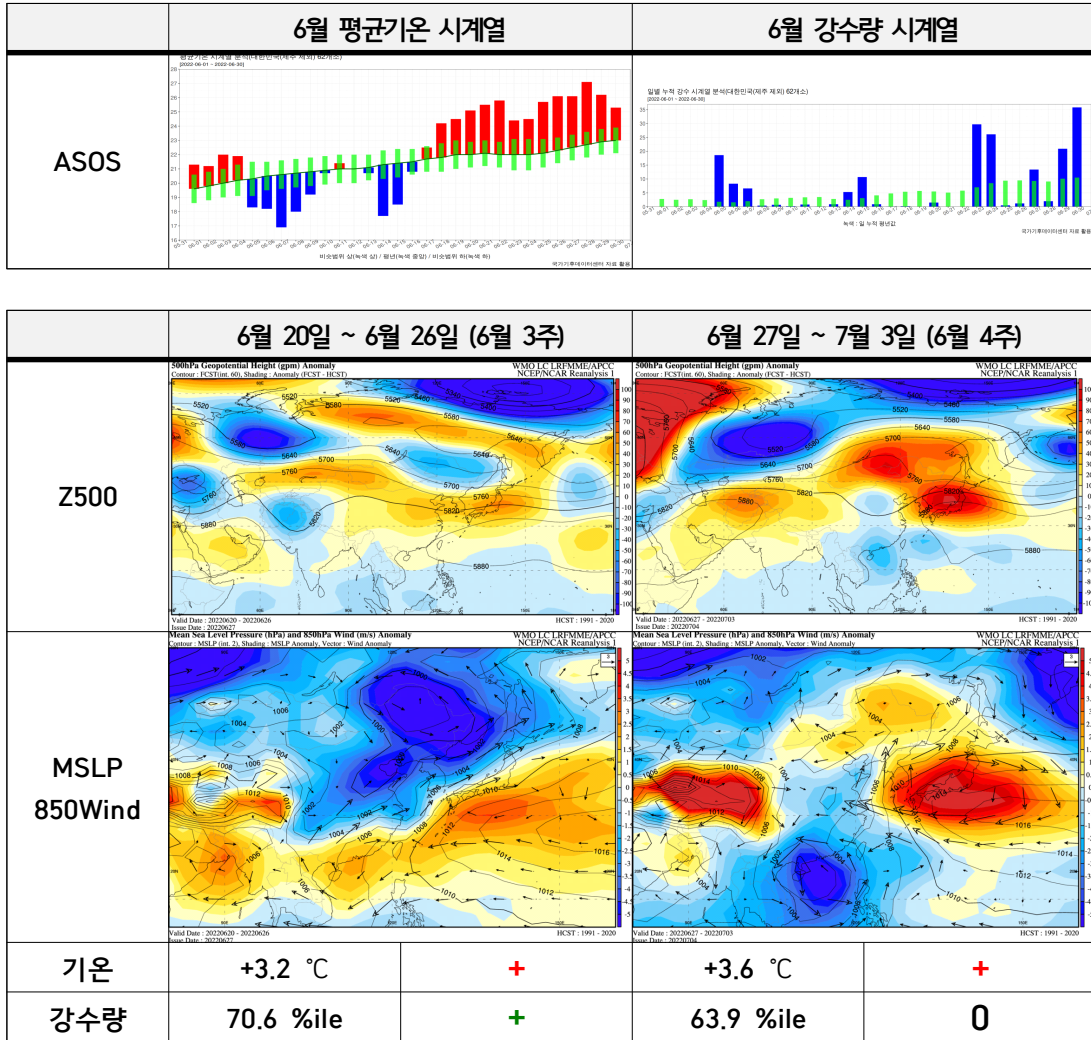
□ 토의 사항

- 기압능이 장기간(3주간) 정체하는 경우 ECMWF 3주전 예측에서도 상/하층의 기압계 패턴을 유사하게 잘 예측함
- 우리나라 주변 상층에서 음의 편차가 나타나는 경우에도, 기압골의 강도와 지속시간에 따라 우리나라 기온에 미치는 영향이 다름
 - 이번 사례처럼 하층에 고기압성 편차장 또는 남서풍 편차를 예측하는 경우, 상층골의 영향은 일시적이며, 기온의 하락폭은 적고 모델 예측보다 고온 건조할 수 있음
 - 20년 5월 사례의 경우, 상/하층 모두 음의 편차가 강했으며, 상층골의 영향을 모델 예측보다 강하게 해석해야 함
 - 봄철 상층골의 영향 정도는 MSLP 편차장 패턴으로 보정이 필요함

APCC 1개월 전망 검증 보고서 (2022년 6월)

【 2022. 8. 18.(목) / 기후분석과 】

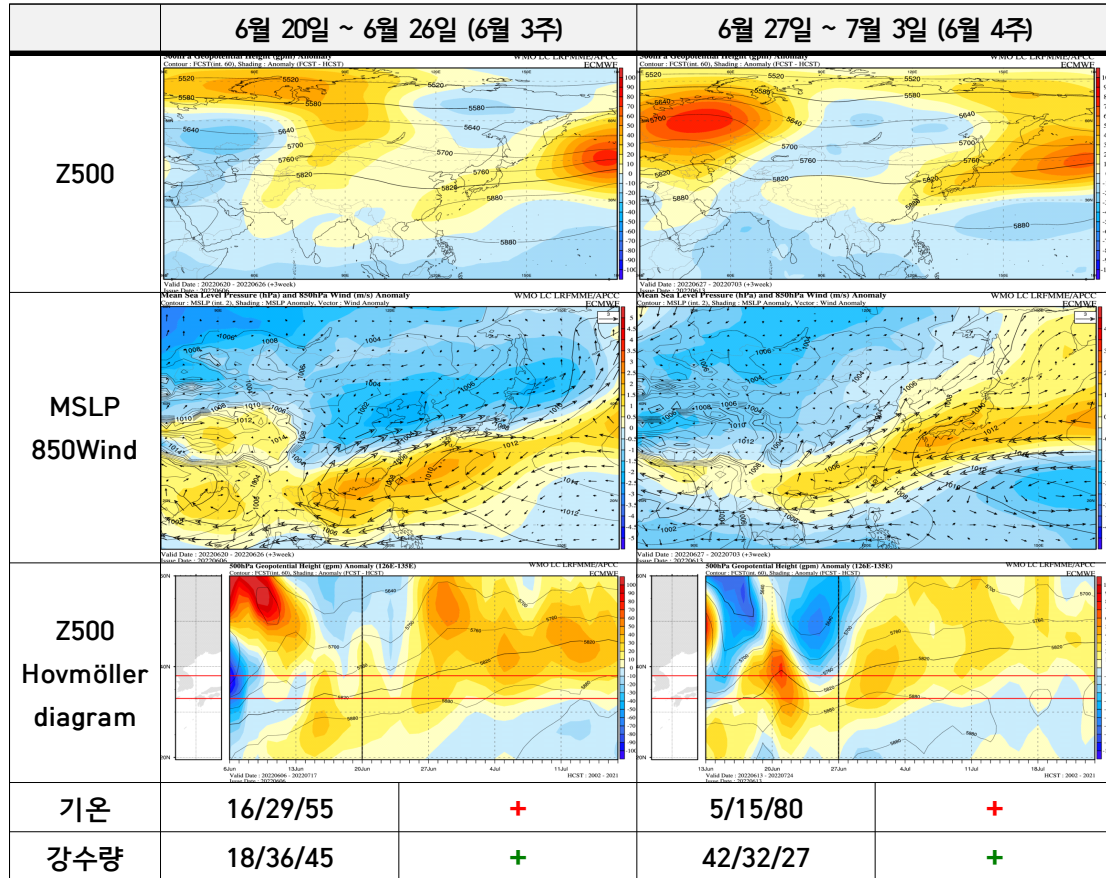
□ 우리나라 기온/강수량 현황 및 대기 순환장 특징



- 우리나라는 6월 3/4주 동안 동쪽에 중심을 둔 Z500 양의 편차 영역의 영향을 받았으며, 양의 해면기압 편차값은 우리나라 남동쪽에 위치하면서 하층의 남서풍 바람 편차가 매우 우세하였음. 기온은 평년보다 높고, 강수량은 많은 경향을 보였음
 - 3주 : 우리나라 북쪽으로 기압골이 통과하면서 Z500과 해면기압 모두 북쪽을 중심으로 음의 편차값을 보였음. 우리나라는 상층 고기압과 하층 남동쪽 고압대의 영향을 함께 받으면서 강한 남서기류 유입으로 기온상승과 더불어 강수량도 많았음(6월 23일 장마 시작).
 - 4주 : 우리나라 동쪽을 중심으로 한 강한 Z500/해면기압 양의 편차의 영향을 받았으며, 이 고압대는 남중국해의 강한 대류활동의 영향으로 더욱 강화됨. 우리나라 하

층 바람 편차는 남풍이 강하였으며, 평년보다 높은 기온과 중부지방 중심의 많은 강수량을 기록함(전국 평균으로는 평년과 비슷한 강수량)

□ ECMWF 대기 순환장 및 기온/강수 3주 전 예측 결과



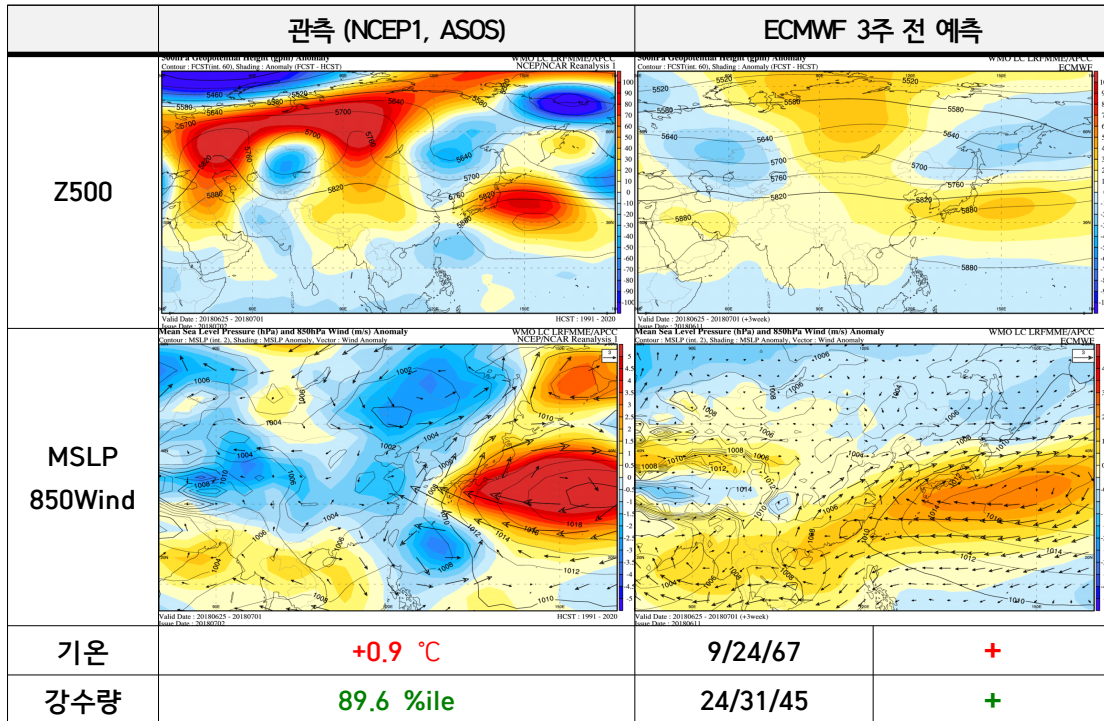
○ 한반도 남동쪽 중심의 상/하층의 양의 편차값 패턴과 하층 남서풍 편차를 관측과 유사하게 예측함.

- 3주 : 우리나라 부근 5820선(Z500)의 위치와 남북 기압계 편차(MSLP)의 배치, 대기 하층 남서풍 편차를 매우 잘 예측하였으며, 우리나라 기온은 평년보다 높고, 강수량은 평년보다 많을 것으로 예측함.

- 4주 : 우리나라 기온은 평년보다 높고, 강수는 평년보다 많을 것으로 정확히 예측함. 다만, 우리나라 북서쪽의 기압골을 강하게 예측하고, 남중국해의 대류활동을 예측하지 못하면서, 북서태평양고기압의 위치가 관측에 비해 남서쪽에 위치하면서 강수 구역이 중부지역에 치우치는 것을 예측하지 못함

※ 4주차 BSISO 대류활동이 남중국해 부근 강화되면서 한반도 남동쪽 고기압 발달 및 남풍으로 인한 수증기 유입 증가 패턴이 관측되나 3주 전 예측에서 모의하지 못함

□ 과거 사례 [2018. 6. 25. ~ 7. 1.]



- 2018년 6월 장마 시작 시점(6월 26일)에 한반도 남동쪽에 고압대가 위치하는 패턴
 - 한반도 북쪽으로 음의 Z500 편차값을 보이지만 우리나라는 남동쪽 중심의 양의 편차 영향을 받음. 해면기압 편차장에서도 남동쪽에 양의 편차값이 위치하며, 우리나라는 강한 남서기류 유입에 따른 평년보다 덥고 강수량이 많았음
 - ECMWF 3주전 예측(6월3주)에서도 Z500/MSLP 편차장을 유사하게 예측하였으며, 하층의 남서풍 편차로 인한 높은 기온과 많은 강수량을 정확히 예측함

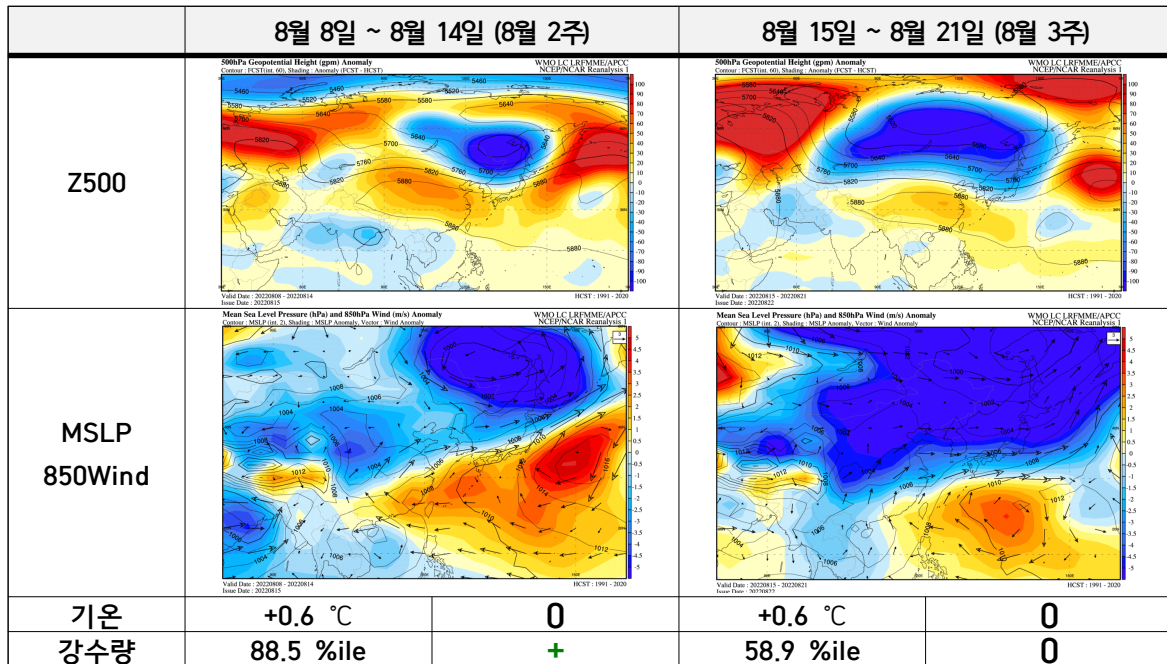

□ 토의 사항

- 6월 중순 전후로 한반도 남동쪽의 양의 편차, 대기 하층 남서풍 편차를 강하게 예측한다면 장마의 시작으로 평년보다 높은 기온과 많은 강수량으로 예측
- 6월은 북쪽 골의 영향이 매우 강하지 않다면 강수에 따른 기온 하강보다는 수증기 유입과 온난이류에 따른 기온상승으로 기온과 강수량이 양의 상관관계를 가질 수 있음
- 2018년과 2022년 사례에서 장마 시작점 예측은 ECMWF의 Z500 시계열 예측 결과에서 5820선이 우리나라 남부지역(북위 35°)까지 북상하고 남서풍 편차가 강할 때 (3m/s 이상)로 판단할 수 있음
- 2018년 6월 4주와 2022년 6월 4주에 남중국해에서 발생한 태풍을 ECMWF 3주전 예측에서는 전혀 예측하지 못함

APCC 1개월 전망 검증 보고서 (2022년 8월)

【 2022. 9. 28.(수) / 기후분석과 】

□ 우리나라 기온/강수량 현황 및 대기 순환장 특징



○ 8월 2~3주 동안 상하층 모두 우리나라 남쪽으로 고기압성 순환이, 북쪽으로 저기압성 순환이 강화되는 순압구조를 보였으며 우리나라는 그 경계에서 발달하는 정체전선의 영향을 받음. 기온은 평년 비슷, 강수량은 많은 경향을 보였음.

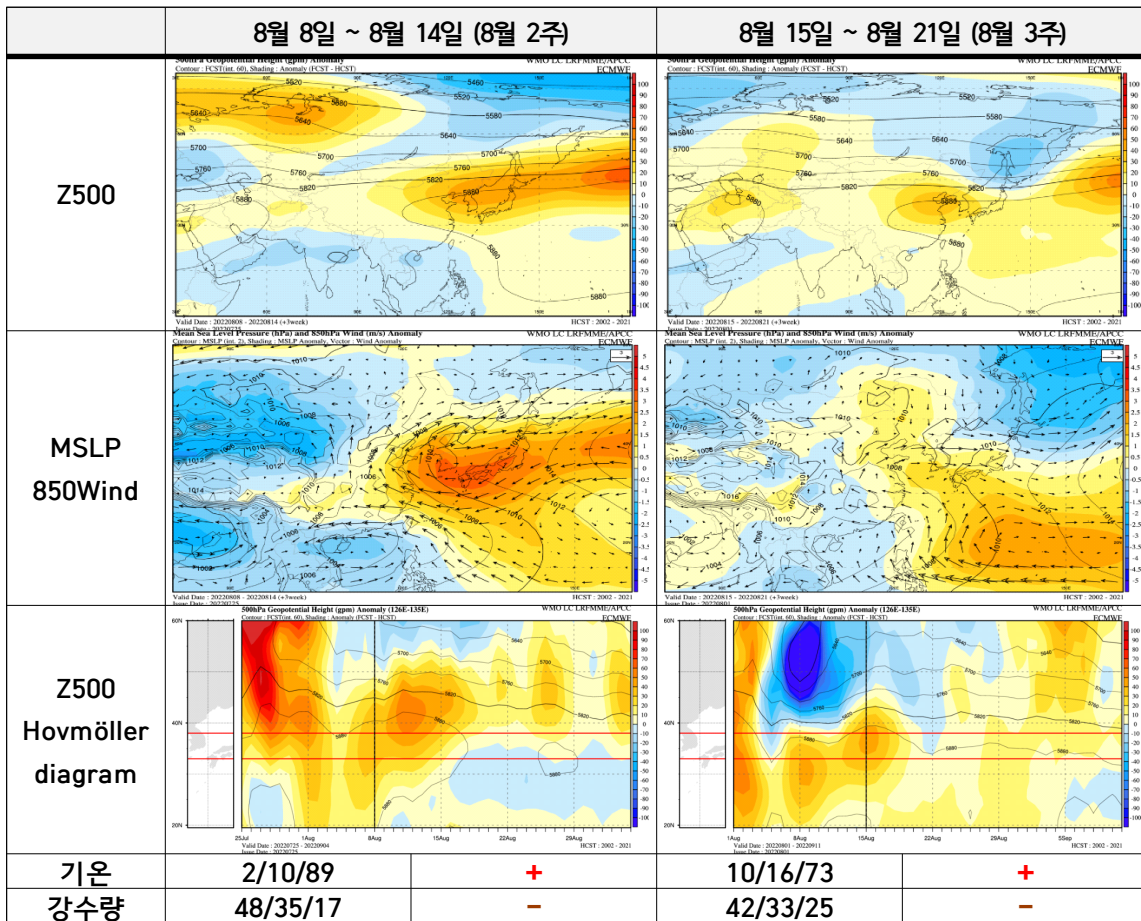
- 2주 : Z500은 북인도양-남중국해 부근 음의 편차, 티벳부근 양의 편차, 만주부근 음의 편차, 캄차카반도 부근 양의 편차로 과도 전과 패턴이 나타남. 하층의 경우 우리나라 남쪽으로 고기압성 흐름, 북쪽 저기압성 흐름 경계에서 남서풍 우세함. 우리나라는 5,880gpm과 5,820gpm 지위고도선 사이에 위치하면서 중부지방 중심으로 정체전선 형성되어 집중호우가 발생하여 일시적인 기온 하강 나타남.

* BSISO 대류활동의 경우 BSISO1 모드는 위상 5(주평균 강도 1.0), BSISO2

모드는 위상 6~7(주평균 강도 1.3)으로 벵골만-필리핀해 부근에 위치함.

- 3주 : 우랄 지역과 캄차카반도 부근 상층 고기압성 순환이 지속되고 두 기압능 사이에서 바이칼호 부근에 중심을 둔 저기압성 순환이 우리나라까지 확장하면서 더 강화되는 패턴임. 하층에서도 북쪽의 강한 음의 편차역이 남하하면서 정체전선 역시 남하함에 따라 중남부지역을 중심으로 많은 양의 강수 및 기온 하강 발생. 전국 평균 기온 및 강수량은 평년비슷 수준임.

□ ECMWF 대기 순환장 및 기온/강수 3주 전 예측 결과

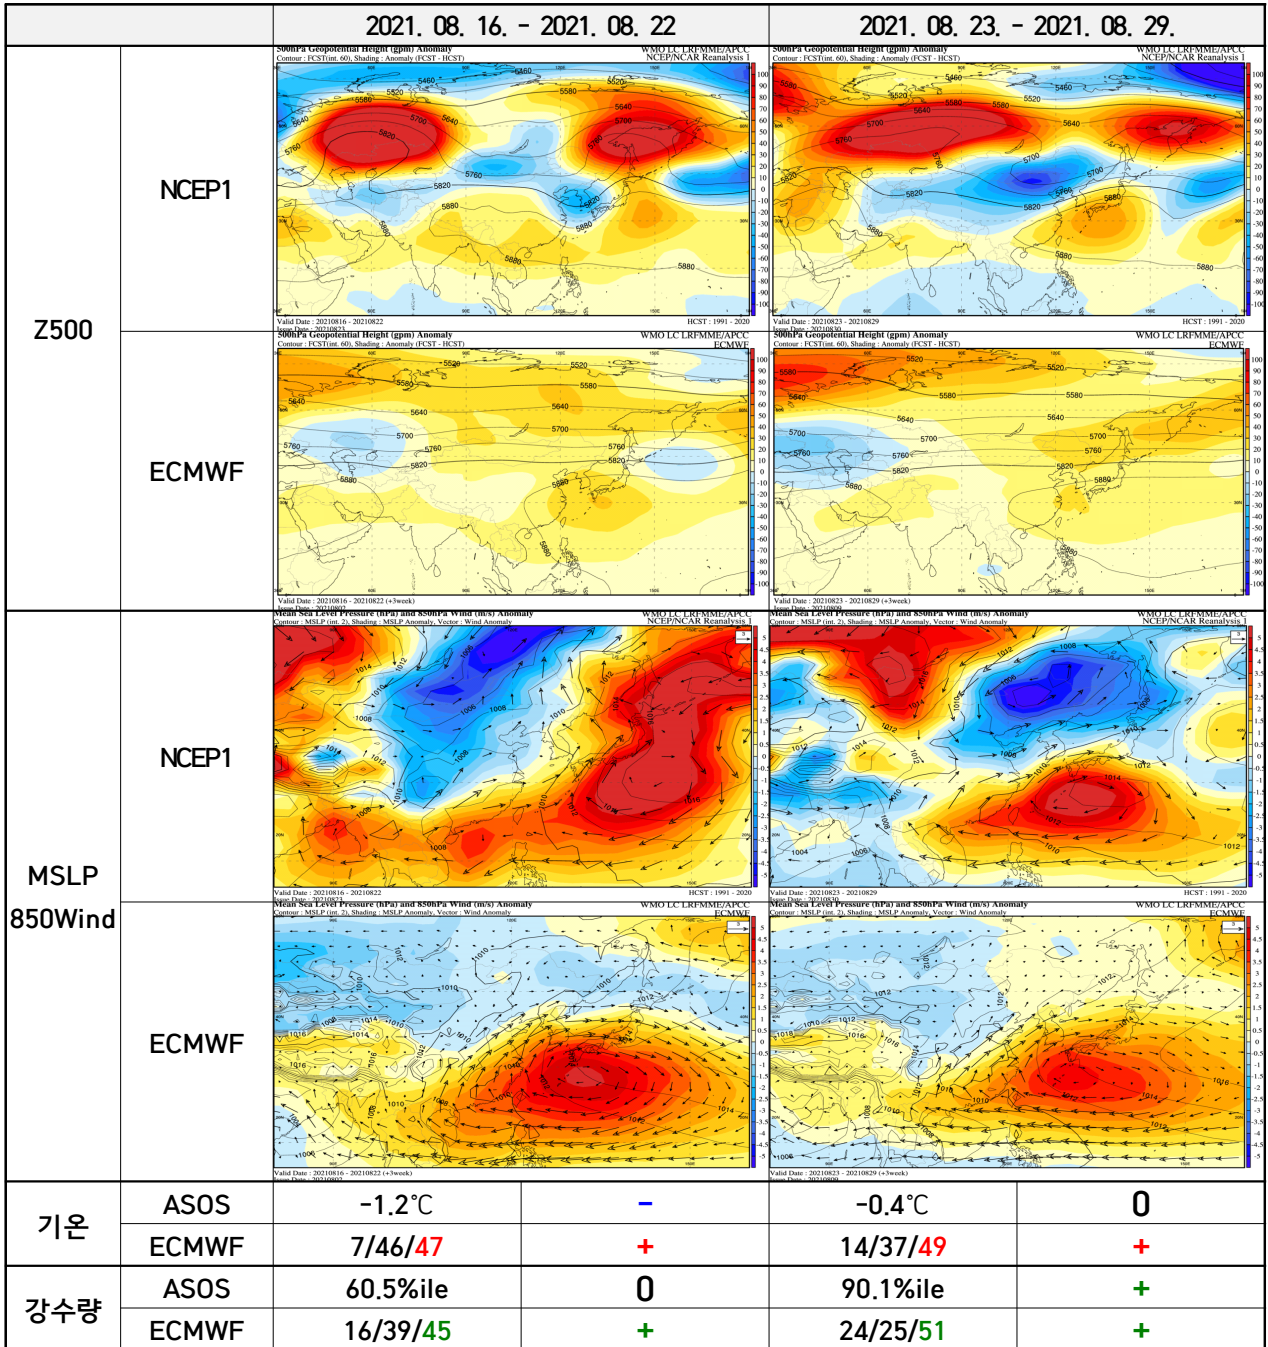


○ Z500/MSLP 변수 모두 우리나라 부근으로 양의 편차로 예측하며, 관측과 다른 고온/건조한 경향으로 예측함.

- 2주 : 우리나라 북쪽으로 발달하는 상층 골을 전혀 예측하지 못하였고 북태평양고기압이 확장하여 강한 고압대 영향을 받을 것으로 예측함. BSISO 대류 활동도 필리핀해 부근에서 발달하면서 한반도에 고기압성 순환 강화에 기여할 것으로 예측함.
- 3주 : 상하층 모두 저기압성 순환의 중심이 우리나라의 북동쪽인 오호츠크해에 위치하고 우리나라는 일본 남쪽 해상에 중심을 둔 고기압성 순환 영향을 받을

것으로 예측함.

□ **과거 사례** [2021. 8. 16. ~ 8. 29.]



- 8월 우랄 지역과 동시베리아 부근으로 상층 기압능이 강화 및 정체되면서 우리나라 북쪽으로 저기압성 순환이 발달하고, 남쪽으로는 북태평양고기압 확장에 따른 고기압성 순환이 발달하는 패턴
(관측) 우리나라 북쪽에서 유입되는 찬 공기와 남쪽에서부터 들어오는 따뜻하고 습한 공기가 만나 형성된 정체전선에 의해 중남부 지역에 많은 양의 강수를 기록함.

(3주 전 예측) 우리나라 북쪽의 상층 골을 모의하지 못하고 상하층 모두 양의 지위 고도 편차 영향을 받을 것으로 예측함. 하층의 경우 우리나라 남쪽에 강한 고기압성 순환이 위치하면서 남서풍이 지배적임에 따라 고온/다습 경향으로 예측함.

□ 토의 사항

- 장마 종료 이후 8월에 다시 형성되는 정체전선에 의해 중부지방 중심으로 집중호우가 발생했고 예측에 실패한 사례임.
- 우랄 지역과 캄차카반도 부근으로 기압능이 발달하면서 블로킹으로 작용해 동서흐름이 느려짐에 따라 우리나라 북쪽으로부터의 한랭건조 공기 유입이 지속되는 한편 남쪽의 북태평양고기압 영향으로 온난습윤한 공기 유입도 지속되면서 정체전선이 형성된 것으로 사료됨.
- 3주 전 ECMWF 모델에서 북쪽에서 유입되는 한기 영향보다 남쪽의 북태평양고기압 세력이 강화/확장되는 것으로 예측하여 강수 가능성을 전혀 고려하지 않음.
- AO/NAO 지수의 경우 중립, BSISO 대류 활동에 의한 대기반응도 관측과 반대의 기압 패턴을 모의하면서 예측이 빗나감.
- 8월에는 ECMWF의 계절내 예측자료 분석 시 북서태평양고기압 과대 모의 가능성과 한반도 북쪽 상층골 발달에 대한 예측성이 낮음을 고려해야 함.