

이상기후 대응을 위한 계절예측의 실효성 향상

**Enhancing the effectiveness of MME seasonal
forecasts for responding to extreme climate**

**유진호, 한정민, 손수진, 김유진,
임슬희, 정유림, 임아영, 박경민**

기후사업본부 예측운영과

2025.12.

아시아·태평양경제협력체 기후센터

Executive Summary

This study aims to develop new predictive content to address extreme climate events, focusing on seasonal forecasts based on extremes and physical quantities, as well as linking the characteristics of monthly and daily precipitation. To produce seasonal prediction information, we first analyzed the distributional properties of observational and climate prediction datasets and examined climatological biases—mean, range, and shape—embedded in dynamical models and grand ensemble data. Various bias-correction methods were applied to align ensemble distributions with the physical distributions observed, thereby improving the match between raw climate prediction data and observations. Nevertheless, the predictability of seasonal forecasts based on extremes and physical quantities yielded somewhat divergent outcomes. To integrate monthly and daily precipitation characteristics, correlations between monthly accumulated precipitation and both precipitation frequency and intensity were investigated. Regional differences were identified, with precipitation intensity generally showing a stronger influence on monthly precipitation variability than frequency. We further assessed the significance of the difference between the two correlations to identify regions with a high potential for extreme precipitation, and interpreted these area and seasons based on their characteristics precipitation regimes. These findings highlight the importance of bias correction and multi-scale precipitation analysis in enhancing the reliability of seasonal climate predictions, particularly under extreme climate conditions.

APEC (Asia-Pacific Economic Cooperation) Climate Center has been conducting comprehensive analyses of climate forecast models across a wide range of aspects. Analysis of various climate modes that represent seasonal scale climate variability can serve as an essential component for understanding climate prediction models, and they can also be used to interpret the sources of seasonal predictability and the physical processes linking remote teleconnections to regional climate variability. In this study, we evaluate the predictability of major oceanic and atmospheric climate modes simulated by APCC MME and investigate their characteristics. By doing so, we aim to derive approaches for interpreting model forecast information and ultimately enhance the usability of seasonal predictions. Additionally, we analyze the most recent hindcast period to better account for contemporary climate change, as well as the real-time forecast period available since 2012 to evaluate the model's performance under operational forecasting conditions.

The oceanic climate mode was selected in the tropical Pacific, North Atlantic, and Indian ocean. For the tropical Pacific climate mode, we analyzed predictability by month and lead time using various ENSO indices. The prediction skill with respect to ENSO phase, spatial structure, and event evolution was also examined. For the North Atlantic, we analyzed the monthly and lead-time-dependent prediction skills of sea surface temperatures in the mid-

and high-latitude regions, where the strong variability area in the SST tripole pattern, and assessed model biases in the climatological mean SST field. For the Indian Ocean, monthly and each lead-month correlations were analyzed to quantify the forecast skill of both the time-series evolution and spatial patterns of the IOD and IOB. For the atmospheric climate modes, we evaluated the prediction skills of the AO, NAO, NP, PNA, WP, and SOI indices, and analyzed their teleconnection responses to temperature and precipitation, as well as their relationships with ENSO. Based on these results, the MME seasonal prediction information is interpreted to identify factors that can influence temperature and precipitation over Korea, and the findings are applied to support seasonal prediction operations at KMA.

The APCC seasonal forecast is produced based on a Multi-Model Ensemble (MME) approach, utilizing data contributed by the world's climate leading climate forecasting operational and research institutes. This year, key system upgrades were implemented, including expansion of participating models, extension of the hindcast climatology period, and provision of high-resolution verification data. Collaborative improvements and the addition of new models have strengthened prediction reliability, while enhanced data quality management was achieved through error identification and feedback sharing among participating institutions. As a result, noticeable improvements were observed in global temperature and precipitation hindcast skill, and the applicability of a new ENSO index accounting for climate change effects was explored. Additionally, automation of the APCC three-month outlook system improved operational efficiency and established a foundation for high-resolution climate prediction for Korea. These advancements and strengthened cooperation are expected to enhance the reliability of seasonal prediction and support effective international collaboration.

The Boreal Summer Intraseasonal Oscillation (BSISO), which originates over the equatorial Indian Ocean and propagates northeastward, is a key source of subseasonal variability affecting the Asian summer monsoon, convection, and large-scale atmospheric circulation. APCC provides real-time BSISO monitoring, prediction, and verification information each year from May to October. The operational system is run daily based on outgoing longwave radiation (OLR) and 850hPa wind fields, following procedures of data collection, quality control, monitoring and prediction production, and real-time system monitoring. Using five participating prediction models, the system produces and delivers various BSISO products, including phase diagram, time-series, reconstruction field, and impact anomaly. In 2025, APCC established its own BSISO input-data processing system, enabling direct use of ECMWF model forecasts within the BSISO operational framework. This improvement ensures the continued provision of ECMWF-based BSISO information to the Korea Meteorological Administration's (KMA) monthly forecast briefing. Furthermore, in preparation for the future operationalization of APCC's MME subseasonal prediction system, a framework was developed to utilize APCC's raw prediction data as BSISO input fields once available, thereby strengthening both the potential for expanding participating models and the autonomous production and

application of BSISO prediction information.

APCC's in-house prediction model, SCoPS (Seamless Coupled Prediction System), is an atmosphere-ocean-sea ice coupled model with a horizontal resolution of approximately 80km and has been used as a participating model in the APCC MME seasonal prediction system since November 2017. Each month, SCoPS generates initial conditions using NCEP CFSR and Argo observations, applies atmospheric and oceanic initialization, and produces 6 months seasonal forecasts. The resulting forecasts undergo post-processing and verification and are used both for the internal forecast briefing and as a participating model in the APCC MME seasonal prediction system. In 2025, the APCC MME hindcast period was updated from 1991-2010 to 1993-2016, and this new hindcast period was applied to the verification and forecast information produced for the SCoPS forecast briefing.

Since 2006, the WMO Lead Centre has served as a one-stop shop by collecting and standardizing seasonal prediction data produced by Global Producing Centres (GPCs), applying various ensemble techniques, and providing seasonal prediction information. Forecast data are generated around the 15th of each month and made available through the WMO and the Korea Meteorological Administration websites. Currently, 15 institutions participate as GPCs, producing multi-model ensemble seasonal prediction information for nine variables using both deterministic and probabilistic methods. Whenever individual GPC models are upgraded, the standards processed by the WMO Lead Centre may change, requiring continuous data verification and program improvements. In 2025, four institutions upgraded their models, and the Lead Centre modified its programs to ensure stable service.

The Fire and Haze Early Warning system provides forecast information to Indonesia and Malaysia by calculating probabilistic risk levels based on regional rainfall predictions. Statistical downscaling and bias correction techniques are applied to tailor the forecast data to local conditions, with risks classified into four levels and visualized in map format. While previous methods provided risk information by region, the new high-resolution forecasts generate grid-based risk assessments. After a trial operation period, the high-resolution service will be officially launched, with errors identified during testing corrected to deliver regionally optimized, stable, and highly useful climate services.

Seasonal prediction information from the WMO Lead Centre is also used in regional climate forums to present outlooks. In 2025, the Lead Centre participated in ASEANCOF, organized by ASMC, and SASCOF, organized by the India Meteorological Department, to discuss climate services for Southeast Asia and South Asia. Furthermore, suggestions were made to expand the use of seasonal prediction information across diverse sectors such as agriculture, water resources, health, and disaster management.

국문 요약

이 연구에서는 이상기후에 대응하기 위한 새로운 예측 콘텐츠를 개발하고자 하며, 목표로 하는 신규 콘텐츠는 이상치(Extreme) 및 물리량 기준의 계절예측 정보, 월강수와 일강수의 특성을 연계한 자료이다. 이상치(Extreme) 및 물리량 기준의 계절예측 정보 생산을 위해서, 관측 및 기후예측자료의 자료 분포 특성을 먼저 분석하고, 관측과의 자료 분포 차이를 만드는 역학 모델 및 그랜드 앙상블 자료에 내재된 기후학적 바이어스(평균, 범위, 형태)를 살펴보았다. 또한, 서로 다른 바이어스를 가진 다량의 앙상블 자료의 분포를 관측의 물리량 분포에 적합하게 만들기 위해서 다양한 보정 방법을 적용하였다. 다양한 보정은 원시 기후예측자료의 기후학적 분포를 관측과 유사하게 매칭하였다. 그러나, 이상치(Extreme) 및 물리량 기준의 계절예측의 예측성능에 있어서는 다소 상이한 결과를 도출하였다. 월강수와 일강수의 특성을 연계하기 위해서, 월 총강수량에 대한 강수일수와 강수강도에 대한 각각의 상관관계를 분석하였다. 지역에 따라 서로 다른 상관관계를 보였으나, 전반적으로 강수일수보다 강수강도가 총강수량 변동을 더 크게 지배하는 경향을 확인하였다. 또한 두 상관계수의 차이에 대한 유의성을 평가하여 극한강수 발생 가능지역을 도출하였으며, 이를 해당 지역과 시기의 강수 특성을 바탕으로 해석하였다.

아태(아시아-태평양 경제협력체, APEC) 기후센터(APEC Climate Center, APCC)는 기후예측 모델에 대한 분석을 여러 방면에서 수행 해오고 있다. 그중 계절규모에서 기후변동성을 나타내는 여러 기후모드에 대한 분석은 기후예측모델을 이해하는 한 축으로 적용할 수 있고 계절규모 예측성의 소스와 원격상관에 의한 지역기후의 물리적 과정을 이해하는데 활용할 수 있다. 이 연구에서는 APCC 다중모델앙상블(Multi-Model Ensemble, MME)에서 모의되는 해양과 대기의 주요 기후모드의 예측성을 진단하고 특성을 이해하였다. 그리고 이를 통해 모델 예측정보의 해석 방안을 도출해 계절 예측의 활용성을 높이고자 하였다. 또한 최근 기후변화를 반영하기 위해 가장 최신의 Hindcast 기간을 분석하였고, 2012년 이후 실제 예측인 실시간 예측(Real-time forecast)기간에 대해 분석하였다. 해양 기후모드 중 태평양의 주요한 기후모드인 ENSO는 다양한 Nino 지수들의 월별 선행 시간별, 위상별 예측 스킬과, ENSO의 공간 분포, 이벤트의 진화 과정을 분석하였다. 북대서양은 해수면온도 삼극자 패턴에서 강한 변동성을 보인 중위도와 고위도 지역에 대한 해수면온도의 월별 선행 시간별 예측 스킬과 북대서양 해수면온도 평균장의 모델 오차를 분석하였다. 인도양은 IOD (Indian Ocean Dipole mode), IOB (Indian Ocean Basin mode)의 시계열과 공간 패턴의 상관관계를 분석하여 월별, 선행 시간별 예측 스킬을 산출하였다. 대기모드는 AO, NAO, NP, PNA, WP, SOI 지수에 대한 예측 스킬을 분석하고 대기 모드와 기온 강수에 대한 원격상관 반응, ENSO와의 관계에 대해 분석하였다. 이를 바탕으로 MME 계절예측정보를 해석하여 우리나라 기온, 강수에 영향을 줄 수 있는 요소를 판별하여 기상청 계절예측 지원에 활용하였다.

APCC 계절예측은 전 세계 여러 국가의 기상청 및 연구 기관으로부터 수집한 앙상블 예측 자료를 기반으로 다중모델앙상블(MME) 기법을 적용하여 예측 정보를 생산하고 있으며, 감시 및 검증 결과와 함께 정기적으로 제공하고 있다. 금년에 MME 계절예측시스템의 성능 향상을

위해 참여모델의 확대, 과거기후예측 기간의 확장, 고해상도 검증정보 제공 등 주요 개선이 이루어졌다. 아울러 원시자료의 오류를 선제적으로 식별하여 참여기관과 공유함으로써 국제 협력 플랫폼으로서의 역할을 강화하고 예측자료 품질관리 기능을 적극 수행하였다. 개선 결과, 전지구 기온 및 강수의 과거기후예측에서 전반적인 성능 향상 추세가 확인되었다. 또한, 기후변화 영향을 반영한 새로운 ENSO 지수 예측정보의 필요성을 분석하여 도입 타당성을 확보하였다. 더불어 APCC 3개월 전망 생산시스템 자동화를 통해 현업 운영 효율을 크게 높였고, 고해상도 예측자료 기반의 국내 예측정보 생산 체계를 마련하였다. 이와 같은 일련의 시스템 개선과 협력 강화는 향후 계절예측의 신뢰도 제고와 국제 공동활동의 효율적 운영에 기여할 것으로 기대된다.

여름철 계절내 진동(BSISO)은 적도 인도양에서 발생해 북동진하며 아시아 지역의 여름 몬순과 대류 및 대기 순환에 영향을 주는 주요 변동성으로 APCC는 매년 5-10월 동안 BSISO 감시, 예측, 검증 정보를 실시간으로 제공하고 있다. 현업시스템은 일별 OLR과 850hPa 바람장을 기반으로 자료 수집, 품질확인, 감시·예측 정보 생산, 현업 모니터링의 절차에 따라 매일 운영되고 있으며 총 5개의 참여 예측모델을 활용하여 BSISO 지수, 위상도, 재구성장, 영향장 등 다양한 정보를 생산·서비스하고 있다. 2025년에는 BSISO 입력자료 처리시스템을 자체 구축하여 ECMWF 모델 예측장을 APCC BSISO 현업에 직접 활용할 수 있는 기반을 마련하였고, 이를 바탕으로 ECMWF BSISO 정보는 기상청의 1개월 예보 회의에 제공되고 있다. 아울러 APCC MME 계절내예측의 현업화에 대비하여 원시 예측자료 확보 시 자체 예측자료를 BSISO 입력자료로 활용할 수 있는 체계를 마련함으로써 BSISO 참여모델 확대 가능성과 예측 정보의 자립적 생산·활용 기반을 강화하였다.

APCC 자체예측모델인 SCoPS (Seamless Coupled Prediction System)는 약 80km 해상도의 대기-해양-해빙 결합모델로, 2017년 11월부터 APCC MME 계절예측의 참여모델로 활용되고 있다. SCoPS는 매월 NCEP CFSR 및 Argo 자료를 이용해 초기장을 생성하고 대기-해양 초기화를 거쳐 6개월 계절예측자료를 생산한다. 생산된 예측자료는 후처리와 검증을 통해 내부 예보토의 자료로 활용되며 매월 APCC MME 참여모델로 제공된다. 2025년에는 APCC MME hindcast 기간이 1991-2010년에서 1993-2016년으로 변경됨에 따라, SCoPS 예보토의 검증 및 예측정보에도 새로운 hindcast 기간이 적용되었다.

WMO 선도센터는 2006년부터 각국 GPC에서 생산하는 계절예측 자료를 수집·표준화하고, 다양한 앙상블 기법을 적용해 계절 예측 정보를 생산·제공하는 one-stop shop 임무를 수행하였다. 매월 15일쯤 예측자료를 생산해 WMO와 한국 기상청의 홈페이지를 통해 정보가 제공되고 있다. 현재 15개의 기관이 GPC로 참여하고 있으며 9개의 변수에 대해 결정론적 기법과 확률론적 기법을 적용한 다중모델 앙상블 계절 예측 정보를 생산하고 있다. 각 GPC의 모델이 업그레이드될 때마다 WMO 선도센터에서 처리하는 표준이 달라질 수 있어 지속적인 자료검증과 프로그램 개선이 필요하다. 25년도에는 4개의 기관에서 개별모델 업그레이드가 진행되었고 안정적인 서비스를 위해 WMO 선도센터의 프로그램을 수정하여 처리하였다.

산불 예측 체계는 지역별 강수량 예측을 바탕으로 확률적 위험 등급을 산출해 인도네시아와 말레이시아에 예측 정보를 제공하고 있다. 통계적 다운스케일링과 편향 보정 기법을 활용해

예측자료를 지역 맞춤형으로 변환하고, 위험을 네 단계로 구분해 지도 형태로 시각화한다. 기존의 정보 제공 방법은 지역을 기준으로 위험 정도를 제공하였으나, 고해상도 예측 정보는 격자 기반의 예측 위험도를 산출하였다. 고해상도 예측 정보는 시범 운영 기간을 거쳐 정식 서비스할 예정으로 시범 운영 과정에서 발견되는 오류를 수정하여 지역 최적화된 형태로 서비스함으로써 안정적이고 활용성이 높은 기후 서비스를 제공할 계획이다.

WMO 선도센터의 계절 예측 정보를 활용하여 계절 예측 지역 기후 포럼에 참석하여 전망 발표를 진행하고 있다. 2025년에는 ASMC에서 운영하는 ASEANCOF와 인도 기상청에서 운영하는 SASCOF에 참석하여 동남아시아 지역과 남아시아 지역의 기후 서비스에 논의하였다. 또한 계절 예측 정보를 활용하는 농업, 수자원, 보건, 재해 관리 등 다양한 분야에 널리 활용될 수 있도록 의견을 제시하였다.

목차

Executive Summary	i
국문 요약	iv
목차	vii
표 차례	x
그림 차례	xi
1. 서론	1
2. 이상기후 대응 예측 콘텐츠 개발	3
2.1. 기후분포 분석 및 이상기후 대응 확률예측 검증	3
2.1.1. 연구방법	3
2.1.2. 자료 분포 및 보정	5
2.1.3. 5분위 확률 예측 및 검증	14
2.1.4. 물리적 임계 초과 확률 예측 및 검증	24
2.2. 이상기후 대응을 위한 월 총 강수 및 월간 일 강수일수, 강수강도와의 관련성 분석	28
2.2.1. 배경 및 목적	28
2.2.2. 자료 및 방법	28
2.2.3. 결과	29
2.2.4. 요약 및 결론	34
3. 계절예측 MME의 주요 기후모드 진단	35
3.1. 기후모드 연구 배경 및 목적	35
3.2. 자료 및 분석 방법	36
3.3. 열대 태평양 기후모드	38
3.3.1. 열대 태평양 기후모드 선정	38
3.3.2. Hindcast 기간 열대 태평양 기후모드 예측성 평가	38
3.3.3. 실시간 예측 기간 열대 태평양 기후모드 예측성 평가	51
3.4. 북대서양 기후모드	60
3.4.1. 북대서양 기후모드 선정	60
3.4.2. 북대서양 기후모드 예측성 평가	63
3.5. 인도양 기후모드	68
3.5.1. 인도양 기후모드 선정	68
3.5.2. Hindcast 기간 인도양 기후모드 진단 및 예측성 평가	73
3.5.3. 실시간 예측기간 인도양 기후모드 예측성 평가	88
3.6. 대기 기후모드	99
3.6.1. 대기 기후모드 선정	99
3.6.2. 대기 기후모드 예측성 평가	100
4. MME 운영 및 개선	109
4.1. MME 예측 및 검증	109
4.1.1. 배경 및 목적	109

4.1.2 자료 및 방법	109
4.1.3. 결과	114
4.2. 기후감시시스템	148
4.3. 기후전망(Climate Outlook) 생산 자동화	150
4.3.1. 서론	150
4.3.2. 기존 Outlook 분석 및 자동화 설계 방향	151
4.3.3. 지역 추출 및 masking	154
4.3.4. 확률 예측 신호 검출 및 텍스트 생성 알고리즘	158
4.3.5. 해수면온도 신호 추출 및 해석 알고리즘	162
4.3.6. 과거예측 skill (HSS) 신호 추출 및 지역 판정	165
4.3.7. 언어모델 기반 Outlook 자동화 체계 구축	167
4.3.8. LaTeX 기반 Outlook 문서 자동 생성 체계 구축	171
4.3.9. 통합 자동화 파이프라인 구축	172
4.3.10. 요약 및 의의	174
4.4. ENSO 경보시스템 개선	176
4.4.1. 배경 및 목적	176
4.4.2. 자료 및 방법	176
4.4.4. 요약 및 결론	181
5. BSISO 계절내예측시스템 운영 및 개선	182
5.1. BSISO 계절내예측시스템 운영	182
5.1.1. 배경 및 목적	182
5.1.2. 자료 및 방법	182
5.1.3. 결과	184
5.2. BSISO 계절내예측시스템 개선 (BSISO 참여모델 활용을 위한 전처리 체계 구축)	188
5.2.1. 배경 및 목적	188
5.2.2. 자료 및 방법	189
6. APCC 자체예측모델(SCoPS) 운영 및 예측정보 제공	194
6.1. 배경 및 목적	194
6.2. 자료 및 방법	194
6.3. 결과	194
7. 국내외 협력 및 지원	198
7.1. 기상청 3개월 전망 지원	198
7.2. WMO 계절예측 선도센터 운영 및 개선	204
7.2.1. 개요	204
7.3. 산불 예측 시스템 운영	211
7.3.1. 산불 예측 시스템 운영 및 예측 정보 제공	211
7.3.2. 고해상도 산불 예측 시스템 시범 운영	214
7.4. 지역기후포럼(Regional Climate Outlook Forum) 참석	216
7.4.1. 동남아시아 기후 전망 포럼(ASEANCOF 24, 25)	216
7.4.2. 남아시아 기후 전망 포럼(SASCOF)	217

8. 요약 및 결론..... 218
Acknowledgement..... 222
References..... 223

표 차례

<표 차례>

Table 2.1. Experimental designs of various bias corrections.	4
Table 3.1. List of participating models and their hindcast periods.	36
Table 3.2. List of participating institutes and their available year for real-time forecast.	37
Table 3.3. List and current status of atmospheric index.	99
Table 4.1. Description of participating models in APCC MME.	110
Table 4.2. Description of CAMS-OPI dataset.	111
Table 4.3. Description of NOAA OISST dataset.	111
Table 4.4. Description of NCEP/DOE Reanalysis 2 dataset.	112
Table 4.5. Description of ERA5 dataset.	112
Table 4.6. Summary of verification metrics for real-time forecast.	113
Table 4.7. Summary of verification metrics for hindcast.	114
Table 4.8. Summary of the existing and improved CWA models.	119
Table 4.9. Summary of the existing and improved CMCC models.	124
Table 4.10. Summary of the existing and improved METFR models.	129
Table 4.11. Contents of CMS and related services.	148
Table 4.12. List of 66 Regions frequently appeared in the APCC Climate Outlook and WMO GSCU.	155
Table 4.13. List of 17 subregions in the Pacific.	157
Table 4.14. Comparison of the ENSO Alert system criteria before and after the revision.	177
Table 5.1. Participant model description of APCC BSISO forecast system.	183
Table 5.2. Differences in the BSISO input data pre-processing system before(previous) and after(current) implementation.	193
Table 7.1. Description of WMO-LC Seasonal Prediction models.	210

그림 차례

Figure 2.1. Probability distributions (left panels, units: %) and medians (right panels) of (a, b) April mean temperature at 2m (units: oC) and (c, d) precipitation (units: mm/day) of K region in (a, c) extra tropics and (b, d) tropics for the period 1993–2016, based on observations (in purple lines) and predictive datasets from yBias (in green lines).…………… 6

Figure 2.2. Probability distributions (left panels, units: %) and medians (right panels) of (a, b) April mean temperature at 2m (units: oC) and (c, d) precipitation (units: mm/day) of K region in (a, c) extra tropics and (b, d) tropics for the period 1993–2016, based on observations (in purple lines) and predictive datasets from yBias (in green lines), yUnb1, yUnb2, yUnb3, and yUnb4 (in respective dark to light blue lines). The absolute differences of medians between observations and prediction datasets are given in the upper left of each right panels.…………… 7

Figure 2.3. Probability distributions (left panel), displacement (middle panel) and inter-range (right panel) of monthly mean temperature at 2m (units: oC) in extra tropics for the period 1993–2016, based on observations (in purple lines) and predictive datasets from yBias (in green lines), yUnb1, yUnb2, yUnb3, and yUnb4 (in respective dark to light blue lines).…………… 9

Figure 2.4. Same as Figure 2.3, but in tropics.…………… 10

Figure 2.5. Same as Figure 2.3, but for precipitation (units: mm/day).…………… 11

Figure 2.6. Same as Figure 2.3, but for precipitation (units: mm/day). …………… 12

Figure 2.7. Time series of the 1-month lead April mean temperature at 2m (units: oC) of K region in tropics for the period 1993–2016, based on observations and predictive datasets from (a) yBias, (b) yUnb1, (c) yUnb2, (d) yUnb3, and (e) yUnb4. The ensemble spread predicted is depicted by the box-and-whisker representation with the whiskers containing the lower and upper quintile of the ensemble. The blue and red dots (horizontal lines) represent the ensemble mean and observations (extreme quintiles, lower 20 and upper 20%), respectively. The overall RPSS skill of categorical probability forecast taken from ensemble spread is given in the upper left of each panel, with respect to the climatology defined by the reference forecast of the category 20–60–20%.…………… 13

Figure 2.8. (a) Temporal–spatial averaged RPSS skills of categorical probabilistic forecasts of monthly mean temperature at 2m (left panel) and precipitation (right) for the period 1993–2016. (b) Annual-averaged RPSS skills (left column), and RPSS skills as function of forecast target time and predictive dataset (right columns) of monthly mean temperature at 2m (upper panels) and precipitation (bottom) in extra tropics and tropics.…………… 15

Figure 2.9. RPSS skills as function of forecast location and predictive dataset of monthly mean temperature at 2m in extra tropics for the whole period 1993–2016 (upper panel), and actually occurred lower and upper 20 events (middle and bottom panels, respectively).…………… 16

Figure 2.10. Same as Figure 2.9, but in tropics.…………… 16

Figure 2.11. Same as Figure 2.9, but for precipitation.…………… 17

Figure 2.12. Same as Figure 2.10, but for precipitation.…………… 17

Figure 2.13. Reliability (upper panels) and sharpness (lower panels) diagrams of extreme quintiles of monthly mean temperature at 2m in extra tropics.....	19
Figure 2.14. Same as Figure 2.13, but in tropics.....	19
Figure 2.15. Reliability (left panel) and resolution (right panel) diagrams of extreme quintiles of monthly mean temperature at 2m in extra tropics.....	19
Figure 2.16. Same as Figure 2.15, but in tropics.....	19
Figure 2.17. Same as Figure 2.13, but for precipitation.	22
Figure 2.18. Same as Figure 2.14, but for precipitation.....	22
Figure 2.19. Same as Figure 2.14, but for precipitation.....	22
Figure 2.20. Same as Figure 2.15, but for precipitation.....	22
Figure 2.21. ROC curves of extreme quintiles of monthly mean temperature at 2m in extra tropics.....	23
Figure 2.22. Same as Figure 2.21, but in tropics.....	23
Figure 2.23. Same as Figure 2.21, but for precipitation.	23
Figure 2.24. Same as Figure 2.22, but for precipitation.	23
Figure 2.25. Probabilities of exceedance (PoE, units: %) for alternative thresholds of (a, c) April mean temperature at 2m (units: oC) and (b, d) precipitation (units: mm/day) of K region in (a, b) extra tropics and (c, d) tropics for the year of 2016, based on observations (in most left panels) and predictive datasets from yBias, yUnb1, yUnb2, yUnb3, and yUnb4 (in the second and sixth panels from the left).....	25
Figure 2.26. Same as Figure 2.8, but POFD skills of PoE forecasts.....	26
Figure 2.27. Same as Figure 2.8, but CRPSS skills of PoE forecasts.....	27
Figure 2.28. Spatial distribution of the correlation between total monthly precipitation (A) and the number of rainy days (O) for each month during the period 1997–2024.....	29
Figure 2.29. Spatial distribution of the correlation between total monthly precipitation (A) and precipitation intensity (I) for each month during the period 1997–2024.	30
Figure 2.30. Spatial distribution of the correlation between the number of rainy days (O) and precipitation intensity (I) for each month during the period 1997–2024.	31
Figure 2.31. Spatial distribution of the difference between the correlation of total monthly precipitation with precipitation intensity and that with the number of rainy days, expressed as $r(A,I) - r(A,O)$, for each month during 1997–2024 (shading). Regions where the difference between the two correlations is statistically significant at 95% confidence level based on the Steiger' s Z-test are marked (hatching).	33
Figure 3.1. Differences of the SST annual cycle bias between Model and Observation, and the SST annual cycle of the observation(last panel) in the equatorial (5S–5N average) Pacific....	39
Figure 3.2. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, Nino4, and NinoW indexes between the model and observation for the hindcast lead-1 to lead-6. Gray bar is for MME and color dot-lines are for individual models.	40
Figure 3.3. Temporal correlation coefficients of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME and observation for the hindcast.	41

Figure 3.4. Temporal correlation coefficients of the monthly Nino3.4 index between the individual models and observation for the hindcast. 42

Figure 3.5. Root mean squared error (RMSE) of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes. 43

Figure 3.6. Standard deviation of the Nino4, Nino3.4, Nino1+2 indexes. Black and gray solid line indicates the observation and MME. Color dashed line indicates the individual model. 44

Figure 3.7. Composites of the December tropical (10S-10N average) SST anomalies with respect to the positive (left) and negative (right) phases. The white circle indicate the center of the anomalies. 45

Figure 3.8. Composites of the April tropical (10S-10N average) SST anomalies with respect to the positive (left) and negative (right) phases. The white circle indicate the center of the anomalies. 46

Figure 3.9. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME hindcast and observation with respect to the phases. 47

Figure 3.10. Temporal correlation coefficients of seasonally divided monthly Nino3.4 index between the MME hindcast and observation with respect to the phases. 47

Figure 3.11. Temporal correlation coefficients of seasonally divided monthly Nino3.4 index between the MME hindcast and observation with respect to the intensity. 48

Figure 3.12. Evolution of the Nino3.4 index (color solid line) and their composite (black dash line) for El Nino (left) and La Nina (right) events during hindcast period. Evolution starts from April of the event developing year to August of the next year. 49

Figure 3.13. Histogram of the ENSO event peak month from the Nino 3.4 index evolution for the hindcast period. 50

Figure 3.14. Data period of the MME and individual models for the SST real-time forecast. 51

Figure 3.15. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, Nino4, and NinoW indexes between the model and observation for the real-time forecast lead-1 to lead-6. Gray bar is for MME and color dot-lines are for individual models. 53

Figure 3.16. Same as figure 3.15 but for after 2020 year. 54

Figure 3.17. Temporal correlation coefficients of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME and observation for the real-time forecast. 55

Figure 3.18. Temporal correlation coefficients of the monthly Nino3.4 index between the individual models and observation for the real-time forecast. 56

Figure 3.19. Root mean squared error (RMSE) of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes for the real-time forecast. 57

Figure 3.20. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME real-time forecast and observation with respect to the phases. 58

Figure 3.21. Evolution of the Nino3.4 index (color solid line) and their composite (black dash line) for El Nino (left) and La Nina (right) events during real-time forecast period. Evolution starts from April of the event developing year to August of the next year. 59

Figure 3.22. The spatial pattern of the first EOF mode for the North Atlantic SST. 61

Figure 3.23. Time correlation coefficients between the monthly NASST1 and Korea (left) temperature and (right) precipitation. The red outline circle indicates statistically significant at 95% confidence level. 61

Figure 3.24. Regression of the monthly NASST1 and (shading) 500hPa and (contour) 200hPa geopotential height anomalies. The diagonal and dot indicate statistically significant at 95% confidence level for 500hPa and 200hPa height anomalies respectively. 62

Figure 3.25. Pattern correlation coefficients of the North Atlantic (80-0W, 10-70N) SST anomalies between the model and observation. Gray bar is for MME and color dot-lines are for individual models. Left is for hindcast and right is for real-time forecast. 63

Figure 3.26. Difference of the climatological annual cycle of the North Atlantic SST along the latitude between the model and observation, and the observational climatological annual cycle at lead-1. Left panels are averages of 70-45W, and right panels are average of 45-15W. 64

Figure 3.27. Temporal correlation coefficients of the NASST1(70-45W, 30-40N) and NASST2(50-20W, 50-60N) between the model and observation for the hindcast lead-1 and lead-3. Gray bar is for MME and color dot-lines are for individual models. 65

Figure 3.28. Temporal correlation coefficients of the NASST1(70-45W, 30-40N) and NASST2(50-20W, 50-60N) between the model and observation for the real-time forecast lead-1 and lead-3. Gray bar is for MME and color dot-lines are for individual models. 66

Figure 3.29. Temporal correlation coefficients between the NASST1 and Korea temperature for the lead-1 hindcast models and observation. 67

Figure 3.30. Spatial patterns of the first two EOF modes of SST over the Indian Ocean (20° S-20° N, 40° E-120° E) for the period 1993-2016 based on OISST observations. 68

Figure 3.31. PC time series of the first two EOF modes of SST over the Indian Ocean (20° S-20°N, 40°E-120°E) based on the OISST observations. 69

Figure 3.32. Spatial patterns of the first two EOF modes of SST over the Indian Ocean (20° S-20°N, 40°E-120°E) for the period 1993-2016 based on APCC SCM MME. 69

Figure 3.33. PC time series of the first two EOF modes of SST over the Indian Ocean (20° S-20° N, 40° E-120° E) based on the APCC SCM MME. 70

Figure 3.34. IOD time series based on OISST observations. Positive and negative IOD events are defined using a threshold of ± 0.5 , with the climatological period 1993-2016. 70

Figure 3.35. Composite SST anomaly patterns of IOD events based on the OISST observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993-2016. 71

Figure 3.36. IOB time series based on OISST observations. Positive and negative IOB events are defined using a threshold of ± 0.3 , with the climatological period 1993-2016. 72

Figure 3.37. Composite SST anomaly patterns of IOB events based on the OISST observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993-2016. 73

Figure 3.38. IOD time series based on APCC MME models with forecasts lead from 1 to 6

months. Positive and negative IOD events are defined using a threshold of ± 0.5 , with the climatological period 1993–2016. The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line. 74

Figure 3.39. Composite SST anomaly patterns of IOD events based on the SCM MME with forecast lead 1-month: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016. 75

Figure 3.40. Composite SST anomaly patterns of IOD events based on the SCM MME with forecast lead 6-months: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016. 76

Figure 3.41. Longitude-month evolution from June to following February of (upper) SST, (middle) SLP and 850-hPa winds, and (lower) precipitation and 200-hPa winds, composited for positive (left) and negative (right) IOD events from observations over the Indian Ocean. All fields are averaged over $10^{\circ}\text{S}-5^{\circ}\text{N}$ 77

Figure 3.42. Longitude-month evolution from June to following February of (upper) SST, (middle) SLP and 850-hPa winds, and (lower) precipitation and 200-hPa winds, composited for positive (left) and negative (right) IOD events from MME observations lead at 1 month over the Indian Ocean. All fields are averaged over $10^{\circ}\text{S}-5^{\circ}\text{N}$ 78

Figure 3.43. Monthly (top) temporal correlation coefficients (TCC) of the IOD time series, and anomaly pattern correlation coefficients (PCC) of SST anomalies over the Indian Ocean ($10^{\circ}\text{S}-5^{\circ}\text{N}$, $50^{\circ}\text{E}-100^{\circ}\text{E}$) for (middle) positive cases and (bottom) negative cases, between observations and MME forecasts with lead times from 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level. 79

Figure 3.44. IOB time series based on APCC MME models with forecasts lead from 1 to 6 months. Positive and negative IOB events are defined using a threshold of ± 0.3 , with the climatological period 1993–2016. The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line. 80

Figure 3.45. Composite SST anomaly patterns of IOB events based on the SCM MME with forecast lead 1-month: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016. 81

Figure 3.46. Composite precipitation anomaly patterns of IOB events based on the GPCP observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016. 82

Figure 3.47. Composite 850-hPa wind anomaly patterns of IOB events based on the NCEP1 observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016. 83

Figure 3.48. Month-Latitude evolution from September to the following August of (top) SST and (bottom) precipitation and 850-hPa winds, composited for (left) positive and (right) negative IOD events from observations over the Indian Ocean. All fields are averaged over $40^{\circ}\text{S}-100^{\circ}\text{E}$ 84

Figure 3.49. Month-Latitude evolution from September to the following August of (top) SST and (bottom) precipitation and 850-hPa winds, composited for (left) positive and (right) negative IOD events from SCM MME forecasts lead 1 month over the Indian Ocean. All fields are averaged over 40° -100° E. 85

Figure 3.50. Monthly (top) temporal correlation coefficients (TCC) of the IOB time series, and anomaly pattern correlation coefficients (PCC) of SST anomalies over the Indian Ocean (20° S-20° N, 40° E-100° E) for (middle) positive cases and (bottom) negative cases, between observations and MME forecasts with lead times from 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level. 86

Figure 3.51. Monthly lead-lag correlation coefficients between (cyan) IOD and ENSO, (orange) IOB and ENSO, and (purple) IOD and IOB for (a) observations and forecasts with lead times of (b) 1 month, (c) 3 months, and (d) 5 months during 1993-2016. 87

Figure 3.52. Participated individual models of SST MME for real-time forecast period. ECCC included MSC. 88

Figure 3.53. IOD time series based on APCC MME models with forecasts lead from 1 to 6 months for the real-time forecast period, 2013-2024. The climatological period for each year corresponds to the model hindcast period (e.g., the hindcast period for 2024 is 1991-2010). Positive and negative IOD events are defined using a threshold of ± 0.5 . The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line. 89

Figure 3.54. Monthly ranked correlation coefficients of the IOD time series between observations and MME forecasts with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level. 90

Figure 3.55. Monthly ranked correlation coefficients of the IOD time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) May, (b) July, (c) September, and (d) November. Filled markers with black edges indicate statistical significance at the 95% level. 91

Figure 3.56. Monthly mean error of the IOD time series between MME forecasts and observations (MME - OBS) with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. 92

Figure 3.57. Monthly mean error of the IOD time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) May, (b) July, (c) September, and (d) November. 93

Figure 3.58. IOB time series based on APCC MME models with forecasts lead from 1 to 6 months for the real-time forecast period, 2013-2024. The climatological period for each year corresponds to the model hindcast period (e.g., the hindcast period for 2024 is 1991-2010). Positive and negative IOB events are defined using a threshold of ± 0.3 . The SCM MME is

shown as thick magenta line, individual models are colored, and observations are shown as a thick black line. 94

Figure 3.59. Monthly ranked correlation coefficients of the IOB time series between observations and MME forecasts with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level. 95

Figure 3.60. Monthly ranked correlation coefficients of the IOB time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) January, (b) April, (c) July, and (d) October. Filled markers indicate statistical significance at the 95% level. 96

Figure 3.61. Monthly mean errors of the IOB time series between MME forecasts and observations (MME - OBS) with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. 97

Figure 3.62. Monthly mean errors of the IOB time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) January, (b) April, (c) July, and (d) October. 98

Figure 3.63. Monthly TCC for AO, NAO, NP, PNA, SOI, and WP indices by participant model. Dots indicate values significant at the 95% confidence level. 100

Figure 3.64. AO regressed patterns for SLP based on monthly observation and 1-month lead forecasts. 101

Figure 3.65. Same as figure 3.64, but for NAO regressed pattern for SLP. 102

Figure 3.66. Same as figure 3.64, but for NP regressed pattern for SLP. 103

Figure 3.67. Same as figure 3.64, but for PNA regressed pattern for 500hPa geopotential height. 103

Figure 3.68. Same as figure 3.64, but for WP regressed pattern for 500hPa geopotential height. 104

Figure 3.69. Same as figure 3.64, but for SOI regressed pattern for SLP. 104

Figure 3.70. Teleconnection correlations between each index and 2m temperature over the mid-latitude region for January. 105

Figure 3.71. Same as figure 3.70, but between each index and precipitation. 106

Figure 3.72. Temporal correlation coefficient (TCC) between NINO3.4 and the WP (left), PNA (center), and NP (right) indices. The values shown in the upper-right corner indicate the mean TCC values. 107

Figure 3.73. Equation for removing ENSO-related variability from 2m temperature using linear regression. 107

Figure 3.74. Comparison of 2m temperature tele-connection of WP index before (top) and after (bottom) the removal of the ENSO signal. 108

Figure 3.75. Same as figure 3.74, but for PNA index. 108

Figure 4.1. seasonal forecast operational system and schedule 115

Figure 4.2. Notice regarding the scheduled update of individual model prediction data.....	116
Figure 4.3. Three-year running mean of global hindcast ACC for temperature(left) and precipitation(right).	116
Figure 4.4. Global forecast ACC for temperature(top) and precipitation(bottom) (black and colored dots) compared with the observed Nino 3.4 index (blue line).....	117
Figure 4.5. Three-year running mean of global forecast ROC scores for temperature (top) and precipitation (bottom).	118
Figure 4.6. Current status and planned updates of participating models in the MME prediction system.	119
Figure 4.7. ACC of individual models (symbols), mean ACC of individual models (black line), and ACC of MME (bars) for global precipitation, SLP, SST, T2M, T850, and Z500.....	120
Figure 4.8. Differences in ACC between the improved and existing CWA Models by key region and season.	121
Figure 4.9. Global seasonal ROC scores of the existing (dotted line) and improved (solid line) CWA models.	121
Figure 4.10. Global ACC differences in MME between the existing and the improved CWA models across seasons and regions.	122
Figure 4.11. Global ROC score differences in MME between the existing and the improved CWA models across seasons.	123
Figure 4.12. (Left) Niño-3.4 TCC of MMEs with the improved (solid) and existing (dotted) CWA models. (Right) Percentage TCC differences (%).	123
Figure 4.13. Forecast anomaly maps of temperature (top) and sea surface temperature (bottom) from the existing model (a) and the improved model (b).	124
Figure 4.14. Global mean bias in SON for precipitation, SLP, SST, T2M, T850, and Z500 from the improved CMCC model.	125
Figure 4.15. Regional ACC in SON for precipitation, SLP, SST, T2M, T850, and Z500 from the improved CMCC model.	126
Figure 4.16. Global ROC in SON for precipitation, SLP, SST, T2M, T850, and Z500 from the improved CMCC model.	127
Figure 4.17. Regional TCC differences in SON between the existing and the improved CMCC models for precipitation, SLP, SST, T2M, T850, and Z500.	128
Figure 4.18. Same as Figure 4.17, but for ACC.	128
Figure 4.19. Same as Figure 4.14, but for the improved METFR model.	130
Figure 4.20. Same as Figure 4.15, but for the improved METFR model.	130
Figure 4.21. Same as Figure 4.16, but for the improved METFR model.	131
Figure 4.22. Same as Figure 4.17, but for the METFR models.	131
Figure 4.23. Same as Figure 4.18, but for the METFR models.	132
Figure 4.24. Directory structure of the MME Automated Forecast System for the extended hindcast period.	133
Figure 4.25. Hindcast availability period by MME participating models for forecasts of January,	

February, and March–December. White indicates missing data, and light green/yellow denote the common hindcast period. 134

Figure 4.26. Probabilistic ENSO forecasts (%) for 2025 SONDJF based on hindcast periods 1991–2010 (top) and 1993–2016 (bottom). 135

Figure 4.27. Differences in probability (%) of above-normal temperature (left) and below-normal temperature (right) in SON between hindcast periods 1991–2010 (top) and 1993–2016 (bottom). 136

Figure 4.28. Probabilistic forecasts (%) for temperature (left) and precipitation (right) in SON for hindcast periods 1991–2010 (top) and 1993–2016 (bottom). 137

Figure 4.29. Directory structure of the high-resolution verification system. 138

Figure 4.30. Regional ACC of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right). 139

Figure 4.31. Regional RMSE of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right). 139

Figure 4.32. Tropical SST indices for 2025 JJASON real-time forecasts (low-resolution: left, high-resolution: right). Red = MME, black = observations, orange dotted = individual models. 140

Figure 4.33. Global ROC curve of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right). 141

Figure 4.34. Regional RPSS of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right). 141

Figure 4.35. Regional ACC of precipitation (top) and T2M (bottom) for OND hindcasts: low-resolution (left) vs. high-resolution (right). 142

Figure 4.36. Global MSSS maps of precipitation (top) and T2M (bottom) for OND hindcasts: low-resolution (left) vs. high-resolution (right). 142

Figure 4.37. Same as Figure 4.41, but for ROC Score. 143

Figure 4.38. 20-year sliding standard deviation ratio and regression slope between SOI and NINO3.4. Yellow lines indicate periods when NINO3.4 is positive, and blue lines indicate periods when NINO3.4 is negative. 145

Figure 4.39. Observed Oceanic Niño Index (Dotted Line) and Relative ONI (Solid Line) from 2023 DJF to 2025 JAS. 145

Figure 4.40. September–October anomaly maps of SST (top), precipitation, and Z500 (bottom). Panels show La Niña conditions (left), 2024 observations (center), and 1-month lead forecasts (right). 146

Figure 4.41. Observed (gray) and forecast (green) Niño–3.4 index (dotted) and relative Niño–3.4 index (solid). 146

Figure 4.42. Hindcast relative Niño–3.4 index(bar) and Niño–3.4 index(solid-line) for the period 1992–2010. 147

Figure 4.43. Hovmöller diagrams of SST, OLR, U850 issued in Oct (upper) and Nov 2025 (bottom). 149

Figure 4.44. Boundaries of 343 subregions for global outlook.....	156
Figure 4.45. Boundaries of 17 subregions for the Pacific outlook.....	157
Figure 4.46. Process flow of forecast signal detection for the Pacific outlook.....	159
Figure 4.47. Example of forecast signals mapped over the subregion masks. Different colors correspond to different signals (category/strength).....	161
Figure 4.48. Example of 4 seasonal SST anomalies of interest for the outlook generation....	163
Figure 4.49. Process flow of SST anomaly signal detection	164
Figure 4.50. Example of HSS distribution of different category mapped over the subregion masks.....	167
Figure 4.51. Example of LLM prompt for ENSO probability forecast. Prompt consists of header and signals (after “Results:”).....	170
Figure 4.52. Description of ENSO probability forecast generated by LLM.....	170
Figure 4.53. Process flow of integrated outlook generation script (build_outlook_script.sh)....	173
Figure 4.54. (Top) ENSO alert from other institutions and APCC before(APCC) and after revision (APCC_NEW), (Middle) NINO3.4, and (Bottom) SOI index. (Period: 2014.01.~2024.12.)	180
Figure 4.55. ENSO alerts, NINO3.4 and SOI index from other institutions and APCC as displayed in the Pacific Regional Climate Centre ENSO Tracker (Top: before the revision of criteria, Bottom: after the revision, period: 2023.08~2025.07).	181
Figure 5.1. APCC BSISO operating system.	183
Figure 5.2. Example of BSISO composite map displayed on the website.	185
Figure 5.3. Contents of BSISO monitoring.	186
Figure 5.4. Contents of BSISO forecast.	187
Figure 5.5. Contents of BSISO verification.	188
Figure 5.6. Flow chart of producing the APCC BSISO operation system.	189
Figure 5.7. Data format of input data for APCC BSISO forecast system.	190
Figure 5.8. Diagram for pre-processing system for BSISO input data.	191
Figure 5.9. BSISO phase diagram and pentad mean OLR before (left) and after (right) construction for pre-processing of ECMWF input data.	193
Figure 6.1. APCC in-house model (SCoPS) operating system.	194
Figure 6.2. Verification of TCC and RMSE for the SON season by hindcast period (top: 1991~2010, bottom: 1993~2016).	195
Figure 6.3. Verification of TCC and RMSE for NINO3.4 during the SON season by hindcast period (top: 1991~2010, bottom: 1993~2016).	196
Figure 6.4. NINO3.4 index for the SON season by hindcast period (top: 1991~2010, bottom: 1993~2016).....	197
Figure 7.1. December cumulative precipitation (mm month ⁻¹) over south Korea since 1973 from station observations. Climatology period is 1991~2020, and the three categories are divided by ± 0.43 standard deviation. Blue dots indicate the below normal (BN) category, gray dots indicate the near normal (NN) Category, and red dots indicate the above normal (AN) category.	198

Figure 7.2. December composite patterns of anomalies of precipitation and 850-hPa horizontal wind anomalies for the AN, NN, and BN categories from observations (GPCP, NCEP2). The composite period is 2008–2024 and climatological period is 1991–2020. The cross-hatched areas indicate precipitation anomalies that are significant at the 95% level based on a t-test. 199

Figure 7.3. December composite patterns of anomalies of precipitation and 850-hPa horizontal wind anomalies for the AN, NN, and BN categories from real-time SCM MME forecasts during 2008–2024. 199

Figure 7.4. Temporal correlation coefficient of precipitation between SCM MME and observation (GPCP) during real-time forecast period, 2008–2024. 200

Figure 7.5. An example slide for the December 2025 precipitation forecast over South Korea, showing composite patterns of convection and horizontal winds for the three categories based on observations and SCM MME forecasts. 201

Figure 7.6. Summary of the APCC MME seasonal forecasts. The consensus forecasts are produced using MME forecasts, model analyses, and observational statistical forecasts. ... 202

Figure 7.7. SST PMME forecasts over East Asia for November 2025–January 2026, issued in October 2025. 203

Figure 7.8. Data produced by 15GPCs are collected and standardized, and the resulting seasonal prediction information is provided through the WMO-LC website..... 204

Figure 7.9. During the process of improving each GPC’s model, changes in the model file structure and hindcast data period required enhancement to the WMO-LC seasonal prediction production program codes..... 208

Figure 7.10. As the GPC-CMCC model and hindcast data were modified, errors occurred in data standardization, which led to inaccuracies in map-based SST information and resulted in large deviations in index values for certain regions. 209

Figure 7.11. APCC Fire and Haze Early Warning System (FHEWS). 211

Figure 7.12. Chart of Downscaling and Early Warning Stage Settings in the Early Warning System 212

Figure 7.13. Monthly History of Dominant Probabilistic Forest Fire Forecast for 2025..... 213

Figure 7.14. 6-month Precipitation Forecast for Jan2025–Jan2026 (issude:2025.07). 213

Figure 7.15. Monthly History of Probabilistic Forest Fire Forecast for 2025..... 214

Figure 7.16. 6-month Precipitation Forecast for May2025–May2026 (issude:2025.11)..... 214

Figure 7.17. Map providing High-Resolution Grid information for Morneo Island..... 215

Figure 7.18. Participated in ASEANCOF and delivered a presentation on WMO’s seasonal prediction outlook 216

Figure 7.19. Participated in ASEANCOF and delivered a presentation on WMO’s seasonal prediction outlook 217

1. 서론

기후변화가 극단적인 날씨뿐만 아니라 물 부족, 식량 부족, 해양산성화, 해수면 상승, 생태계 붕괴 등 인류 문명에 회복할 수 없는 위험을 초래하고 있다. IPCC 6차 평가보고서(IPCC, 2021)는 인간이 유도한 기후변화가 더 빈번하고 강력한 극한 현상을 초래하고 있음을 명확히 하였으며, WMO는 2022년 세계 기상의 날 주제를 '조기 경고와 조기 행동(Early Warning and Early Action)'으로 정하여 극한 기후 대응의 시급성을 강조한 바 있다. 최근 동아시아 지역에서 발생한 기록적 폭염은 농업, 에너지, 보건 등 전 분야에 걸쳐 막대한 피해를 초래하였으며, UN과 국제사회는 자연재난 및 위험 완화를 위한 조기경보의 중요성을 강조하고 있다.

계절예측은 폭염, 가뭄, 호우 등 이상기후에 대한 1~6개월 앞서의 선제대응에 활용할 수 있는 중요한 정보이다. 그러나 전통적으로 계절예측은 월평균 기온과 강수량을 3개 범주(above/near/below normal)로 나눈 3분위 확률예측 형태로 제공되어 왔다. 3분위 예측은 “평년보다 높을 확률 60%”와 같이 전반적인 기후 경향성을 파악하는 데에는 유용하나, 실제 의사결정자들이 필요로 하는 극한값 정보를 직접 제공하지 못하는 한계가 있다. 예를 들어, 전력 수급 계획 담당자는 “평년보다 더울 확률”이 아니라 “월평균 기온 28℃ 이상일 확률”을 필요로 하며, 농업 현장에서는 “작물 생육에 필요한 300mm 이상의 강수 확률”을 요구한다. 즉, 3분위 예측이 제공하는 평균적 경향성 정보와 사용자가 실제로 필요로 하는 구체적 임계값 기반 극한 정보 사이에는 본질적인 간극이 존재한다.

Hansen et al.(2022)은 농업, 보건, 재난 관리 등 각 섹터의 사용자가 3분위 임계값이 아닌 각 분야의 의사결정에 필요한 맞춤형 임계값 정보를 요구하고 있음을 보여주었다. 최근 전 세계 우수 기관들은 기존의 3분위 확률예측뿐만 아니라 극한 기후조건에 대한 예측 정보를 제공하기 시작하였다. NOAA 기후예측센터는 Probability of Exceedance (POE) 서비스를 제공하고, IRI는 사용자 정의 백분위수에 대한 확률 정보를 제공하며, 영국 기상청은 outer quintile(상위/하위 20%) 예측을 추가로 제공하고 있다.

그에 반해 APCC 현업 기후예측정보는 여전히 3분위 확률예보만을 제공하고 있다. 다만, 2017년 상하위 15% percentile 예측을 위한 기초 연구가 진행된 바 있어 기술적 기반이 마련되어 있다. 특히 APCC MME는 16개 기관, 11개국이 참여하는 대규모 다중모델 앙상블 시스템으로, 총 500개 이상의 앙상블 멤버를 보유하고 있다. 이는 극한값 예측에 있어 결정적인 강점이다. 극한값 예측은 본질적으로 확률 분포의 꼬리(tail) 부분을 다루므로 충분한 샘플 수가 확보되어야 안정적인 추정이 가능하다. 50개 앙상블을 활용하는 단일 모델 시스템은 95번째 백분위수 추정 시 2-3개 멤버만 사용하게 되어 매우 불안정하나, 500개 멤버를 보유한 APCC MME는 25개 멤버를 사용할 수 있어 훨씬 더 안정적이고 신뢰할 수 있는 극한값 추정이 가능하다. 본 연구에서는 APCC 예측정보의 이상기후 대응 활용성을 높이고 국제 경쟁력을 강화하기 위해 APCC MME의 특성을 고려하여 집중호우, 폭염, 가뭄 등 이상기후 대응에 활용할 수 있는 새로운 예측정보를 발굴하여 제공하고자 한다.

한편, 설립 이후부터 운영되어 온 MME 계절예측은 모델의 예측성능 스코어를 중심으로 다소 단편적인 평가가 이루어져 왔다. 더욱 중요한 것은, 주된 분석과 연구들이 hindcast (과거

재예측)를 중심으로 이루어져 실시간 예측(real-time forecast)이 급격한 기후변화 경향 속에서 어떠한 특성을 보이는지에 대한 이해가 부족하다는 점이다. Hindcast는 재분석 자료를 초기조건으로 사용하여 예측성의 이론적 상한선을 제시하나, real-time 예측은 실시간 분석장을 초기조건으로 사용하므로 예측성이 낮을 수밖에 없다. 따라서 실제 운영 환경에서의 예측 가능성을 정확히 파악하기 위해서는 real-time 예측에 대한 평가가 필수적이다.

APCC MME가 매월 6개월 예측 정보를 생산한 2013년 이래 약 10년 이상 축적된 실시간 예측 자료가 확보되었으므로 hindcast와 real-time 예측 성능의 격차를 정량화하고, 실제 운영 환경에서의 신뢰도를 평가할 수 있는 시점이 되었다. 따라서 과거부터 현재까지 약 10년간의 APCC MME 예측으로부터 MME의 현 상태를 진단하고, 최근 기후변동성을 고려한 모델의 주요 기후모드에 대한 예측성 진단 및 평가를 수행하고자 한다. 이러한 평가 결과는 “이번 예측은 얼마나 믿을 만한가?”에 대한 근거 있는 답변을 제공할 수 있으며, 예측 신뢰도에 따라 차등화된 정보 제공이 가능하게 한다.

본 연구는 크게 세 가지 부분으로 구성된다:

1. New contents: 극한 기후 예측 정보 생산: APCC MME의 500여 멤버를 활용하여 outer quintile 및 POE 예측을 개발하고, 월강수를 강수일수와 강수강도로 분해 ($P=N \times D$)하여 극한 강수 특성을 분석하고 극한 기후 대응에 활용할 수 있는 예측 정보를 생산한다.
2. New knowledge: MME 기후모드 분석: 20여년의 hindcast와 약 10년간의 real-time 예측 데이터를 활용하여 주요 기후모드(ENSO, IOD 등)에 대한 예측성을 평가하고, hindcast 대비 real-time 성능 격차를 분석하여 향후 실무 예보에 활용할 수 있는 예보 지식을 생산한다.
3. Operation: 매월 안정적인 MME 계절예측을 생산하고, SCOPS 운영 및 BSISO, 산불 예측 등의 특화 서비스를 제공하며, WMO LC-LRFMME를 운영한다. Hindcast 기간 변경, 신규 모델 추가 및 구모델 업데이트를 통한 MME 구성 최적화, ENSO 정보 개선 등 지속적인 시스템 개선을 포함한다.

APCC 기후예측 시스템은 세계 최대 규모의 앙상블을 활용한 안정적인 극한값 예측, real-time 성능 평가를 통한 신뢰도 기반 정보 제공, 그리고 아시아-태평양 지역 대표 기후예측 서비스라는 차별화된 경쟁력을 바탕으로, “이상기후 대응을 위한 계절예측의 실효성 강화”라는 사업 목표를 달성하고자 한다.

2. 이상기후 대응 예측 콘텐츠 개발

이상기후에 대응하기 위한 계절예측정보의 실효성 향상을 위해 이 연구과제에서는 두 가지 방향이 제안되었다 (1장 참조). 그 두 가지 연구방향은 이상기후예측 콘텐츠 개발과 MME 기후모드 해석체계 개발로, 두 연구내용 모두 7단계 (2025년-2027년) 연구기간 동안 APCC MME 계절 기후 예측정보를 바탕으로 하며, 이상기후 대응을 위해 새로이 활용 가능한 신규 기후예측정보를 생산하기 위한 기술을 확보하고, 나아가 여러 기후모델의 기후모드 예측에 대한 분석 정보를 축적하는 것에 그 의의를 두고 있다. 특히, 이상기후 진단 및 예측을 위한 신규 계절예측 정보의 개발은 아래 두 가지 과학적 질문에 대한 해답을 찾고자 구성되었다.

1. 서로 다른 오차(bias)를 가진 다량의 앙상블 자료 분포를 어떻게 관측의 물리량 분포에 적합하게 만들 것인가?
2. 기존의 월평균 이상으로 좀 더 제공할 수 정보는 무엇인가?

전체 연구과정은 “데이터 분포 특성 및 분석(1차년도)”, “극한기후 예측 정보 개발(2차년도)”, “유효성 검증 (3차년도)” 의 3단계로 진행되며, 1차년도인 2025년에는 이상기후 대응 정보 산출을 위해 관측 및 예측 데이터 분포의 특성을 분석하고자 한다. 세부 연구내용은 크게 (1)기후 자료 분포를 분석하고, 분포를 기반으로 분위확률 및 임계초과확률을 예측 및 검증하는 부분과 (2)월강수 및 일강수의 특성을 분석하고, 그 특성들을 연계하는 부분으로 나뉜다. 각각의 상세한 당해 연도 연구결과는 아래 2.1절과 2.2절에 나타난다.

2.1. 기후분포 분석 및 이상기후 대응 확률예측 검증

2.1.1. 연구방법

2.1.1.1. 자료의 보정

이 연구에서는 과도한 보정을 회피하기 위해서, 우선 기후학적 평균을 보정하는 방법만을 고려하였다 (Table 2.1 참조). 즉, 단순히 자료 내 기대값을 보정하는 방식(y_{Unb1} , y_{Unb2})과, 관측 및 모델의 편향을 보정하여 통계적 분포를 맞추는 전통적인 분위사상법(Quantile mapping)을 적용(y_{Unb3} , y_{Unb4})하였다. 각각은 다시 기후값 또는 자료 분포를 추정하는 자료가 개별 모델(y_{Unb1} , y_{Unb3})인지 그랜드 앙상블(y_{Unb2} , y_{Unb4})인지에 따라 구분되었다. 각 실험(보정)의 코드네임은 보정을 적용한 자료는 기후값 또는 분포의 오차가 보정되었다는 의미로 y_{Unb} 로, 보정 전 그랜드 앙상블은 바이어스를 포함한다는 의미로 y_{Bias} 로 명명한다.

Table 2.1. Experimental designs of various bias corrections.

Correction Code	Detailed Explanation
yBias	Raw (Direct) Grand Ensemble
yUnb1	Simple Mean Bias Correction of Individual Models
yUnb2	Simple Mean Bias Correction of Grand Ensemble
yUnb3	Conventional Quantile Mapping of Individual Models
yUnb4	Conventional Quantile Mapping of Grand Ensemble

2.1.1.2. 확률의 추정

추후 분위 확률예측이나 물리적 임계 초과 확률 예측 도출 시, 확률 추정은 모수화나 비모수화의 차이는 무시했으며, 아울러 모델간 합성의 차이도 무시했다. 즉, 원시 모델의 경험적 순위로부터 도출된 분포로부터 확률밀도함수를 추정했으며, 모델간 가중치에 무관하며 하나의 앙상블 멤버가 동일한 가중치를 가지는 폴링 방법을 활용하였다. 기후값 보정 및 확률 추정 모두 목표로 하는 해를 제외하고 나머지 자료를 기후값으로 활용하는 교차검증을 적용하였다.

2.1.1.3. 확률예측의 검증

앙상블예측은 어떠한 사건이 발생할 확률을 0과 1 사이의 값 (혹은 0에서 100%)으로 나타낸다. 일반적으로 단일 확률 예측을 검증하기는 어렵다. 대신에 일련의 확률 예측 p 를 관측, 즉 사건의 발생($o=1$) 혹은 발생하지 않음($o=0$)을 이용하여 검증한다. 정확한 앙상블예측인지 검증하기 위해서 다음의 요소들을 살펴보았다.

- 신뢰도(Reliability): 예측 확률과 평균 관측 빈도 사이의 일치성
- 예리함(Sharpness): 극값을 예보하는 경향
- 분해능(Resolution): 표본 사건들을 특징적으로 상이한 빈도수를 가지는 부분집합으로 분해할 수 있는 능력

이 연구에서 확률예측의 검증 방법은 Continuous Ranked Probability Skill Score(CRPSS), Brier Score (BS), Brier Skill Score (BSS), Relative Operating Characteristic curve (ROC 곡선), 신뢰도 그림(Reliability diagram) 등이다. BS는 확률 오차를 제공하여 평균한 수치로, (1) 신뢰도, (2) 분해능, (3) 불확정성으로 나뉜다. 값의 범위는 0에서 1이며, 완벽한 예보는 0의 값을 갖는다. 일반적으로 사건의 기후학적 빈도에 민감하다는 특징을 갖는다. 분위확률예측의 검증을 위해 사용한 RPSS의 기후자료는 균등 확률예측에 대해서는 33-33-33%의 발생 확률을 기후값으로, 비균등 확률예측에 대해서는 20-60-20%의 발생 확률을 기후값으로 정의하여 RPS를 산출하였다.

2.1.2. 자료 분포 및 보정

2.1.2.1. 관측 및 (원시) 예측 자료의 분포 특성

이 연구에서는 기존의 3분위 확률예측과 달리, 5분위 및 물리적 임계초과 확률예측을 동시에 만족하는 “자료분포” 자체를 예측하고자 한다. 즉, 임계확률 예측을 위해서 기후편차(anomaly)가 아닌 원시 자료를 활용하고자 하며, 자료의 단위(unit)을 유지하기 위해서, 특정 확률값이 아닌 자료 분포 자체의 예측을 목표로 한다. 따라서, 원시 자료의 활용성을 살펴보기 위하여 관측 및 예측 자료 분포 특성을 먼저 살펴보았다.

Figure 2.1은 물리량을 가지는 관측자료와 아무런 보정을 하지 않은 원시 예측자료의 확률 분포를 나타낸다. 먼저, 동일한 경도(K 지역)의 자료일지라도 위도에 따라 관측 및 예측자료의 특성이 크게 다를 수 있다. 먼저, 사용된 기후값이 1993-2016년으로, 참값으로 사용된 관측자료의 개수는 단지 24개 불과하다. 이렇게 작은 샘플은 결국 관측자료가 (기온에 대해서도) 정규분포 등의 이론적인 자료 분포를 나타내지 못한다. 즉, 기온은 중위도, 적도 모두 모두가 두 개이거나 여러 개인 분포를 보여주면서, 결국 대표적인 정규분포의 특징인 모드가 하나인 구조를 보여주지 못한다. 이러한 특징으로 인해, 당해 연도 연구에서는 이론적인 분포를 활용하여 모수화 기반의 확률을 추정하는 대신에, 자료 내에서 경험적으로 순위를 매기고 이로부터 확률을 추정하는 방식을 사용하였다(2.1.1.2절 참조). 반면 모델이 예측한 기온의 경우에는 좀 더 정규분포에 가까운 형태로 예측하지만, 그 위치는 관측과 다소 차이가 있다. 중위도 기온의 경우에는 관측보다 과소 모의, 적도의 경우에는 관측보다 과대 모의한다.

강수의 경우에는 중위도 및 적도 지역 모두에서 관측, 모델 자료 모두 양의 왜도를 나타낸다. 즉, 데이터 분포의 비대칭성이 크다. 따라서 기존의 현업 삼분위 예측에서 사용하는 정규분포 기준의 모수화 대신에, 자료 내에서 경험적으로 순위를 매기고 이로부터 확률을 추정하는 방식을 사용하였다(2.1.1.2절 참조). 자료의 위치도 관측과 모델간 큰 차이를 보인다. 중위도 지역에서는 관측 대비 과대 모의, 적도 지역에서는 과소 모의한다. 특히, 적도 지역 강수의 경우에는 관측의 형태와 모델의 형태가 다소 상이하다. 강수의 확률분포는 감마분포의 형태를 띠며, 형상 모수 및 척도 모수 두 개의 모수를 가진다. 모델은 중위도와 적도 지역에 구분 없이 관측에 비해 척도 모수가 큰 구조를 보이는데, 이는 모델의 기온과 마찬가지로 모델의 샘플 사이즈가 상대적으로 관측보다 큰 것에서 기인한다고 볼 수 있다. 형상 모수의 경우에는, 적도 지역이 중위도 지역에 비해 큰 차이를 보이며, 모델의 형상 모수가 관측 대비 매우 작아, 분포의 형태가 상당 차이를 알 수 있다.

관측 및 모델은 위치, 형태, 범위 등 자료 분포를 구성하는 요건에서 상당 차이를 보이며, 이는 모델 자료의 보정 없이 물리적 임계초과 확률 예측을 하는 것에 상당한 장애 요인으로 작용한다. 따라서, 이상기후 대응 확률 예측 이전에, 모델 자료의 분포를 관측에 보정하는 작업을 수행하였으며, 보정 및 확률 추정 방법은 다음의 2.1.1.2절에 기술하였다.

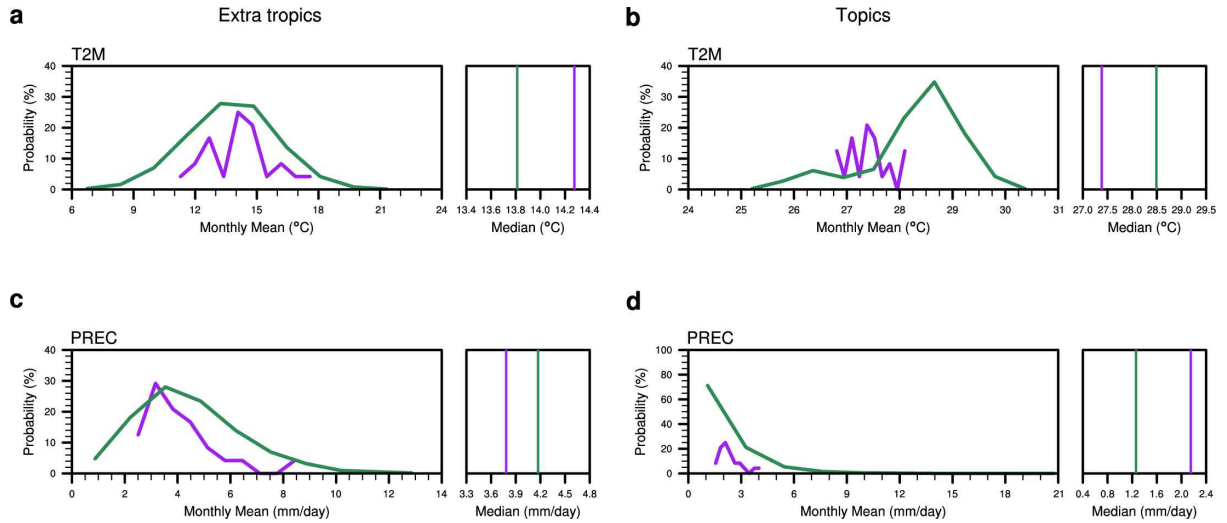


Figure 2.1. Probability distributions (left panels, units: %) and medians (right panels) of (a, b) April mean temperature at 2m (units: °C) and (c, d) precipitation (units: mm/day) of *K* region in (a, c) extra tropics and (b, d) tropics for the period 1993–2016, based on observations (in purple lines) and predictive datasets from yBias (in green lines).

2.1.2.2. 기후값 보정

Figure 2.2은 Figure 2.1의 기존 자료에 보정된 자료의 확률 분포를 함께 나타낸 것으로, 보정 전후 자료 분포의 위치 및 중위값에 상당 차이를 보이는 것을 알 수 있다. 중위도 지역 기온의 경우, 원시 모델 자료는 관측에 비해 과소 모의하였으나, 그 옴의 오차는 보정 후에 방법에 상관없이 개선되며, 단순 보정이 분위사상법에 비해 관측과의 위치가 가까워진다. 적도 기온의 경우에는 관측 및 원시 모델 자료의 중위값이 1도를 넘는 차이를 보이며, 과대 모의하는데, 보정 후에 관측과 상당 가까워진다. 분위사상법이나 개별모델의 기후값을 보정하는 방법들 모두 상당한 보정 효과를 보여주나, 그랜드 앙상블로부터 단순 기후값을 보정하는 방법은 다른 방법에 비해 상대적으로 그 효과가 떨어진다.

장수의 경우에는, 중위도에서 과대 모의하던 모델 자료가 보정을 통해서 관측과 유사로 범위로 매칭된 것을 확인하였다. 적도의 경우에는 과소모의하던 모델 자료가 상당 개선되었으며, 자료의 위치 이외에 자료의 형태도 상당 개선되었다. 즉, 원시 모델은 형상 모수가 관측에 비해 상당 작아 자료 분포의 형태가 차이를 보였으나, 대부분의 보정 적용 후에는 자료의 기댓값 및 분산이 모두 보정되면서 형상 모수의 개선 및 자료 분포 형태의 개선도 확인 할 수 있다. 단, 그랜드 앙상블의 기후값을 단순 보정하는 경우에는 자료 위치도 다른 방법에 비해 적게 보정되며, 따라서 형상 모수의 개선이나 자료 형태의 개선은 크지 않다.

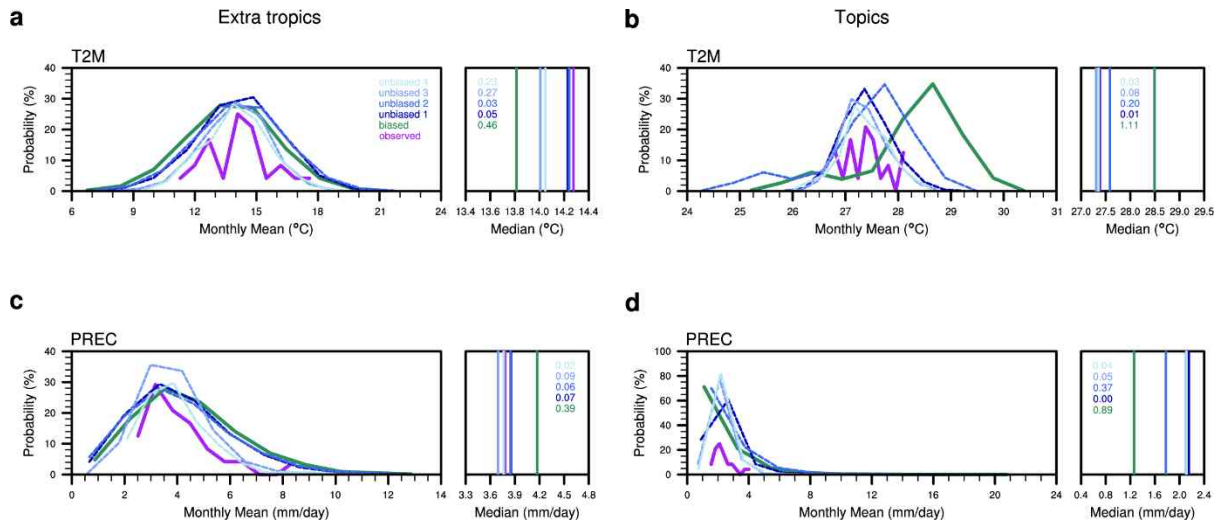


Figure 2.2. Probability distributions (left panels, units: %) and medians (right panels) of (a, b) April mean temperature at 2m (units: °C) and (c, d) precipitation (units: mm/day) of K region in (a, c) extra tropics and (b, d) tropics for the period 1993–2016, based on observations (in purple lines) and predictive datasets from yBias (in green lines), yUnb1, yUnb2, yUnb3, and yUnb4 (in respective dark to light blue lines). The absolute differences of medians between observations and prediction datasets are given in the upper left of each right panels.

지금까지는 K지역의 4월 기온 및 강수의 위도대에 따른 차이를 보정 효과와 함께 살펴보았으며, 보정 이후에 자료의 위치 및 (강수의 경우에는) 자료의 형태도 보정됨을 확인하였다. 보정의 일반적 효과를 살펴보기 위해서, 이 연구에서 고려된 22개 지역의 주요 월(2개씩)의 자료 분포 및 보정 효과를 한눈에 비교해 보고자 한다. Figure 2.3-6은 각 중위도, 적도의 기온, 중위도, 적도의 강수 자료 분포 및 관측 대비 모델 자료의 전치 (위치의 이동), 관측 대비 모델 범위의 비를 나타낸다.

먼저, 기온의 중위도 및 적도 분포를 살펴보면, 중위도 기온 자료의 경도 변화가 적도 기온에 비해 크며, 월별 차이도 크다. 그에 반해, 적도 기온의 경우 (월별 차이가 없는 것으로 미루어보아) 연중 기온이 높고 (연간) 변동도 작으며, 특히나 경도의 차이가 거의 없다. 이러한 차이에 무관하게 보정은 관측 분포와 좀 더 가깝게 모델 분포를 조정하는 효과가 있다. 즉, 보정 이후에 자료분포의 위치 및 범위도 상당 관측과 유사하게 개선된다. 전치 및 내부 범위 모두 분위사상법이 단순 기후값 보정보다 좀 더 효과적으로 작동하는 것으로 보인다. 단, 교정 검증을 수행하더라도 그랜드 앙상블의 기후값을 단순 보정하는 경우에는 자료의 위치는 보정이 되지만, 자료 범위는 보정 전과 거의 유사하다.

강수의 경우에는 단순 기후값 보정 또는 분위사상법 적용 후 음수의 값을 가질 경우, 0으로 절삭했다. 강수의 자료 분포는 거의 대부분 양의 왜도를 가지는 분포를 보여주며, 중위도나 적도 지역이 크게 다르지 않으면, 적도 지역은 중위도에 비해 경도대에 대한 차이가 크며, 월별 차이도 크다. 즉, 경도에 따라 건조한 지역과 습윤한 지역의 자료 변동 차이가 크다. 자료 분포의 위치나 범위는 보정 이후에 관측과 자료 분포와 상당 유사해지면, 분위사상법이 단순기후값 보정에 비해 좀 더 매칭이 잘 되는 것으로 보인다. 기온과 마찬가지로, 보정 방법 가운데 그랜드 앙상블의 단순 기후값 보정이 여타 방법에 비해 효능이 떨어지는 것으로 보인다.

기후값 전체의 자료 분포 이외에, 보정 전후 앙상블 예측 자료의 연간 분포 및 전체 기간에 예측 성능을 살펴보았다. Figure 2.7은 4월 평균 적도 K 지역의 기온 타임시리즈이다. 그림에서 예측값의 앙상블 멤버내 5분위의 상하위 20%를 상자 수염 그림으로 나타냈다. 관측값 또한 함께 표시했다. 파랑 및 빨강 점선들은 각각 상하위 20%의 범위를 나타낸다. 관측 및 앙상블 평균의 연변동 뿐만 아니라 관측 및 예측 자료의 범위에 대한 연변동 또한 보정 전/후 앙상블 자료의 전체 기간 자료의 예측 성능에 대한 시각적인 결과를 보여준다. 눈으로 보는 검증의 경우, 보정 전 앙상블은 관측과 아주 다른 상태를 예측함을 알 수 있다(Figure 2.7a). 그리고, 보정은 좀 유사한 상태를 만듦을 알 수 있다(Figure 2.7b-e).

또한, 보정은 예측 성능 변화시킨다. 보정 전/후의 앙상블 예측 모두 기후값 예측보다 높은 예측성능을 보이는 반면(Figure 2.7b-e), 보정의 일부는 예측 성능의 감소를(Figure 2.7b-d) 다른 하나는 향상을 보인다(Figure 2.7e). 하지만, 각 지점에서의 예측 성능은 넓은 지역의 점들을 기준으로 한 것보다 덜 유의하므로, 특히나 상대적으로 짧은 기간의 자료를 사용할 경우, 보정/비보정 앙상블 예측간 차이를 고려하기에는 충분히 크지 않다.




Figure 2.3. Probability distributions (left panel), displacement (middle panel) and inter-range (right panel) of monthly mean temperature at 2m (units: °C) in extra tropics for the period 1993-2016, based on observations (in purple lines) and predictive datasets from yBias (in green lines), yUnb1, yUnb2, yUnb3, and yUnb4 (in respective dark to light blue lines).




Figure 2.4. Same as Figure 2.3, but in tropics.




Figure 2.5. Same as Figure 2.3, but for precipitation (units: mm/day).




Figure 2.6. Same as Figure 2.3, but for precipitation (units: mm/day).

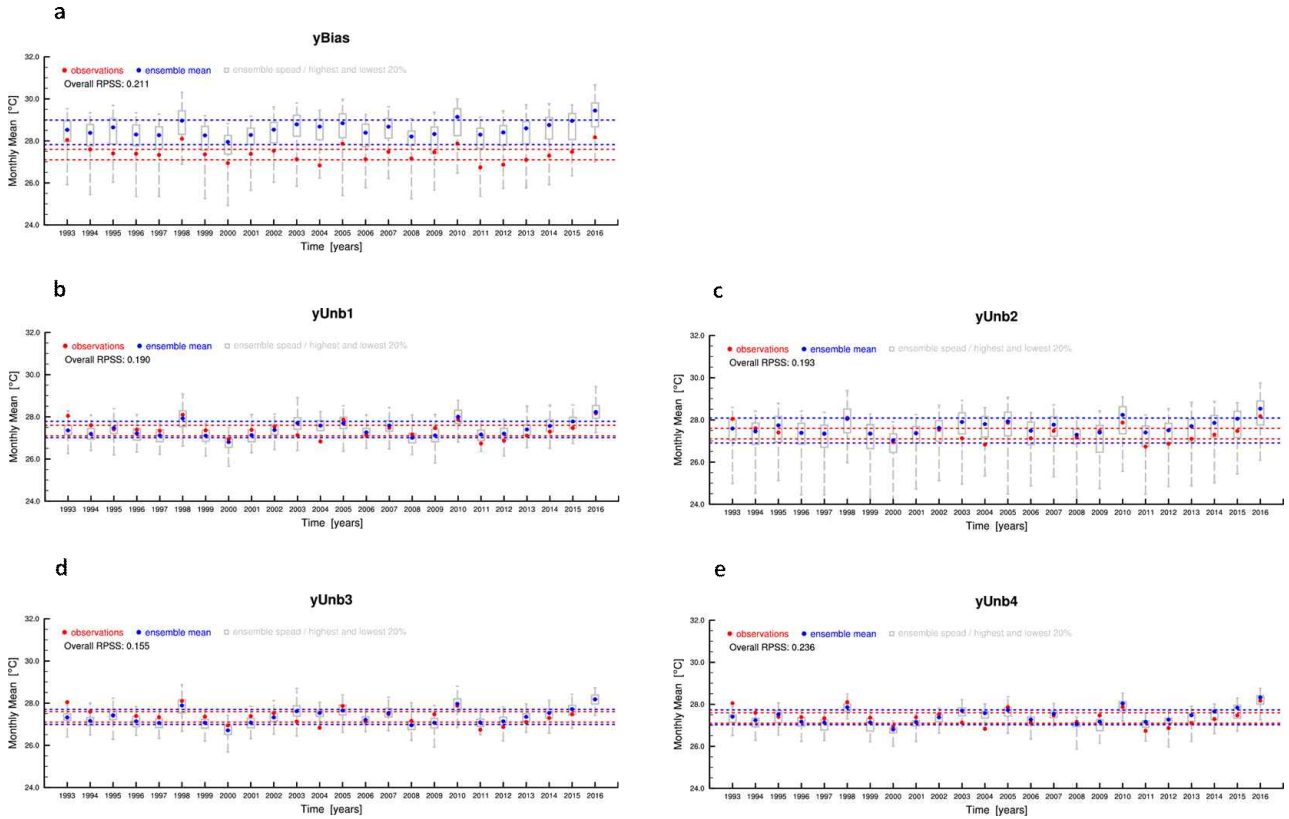


Figure 2.7. Time series of the 1-month lead April mean temperature at 2m (units: °C) of K region in tropics for the period 1993–2016, based on observations and predictive datasets from (a) yBias, (b) yUnb1, (c) yUnb2, (d) yUnb3, and (e) yUnb4. The ensemble spread predicted is depicted by the box-and-whisker representation with the whiskers containing the lower and upper quintile of the ensemble. The blue and red dots (horizontal lines) represent the ensemble mean and observations (extreme quintiles, lower 20 and upper 20%), respectively. The overall RPSS skill of categorical probability forecast taken from ensemble spread is given in the upper left of each panel, with respect to the climatology defined by the reference forecast of the category 20–60–20%.

2.1.3. 5분위 확률 예측 및 검증

2.1.3.1. 20-60-20% 카테고리 확률 예측

보정 전/후의 앙상블 자료를 바탕으로 5분위 확률 예측 자료를 생산하고 그 예측성능을 검증하였다. 우선 보정 전/후의 앙상블 자료를 균등 확률예측과 비균등 확률예측의 RPSS 예측 성능을 비교하였다(Figure 2.8a 참조). 균등 확률은 33-33-33%을 기준으로 순위확률을 기준으로 삼았고, 비균등 확률은 20-60-20%을 기준으로 순위확률을 기준으로 삼았다. 순위 확률 분포에 대해서는 보정 여부에 상관없이 기온 및 강수 모두 균등 확률 대비 비균등 확률의 예측성능이 감소한다. 이는 비균등 확률예측, 즉 이상기후에 대한 확률 예측이 좀 더 도전적인 예측정보임을 알 수 있다. 또한, 변수 및 균등/비균등 확률에 무관하게 기후값 보정 이후에 확률 예측 성능의 성능이 감소한다. 기온의 경우에는, 단순 기후값 보정이 분위사상법에 비해 나은 결과를 보여준다. 그리고, 보정 방법에 상관없이 자료 분포의 보정 기준을 개별기후모델에 시행할 때가 그랜드 앙상블에 시행할 때보다 나은 예측성능을 보여준다. 강수의 경우에는 보정 이후에 예측성능의 감소가 크게 보이는데, 비균등 확률예측의 일부(그랜드 앙상블을 기준으로 보정을 시행한 경우)는 기후값 예측보다 낮은 예측 성능을 보이기도 한다. 예측성능의 변화에 있어서는 기온과 달리 일관된 패턴은 보이지 않지만, 그랜드앙상블로부터 기후값을 단순보정하는 경우에 예측성능이 크게 감소했다.

예측성능의 상당 부분은 보정 전의 원시자료의 예측성이 보정 유무보다 좀 더 중요하게 작용한다(Figure 2.8b 참조). 즉, 중위도 및 적도 지역을 나누어 살펴보면, 두 지역 모두 보정 후 예측성능이 감소하는 경향을 보이지만 보정/전후의 차이보다 지역간 차이가 훨씬 크다. 기온의 경우, 기후값을 단순 보정하는 경우가 분위사상법보다 좀 더 높은 예측성을 보여준다. 강수는 기온과 달리 일관된 패턴이 보이지 않는다. 보정 전의 원시 앙상블 자료의 경우에는 적도 지역의 강수 예측이 중위도 지역의 강수 예측보다 훨씬 높은 예측성은 보여준다. 중위도 지역의 강수 예측은 기온과 마찬가지로 보정 이후에 예측성이 감소하지만, 단순 보정 방법이 그 감쇠가 분위사상법에 비해 작고, 개별모델을 기준으로 보정을 시행한 경우 보정 방법에 상관없이 그 감쇠가 적다. 적도 강수예측의 경우에는 개별 모델에 보정을 시행한 경우가 그랜드 앙상블에 시행한 경우보다 예측 성능의 손실이 작다. 그러나, 예외적으로 그랜드 앙상블을 단순 보정하는 경우 예측성이 크게 떨어진다. 결과적으로 보정 방법 간에는 개별모델을 기준을 단순 기후값을 보정하는 경우가 기온/강수가 예측 성능이 제일 높았다.

Figure 2.9-12은 중위도, 적도의 기온 및 강수의 RPSS를 대상 지역(월)에 대해서 보정 전/후에 대해서 살펴본 것으로, 전체기간, 실제로 상하위 20%의 사례들에 대해서 나누어 분석하였다. 기온의 종전의 결과와 마찬가지로, 보정의 차이보다는 위도대의 차이가 훨씬 크다. 또한 위도대의 평균적인 차이보다는 작지만, 지점별 편차(경도에 의한 차이)도 보여진다. 아울러 보정에 의한 차이보다는 실제 상하위 20%의 사례에 대한 RPSS 성능이 전체 기관에 비해 높다. 적도보다는 중위도에서 보정 이후 예측성능 감쇠가 보이며, 단순 기후값 보정이 분위사상법에 비해 좀 더 안정적으로 보인다.

강수의 경우에는 기온과 달리 뚜렷한 중위도-적도의 대칭은 보이지 않으며, 보정에 상관없이 일부 지역은 적도가 중위도 보다 높은 성능을 보이지만, 적도의 다른 일부 지역은 보정 이

후에 예측 성능이 크게 떨어진다. 기온에서 보여지는, 극한 사례에서 예측성이 더 좋아지지는 않고, 3개의 카테고리에서 유사한 패턴을 보여준다. 일반적으로 보정 이후 예측성능이 감소하는데, 중위도 지역의 강수에서는 단순 기후값 보정이 분위사상법에 비해 나은 예측성능을 보여준다. 적도 강수의 경우에는 일부 지역(원래 예측성이 높은 지역)은 3개의 카테고리 모두 보정의 영향이 없어 보이는데, 원래 예측성이 낮은 일부 지역은 보정 이후 예측성이 크게 감소한다. 흥미로운 점은 이 가운데 그랜드 앙상블의 기후값을 보정하는 방법이 예측성이 크게 감소한다. 이는 Figure 2.8의 보여지는 적도 강수의 yUnb2의 예측성이 감소하는 것에 대한 요인으로 보여진다. 특히나 이 지역들은 굉장히 건조하고 양의 왜도가 큰 지역으로 그랜드 앙상블로부터 단순보정하는 것은 큰 주의를 요함을 알 수 있다.

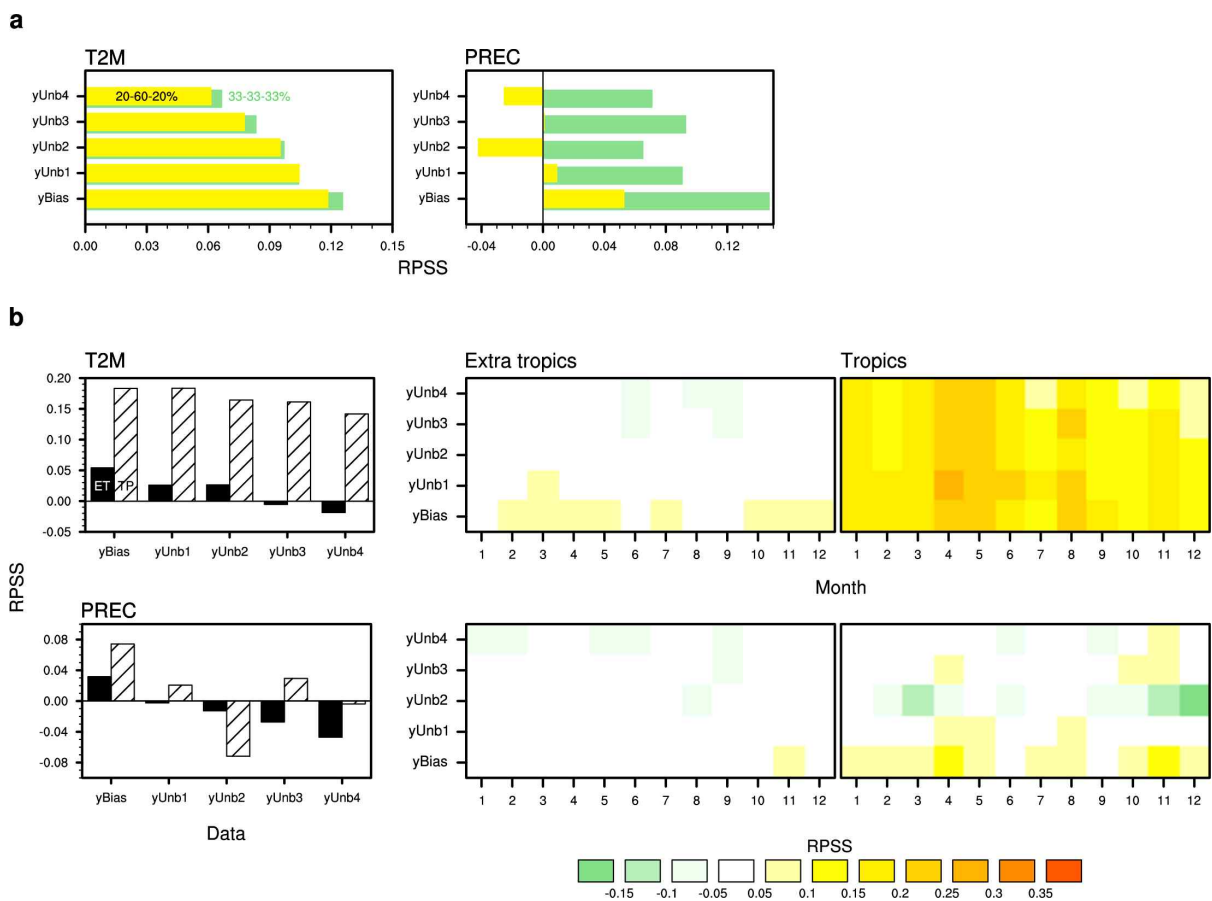


Figure 2.8. (a) Temporal-spatial averaged RPSS skills of categorical probabilistic forecasts of monthly mean temperature at 2m (left panel) and precipitation (right) for the period 1993–2016. (b) Annual-averaged RPSS skills (left column), and RPSS skills as function of forecast target time and predictive dataset (right columns) of monthly mean temperature at 2m (upper panels) and precipitation (bottom) in extra tropics and tropics.




Figure 2.9. RPSS skills as function of forecast location and predictive dataset of monthly mean temperature at 2m in extra tropics for the whole period 1993–2016 (upper panel), and actually occurred lower and upper 20 events (middle and bottom panels, respectively).

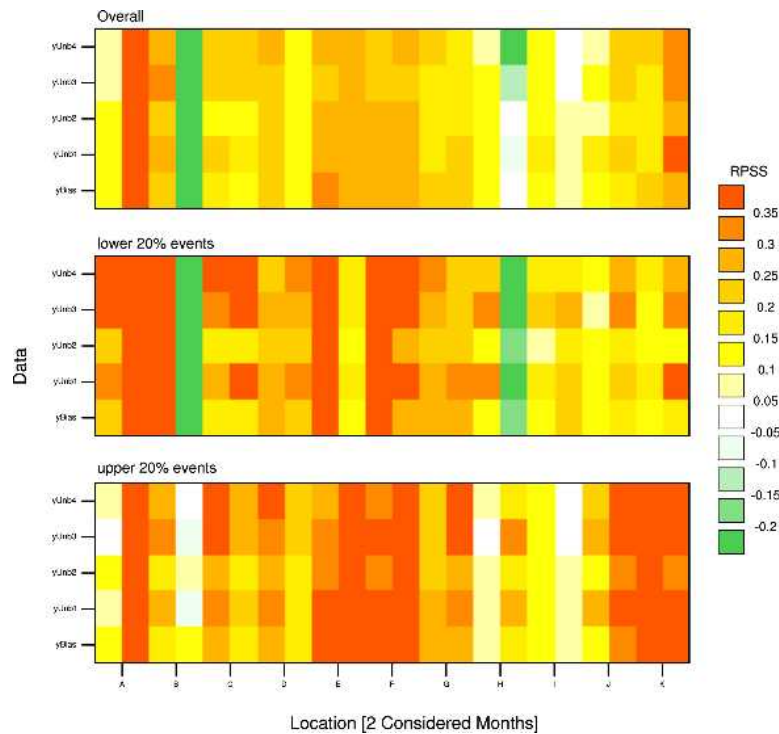


Figure 2.10. Same as Figure 2.9, but in tropics.

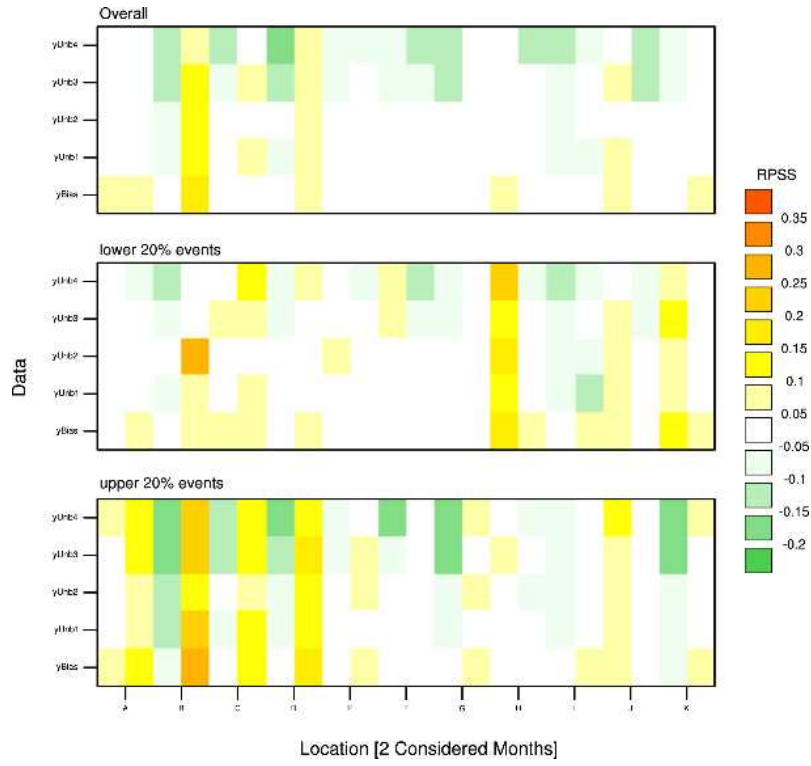


Figure 2.11. Same as Figure 2.9, but for precipitation.

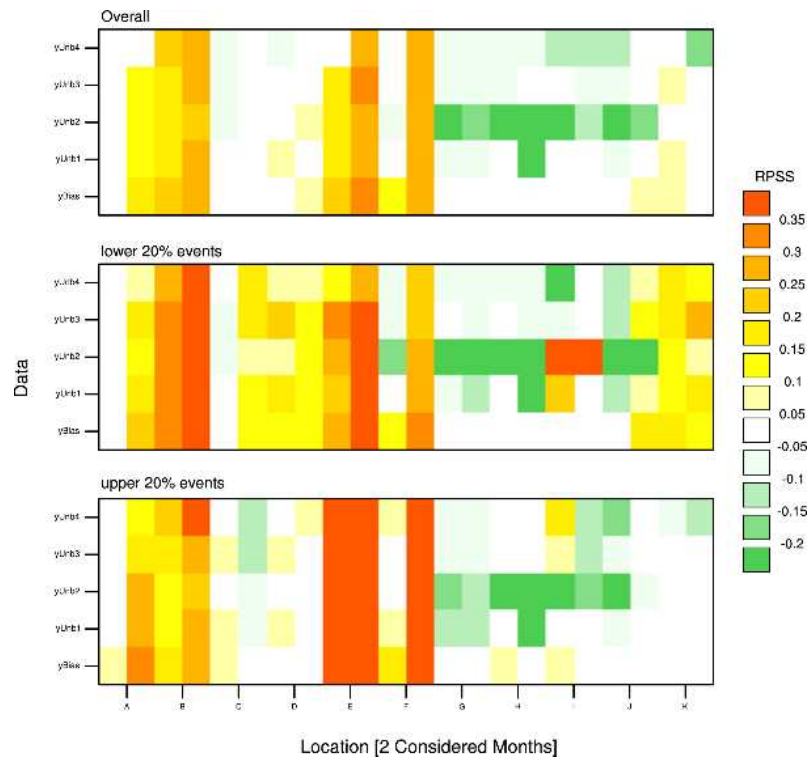


Figure 2.12. Same as Figure 2.10, but for precipitation.

2.1.3.2. 상하위 20% 확률 예측

이번 절에서는 전체 분포가 아닌, 상하위 20% 확률 예측을 기준으로 예측성능을 분석하였다. Figure 2.13-14은 보정 전후 자료들에 대해서 중위도 및 적도 기온의 상하위 20%에 대한 신뢰도 및 선명도(또는 예리함) 그림(다이아그램)이다. Reliability diagram은 예측 확률에 대한 관측 빈도를 표시한 것으로 예보 확률의 범위는 k개의 구간으로 나누고, 각 구간의 표본 빈도를 이은 선과 대각선이 근접한 정도를 나타낸다. 이상치 예측에 대한 특징으로, 예측확률이 높은 구간 및 관측 빈도는 잘 보여지지 않는다.

신뢰도는 각 구간의 표본 빈도를 이은 선과 대각선이 근접한 정도를 나타낸다. 즉, 신뢰도와 구간별 표본 빈도를 이은 선과 대각선이 일치하면 오차가 전혀 없는 완전한 신뢰도를 나타낸다. 2.1.3.1절에서 나타난 분석 결과와 마찬가지로, 보정 여부와 상관없이 적도의 기온의 예측성능이 중위도 기온에 기온보다 높다. 좀 더 구체적으로 살펴보면, 적도 지역의 신뢰도 라인(구간별 표본 빈도를 이은 선)이 중위도 지역의 신뢰도 라인에 좀더 근접한다. 즉, 확률오차의 제곱을 평균한 수치인 BS의 경우, 중위도 및 적도 모두에서 0.14~0.19의 범위에서 변하며, 중위도의 BS(0.16~0.19)가 적도 지역의 BS(0.14~0.16)보다 크다. 중위도든 적도 기온이든 단순 기후값을 보정하는 경우에는 BS의 변동이 없지만, 분위사상법의 BS가 약간(0.01) 커진다.

신뢰도 라인의 대각선으로부터의 편차(Deviation)는 조건부 편차(conditional bias)를 나타낸다. 표본 빈도를 이은 선이 대각선 아래에 위치하면 과대모의(확률이 높음), 대각선이 위에 위치하면 과소모의(확률이 낮음)임을 의미한다. 보정 전 기온 예측은 지역(적도 및 중위도) 및 분포의 양 끝 쪽(상하위 20%)에 상관없이 과소모의하는 경향이 있다. 중위도 기온의 경우에는 단순 기후값 보정의 경우 이러한 과소모의 경향이 줄면서 좀 더 대각선에 가까워진다. 하지만, 분위사상법은 오히려 대각선 아래로 내려오면서 과대모의하게 된다. 적도 기온의 경우에도 보정 전 자료의 과소모의 경향은 개별모델의 기후값을 단순보정하는 방법이 대각선에 가장 가까운 모습을 보여준다. 그랜드양상블로부터 기후값을 보정하는 경우에는 보정 전과 크게 다르지 않지만, 일부 구간에서 좀 더 대각선에 가까워져 있다. 분위사상법으로 보정한 이후에는 대각선 아래로 내려오면서 과대모의하는 모습을 보이지만, 원시자료에 비해서는 좀 더 대각선에 인접해 있다.

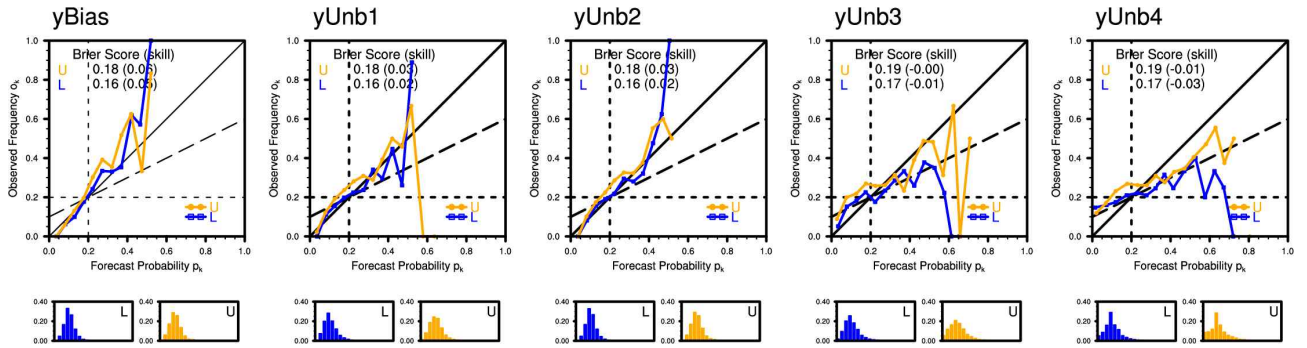


Figure 2.13. Reliability (upper panels) and sharpness (lower panels) diagrams of extreme quintiles of monthly mean temperature at 2m in extra tropics.

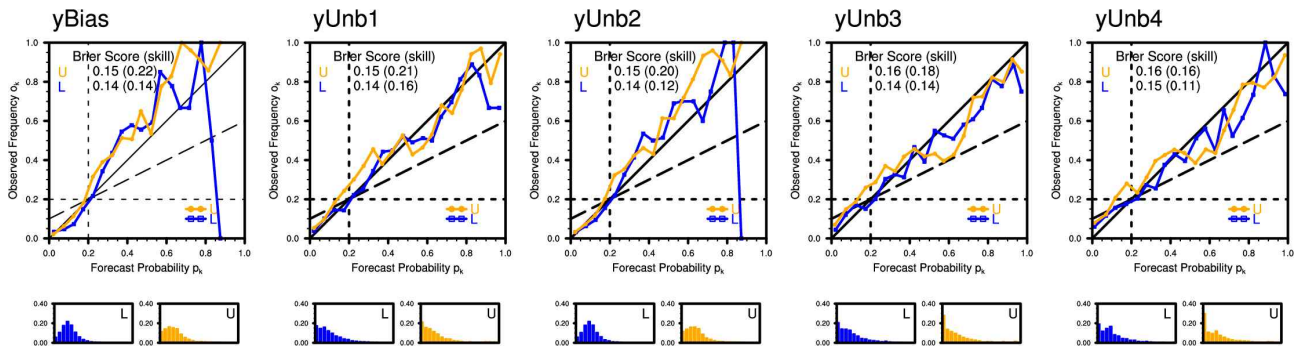


Figure 2.14. Same as Figure 2.13, but in tropics.




Figure 2.15. Reliability (left panel) and resolution (right panel) diagrams of extreme quintiles of monthly mean temperature at 2m in extra tropics.




Figure 2.16. Same as Figure 2.15, but in tropics.

각 구간에서의 예측확률과 관측빈도의 오차 제곱평균(BS를 3가지 항으로 나뉘었을 때 신뢰도 항목, 2.1.1.2절 참조)과 관측빈도와 관측의 기후값 차의 오차제곱((BS를 3가지 항으로 나뉘었을 때 분해능 항목, 2.1.1.2절 참조)을 Figure 2.14-15에 나타내었다. 위의 신뢰도 결과는 Figure 2.14-15의 결과와도 일치한다. Figure 2.14-15의 신뢰도는 일종의 오차를 나타내면서 작을수록 높은 신뢰도를 나타내므로 편의상 -1을 곱하였다. 지역 및 보정 방법에 상관없이 하위 20%의 신뢰도(오차)의 크기가 상위 20%에 비해 작다. Figure 2.13-14의 신뢰도 라인에서도 알 수 있듯이 상위 20%라인이 하위 20%라인에 비해 덜 왔다갔다 한다. 반면에 하위 20%는 높은 확률 구간에서 갑자기 증가하거나 감소하는 양상을 보여준다. 적도에서 보정을 할수록 오차가 줄어드는 것을 알 수 있으며, 중위도 지역에서는 보정 방법에 따라 오차가 줄기도 하고 커지기도 한다. 사실 원시 자료의 경우, 적도 지역의 오차가 더 큰 경향이 있었으나, 적도 지역의 보정 방법에 상관 없이 안정적으로 작용하는 것으로 보이며, 중위도 지역은 보정 방법에 민감하게 작용하는 것으로 보인다. 중위도 및 적도 모두 개별모델의 자료의 단순 기후값을 보정하는 경우가 오차를 가장 많이 줄이는 방법으로 보여진다.

신뢰도 그림에서 대각선 아래 파쇄선은 no-skill을 가리키며 예측확률에 대한 기후값(세로 점선)에서 no-skill라인까지 구간에 신뢰도 라인이 들어올 때 기후값보다 나은 예보를 말하며, 관측빈도의 기후값(가로 점선)보다 신뢰도 라인이 위에 있으면 임의 추정 예보보다 나은 예보를 말한다. 여기서 기후값보다 나은 예보는 BSS가 0보다 큼을 의미한다. 적도 기온의 경우에는 보정 전후 모두 기후값보다 나은 예보를 나타낸다. 보정 이후에 BSS는 약간 하락 하기는 하지만 그 차이는 크지 않으며, yUnb1의 경우에는 예측성능이 증가한다. 중위도 기온의 경우에는 분위사상법의 성능이 다소 하락하는데(BSS<0), 그럼에도 임의 추정 예보보다 나은 예측을 보인다. 즉, 보정 이후에 예측성이 약간 하락하지만, 여전히 유용한 예보로 활용할 수 있을 것으로 보인다.

예측성의 차이가 어디에서 기인하는지는 중위도와 적도의 예측성을 비교해 봄으로써 가늠해 볼 수 있다. 중위도와 적도의 예측성을 비교해 보면, 보정 여부에 상관없이 적도가 중위도보다 높은 예측성을 보여줌으로써 보정 여부보다 원시 예측성이 좀 더 중요하게 작용함을 알 수 있다. 그 차이는 BS를 불확실성, 분해능(resolution), 신뢰도로 나뉘보면 알 수 있는데, 오차의 상당부분은 불확실성(0.16)이 설명하며, 나머지 두 부분에 의해 오차가 결정된다. 중위도와 적도의 신뢰도(Figure 2.14-15)는 크기는 유사한 반면, 분해능의 차이가 큰 것을 알 수 있다. 즉, 적도 기온의 경우, 신뢰도는 크기는 감소하였지만, 분해능도 함께 줄어 예측성능이 약간 감소한 것을 알 수 있다. 마찬가지로 yUnb1의 하위 20%는 신뢰도의 크기는 줄고, 분해능은 보정 전과 동일하게 유지되면서 예측성능(BSS)이 개선된 것으로 보인다. Reliability diagram에서 표본 빈도를 이은 선이 편편한 경우 분해능이 낮음을 의미한다. 즉, 모두 구간에서 확률예측은 관측 빈도의 기후값(가로 점선)으로 대응되며, 이는 표본 사건들을 특징적으로 상이한 빈도수를 가지는 부분집합으로 분해하지 못함을 의미한다. 즉, 적도 지역의 신뢰도 라인의 추세선 기울기가 보정에 관계없이 중위도 지역에 비해 큼을 알 수 있다. 또한 상위 20%의 분해능이 하위 20%에 비해 훨씬 크며, 보정 방법에 따른 차이는 크지 않다.

확률 예측 검증에서 예리함(sharpness)은 극값을 예보하는 경향을 말하며, Figure 2.13-14에서 각각의 확률 구간의 빈도를 나타낸다. 예리함 그림에서 기후값 빈도에서 가장 큰 값을 가질

때 선명도 낮다고 하는데, 중위도 기온의 보정 전 자료는 예리하지 못한 예측을 하는것으로 보여진다. 단순 기후값 보정을 한 경우에도 예리함은 개선되지 않지만, 분위사상방법을 적용하여 쓸 경우보다 예리한 확률 예측이 만들어진 것을 알 수 있다. 적도 기온의 경우에는, 보정 전보다 보정 후에 방법에 상관없이 예리함이 개선된 것을 알 수 있다.

Figure 2.13-14은 보정 전후 자료들에 대해서 중위도 및 적도 강수의 상하위 20%에 대한 신뢰도 및 선명도(또는 예리함) 그림(다이아그램), Figure 2.14-15는 중위도 및 적도 강수의 신뢰도와 분해능을 나타낸다. 기온과 마찬가지로 강수에 대한 이상치 예측도 예측확률이 높은 구간에서는 예측 확률의 표본 빈도가 관측 빈도와 대응되는 경우가 잘 보이지 않는다. 강수의 경우에는 지역별(중위도 및 적도) 차이는 크게 보이지 않으며, 보정 전 자료의 BS는 중위도 기온의 BS와 유사한 수준이다. 보정 후에 BS는 약간 상승하여, 0.17~0.20에서 변동한다. 중위도 강수의 구간별 예측 빈도는 관측에 비해 과소 모의하거나 유사한데, 보정 이후에는 하위 20%는 과대 모의한다. 특히나 보정 이후에 신뢰도로 라인이 대각선 아래로 많이 내려오는데 이는 보정 후에 신뢰도의 크기가 커지고, 분해능이 크게 감소하는 것과 관련이 있다. 적도 강수는 보정 전에는 관측과 유사한 빈도로 예측하는데, 보정 이후에는 보정 전에 비해 과대 모의하는 경향이 있다. 특히나 그랜드양상블부터 단순 기후값을 보정하는 yUnb2는 하위 20%에 대한 예측 결과는 관측빈도 대비 과대 모의한다. 이런 구간별 확률예측 빈도 및 관측의 오차는 신뢰도 결과에서도 확인할 수 있다. 보정 이후에 하위 20%에 대해서 예측 과대 모의 되는 이유는 강수가 양의 왜도를 가진다는 점에 기인할 수 있을 것 같다. 또한 적도 강수를 yUnb2의 하위 20%가 좀 더 과대모의하게 된 이유는 건조하고 양의 왜도를 상대적으로 많이 포함하고 있고, yUnb2의 방법적인 특징상 보정 이후에 음의 강수를 0으로 절삭하는 비율이 높아지고, 강수의 자료 분포에서 형상은 보정되지 않은 점 등이 그 원인으로 추정해 볼 수 있을 것 같다. 하위 20%의 예측에 대해서 보정 이후에 BSS가 음이 되는 경향이 높은 반면, yUnb1은 BSS를 양으로 유지하면서 여전히 유용한 예측자료로 활용될 수 있음을 알 수 있다. 예리함 측면에서는 적도 강수의 예리함이 중위도 강수의 예리함에 비해 나은 결과를, 그리고 보정 이후에 예리함이 더 좋아진다.

보정 이후에 대체로 선명도는 더 좋아지고, 해상도는 작아진다. 신뢰도는 변수 및 방법에 따라 다르게 작용하는데, 기온 및 강수 모두에서 보정 방법 가운데 yUnb1가 신뢰도는 가장 높고 적도 기온 및 같은 경우에는 보정 전보다 더 작은 신뢰도를 보이기도 한다. 예측성을 결정하는 큰 요소는 신뢰도 보다는 해상도가 더 크게 좌우하는 것으로 보이며, 추후 해상도의 손실을 막는 보정 방법에 대한 고민이 필요해 보인다.

양분예보(dichotomous, yes/no)를 위해, Figure 2.23-24는 증가하는 확률임계값을 사용하여 적중률 대 오정보율을 그린 것이다. 좌측 상단으로 가까이 갈수록 감지 성능이 뛰어난 것을 의미한다. 기온 및 강수보다 적도의 예측성이 중위도보다 높은 점으로 미루어, 보정 적용이나 보정 방법의 차이보다는 원시 예측성이 좀 더 중요하게 작용함을 알 수 있다. 보정 이후에 예측 성능은 감소하나, 보정 방법 간에는 yUub1 방법이 가장 안정적으로 작동함을 알 수 있다.

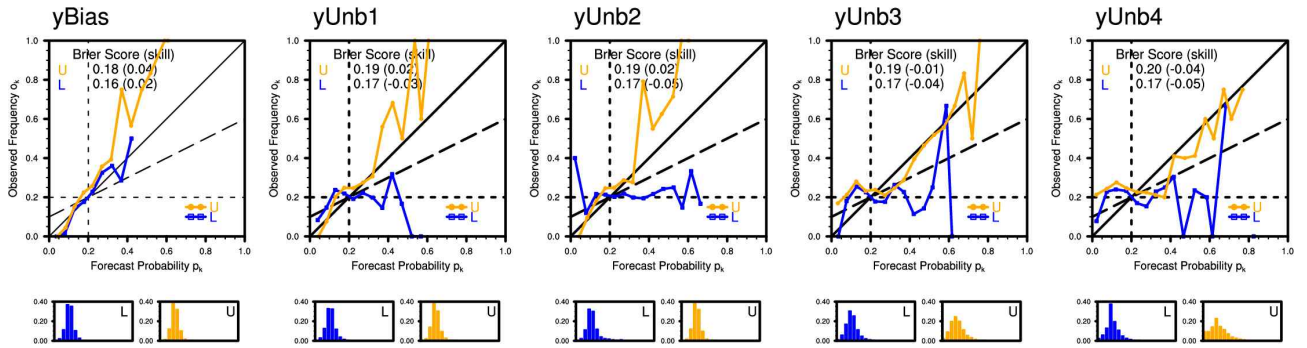


Figure 2.17. Same as Figure 2.13, but for precipitation.

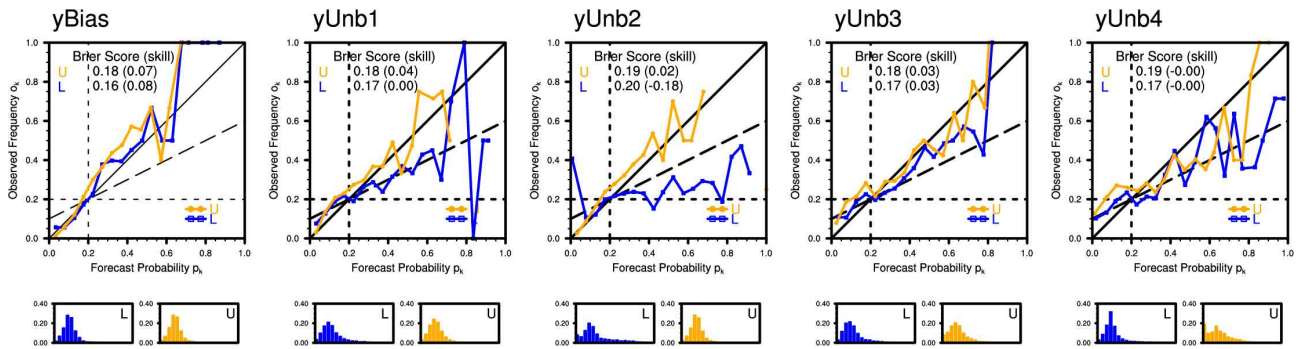


Figure 2.18. Same as Figure 2.14, but for precipitation.




Figure 2.19. Same as Figure 2.14, but for precipitation.




Figure 2.20. Same as Figure 2.15, but for precipitation.




Figure 2.21. ROC curves of extreme quintiles of monthly mean temperature at 2m in extra-tropics.




Figure 2.22. Same as Figure 2.21, but in tropics.




Figure 2.23. Same as Figure 2.21, but for precipitation.




Figure 2.24. Same as Figure 2.22, but for precipitation.

2.1.4. 물리적 임계 초과 확률 예측 및 검증

유의한 이벤트에 대한 예측정보를 생산하기 위해서, 원시 모델 자료 및 그랜드 앙상블의 바이어스를 보정하고 물리적 임계 초과 확률을 예측 및 검증하였다. 그 예시로서, Figure 2.25는 2016년 4월의 중위도 및 적도의 K 지역에 기온과 강수의 물리적 임계 초과 확률을 나타낸다. 2016년 4월 실제 이벤트는 관측으로 표시하였으며, 이때 특정 물리적 임계치에 대한 초과 확률을 관측, 보정 전후에 대해서 계산하였다. 그림에서 알 수 있듯이, 원시 모델 자료의 그랜드 앙상블은 유의한 바이어스를 가지므로 유의한 이벤트에 대한 예측을 하는데 있어서 적당하지 않음을 알 수 있다. 중위도 지역의 기온에 대한 원시 자료의 바이어스는 크지 않으므로, 보정 후 약간 성능이 좋아졌다(hit rate: 보정 전 0.88, 보정 후 0.91~0.93; false alarm: 보정 전 0.06에서 보정 후 0.04~0.08). 보정의 효과는 보정 방법에 따라 다른 자료 분포를 만들고, 이는 예측 성능의 차이를 만든다. 반대로, 원시 자료의 바이어스가 큰 적도 기온 같은 경우에는 예측 성능이 크게 개선된다(false alarm: 보정 전 0.39에서 보정 후 0.06~0.14). 강수의 경우에는 중위도 강수의 바이어스가 있는 자료가 관측의 분포와 가까워, 보정 후 예측 성능은 약간 향상된다(false alarm: 보정 전 0.16에서 보정 후 0.09~0.14). 하지만, 차이가 큰 적도 강수는 보정 후에 그 예측 성능이 크게 향상된다(hit rate: 보정 전 0.60, 보정 후 0.77~0.92). 즉, 바이어스 보정은 유의한 이벤트를 적당히 예측하기 위해서 잠재적인 역량을 가진 것으로 보인다. 특히 보정 방식에 무관하게, 관측에 비해 바이어스 클수록 잠재성은 보다 큰 것으로 보인다.

Figure 2.26-27은 특정 해가 아닌 전체 분석기관에 대한 물리적 임계 초과 확률의 성능을 타낸다. 보정 전/후의 앙상블 자료를 바탕으로 물리적 임계 초과 확률을 산출하고, 그 예측 성능을 검증하였다. 변수 및 지역에 무관하게 기후값 보정 이후에 확률 예측 성능 크게 향상되었다. 일반적으로 보정 방법들간의 성능차이보다 원시 자료와의 차이가 크므로 어떤 방법을 써도 무방할 것으로 보인다. 기온 예측의 경우, yUnb1과 분위사상법이 유사한 성능을 보이면, 강수의 경우에는 분위사상법이 단순보정에 비해 나은 예측 성능을 보인다. 이는 기온 및 강수의 자료 분포 특성상 기울어짐이 있냐 없냐의 차이가 있으며, 분위사상법이 기울어짐이 있는 자료에 더 효과적으로 작용하는 것으로 보인다.

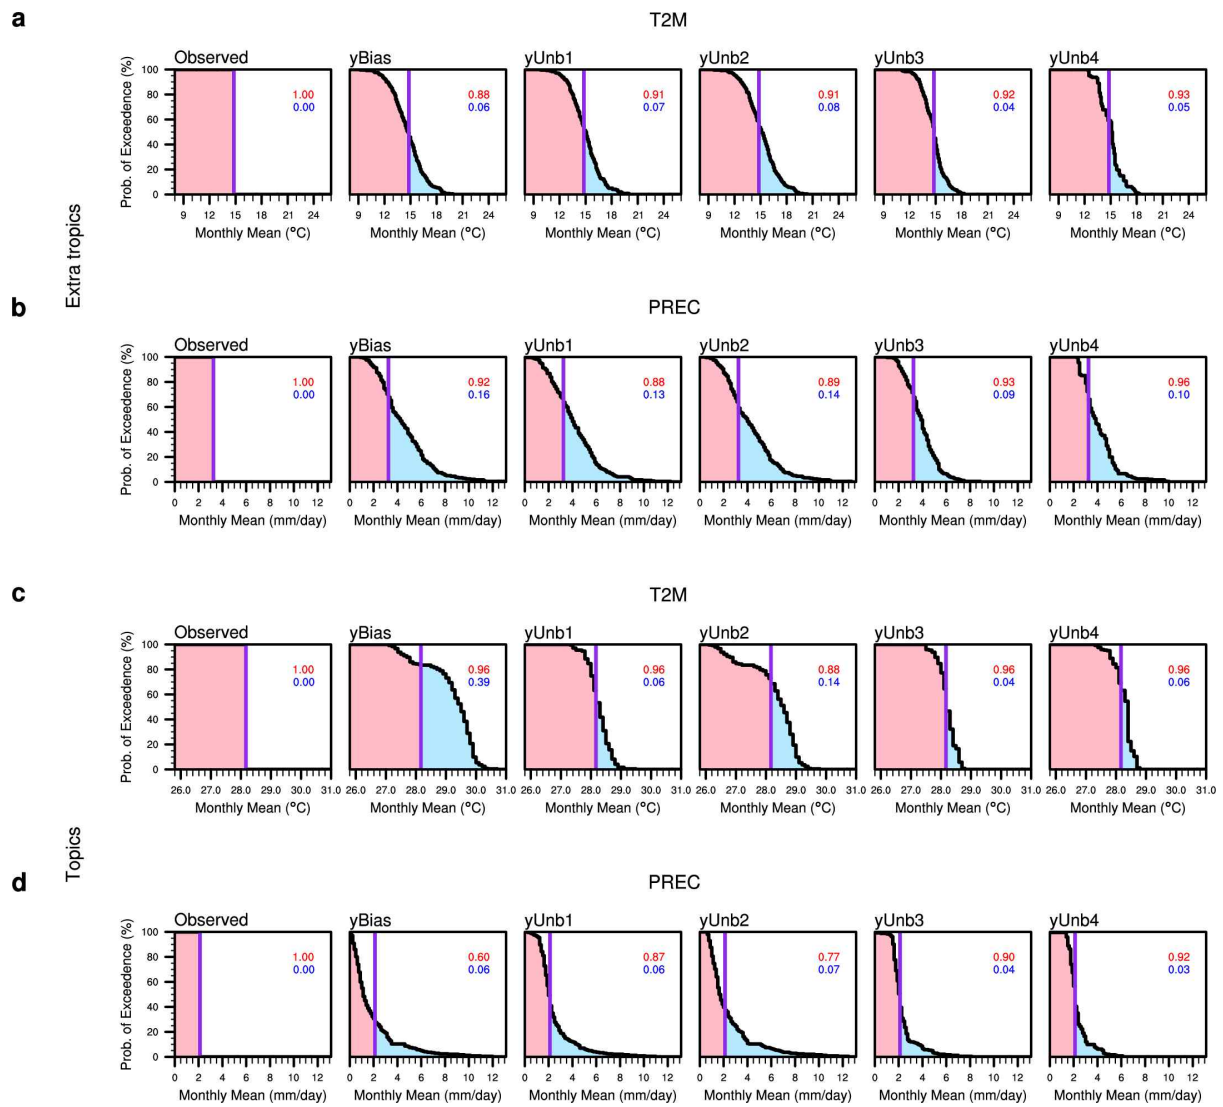


Figure 2.25. Probabilities of exceedance (PoE, units: %) for alternative thresholds of (a, c) April mean temperature at 2m (units: °C) and (b, d) precipitation (units: mm/day) of K region in (a, b) extra tropics and (c, d) tropics for the year of 2016, based on observations (in most left panels) and predictive datasets from yBias, yUnb1, yUnb2, yUnb3, and yUnb4 (in the second and sixth panels from the left).

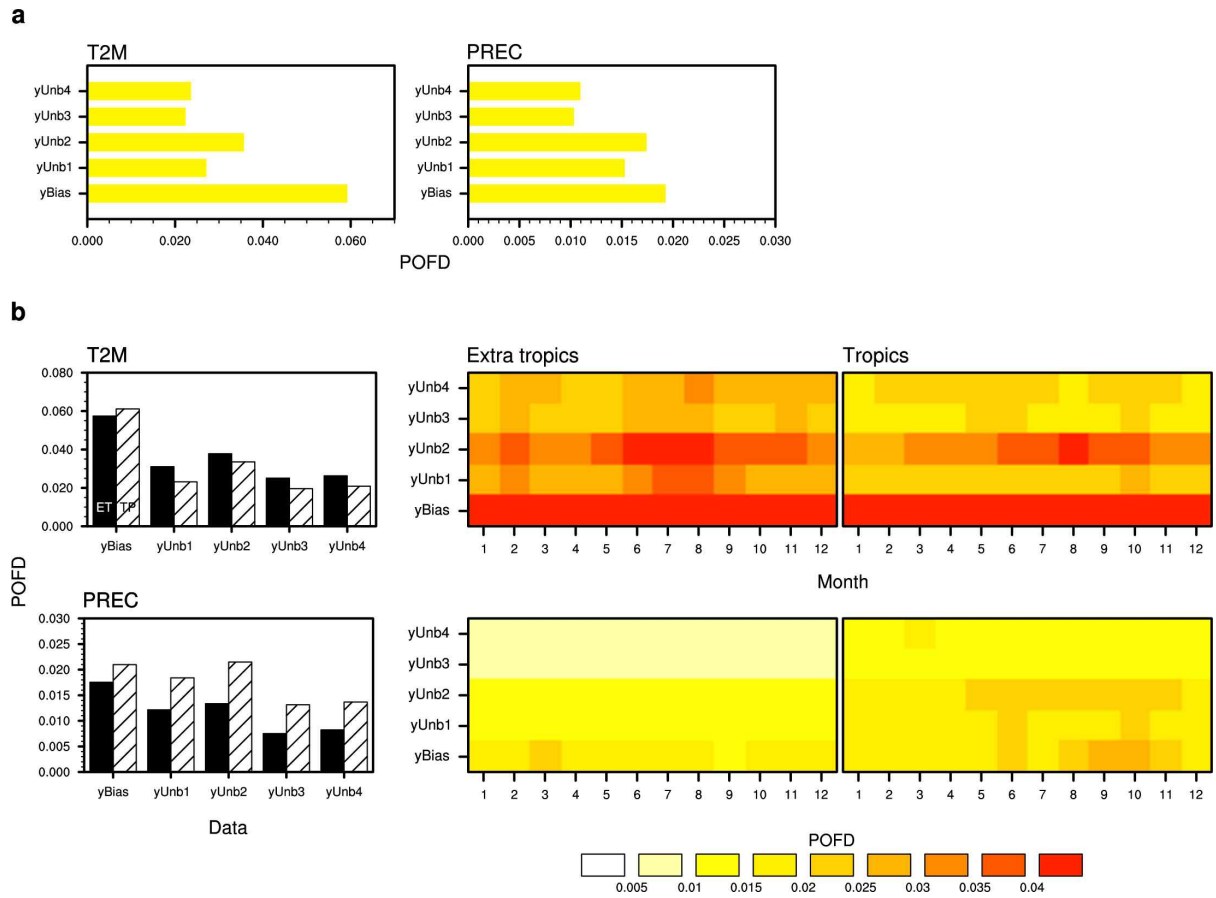


Figure 2.26. Same as Figure 2.8, but POFD skills of PoE forecasts.

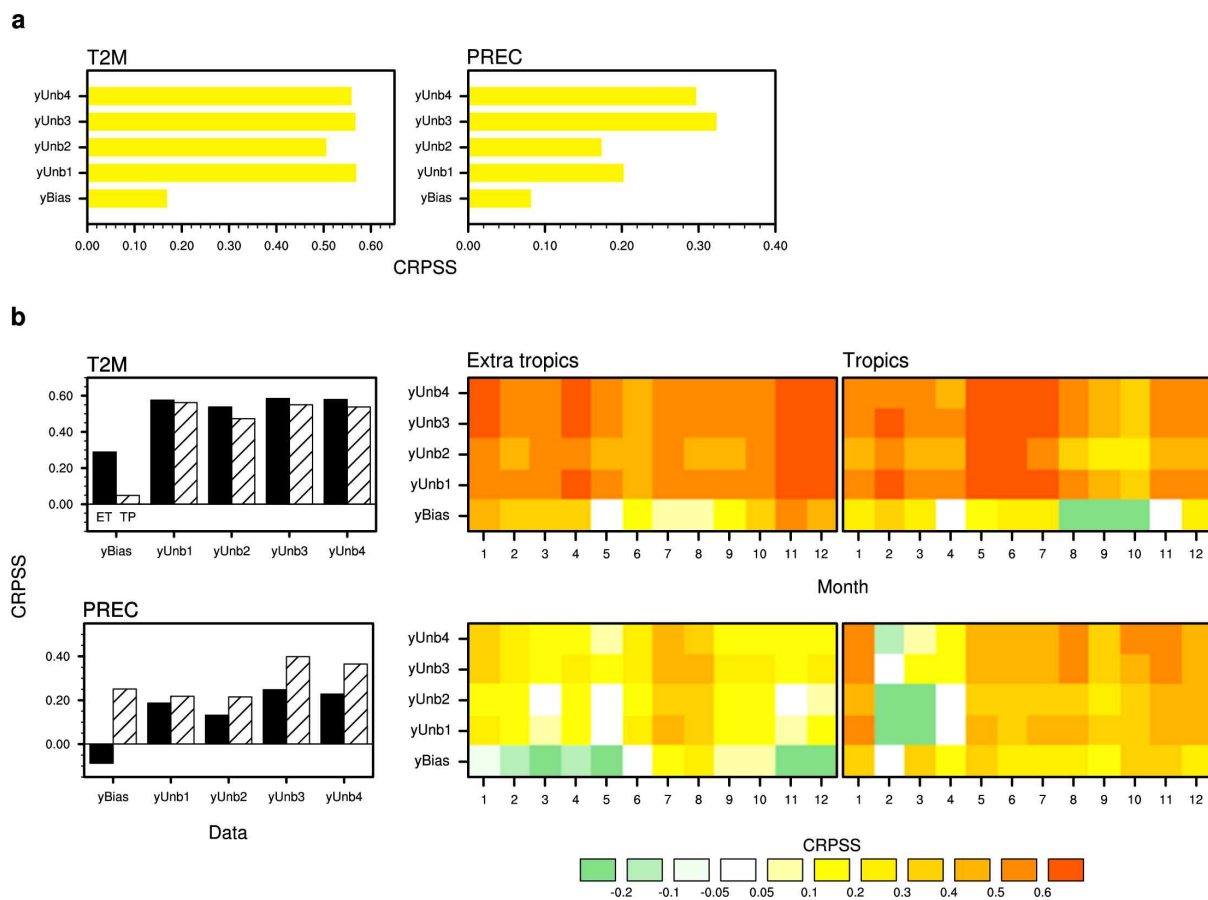


Figure 2.27. Same as Figure 2.8, but CRPSS skills of PoE forecasts.

2.2. 이상기후 대응을 위한 월 총 강수 및 월간 일 강수일수, 강수강도와의 관련성 분석

2.2.1. 배경 및 목적

기후변화는 전 지구적으로 강수패턴의 불확실성을 증가시키며, 집중호우, 홍수와 같은 극단적 강수 현상의 빈도와 강도가 높아지는 추세를 보이고 있다. 이로 인해 사회경제적 피해가 빠르게 확대되고 있으며, 이러한 극한강수에 대한 조기 감시와 예측 정보의 중요성이 그 어느 때보다 강조되고 있다. UN과 국제사회는 자연재난 및 기후위험 완화를 위해 조기경보 체계의 중요성을 강조하고 있으며(Early Warning for All), 이를 위해 세계기상기구(WMO)는 기후위험조기경보시스템(Climatic Risk Early Warning System, CREWS) 프로그램을 통해 다양한 이상기후 대응체계를 갖추도록 지원하고 있다.

이러한 흐름 속에서 전 세계 주요 기관들은 계절예측에서 기존의 3분위 기반 확률 정보뿐 아니라, 발생확률은 낮지만 영향은 큰 극한 강수 조건에 대한 예측 정보까지 제공하는 방향으로 확장하고 있다. 그러나 아태기후센터(APCC)에서 운영 중인 다중모델 앙상블(Multi Model Ensemble, MME)은 현재까지 월 단위 3분위 확률예측에 머물러 있어, 평년 대비 많다, 적다 이상의 강수 특성 진단이나 극한강수 위험성 판단이 어려운 구조적 한계가 있다.

극한강수 대응에 활용 가능한 새로운 예측 혹은 진단 정보 개발을 위해서는 보다 직접적으로 강수의 물리적 특성을 분해하고 이해하는 과정이 필요하다. 특히, 월 총강수량이 강수일수(빈도)에 의해 좌우되는지, 아니면 강수강도에 의해 결정되는지는 극한 강수 잠재력 평가에 있어 중요한 단서가 될 수 있다.

이에 본 연구는 1997-2024년 GPCP 일 강수 관측자료를 활용하여, 월 총강수량을 구성하는 요인이 월별, 지역별로 어떻게 달라지는지 규명하고, 특히 강수강도 변화에 의해 지배되는 지역을 극한강수 잠재지역으로 식별함으로써, 향후 APCC MME 예측정보의 이상강수 대응 활용성을 높일 수 있는 보조 진단정보를 발굴하는데 목적이 있다.

2.2.2. 자료 및 방법

본 연구에서는 Global Precipitation Climatology Project (GPCP) 일 강수자료를 활용하여 1997-2024년 기간의 월별 강수 특성을 분석하였다. 먼저 일 강수자료를 월 단위로 합산하여 월 총강수량을 산출하였으며, 0.1mm/day 이상의 강수가 기록된 날을 기준으로 월별 강수일수를 계산하였다. 또한 월 총강수량을 해당 월의 강수일수로 나누어 일 강수강도를 정의하였다. GPCP는 위성 기반의 관측 특성상 40도 이상의 위도에서 결측값이 빈번하게 나타난다. 따라서 분석의 신뢰성을 확보하기 위해 연구 대상 영역을 남위 40도에서 북위 40도로 제한하였다.

이와 같이 산출한 월 총강수량, 강수일수, 강수강도 간의 관계를 상관분석하여, 월별, 지역별로 어떤 강수 요인이 월 총강수량을 주도하는지를 평가하였다. 이를 바탕으로 강수강도가 주요한 역할을 하는 지역, 즉 극한 강수 발생 가능성이 상대적으로 높은 지역을 선별하고자 하였다.

2.2.3. 결과

우선, 산출된 월 총강수량(Amount, A), 강수일수(Occurrence, O), 강수강도(Intensity, I) 간의 관계를 파악하기 위해 세 변수 쌍의 상관계수를 월별로 계산하여 공간 분포로 나타내었다. 먼저 월 총강수량과 강수일수의 상관관계(Figure 2.28), 월 총강수량과 강수강도의 상관관계(Figure 2.29), 그리고 강수일수와 강수강도의 상관관계(Figure 2.30)를 제시함으로써, 각 변수 간의 기초적인 연관성을 월별로 비교하였다.

Figure 2.28, 2.29를 통해 확인할 수 있듯이, 월 총강수량과 강수강도의 상관계수가 강수일수와의 상관계수보다 모든 월, 대부분의 지역에서 더 높게 나타난다. 이는 연구 대상 대부분의 지역에서 월 총강수량의 변동이 강수일수보다는 강수강도의 변화에 의해 더 크게 좌우됨을 의미한다.

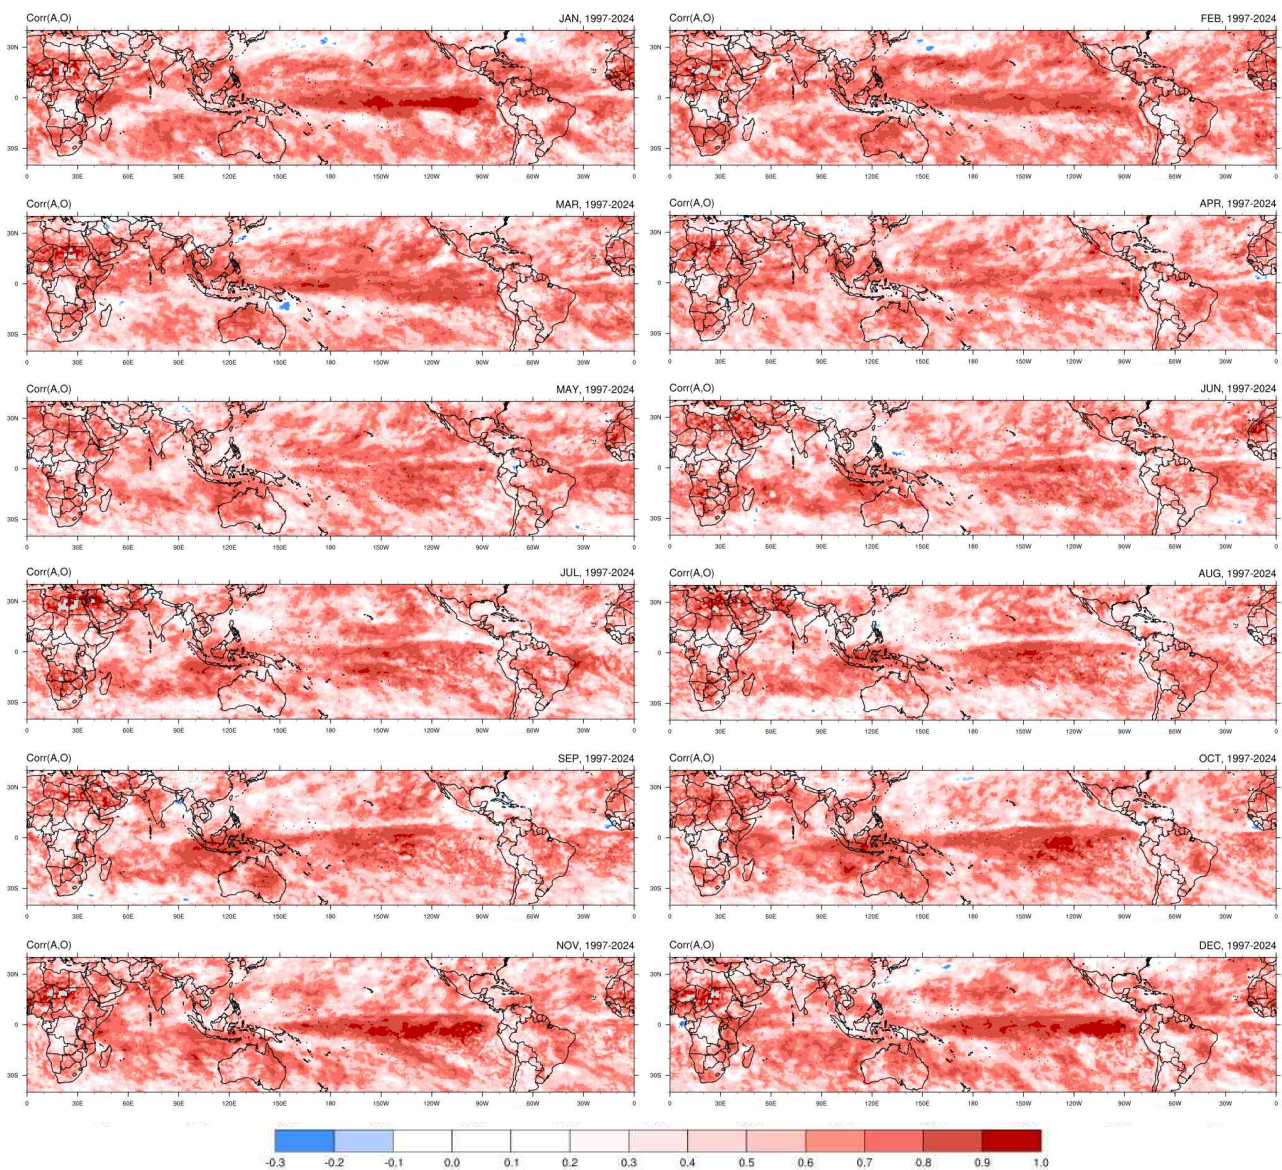


Figure 2.28. Spatial distribution of the correlation between total monthly precipitation (A) and the number of rainy days (O) for each month during the period 1997-2024.

Figure 2.28의 월 총강수량과 강수일수의 상관관계를 더 자세히 살펴보면, 지속적인 강수가 이어지는 ITCZ 지역에서 대체로 높은 양의 상관관계가 나타난다. 다만 이러한 상관관계 패턴은 ITCZ의 계절적 평균 위치와 완전히 일치하지는 않는데, 이는 적도 지역에서는 강수일수가 월별로 크게 변동하지 않아 계절적 이동 신호가 상관관계 패턴에서 뚜렷하게 드러나지 않기 때문이다. 또한 호주 내륙, 남아메리카 동부, 아프리카 일부 건조 지역 등 강수 발생 자체가 제한적인 지역에서도 강수일수 증가가 곧 월 총강수량 증가로 이어지기 때문에 비교적 높은 상관관계를 보인다.

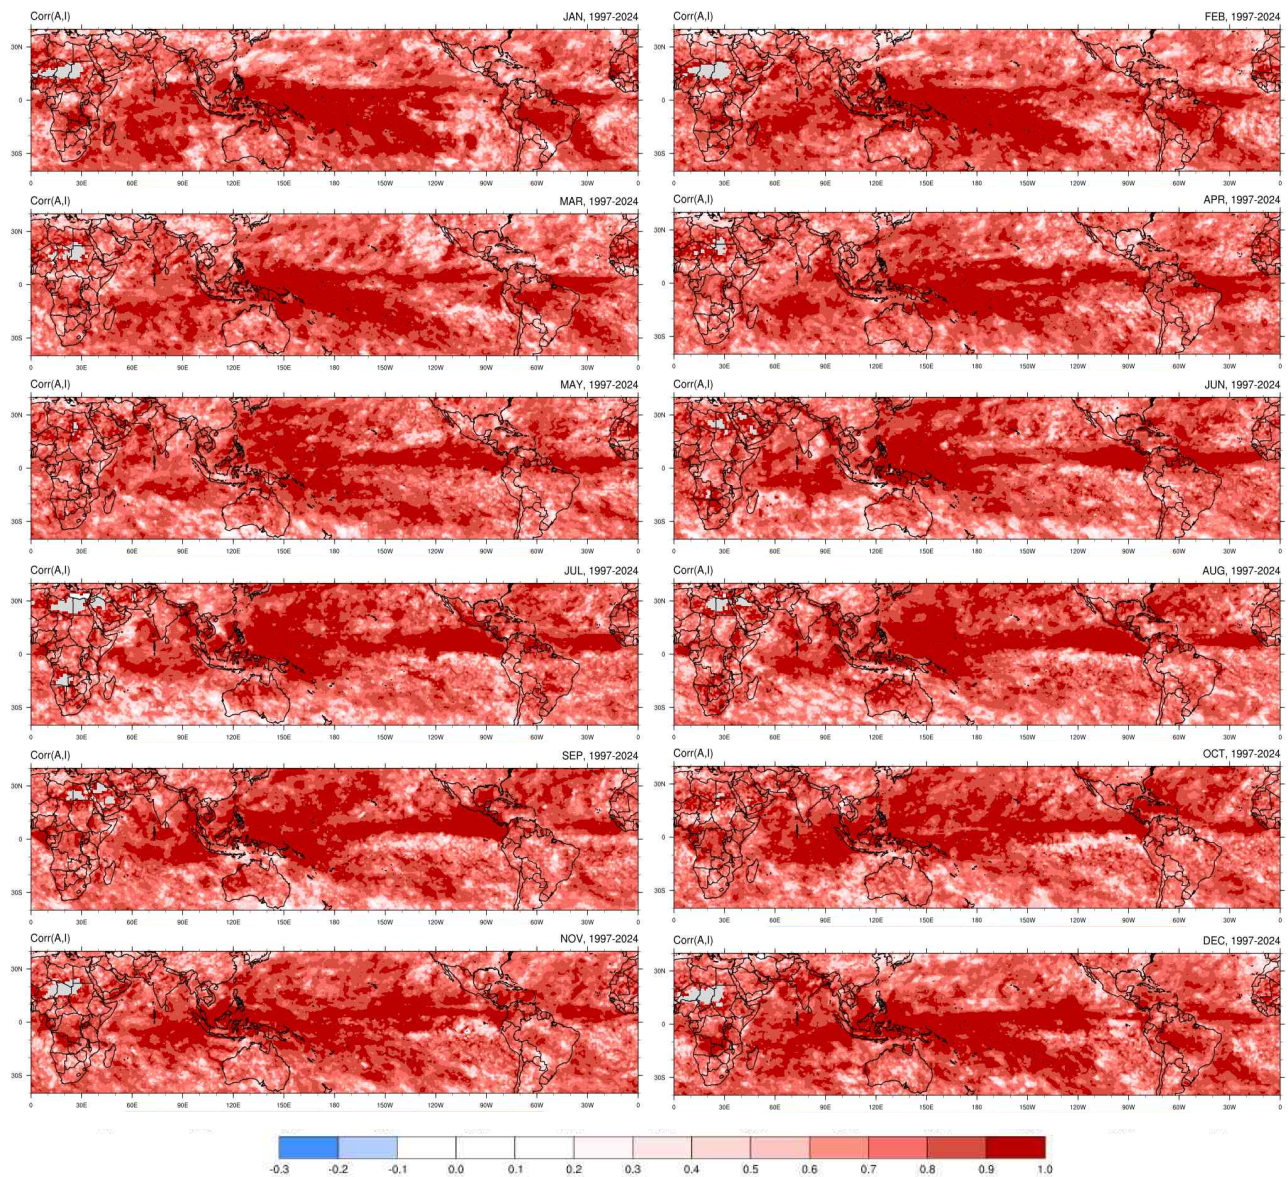


Figure 2.29. Spatial distribution of the correlation between total monthly precipitation (A) and precipitation intensity (I) for each month during the period 1997-2024.

반면, Figure 2.29에서의 월 총강수량과 강수강도의 상관은 월별 ITCZ 구조와 이동 패턴을 훨씬 잘 반영하는 모습을 보인다. 이는 적도 부근에서는 강수일수보다 강수강도의 변동이 월 총강수량 변화를 결정하는데 더 큰 역할을 하기 때문이다. 즉, ITCZ 내부는 비가 자주 오는 지역이라는 특성 때문에 강수일수는 비교적 일정하게 유지되는 반면, 강수강도의 변화가 월 총강수량의 증감과 직접적으로 연관되는 경향이 큰 것으로 보인다. 또한 북반구 겨울철에는 적도 수렴대에 더해 남서 태평양으로 뻗는 남태평양 수렴대(SPCZ)의 대류 강도 변화가 함께 작용하면서, 적도 및 서남태평양 지역에 걸쳐 보다 넓고 연속적인 양의 상관대가 형성된다. 이 시기 SPCZ는 강수강도의 계절적 변동이 뚜렷한 영역으로, 월 총강수량 역시 이 강도 변화에 크게 영향을 받기 때문에 해당 지역에서 높은 상관이 나타난다.

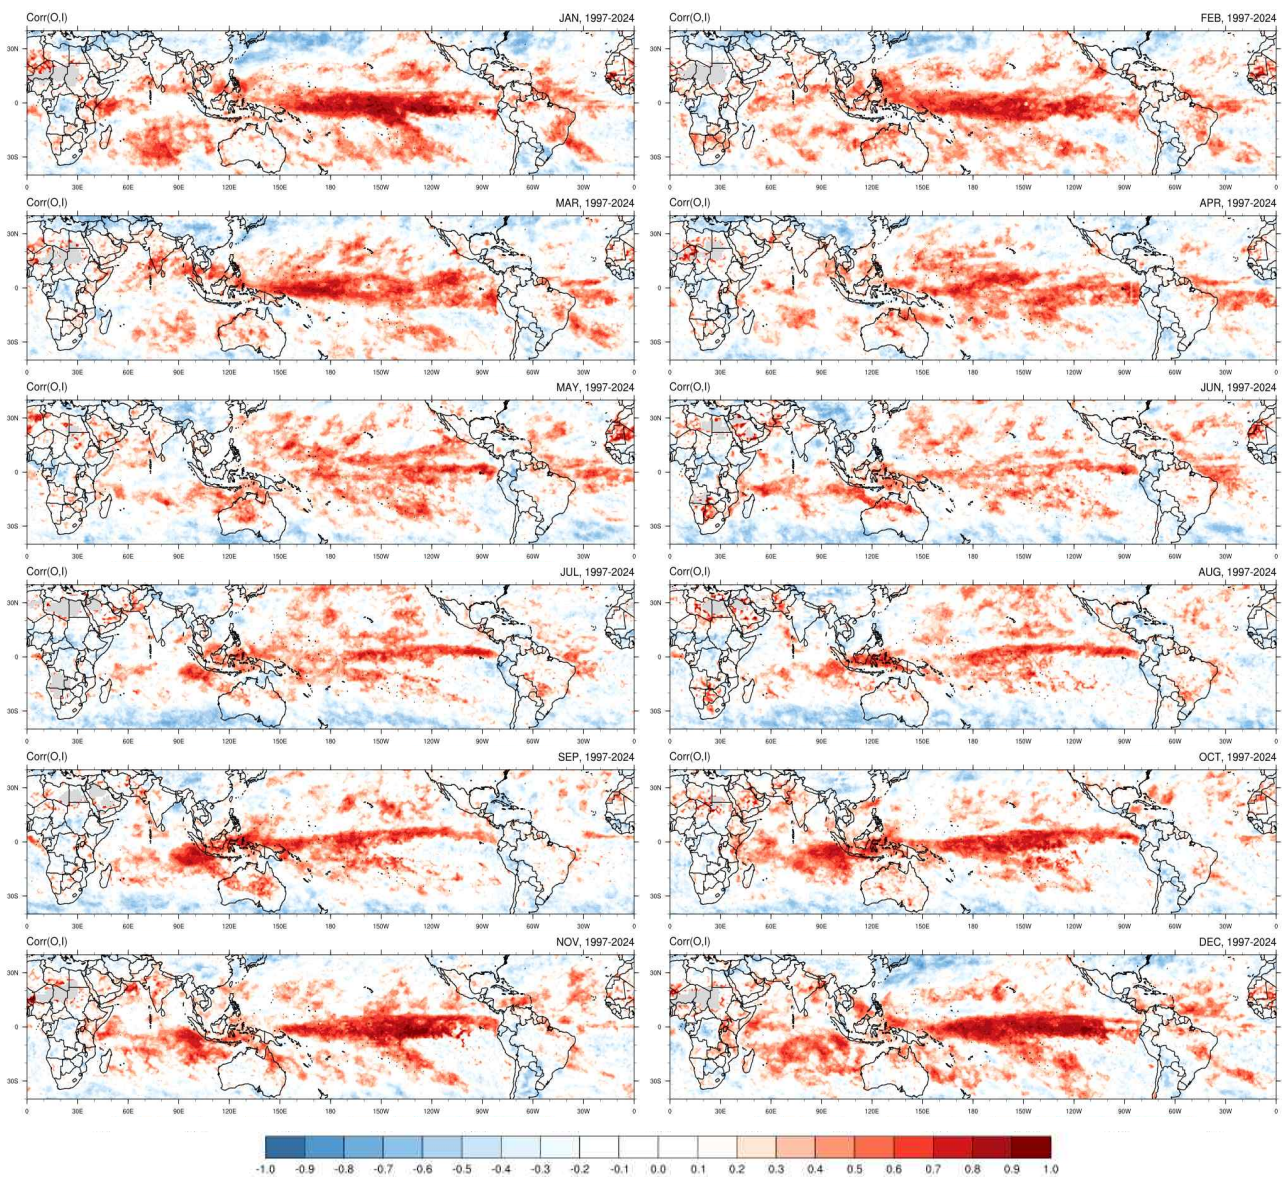


Figure 2.30. Spatial distribution of the correlation between the number of rainy days (O) and precipitation intensity (I) for each month during the period 1997-2024.

Figure 2.30의 적도 지역에서는 전반적으로 강수량이 많아 강수일수와 강수강도가 함께 증가하는 경향을 보이며, 이러한 양의 상관 구조는 계절에 따라 이동하는 ITCZ의 위치 변화와 대체로 일치한다. 예를 들어 8월에는 북반구 여름철 ITCZ가 북상함에 따라 양의 상관대가 적도선보다 북쪽에 형성되고, 2월에는 북반구 겨울철의 광역적 적도 수렴대와 SPCZ의 영향으로 적도 주변에 보다 넓은 범위의 양의 상관관이 나타난다. 아열대 지역에서는 계절에 따른 상관 구조의 차이가 나타난다. 여름철에는 대류성 소나기와 빈도 중심의 약한 강수가 혼재하여 강수일수와 강수강도가 함께 증가하거나 서로 독립적으로 변동하는 경우가 많아 일관적인 패턴이 보이지 않는다. 반면, 겨울철에는 강수일수가 전반적으로 적은 대신, 발생하는 강수는 비교적 강한 사건성 강수의 형태가 많아 양 반구 아열대에서는 겨울철에 공간적으로 연속적인 음의 상관대가 뚜렷하게 형성된다.

이러한 월별 상관 구조를 보다 명확하게 비교하기 위해, 월 총강수량과 강수강도(A-I) 간 상관계수에서 월 총강수량과 강수일수(A-O) 간 상관계수를 빼 두 변수의 상대적 기여도를 공간적으로 분석하였다. 또한 이 두 상관계수는 공통변수(A)를 공유하고 있기 때문에 일반적인 독립 표본 기반의 유의성 검정으로는 차이를 평가하기 어렵다. 따라서 공통변수를 포함하는 두 상관계수의 차이가 통계적으로 유의한지를 검정하기 위해 Steiger's Z-test를 적용하였다.

Figure 2.31을 살펴보면 월 총강수량이 강수일수보다 강수강도에 의해 더 크게 좌우되는 지역이 월별로 뚜렷하게 구분된다. 북반구 여름철에는 인도차이나반도에서 유의한 양의 값이 나타나는데 이는 몬순기 동안 강수일수는 지속적으로 높게 유지되는 반면, 대규모 대류 활동의 세기 변화가 커 강수강도 변동이 월 총강수량을 결정하는 주요 요인으로 작용하기 때문이다. 다만 7월에는 유의한 값이 나타나지 않는데, 이는 몬순 강수 구조의 변화나 태풍의 영향 여부 등 추가적인 분석이 필요하다. 북서대서양-카리브해 지역에서도 유의한 양의 값이 나타난다. 이 지역의 여름철 강수는 지속적으로 이어지는 빈도 기반 강수보다는 열대 요란과 같은 사건성 대류 활동에 의해 발생하는 경우가 많기 때문으로 분석된다. 북반구 겨울철에는 일본 동쪽 해역에서부터 북태평양 중위도 지역까지 연속적으로 유의한 양의 값이 나타난다. 이 지역은 겨울철 중위도 저기압 활동이 활발한 경로에 해당하며 강수일수는 많지 않지만 개별 저기압 통과 시 강한 상승 운동과 함께 강한 강도가 동반되는 강수가 집중되는 특징이 있다.

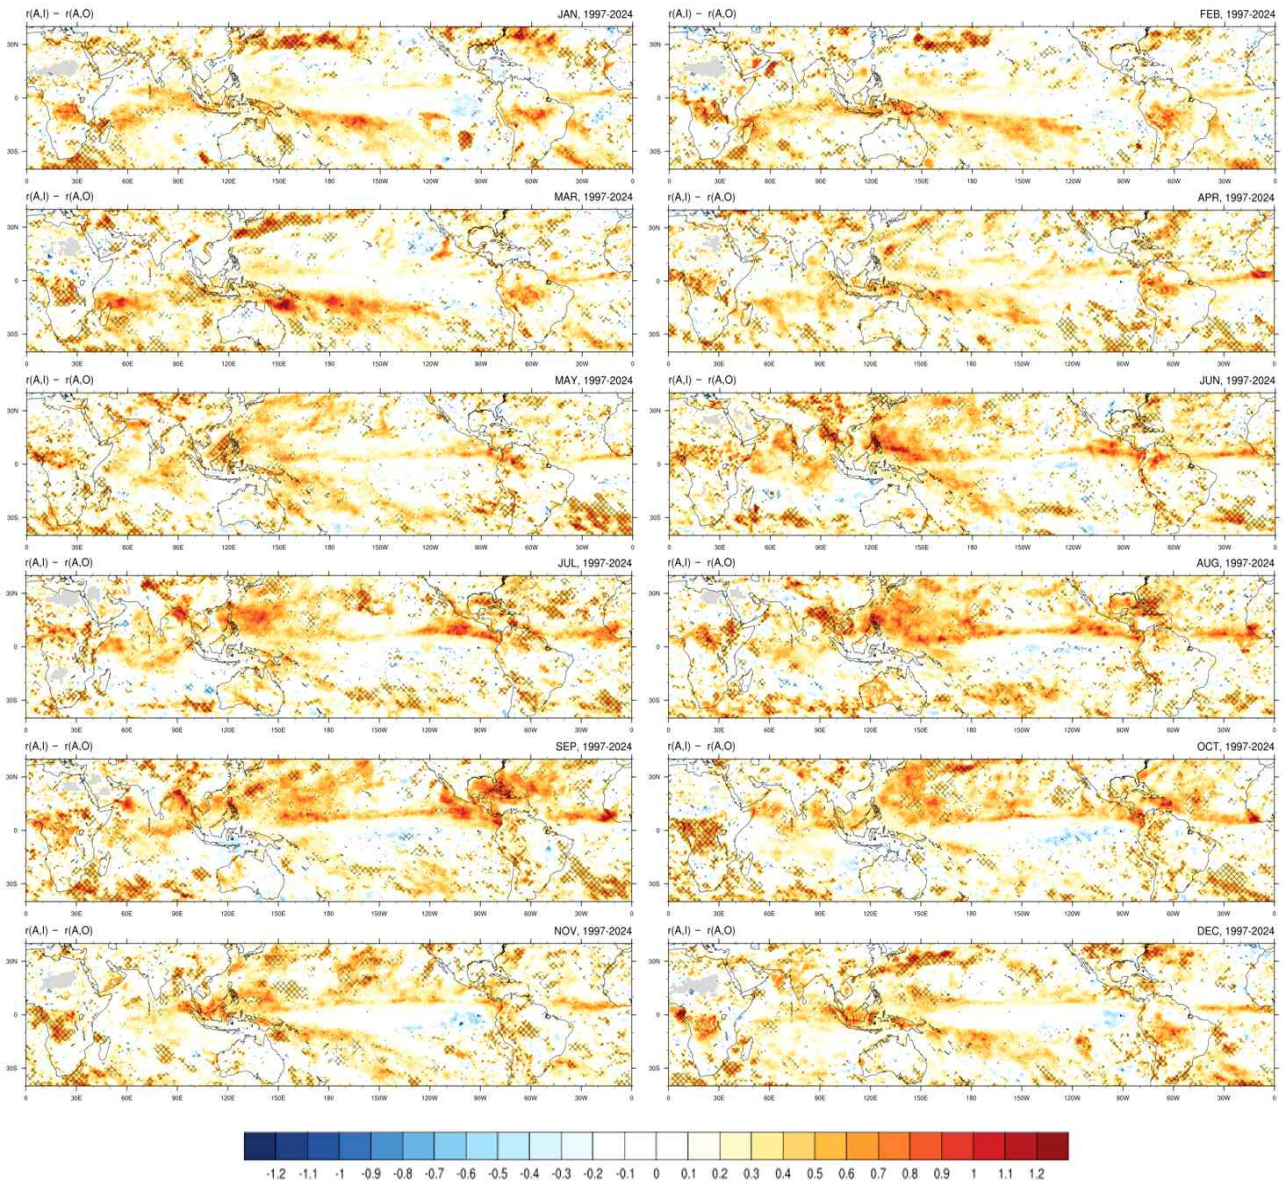


Figure 2.31. Spatial distribution of the difference between the correlation of total monthly precipitation with precipitation intensity and that with the number of rainy days, expressed as $r(A,I) - r(A,O)$, for each month during 1997–2024 (shading). Regions where the difference between the two correlations is statistically significant at 95% confidence level based on the Steiger’s Z-test are marked (hatching).

2.2.4 요약 및 결론

본 연구에서는 GPCP 일 강수량 자료를 이용하여 1997-2024년 기간 동안 월 총강수량이 강수일수와 강수강도 중 어느 요인에 의해 더 크게 결정되는지를 분석하였다. 월 총강수량과 상관관계를 살펴본 결과, 대부분의 지역과 월에서 강수강도가 강수일수보다 총강수량 변동을 더 잘 설명하는 경향이 나타났다. 적도 지역에서는 ITCZ의 계절적 이동과 함께 강수일수와 강수강도가 동시에 증가하는 양의 상관 구조가 관찰되었으며, 아열대 지역에서는 겨울철에 강수일수와 강수강도 간의 음의 상관이 나타났다. 강수강도와 강수일수의 상대적 기여도를 명확히 평가하기 위해 $r(A,D) - r(A,O)$ 를 계산하고 Steiger's Z-test를 적용한 결과, 강수강도가 월 총강수량을 지배하는 지역이 월별로 구분되었다. 여름철에는 인도차이나반도와 북서대서양-카리브해, 겨울철에는 일본 동쪽-북태평양과 북대서양 등에서 강수강도의 영향이 유의하게 나타났으며, 이는 해당 지역 강수가 사건성 강수나 중위도 저기압 활동 등 강도 중심 메커니즘에 의해 결정되는 특성을 반영한다.

향후에는 다른 강수 관측자료를 활용하여 동일한 분석을 수행함으로써 본 연구 결과의 신뢰도를 강화할 예정이다. 또한 도출된 극한강수 발생 가능지역이 실제로 MME 강수예측 결과와 결합되어 활용될 수 있는지를 평가하기 위해, 해당 지역에서 APCC MME 강수 예측이 어느 정도의 예측성을 보이는지 검증할 계획이다.

3. 계절예측 MME의 주요 기후모드 진단

3.1. 기후모드 연구 배경 및 목적

최근 전 지구적 기후변화가 가속화됨에 따라, 이상기후 현상의 발생 빈도와 강도가 점차 증가하고 있다. 이러한 변화는 단지 일시적인 현상이 아닌, 장기적 기후시스템의 구조적 변동 가능성을 시사하고 있으며, 이에 따라 기후 예측의 중요성은 그 어느 때보다도 커지고 있다. 아시아-태평양경제협력체 기후센터(APCC)에서 운영 중인 다중모델 앙상블 (Multi-Model Ensemble, MME) 기반의 계절 예측 시스템은 지난 20년간 기후 예측 분야에서 중요한 역할을 수행해 왔다.

MME 시스템의 장기적인 예측 성능에 대해 그동안 다수 연구에서 평가한 바 있으나 단편적인 예측성 평가 위주로 이루어져 왔다. 또한 주로 Hindcast 자료에 대한 분석으로만 이루어져 실제 예측에 사용되었던 실시간 예측(Real-time forecast)에 대한 예측성 평가는 부족한 실정이다. 지난 20년간 계절 예측 시스템을 운영해 오는 동안 MME에도 변화가 있었는데, MME에 참여하는 모델 수가 증가하고 일부 모델은 개선되었으며, Hindcast 기간에도 변화가 있었다. 따라서 조금 더 최근 기간이 반영된 Hindcast에 대한 분석과 그동안 생산해 온 실시간 예측에 대한 MME 시스템의 장기적인 예측 성능에 대한 종합적이고 체계적인 평가가 필요한 시점이다.

기후예측모델에서 생산되는 예측 정보는 기온, 강수 등의 변수에 대한 결정론적 혹은 확률론적 예측 정보이며 예측성 평가도 이러한 변수 위주로 이루어져 왔다. 그러나 실제 예보를 생산하는 과정에서 활용성을 높이기 위해서는 지역 기후에 영향을 미치는 순환장에 대한 평가가 중요하다. 특히 해양과 대기의 주요 기후모드들은 그 자체가 모델 예측성의 주요 소스가 되기도 하면서 기후모드와 관련된 원격 상관은 전세계에 영향을 미치기 때문에 모델의 기후모드 예측성을 평가하고 이들의 원격 상관을 이해하는 것은 예측 활용에서 필수적인 부분이다.

이 연구의 목적은 APCC MME에서 모의되는 주요 기후모드들의 예측성을 진단하고 모델에서 모의하는 기후모드에 대한 원격 상관 반응을 평가해, 모델의 예측 특성을 면밀하게 이해하고 모델 예측 정보의 해석 방안을 도출해 계절 예측의 활용성을 높이는 데 있다. 기후모드에 대한 모델 반응의 이해도를 높이기 위해서는 기후모드 자체를 모델에서 어떻게 모의하고 있는지에 대한 이해가 바탕이 되어야 하며, 최근 기간의 자료에 대한 분석이 이루어져야 변화하는 변동성을 고려한 계절예측의 생산과 해석이 가능할 것이다. 이 연구는 그중 첫 번째 단계로 모델에서 모의하는 기후모드 자체에 대한 예측성을 진단하고자 한다. 이를 위해 APCC MME 예측자료에서 가장 최근 기간이 반영된 Hindcast 자료와 과거부터 현재까지 축적해 온 실시간 예측자료를 활용하여, 모델의 해양과 대기 기후모드의 예측 특성을 분석하였다.

3.2. 자료 및 분석 방법

연구를 위해 사용된 모델 자료는 APCC MME와 MME에 참여한 개별 모델의 Hindcast와 실시간 예측자료(Real-time forecast)를 이용하였다. Hindcast는 가장 최근 버전인 2024년 자료를 이용하였으며 분석 기간은 2025년 8월부터 변경 적용된 hindcast 기간인 1993~2016년에서 이루어졌다. Table 3.1은 hindcast 분석에 사용된 모델들로, 현재 APCC MME에 참여 중인 개별 모델 중 해양-대기 모델이 1-Tier 모델이고 hindcast 기간을 충족하는 참여모델 11개를 나타낸 것이다.

Table 3.1. List of participating models and their hindcast periods.

	Institute and Model name	Hindcast period
1	APCC_SCOPS	1982~2016
2	BOM_ACCESS-S2	1981~2018
3	CMCC_SPS3.5	1993~2016
4	CWA_TCWA1Tv1.1	1991~2020
5	ECCC_CANSIPsv2.1	1990~2020
6	JMA_MRI-CPS3	1991~2020
7	KMA_GLOSEA6GC3.2	1993~2016
8	METFR_SYS8	1993~2016
9	NASA_GEOS-S2S-2.1	1981~2016
10	PNU-RDA_CGCMv2.0	1980~2022
11	UKMO_GLOSEA6	1993~2016

실시간 예측자료는 예측 시점에 생산되어 실제 배포되었던 자료로, 가용한 해수면온도 자료가 있는 2012년 이후부터 2025년 최근 자료까지 사용되었다. 기온이나 강수와 같은 대기 변수의 경우 APCC가 MME를 생산하기 시작한 2008년부터 자료가 있으나, 해수면온도에 대한 자료 수집 및 MME 생산은 그 이후에 이루어졌기 때문에 일부 개별 모델은 2012년부터, MME 자료는 2013년 중반부터 자료를 확보할 수 있었다. 또한 해양 기후모드의 경우 대기보다 더 긴 리드에서도 예측성을 볼 수 있기 때문에 MME는 6달 예측자료를 사용했고 개별 모델도 6달 혹은 5달의 리드를 갖고 있는 모델 자료를 사용했다.

Table 3.2는 APCC MME에 참여하는 모델 중 분석에 사용된 실시간 예측자료의 생산 기관과 사용 가능한 자료의 첫 번째 예측 연도를 나타낸다. 중간에 이름이 변경된 기관의 경우 현재 사용되는 기관명과 이전 기관명을 함께 표기하였다. Hindcast 자료와 마찬가지로 해양 모델이 없는 경우는 분석에서 제외하였다. 실시간 예측자료는 중간에 모델이 개선되거나 변경되기도 하고, MME의 경우 예측 생산 시점에서 수집 완료된 모델만으로 예측자료를 생산하기 때문

에 사용된 모델들이 항상 동일하지는 않다. 따라서 동일한 조건에서 생산된 자료는 아니기 때문에 결과를 해석할 때 주의가 필요하다.

Table 3.2. List of participating institutes and their available year for real-time forecast.

	Institute	available since
1	APCC	2014~
2	BCC	2016~
3	BOM(POAMA)	2012~
4	CMCC	2014~
5	CWA(CWB)	2018~
6	ECCC(MSC)	2016~
7	JMA	2012~
8	KMA	2020~
9	METFR	2021~
10	NASA	2012~
11	NCEP	2012~
12	PNU-RDA(PNU)	2013~
13	UKMO	2020~

모델과의 비교를 위해 사용한 관측 재분석 자료로 대기 변수는 NCEP-NCAR Reanalysis 1 자료와 NCEP/DOE Reanalysis 2 자료를 사용하였다. 해수면온도 (Sea Surface Temperature; SST)는 NOAA (National Oceanic and Atmospheric Administration)에서 제공하는 OISST (Optimum Interpolation SST) V2 자료를 사용하였고, 강수 자료는 CAMS OPI (Climate Anomaly Monitoring System and OLR Precipitation Index) 자료와 Global Precipitation Climatology Project (GPCP) version 2.3 자료를 사용하였다.

자료 분석 방법으로는 합성장 분석, 상관분석, 회귀분석, 경험적 직교함수(Empirical Orthogonal Function; EOF) 등의 통계분석 방법이 사용되었다. 모델의 예측성은 PCC (Pattern Correlation Coefficient), TCC (Temporal Correlation Coefficient), RMSE (Root Mean Squared Error), Mean Error, RCC (Ranked Correlation Coefficient) 등으로 평가했다.

3.3. 열대 태평양 기후모드

3.3.1. 열대 태평양 기후모드 선정

열대 태평양에서 가장 중요한 기후모드는 동태평양 해수면온도 편차가 양의 값과 음의 값으로 변동하는 El Nino-Southern Oscillation (ENSO)이다. ENSO는 북반구 겨울철 최성기에 이르며 약 2년에서 7년을 주기로 발생한다. ENSO 현상 자체는 열대 태평양에서 발생하는 기후 변동성이지만 그 영향은 전 지구적으로 크게 미치는 가장 중요한 대기-해양 결합 모드이다. 또한 계절예측 모델에서 열대지역의 강제력은 매우 중요한 예측 원천으로 작용하기 때문에 계절예측에서 ENSO의 예측 성능 향상은 매우 중요하다.

계절예측 모델에서 ENSO의 예측성은 지난 수십 년 동안 향상되어 왔으며 다른 기후모드에 비해 뛰어난 것으로 알려져 있다 (e.g. Barnston et al. 2012, Tippett et al. 2019). APCC MME의 ENSO 예측성에 대해서도 기존에 선행 연구들에서 다룬 바 있다 (e.g. 김선태 등 2018, Sohn, 2016). APCC MME의 ENSO 예측성에 대한 연구는 주로 ENSO의 대표 지수인 Nino3.4 지수에 대해서만 평가되었고 모델의 Hindcast에 대해서만 평가되었다. 최근 온난화 및 기후변화로 인해 ENSO 예측과 ENSO 반응에 대해 알려진 지식들이 실제 현상과 맞지 않는 경우도 발생하고 있어, 모델의 최근 기간 예측자료를 최대한 반영한 예측성 평가가 필요하다.

3.3.2. Hindcast 기간 열대 태평양 기후모드 예측성 평가

모델의 ENSO 예측성을 살펴보기에 앞서 모델의 해수면온도 평균장에 대한 오차를 확인하였다. Figure 3.1은 적도 태평양 해수면 온도 연변동의 모델과 관측의 차이를 나타낸다. 적도 태평양 해수면온도는 봄철 가장 따뜻했다가 가을철 차가워지는 연변동을 하는데, 거의 모든 모델에서 동태평양에 한랭 편차(cod bias)가 나타났다. 리드가 증가할수록 한랭 편차의 강도는 강해졌는데 편차가 나타나는 시기는 모델마다 차이가 있었다. 리드-1에서는 대부분 한랭 편차가 가을철에 나타났으나 리드-5에서는 여름에 나타나거나 봄에 나타나는 등 모델마다 차이가 있었다. 이러한 차이는 모델에서 리드가 길어짐에 따라 해수면온도의 연변동이 달라지며, 모델간의 차이도 증가함을 의미한다. 적도 태평양에서 한랭 편차는 적도 무역풍 편차와 관련되어 있고 바람 편차는 해수면온도에 영향을 주기 때문에 모델의 ENSO 모의에도 영향을 줄 수 있다.

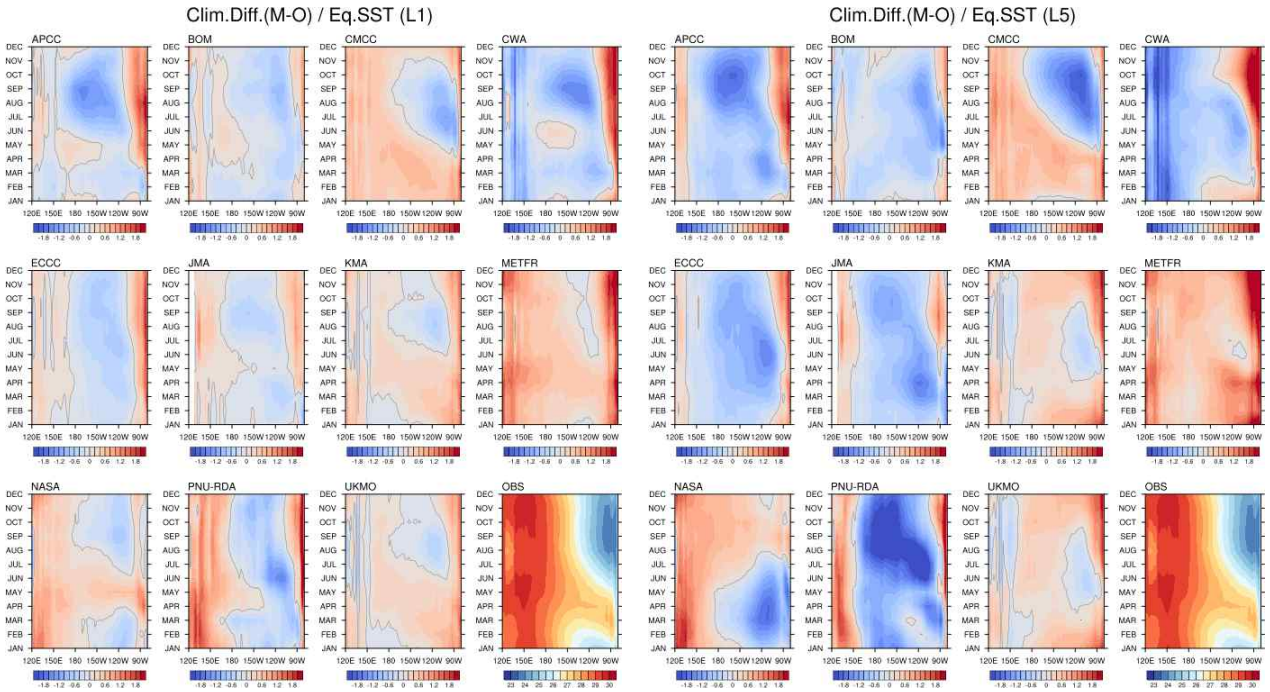


Figure 3.1. Differences of the SST annual cycle bias between Model and Observation, and the SST annual cycle of the observation(last panel) in the equatorial (5S-5N average) Pacific.

모델의 ENSO 예측성을 다양한 Nino 지수들에서 살펴보았다. ENSO를 대표하는 지수로 적도 중동태평양 지역 해수면온도 편차를 평균한 Nino3.4 지수가 널리 사용되고 많은 기관에서 ENSO 예측에 Nino3.4 지수를 사용하지만, ENSO의 다양한 특징을 한 지수만으로 살펴보기는 어렵기 때문에 다른 Nino 지수들과 함께 살펴보았다. Nino 지수들의 영역은 다음과 같다. Nino1+2 (90W-80W, 10S-0), Nino3 (150W-90W, 5S-5N), Nino3.4 (170W-120W, 5S-5N), Nino4 (160E-150W, 5S-5N), NinoW (130E-150E, 0-10N). NinoW는 일반적으로 널리 사용되는 지수는 아니지만 서태평양의 대류 활동이 활발한 지역의 해수면온도 예측성을 보기 위해 추가하였다.

Figure 3.2는 Nino 지수들의 시간 상관계수를 리드에 따라 나타낸 것이다. 막대로 표시된 MME의 상관계수는 리드-1에서 Nino3.4 지수 0.97로 매우 높았고 Nino3, Nino4 지수 0.95, Nino1+2 지수 0.91로 높은 예측성을 나타냈다. NinoW 상관계수는 0.82로 다른 Nino 지수들보다는 낮았지만 높은 값을 나타냈다. 지수의 상관계수는 리드가 길어질수록 감소했는데, 리드-6에서 Nino3.4 0.85, Nino3 0.81, Nino4 0.83으로 주로 많이 사용되는 Nino 지수들은 긴 예측 선행 시간에서도 비교적 높은 예측성을 보였다. 반면 동태평양과 서태평양 양극단의 지수들은 선행 시간이 길면 예측성이 더 낮아졌는데 리드-6에서 Nino1+2 0.67, NinoW 0.67을 나타내 다른 Nino 지수들보다 낮은 예측성을 보였다. NinoW 지수의 경우 상관계수가 다른 지수들보다 낮았으나 예측 선행시간이 증가해도 상관계수의 감소가 다른 지수들보다 크게 나타나지 않았다.

개별 모델들의 Nino 지수 시간 상관계수는 MME와 비슷하게 나타났으나 일부 모델은 다른 모델보다 리드-1에서부터 다소 낮은 상관계수를 보였고 선행시간이 길수록 그 차이는 더 증가했다. 상관계수가 낮은 모델은 다른 모델과의 차이가 Nino1+2, NinoW 지수에서 더 크게 나타

났는데 이들 두 지역은 남아메리카 대륙과 서태평양 도서 지역에 맞닿아 있는 곳으로 육지나 섬과 가까운 지역에서의 해수면온도 예측성이 다른 모델보다 떨어지는 것으로 보인다. 예측성이 떨어지는 몇몇 모델의 영향으로 Nino1+2와 NinoW 지수는 개별 모델에서 MME보다 예측성이 높게 나타나는 모델들이 있었다.

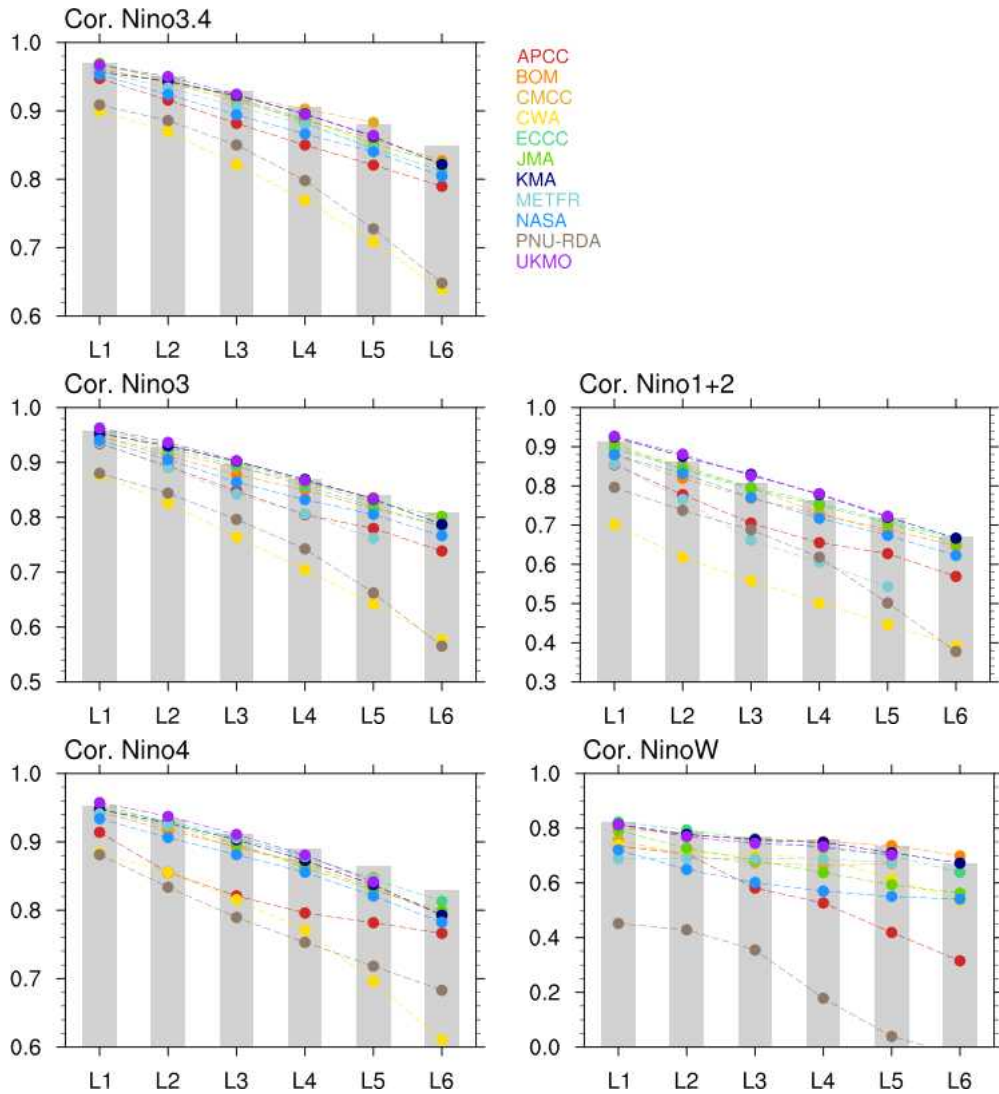


Figure 3.2. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, Nino4, and NinoW indexes between the model and observation for the hindcast lead-1 to lead-6. Gray bar is for MME and color dot-lines are for individual models.

Nino 지수들의 월별 리드별 예측성을 시간 상관계수로 살펴보았다. Figure 3.3은 MME Nino 지수들의 월별 시간 상관계수를 예측 출발 시점부터 리드-6까지 나타낸 것이다. 전체 월에 대한 상관계수와 마찬가지로 월별로도 Nino3.4 지수가 가장 예측성이 높았고 Nino4, Nino3 지수도 높게 나타났다. Nino3.4, Nino3, Nino4 지수는 겨울철 예측의 경우 긴 선행시간에서도

상관계수가 크게 떨어지지 않고 높은 예측성을 보였다. 그러나 늦겨울~봄에 출발한 봄~초여름 예측에서는 선행시간이 길어질수록 상관계수가 감소했는데 이 시기는 ENSO가 최성기를 지나 소멸하거나 반대 위상으로 전환되는 시기로 이전 연구들에서도 제시했던 봄철 예측성이 떨어지는 부분이 MME에서도 나타남을 확인하였다. 봄철 상관계수의 감소는 Nino4 지수보다는 Nino3.4와 Nino3 지수에서 더 크게 나타나 중태평양보다 동태평양 쪽으로 갈수록 봄철에 예측성이 더 낮아졌다. 더 동쪽에 위치한 Nino1+2 지수는 Nino3 지수보다 이른 2월부터 상관계수가 감소했는데 선행시간 길이와 관계없이 다른 월보다 낮은 상관계수를 보여 ENSO 소멸 시기의 동태평양 해안 지역의 예측성이 낮음을 알 수 있었다. NinoW 지수는 Nino 지수들 중 가장 낮은 상관계수를 나타냈고 다른 지수들과 다르게 12월 상관계수가 리드와 관계없이 낮게 나타났다. 열대지역 해수면온도는 강수와 밀접하게 관련되어 있고 서태평양 지역의 강수는 동아시아 순환장에 영향을 미치기 때문에, 해수면온도의 예측성이 떨어지면 결국 우리나라를 포함한 동아시아 지역 예측성도 떨어질 수 있다. 개별 모델들의 Nino 지수 예측성은 MME와 유사한 경향을 보이며 겨울철 예측성이 높고 봄철 예측성이 떨어지는 특징을 보였다(Figure 3.4). 모델들 간의 차이는 겨울철보다는 예측성이 낮은 봄철과 여름철 크게 나타났고, Nino1+2와 NinoW에서 큰 차이를 보였다.

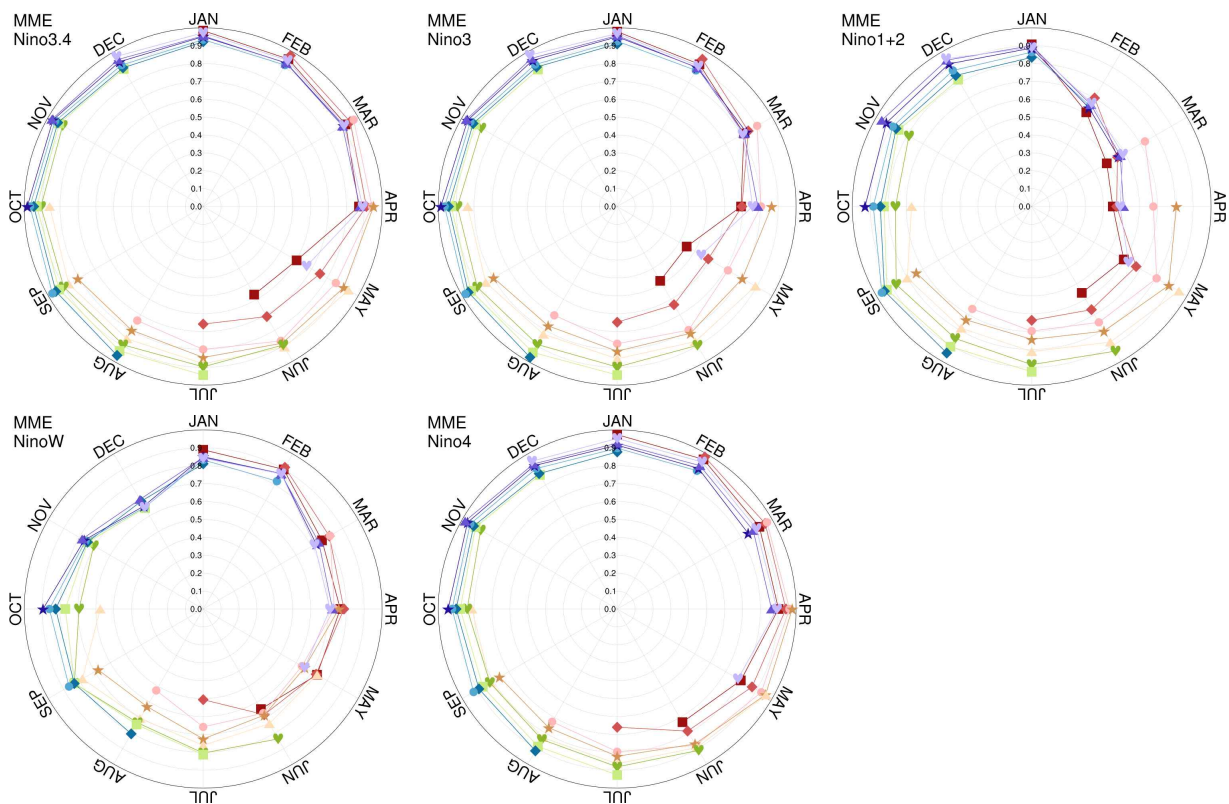


Figure 3.3. Temporal correlation coefficients of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME and observation for the hindcast.

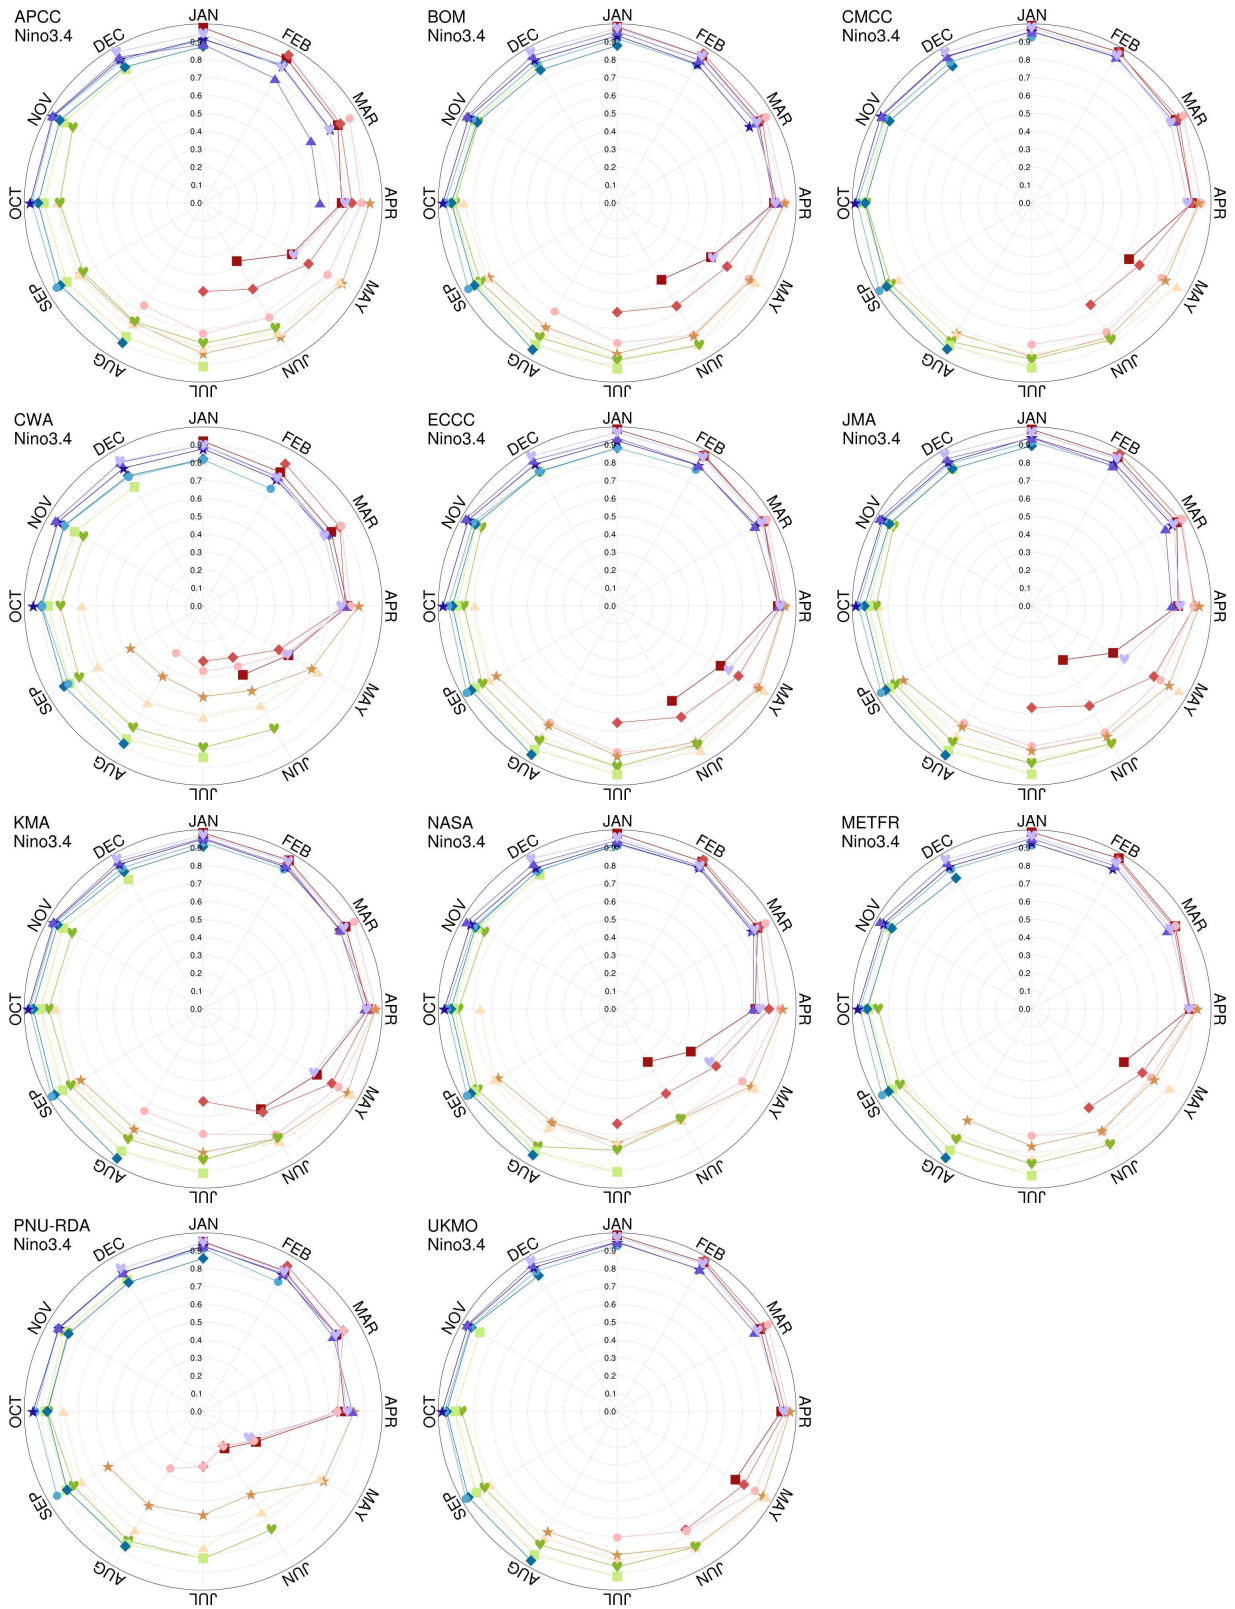


Figure 3.4. Temporal correlation coefficients of the monthly Niño3.4 index between the individual models and observation for the hindcast.

Figure 3.5는 MME Nino 지수들의 평균 제곱근 오차(RMSE)를 나타낸 것이다. 그림에서 같은 색으로 표시 값은 같은 시점에 출발한 예측을 의미한다. Nino 지수들 중 RMSE가 가장 큰 지수는 Nino1+2 지수였는데 4월에서 7월 사이 가장 큰 오차를 나타냈다. 다른 지수들은 특정월에 오차가 증가하기보다는 예측 시간이 길어질수록 오차가 증가하는 것으로 나타났다. 오차의 범위는 지수들 마다 차이가 있었는데 이는 각 지수들의 변동 폭 자체에 차이가 있기 때문이다.

Figure 3.6은 Nino3.4, Nino4, Nino1+2 지수의 표준편차를 나타낸다. 오차가 작았던 Nino4 지수는 표준편차도 작았다. Nino4 지수의 월별 표준편차는 리드-1에서 대부분 모델이 관측보다 크게 나타났고 선행시간이 긴 리드-5에서도 다수는 관측보다 컸으나 일부 관측보다 작아진 모델도 있었다. 오차가 컸던 Nino1+2 지수는 표준편차도 컸는데, 관측에서 4월부터 12월까지의 표준편차 1이상으로 변동폭이 컸고 1월부터 3월 사이에는 1보다 작아 다소 감소했다. 모델에서도 이러한 월 변화는 따라갔으나 값은 차이가 있었는데 관측보다 변동폭이 큰 모델과 작은 모델이 섞여 있어 모델간의 차이도 컸다. NASA모델의 경우 거의 Nino3.4와 Nino4 지수 모두 리드-1부터 관측보다 표준편차가 크게 나타났으며 리드-5에서는 표준편차가 더 증가해 선행시간이 길어질수록 변동폭을 크게 모의하는 것으로 나타났다.

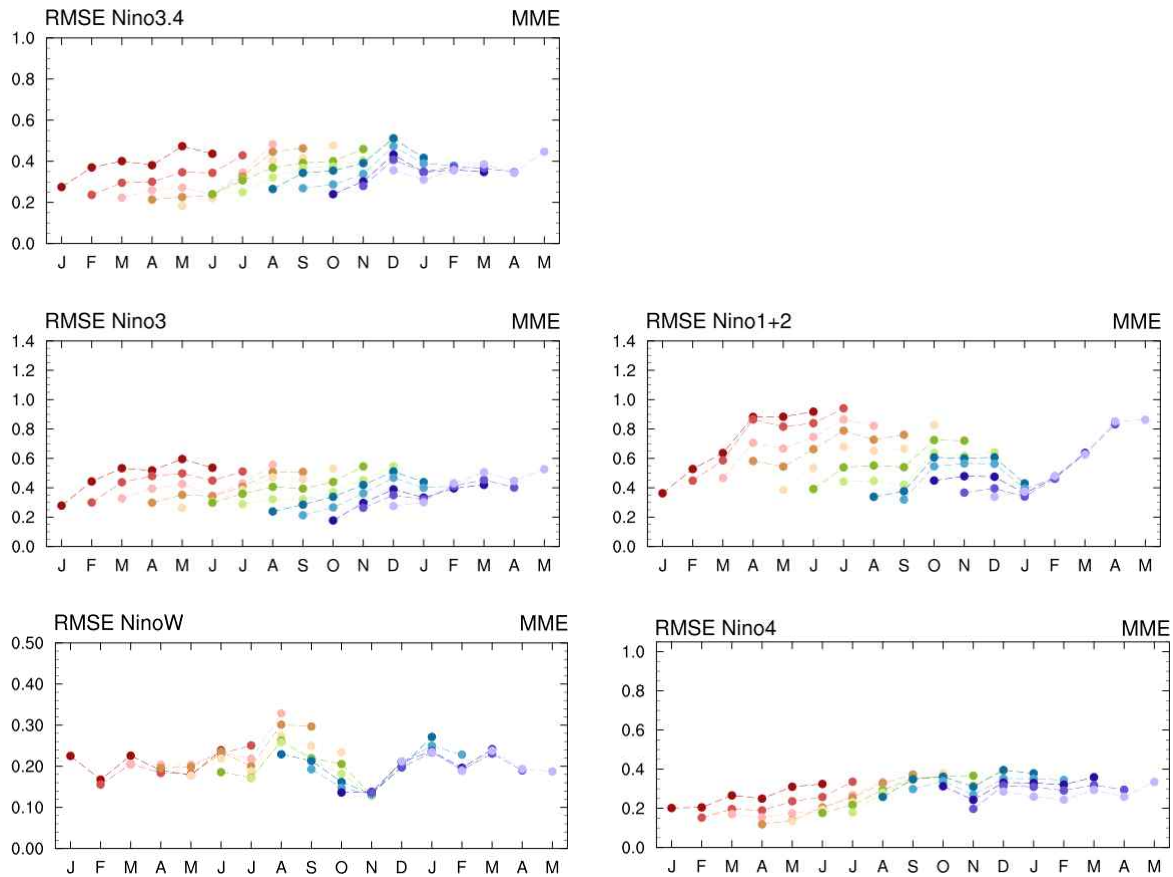


Figure 3.5. Root mean squared error (RMSE) of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes.

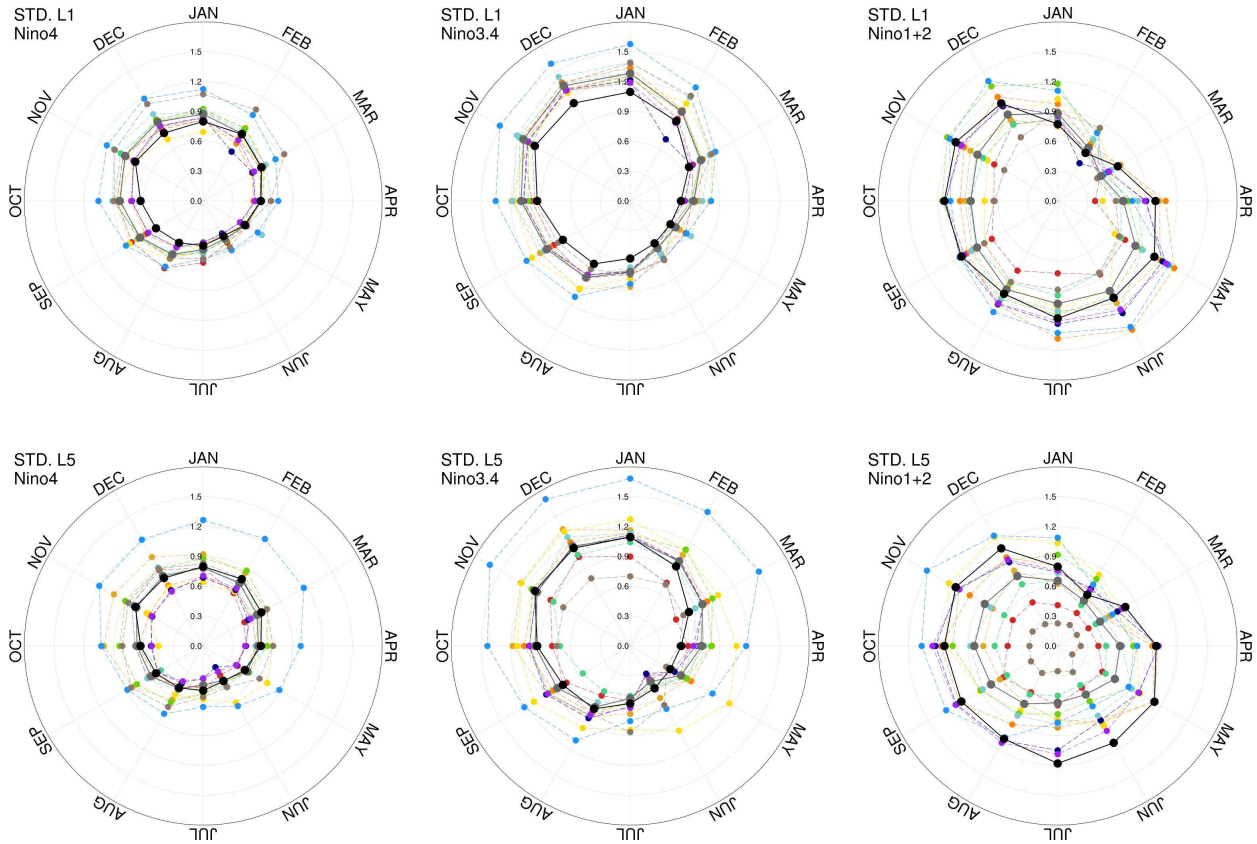


Figure 3.6. Standard deviation of the Nino4, Nino3.4, Nino1+2 indexes. Black and gray solid line indicates the observation and MME. Color dashed line indicates the individual model.

Figure 3.7과 3.8은 12월과 4월 ENSO 위상별로 10S-10N에서 평균한 열대 태평양 해수면온도의 합성장을 모델별로 나타낸 것이다. 위상은 관측의 Nino3.4 지수를 기준으로 0.5 이상 양의 위상, -0.5 이하 음의 위상, -0.5~0.5 사이 중립으로 나누었다.

모델에서 12월에 중태평양~동태평양에 강한 양/음의 편차와 서태평양 약한 음/양의 편차가 잘 나타났다. MME에서는 리드-1에서 관측과 유사하게 모의했고 리드-5에서도 관측과의 차이가 크지 않았다. 다른 개별 모델들도 리드-1에서는 모델과 관측의 차이가 작았으나 리드가 길수록 차이가 모델에 따라 차이가 증가한 모델이 있었다. 합성장에서 각 양/음의 편차에서 최대 값을 보인 지역을 중심 위치로 보면, 모델별로 차이는 있지만 대부분의 모델이 양의 위상일 때 양의 편차 중심이 관측보다 서쪽에서 나타났다. 음의 위상일 때는 리드-1에서는 많은 모델들이 관측과 유사한 위치에 음의 편차 중심이 위치했으나 리드-5에서는 관측보다 서쪽에 중심이 위치한 경우가 많았다.

4월 합성장에서는 12월보다 관측과 모델의 차이가 크게 나타났다. 양의 위상일 때 서태평양에서 모델들은 음의 편차를 관측보다 다소 약하게 모의했고 동태평양은 관측보다 양의 편차를 다소 강하게 모의했다. 선행시간이 긴 리드-5에서는 동태평양에서 차이가 컸는데 다수 모델이 관측보다 양의 편차를 강하게 모의했다. 음의 위상일 때는 리드-1에서는 관측과의 차이가 작았으나 리드-5에서는 차이가 증가했고 음의 편차를 중태평양은 관측보다 약하게, 동태평양은

관측보다 강하게 모의했으며 동태평양에서 차이가 훨씬 크게 나타났다. Nino 지수에서 봄철 상관관계수가 낮았던 부분은 합성장에서도 나타났으며 중태평양 지수보다 동태평양 쪽 지수에서 예측성이 낮았던 부분 또한 합성장에서도 나타났다.

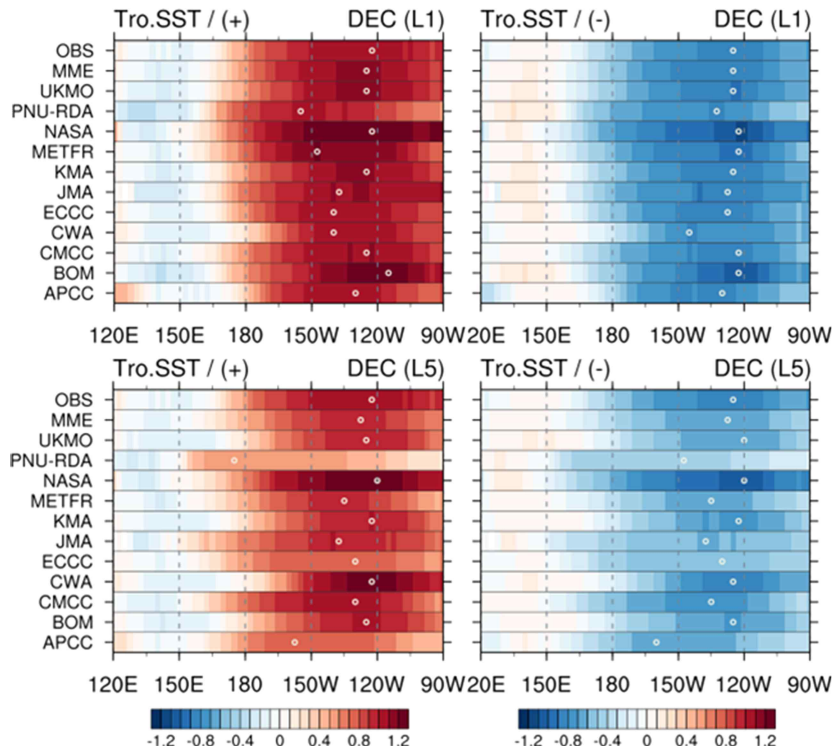


Figure 3.7. Composites of the December tropical (10S-10N average) SST anomalies with respect to the positive (left) and negative (right) phases. The white circle indicate the center of the anomalies.

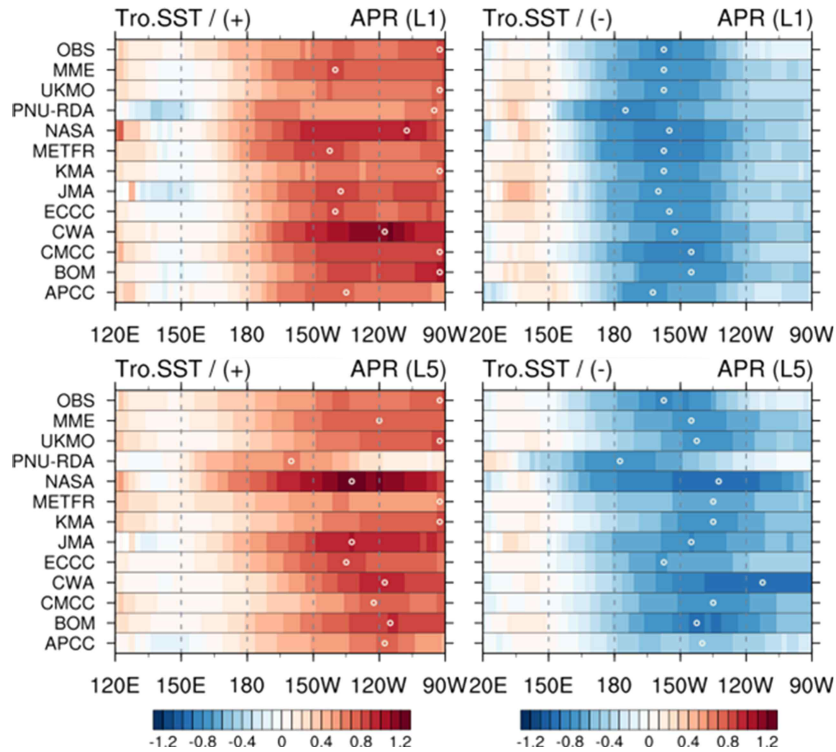


Figure 3.8. Composites of the April tropical (10S-10N average) SST anomalies with respect to the positive (left) and negative (right) phases. The white circle indicate the center of the anomalies.

Figure 3.9는 ENSO 위상에 따른 MME Nino 지수들의 시간 상관계수를 나타낸다. 양의 위상은 Nino3.4, Nino3, Nino1+2, NinoW 지수에서 높은 상관계수를 나타냈으며 리드-6에서도 높은 수준으로 나타났다. 반면 음의 위상은 양의 위상보다 낮은 상관관계를 나타냈는데, Nino3.4에서는 리드-6까지 비교적 높은 수준으로 나타났으나 Nino3와 Nino1+2에서는 리드가 길수록 상관계수가 크게 감소했다. 중립일 때는 모든 지수에서 리드가 길수록 감소했는데, 동쪽에 위치한 Nino3.4, Nino3, Nino1+2 지수는 선행시간이 길면 예측성이 거의 없어지는 반면에 서쪽에 위치한 Nino4와 NinoW는 리드-6에서도 0.5 이상의 상관계수를 나타냈다. Nino3.4 지수를 기준으로 특별한 이벤트가 발생하지 않는 경우, 동태평양에서는 예측성이 매우 낮지만 서태평양에서는 예측성이 일정 수준은 유지가 되는 것으로 볼 수 있다. Nino4 지수는 다른 지수들과 다른 예측성을 보였는데, 음의 위상 예측성이 다른 위상보다 높았고 양의 위상 예측성이 리드-3까지 가장 낮았다. 모델은 ENSO와 관련된 해수면온도 변동성이 관측보다 서쪽으로 확장되어 나타나며 음의 위상보다 양의 위상일 때 서쪽으로 더 편향되기 때문에 관측의 Nino3.4 지수를 기준으로 위상을 나누면 Nino4 지수의 변동성에 차이가 크게 나타난 것으로 보인다.

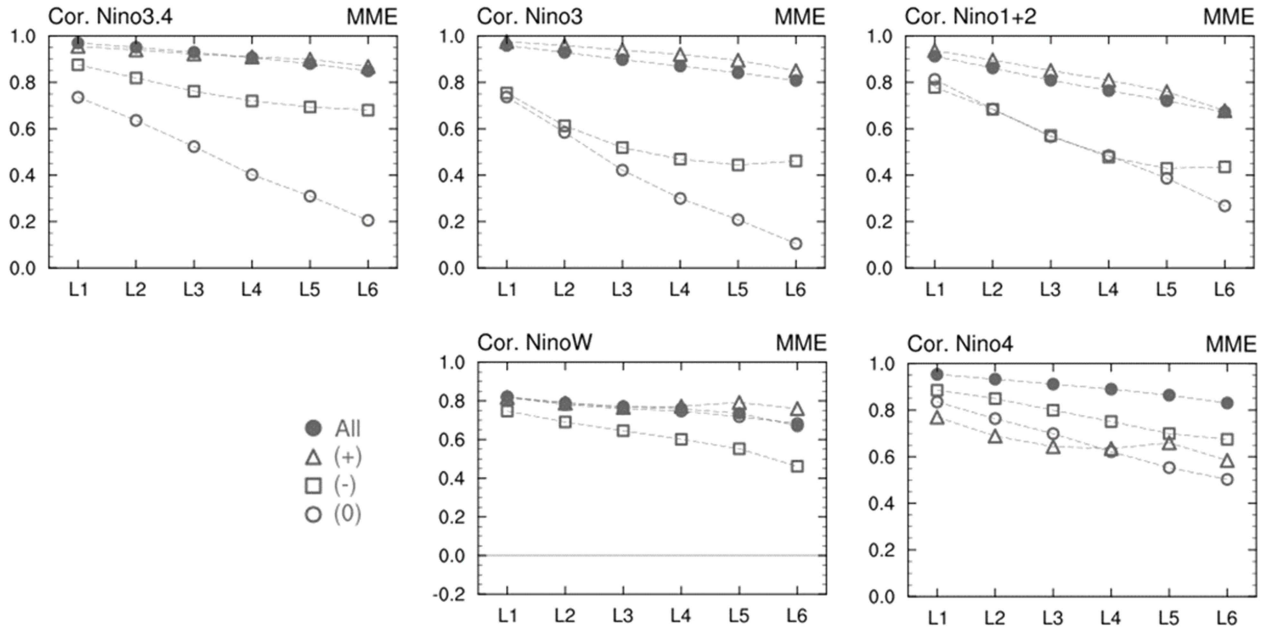


Figure 3.9. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME hindcast and observation with respect to the phases.

ENSO 위상에 따른 MME Nino3.4 지수의 상관계수를 계절별로 나누어 보면 (Figure 3.10), 양의 위상은 모든 계절에서 가장 높은 상관계수를 나타냈고 음의 위상, 중립 순으로 나타났다. 겨울철은 선행시간이 길어도 양의 위상과 음의 위상의 상관계수는 거의 감소하지 않았으나 중립에서는 크게 감소했다. 여름철은 양의 위상의 상관계수가 매우 높고 긴 선행시간에서도 높게 나타났는데, Nino3.4 지수가 0.5를 넘는 경우가 많지 않아 사례 수가 적었다. 양의 위상과 음의 위상의 차이는 여름철에 가장 크게 나타났다. 봄철은 양의 위상과 음의 위상 간의 차이는 작았으나 양의 위상의 상관계수는 다른 계절보다 낮았다.

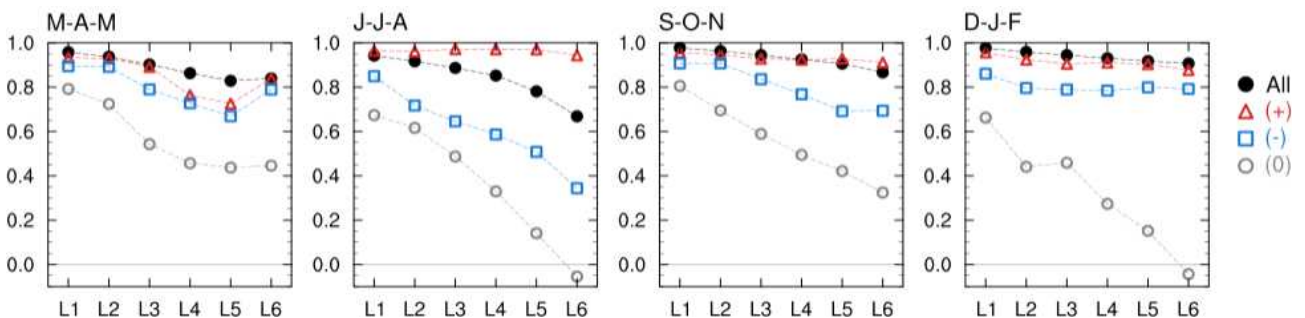


Figure 3.10. Temporal correlation coefficients of seasonally divided monthly Nino3.4 index between the MME hindcast and observation with respect to the phases.

MME Nino3.4 지수의 상관계수를 강도에 따라 나누어 살펴보았다. Figure 3.11은 월별 Nino3.4 지수를 강도에 따라 나눈 다음 계절별로 묶어서 상관계수를 구한 것이다. 강도는 관측 Nino3.4 지수의 절대값을 기준으로 1.0 이상은 강한 강도(ST), 0.5 이상 1.0 미만은 약한 강도(WK)로 분류하였다. 상관계수는 강한 강도일 때 매우 높게 나타났고 전 계절에서 높게 나타났다. 약한 강도의 경우 봄철과 여름철에는 모든 사례를 다 포함한 경우보다는 높았으나 가을철과 겨울철에는 가장 낮았다.




Figure 3.11. Temporal correlation coefficients of seasonally divided monthly Nino3.4 index between the MME hindcast and observation with respect to the intensity.

Figure 3.12는 엘니뇨와 라니냐 이벤트 동안 Nino3.4 지수의 시계열을 나타낸 것으로 관측과 모델에서 각 이벤트의 진화 과정을 보여주며 Figure 3.13은 각 이벤트에서 피크가 나타나는 월의 히스토그램을 나타낸 것이다. Hindcast 기간 동안 엘니뇨는 8번 라니냐는 9번 발생했다. 관측에서 각 이벤트의 최대값이 나타난 월은 11월 4번, 12월 8번, 1월 4번으로 12월이 가장 많았고, 이중 엘니뇨는 12월에 5번, 11월과 1월은 1번씩 나타났으나 라니냐는 11월, 12월, 1월이 3번씩 고르게 나타났다. 2014년은 2015년과 이어지면서 겨울철 이후로 Nino3.4 지수가 계속 증가했기 때문에 피크에서 제외했다. 모델은 리드-1에서 이벤트의 최대값이 11월에 1번, 12월에 9번, 1월에 6번 나타났으며, 이중 엘니뇨는 12월에 4번, 1월에 3번 나타났고, 라니냐는 11월에 1번, 12월에 5번, 1월에 3번 나타났다. 엘니뇨는 관측과 유사했으나 라니냐는 12월에 가장 많이 나타나 관측과 차이가 있었다. 선행시간이 길어질수록 모델에서는 12월에 피크가 나타나는 횟수가 줄어들었고 12월보다 더 늦게 피크가 발생하는 횟수가 증가했다. 리드-5에서 강한 엘니뇨 이벤트인 1997년과 2015년은 관측과 유사한 진화 과정을 보였으나 약한 이벤트인 1994년, 2006년 등은 관측과 차이가 있었다. 라니냐도 리드-5에서 관측과 차이가 있었는데 2005년과 연속된 이벤트였던 2007년과 2008년은 관측보다 강도도 약하고 피크가 나타난 시기에도 차이가 있었다. 리드-5에서 이벤트의 피크가 나타난 월의 횟수는 12월이 가장 많았으나 최대 다음 해 5월에서 까지 피크가 나타나는 등 관측보다 지연되어 나타났고 엘니뇨보다 라니냐 때 지연이 더 많이 발생했다.

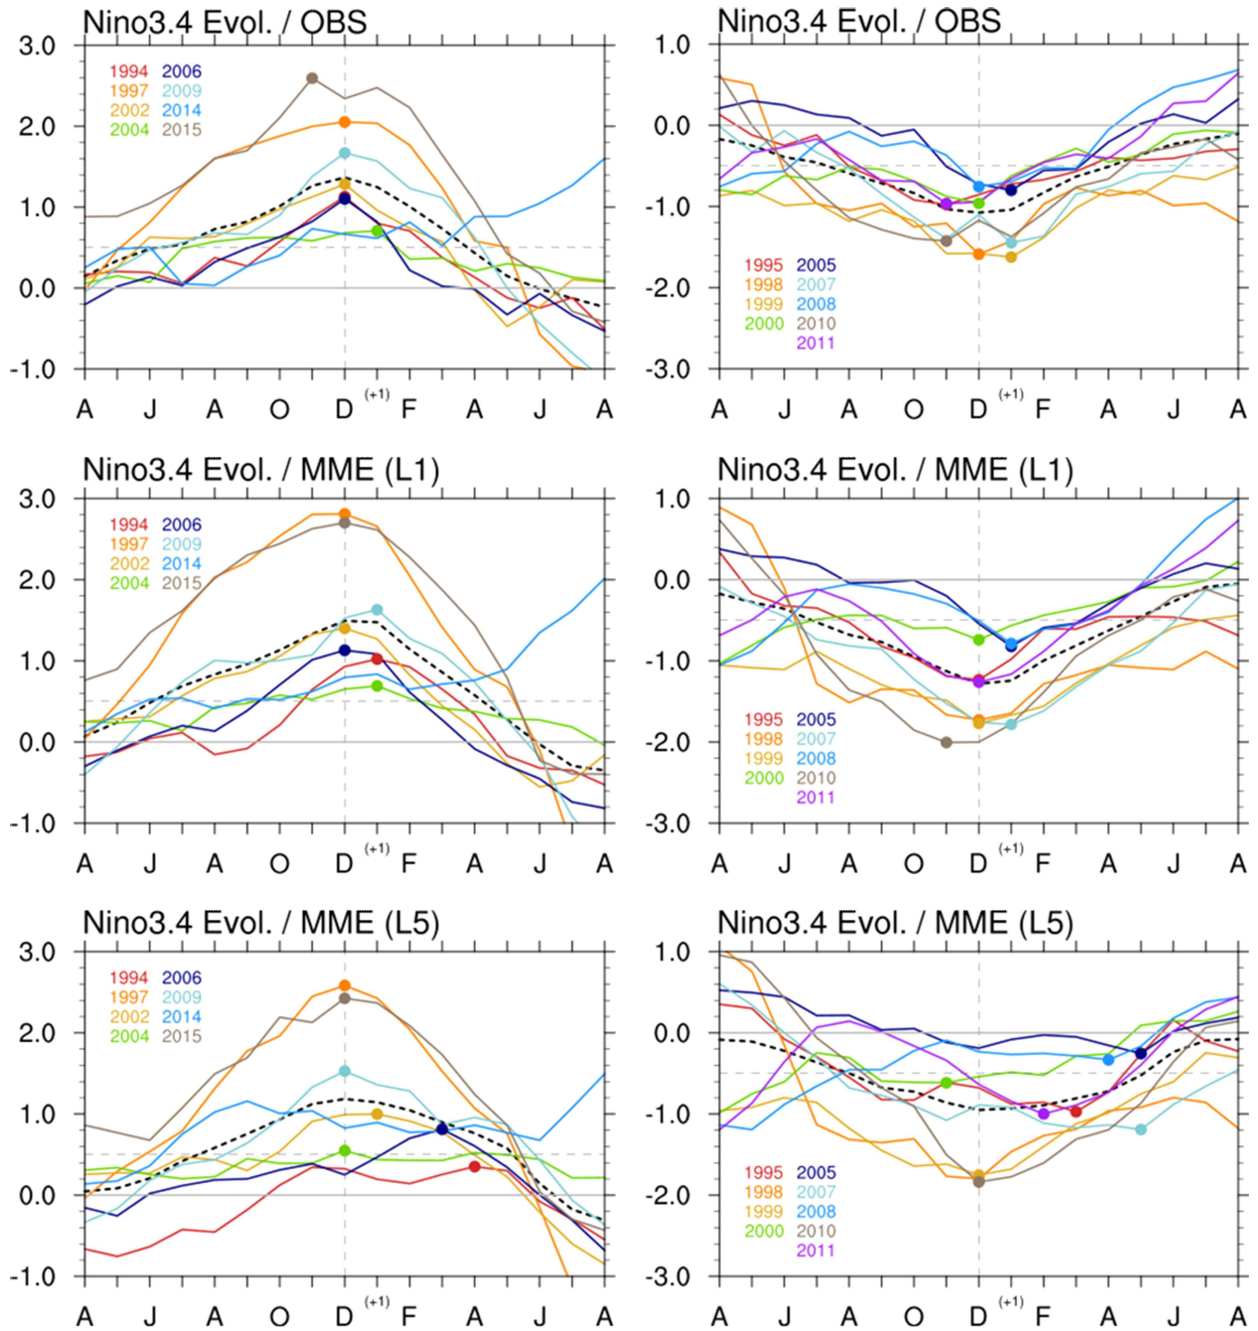


Figure 3.12. Evolution of the Nino3.4 index (color solid line) and their composite (black dash line) for El Niño (left) and La Niña (right) events during hindcast period. Evolution starts from April of the event developing year to August of the next year.




Figure 3.13. Histogram of the ENSO event peak month from the Nino 3.4 index evolution for the hindcast period.

3.3.3. 실시간 예측 기간 열대 태평양 기후모드 예측성 평가

최근 변화하는 기후에 대한 대응력을 높이기 위해서는 모델의 최근 기간 예측성에 대한 분석이 필요하며, 과거 예측을 재생산한 hindcast 뿐만 아니라 실제로 모델이 어떻게 예측해 왔는지에 대한 분석도 필요하다. 실시간 예측에서의 ENSO 예측성 분석에는 MME와 개별 모델의 가용한 해수면온도 자료를 사용했다. Figure 3.14는 분석에 사용한 해수면온도 실시간 예측 자료의 모델별 기간을 나타낸다. 앞서 설명한 바와 같이 개별 모델에서 해수면온도 자료가 있는 2012년 이후부터 각 모델의 예측자료가 있는 기간을 모두 사용하였다. 모델별로 보유한 자료 기간이 다르기 때문에 분석 기간도 다르게 사용되었다. 실시간 예측에서 사용한 개별 모델은 MME에 포함된 모델도 있지만 자료의 제약상 제외된 모델도 있어, 실시간 예측에서의 MME와 hindcast에서의 MME는 차이가 있다.




Figure 3.14. Data period of the MME and individual models for the SST real-time forecast.

Figure 3.15는 실시간 예측에서의 Nino 지수들의 시간 상관관계를 리드에 따라 나타낸 것이다. 막대로 표시된 MME의 상관계수는 리드-1에서 Nino3.4 지수 0.95로 매우 높았고 Nino3 지수 0.96, Nino4 지수 0.92, Nino1+2 지수 0.88, NinoW 지수 0.80으로 높은 예측성을 나타냈다. MME는 hindcast에서의 상관계수보다는 작았지만 차이가 적어 실시간 예측에서도 높은 예측성을 나타냈다. 지수의 상관계수는 hindcast와 마찬가지로 리드가 길수록 감소했는데, 리드-6에서 Nino3.4 0.81, Nino3 0.78, Nino4 0.78, Nino1+2 0.61, NinoW 0.49 였고, hindcast와 마찬가지로 주로 사용되는 중~동태평양 Nino 지수들은 긴 예측 선행시간에서도 약 0.8의 비교적 높은 예측성이 나타났고 동쪽의 Nino1+2지수는 hindcast와 비슷한 수준으로 감소했다. NinoW 지수도 hindcast와 마찬가지로 상관계수가 크게 감소했는데 실시간 예측에서는 hindcast보다도 훨씬 낮은 상관계수를 보이며 예측성이 더 낮았다.

개별 모델의 Nino 지수 예측성 또한 살펴보았다. 개별 모델에서도 MME와 마찬가지로 리드-1에서 모든 지수들이 높은 상관계수를 나타냈고 리드가 길수록 감소했다. 긴 예측 선행시간

에서는 일부 모델에서 음의 상관계수가 나타나기도 하는 등 hindcast보다 예측성이 낮았다. Hindcast와 다르게 실시간 예측의 개별 모델들은 서로 분석된 기간이 다르기 때문에 모델들 간의 결과를 해석할 때 주의가 필요하다. 예를 들어 NASA 모델의 경우 2012년부터의 예측자료가 사용되었으나 KMA 모델은 2020년부터의 예측자료가 사용되었다. 과거보다 최근 기간에 가까울수록 모델의 물리역학 과정이나 관측 초기장 등이 개선되면서 예측성은 더 좋아졌을 것으로 기대할 수 있다. 따라서 더 긴 예측 기간 자료가 사용된 모델의 예측성이 짧은 예측 기간 자료가 사용된 모델보다 좋게 나타날 수 있다.

모델 간의 비교를 위해 대부분의 모델 자료가 있는 2020년 이후에 대해서만 상관계수를 살펴보았다 (Figure 3.16). 모델의 전체 기간 자료를 사용한 결과보다 일부 모델에서는 긴 리드에서까지 상관계수가 높게 나타나 최근 기간일수록 모델의 예측성이 증가한 것으로 볼 수 있다. 그러나 여전히 일부 모델은 긴 선행시간에서 상관계수가 크게 감소하였고 특히 NinoW와 Nino4 지수에서는 큰 차이가 나지 않는 경우도 있었다. 특히 NinoW 지수는 최근 기간만 사용했을 때 오히려 상관계수가 낮아진 모델도 있었는데, 실시간 예측에서 서태평양 해수면온도 예측에 여전히 어려움이 있는 것으로 볼 수 있다.

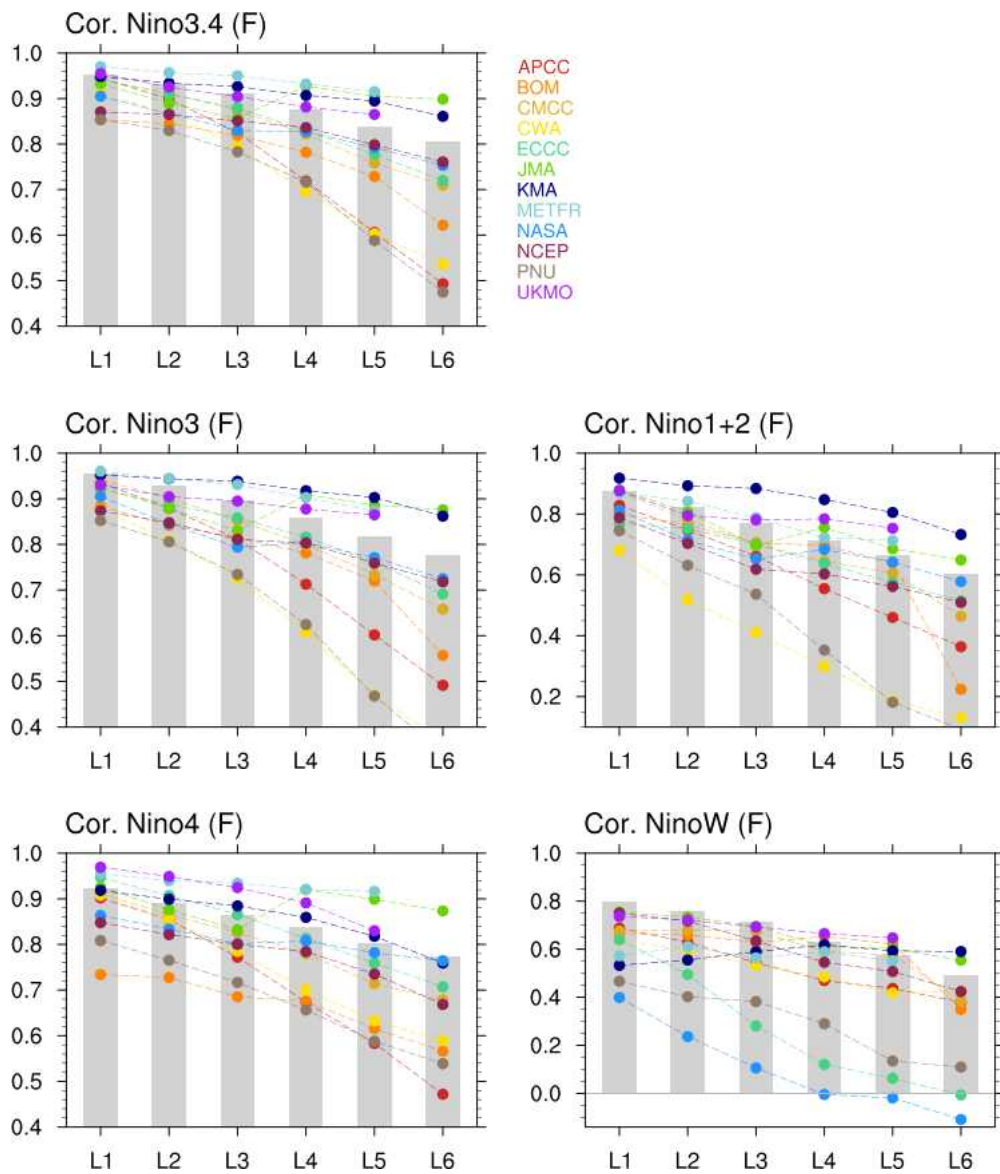


Figure 3.15. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, Nino4, and NinoW indexes between the model and observation for the real-time forecast lead-1 to lead-6. Gray bar is for MME and color dot-lines are for individual models.

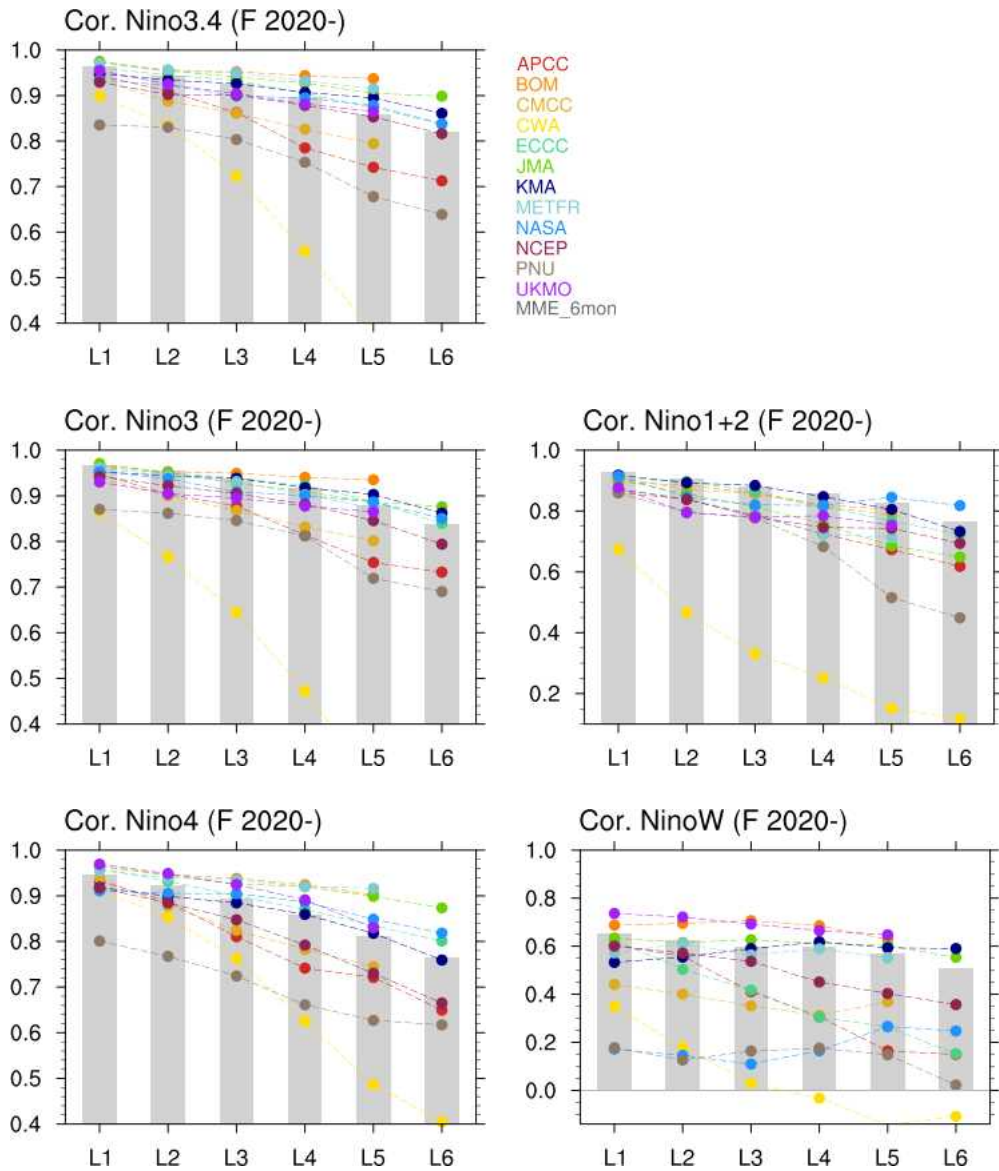


Figure 3.16. Same as figure 3.15 but for after 2020 year.

실시간 예측에서 Nino 지수들의 월별 리드별 예측성을 시간 상관계수로 살펴보았다. Figure 3.17은 MME Nino 지수들의 실시간 예측에서의 월별 리드별 시간 상관계수를 리드-6까지 나타낸 것이다. Hindcast와 마찬가지로 Nino3.4 지수의 예측성이 가장 높았고 Nino3 지수와 Nino4 지수도 높은 예측성을 나타냈다. 실시간 예측에서도 선행시간이 길어질수록 상관계수가 감소했는데, hindcast에서 보다는 조금 늦은 시기인 봄~초여름 출발한 여름~초가을 예측에서 상관계수가 감소했다. Nino1+2 지수도 hindcast와 마찬가지로 2월부터 상관계수가 낮았다. Hindcast와 비교해 상관계수 차이가 크게 나는 지수는 NinoW 지수였는데 특히 봄철 상관계수가 hindcast에서 보다 낮았다.

Figure 3.18은 개별 모델의 실시간 예측 Nino3.4 지수의 시간 상관계수를 나타낸 것이다.

개별 모델들도 늦봄~여름철 상관계수가 다른 월에 비해 낮게 나타났고, 선행시간이 길수록 상관계수가 감소했다. METFR 모델은 상관계수가 가장 높고 긴 선행시간에서도 거의 감소하지 않았는데, 모델들 중 분석 기간이 가장 짧은 모델로 샘플 수가 적었다. KMA와 UKMO 모델도 분석 기간이 짧은 모델로 늦가을~겨울철 높은 예측성을 나타냈는데, 늦봄~여름철은 hindcast보다 예측성이 낮게 나타났다. UKMO 모델의 12월 출발 예측은 상관계수가 낮았는데, 이 또한 샘플 수가 적어 나타날 수 있는 결과로 보인다. 비교적 분석 기간이 긴 편에 속하는 모델들에서도 봄~여름철 상관계수가 감소했고 hindcast보다 더 늦은 시기까지 감소가 이어져, 실시간 예측에서 여름철 ENSO 예측성은 hindcast보다 낮았다. 일부 모델은 모든 계절에서 선행시간이 길어지면 상관계수가 크게 감소했는데, 겨울철에서도 상관계수 감소가 다른 모델들보다 크게 나타나 개선이 필요해 보였다.

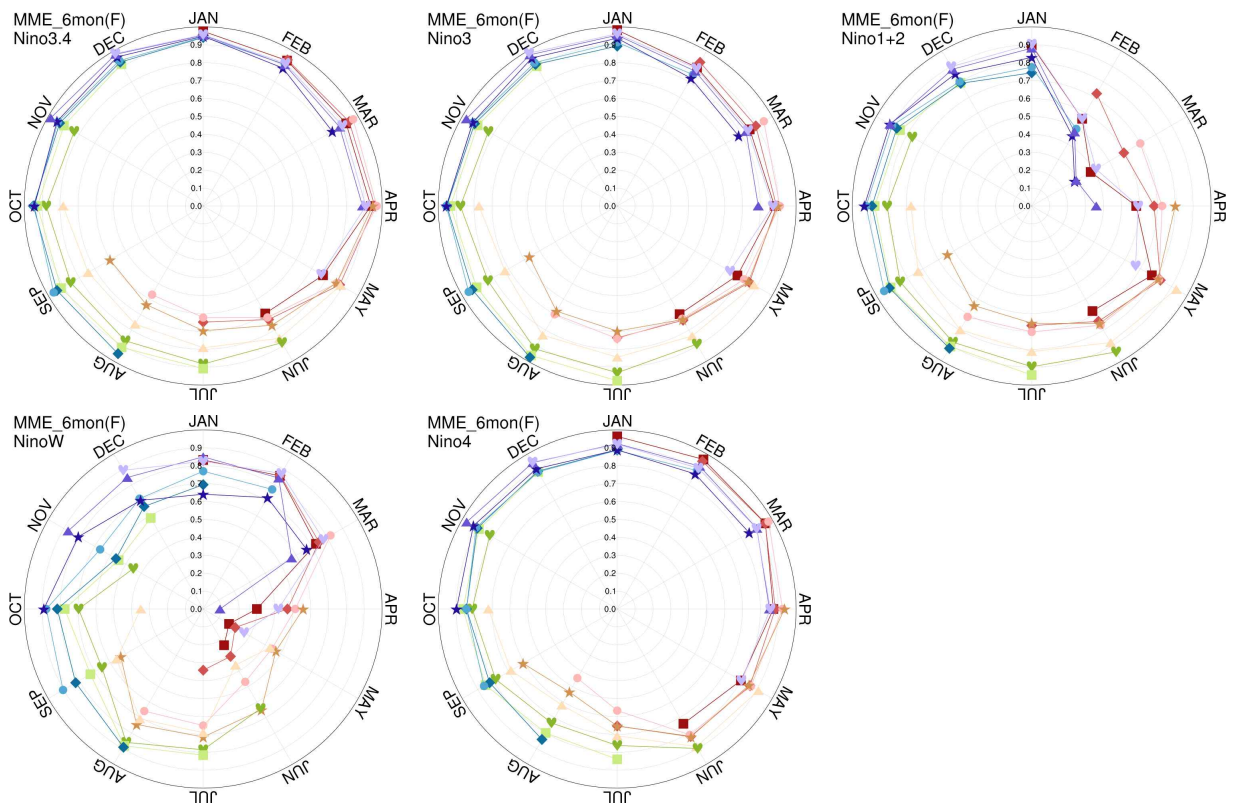


Figure 3.17. Temporal correlation coefficients of the monthly Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME and observation for the real-time forecast.

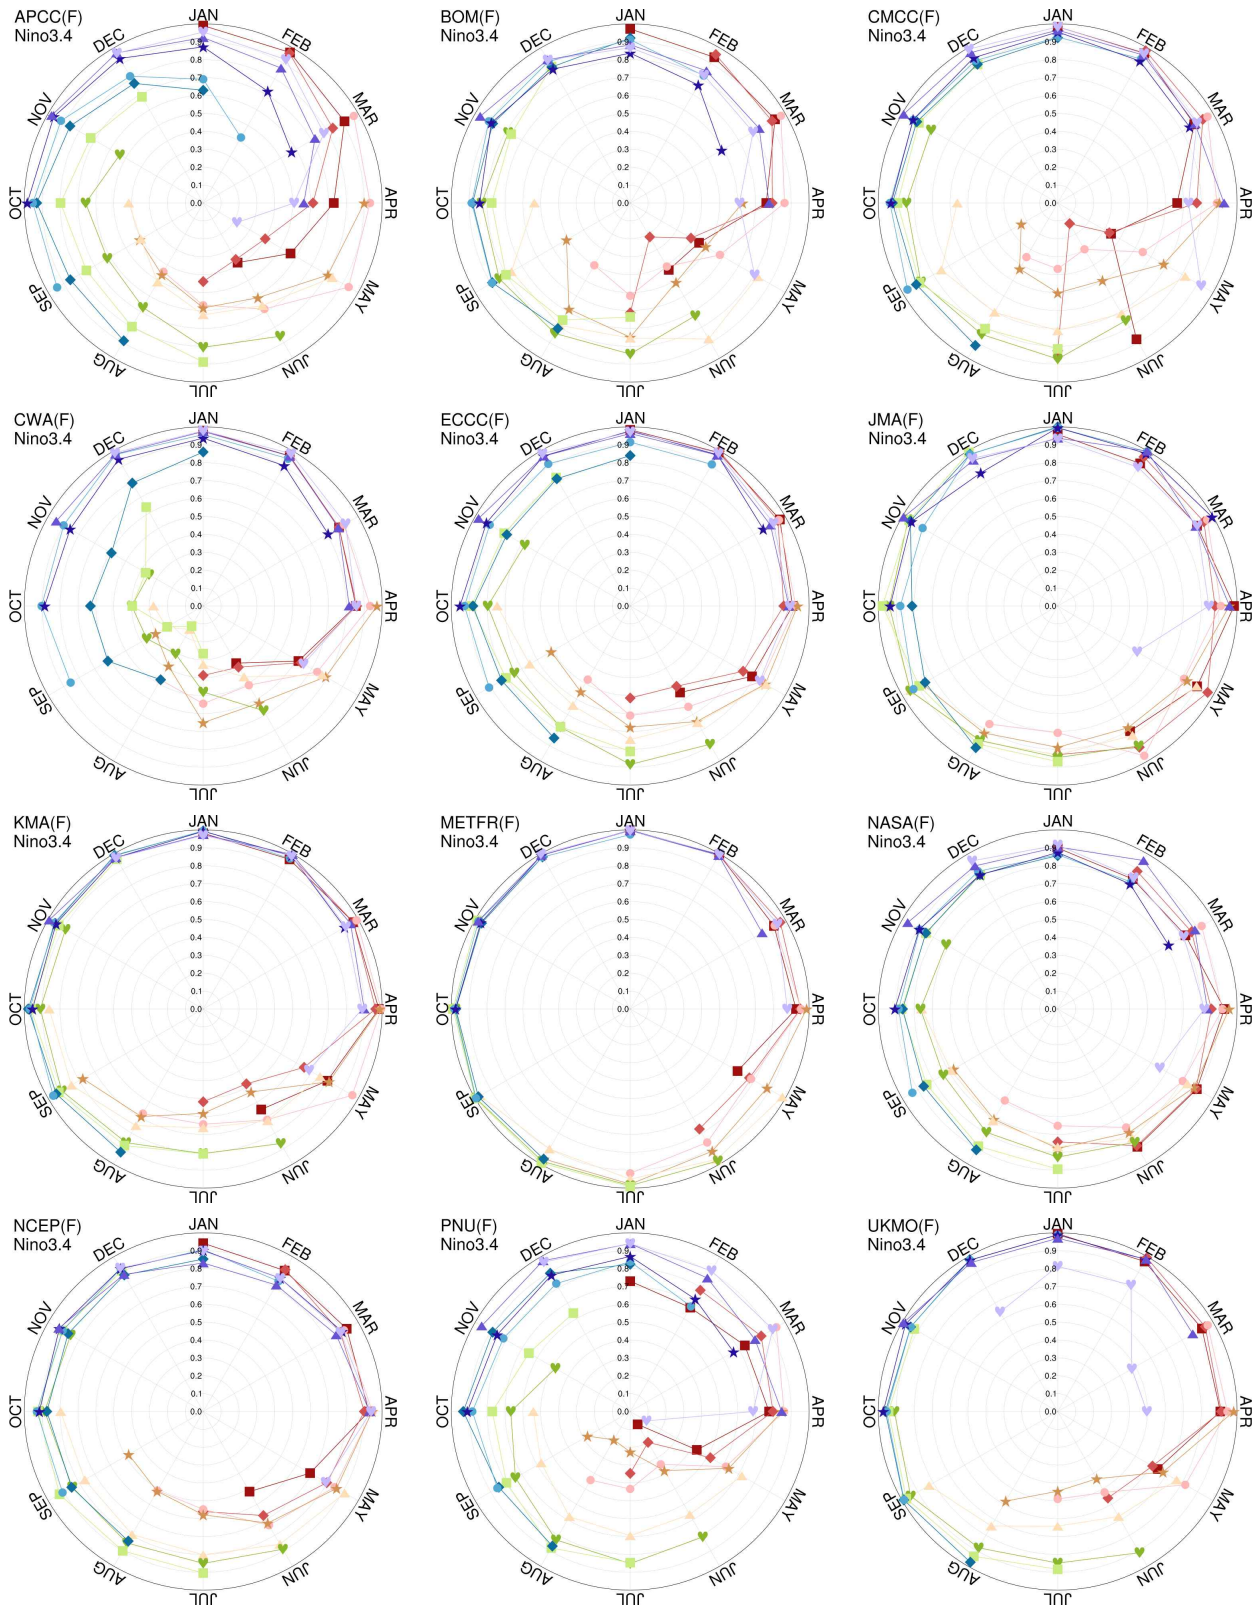


Figure 3.18. Temporal correlation coefficients of the monthly Nino3.4 index between the individual models and observation for the real-time forecast.

Figure 3.19는 실시간 예측에서 MME Nino 지수들의 평균 제곱근 오차(RMSE)를 나타낸 것이다. 실시간 예측에서 오차는 hindcast보다 다소 크게 나타났는데, Nino3.4 지수의 경우 8월에서 11월 사이 오차가 증가했다. hindcast에서 가장 큰 RMSE를 보인 지수는 Nino1+2 지수 였는데, 실시간 예측에서도 큰 오차가 나타났고 2월에서 10월 사이 크게 나타났다. NinoW 지수는 hindcast보다 겨울철 오차가 크게 나타났는데, 겨울철 서태평양 해수면온도는 동아시아 순환장과 밀접하게 관련되어 있기 때문에 이 지역에서의 오차는 동아시아 예측에 영향을 줄 수 있다.

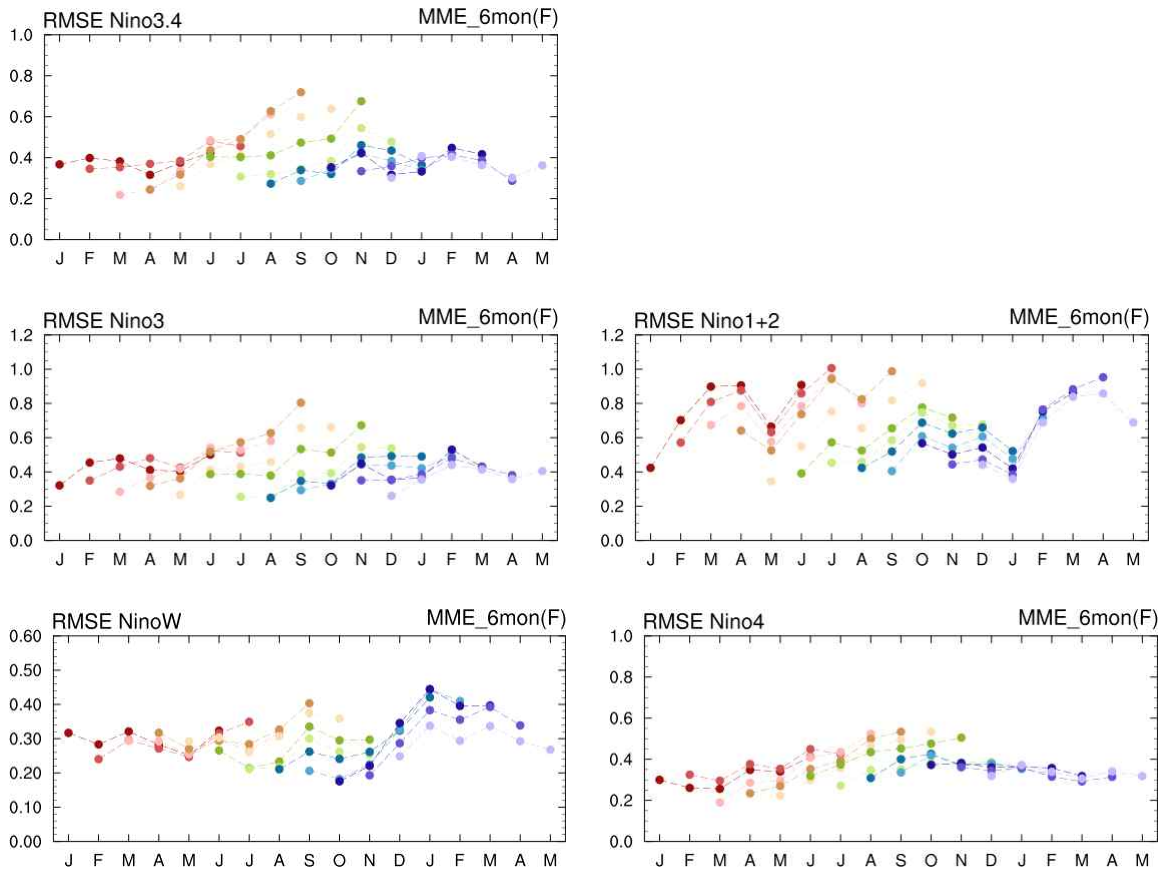


Figure 3.19. Root mean squared error (RMSE) of the monthly Niño3.4, Niño3, Niño1+2, NiñoW, and Niño4 indexes for the real-time forecast.

Figure 3.20은 실시간 예측에서 ENSO 위상에 따른 MME Niño 지수들의 시간 상관계수를 나타낸다. 양의 위상은 Niño3.4, Niño3에서 높은 상관계수를 나타냈다. 반면 음의 위상은 상관계수가 낮았는데, 중립일 때보다도 낮게 나타났고 선행시간이 긴 경우 0에 가까운 값을 나타내 예측성이 매우 낮았다. 실시간 예측 자료의 기간 동안 엘니뇨는 5번, 라니냐는 6번 발생했는데, 이중 엘니뇨는 매우 강한 이벤트가 2번 있었고, 라니냐는 연속되어 발생한 이벤트가 많았고 강도가 강하지 않았다. Figure 3.21은 엘니뇨와 라니냐 이벤트 동안의 Niño3.4 지수의 시계열을 나타낸 것으로 실시간 예측기간 동안 관측과 모델에서 각 이벤트의 진화 과정을 보여준다. 엘니뇨의 경우 강한 엘니뇨였던 2015년과 2023년 이벤트는 모델에서 발달과 소멸 과정이 비교적 잘 모의되었다. 다만 모델에서는 이벤트 최성기 이후 음의 편차로 빠르게 전환되는 것으로 예

측했다. 라니냐의 경우 엘니뇨보다 관측과 차이가 크게 나타났는데, 2016년의 경우 모델에서는 관측보다 빠르게 발달한 다음 양의 편차로 전환되어 2017년에 여름~가을에 엘니뇨로 발달할 것으로 예측하였으나 실제로는 양의 편차가 모델만큼 크게 발달하지 않고 라니냐로 발달했다. 실시간 예측에서 MME Nino3.4 지수는 증가할 것으로 예측하는 경향이 있었는데, 2017년 초부터 모델은 엘니뇨로 발달을 계속해서 예측했으나 실제로는 Nino3.4 지수가 감소하였고, 2022년에도 모델은 라니냐에서 엘니뇨로 전환을 예측했으나 실제로는 Nino3.4 지수가 음의 편차를 유지하며 라니냐가 지속되었다. 2024년에는 엘니뇨 이후 모델은 지속적으로 라니냐 발달로 예측했으나 관측 지수는 크게 감소하지 않고 중립 상태가 이어져 예측이 어긋났다.




Figure 3.20. Temporal correlation coefficients of the Nino3.4, Nino3, Nino1+2, NinoW, and Nino4 indexes between the MME real-time forecast and observation with respect to the phases.

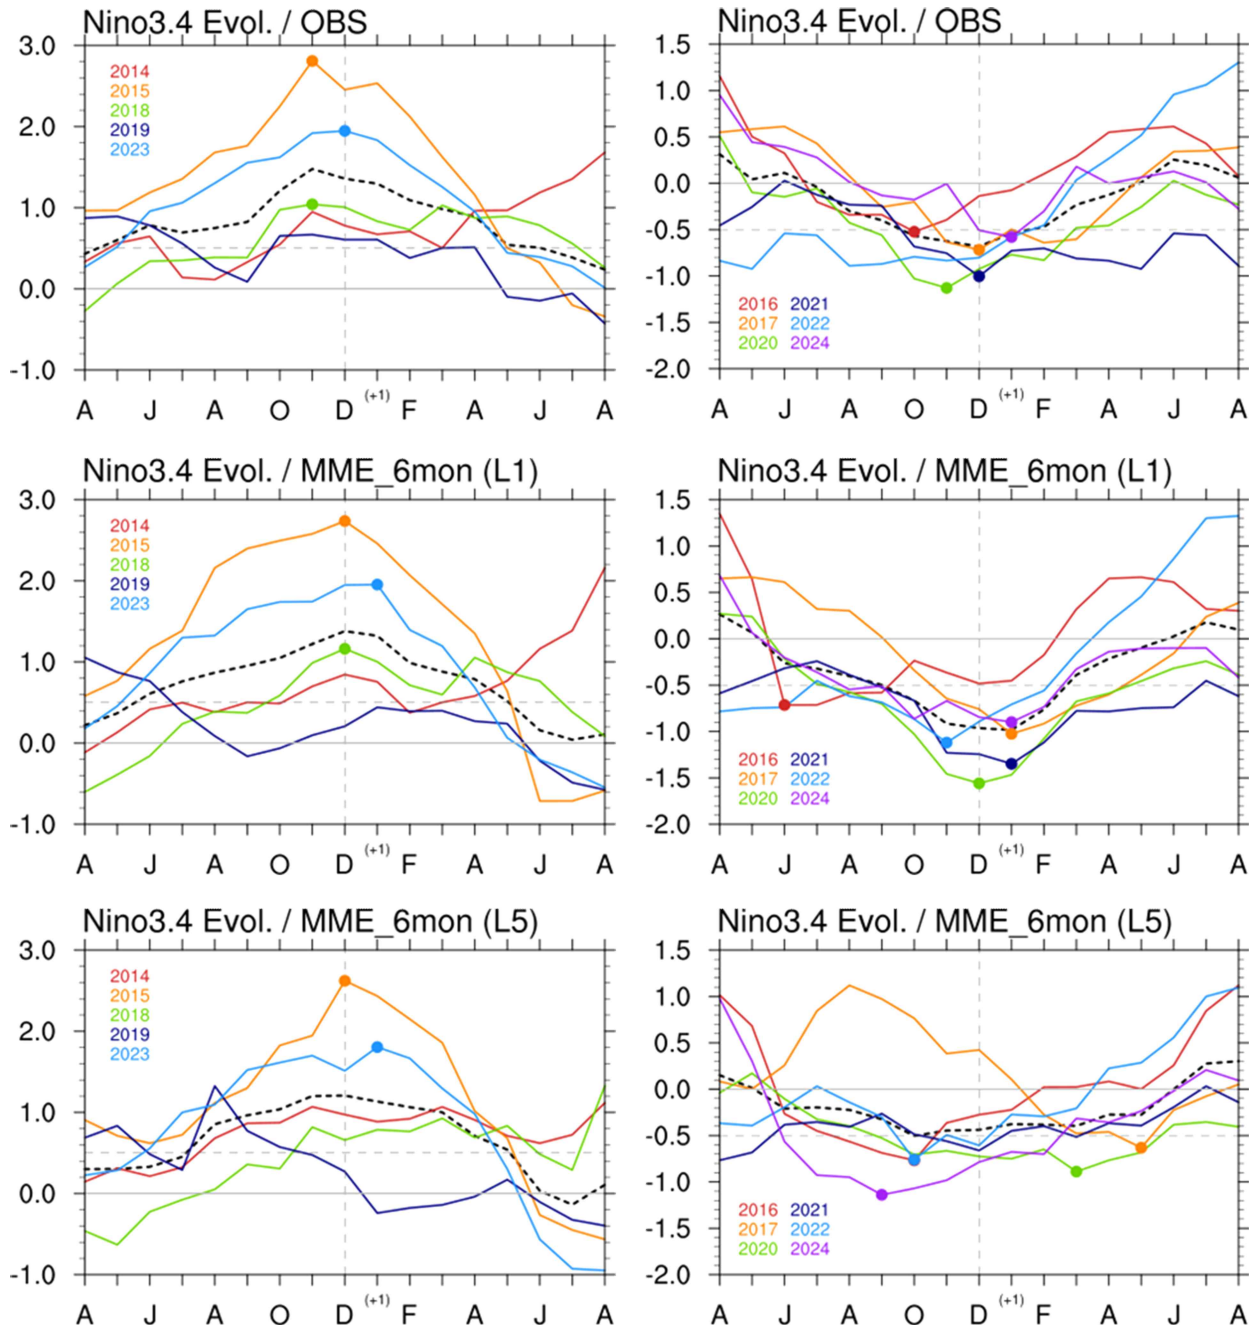


Figure 3.21. Evolution of the Nino3.4 index (color solid line) and their composite (black dash line) for El Niño (left) and La Niña (right) events during real-time forecast period. Evolution starts from April of the event developing year to August of the next year.

3.4. 북대서양 기후모드

3.4.1. 북대서양 기후모드 선정

최근 북대서양 해수면온도가 원격 상관을 통해 동아시아에 미치는 영향에 관한 다수의 연구 결과들이 제시되고 있다. 이들 연구에서 공통으로 제시하는 바는 북대서양에서 남북 방향의 tripole 또는 dipole 형태의 해수면온도가 NAO-like 대기 패턴을 유도하고 이것이 로스비 파동 전파로(Rossby wave train) 동아시아까지 영향을 줄 수 있다고 하였다 (Lee et al. 2024, Zhang et al. 2023, Xu et al. 2023, Chen et al. 2019, Lim and Seo 2019). 한편, 최근에는 이러한 원격 상관이 수십년 규모의 변동성 (Atlantic Multidecadal Oscillation) 과도 관련되어 있으며 과거와는 다르게 작용할 수 있고, 계절이나 시기, 대기 상태 등에 따라서도 달라질 수 있다는 연구 결과들도 제시되고 있다 (Monerie et al. 2021, Chen et al. 2024). 그러나 북대서양과 동아시아는 지리적으로 멀리 떨어져 있는 특성상 북대서양 영향만으로는 설명하기 어렵고 북태평양이나 인도양, 열대 대서양과 같은 다른 해역이나 대기 내부 변동성 같은 다양한 요인들과의 복잡한 상호작용 영향이 있으며 (Yao et al. 2025, Xie et al. 2025), 모델 예측을 활용하는 경우 앙상블 평균에서는 다양한 파동 패턴들이 상쇄되기 때문에 대륙을 지나오는 파동 패턴을 예측하기 어려운 한계도 있다.

이러한 한계는 있지만 북대서양 해수면온도가 동아시아에 영향을 주는 것은 분명하며 기후 후 예측 또는 계절예측에서 북대서양 해수면온도의 변동을 고려하는 것은 유의미하기 때문에 앞으로 많은 연구가 필요할 것이다. 따라서 계절예측 APCC MME에서 북대서양 해수면온도를 활용하기 위해서는 먼저 북대서양 해수면온도에 대한 모델의 기본적인 예측 특성을 진단하는 것이 필요하다.

북대서양에서 가장 주요하게 나타나는 해수면온도 변동성을 찾기 위해 관측 해수면온도 자료의 북대서양(0-80W, 10-70N) 지역에 EOF 분석을 적용하였다. 분석 기간은 모델의 hindcast와 동일한 1993-2016년이며, 북대서양은 해수면온도의 증가 추세가 강한 지역이기 때문에 선형 추세를 제거한 다음 EOF를 적용하였다. 북대서양의 선형 추세는 북대서양 전 지역에서 나타나는데, 여름부터 가을까지 북아메리카 동부 해안선 근처 멕시코 만류가 지나가는 지역에서는 증가 추세가 강하게 나타났고, 약 50N 부근에서는 2010년대 중반 온도가 낮아지는 시기가 있어 추세가 뚜렷하지 않았다. 북대서양 해수면온도의 EOF 첫 번째 모드는 아열대 음의 편차, 중위도 북대서양 서편에 양의 편차, 고위도 그린란드 남쪽에 음의 편차가 위치하는 삼극자 패턴으로 나타났으며 전체 변동성의 약 18%를 차지했다 (Figure 3.22). 월별로 EOF를 적용했을 경우에도 삼극자 패턴이 첫 번째 모드로 나타났다. 패턴은 월별로 약간의 차이는 있었는데 초겨울~초여름에 삼극자 패턴이 뚜렷했고 여름철에는 중위도의 양의 편차가 약화 되고 고위도 음의 편차가 더욱 강화되는 것으로 나타났다. 월별 첫 번째 모드는 전체 변동성의 약 20% 정도를 차지해 전체 기간에 대한 변동성과 비슷했다.




Figure 3.22. The spatial pattern of the first EOF mode for the North Atlantic SST.

북대서양 해수면온도의 EOF 첫 번째 패턴에서 나타난 변동성이 큰 지역을 선정해 해수면 온도를 평균한 다음 지수를 산출했다. 북대서양 해수면온도는 대체로 증가 추세에 있으나 분석 기간이나 지역에 따라 추세가 달라질 수 있으며 모델에서도 해수면온도 지수를 쉽게 비교할 수 있도록 영역 평균한 해수면온도를 지수로 사용하였다. 영역은 중위도 동편 (NASST1, 70-45W, 30-40N), 그린란드 남쪽 (NASST2, 50-20W, 50-60N) 두 지역을 선정했다.

모델의 해수면온도 지수 예측성을 살펴보기에 앞서 두 해수면온도 지수와 우리나라 기온 강수와의 관련성을 살펴보았다. Figure 3.23은 두 해수면온도 지수와 우리나라 기온 강수와의 월별 상관관계를 나타낸 것이다. NASST1과 우리나라 기온은 1월, 4월, 7월 유의한 양의 상관성이 있고 강수는 4월 양의 상관성이 있었다. NASST2는 기온 강수와의 상관관계가 약했다. 선형 추세를 제거하거나 분석 기간을 달리 해도 NASST1은 4월, 7월 기온과 유의한 양의 상관성을 나타내 두 경우는 기온과 해수면온도 간에 높은 관련성이 있는 것으로 볼 수 있다.




Figure 3.23. Time correlation coefficients between the monthly NASST1 and Korea (left) temperature and (right) precipitation. The red outline circle indicates statistically significant at 95% confidence level.

Figure 3.24는 월별로 NASST1의 지위고도에 대한 회귀분석을 나타낸 그림이다. NASST1과 관련된 지위고도 패턴은 북대서양에서 겨울~봄철에 양의 NAO와 유사한 패턴으로 나타났다. 유라시아 대륙에서는 유럽과 중앙아시아를 지나 동아시아까지 이어지는 양~음~양의 파동 패턴으로 나타났는데, 우리나라 기온과 상관성이 높은 4월과 7월에 파동 패턴이 뚜렷했고 10월에도 뚜렷하게 나타났다. 따라서 모델 hindcast 기간 안에서도 중위도 북대서양 서편의 해수면온도가 NAO-like 대기 패턴 및 유라시아 파동과 관련되어 있음을 확인했다.

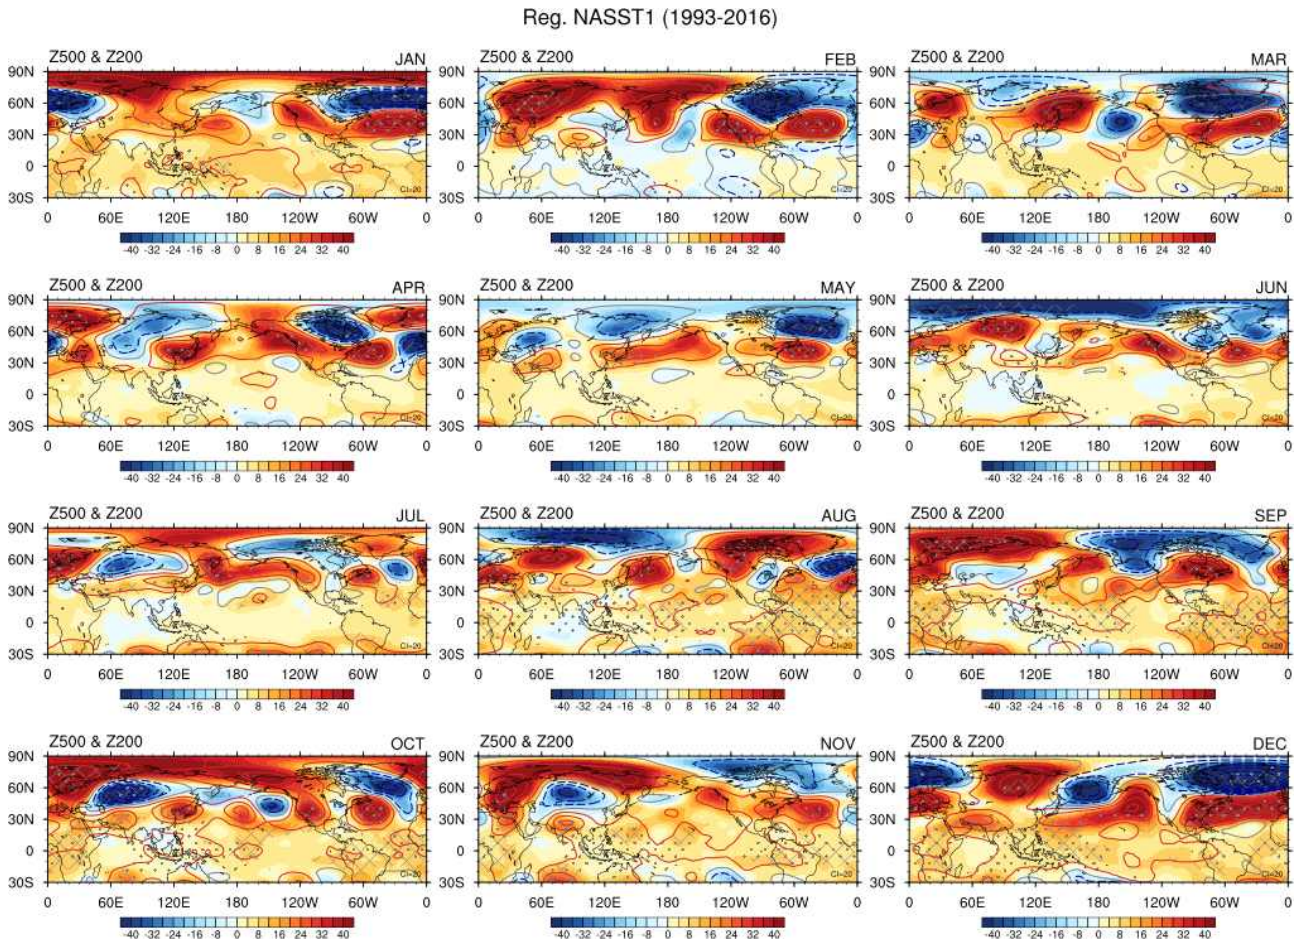


Figure 3.24. Regression of the monthly NASST1 and (shading) 500hPa and (contour) 200hPa geopotential height anomalies. The diagonal and dot indicate statistically significant at 95% confidence level for 500hPa and 200hPa height anomalies respectively.

3.4.2. 북대서양 기후모드 예측성 평가

모델 북대서양 해수면온도의 평균적인 예측성을 살펴보기 위해 매월의 예측 시점마다 관측과의 공간 상관계수를 구한 다음 전체 평균을 구했다 (Figure 3.25). 예상할 수 있는 바와 같이 모델에서 리드가 길수록 상관계수는 감소했다. 모델마다 감소 폭은 차이가 있었으나 리드1과 리드2의 차이가 크게 나타났다. 또한 개별 모델들 간의 차이도 컸는데, Hindcast 리드1에서 상관계수가 가장 큰 모델은 0.5를 넘었지만 가장 작은 모델은 0.2로 모델의 성능 차이가 열대태평양에서 보다 컸다. 실시간 예측에서의 공간 상관계수는 MME는 hindcast보다 낮았지만, 최근 기간만 포함된 일부 모델은 hindcast보다 높은 상관계수를 보였고 리드가 길어져도 상관계수가 크게 감소하지 않았다. 일부 모델을 제외하고 MME를 비롯한 모델들 대부분이 hindcast와 실시간 예측에서 리드3 이후로는 공간 상관계수 0.3 이하를 나타내 모델의 전반적인 북대서양 해수면온도 패턴은 예측성이 낮았다.

Figure 3.26은 북대서양 서편(70-45W)과 동편(45-15W)에서 위도를 따라 평균한 해수면 온도 월별 평균장의 관측과의 차이를 나타낸 것이다. 평균장의 차이는 모델마다 다르게 나타났으며 고위도에서 차이가 컸고 동편보다 서편에서 차이가 더 컸다. 북아메리카 대륙 쪽의 서편 고위도에서 CWA, KMA, NASA, UKMO 모델은 겨울철은 해수면 온도를 관측보다 차갑게, 여름철은 따뜻하게 모의해 관측보다 계절변동을 크게 모의했다. 반면 BOM, CMCC, METFR 모델은 여름철은 관측보다 따뜻하게 모의했고 겨울철은 차이가 작았다. 평균장의 차이는 리드에 비례해 증가하지는 않았는데 모델이 내부적으로 갖고 있는 오차가 반영된 것으로 보인다.




Figure 3.25. Pattern correlation coefficients of the North Atlantic (80-0W, 10-70N) SST anomalies between the model and observation. Gray bar is for MME and color dot-lines are for individual models. Left is for hindcast and right is for real-time forecast.

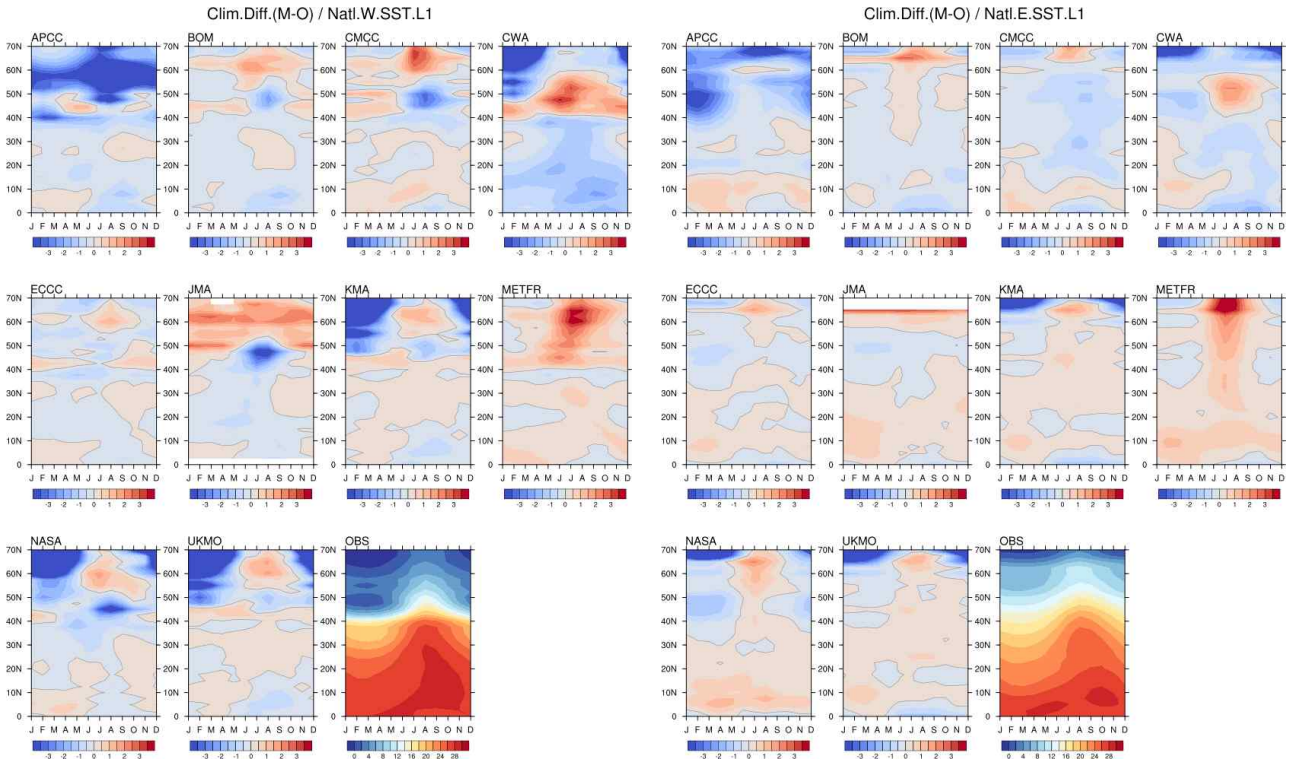


Figure 3.26. Difference of the climatological annual cycle of the North Atlantic SST along the latitude between the model and observation, and the observational climatological annual cycle at lead-1. Left panels are averages of 70-45W, and right panels are average of 45-15W.

모델의 해수면온도 지수 예측성을 시간 상관계수로 살펴보았다. Figure 3.27은 모델 hindcast의 북대서양 해수면온도 지수 NASST1과 NASST2 지수의 리드-1과 리드-3에서의 월 별 시간 상관계수를 나타낸 것이다. 막대로 나타낸 MME의 NASST1 지수는 리드-1에서 0.6~0.9 사이의 상관계수를 보였고 3월에 가장 높고 7월에 가장 낮았다. 리드-3에서는 약 0.5~0.7 사이의 상관계수를 보이며 준수한 예측성을 나타냈다. 리드-1에서는 겨울~봄철 상관계수가 대체로 높고 여름철에 낮았으나 리드-3에서는 대체로 가을과 초겨울 높고 늦겨울부터 여름까지 낮게 나타나 늦겨울과 봄철 상관계수 감소가 다른 계절보다 크게 나타났다. MME의 NASST2 지수는 리드-1에서 0.7~0.9 사이의 상관계수를 나타냈고 리드-3에서는 0.5~0.8 사이로 나타나 NASST1 보다 높게 나타났다. NASST2에서도 다른 계절보다 대체로 여름철 상관계수가 낮게 나타났다. 북대서양 해수면온도의 삼극자 패턴은 여름철에는 중위도의 양의 편차가 약화 되고 고위도 음의 편차가 더욱 강화되어 겨울~봄철과 패턴에 다소 차이가 있었고 모델의 해수면온도 삼극자 패턴도 여름철 관측과의 유사성이 떨어졌는데 이러한 부분이 여름철 예측성 감소와 연관된 것으로 보인다.

개별 모델에서의 시간 상관계수는 모델마다 큰 차이를 보였다. 다수의 모델에서 월별 시간 상관계수가 MME와 유사한 경향으로 나타났으나 일부 모델은 큰 차이를 보였는데, APCC 모델은 특히 겨울~봄철 NASST1과 NASST2에서 상관계수가 낮았고 선행시간이 길어지면 상관계수가 더욱 감소해 예측성이 매우 낮았다. APCC 모델은 평균장에서도 큰 오차를 나타내 개선이 필요해 보인다. 일부 예측성이 낮은 모델의 영향으로 hindcast에서 모델들의 평균인 MME는 개

별 모델보다 상관계수가 다소 낮게 나타났다.

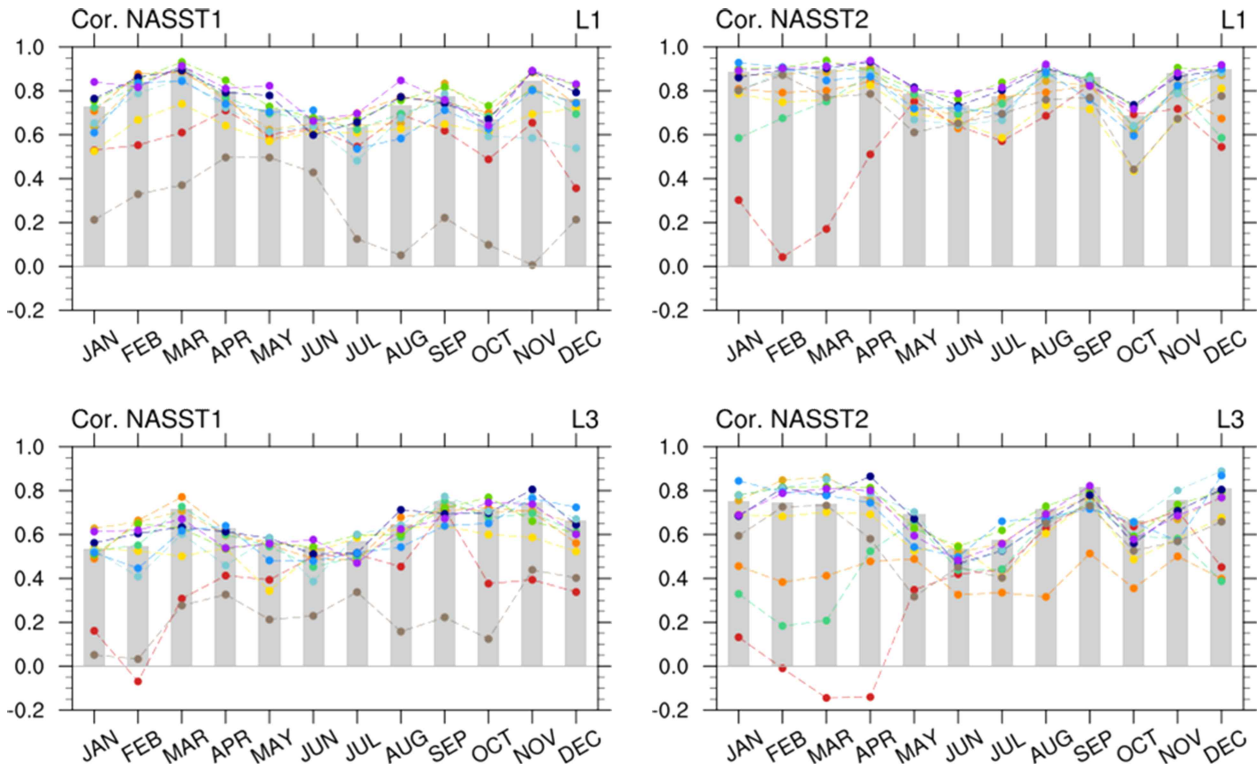


Figure 3.27. Temporal correlation coefficients of the NASST1(70-45W, 30-40N) and NASST2(50-20W, 50-60N) between the model and observation for the hindcast lead-1 and lead-3. Gray bar is for MME and color dot-lines are for individual models.

Figure 3.28은 모델 실시간 예측에서의 시간 상관계수를 나타낸다. 실시간 예측 자료는 앞선 열대 태평양(ENSO) 분석에 사용된 자료와 동일하다. 분석 기간은 모델마다 다르며 기간이 짧은 모델도 있기 때문에 결과 해석에는 주의가 필요하다. 먼저 MME의 상관계수는, NASST1에서 최대 리드-1에서 0.7, 리드-3에서 0.5를 나타내 hindcast보다 훨씬 낮았고 음의 상관계수를 나타낸 모델도 있었다. NASST2는 NASST1 보다는 상관계수가 높았는데 리드-1에서 0.5~0.9 사이를 나타냈고 리드-3에서는 0.3~0.9를 나타냈다. NASST2는 hindcast와 마찬가지로 겨울철에 예측성이 높았고 여름철에 낮았다.

개별 모델에서도 NASST1 지수의 상관계수는 월별로 큰 차이를 보였고 리드에 따라서도 큰 차이가 있었는데, 예를 들어 BOM 모델은 4월 리드-1에서 음의 상관이었으나 리드-3은 양의 상관으로 선행시간이 길어짐에 따라 예측성이 감소하지 않고 오히려 증가했다. NASST2 지수도 개별 모델의 예측성은 MME보다 월별 차이가 컸고 일정 수준으로 유지되는 모델을 찾기 어려웠다. 따라서 실시간 예측에서의 북대서양 해수면온도 지수는 예측성이 낮았고, 고위도의 NASST2 MME는 겨울철 예측성이 비교적 높았다. 북대서양은 열대 태평양과 달리 해수면온도의 변동성에 영향을 미치는 요인이 다양하며 대기 상태에 따라서도 영향을 받을 수 있다. 모델에서 예측을 시작하는 단계에서 초기값이 어떻게 처방되었는지에 예측 결과가 달라질 수 있으

며, 선행시간이 길어지면 차이가 더 커질 수 있기 때문에 예측성이 대체로 낮게 나타난 것으로 볼 수 있다.

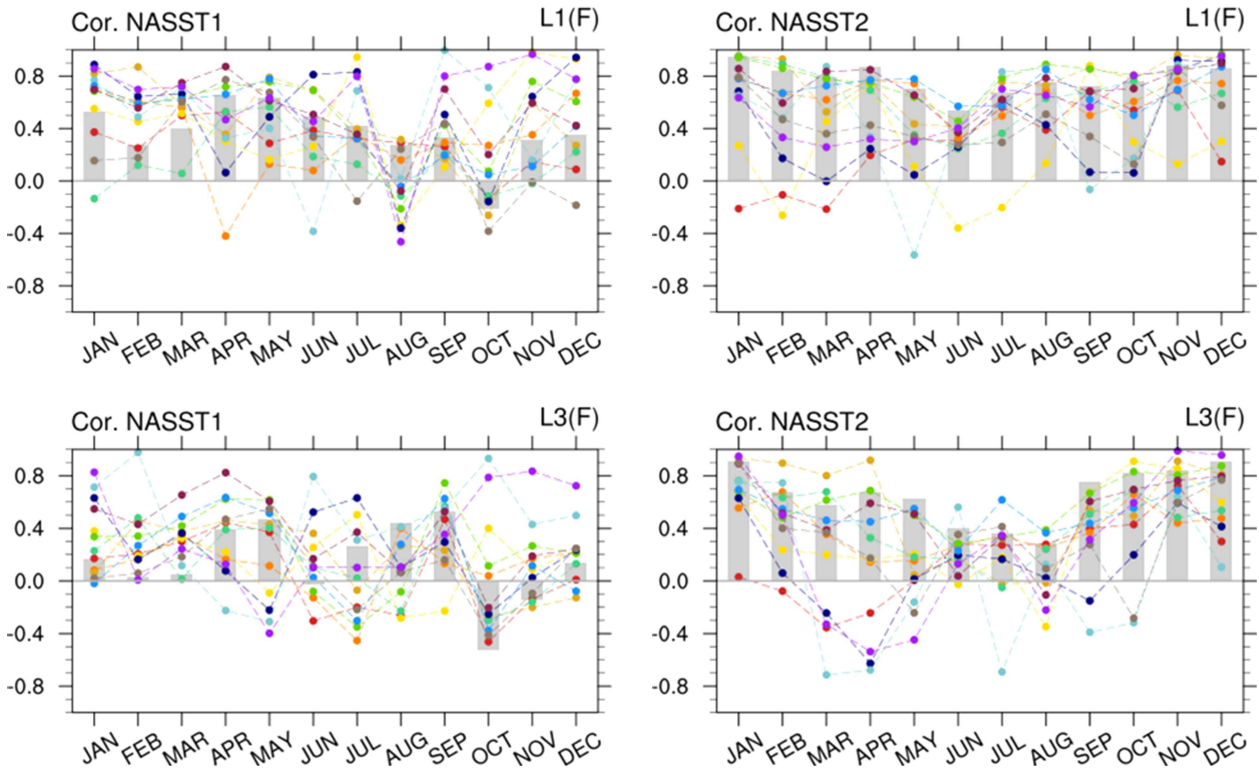


Figure 3.28. Temporal correlation coefficients of the NASST1(70-45W, 30-40N) and NASST2(50-20W, 50-60N) between the model and observation for the real-time forecast lead-1 and lead-3. Gray bar is for MME and color dot-lines are for individual models.

Figure 3.29는 NASST1 지수와 우리나라 기온의 상관계수를 관측과 모델 hindcast 리드-1에서 월별로 나타낸 것이다. 앞서도 살펴봤듯이 우리나라 기온과 NASST1 지수는 1월, 4월, 7월에 양의 상관성이 있었다. 모델에서도 4월과 7월은 대다수 모델에서 유의한 양의 상관성이 나타났으나 1월은 한 개 모델을 제외하고 관련성이 나타나지 않았다. 모델은 4월부터 11월까지 대부분 모델이 우리나라 기온과 NASST1 간에 유의한 양의 상관으로 나타나 관측에서 관련성이 낮았던 월에서도 높은 양의 상관을 보였다. 이는 모델에서 모의 되는 우리나라 기온이 관측과는 다른 영향을 받음을 의미하며 관측과 다르게 모델에서 상관성이 높게 나타나는 원인은 추후 순환장 분석 등이 필요해 보인다.

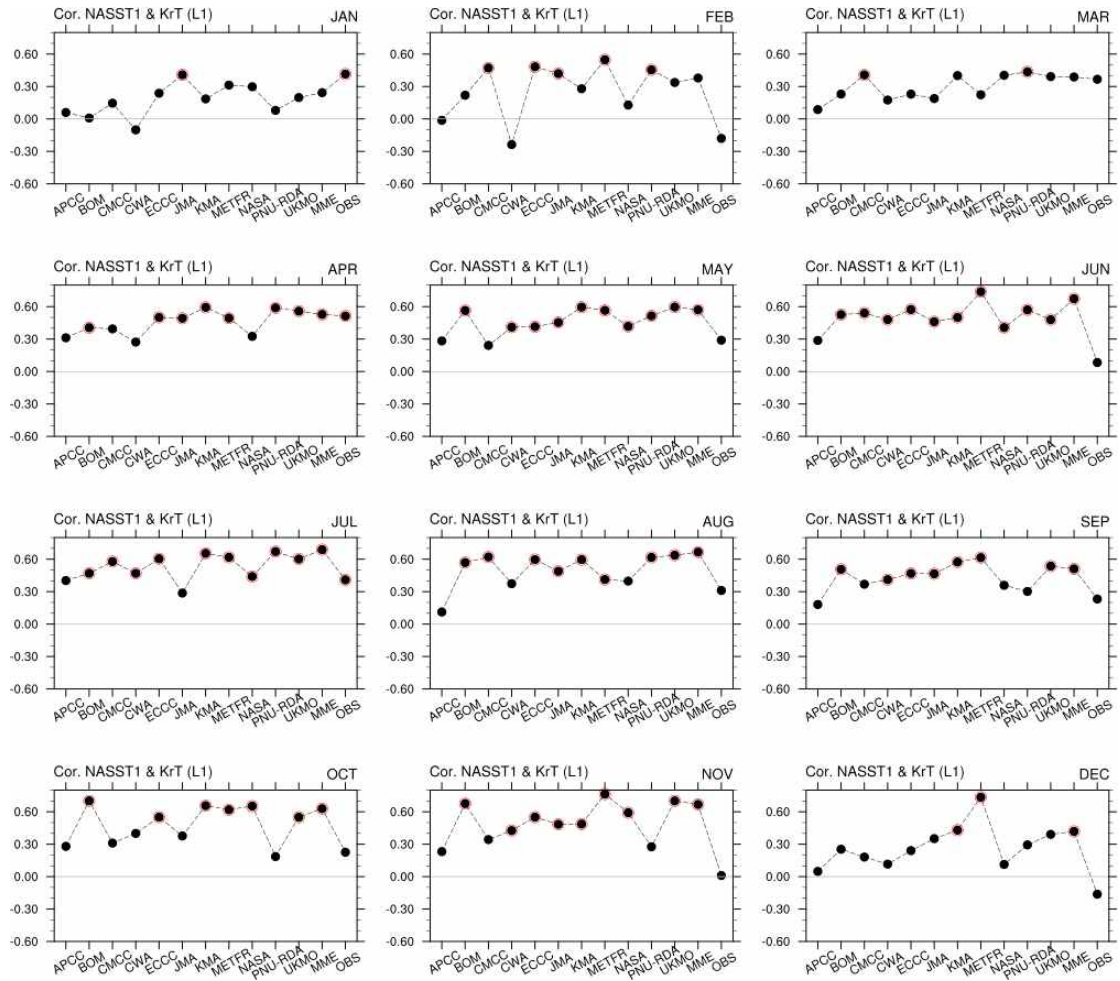


Figure 3.29. Temporal correlation coefficients between the NASST1 and Korea temperature for the lead-1 hindcast models and observation.

3.5. 인도양 기후모드

3.5.1. 인도양 기후모드 선정

인도양은 세계에서 세 번째로 큰 대양으로, 유라시아 대륙의 남쪽에 자리잡고 있어 아시아 계절풍에 큰 영향을 미치는 해양이다. 또한 대부분 적도, 아열대 위도에 위치하고 북쪽이 육지로 막혀있어 가장 따뜻하고, 지구 온난화의 영향을 강하게 받는 지역이다. 인도양에서 주요한 기후모드는 경험적 직교함수(Empirical Orthogonal Function, EOF) 분석으로 확인할 수 있는데, 첫 번째 모드는 인도양 전반적인 온난/냉각 변동으로서 흔히 인도양 전역모드(Indian Ocean Basin, IOB)와 유사하고 (34%), 두 번째 모드는 인도양 SST의 동서 대비로 나타나는 인도양 쌍극자(Indian Ocean Dipole, IOD) 모드와 유사하며(9.3%), 적도 워커 순환(Walker Circulation)과 연관되어 나타나는 변동성이다(Figures. 3.30, 31).

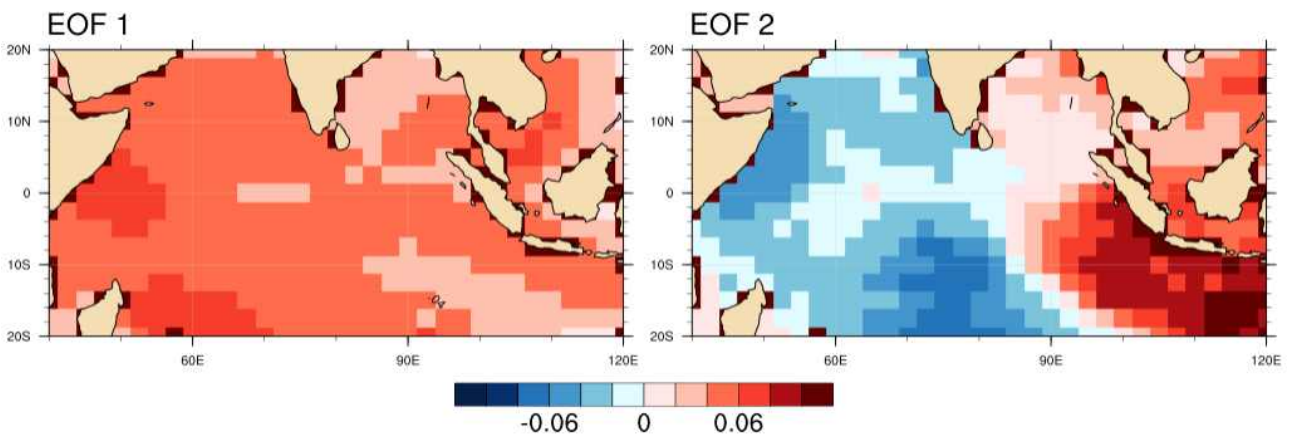


Figure 3.30. Spatial patterns of the first two EOF modes of SST over the Indian Ocean (20° S-20° N, 40° E-120° E) for the period 1993-2016 based on OISST observations.




Figure 3.31. PC time series of the first two EOF modes of SST over the Indian Ocean (20°S-20°N, 40°E-120°E) based on the OISST observations.

첫 번째 모드는 인도양 전반적으로 나타나는 신호로 경년 변동성이 있지만 장기적으로 우상향한 것을 보여준다. 즉, 인도양 SST는 지구 온난화를 여실히 반영하는 것을 의미하는데 두 번째 모드는 장기적 경향이 있지는 않다. 관측에서 나타나는 주요 모드들은 모델에서도 주요하게 모의한다(Figures 3.32, 3.33). 모델의 EOF 공간 패턴과 PC 시계열은 관측과 매우 유사하다. 다만 처음 두 모드가 설명하는 변동성이 관측에 비해 매우 높는데(각각 53%, 15%) 이는 모델의 SST 변동성이 관측만큼 크지 않고 주로 주요모드에 의해 설명된다는 것을 의미한다.

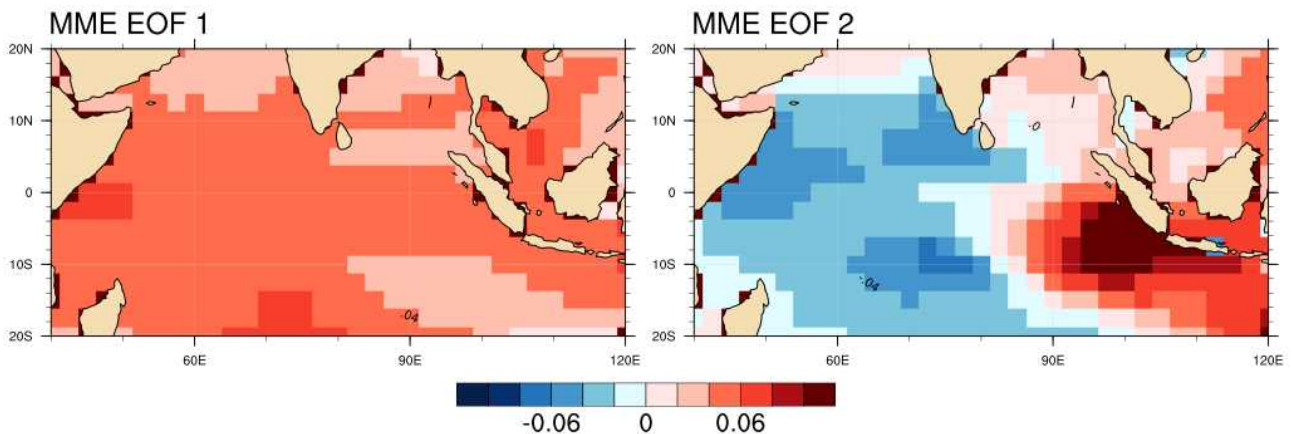


Figure 3.32. Spatial patterns of the first two EOF modes of SST over the Indian Ocean (20°S-20°N, 40°E-120°E) for the period 1993-2016 based on APCC SCM MME.




Figure 3.33. PC time series of the first two EOF modes of SST over the Indian Ocean (20° S-20° N, 40° E-120° E) based on the APCC SCM MME.

IOD, IOB는 EOF 분석 뿐 아니라 지역 SST 평균값으로 정의되는 전통적인 방법이 있는데 본 연구에서는 모델 예측과 비교하여 해석하기 쉬운 지역 SST 평균으로 두 기후모드를 정의하고 분석하였다.

IOD는 서인도양(WIO, 10° S-10° N, 50° E-70° E)과 동인도양(EIO, 10° S-0° , 90° E-110° E) SST의 차이로 정의하며 (IOD = WIO - EIO (Saji et al. 1999)) 표준편차로 나눈 표준화된 아노말리의 5개월 이동평균을 적용하였다. Figure 3.34는 관측 IOD의 시계열이며, 기후기간은 MME의 hindcast 기간인 1993-2016이다.




Figure 3.34. IOD time series based on OISST observations. Positive and negative IOD events are defined using a threshold of ± 0.5 , with the climatological period 1993-2016.

IOD가 양의 사례일 때, 동인도양에서 SST는 음의 아노말리를, 서인도양에서 양의 아노말리를 보인다(Figure 3.35). 음의 사례일 때는 반대 위상을 보이는데 양의 사례일 때 강도가 좀 더 강하다. IOD는 여름철에 점점 발달하다가 가을, 초겨울에 절정을 보이고, 2월이 되면서 패턴이 흐트러지는, 계절에 매우 의존적인 모드이며 동서 대비는 가을철에 가장 강하지만 서인도양의 강도는 특히 겨울철에 더욱 발달하여 비선형적 발달과정을 보인다. 봄철에는 사례가 없는 경우도 있어서 (5월 양의 사례, 3월 음의 사례) 봄철 합성장은 의미가 없다고 할 수 있다.

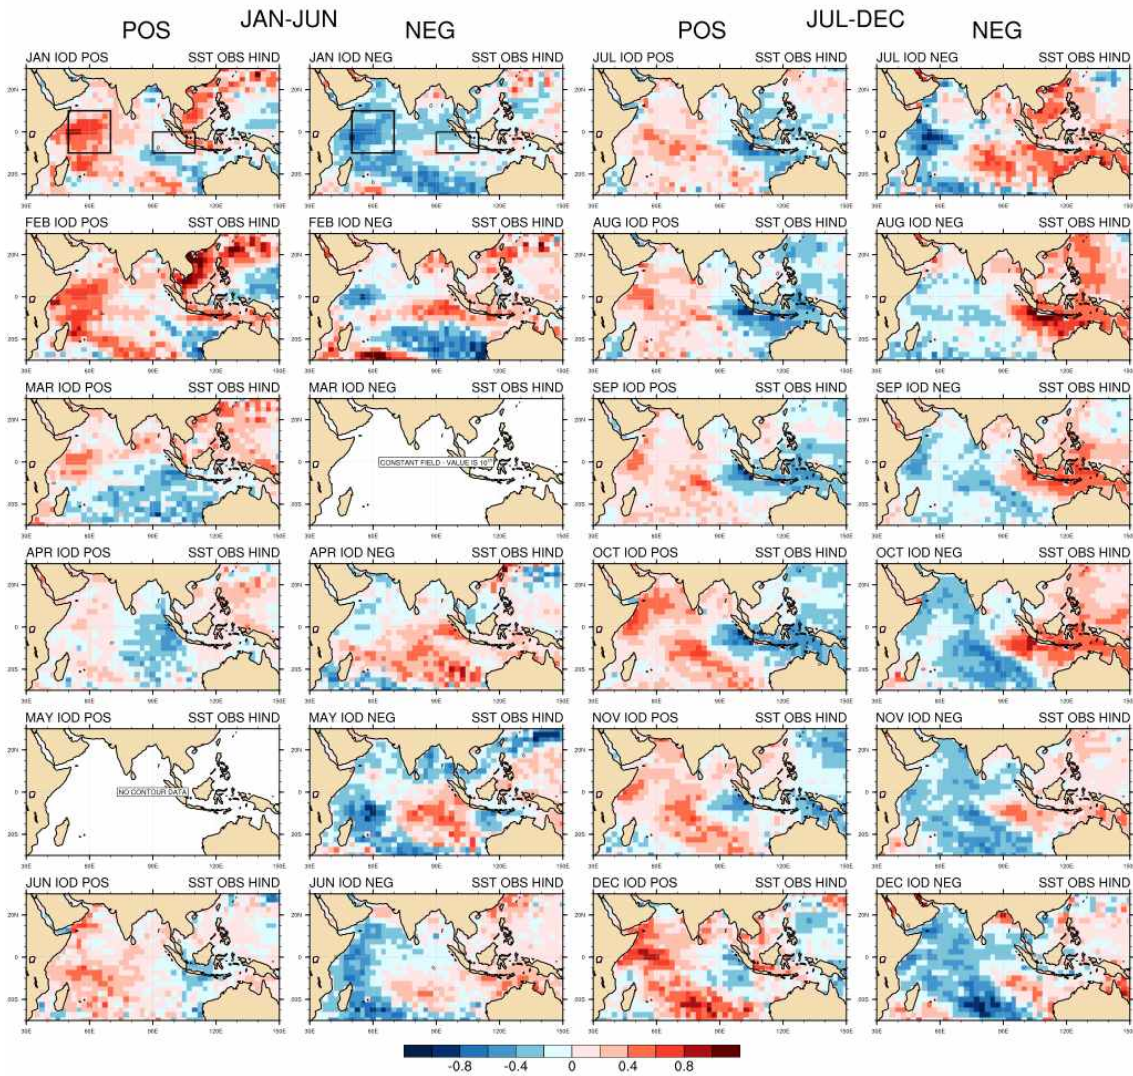


Figure 3.35. Composite SST anomaly patterns of IOD events based on the OISST observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016.

IOB는 인도양 전역(40° -100° E, 20° S-20° N)의 SST 아노말리를 평균한 값을 지수로 삼는다(Figure 3.36). IOD와 마찬가지로 5개월 이동 평균하고, 표준편차로 표준화한 값을 적용하였고 0.3을 초과할 때 양 혹은 음의 사례로 정의한다(Guo et al. 2018). 1990년대 이후 강한 온난화가 인도양 SST에 영향을 끼치고 IOB 지수는 그 효과를 여실히 반영한다. 1993-2016년 hindcast 기간 동안 IOB 지수의 선형추세는 0.72°Cyr-1이고, 2010년 이후 IOB는 대부분 양의 상태이다.




Figure 3.36. IOB time series based on OISST observations. Positive and negative IOB events are defined using a threshold of ± 0.3 , with the climatological period 1993-2016.

IOB가 양/음의 사례일 때의 SST 합성장 공간패턴은 인도양 전역의 온난화 혹은 냉각화를 보여준다. IOB는 계절에 크게 의존적이진 않지만 겨울에 발달하여 봄철에 절정이 되고 여름까지 지속되는 발달과정을 보인다.

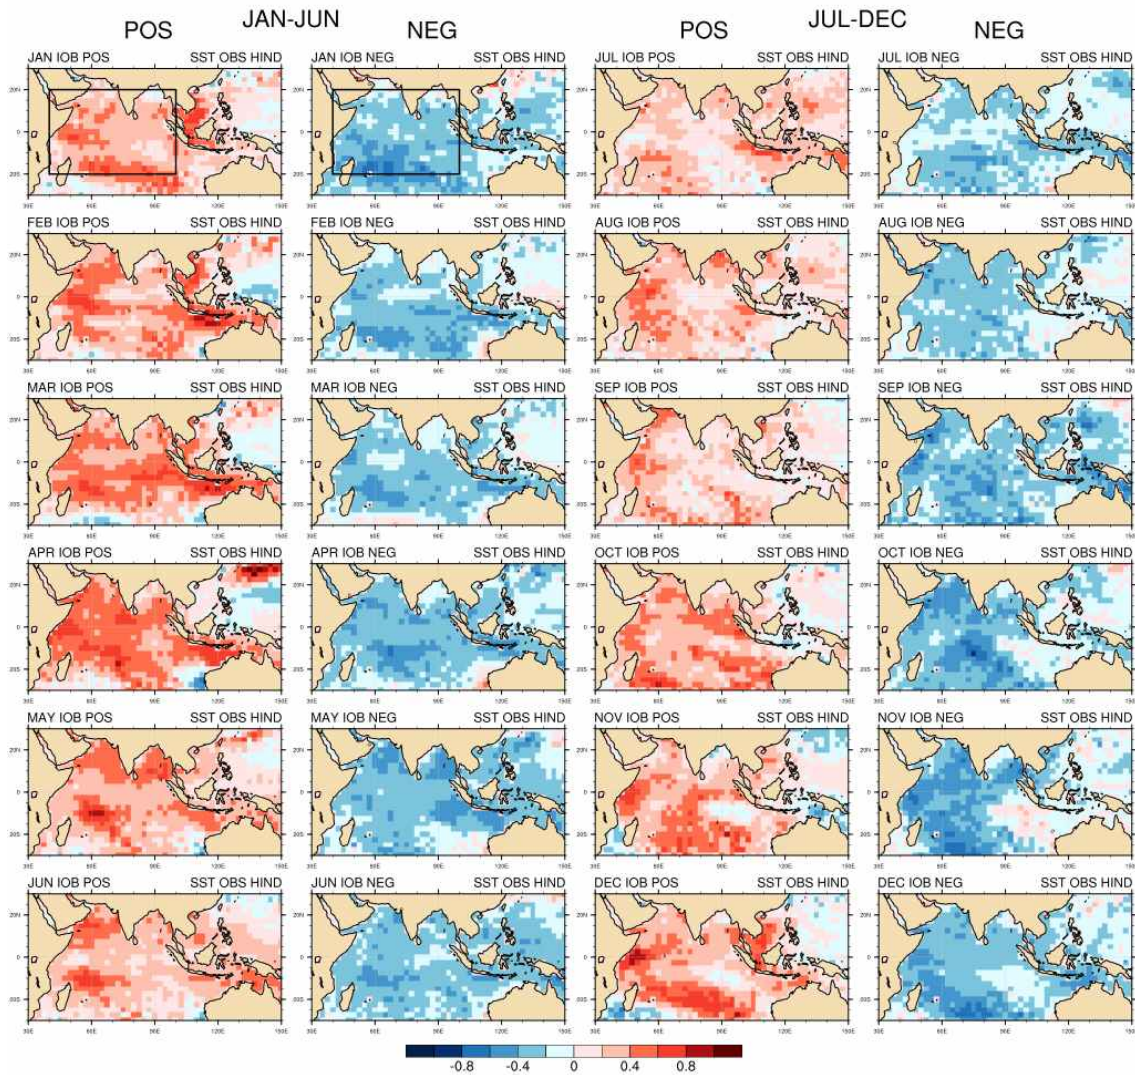


Figure 3.37. Composite SST anomaly patterns of IOB events based on the OISST observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016.

3.5.2. Hindcast 기간 인도양 기후모드 진단 및 예측성 평가

모델에서도 마찬가지로 IOD를 정의하여 시계열을 표현하였다(Figure 3.38). 1개월 선행 예측에서는 MME를 비롯하여 많은 개별모델의 예측이 관측과 괴리가 크지 않지만 선행시간이 길어질수록 MME도 그렇지만 특히 개별모델의 예측이 달라지고 다양해진다.

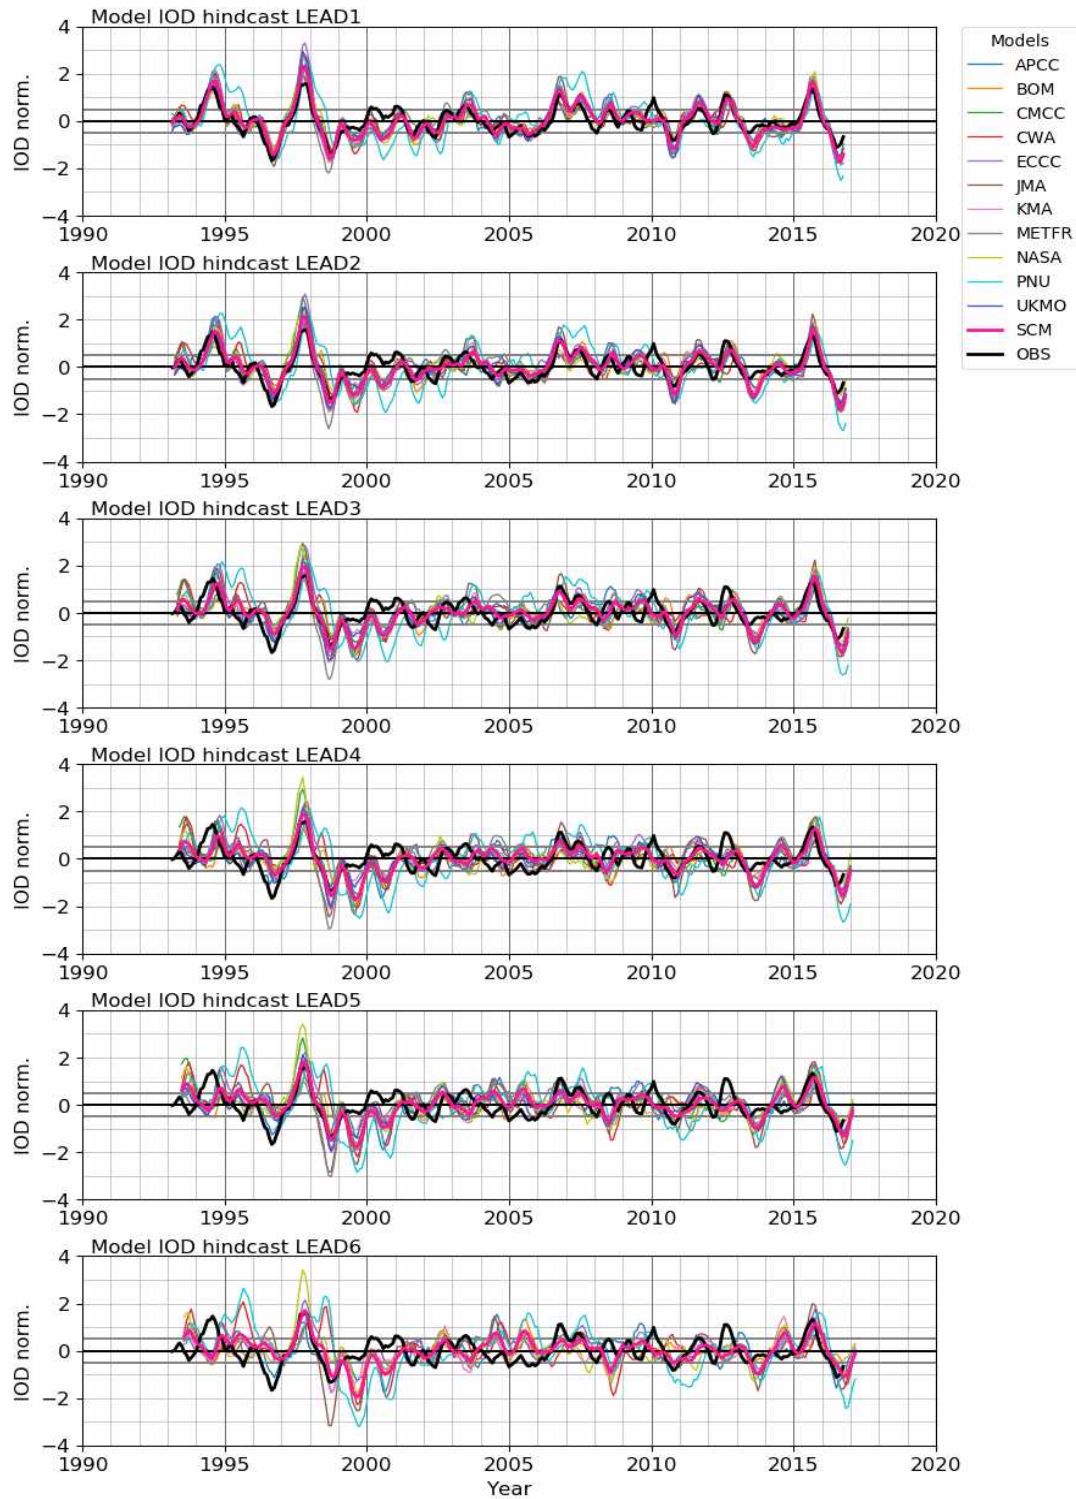


Figure 3.38. IOD time series based on APCC MME models with forecasts lead from 1 to 6 months. Positive and negative IOD events are defined using a threshold of ± 0.5 , with the climatological period 1993–2016. The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line.

모델의 공간패턴의 합성장은 관측의 주요한 특성을 꽤 잘 반영하지만 서인도양에서의 강도는 비교적 약하게 예측하며 특히 음의 사례에서 SST의 동서대비 편차가 줄어들고, 2월이 되어 IOD가 붕괴되는 시기에도 모델에서는 신호가 비교적 강하게 남아있는 특성이 있다(Figure 3.39).

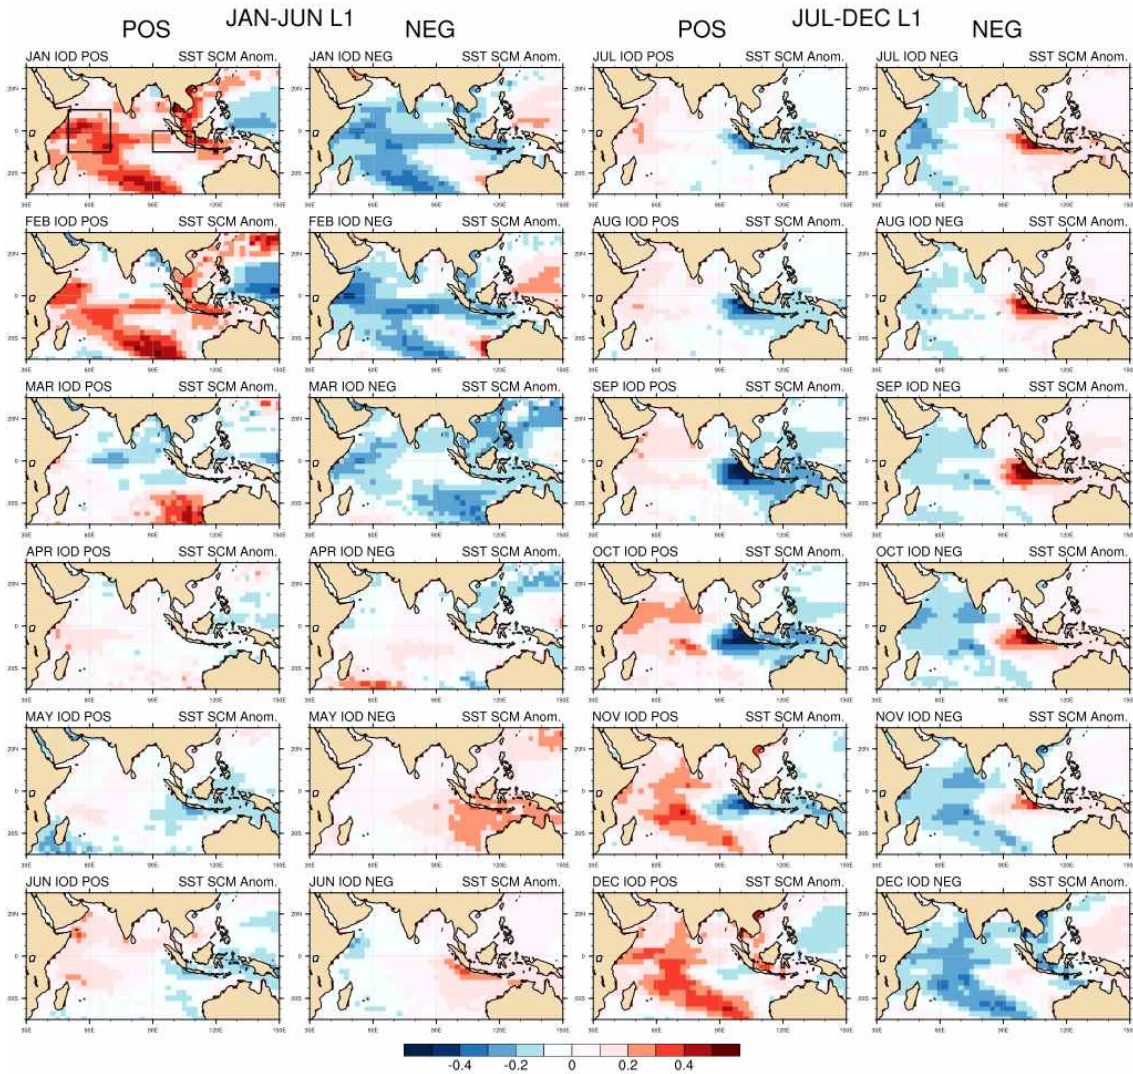


Figure 3.39. Composite SST anomaly patterns of IOD events based on the SCM MME with forecast lead 1-month: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016.

모델은 1개월 선행시간에서는 비교적 공간적 패턴을 유사하게 모의하지만 선행시간이 길어질수록 예측력은 안 좋아지고 5개월 선행시간에서는 가을철 SST의 동서대비가 약하게 나타나는 패턴을 보여준다(Figure 3.40).

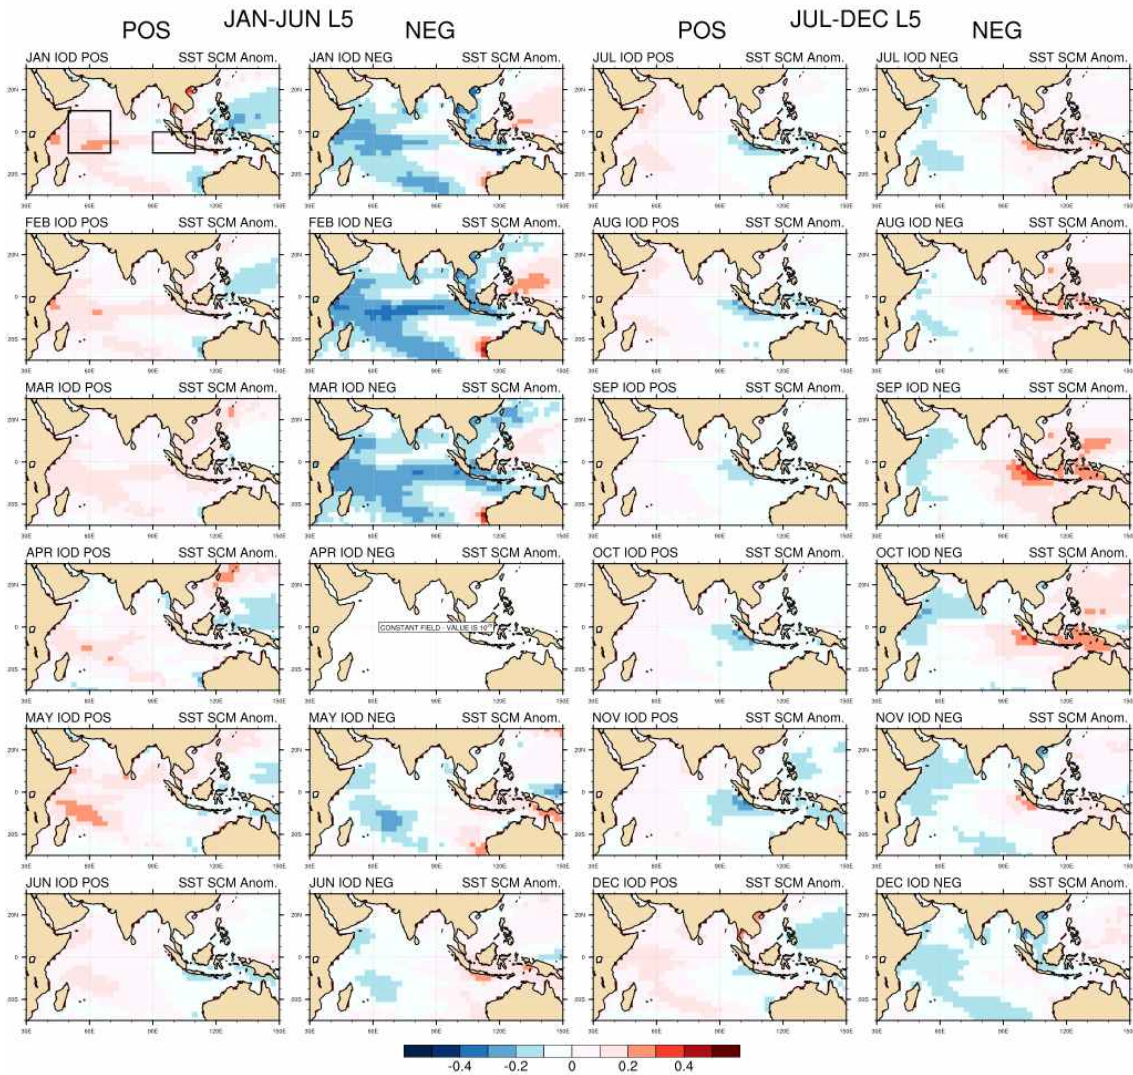


Figure 3.40. Composite SST anomaly patterns of IOD events based on the SCM MME with forecast lead 6-months: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016.

SST 공간패턴이 동서대비를 보이는 동안 해면기압과 강수, 상하층 바람도 이에 상응하는 물리과정을 보여준다(Figure 3.41). 양의 사례에서 동인도양의 냉각수온이 나타나면, 고기압과 건조대가 나타나고 하층에서는 동풍, 상층에서는 서풍이 나타나며, 서인도양에서는 따뜻한 수온과 저기압대, 강한 강수활동이 나타난다. 음의 사례에서는 이와 반대되는 패턴이 나타난다.

모델은 관측과 유사하게 물리과정을 모의하지만 변동성이 작으며, 특히 서태평양에서의 변동성이 약하게 나타나고 관측에 비해 패턴의 지속시간이 짧다(Figure 3.42).

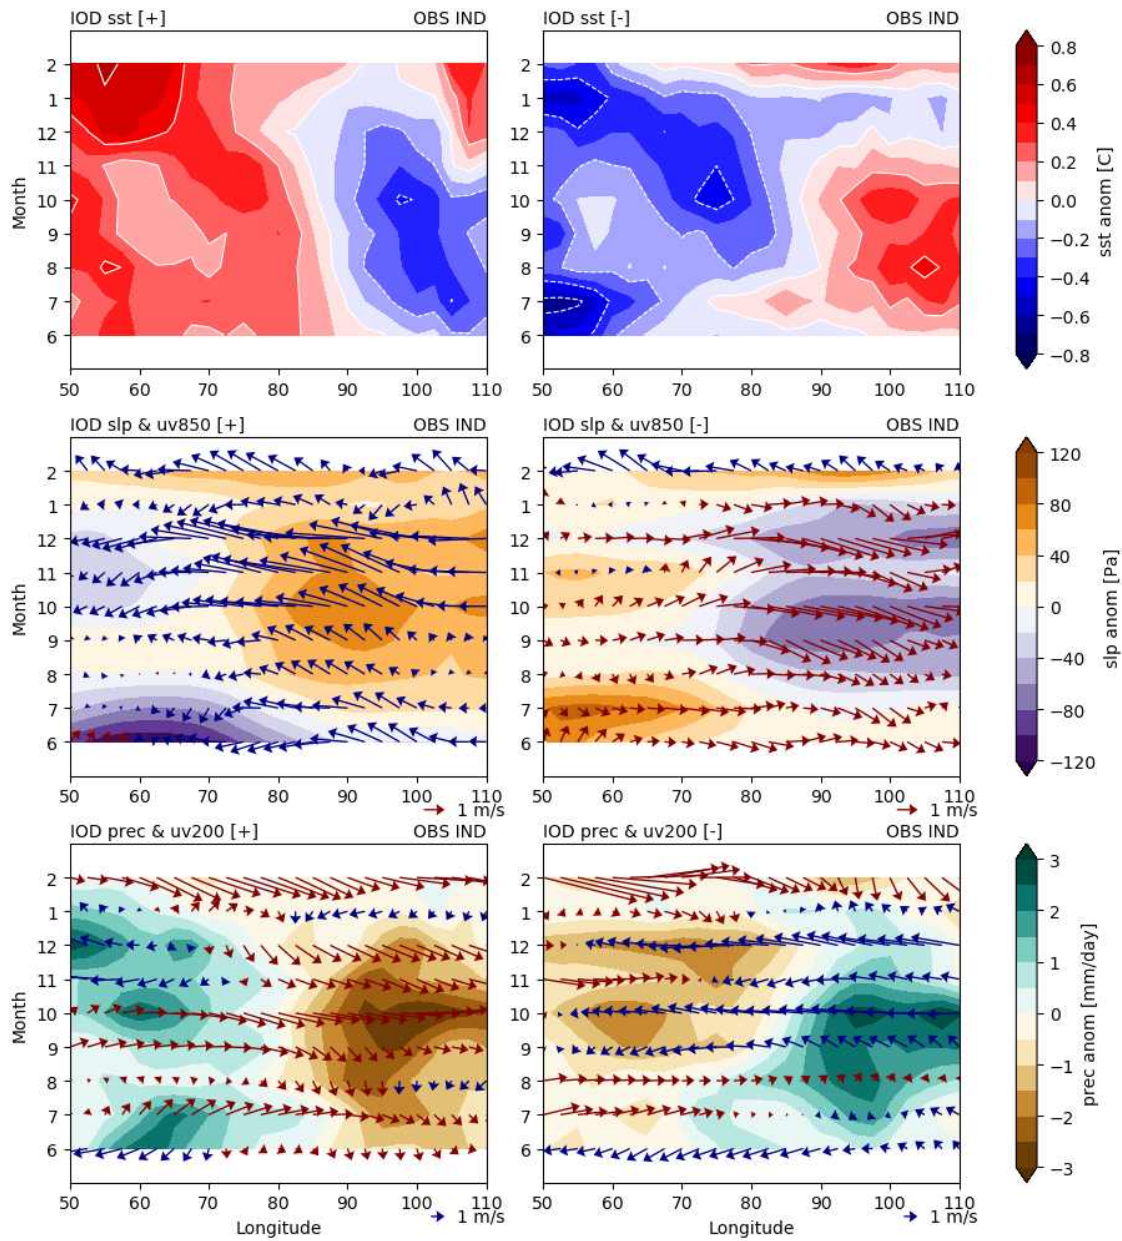


Figure 3.41. Longitude-month evolution from June to following February of (upper) SST, (middle) SLP and 850-hPa winds, and (lower) precipitation and 200-hPa winds, composited for positive (left) and negative (right) IOD events from observations over the Indian Ocean. All fields are averaged over 10°S-5°N.

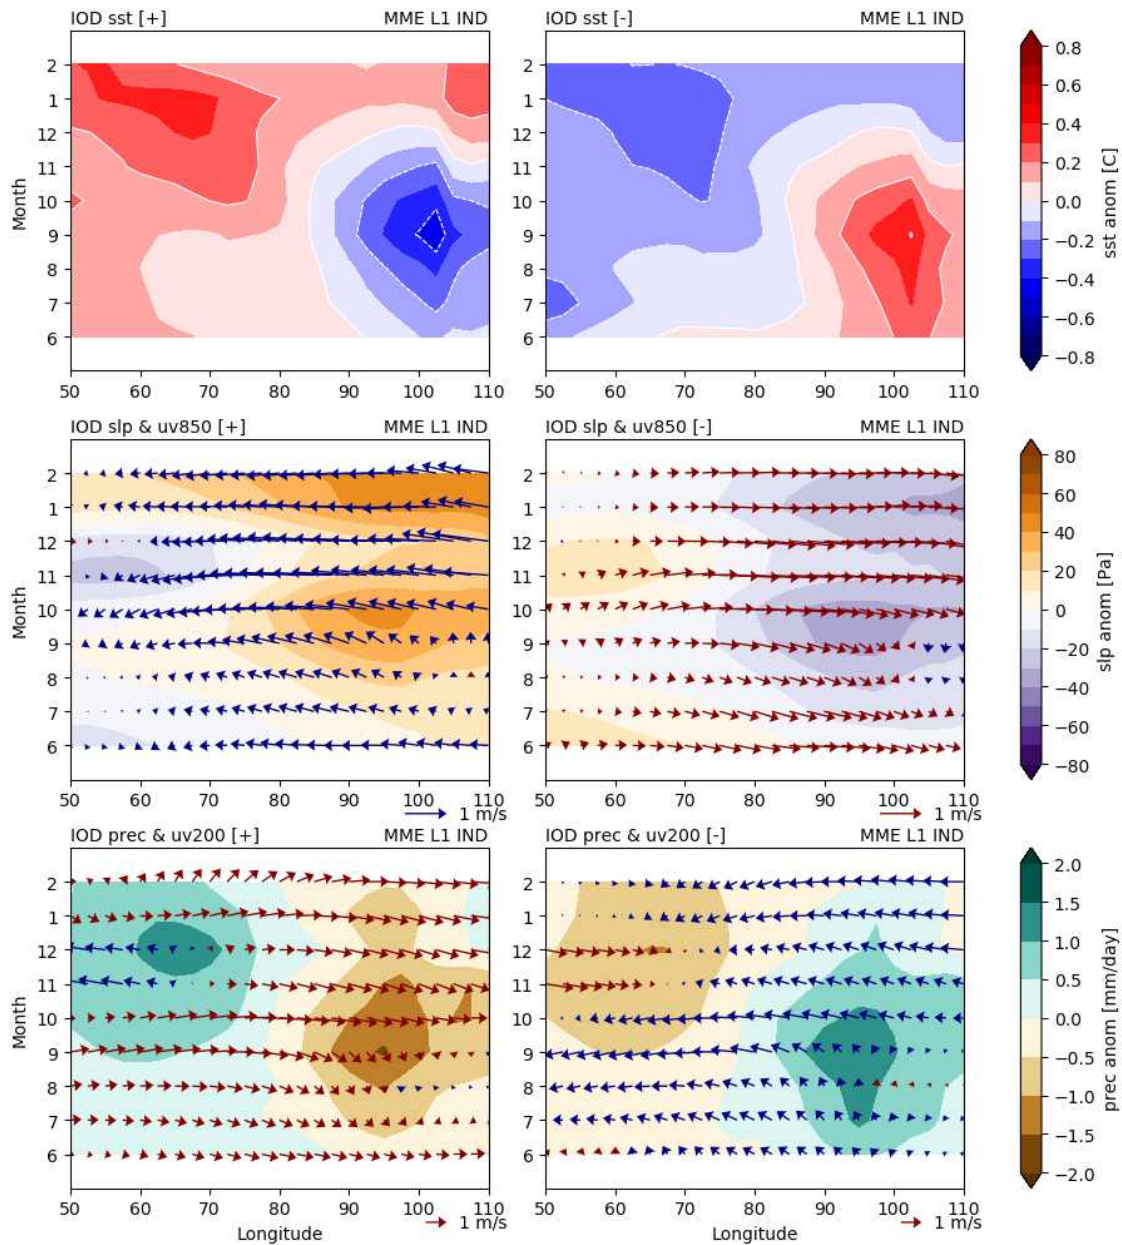


Figure 3.42. Longitude-month evolution from June to following February of (upper) SST, (middle) SLP and 850-hPa winds, and (lower) precipitation and 200-hPa winds, composited for positive (left) and negative (right) IOD events from MME observations lead at 1 month over the Indian Ocean. All fields are averaged over 10° S– 5° N.

모델의 IOD 예측스킬을 객관적으로 분석하기 위해 IOD 시계열과, 사례별 SST 패턴 공간장의 월별 상관관계를 계산하였다(Figure 3.43). IOD는 계절의존적인 기후모드이기에 강도가 강한 시기에는 예측력이 우수하다. 여름부터 예측력은 좋아지고, 가을에 가장 좋았다가, 2월이 되면 예측력이 급격하게 떨어진다. 대체로 선행시간이 길어질수록 예측력은 낮아지지만 여름에 시작한 예측은 가을이 되어 오히려 TCC 스킬이 좋아지기도 한다. 봄철에는 예측력이 좋지 않지만 선행시간 1개월은 TCC 스킬은 유의미하다. PCC 스킬은 여름, 가을, 이른 겨울철에 비교적 높

은데 이는 SST 동서대비를 잘 모의하는 것을 반영한다. 다만 음의 사례는 양의 사례에 비해 PCC 스킬은 낮다.

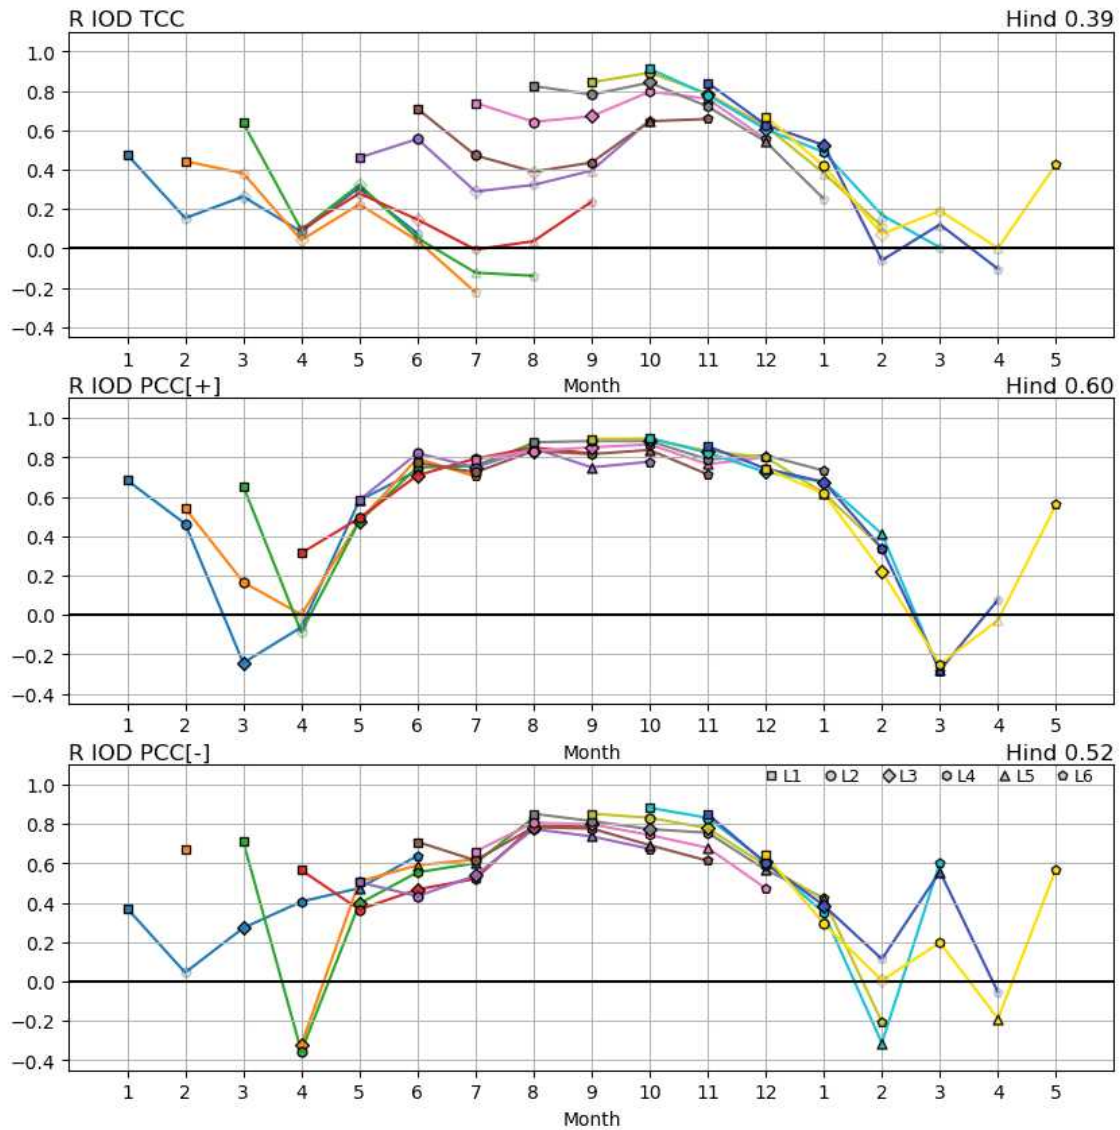


Figure 3.43. Monthly (top) temporal correlation coefficients (TCC) of the IOD time series, and anomaly pattern correlation coefficients (PCC) of SST anomalies over the Indian Ocean (10° S- 5° N, 50° E- 100° E) for (middle) positive cases and (bottom) negative cases, between observations and MME forecasts with lead times from 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level.

모델에서도 마찬가지로 IOB를 정의하여 시계열을 표현하였다(Figure 3.44). 선행시간이 길어져도 IOB 시계열의 예측력은 비교적 우수하고, 개별모델간의 차이도 크지 않다. 반면에 모델의 공간패턴의 합성장은 SST의 양과 음의 패턴은 잘 모의하지만 강도가 약하고, 관측에서 나

타나는 패턴을 세밀하게 따라가지는 못한다(Figure 3.45).




Figure 3.44. IOB time series based on APCC MME models with forecasts lead from 1 to 6 months. Positive and negative IOB events are defined using a threshold of ± 0.3 , with the climatological period 1993-2016. The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line.

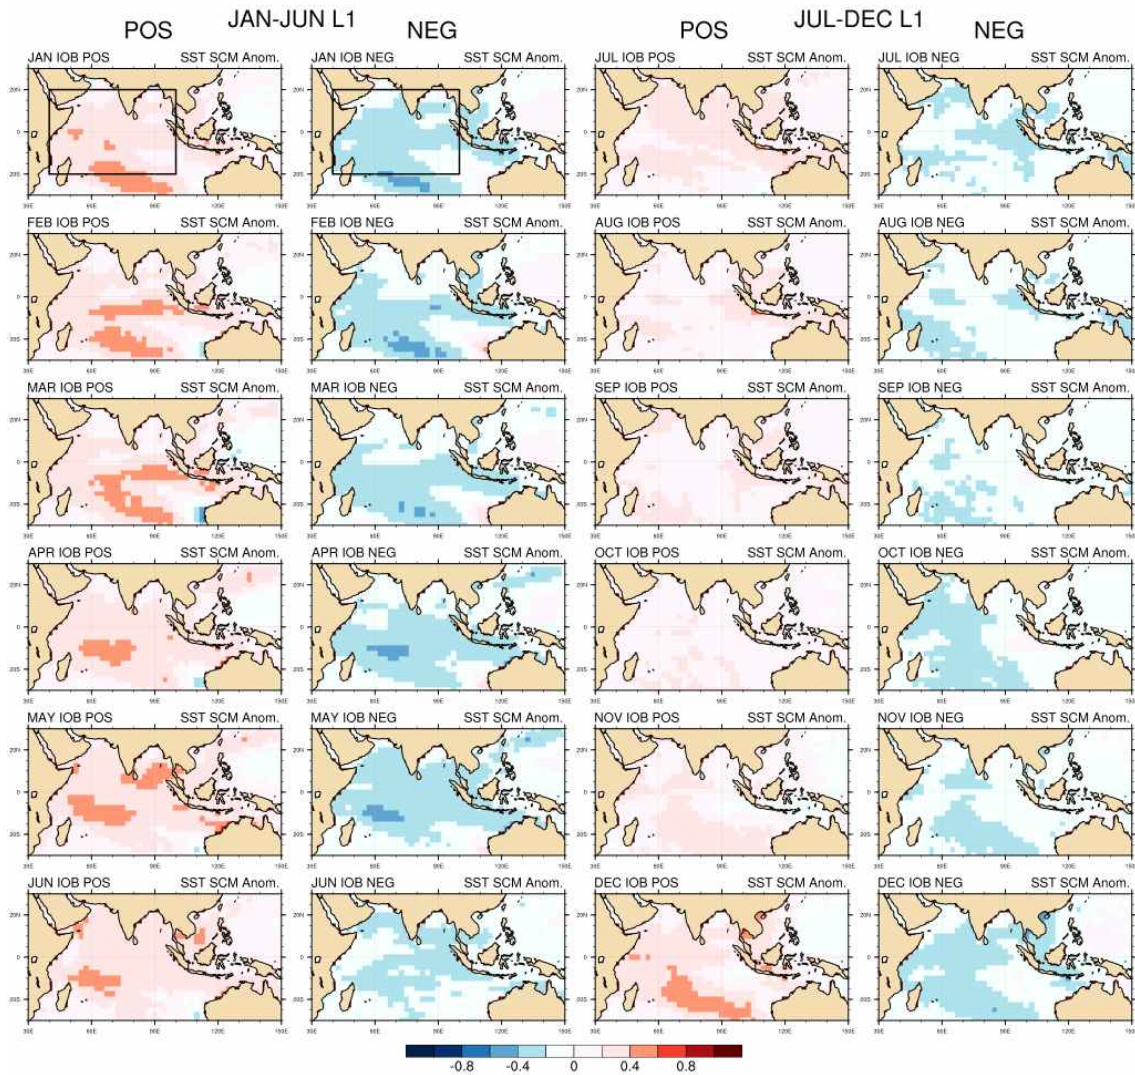


Figure 3.45. Composite SST anomaly patterns of IOB events based on the SCM MME with forecast lead 1-month: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993-2016.

인도양의 SST가 전반적인 양/음의 패턴을 보일 때 이에 상응하는 강수와 하층바람의 물리 과정이 나타난다(Figure 3.46, 3.47, 3.48). IOB의 온난한/차가운 SST는 축전기(capacitor)와 같은 역할을 해서 겨울-봄철에 온난한/차가운 열에너지를 여름에 인접한 지역에 이를 전파하는 역할을 한다. 양의 사례에서 겨울철 동인도양의 동풍 편차는 Rossby wave를 서쪽으로 전달하고, 적도 남서쪽 인도양의 따뜻한 SST는 적도를 중심으로 한 비대칭적(antisymmetric) 바람장을 유발한다. 이는 겨울철, 봄철에 유지되고 늦봄이 되면 북인도양의 동풍 편차는 따뜻한 해수면 온도를 유발하고 이는 여름철까지 지속된다. 그리고 인도양 적도의 따뜻한 해수면온도는 Kelvin 파를 유도하여 여름철 북서태평양 지역 대류활동을 약화시키는 역할을 한다.

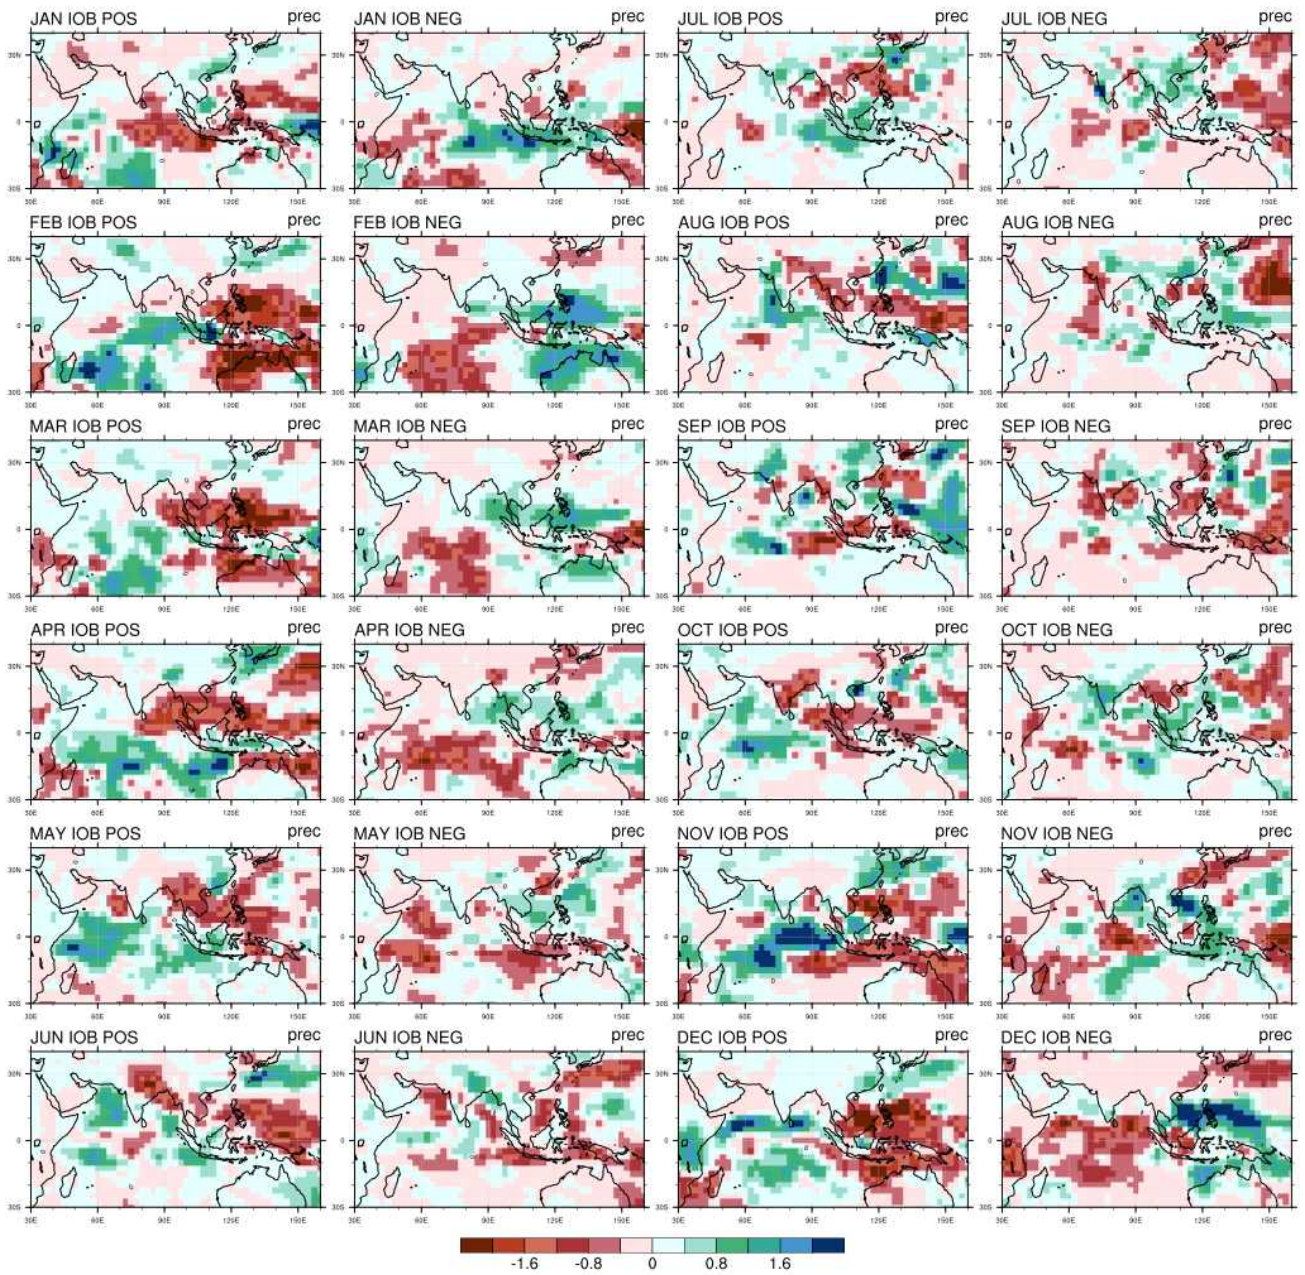


Figure 3.46. Composite precipitation anomaly patterns of IOB events based on the GPCP observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993–2016.

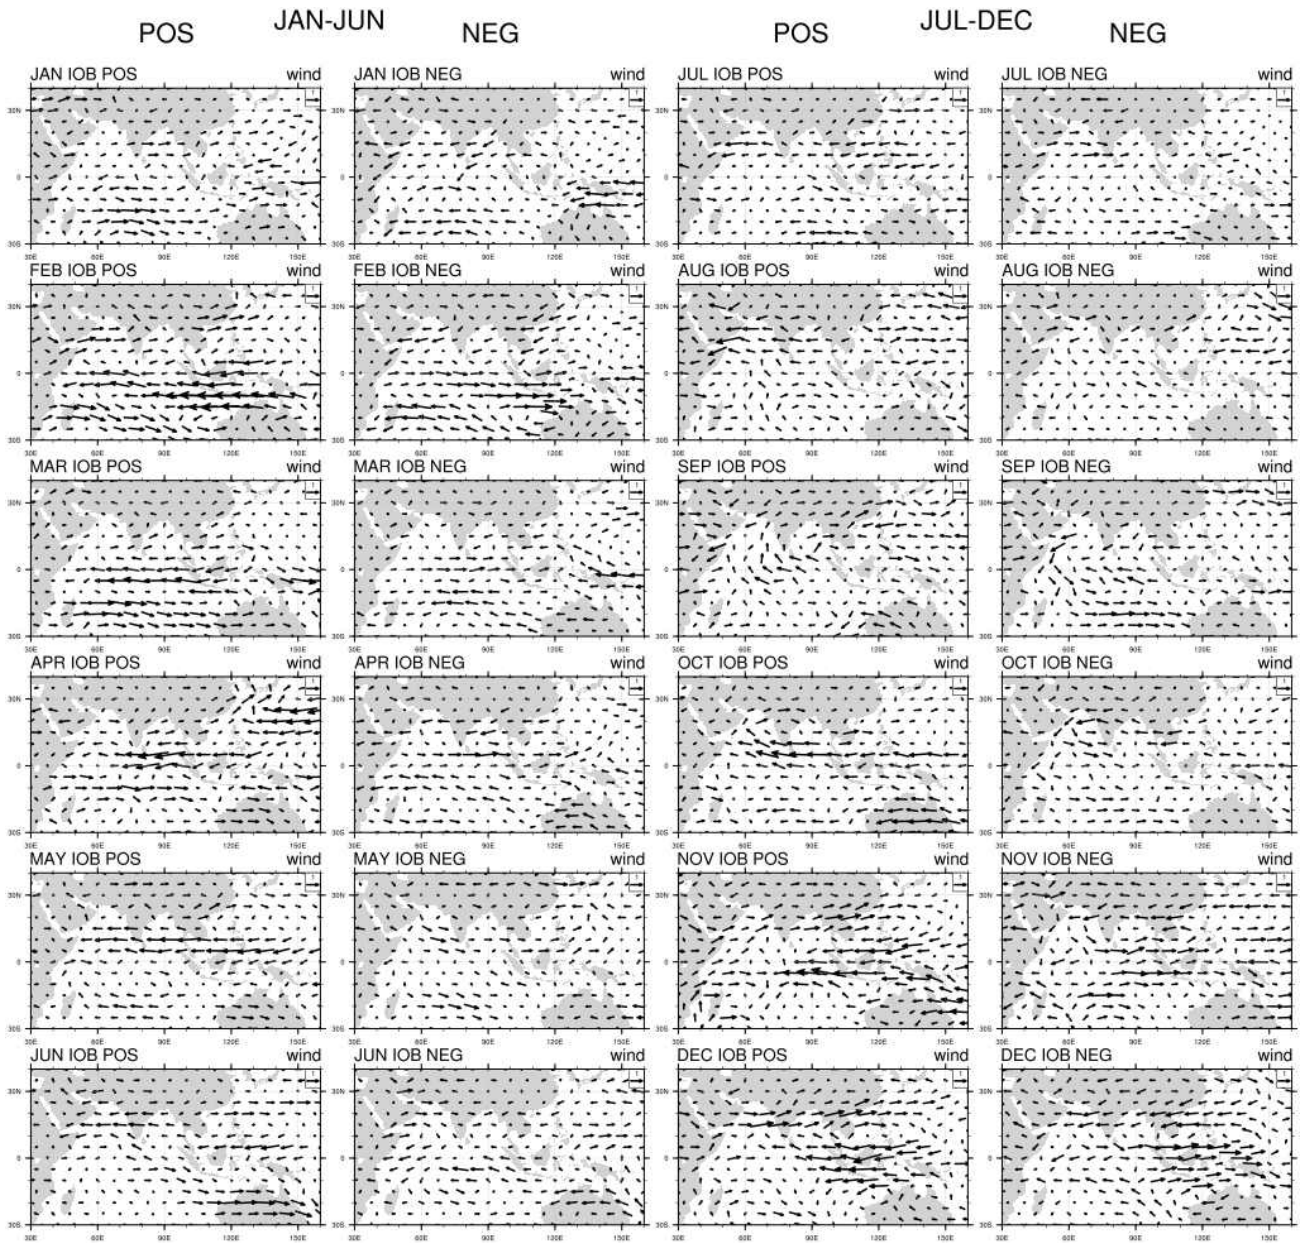


Figure 3.47. Composite 850-hPa wind anomaly patterns of IOB events based on the NCEP1 observations: positive cases (columns 1 and 3) and negative cases (columns 2 and 4), from January (top left) to December (bottom right) for the period 1993-2016.

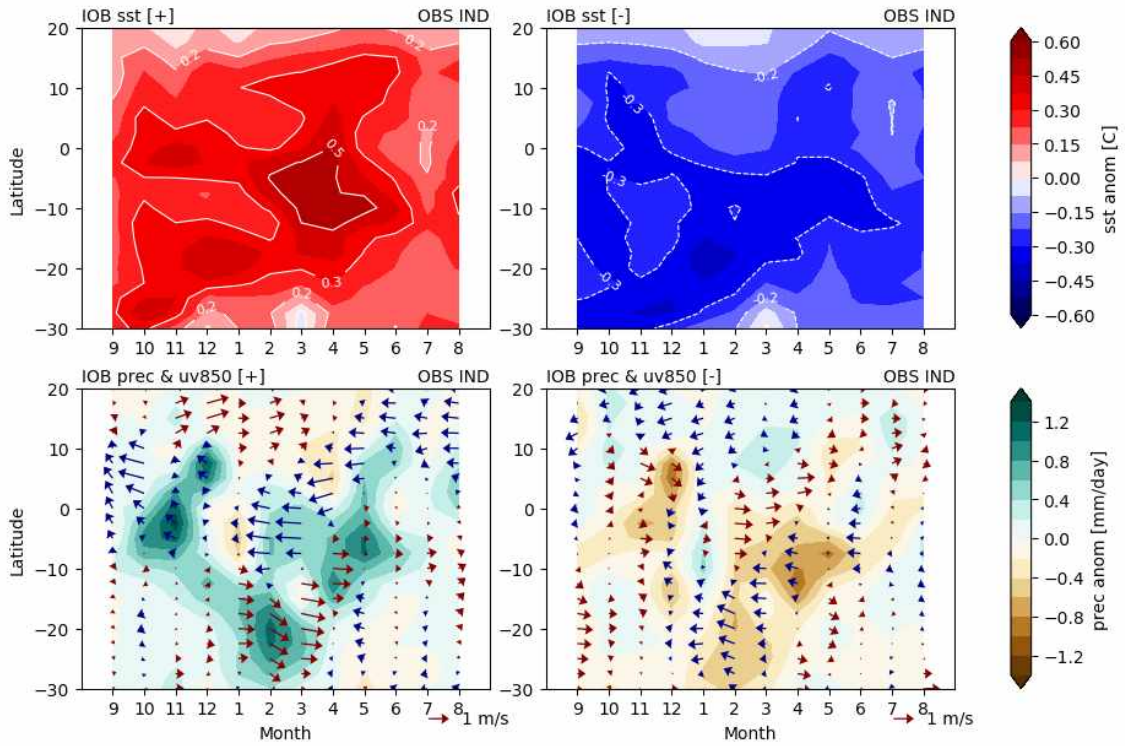


Figure 3.48. Month-Latitude evolution from September to the following August of (top) SST and (bottom) precipitation and 850-hPa winds, composited for (left) positive and (right) negative IOD events from observations over the Indian Ocean. All fields are averaged over 40° -100° E.

반면에 모델의 SST, 강수, 하층 바람장은 전반적인 해수면온도의 온난/냉각과 동/서풍 편차는 유사하지만 강도가 작고 세밀한 강수 구조는 모의하지 못한다(Figure 3.49). 특히 남서인도양의 강수/건조 패턴이나 북인도양 늦봄/초여름에 나타나는 해수면온도의 강한 온난/냉각 구조는 지연되어 모의하는 경향이 있다.

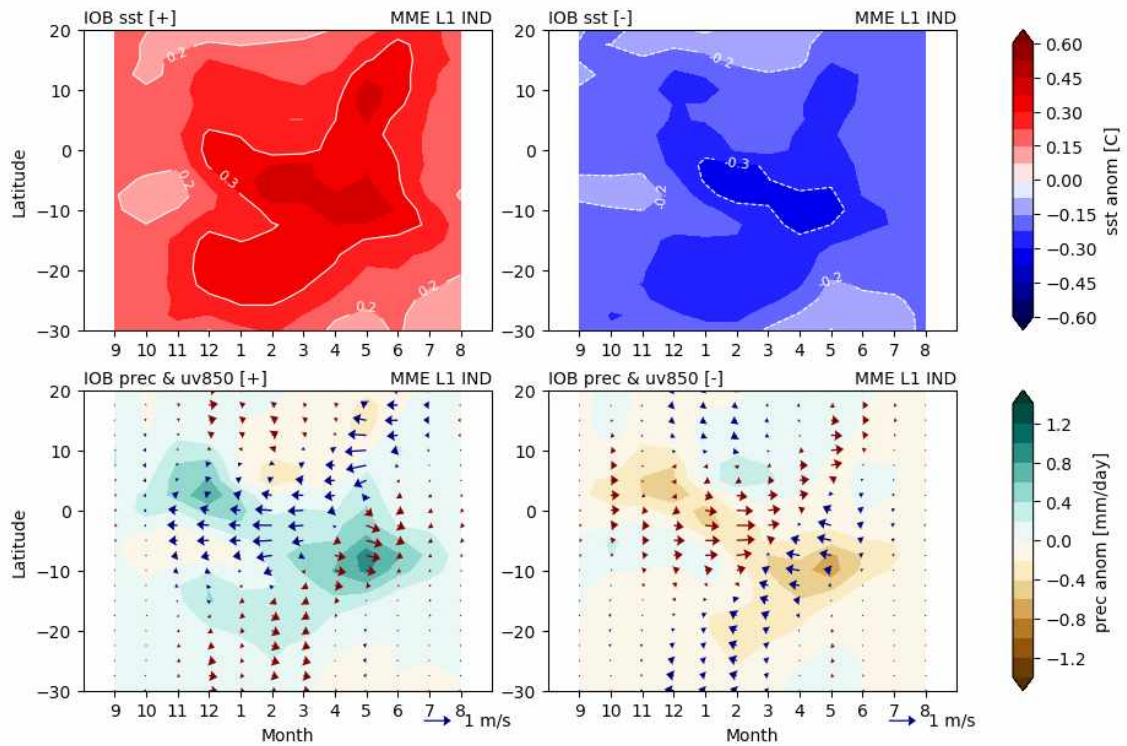


Figure 3.49. Month-Latitude evolution from September to the following August of (top) SST and (bottom) precipitation and 850-hPa winds, composited for (left) positive and (right) negative IOD events from SCM MME forecasts lead 1 month over the Indian Ocean. All fields are averaged over 40° -100° E.

IOB 시계열과 SST 공간패턴의 상관관계를 객관적으로 나타내기 위해 TCC와 PCC를 계산하였다(Figure 3.50). 시계열의 TCC 스킵은 비교적 우수하며 특히 겨울, 봄철에 스킵이 우수한 것을 볼 수 있다. 여름철이 되면 선행시간이 길어짐에 따라 스킵이 낮아지지만 유의미한 수준을 유지한다. 하지만 PCC 스킵은 겨울, 봄철은 유의미하지만 여름철에는 매우 낮다. 따라서 IOB는 시계열 예측은 신뢰할 수 있지만 특히 여름철 SST 패턴 예측은 신뢰할 수 없다고 판단한다.

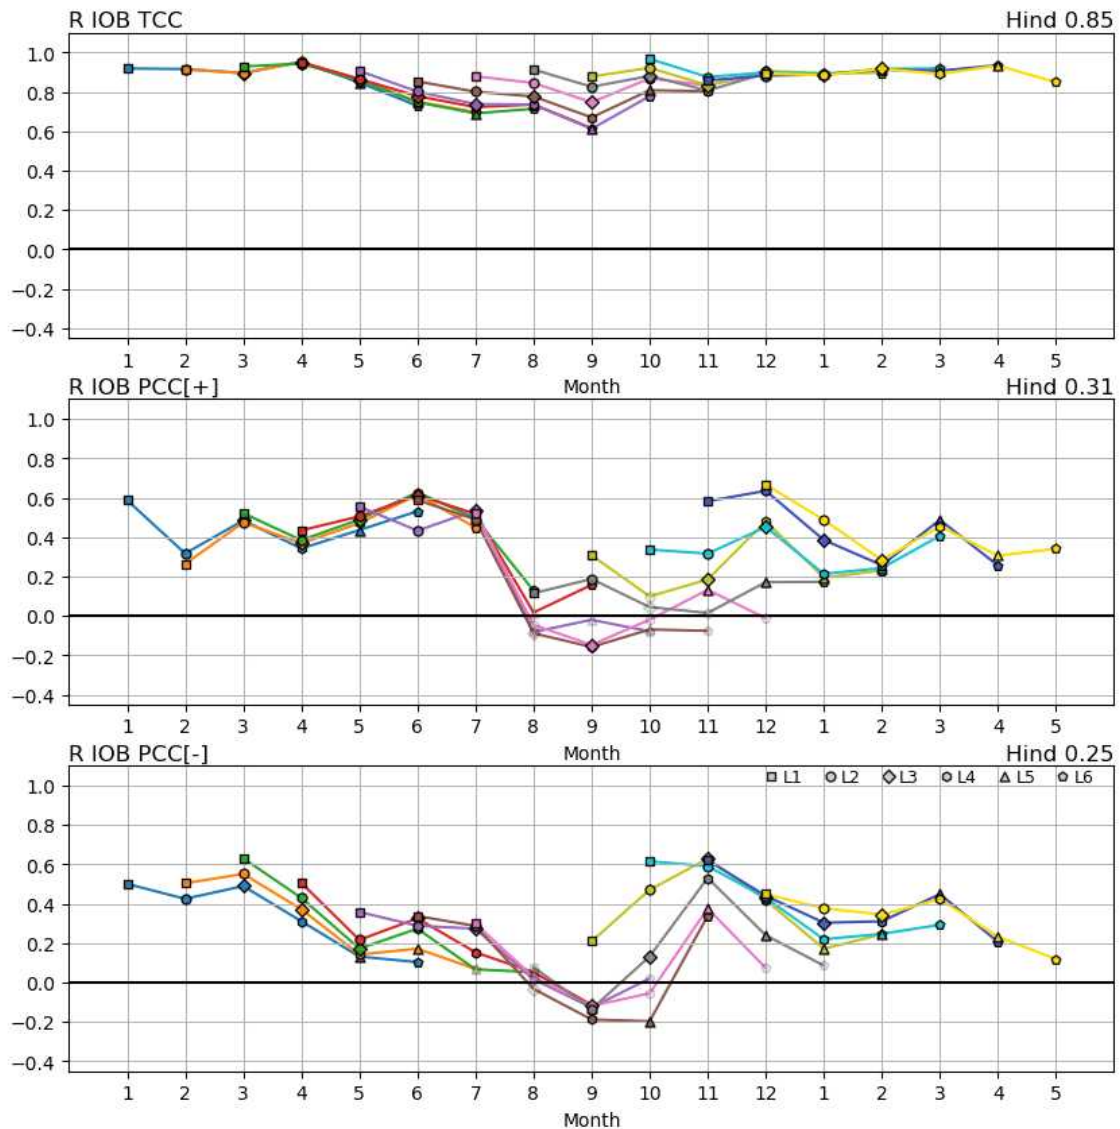


Figure 3.50. Monthly (top) temporal correlation coefficients (TCC) of the IOB time series, and anomaly pattern correlation coefficients (PCC) of SST anomalies over the Indian Ocean (20° S- 20° N, 40° E- 100° E) for (middle) positive cases and (bottom) negative cases, between observations and MME forecasts with lead times from 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level.

IOD, IOB 그리고 태평양의 기후모드 ENSO는 대기의 가교역할과 해양 상호작용을 통해 서로 영향을 주고 받는다고 알려져있다. ENSO는 Nino3.4 지수(5° S- 5° N, 120° W- 170° W)로 정의하였고 5개월 이동평균하여 표준편차로 나누어 표준화하였다. 관측과 모델의 선행지연 상관관계를 계산하였는데(Figure 3.51), 관측에서는 ENSO가 IOB를 3개월 선행하여 0.6의 강한 상관관계가 있고, IOD는 ENSO와 0.36의 동시상관관계가 있다. 따라서 IOD는 IOB를 3개월 선행하고, 0.32의 상관관계가 있다. 따라서 ENSO와 IOD가 가을에 발생하고 겨울에 절정이 되는 경향이 있고, 이후 IOB가 겨울에 발달하면서 봄철에 절정이 되는 경향이 있으며 특히 ENSO와 IOB

의 상관관계가 강하다. 모델에서도 이러한 상관관계는 유사하거나 오히려 강하게 나타나는데, 선행시간이 길어질수록 오히려 상관관계가 높아진다. 이는 역학모델에서 공통적으로 나타나는 spurious oceanic teleconnection에 의한 것으로, 모델에서는 IOD-ENSO의 관계가 과장되어 나타난다.

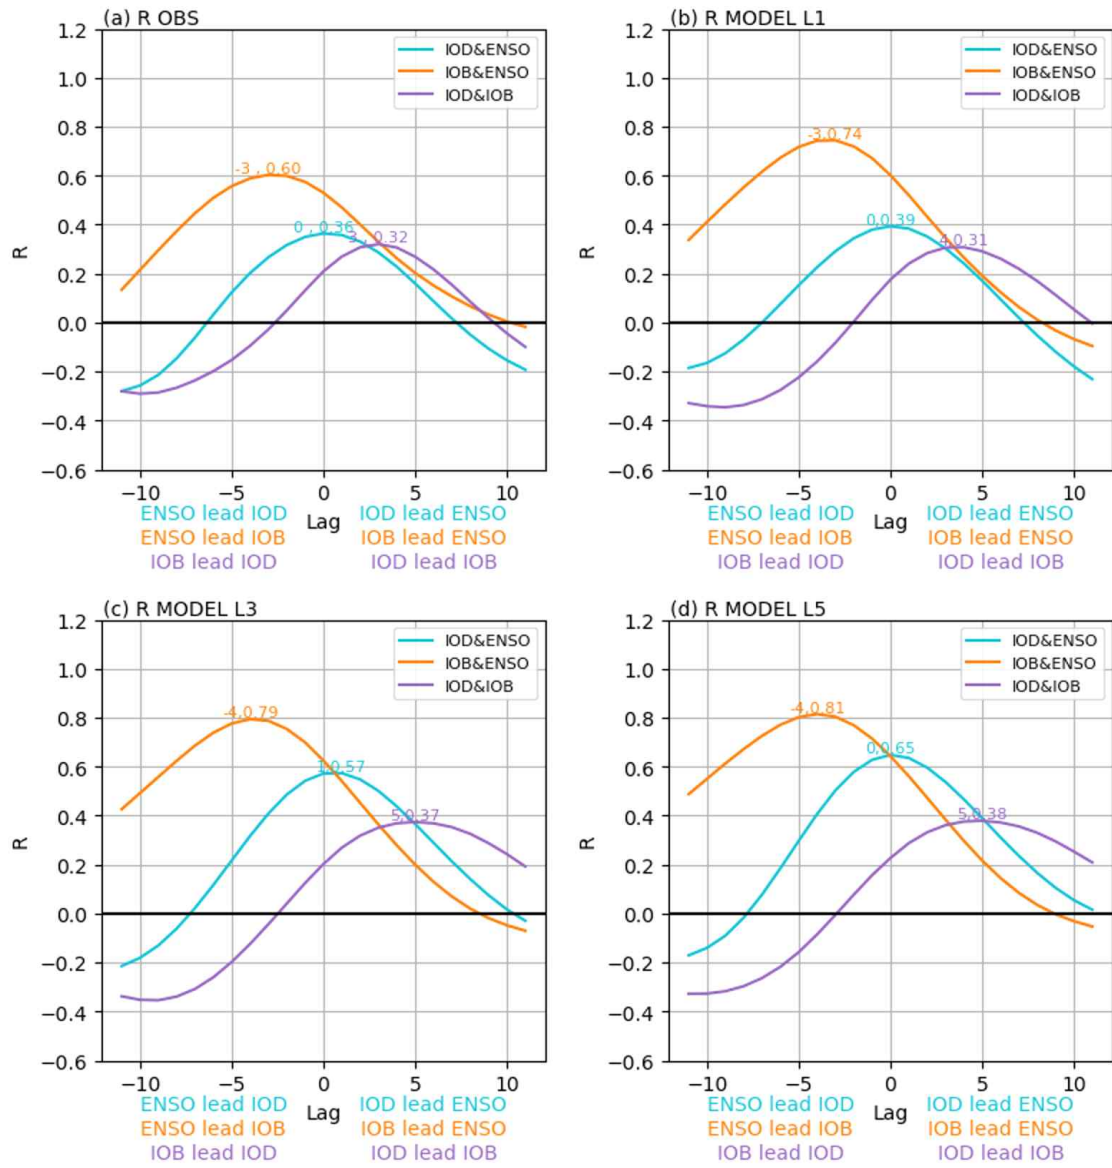


Figure 3.51. Monthly lead-lag correlation coefficients between (cyan) IOD and ENSO, (orange) IOB and ENSO, and (purple) IOD and IOB for (a) observations and forecasts with lead times of (b) 1 month, (c) 3 months, and (d) 5 months during 1993-2016.

3.5.3. 실시간 예측기간 인도양 기후모드 예측성 평가

최근 지구 온난화와 같은 기후변화로 인해 역학모델의 최근인 실시간 예측기간과 과거인 hindcast 기간의 예측특성 변화는 예측 신뢰도를 낮추는 요인으로서, 이를 극복하기 위해서는 r 실시간 예측 기간에 대해 분석을 강화해야 한다. 앞서 설명한 바와 같이 가용한 해수면온도 자료는 2012년부터 있지만 인도양 분석에는 MME를 생산한 이후인 2014년부터, MME와 MME 데이터에 메타정보에 명시되어 있는 개별모델만을 이용하여 적용하였다(Figure 3.52).




Figure 3.52. Participated individual models of SST MME for real-time forecast period. ECCC included MSC.

Figure 3.53은 SST의 real-time 기간 선행시간 1, 3, 5개월 IOD 예측 시계열을 관측과 함께 표현한 것이다. 대체적으로 관측과 유사하게 예측을 하지만 비교적 개별모델들의 예측의 범위가 넓으며 사례별로 예측력이 상이하다. 2015년, 2024년 사례는 모델이 IOD를 관측보다 강하고 오래 지속하는 것으로 예측하였으나 2019년은 관측에 비해 약한 강도로 예측하였다.

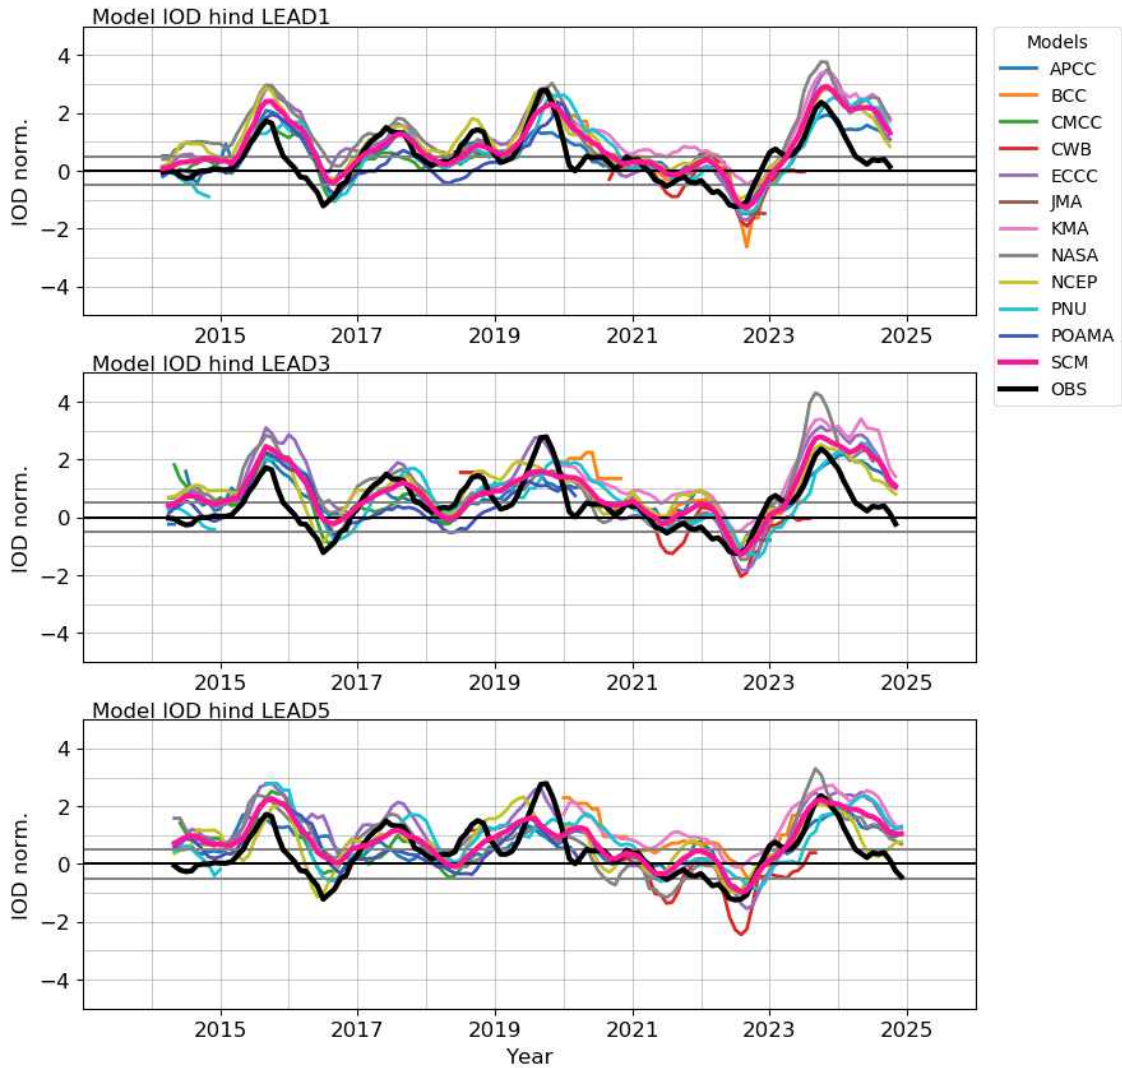


Figure 3.53. IOD time series based on APCC MME models with forecasts lead from 1 to 6 months for the real-time forecast period, 2013–2024. The climatological period for each year corresponds to the model hindcast period (e.g., the hindcast period for 2024 is 1991–2010). Positive and negative IOD events are defined using a threshold of ± 0.5 . The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line.

11년 동안 IOD 시계열의 상관관계를 계산하기 위해 월별 ranked correlation coefficient (RCC)를 Figure 3.54에 표현하였다. 11년은 샘플수가 적기 때문에 샘플수가 덜 민감한 RCC를 적용하였다. 5월부터 상관관계는 유의미하고, 점점 증가하다가 11, 12월이 되면 예측력은 떨어지는 것은 hindcast 기간과 유사하지만 겨울, 봄철 예측력은 유의미하지 않고 낮아서 실제로 이 시기에는 IOD의 예측을 신뢰하지 못한다.




Figure 3.54. Monthly ranked correlation coefficients of the IOD time series between observations and MME forecasts with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level.

MME의 스킬이 안정적이고 대체적으로 우수하지만 개별모델별로 RCC 스킬을 살펴보면 NCEP, ECCG가 비교적 높다(Figure 3.55). BCC, CWB가 큰 경우도 있는데, 이들은 실제 예측 기간이 얼마되지 않아 샘플수가 적기 때문에 해석에 주의해야 한다.

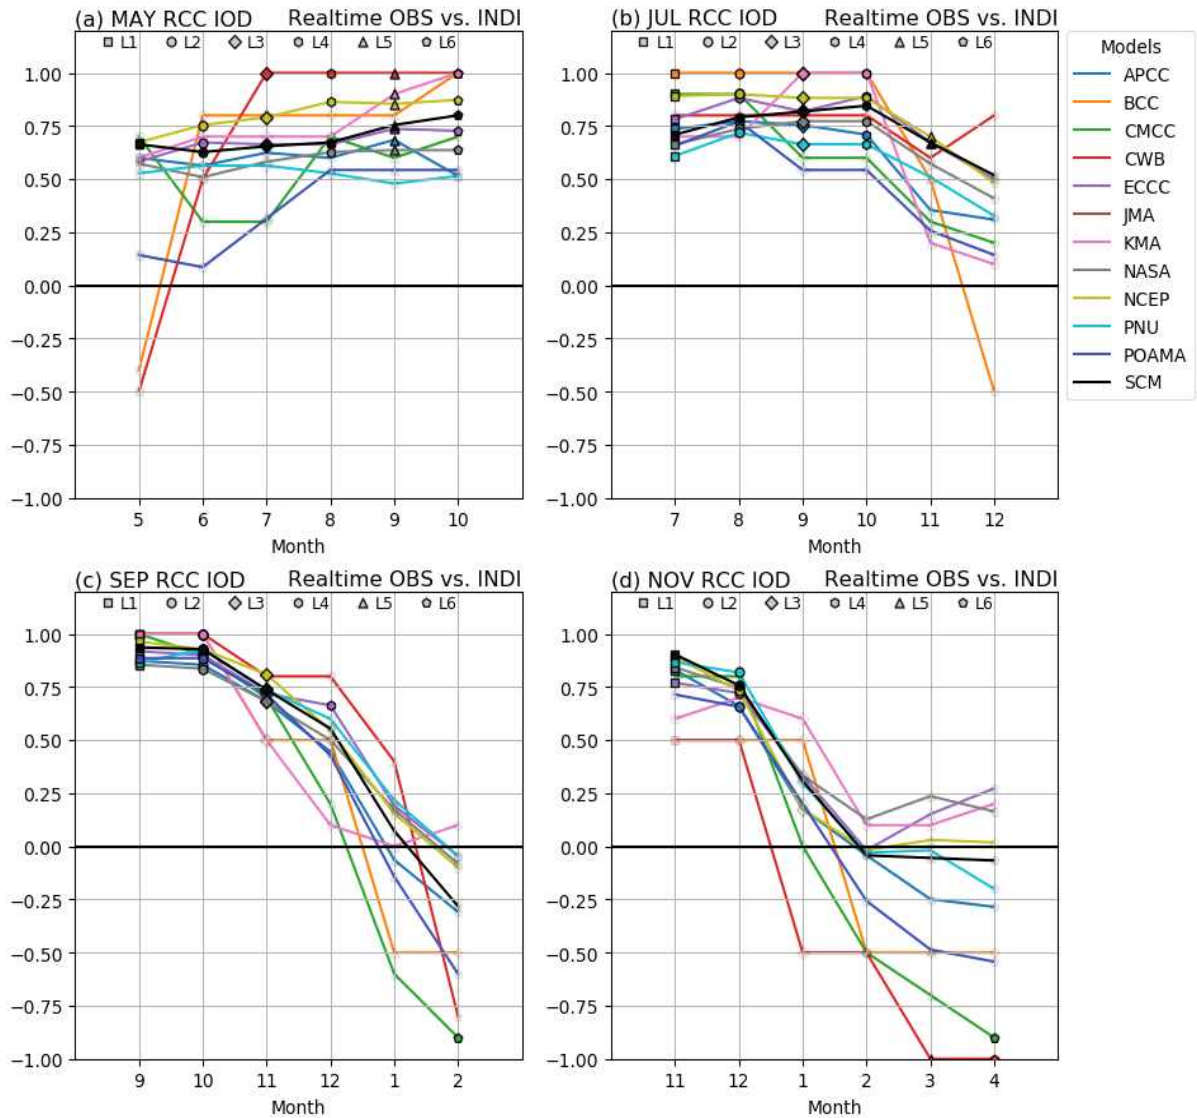


Figure 3.55. Monthly ranked correlation coefficients of the IOD time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) May, (b) July, (c) September, and (d) November. Filled markers with black edges indicate statistical significance at the 95% level.

오차(error)는 IOD 시계열의 예측값에서 관측값을 뺀 것으로, 예측과 관측은 자체 기후값을 뺀 아노말리이다(Figure 3.56). 오차가 양인 것은 예측값이 관측값보다 큰 것이고 월별 평균 오차를 비교했을 때 대체로 모델이 실제보다 크게 예측하는 경향이 있는데, 겨울, 봄철에 그 정도가 크고 점점 오차가 줄어들다가 가을철에는 오차가 작다.




Figure 3.56. Monthly mean error of the IOD time series between MME forecasts and observations (MME - OBS) with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue.

MME는 대체로 양의 오차가 있는데 개별모델은 대부분 양의 오차를 가지는 경향이지만 음의 오차를 가지는 모델도 꽤 있다(Figure 3.57). 특히 KMA가 양의 오차를 가지는 경향이 크고, CWB, JMA가 음의 오차를 가지는 경향이 있는데 이 두 개의 모델은 분석 기간이 매우 짧으므로 주의해야 한다.

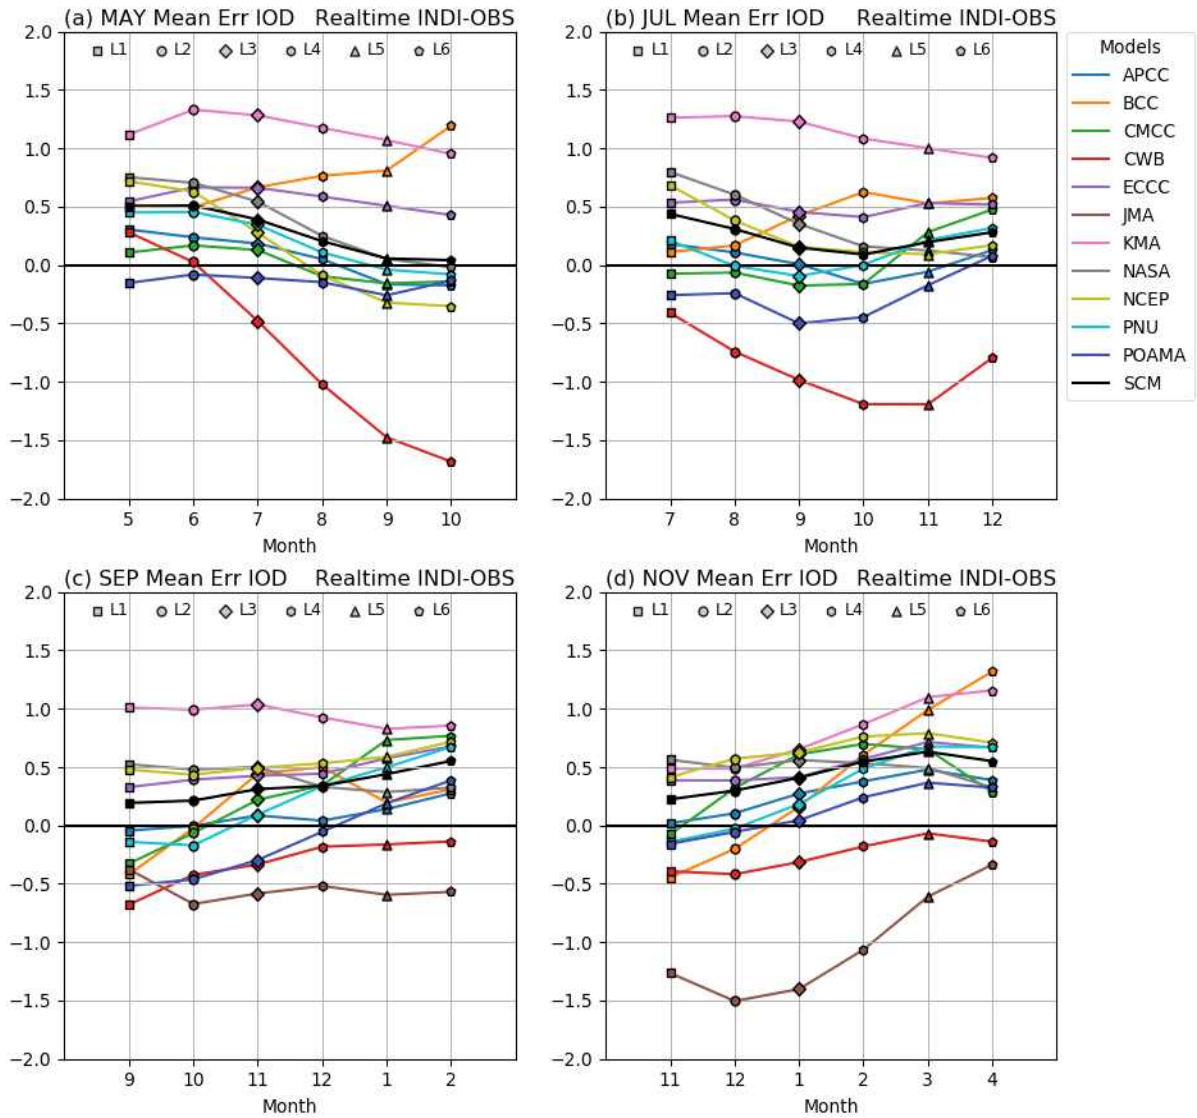


Figure 3.57. Monthly mean error of the IOD time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) May, (b) July, (c) September, and (d) November.

Real-time forecast 기간 IOB 시계열을 추출하여 관측과 함께 Figure 3.58에 표현하였다. 최근 인도양 SST는 지구 온난화의 영향을 받아 대체로 따뜻한 경향을 유지하고 있기에 대부분 시기에 IOB는 양의 상태이다. 특히 2015년, 2024년은 IOD 양의 사례와 함께 IOB 또한 강한 양이었으며, 2019년 또한 양의 상태였으나, 강도는 상대적으로 약했다.

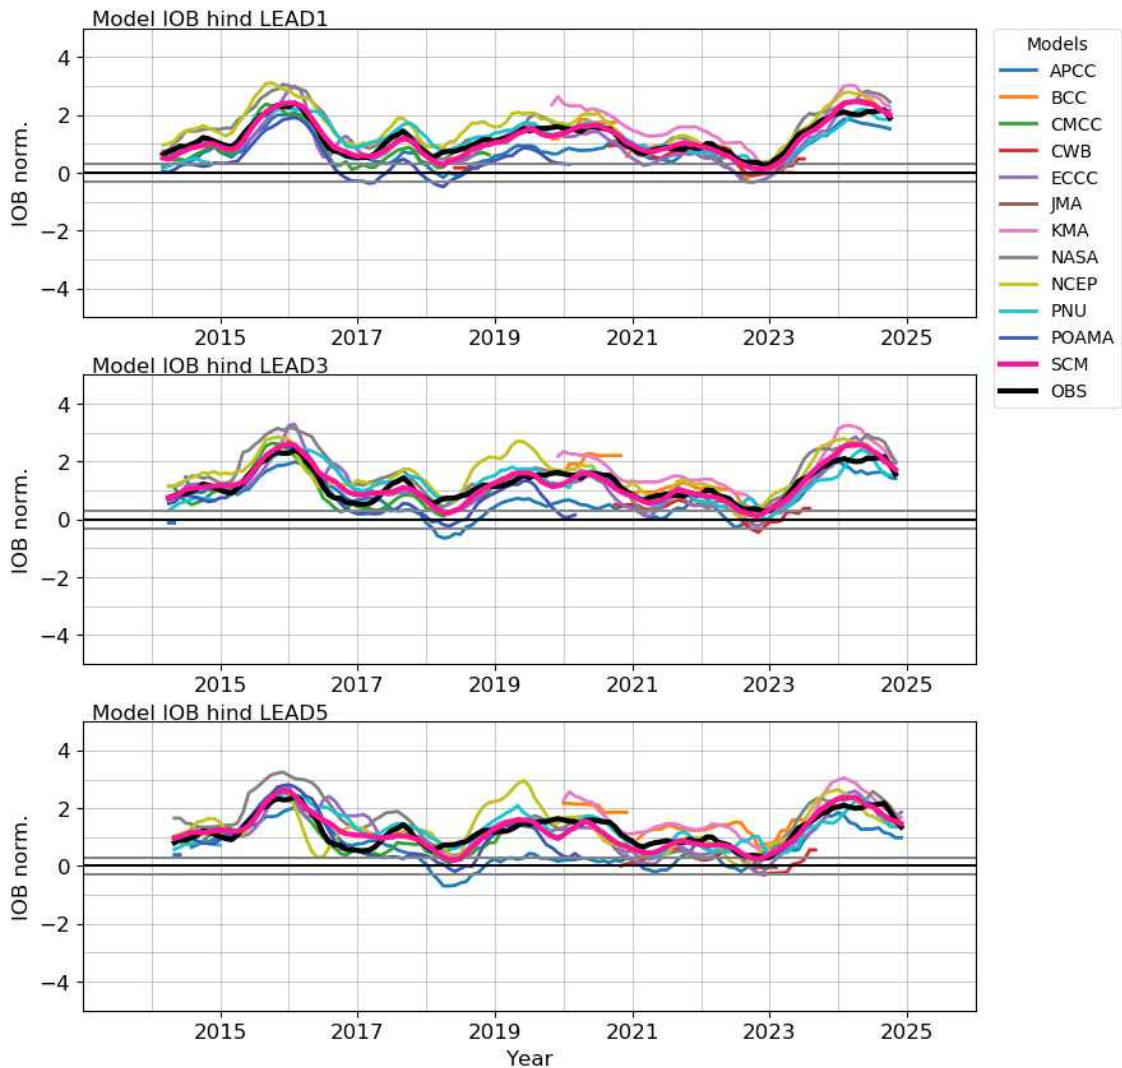


Figure 3.58. IOB time series based on APCC MME models with forecasts lead from 1 to 6 months for the real-time forecast period, 2013–2024. The climatological period for each year corresponds to the model hindcast period (e.g., the hindcast period for 2024 is 1991–2010). Positive and negative IOB events are defined using a threshold of ± 0.3 . The SCM MME is shown as thick magenta line, individual models are colored, and observations are shown as a thick black line.

IOD와 마찬가지로 11년 동안 시계열의 상관관계를 계산하기 위해 월별 RCC를 Figure 3.59에 표현하였다. IOB는 계절적 특성이 약한 편이기에 전 계절에 스کیل이 높고 예측 선행시간이 길어질수록 순차적으로 스کیل이 떨어지는데 다만 겨울, 봄철에 여름, 가을에 비해 높고 떨어지는 속도도 느리다.




Figure 3.59. Monthly ranked correlation coefficients of the IOB time series between observations and MME forecasts with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue. Filled markers indicate statistical significance at the 95% level.

MME는 대체로 개별모델에 비해 예측 스킬이 우수하다. MME, 개별모델은 IOD에 비해 선행시간이 길어지면서 예측 스킬이 떨어지는 속도가 느리고, 1월 예측스킬이 높다(Figure 3.60). CWB의 IOB 예측 스킬이 안정적이지 못한데, 이는 샘플수가 적어서 나타나는 현상으로 보인다.

IOB의 오차는 월별로 다르긴 하지만 가을, 겨울철에 선행시간 2개월 후부터 양의 오차를 가지는 경향이 있고, 선행시간이 길어지면 오히려 오차는 줄어든다. 봄철, 여름철은 오히려 음의 오차가 계속 유지되는 경향이 있다(Figure 3.61).

MME는 개별모델에 비해 오차가 매우 작고, 개별모델은 오차의 범위가 넓은데, KMA, NCEP, NASA는 양의 오차를 가지는 경향이 있고, APCC, CMCC, ECCC는 음의 오차를 가지는 경향이 있다(Figure 3.62).

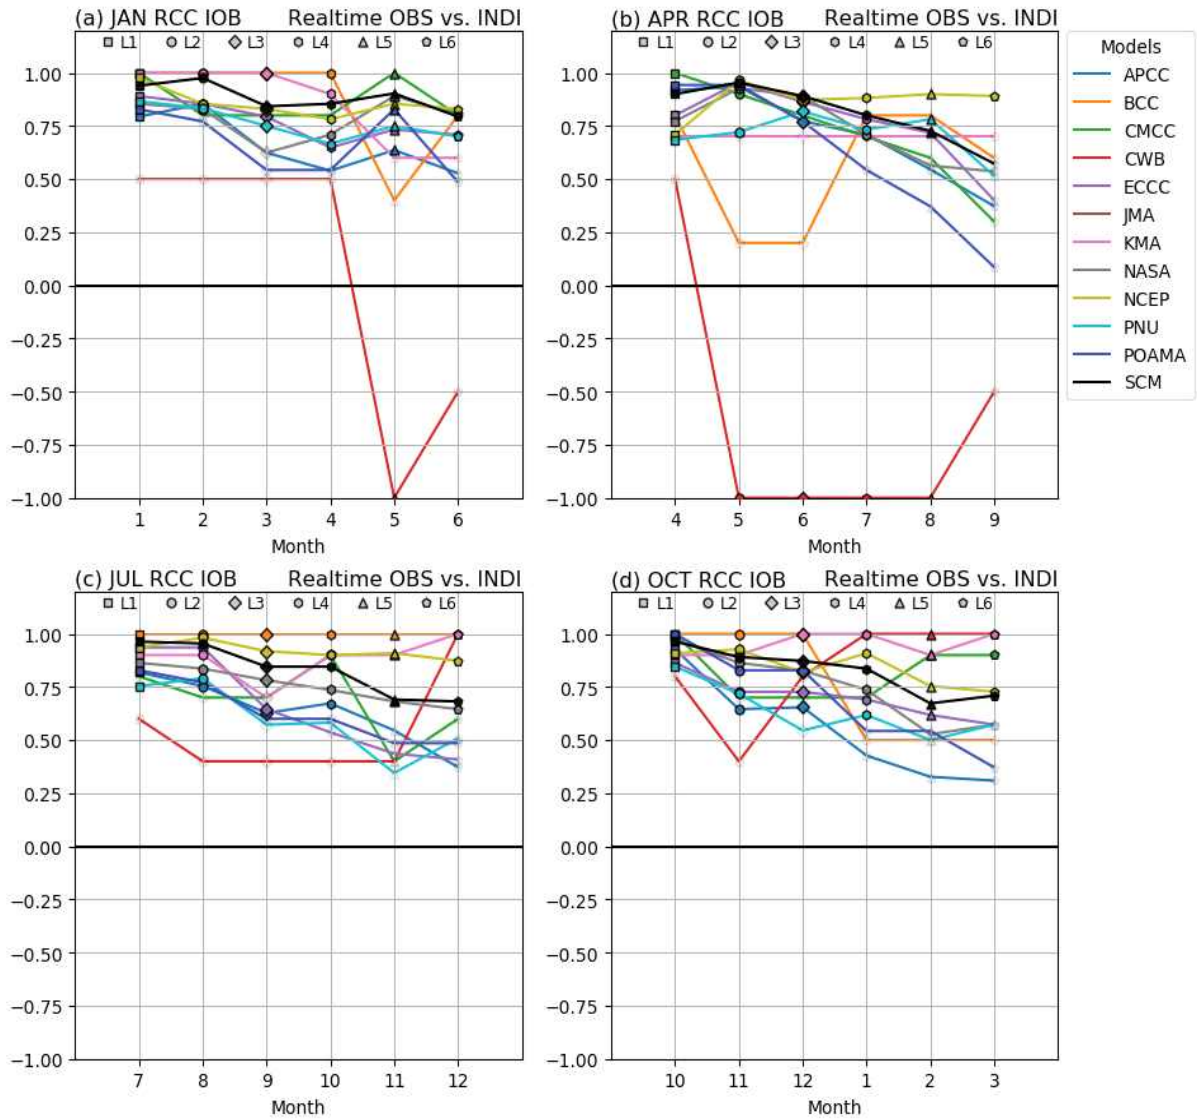


Figure 3.60. Monthly ranked correlation coefficients of the IOB time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) January, (b) April, (c) July, and (d) October. Filled markers indicate statistical significance at the 95% level.




Figure 3.61. Monthly mean errors of the IOB time series between MME forecasts and observations (MME - OBS) with lead times 1 to 6 months. Line colors denote the forecast issue month; for example, forecasts issued in December (covering January to July) are shown in blue.

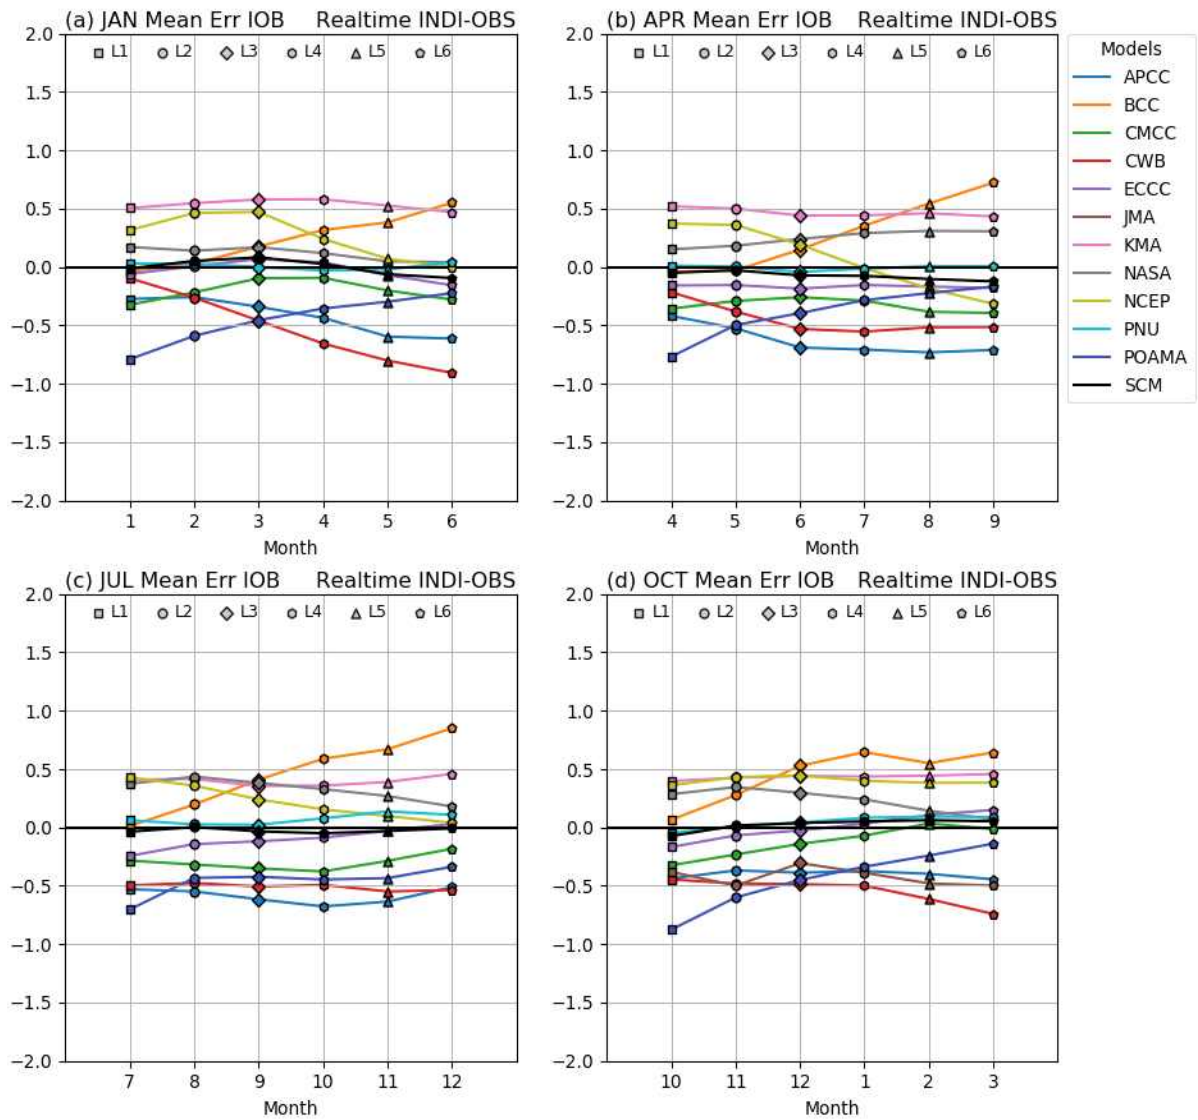


Figure 3.62. Monthly mean errors of the IOB time series between observations and individual models (colored) and MME forecasts (black) with lead times 1 to 6 months from (a) January, (b) April, (c) July, and (d) October.

3.6. 대기 기후모드

이 연구는 APCC MME 계절 예측 자료를 분석하여, 과거부터 현재까지의 기후모드 예측 상태를 진단하고, 이를 기반으로 이상기후 시대에 적합한 예측 가이드라인을 제시하는 것을 최종 목표로 한다. 이를 위해 먼저, Hindcast 기간 주요 기후 모드의 예측 특성을 분석하고자 한다. 이번 장에서는 대기 기후 모드에 초점을 맞추어, 해당 지수들의 예측성과 예측 오차 특성을 분석하고자 한다. 이 과정에서 다양한 대기 지수 중에서도 모델 기반 예측에서 유의미한 예측성을 나타내는 지수를 선별하고, 이들이 온도 및 강수와 어떤 원격 상관(tele-connection) 패턴을 형성하는지를 비교 분석하고자 한다.

3.6.1. 대기 기후모드 선정

주요 대기 지수는 현재 APCC 홈페이지에서 제공하고 있는 대기 지수 중 APCC MME에서 제공 중인 변수로 계산이 가능한 PNA (Pacific/North American), WP (Western Pacific), NP (North Pacific), AO (Arctic Oscillation), NAO (North Atlantic Oscillation), SOI (Southern Oscillation Index) 지수로 총 6개의 지수를 우선 선정하였다(Table 3.3). 그리고 각 지수의 계산 방식은 APCC 홈페이지에서 공식적으로 제공 중인 지수 감시시스템의 정의에 따라 계산되었다. 그 중 AO를 계산하기 위한 1000hPa 지위고도는 현재 APCC MME 제공 변수가 아니기 때문에 SLP(해수면기압)으로 대체하여 계산하였다.

본 연구에서는 모델 및 관측 자료를 이용하여 과거부터 현재까지의 약 20년간의 APCC MME 예측 현 상태를 진단하고 최근 기후 변동성을 고려하여 실제 예보에 활용 가능한 예측 가이드라인을 제시하고자 먼저 최근 Hindcast 기간(1993~2016년)에 기후 모드의 예측 추이를 살펴보고자 하였다. 우선 해양 및 대기 관련 주요 기후 모드에 대한 예측성 및 오차 특성을 살펴보고, 이에 모델에서 유의미한 예측성을 나타내는 지수를 선별하고, 나아가 대기 지수의 온도와 강수에 대한 원격 상관 패턴을 비교해 보고자 하였다.

Table 3.3. List and current status of atmospheric index.

지수	필요 변수	관측 자료	Climatology Period	홈페이지 업데이트 현황	
				APCC	CPC
PNA	Z500	NCEP R1	1993~2016년	O	O
WP	Z500				
NP	SLP				
AO	SLP				
NAO	SLP				
SOI	SLP				

3.6.2. 대기 기후모드 예측성 평가

Figure 3.63은 대기 지수에 대한 참여모델 별, 월별 평균 시간 상관 계수(TCC; Temporal Correlation Coefficient)를 나타낸 것이다. 지수별로 살펴봤을 때 AO는 MME에서 6월 유의미한 예측성을 나타내지만 이를 제외한 기간에서는 대부분의 개별 모델에서 지수 예측성이 현저히 낮게 나타나 유의미한 예측성을 나타내지 않는다. 그리고 NAO의 경우 MME에서 1월, 4~5월에 유의미한 예측성이 나타나고 역시나 이를 제외한 기간에서는 유의미한 예측성이 나타나지 않는다. 그리고 북태평양 지역의 대규모 기압 변동 패턴을 살펴볼 수 있는 NP의 경우 12~1월, 5월, 7~8월에 유의미한 예측성을 나타내는 것을 확인하였다. 그리고 PNA는 1~4월, 6월에, WP는 12~1월, 4~5월, 9월에 예측성이 높게 나타나 주로 봄철과 겨울철에 유의미한 예측성을 나타낸다. 이 지수들은 북태평양 및 북서태평양의 주요 기압 파동 패턴에 영향을 미치는 지수로서 겨울철부터 봄철까지 실제 한반도를 포함한 동아시아 예보에 예측인자로 중요하게 활용될 수 있다. 그리고 SOI는 ENSO의 영향 지수로 대기 변수만으로 ENSO 지수와 유사한 의미를 가지기 때문에, 전 계절 및 모든 참여모델에서 다른 대기 변수에 비해 상대적으로 아주 높은 예측성을 나타내는 것을 확인하였다.

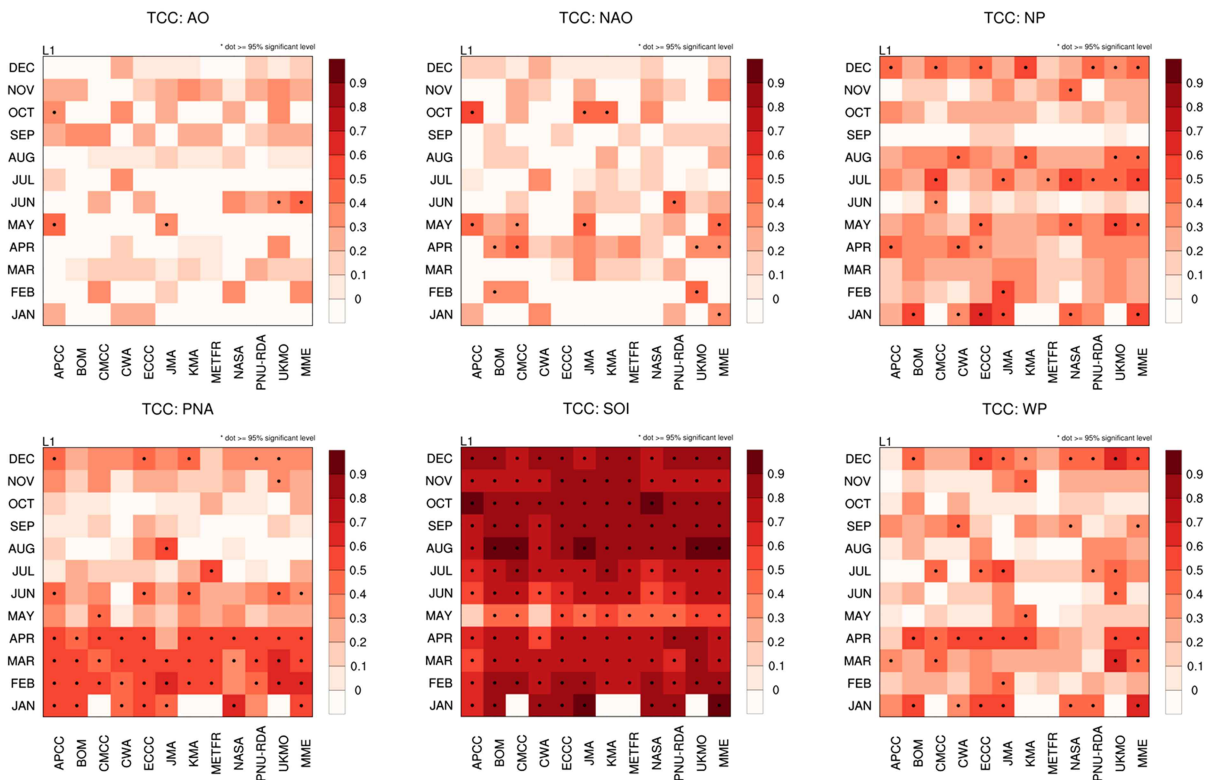


Figure 3.63. Monthly TCC for AO, NAO, NP, PNA, SOI, and WP indices by participant model. Dots indicate values significant at the 95% confidence level.

다음으로 각 지수들의 관측과 MME에서의 월별 회귀 패턴의 모의성을 살펴보았다. 회귀 패턴 분석을 통해 실제 관측에서 나타나는 대기 지수 특성이 기후 모델에서도 유사하게 재현되는지와 관측에서 정의되고 있는 지수를 모델에서도 그대로 적용해도 되는지를 먼저 검토하였다. Figure 3.64-3.69는 6개 지수에 대한 월별 회귀 패턴을 비교한 것이고 각 월별 오른쪽 상단에 표시된 숫자는 관측과 MME간 공간 상관 계수 (PCC; Pattern Correlation Coefficient)를 나타낸 것이다. AO는 북극을 중심으로 한 북반구 고위도의 기압패턴과 제트기류를 나타내는 주요 기후 지수로, 관측에서 AO의 영향이 가장 큰 겨울철은 북극의 기압 위상과 중위도의 기압 위상이 반대로 나타나는 것이 특징이다. 그러나 Figure 3.64에서 보면 모델에서는 북극의 중심 기압이 약하게 나타나 중위도와 기압 위상차가 뚜렷하게 나타나지 않고 중위도의 기압 중심의 위치가 다르게 나타나는 특징이 있다. 따라서 실제로 PCC 값 자체는 유의미한 것으로 나타나나 북극과 중위도 사이의 기압 위상의 강도가 약하고 기압의 대칭 구조도 다르게 나타남을 확인하였다.

공통적으로 AO를 제외한 대기 지수 모두에서 겨울철, 특히 1월에 유의미한 지수의 예측성이 나타나는 것을 확인하였다. 그래서 본 보고서에서는 특히 1월에 대한 추가 분석 결과들을 제시하였다. 그리고 NAO 회귀 패턴(Figure 3.65)도 AO의 회귀 패턴과 매우 유사하게 나타나는 것을 확인할 수 있다.

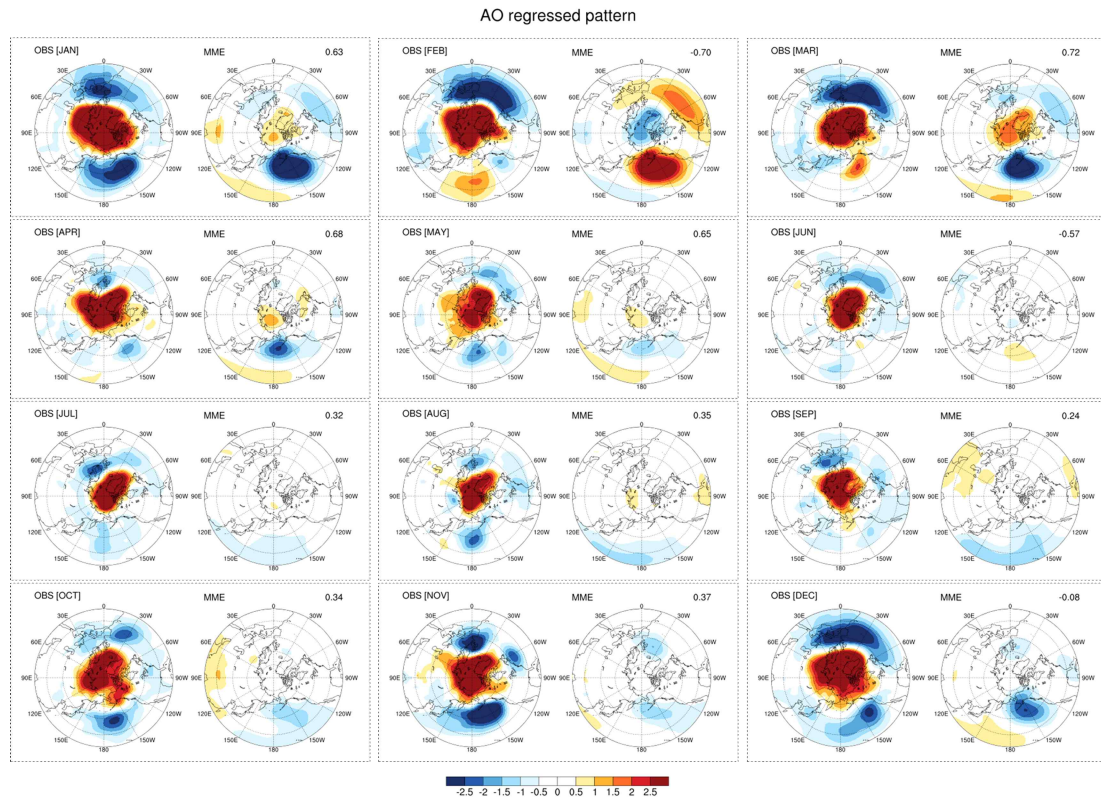


Figure 3.64. AO regressed patterns for SLP based on monthly observation and 1-month lead forecasts.

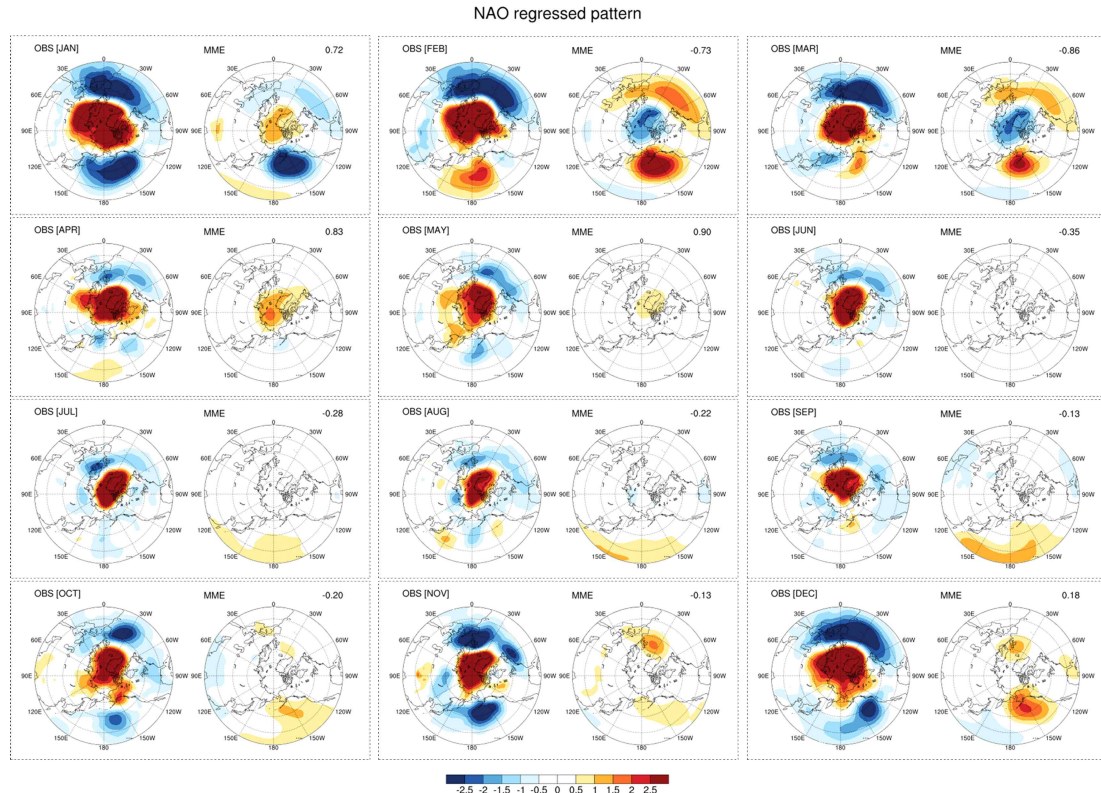


Figure 3.65. Same as figure 3.64, but for NAO regressed pattern for SLP.

Figure 3.66은 북태평양의 겨울철 대기 순환 패턴을 설명하는 NP에 대한 회귀 패턴이다. NP는 시간 변동에 대한 상관성은 12~1월, 5월, 7~8월에 유의미하게 나타났지만 공간 상관 분석을 살펴보면 11~1월, 5~6월에 지수의 공간 모의성이 높게 나타나고 여름철에는 공간 모의성이 크게 감소하는 것으로 나타난다.

Figure 3.67은 북태평양에서 북미대륙을 연결하는 대규모의 겨울철 대기 파동을 설명하는 PNA에 대한 회귀 패턴이다. PNA는 시간 변동에 대한 상관성은 1~4월, 6월에 유의미하게 나타났지만 공간 상관 분석을 살펴보면 북반구 가을철부터 겨울철까지 지수의 공간 모의성이 높게 나타나는 것을 확인하였다. 그리고 타 계절에서는 회귀 패턴의 강도가 관측에 비해 매우 약하게 모의되는 것을 확인하였다.

그리고 북서태평양 주변의 기압을 설명하는 WP 회귀 패턴(Figure 3.68)은 PNA 패턴과 유사하게 11월부터 4월까지 겨울철에서 봄철까지 최성기를 보이며, 지수의 공간 모의성이 높게 나타나는 것을 확인하였다. 그러나 전반적으로 관측에 비해서 모델 회귀 패턴의 강도가 약하게 모의되는 것을 확인하였다.

Figure 3.69는 엘니뇨와 라니냐를 설명하는 기압 지수인 SOI에 대한 회귀 패턴이다. SOI 지수의 경우 ENSO와 직결된 대기 관련 지수로서 시간 상관성이 전 계절에 걸쳐 매우 높게 나타났지만 이에 반해, 공간 모의성에서는 겨울철만 높게 나타나고 회귀 패턴 강도는 관측에 비해 매우 약하게 모의되는 것을 확인하였다.

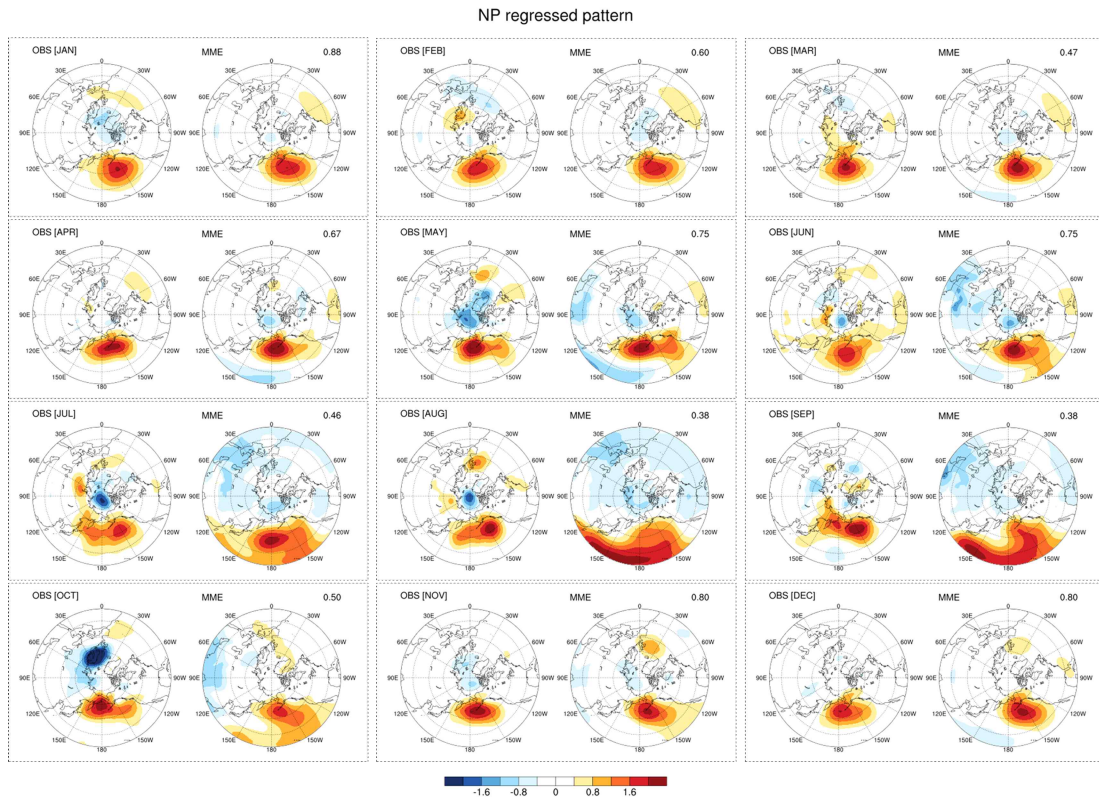


Figure 3.66. Same as figure 3.64, but for NP regressed pattern for SLP.

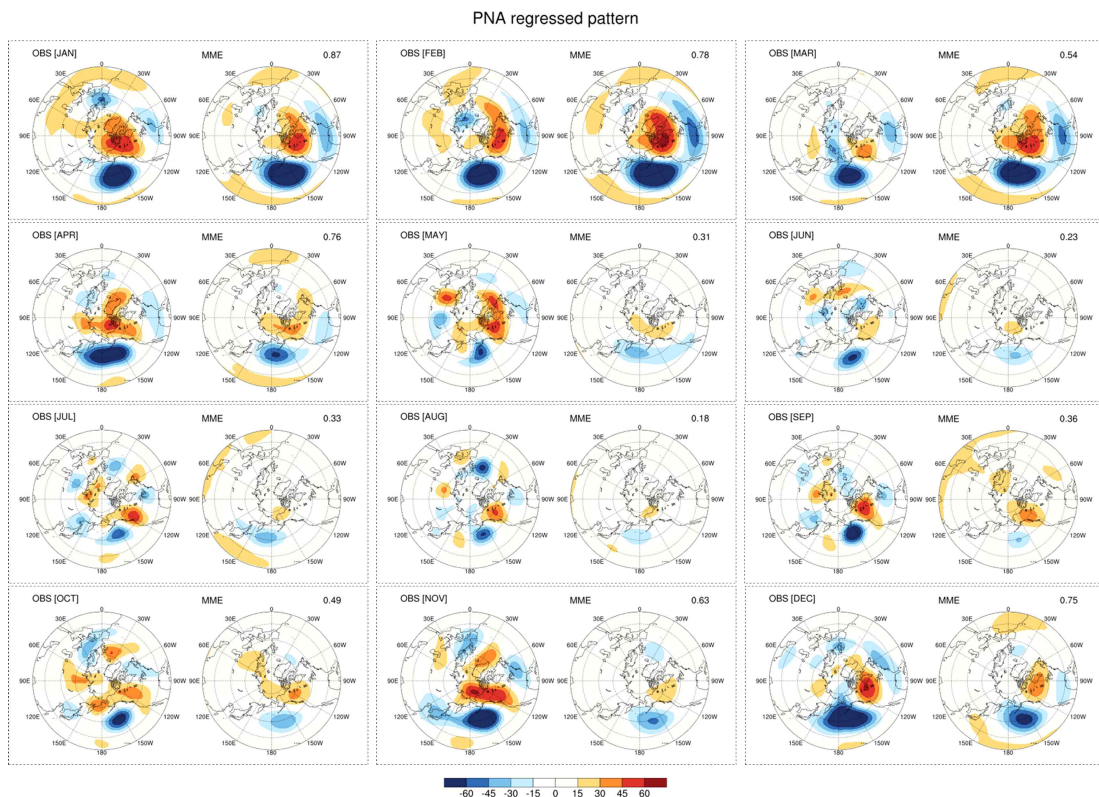


Figure 3.67. Same as figure 3.64, but for PNA regressed pattern for 500hPa geopotential height.

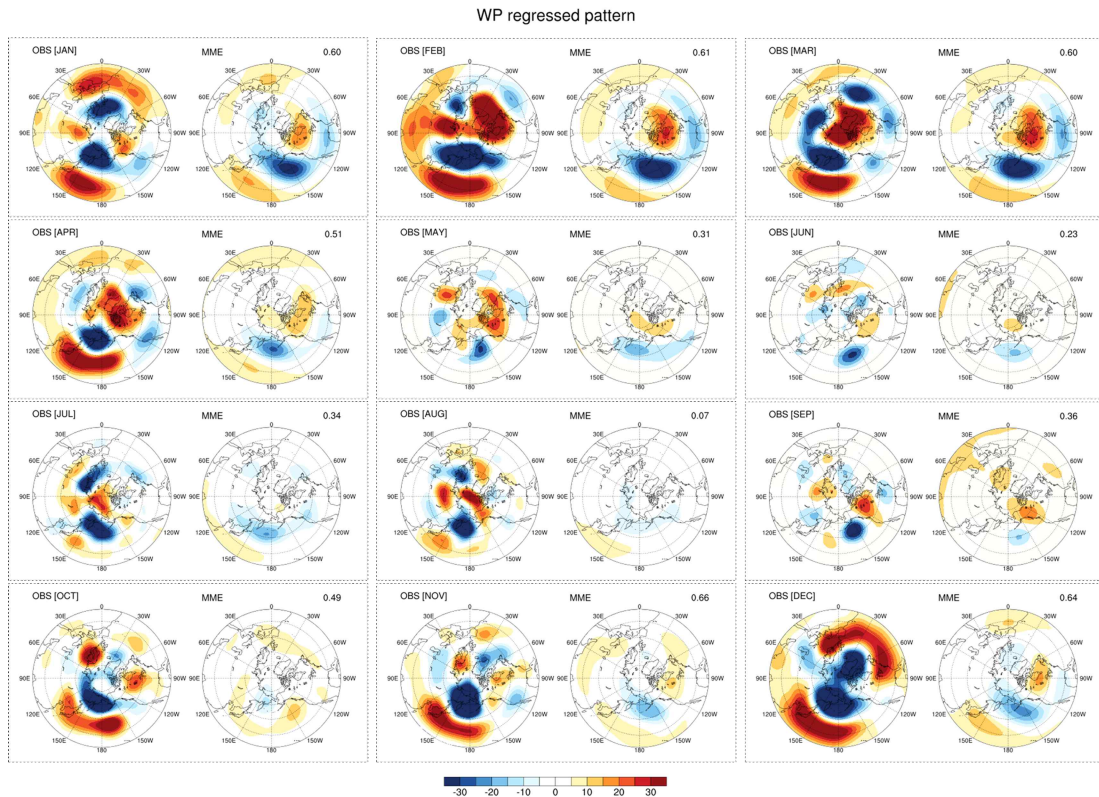


Figure 3.68. Same as figure 3.64, but for WP regressed pattern for 500hPa geopotential height.

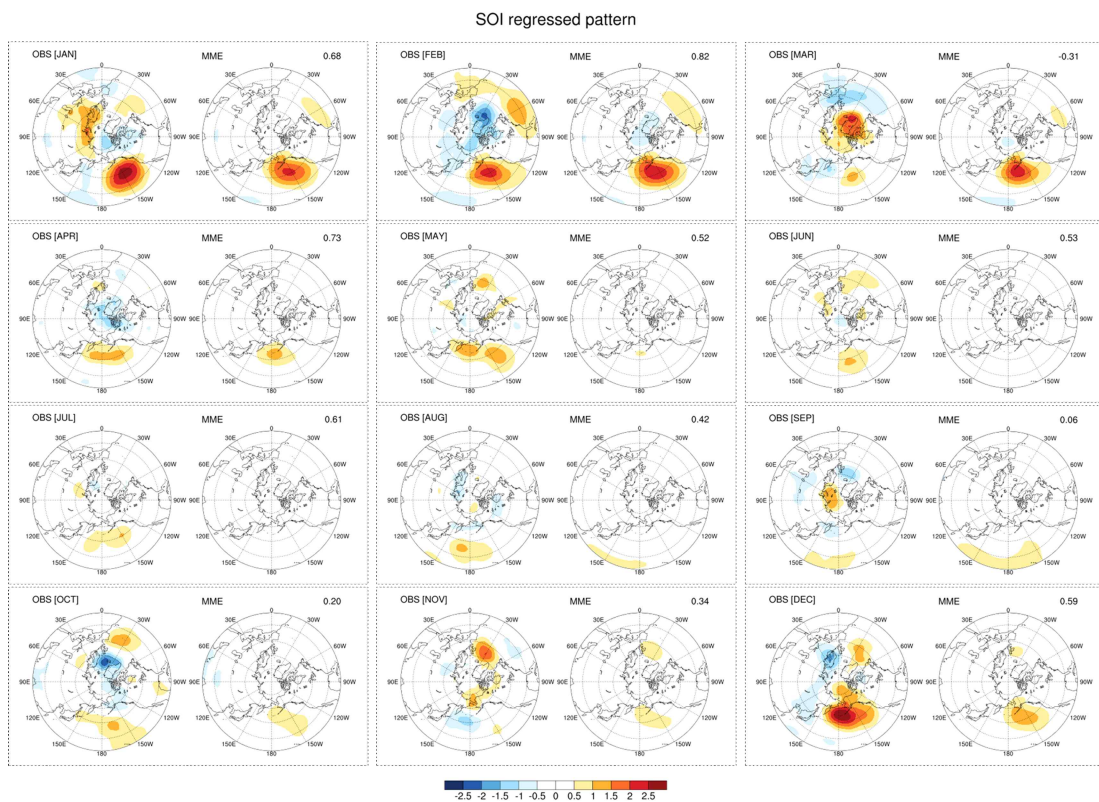


Figure 3.69. Same as figure 3.64, but for SOI regressed pattern for SLP.

Figure 3.70은 Hindcast 기간 1월의 각 지수가 중위도 지역의 2m 기온에 미치는 원격 상관 분석 결과이다. 지수별로 왼쪽이 관측, 오른쪽이 MME에 대한 원격 상관 패턴이다. 그리고 유의미한 상관 계수가 나타나는 지역을 빗금으로 표시하였다. 우선 공통적으로 모든 지수의 실제 대기에서 나타나는 원격 반응과 모델에서의 반응이 상이하게 나타나는데, 관측에 비해 모델에서 중위도 대기 반응을 과대모의 하는 특징이 나타났다. 그리고 1월에 동아시아에 유의미한 영향을 나타내는 지수로는 WP 지수가 있음을 확인하였다. 두 번째 특징은 이러한 과대모의 패턴이 ENSO의 대기 원격 상관 반응과 유사한 점이다. Figure 3.70의 첫 번째 패턴이 NINO3.4 지수와 2m 기온과의 원격상관 반응인데 다른 대기 지수의 반응이 이와 매우 유사하게 나타나는 것을 알 수 있었다. 관측에서 나타나는 ENSO의 중위도 기온 반응으로는 북미 서쪽 지역에 약한 상관성이 나타나는 것과 더불어 북태평양에서 유의미한 상관성이 나타나는 것이고 MME 예측에서는 북미 서쪽 지역의 반응을 과대모의하여 북미 대륙 전체에 유의한 상관성이 나타나는 것이 특징이다. 이러한 반응이 전 대기 지수에서 나타나는 것으로 보아 모델의 대기 반응성이 ENSO에 매우 의존적이며 실제 대기에서의 역학 반응을 잘 나타내지 못하고 있음을 제시하고 있다. 이는 MME 뿐만 아니라 모든 개별 모델에서도 유사하게 나타나는 것을 확인하였다.

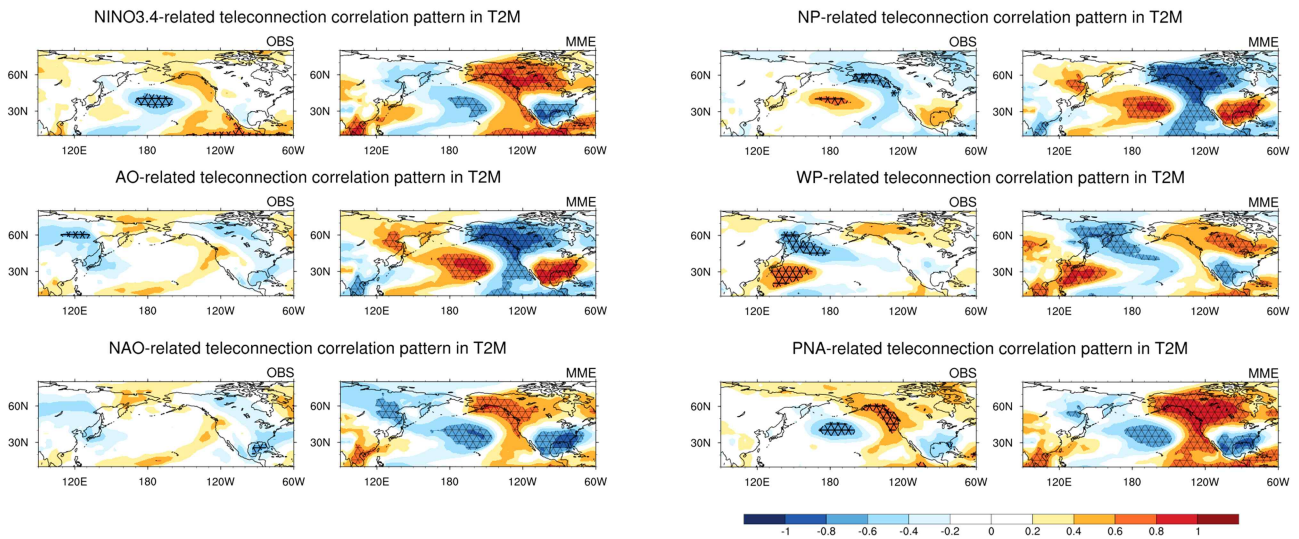


Figure 3.70. Teleconnection correlations between each index and 2m temperature over the mid-latitude region for January.

Figure 3.71은 Hindcast 기간 1월의 각 지수가 중위도 지역의 강수에 미치는 원격 상관 분석 결과이다. 기온의 원격 상관 반응과 유사하게 관측에서 각 지수가 모의하는 원격 상관 반응을 모델에서는 재현하지 못하는 특징이 있다. 그리고 관측에서 나타나는 강수에 대한 NINO3.4 지수의 원격 상관 반응을 역시나 모델에서도 과대 모의하는 특징을 가지면서 이 반응이 대기 지수의 반응에도 유사하게 나타나는 것을 확인하였다.

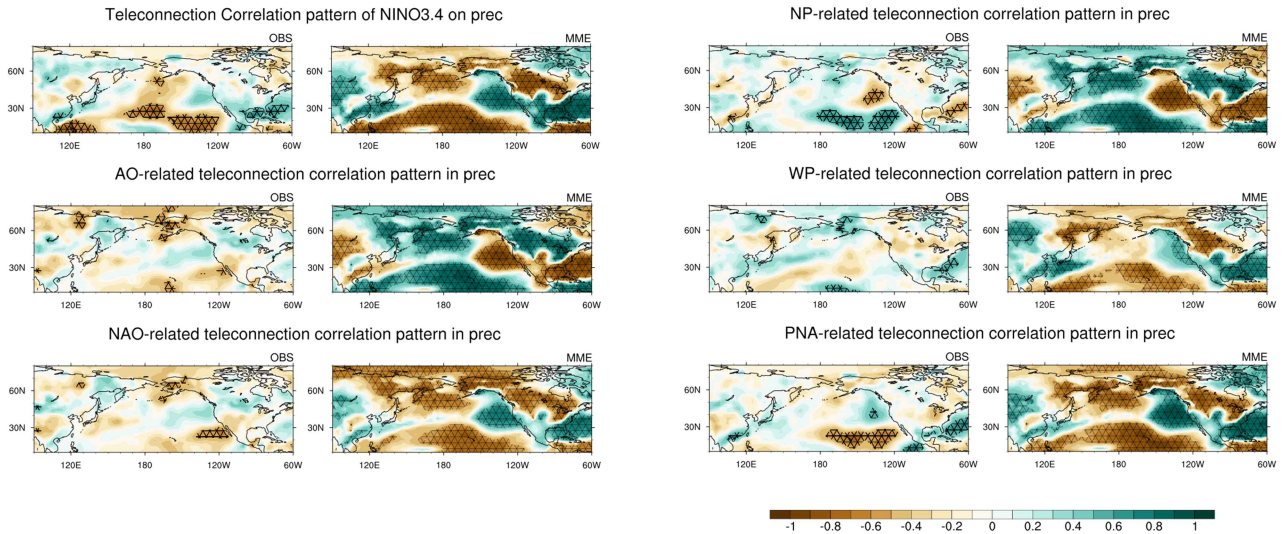


Figure 3.71. Same as figure 3.70, but between each index and precipitation.

그렇다면 각 대기 지수와 ENSO와의 상관성이 모델과 관측에서 어떤 차이가 있는지를 확인해보기 위해 동아시아에 밀접하게 영향을 주는 주요 대기지수 (WP, PNA, NP)와 NINO3.4간의 TCC를 분석하였다 (Figure 3.72). Figure 3.72에서 분홍색 실선이 MME, 파란색 실선이 관측의 월별 TCC를 나타낸 것이다. 그리고 오른쪽 상단에 12개월 TCC의 평균값을 나타낸 것이다. 실제로 관측에서는 ENSO와의 상관성이 높지 않음에도 불구하고 모델에서는 지수와 ENSO와의 상관성이 매우 높게 나타나는 것을 확인하였다. WP는 겨울철, 봄철에 과대 모의 특징이 매우 강하게 나타나고 반면, PNA와 NP는 전 계절에 걸쳐 과대 모의하는 특징이 나타났다. 이러한 결과로 미루어 봤을 때 지수 자체의 ENSO 과대 모의성이 결국 기온과의 원격 반응에도 영향을 미쳐 ENSO의 반응성과 매우 유사하게 나타났을 가능성이 큰 것으로 추정된다.

모델에서 나타나는 기온의 원격 반응에서 ENSO로 인한 대기 반응이 과대 모의되는 문제를 해결하기 위해 ENSO 관련 반응을 회귀(regression) 수식(Figure 3.73)을 통해 제거하여 대기 지수에 대한 순수 원격 반응만을 추출하고자 하였다. 따라서 figure 3.73의 수식을 통해 ENSO 반응 제거 후 Index의 raw term에서 ENSO 반응 제거 후 남은 residual term의 비교 분석을 통해 모델의 원격 반응의 차이, 공간적 변화 등을 확인하고자 하였다.




Figure 3.72. Temporal correlation coefficient (TCC) between NINO3.4 and the WP (left), PNA (center), and NP (right) indices. The values shown in the upper-right corner indicate the mean TCC values.

$$\alpha = \text{reg}[Index_{raw}(t), ENSO(t)]$$

$$Index_{residual}(t) = Index_{raw} - \alpha ENSO(t)$$

Figure 3.73. Equation for removing ENSO-related variability from 2m temperature using linear regression.

Figure 3.74~3.75는 각각 WP와 PNA에서 ENSO의 원격 반응을 제거한 결과를 나타낸 그림이다. 상단의 raw는 기존에 ENSO 반응을 제거하기 전, 하단의 res는 ENSO 반응을 제거한 후 residual term의 결과를 비교한 것이다. ENSO의 반응을 회귀분석으로 제거한 후 WP에서의 대기 반응을 보면 기존에 유의미하게 나타났던 동아시아에서의 원격 상관 반응(점선으로 표기)이 제거되었다. 이는 단순히 선형적으로 모델에서 ENSO 반응을 제거하면 모델이 그나마 가지고 있던 ENSO에 기인해서 나타난 자체적인 유의미한 예측성마저도 제거될 수 있음을 시사하는 바이다.

PNA 같은 경우는 ENSO의 원격 상관 반응을 제거했을 때, 기존 원격 상관 반응과는 반대 시그널의 영향이 나타나기도 했다. 이 같은 반응을 통해서 PNA 지수의 근원 자체가 ENSO의 반응과 직접적인 연관이 있는데 ENSO 반응성을 제거하니 오히려 ENSO의 반대 시그널이 나오는 역효과가 나타나는 것을 확인하였다. 따라서 이 같은 결과는 대기 반응에서의 유의미한 예측인자를 추출하기 위해 단순히 선형 회귀 분석으로 ENSO 반응을 제거하는 후보정은 한계가 있음을 제시하는 바이다.

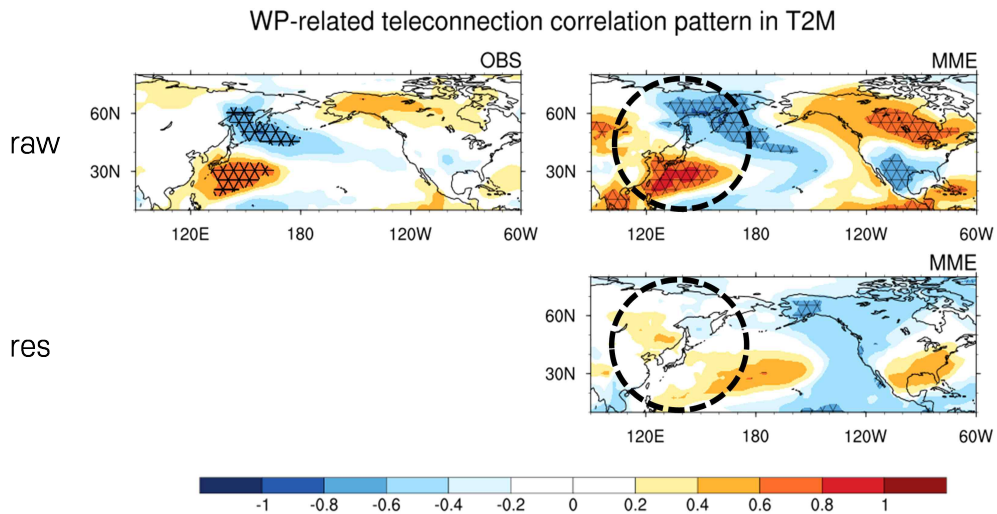


Figure 3.74. Comparison of 2m temperature tele-connection of WP index before (top) and after (bottom) the removal of the ENSO signal.

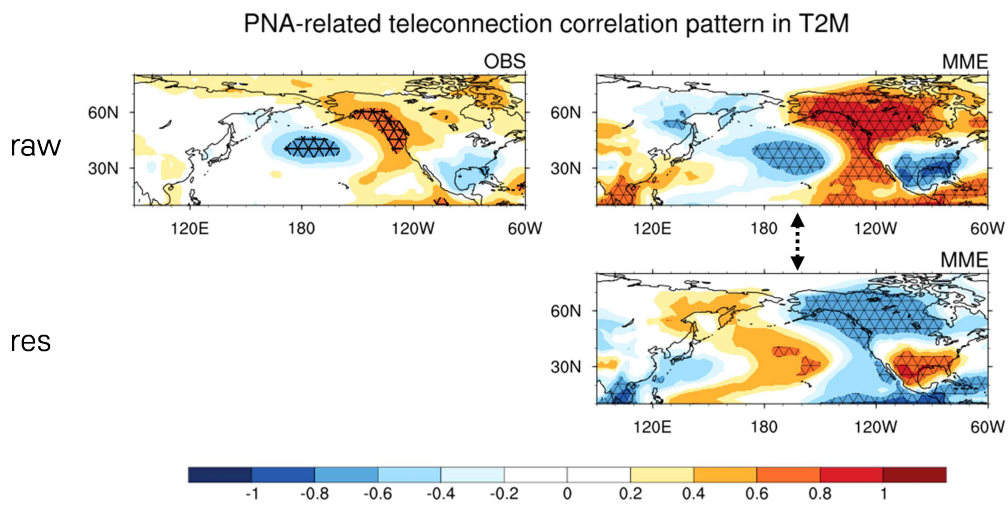


Figure 3.75. Same as figure 3.74, but for PNA index.

4. MME 운영 및 개선

4.1. MME 예측 및 검증

4.1.1 배경 및 목적

아태기후센터(APCC)는 2005년 설립 이후 국내외 다양한 모델예측자료를 기반으로 다중모델앙상블(MME) 예측기법을 적용한 자동예측시스템(AFS, Automated Forecast System)을 구축하여 매월 계절예측 및 검증결과에 대한 실시간 정보를 제공하고 있다. 2018년부터 AFS 개선이 꾸준히 이루어졌으며, 매년 사용자 수요조사를 통해 계절예측 자료 활용성 및 편의성을 증대시키기 위해 노력하고 있다. 그 결과, 2019년 11월(25일→20일) 및 2022년 4월(20일→15일) 두 차례에 걸쳐 예측정보 제공시기를 앞당긴 바 있고, 2022년 4월부터 가장 최신의 ENSO 경보 정보를 제공하기 위해 월 2회(15일, 말일) 생산체제로 전환하였으며, 9월부터 고해상도(1도) 예측정보 서비스를 개시(김유진 등, 2022), 2024년 2월에는 동적 기후정보 서비스를 제공하기 시작하였다(이현록 등, 2024). 올해는 현업 예측시스템의 확장성 및 실효성 개선을 목표로 새로운 모델 추가, 과거기후예측(hindcast) 공통기간 확장과 더불어 고해상도(1.0°) 검증정보를 제공하는 등 다양한 개선이 이루어졌다.

4.1.2 자료 및 방법

4.1.2.1 예측자료

현재 11개국(한국, 일본, 호주, 중국, 대만, 영국, 미국, 캐나다, 이탈리아, 러시아, 프랑스) 16개의 현업·연구기관으로부터 기후예측 자료를 수집하고 있으며, 각 기관의 모델명, 모델해상도, 앙상블 멤버수, hindcast 기간, forecast 기간에 대한 설명은 Table 4.1에서 확인할 수 있다. 금년에는 다수의 모델 개선 및 hindcast 기간 연장 등을 포함한 주요 변경 사항이 반영되었다. 2024년 12월(2025년 1월~6월 예측)부터 아태기후센터(APCC) SCoPs 모델의 hindcast 기간이 2013년에서 2016년으로 연장되었고, 2025년 9월(2025년 10월~2026년 3월 예측) 러시아 수문기상센터(HMC) SL-AV 모델의 hindcast 기간이 2015년에서 2020년으로 연장되었다. 유럽지중해기후변화센터(CMCC)의 경우 2025년 8월(2025년 9월~2026년 2월 예측)부터 개선모델 SPS4 예측자료, 대만기상청(CWA)은 2025년 2월(2025년 3월~8월 예측)부터 개선모델 CWACFSv2 예측자료, 프랑스기상청(METFR)은 2025년 5월(2025년 6월~12월)부터 개선모델 Sys 9 예측자료의 제공이 시작되었다. 부경대학교(PKNU)는 2024년에 APCC MME 참여기관으로 등록하여, 2025년부터 2월(2025년 3월~8월 예측)부터 MME에 참여하게 되었다.

Table 4.1. Description of participating models in APCC MME.

기관(국가)	모델명	모델해상도	양상블 개수 (F/H)	Hindcast 기간	Forecast 기간
APCC (한국)	SCoPS	T159L31	10/10	1982-2016	6개월
BCC (중국)	CSM1.1m	T106L26	24/24	1991-2015	6개월
BOM (호주)	ACCESS-S2	N216L85	11/27	1981-2018	5개월
CMCC (이탈리아)	SPS4	0.5x0.5, L83	50/30	1993-2022	5개월
CWA (대만)	CWACFSv2	T395L60	30/30	1991-2020	9개월
ECCC (캐나다)	CanSIPsv3	T63L49	40/40	1990-2020	11개월
HMC (러시아)	SL-AV	0.72x0.9, L96	41/11	1991-2020	3개월
JMA (일본)	JMA/MRI-CPS3	T319L100	50/10	1991-2020	6개월
KMA (한국)	GloSea6GC3.2	N216L85	84/28	1993-2016	6개월
METFR (프랑스)	Sys 9	T359L127	51/31	1993-2024	5개월
MGO (러시아)	MGOAM2.4	T63L25	10/10	1991-2020	3개월
NASA (미국)	GEOS-S2S-2.1	0.5x0.5, L72	10/4	1981-2016	8개월
NCEP (미국)	CFSv2	T126L64	20/20	1982-2010	6개월
PKNU (한국)	CGCMv1.0	f19_g16 (~1.9° × 2.5°)	31/31	1993-2016	3개월
PNU-RDA (한국)	CGCMv2.0	T42L18	35/35	1980-2022	6개월
UKMO (영국)	GloSea6	N216L85	42/28	1993-2016	5개월

각 기관의 예측자료 수집 방식은 참여기관에서 운영하는 서버에 접속하여 APCC가 직접 다운로드하는 방식과 APCC ftp 서버에 참여기관이 예측자료를 업로드 하는 두 가지 방식으로 수행된다. 각 기관별 예측자료는 초기장 날짜에 따라 수집 시기가 상이하며, 2025년 기준의 수집 일정은 다음과 같다. 보통 월초에 호주기상청(BoM), 대만기상청(CWA), 캐나다 환경기후변화청(ECCC), 러시아 기상청 지구물리관측센터(MGO), 미국 항공우주국 글로벌모델링동화사무국(NASA), 미국 기상청(NCEP) 예측자료가 수집되고, 약 10일 이후로 나머지 기관의 예측자료가 수집되며, 매달 각 기관의 상황에 따라 수집 시기가 달라질 수 있다. 현 MME AFS에서는 초기장 날짜에 따른 가중치는 반영되지 않는다.

위와 같이 수집한 각 참여기관별 예측자료는 자료의 형식을 일정한 규격으로 표준화하는 APCC 전처리 체계를 통해 1.0° × 1.0° (고해상도)와 2.5° × 2.5° (저해상도)의 두 가지 해상도로 격자화하여 생산 및 제공하고 있다.

4.1.2.2 관측자료

현재 MME 저해상도 검증시스템에 사용되고 있는 관측 및 재분석자료는 강수의 경우 CAMS-OPI(Table 4.2), 해수면 온도의 경우 NOAA OISST version2(Table 4.3), 그 외 변수들은 NCEP/DOE Reanalysis 2(Table 4.4)이며, MME 고해상도 검증시스템은 해수면 온도를 제외하고 모두 ERA5(Table 4.5) 자료가 활용된다. 고해상도 검증을 위한 재분석자료는 다음의 기준을 근거로 ERA5를 선정하였다.

- 실시간 현업 운영에 적합한 안정적 자료 제공 주기
- 변수별 통일된 자료 사용으로 물리적/역학적 일관성 확보
- 지속적인 업데이트를 통한 향후 품질 개선 가능성 고려
- 저해상도 대비 전반적으로 향상된 고해상도 기온/강수 검증 스코어(김유진 등, 2024)

Table 4.2. Description of CAMS-OPI dataset.

	내용
출처	ftp://ftp.cpc.ncep.noaa.gov/precip/data-req/cams_opi_v0208
변수	강수(comb)
기간	1979. 1~현재 (매월 업데이트)
형식	2.5 x 2.5 degree
참조	https://www.cpc.ncep.noaa.gov/products/global_precip/html/wpage.cams_opi.html

Table 4.3. Description of NOAA OISST dataset.

	내용
출처	ftp://ftp.cdc.noaa.gov/Datasets/noaa.oisst.v2
변수	해수면온도(sst)
기간	1981. 12~현재 (매월 업데이트)
형식	1.0 x 1.0 degree
참조	http://www.esrl.noaa.gov/psd/data/gridded/data.noaa.oisst.v2.html

Table 4.4. Description of NCEP/DOE Reanalysis 2 dataset.

	내용
출처	ftp://ftp.cdc.noaa.gov/Datasets/ncep.reanalysis2.derived/
변수	surface gauss : 2m 기온(air) pressure : 850hPa 기온(air), 500hPa 지위고도(ght)
기간	1979. 1.~현재 (매월 업데이트)
형식	surface gauss: T62 Gaussian grid with 192x94 points pressure : 2.5 x 2.5 degree
참조	https://www.esrl.noaa.gov/psd/data/gridded/data.ncep.reanalysis2.html

Table 4.5. Description of ERA5 dataset.

	내용
출처	cds.climate.copernicus.eu/datasets/reanalysis-era5-single-levels
변수	2m 기온(t2m), 강수(tp), 850hPa 기온(t), 500hPa 지위고도(z)
기간	1991. 1~현재 (매월 업데이트)
형식	1.0 x 1.0 degree
참조	Hersbach, H. et al., 2020: The ERA5 global reanalysis, <i>Q.J.R. Meteorol. Soc.</i> , 146, 1999-2049.

4.1.2.3 예측 및 검증 기법

APCC는 표준화된 전지구 예측 모델의 500개 이상의 앙상블 예측 자료를 활용하여 단정(deterministic) 및 확률(probabilistic) MME 기법을 통해 계절예측을 수행하고 있다. 단정 예측은 개별모델의 모든 앙상블 예측 편차값을 각 모델에 동일한 가중치를 부여하여 종합하는 방식(Doblas-Reyes et al., 2000; Peng et al., 2002; Palmer et al., 2004; Wang et al., 2009)으로 수행된다. 확률 예측은 개별모델 예측 확률값을 각 모델별로 가중치를 부여하여 통합하는 방식으로 수행된다. 가중치는 각 모델별 확률분포 산출 과정의 불확실성을 고려해 앙상블 개수의 제곱근에 반비례하도록 설정한다(Min et al., 2009). 확률값은 평년과 비교하여 3분위(적음/비슷/많음) 발생가능성을 나타내며, 평년 범위는 과거 기후값 분포 중 33.3%~66.6%에 해당하는 값으로 정의된다.

기후예측 자료는 향후 6개월에 대해 전지구 및 동아시아 지역의 공간분포장, 열대지역 해수면 온도 지수, 엘니뇨 남방 진동(El Niño-Southern Oscillation, ENSO) 경보 등 다양한 콘텐츠 형태로 가공·생산되고 있다. 해수면 온도 지수 정의에 관한 내용은 김유진 등(2024)에 자세히 기록되어 있으며, ENSO 경보 시스템은 4.4장에서 다룰 예정이다. 금년에 개선된 ENSO 경보 예측정보는 10월부터 APCC 홈페이지에서 제공되고 있다.

APCC는 MME 계절예측 정보에 대한 신뢰성 확보를 위해 MME 기법(단정예측 및 확률예측)에 따라 다양한 검증 메트릭을 적용하여 정량적이고 객관적인 예측 정확도 정보를 함께 제공하고 있다. 검증 메트릭은 세계기상기구(WMO) 기본체계위원회(CBS)의 권고사항을 우선적으로 고려하였으며, 기후예측에서 주로 사용하는 검증 메트릭을 추가하였다(Table 4.6; Table 4.7). APCC 홈페이지를 통해 총 14개 주요 지역(김유진 등, 2024)에 대해 강수량, 2m 기온, 850hPa 기온, 500hPa 지위고도, 해수면 온도에 대한 단정예측 및 확률예측에 대한 검증 정보가 서비스된다.

먼저, 단정예측에서 활용되는 Anomaly Correlation Coefficient(ACC)는 관측과 예측의 편차 패턴의 유사성을 측정하는 상관계수로 1에 가까울수록 예측 성능이 높다. Root Mean Square Error(RMSE)는 예측값과 관측값의 평균 제곱오차의 제곱근으로써 값이 작을수록 정확도가 높다. Mean Square Skill Score(MSSS)는 위상오차, 진폭오차, 편향이 모두 반영되어 기준 예측 대비 성능 향상을 평가하는 지표이며 값이 1에 가까울수록 예측 성능이 높다. MSSS Correlation은 Temporal Correlation Coefficient(TCC)와 유사한 지표로서 본 연구에서는 99%, 98%, 95%, 90% 유의수준에서 통계적으로 유의미한 값으로 예측 성능을 구분하였다. Gilbert Skill Score(GSS)는 사건 발생과 비발생에 대한 예측 정확성이 랜덤한 예측 대비 얼마나 향상되었는지 보여주는 지표로, 값이 1에 가까울수록 정확성이 높음을 의미한다.

확률예측의 검증지표로 활용되는 Reliability Diagram은 예측 확률이 실제 발생빈도와 얼마나 일치하는지 시각적으로 평가하는 도표로서 점들이 대각선에 가까울수록 신뢰성이 높다. Relative Operating Characteristic(ROC) Curve는 특정 현상(‘기온이 평년보다 높음’ 등)의 발생 및 비발생을 얼마나 잘 구분하는지 곡선으로 표현되며, ROC 곡선 아래의 면적(AUC)으로 ROC score가 산출된다. False Alarm Rate(발생하지 않았는데 발생한다고 예측한 비율)가 작고 Hit Rate(실제 발생을 맞춘 비율)가 클수록 AUC가 커지며, 일반적으로 0.5 이상의 값을 의미있는 예측으로 간주한다. Heidke Skill Score(HSS)는 범주형 예측의 정확도를 우연의 일치 효과를 제거하여 평가하는 지표로 1로 갈수록 우수하다. Ranked Probability Skill Score(RPSS)는 확률예측(높음/비슷/낮음) 정확도를 관측 누적확률과 비교해 평가하는 지표로서, 0보다 크면 기준값보다 우수함을 보여준다. Brier Skill Score(BSS)는 예측확률의 제곱오차를 기준예측과 비교한 지표로, 값이 1에 가까울수록 예측성능이 우수함을 의미한다.

Table 4.6. Summary of verification metrics for real-time forecast.

	Variable	Region	Metric
Deterministic	PRCP, T2M, T850, Z500	14 regions	ACC, RMSE
Probabilistic	PRCP, T2M, T850, Z500	Global/4 regions/14 regions	Reliability Diagram, ROC Curve, HSS, RPSS
SST index	Nino3.4, Nino3, Nino4, Nino1+2, WIOD, EIOD	4 regions	ACC, SST indices time-series

Table 4.7. Summary of verification metrics for hindcast.

	Variable	Region	Metric
Deterministic	PRCP, T2M, T850, Z500	14 regions/Global	ACC, RMSE, MSSS, MSSSCorrelation, GSS
Probabilistic	PRCP, T2M, T850, Z500	4 regions/14 regions/Global	Reliability Diagram, ROC Curve, ROC Score, BSS

4.1.3. 결과

4.1.3.1 MME 계절예측시스템 운영

APCC MME 계절예측시스템 현업 운영은 Figure 4.1과 같은 일정으로 진행된다. 매월 1일, 국내외 현업·연구기관에 기후예측 자료 요청 메일을 발송하고, 13일까지 각 기관의 실시간 예측/과거기후예측자료(on-the-fly 모델 한정), 관측/재분석자료를 수집한다. 수집된 원시자료는 전처리 과정을 통해 표준화 및 품질 검증 절차를 거친 후 MME 산출에 활용된다.

APCC MME 참여모델 리스트는 참여기관의 기술적 상황, 모델의 개선 또는 신규 도입 등의 이유로 매월 변동 될 수 있다. 예를 들어, 2025년 4월 호주기상청(BoM)의 자체 시스템 업그레이드로 인한 자료 제공 불가, 미국항공우주국 글로벌모델링동화사무국(NASA)의 OS 업그레이드에 따른 자료 제공 지연으로 인해 두 모델이 MME 구성에서 제외된 바 있다. 또한, 모델이 개선됨에 따라 참여모델 구성이 변경되는 경우가 있었으며, CWA는 2025년 2월부터, METFR은 2025년 5월부터, CMCC는 2025년 8월부터 개선 모델이 MME에 참여하였다. 2025년 2월에는 PKNU 모델이 새롭게 참여하게 되었다. 2025년 10월에는 영국기상청(UKMO) 모델의 forecast 자료에서 마지막 앙상블 멤버 자료 누락이 확인되어 누락된 멤버만 제외한 후 MME 산출에 활용하였다.

이와 더불어, 올해는 참여 모델의 원시 예측자료의 오류 이슈가 지속적으로 발생하였다(Figure 4.2). 국립농업과학원(PNU-RDA) 모델의 경우 후처리 과정에서 비정상적인 bias가 발생하는 문제가 발견되어 2020년 3월 이후 생산된 예측자료를 모두 재처리하였다. 수정된 예측자료의 경우 양극(90°N, 90°S) 영역이 결측값으로 구성되어 있어 APCC 자체 해상도 변환 시 양극에 상당수의 결측값이 발생한다. 내부 회의를 통해 결측값 처리 방안을 논의한 결과, 90°N와 90°S의 값을 87.5°N와 87.5°S 값으로 대체 후 동일한 리그리드 방식을 적용하여 표준화하였다. 또한, 수정된 자료의 자료명, 포맷, 파일 구조 등이 변경됨에 따라 자료수집·전처리 시스템을 개선하였다. PNU-RDA의 과거기후 예측자료의 경우 초기에는 on-the-fly 형태의 자료로 인지함에 따라 매월 자료 수집 및 전처리 작업을 수행하였다. 그러나 해당 자료는 static(fixed) 자료임을 확인하였으며, 이에 따라 자료 처리 주기를 상시 활용 체계로 전환하여 현업 운영 효율성을 향상시켰다. 또한, PKNU 및 APCC 모델의 경우 해수면 온도(ssr) 육지값 또는 결측처리 설정 오류로 인해 해상도 변환 이후 육지-해양

경계선에서 이상치가 발생하는 문제가 발견되어, 해당 오류가 포함된 전 기간의 자료를 재처리하였다. NASA의 경우 2025년 9월 기존 GEOS-S2S-2.1 모델에서 GEOS-S2S-3 모델로 업그레이드되었으나 개선 모델의 실시간 예측 자료에서 이상치가 확인되었다. NASA 측 공식 답변에 따르면 near-real-time 예측자료에서 자료 형식, 파일 구조 및 내용 모두에 오류가 존재하며 자료동화 시스템의 정상화에 약 2개월 이상의 추가 기간이 필요함을 명시하였다. 본 사례는 APCC MME 운영 체계가 참여기관의 예측자료 검증 및 품질관리의 협력 플랫폼으로서 중요한 역할을 수행하고 있음을 보여준다. 이와 같이 APCC는 자료 오류 및 기술적 장애 발생 시 즉각적인 대응을 통해 다기관 모델 예측자료의 사전 품질 확보 및 예측 안정성 강화에 기여하고자 노력하고 있다.

이후 14일에 MME 기법별·선행시간별·해상도별 MME 예측자료를 산출하고, 이를 기반으로 파생되는 다양한 예측 콘텐츠들을 생산한다. 공식적으로 매달 15일에 APCC 누리집(www.apcc21.org)을 통해 향후 6개월에 대한 계절예측 정보가 발표되며, 해당 날짜가 공휴일인 경우 다가오는 평일에 발표된다.

이와 더불어, 동아시아 지역을 대상으로 한 감시정보 생산 및 검증시스템 운영이 동시에 수행된다. 검증 서비스 결과는 매월 20일에 홈페이지를 통해 공개하며, 해당 날짜가 공휴일인 경우 다가오는 평일에 게시하도록 운영하고 있다. 또한 감시 및 검증에 활용되는 재분석 자료의 수집이 지연되는 경우에는 대체 자료를 활용하여 즉각 대응하고 있다. 2025년 11월에는 NCEP/DOE reanalysis 2 자료의 실시간 업로드가 지연됨에 따라, NCEP/NCAR reanalysis 1 자료로 대체하여 감시 및 검증 작업을 수행하였다. 최종적으로 감시/예측/검증 정보를 종합하여 Climate outlook을 작성하여 홈페이지 및 이메일을 통해 배포된다.

2025년 2월부터 기상청 3개월 전망 생산 지원을 목표로 APCC 3개월 전망 예측자료를 추가 생산하고 있다. APCC 내부 예보토의를 통해 MME 계절예측 정보와 관측기반의 기후분석 정보를 종합해 우리나라 기온 및 강수에 대한 3개월 월별 예측 결과를 생산한다.

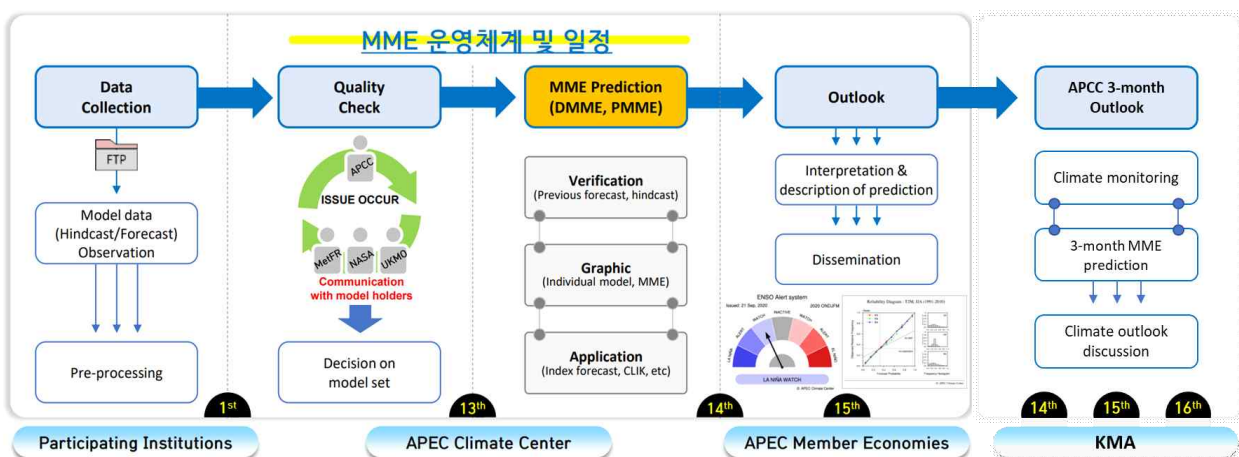


Figure 4.1. seasonal forecast operational system and schedule

Notice

Scheduled update of individual model prediction data!

PNU_CGCMv2.0 / PNU-RDA_CGCMv2.0		
Forecast :	2.5°	: 2020APR-2025MAY
Forecast :	1.0°	: 2022OCT-2025MAY
Hindcast :	2.5°/1.0°	: v2020-v2025
PKNU_CGCMv1.0*		
Forecast :	2.5°/1.0°	: 2025MAR-2025NOV
Hindcast :	2.5°/1.0°	: v2025
APCC_SCoPS		
Forecast :	2.5°/1.0°	: 2022FEB~2022DEC, 2023JAN
*Hindcast :	2.5°	: v2022-v2025

** SST-only*

Figure 4.2. Notice regarding the scheduled update of individual model prediction data.

올해까지 누적된 MME 계절예측 정보의 신뢰도 평가를 위하여 과거기후 단정예측 및 실시간 단정예측에 대한 ACC 분석을 수행하였다. 먼저, 과거기후 예측력을 진단하기 위해 전지구 기온 및 강수에 대한 ACC의 3년 이동평균값을 2015년부터 현재까지 산출하였으며, 이를 Figure 4.3에 제시하였다. 기온 및 강수 모두 2017년 이후 뚜렷한 향상 추세를 보였으며, 2015년~2017년 평균 대비 2023년~2025년 평균 ACC는 기온이 약 8.8%, 강수가 약 8.1% 향상된 것으로 나타났다.




Figure 4.3. Three-year running mean of global hindcast ACC for temperature(left) and precipitation(right).

Figure 4.4는 2008년 1월~3월 예측부터 2025년 7월~9월 예측까지 전지구 기온 및 강수의 실시간 예측에 대한 ACC를 월별로 제시한 결과이다. 색상 점은 개별모델의 ACC, 검정색 점은 MME ACC, 파란 실선은 관측된 Nino3.4 지수를 보여준다. 일부 계절을 제외하고 대체로 개별모델 대비 MME의 예측력이 우수하게 나타났으며, 전 기간 평균 ACC는 기온 0.49, 강수 0.37 수준으로 확인되었다. 특히, ENSO 강도가 강화되는 시기에 강수 예측력이 크게 향상되는 경향이 나타난다(김유진 등, 2024).

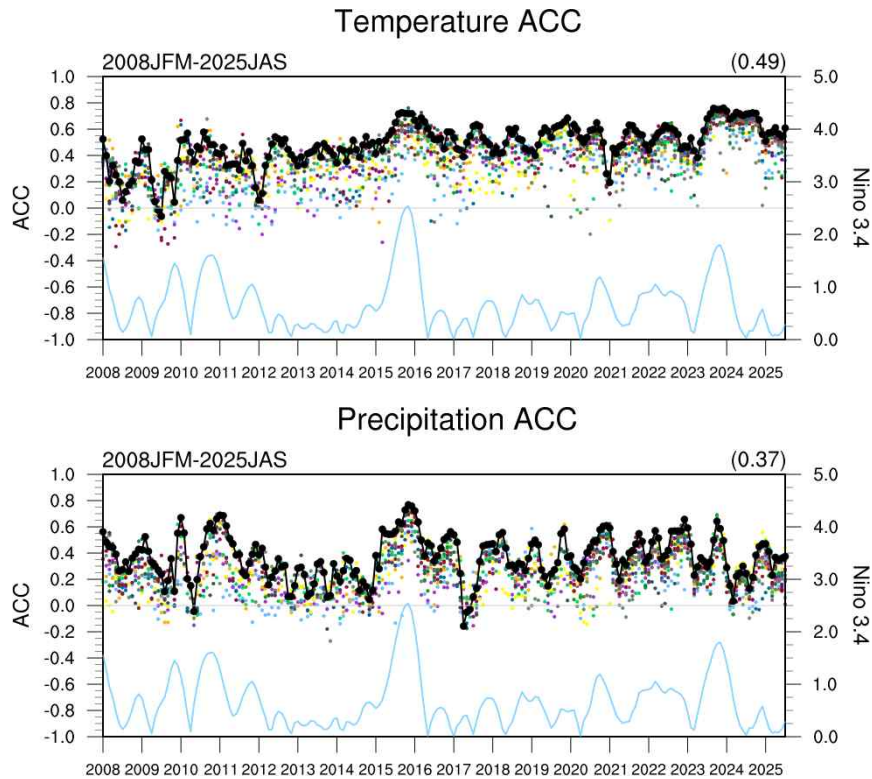


Figure 4.4. Global forecast ACC for temperature(top) and precipitation(bottom) (black and colored dots) compared with the observed Nino 3.4 index (blue line).

Figure 4.5는 전지구 기온 및 강수의 실시간 예측에 대한 ROC Score의 3년 이동평균값을 나타낸 결과이다. 가로축은 왼쪽부터 3분위 예측(평년이상/평년비슷/평년이하)에 대한 값을 의미하며, 가장 오른쪽은 세 범주의 평균값이다. 최신 관측자료를 포함하여 관측자료의 가용 시기를 반영한 결과로서, 1월~3월 예측에서 7월~9월 예측까지 평균값을 제시하였다. 최근 들어 모든 예측 범주에서 기온 및 강수 모두 ROC Score 0.5 이상으로 유의미한 예측 성능을 확보하고 있는 것으로 나타났다. 특히, 평년이상(Above-normal) 및 평년이하(Below-normal)의 범주에서 ROC Score가 높은 특징을 보인다. 이는 평년이상(Above-normal) 또는 평년이하(Below-normal) 범주는 뚜렷한 signal을 가지지만 평년비슷(Near-normal) 범주에서 signal은 약한 반면 내부 변동성(noise)과 이로 인한 모델 불확실성이 증가하기 때문으로 판단된다(Kharin and Zwiers, 2003). 또한 전지구 기온의 실시간 단정예측 및 실시간 확률예측 모두에서 과거 대비 예측 성능의 향상이 뚜렷하게 나타난다.

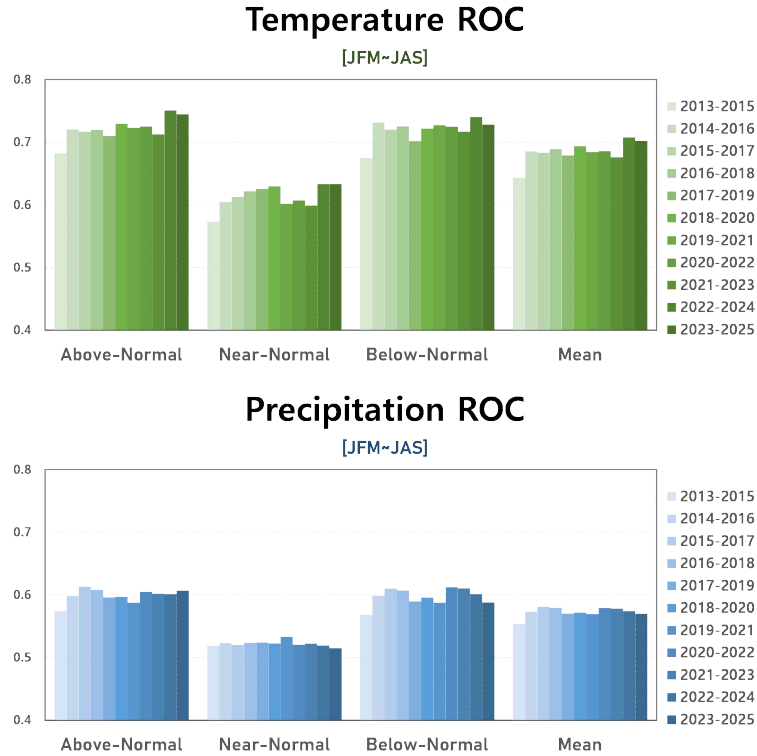


Figure 4.5. Three-year running mean of global forecast ROC scores for temperature (top) and precipitation (bottom).

4.1.3.2 MME 참여모델 변경 및 추가

Figure 4.6은 MME 참여모델 변경·추가 현황 및 계획에 대한 내용을 도식화 한 것이다. 상반기에 대만기상청(CWA) 및 프랑스기상청(METFR) 모델이 개선되었고, 부경대학교(PKNU) 모델이 신규 도입되었으며, 하반기에 유럽지중해기후변화센터(CMCC) 모델이 개선되었다. 추후 대만기상청(CWA), 미국국립환경예측센터(NCEP), 일본기상청(JMA)에서 모델 개선 계획을 밝힌 바 있고, 유럽중기예보센터(ECMWF) 모델을 추가할 예정이다. 참여모델이 개선됨에 따라 변경된 자료 구조 및 형식을 반영하기 위해 자료 수집·전처리 시스템 개선을 수행하였다. 이와 더불어 개선 모델의 예측성능 및 기존 모델과의 예측성능 비교 분석을 통해 모델 개선 효과를 파악하고자 하였으며 그 결과는 다음과 같다.

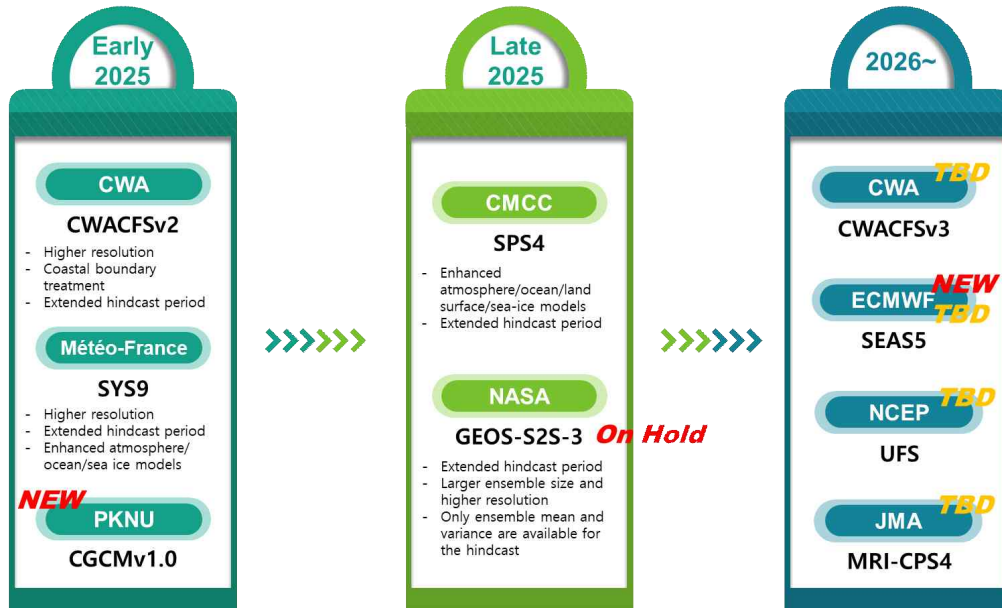


Figure 4.6. Current status and planned updates of participating models in the MME prediction system.

4.1.3.2.1 CWA

CWA는 기존 TCWA1Tv1.1 모델에서 CWACFSv2 모델로 개선되었으며, 주요 변경사항은 Table 4.8에서 확인할 수 있다. 기존 모델에 비해 수평 및 연직 해상도가 증가하고 예측기간이 10개월로 확대되었다.

Table 4.8. Summary of the existing and improved CWA models.

모델명	TCWA1Tv1.1	CWACFSv2
대기 모델명 및 해상도	GFS, T119L40	불명, T395L60
지면 모델명 및 해상도	NOAH, T119	NOAH, T395L4
해양 모델명 및 해상도	MOM3, 1° × 1°	GFDL/MOM5, T395L40
해빙 모델명 및 해상도	N/A	SIS, T395L3
앙상블 개수 (F/H)	30/30	30/30
선행시간	7개월 (0.5-month 포함)	10개월 (0.5-month) 포함
Hindcast 기간	1991-2020	1991-2020

Figure 4.7은 전지구 hindcast 참여모델별 ACC(심볼), ACC 전체 평균(검정 실선), CWA 개선 모델이 반영된 MME 예측에 대한 ACC(파란색 bar) 값을 보여준다. 기온 및 상하층 기압의 경우, 봄철 또는 겨울철 예측을 제외하고 전반적으로 모델 평균 예측 성능과 유사하거나 그 이상의 예측 성능을 보인다. 강수는 여름 및 가을철 예측 성능이 다른 계절에 비해 높게 나타난다. 그러나, 해수면 온도(sst)의 경우 전 계절에 대해 모델 평균 이하의 예측 성능을 보인다.

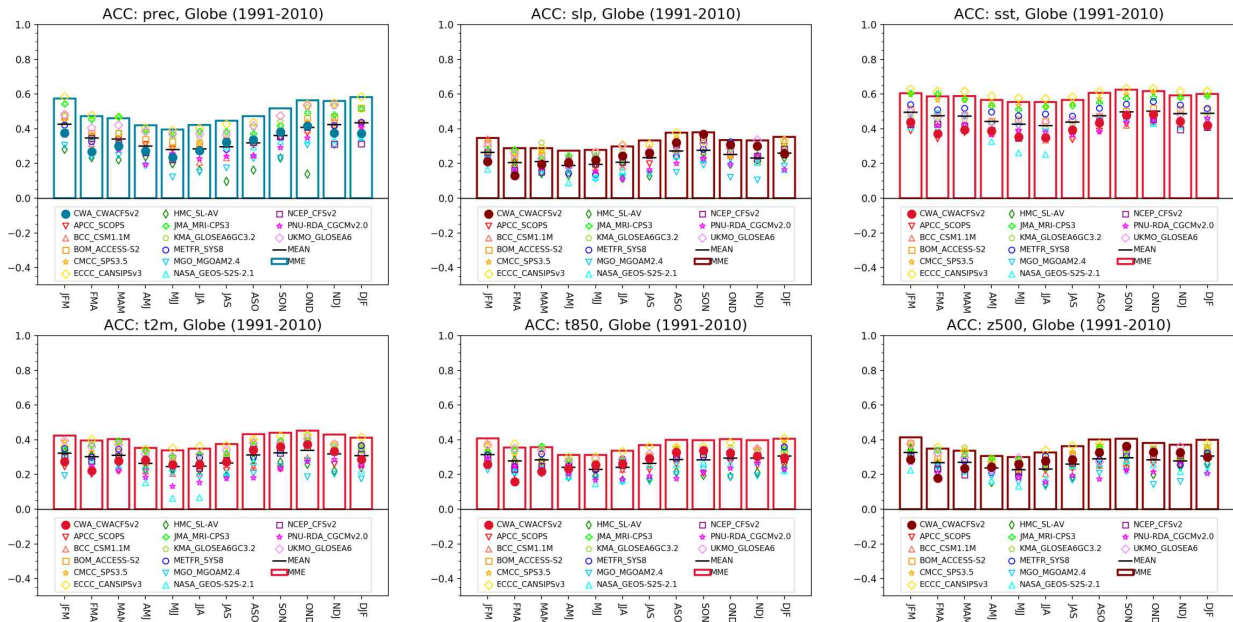


Figure 4.7. ACC of individual models (symbols), mean ACC of individual models (black line), and ACC of MME (bars) for global precipitation, SLP, SST, T2M, T850, and Z500.

Figure 4.8은 기존 모델 대비 개선 모델에 대한 주요 지역 및 계절별 hindcast ACC 차이를 보여준다. CWA 개선 모델은 많은 지역 및 계절에서 예측 성능 향상이 나타난다. 다만, 가을철 및 겨울철 동아시아 지역의 500hPa 지위고도 및 850hPa 기온의 예측 성능이 낮은 경향이 보이며, 다른 계절에 비해 FMA 계절의 경우 일부 지역에서 예측 성능이 낮은 특징이 나타난다.

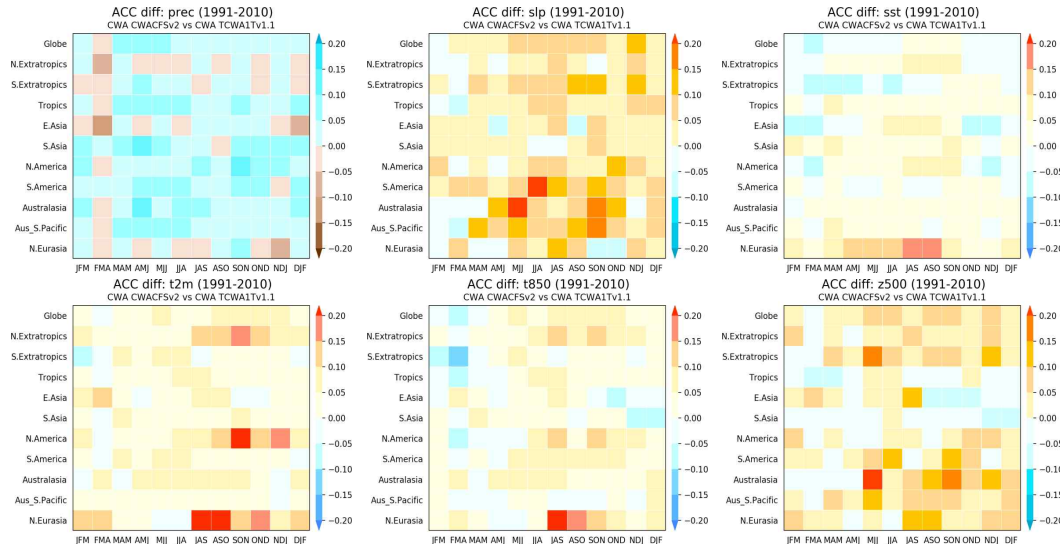


Figure 4.8. Differences in ACC between the improved and existing CWA Models by key region and season.

Figure 4.9는 계절별 전지구 hindcast ROC Score를 보여주며 점선은 기존 모델, 실선은 개선 모델에 대한 값이다. 개선 모델에서 500hPa 지위고도(z500)를 제외하고 전반적으로 연평균 ROC score가 향상된 것을 확인할 수 있다. 특히, 해면기압(slp)의 평년보다 높을 확률(AN)에 대한 예측 성능이 가장 크게 향상되는 것으로 나타난다.

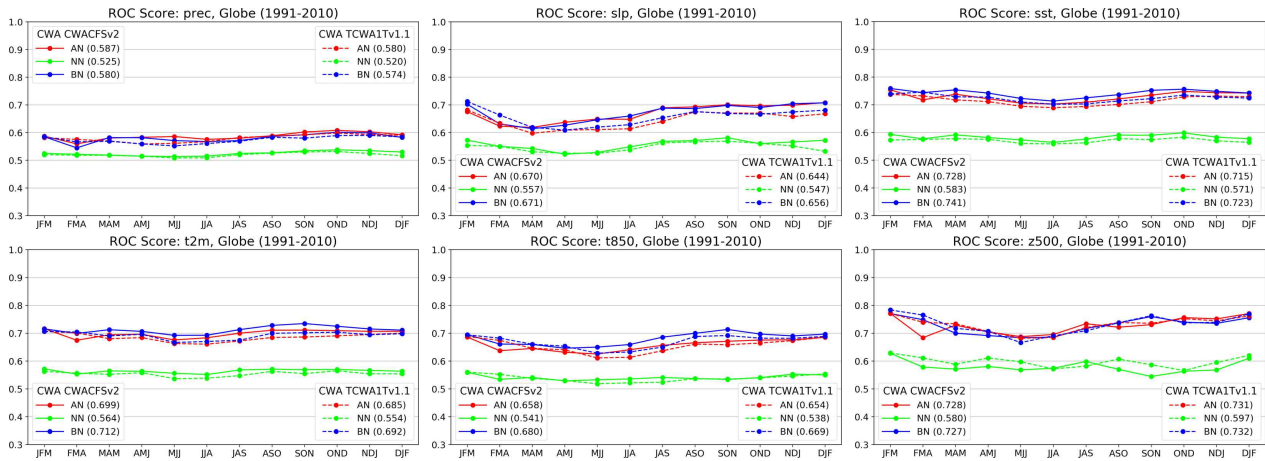


Figure 4.9. Global seasonal ROC scores of the existing (dotted line) and improved (solid line) CWA models.

다음으로 CWA 개선 모델이 MME 예측 성능에 미치는 영향을 살펴 보기 위해 기존 모델이 참여한 MME 예측 대비 개선 모델이 참여한 MME 예측에 대한 주요 지역 및 계절별 hindcast ACC 차이를 Figure 4.10에 제시하였다. MME 예측 성능의 차이는 지역 및 계절에 따라 상이하게 나타난다. 해면기압(slp)의 예측 성능이 두드러지게 향상되는 것으로 보이는 반면, 봄철 850hPa 기온 예측 성능은 대부분의 지역에서 낮아지는 경향이 보인다. 해수면온도(sst) 예측 성능은 전지구 값은 낮아지는 반면 열대 지역에서는 향상되는 특징이 나타난다.

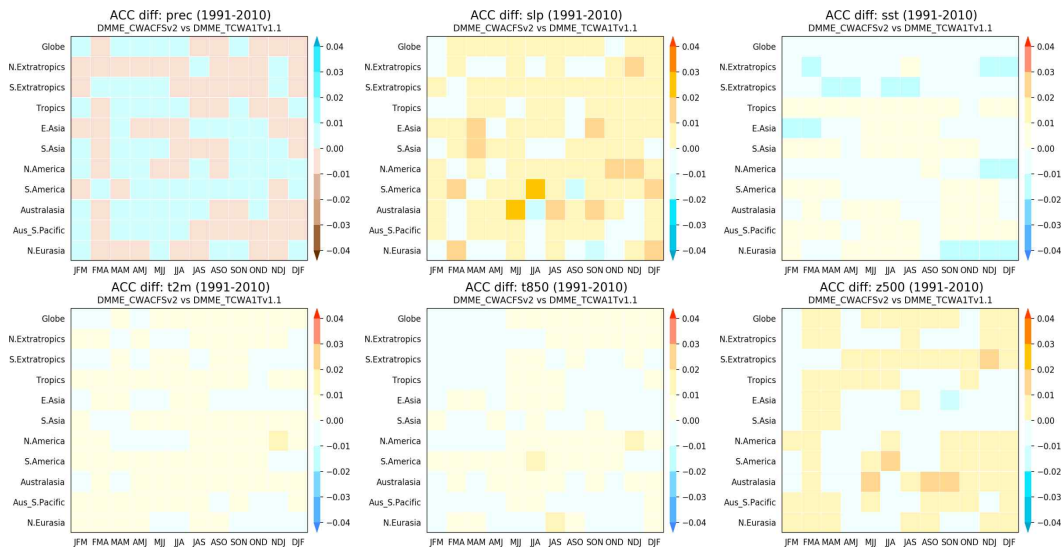


Figure 4.10. Global ACC differences in MME between the existing and the improved CWA models across seasons and regions.

기존 모델이 참여한 MME 예측 대비 개선 모델이 참여한 MME 예측에서 500hPa 지위고도(z500)를 제외하고 전반적으로 ROC Score가 향상되는 것으로 나타나며, 특히 해수면 온도(sst)의 경우 모든 계절에서 확률 예측 성능이 향상됨을 보여준다(Figure 4.11).




Figure 4.11. Global ROC score differences in MME between the existing and the improved CWA models across seasons.

Nino3.4 지수의 경우, 기존 모델이 참여한 MME 예측 대비 개선 모델이 참여한 MME 예측에서 연평균 TCC가 모든 예측 선행시간에 대해 더 높은 값을 보여주며, 특히 선행시간이 길어질수록 5~6월의 TCC가 크게 향상되는 것을 확인할 수 있다(Figure 4.12).

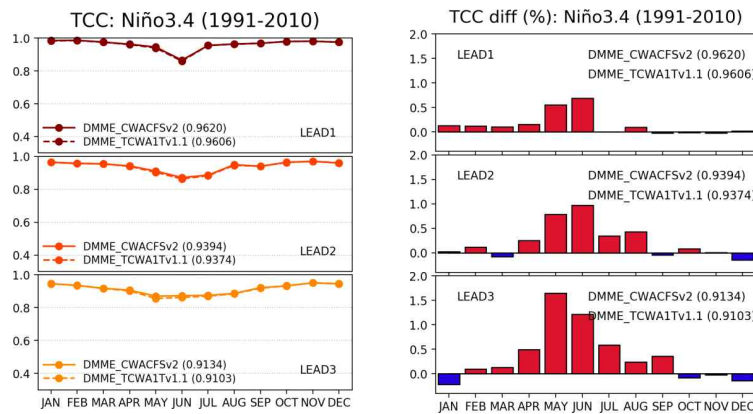


Figure 4.12. (Left) Niño-3.4 TCC of MMEs with the improved (solid) and existing (dotted) CWA models. (Right) Percentage TCC differences (%).

추가적으로, 기존 모델 TCWA1Tv1.1의 기온(t2m) 및 해수면 온도(sst) 실시간 예측자료에서 육지-해안 경계선 부근에 이상치가 나타나는 문제가 있었으며, 이는 대기-해양 결합 과정에서 발생하는 오류임을 CWA의 자체 분석을 통해 확인된 바 있다. 개선 모델 CWACFSv2의 기온 및 해수면 온도의 공간 분포를 재검토한 결과, 해당 문제가 해소된 것으로 확인되었다(Figure 4.13).

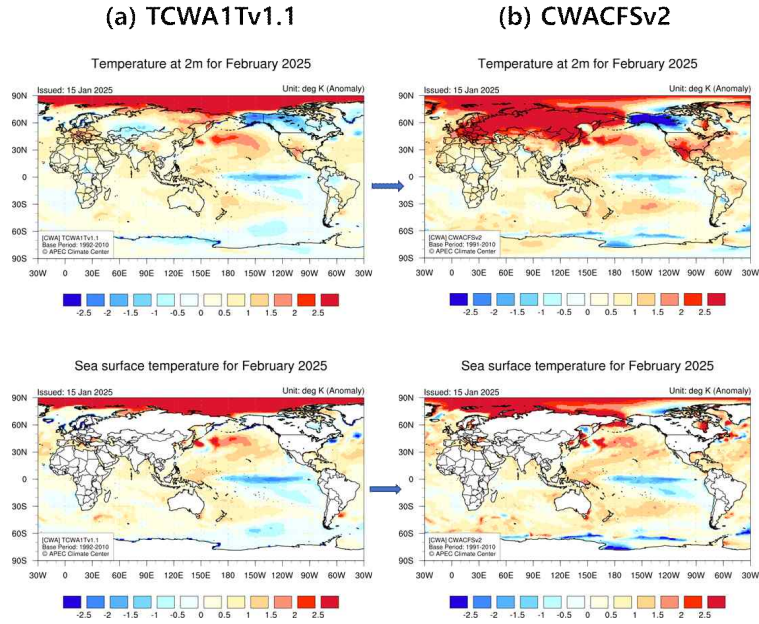


Figure 4.13. Forecast anomaly maps of temperature (top) and sea surface temperature (bottom) from the existing model (a) and the improved model (b).

4.1.3.2.2 CMCC

CMCC는 기존 SPS3.5 모델에서 SPS4 모델로 개선되었으며 주요 변경사항은 Table 4.9에서 확인할 수 있다. 대기 모델, 지면 모델, 해양 모델, 해빙 모델 모두 업그레이드 되었으며 연직해상도가 증가하였다. 과거기후예측(hindcast) 앙상블 멤버수는 기존 40개에서 30개로 축소되었으며, hindcast 기간은 2016년에서 2022년으로 연장되었다.

Table 4.9. Summary of the existing and improved CMCC models.

모델명	SPS3.5	SPS4
대기 모델명 및 해상도	CAM5.2, ~0.5° L46	CAM6, ~0.5° L83
지면 모델명 및 해상도	CLM4.5, ~0.5° L15	CLM5.1, ~0.5° L20
해양 모델명 및 해상도	NEMO3.4, ~0.25° L55	NEMO4.2, ~0.25° L75
해빙 모델명 및 해상도	CICE4, ~0.25°	CICE6, ~0.25° 8 ice layers + 3 snow layers
앙상블 개수 (F/H)	50/40	50/30
선행시간	5개월	5개월
Hindcast 기간	1993-2016	1993-2022

먼저, CMCC 개선 모델 자체 모의 성능 특성을 분석해 보았다. CMCC 개선 모델의 hindcast 가용자료의 제약으로 인해 예측력 분석 결과는 모두 1993년~2010년 가을철(SON) 예측에 한정된다. 전지구 가을철(SON) Mean Bias(Figure 4.14)를 살펴보면, 해수면 온도(sst)의 경우 열대 해양에서 warm bias가, 북태평양 및 극지역에서 cold bias가 나타난다. 지표 기온(t2m)도 비슷한 양상을 보이며 대륙 전반과 북극해 부근에서 뚜렷한 warm bias 나타난다. 이와 관련하여 해면기압(slp)의 경우 열대 및 고위도 부근에서 음의 bias가 중위도 부근에서 양의 bias가 발생한다. 강수량(prec)의 경우 다른 지역에 비해 열대지역에서 bias가 크게 나타난다. 동인도양 및 서태평양(동아프리카 및 서인도양)에서 dry bias(wet bias)와 함께 500hPa 지위고도에서 양의 bias(음의 bias)가 나타나는 특징이 보인다.

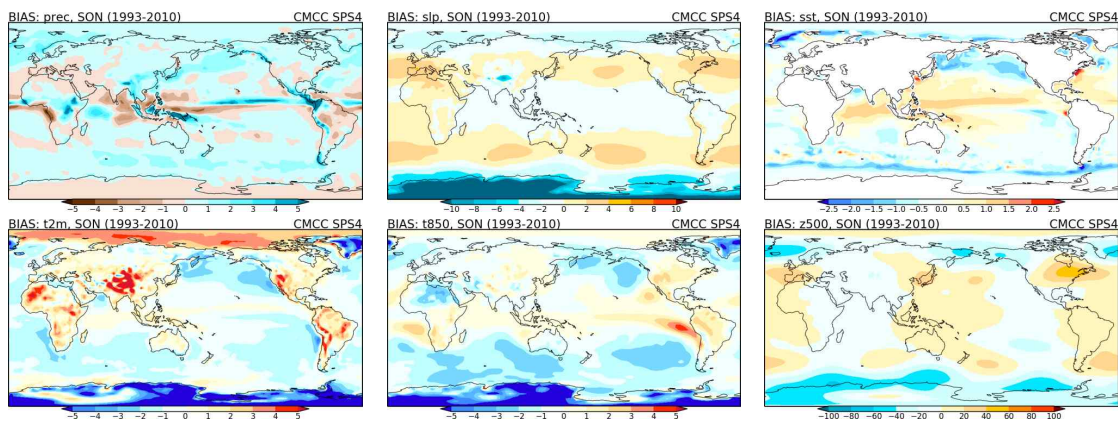


Figure 4.14. Global mean bias in SON for precipitation, SLP, SST, T2M, T850, and Z500 from the improved CMCC model.

주요 11개의 지역별 가을철(SON) ACC 결과를 살펴보면(Figure 4.15), 해수면 온도(sst)의 경우 대부분의 지역에서 약 0.5 이상의 높은 상관관계를 보이며, 그 외 변수에서 열대, 남아시아, 남태평양 지역에서 상대적으로 높은 ACC를 보인다. 상하층 기압(slp, z500) 및 강수량(prec)의 경우 북반구 대륙에서 낮은 ACC를 보여준다.

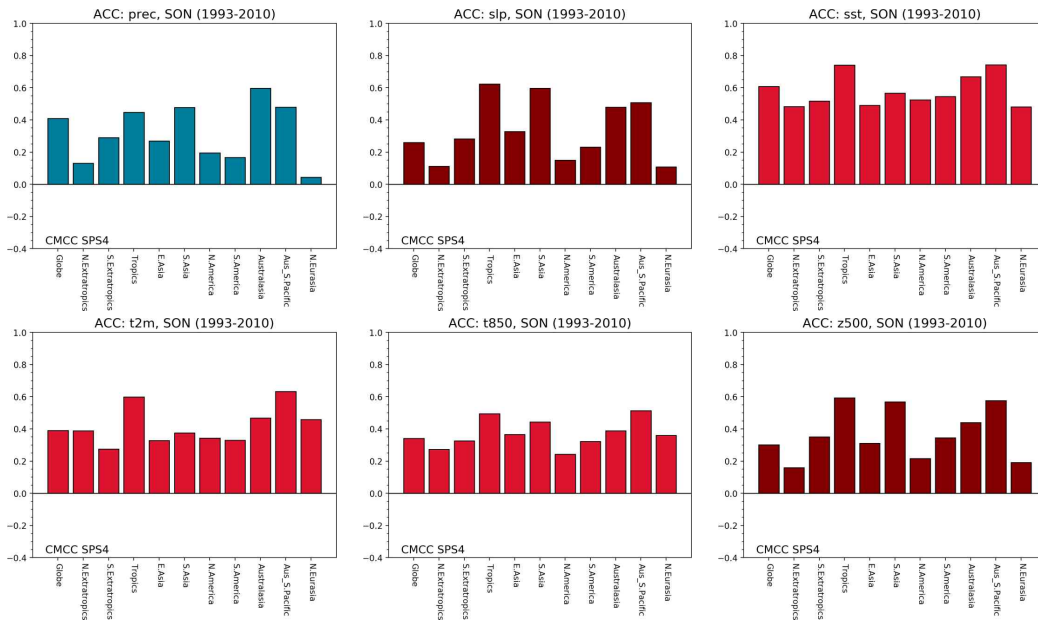


Figure 4.15. Regional ACC in SON for precipitation, SLP, SST, T2M, T850, and Z500 from the improved CMCC model.

전지구 가을철(SON) ROC Curve 결과를 살펴보면(Figure 4.16), 평년이상(AN) 및 평년이하(BN) 예측은 모든 변수에서 비슷한 수준의 ROC Score을 보여주며, 평년비슷(NN) 예측보다 높은 값을 나타내는 경향이다. 이는 앞서 언급한 바와 같이 평년비슷(NN) 예측의 경우 signal 대비 noise의 비율이 더 크기 때문에 예측 성능이 상대적으로 낮게 나타나는 것으로 판단된다. 평년이상(AN) 및 평년이하(BN) 예측에 대해 강수량(prec)의 경우 ROC Score가 약 0.6 수준이며, 그 외 변수는 0.7 이상의 다소 높은 예측 성능을 보인다.

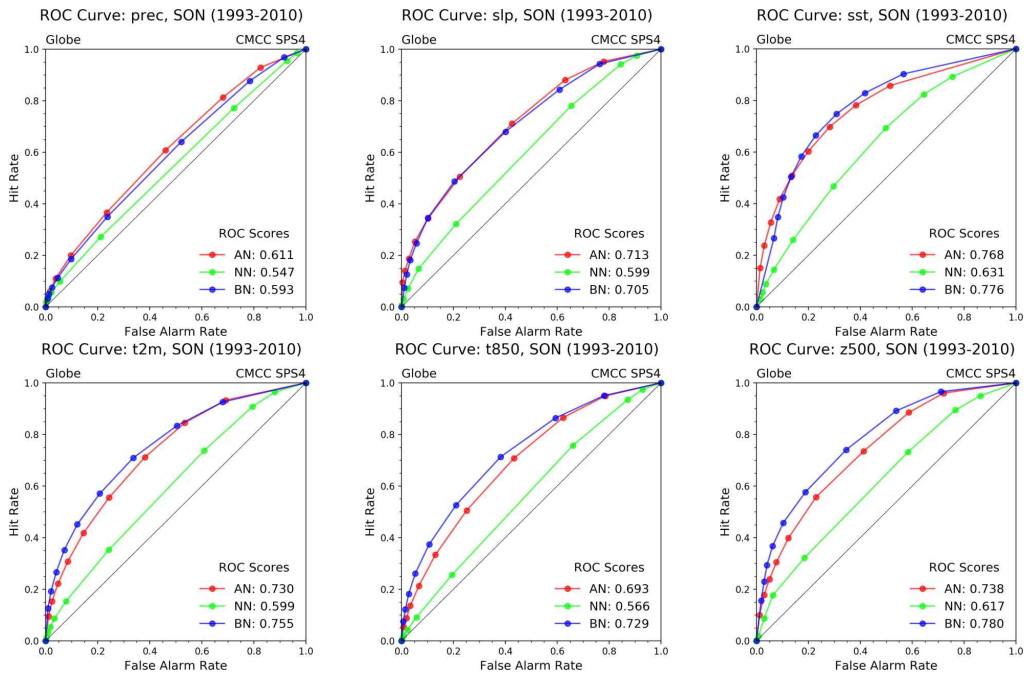


Figure 4.16. Global ROC in SON for precipitation, SLP, SST, T2M, T850, and Z500 from the improved CMCC model.

다음으로 CMCC 기존 모델 대비 개선 모델의 가을철(SON) 예측 성능의 차이를 분석해보았다. 주요 지역별 TCC 차이 결과(Figure 4.17)에서는 변수 대부분이 개선 전/후 모델의 TCC 차이가 0.1 이하로 미미하다. 해수면 온도(sst), 850hPa 기온(t850), 해면기압(slp)의 경우 개선 모델의 TCC가 대부분의 지역에서 높게 나타난다. 2m 기온(t2m) 및 500hPa 지위고도(z500)의 경우, 남아시아 및 남반구 중고위도 지역을 제외한 지역에서 개선 모델의 TCC가 높다. 강수량(prec)의 TCC는 북반구 중위도 지역을 제외한 대부분 지역에서 개선 모델에서 향상된 값을 보인다.

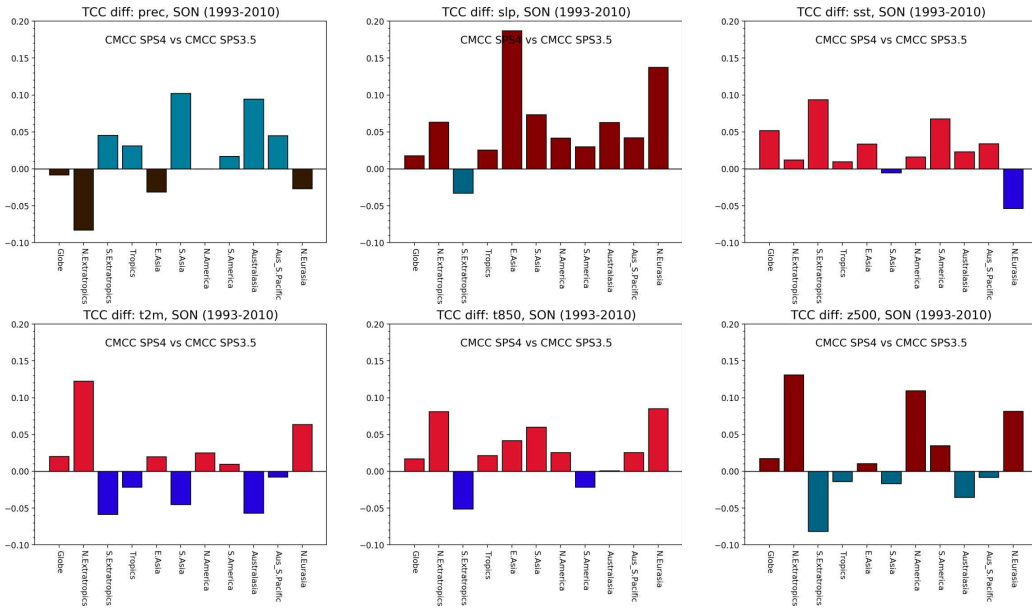


Figure 4.17. Regional TCC differences in SON between the existing and the improved CMCC models for precipitation, SLP, SST, T2M, T850, and Z500.

지역별 ACC 차이를 살펴보면(Figure 4.18) 변수 대부분이 개선 전/후 모델의 ACC 차이가 0.1 이하로 나타나며, 개선된 모델의 해수면 온도, 강수량, 850hPa 기온, 해면기압의 ACC가 대부분의 지역에서 높게 나타나는 경향이다. 2m 기온의 경우 동아시아 및 북유라시아를 포함한 북반구 중/고위도 지역에서 개선된 모델의 ACC가 높은 반면, 그 외 지역은 다소 낮아지는 경향이다.

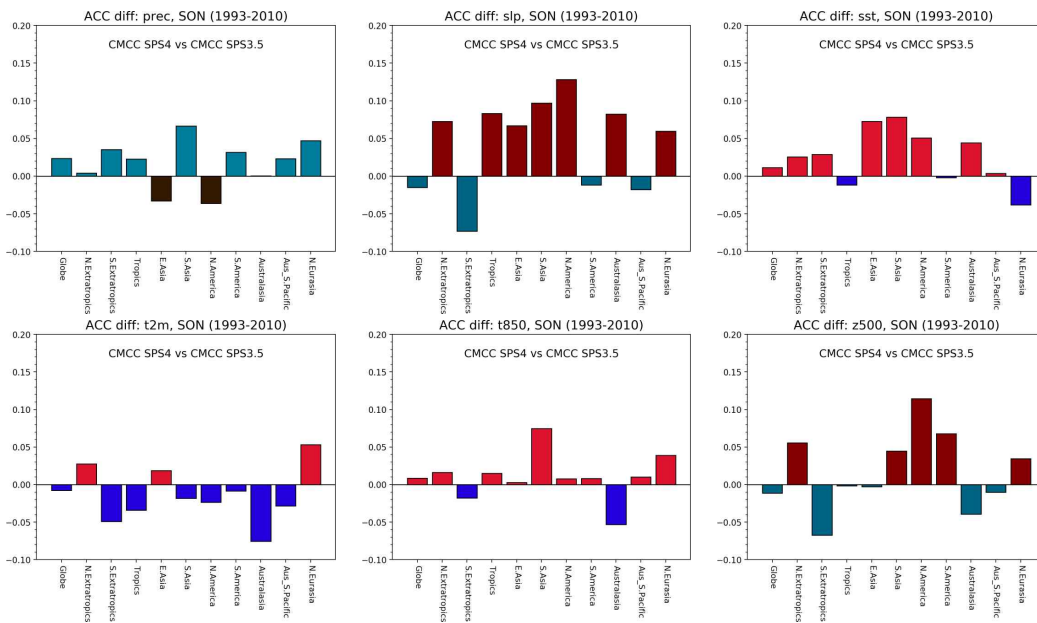


Figure 4.18. Same as Figure 4.17, but for ACC.

위의 결과를 종합해 보면, CMCC 개선 모델(SPS4)은 가을철(SON) 해수면 온도 예측 성능이 가장 우수한 반면, 강수량 예측력은 여전히 낮은 수준이다. 특히, 열대, 남아시아, 남태평양 지역에서 TCC 및 ACC가 전반적으로 높은 경향을 보인다. 모델 개선 전후의 예측력 변화는 지역 및 변수에 따라 다소 차이가 있으나, 전반적인 개선 폭은 제한적이다. 해수면 온도, 850hPa 기온, 해면기압에서 개선된 모델 예측력이 전반적으로 향상되었고, 이 중 해면기압은 동아시아 지역에서 개선 효과가 가장 뚜렷하게 나타난다.

4.1.3.2.3 METFR

METFR은 기존 System 8 모델에서 System 9 모델로 개선되었으며 주요 변경사항은 Table 4.10에서 확인할 수 있다. 대기 모델 및 해양 모델이 업그레이드 되었으며, 해빙 모델이 변경되었다. 과거기후예측(hindcast) 앙상블 멤버수가 25개에서 31개로 증가하였고, hindcast 기간 또한 2018년에서 2024년으로 연장되었다.

Table 4.10. Summary of the existing and improved METFR models.

모델명	System 8	System 9
대기 모델명 및 해상도	ARPEGE v6.4, TL359; 137 levels	ARPEGE v6.5, TL359; 137 levels
지면 모델명 및 해상도	SURFEX v8.0, TL359	SURFEX v8.0, TL359
해양 모델명 및 해상도	NEMO v3.6, 0.25°	NEMO v4.2.0, 0.25°
해빙 모델명 및 해상도	GELATO v6.0, 0.25°	SI3, 0.25°
앙상블 개수 (F/H)	51/25	51/31
선행시간	6개월	6개월
Hindcast 기간	1993-2018	1993-2024

METFR의 경우 System 9 모델의 Hindcast 가용자료의 제약으로 인해 예측력 분석 결과는 모두 1993년~2010년 여름철(JJA) 예측에 한정된다. 먼저, 개선 모델의 전지구 여름철(JJA) 예측에 대한 Mean Bias를 살펴보면(Figure 4.19), 해수면 온도의 경우 남태평양 부근 cold bias와 함께 상하층 지위고도를 과소모의 하는 반면, 인도양 및 필리핀해 부근 warm bias와 함께 상하층 지위고도를 과대모의 하는 경향이 나타난다. 열대지역에서 강수량 bias가 크며, 2m 기온의 경우 대륙의 일부 지역을 제외하고 대부분 warm bias가 나타난다. 또한, 북태평양 및 북대서양 부근으로 뚜렷한 cold bias가 존재한다.

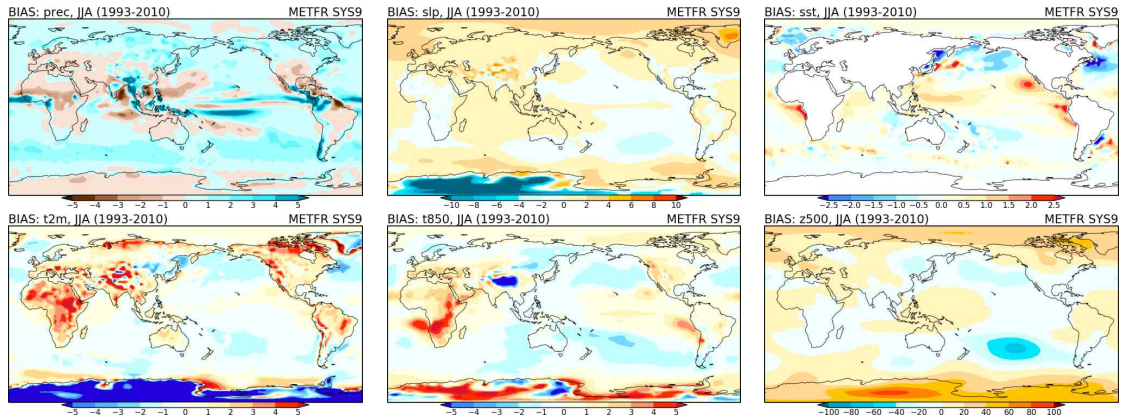


Figure 4.19. Same as Figure 4.14, but for the improved METFR model.

Figure 4.20은 주요 지역별 여름철(JJA) 예측의 ACC를 보여준다. 해수면 온도의 경우 아시아를 포함한 북반구 중/고위도 지역을 제외하고 0.5 이상의 상관 관계를 보인다. 해수면 온도를 제외한 나머지 변수에서 열대 및 남태평양 지역에서 높은 ACC를 보이는 반면, 중위도 대륙 부근으로 낮은 값을 나타낸다.

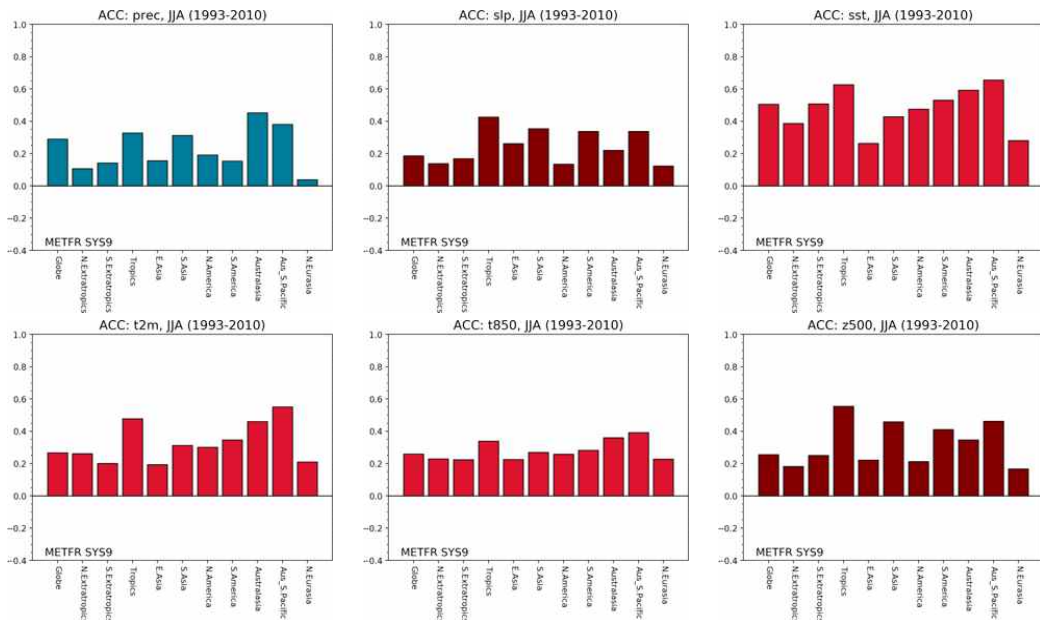


Figure 4.20. Same as Figure 4.15, but for the improved METFR model.

전지구 여름철(JJA) ROC Curve (Figure 4.21) 결과로부터 평년이상(AN) 및 평년이하(BN) 예측은 모든 변수에서 비슷한 수준의 ROC Score을 보여주며, 평년비슷(NN) 예측보다는 높은 값을 가지는 경향을 확인 할 수 있다. 평년이상(AN) 및 평년이하(BN) 예측에 대해 해수면 온도, 2m 기온, 500hPa 지위고도는 0.7 이상의 다소 높은 예측 성능을 보여준다.

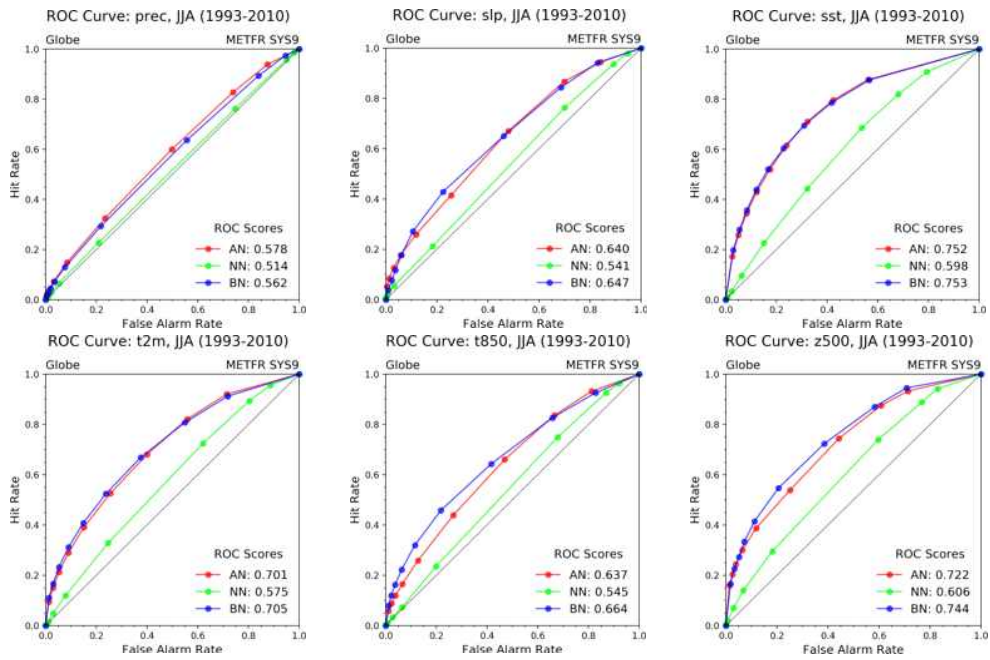


Figure 4.21. Same as Figure 4.16, but for the improved METFR model.

지역별 여름철(JJA) TCC 차이를 살펴보면(Figure 4.22), 해수면 온도의 경우 개선된 모델의 TCC가 대부분의 지역에서 높은 것을 확인할 수 있다. 2m 기온, 850hPa 기온, 해면기압, 500hPa 지위고도의 경우 남미 및 북유라시아 지역에서 개선 전 모델에 비해 TCC 향상이 뚜렷하게 나타나는 반면 그 외 지역에서 다소 낮아지는 경향이 보인다. 동아시아 지역은 해수면 온도, 강수량, 2m 기온의 TCC 증가 두드러지게 나타난다.

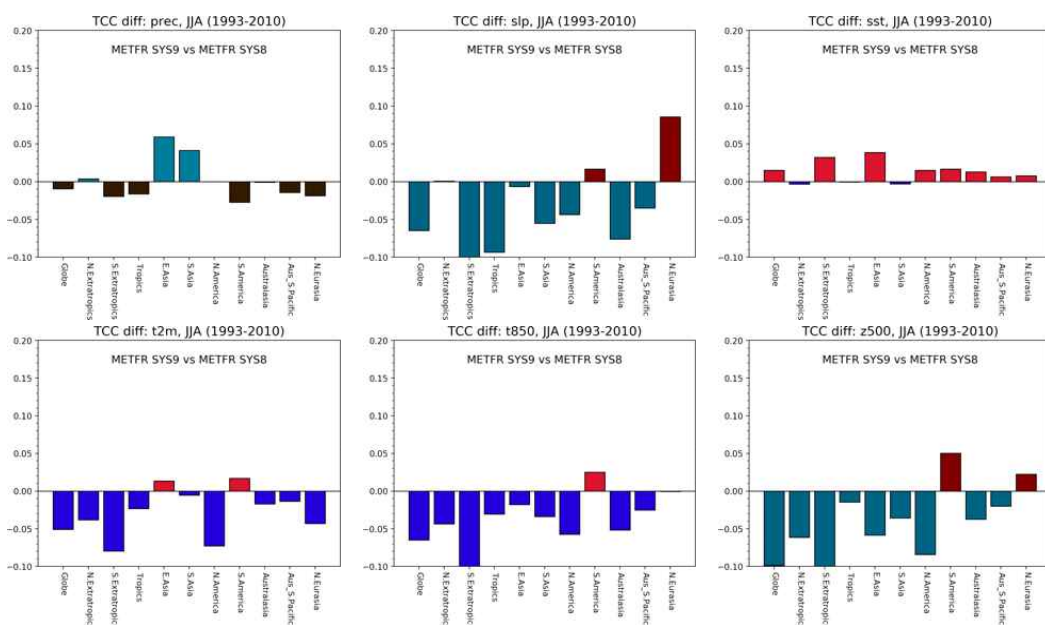


Figure 4.22. Same as Figure 4.17, but for the METFR models.

지역별 여름철(JJA) ACC 차이를 살펴보면(Figure 4.23), 변수 대부분이 개선 전/후 모델의 ACC 차이가 0.1 이하로 나타나며, 개선된 모델의 해수면 온도 및 강수량의 ACC가 대부분의 지역에서 높게 나타나는 경향이다. 2m 기온, 850hPa 기온, 해면기압, 500hPa 지위고도의 경우 남미 지역에서 개선 전 모델에 비해 예측력 향상이 뚜렷하게 나타나는 반면 그 외 지역에서 다소 낮아지는 경향을 보인다.

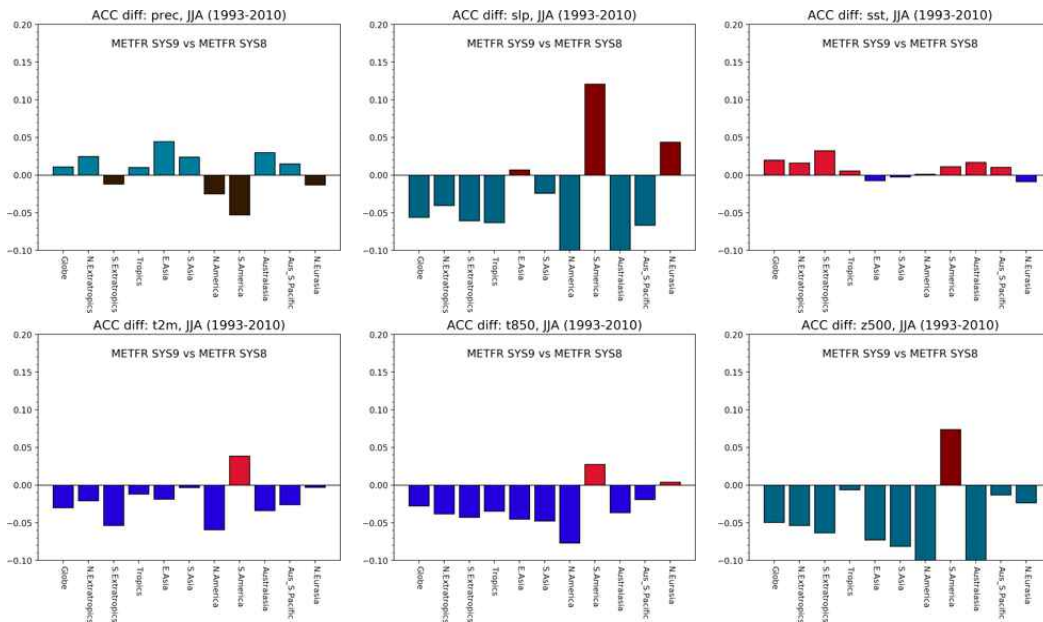


Figure 4.23. Same as Figure 4.18, but for the METFR models.

위의 분석 결과를 토대로 METFR 개선 모델(System 9)은 여름철(JJA) 해수면 온도 예측 성능이 가장 우수한 반면 여전히 강수량 예측력은 낮은 수준이며, 다른 지역에 비해 열대 및 남태평양 지역에서 TCC 및 ACC 모두 높은 경향을 보이는 것을 확인할 수 있다. 개선 전/후 모델의 예측력 변화는 지역 및 변수에 따라 일부 차이를 보이나, 전반적으로 개선 효과 폭은 크지 않다. 대부분의 변수에서 남미 지역의 예측력 향상이 뚜렷하고 강수량의 경우 다른 지역에 비해 아시아 지역에서 개선 효과가 강하게 나타나는 특징이 보인다.

4.1.3.3 Hindcast 기후값 기간 연장

현재 APCC 다중모델앙상블(MME) 계절예측시스템에서는 기후값(climatological normal)의 기준 기간으로 1991-2010년의 20년 평균을 사용하고 있다. 그러나 세계기상기구(WMO)는 기후값 산정을 위해 최근 30년 평균 사용을 권고하고 있으며, 최소 24년 이상의 자료 확보를 기준으로 제시하고 있다(WMO, 2017). 이러한 국제 기준을 충족하고 최근 기후 변동을 보다 현실적으로 반영하기 위해 APCC MME 시스템의 hindcast 기후값 기간을 1993-2016년(24년)으로 확장하는 작업을 추진하였다. 다양한 기후값 기간에 대한 민감도 실험

결과는 김유진 등(2024)에 의해 공유되었으며, 내부 검토 및 협의가 완료됨에 따라 본 개선 사항을 시스템에 반영하였다. 본 시스템 개선에 기반하여 hindcast 기간 확장 버전의 예측 정보는 2025년 8월 (2025 SONDJF 예측)부터 APCC 홈페이지에 공식 배포되고 있다.

Hindcast 기간 확장에 따라 MME 계절예측 및 검증시스템이 전반적으로 개선되었다. 개선된 APCC 예측 자동화 시스템(Automated Forecast System, AFS)은 MME 현업 운영 전용 서버(10.100.9.116)에서 구동되며, /data02/OPER/Hres_AFS 경로를 중심으로 ‘CODE’, ‘DATA’, ‘Lres_DATA’, ‘DATA_daily’, ‘RUN’ 디렉터리 등 기능별 구조를 갖추어 운영되고 있다(Figure 4.24). 특히, ENSO 감시·예측, 동아시아 기후 감시·예측, APCC 3개월 전망, 동적 콘텐츠, 검증 관련 예측 및 가시화 전 과정이 일관된 하나의 디렉터리에서 처리되는 통합 환경을 구축하며, 날짜·모듈 환경설정 자동화 기능과 모델 가용 연도 기반 자동 필터링 기능 등을 추가하여 현업 운영 환경을 개선하였다.

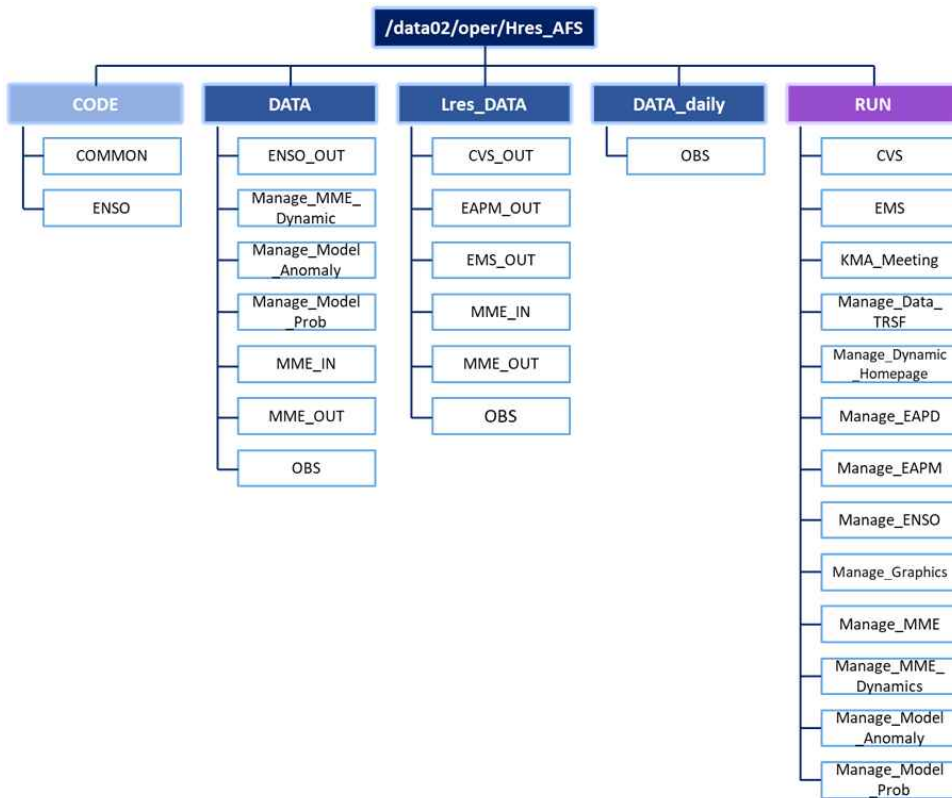


Figure 4.24. Directory structure of the MME Automated Forecast System for the extended hindcast period.

Figure 4.25는 APCC MME 참여모델별 1-month lead time의 1월 예측, 2월 예측, 3월~12월 예측에 대한 hindcast 자료의 가용 기간을 제시한다. 표 내 녹색 음영은 기존 hindcast 기후값 기간, 노란색 음영은 확장된 hindcast 기간을 각각 나타낸다. 1-month lead 예측 특성상 1991년 1월 초기화된 예측의 시작시점은 1991년 2월이며 2010년 12월 초기화된 예측의 시작시점은

2011년 1월이 된다. 따라서 기준 기간은 1월 예측의 경우 1992-2011년, 2월-12월 예측은 1991-2010년이 된다. 반면, 확장된 기간은 동일한 방식으로 lead time을 적용할 경우 1월 예측의 경우 1994-2017년, 2월-12월 예측은 1993-2016년이 된다. 기존 hindcast 기후값 기간에 의하면 CMCC, CWA, KMA, METFR, NCEP, UKMO, PKNU 등 다수의 참여모델에서 상당수 결측값이 발생하는 문제가 있었다. 그러나 hindcast 기후값 기간을 1993-2016년으로 조정함에 따라 NCEP을 제외한 모델들이 기준 기간을 충족하여 결측값이 크게 감소하였다. 이는 참여모델 간 유효 샘플 수의 불균형이 완화되어 MME 구성의 안정성이 강화되었으며, 결측 보완 작업이 대폭 감소하여 실시간 예측 운영의 효율성이 증대되었다.

January	1991	1992	1993	1994	1995	2010	2011	2012	2013	2014	2015	2016	2017
APCC															
BOM															
CMCC															
CWA															
ECCC															
HMC															
JMA															
KMA															
MetFR															
MGO															
NASA															
NCEP															
PNU-RDA															
UKMO															
PKNU															

February	1991	1992	1993	1994	1995	2010	2011	2012	2013	2014	2015	2016	2017
APCC															
BOM															
CMCC															
CWA															
ECCC															
HMC															
JMA															
KMA															
MetFR															
MGO															
NASA															
NCEP															
PNU-RDA															
UKMO															
PKNU															

Mar.-Dec.	1991	1992	1993	1994	1995	2010	2011	2012	2013	2014	2015	2016	2017
APCC															
BOM															
CMCC															
CWA															
ECCC															
HMC															
JMA															
KMA															
MetFR															
MGO															
NASA															
NCEP															
PNU-RDA															
UKMO															
PKNU															

□ : Missing data □ □ : Hindcast 공통 기간

Figure 4.25. Hindcast availability period by MME participating models for forecasts of January, February, and March-December. White indicates missing data, and light green/yellow denote the common hindcast period.

Hindcast 기후값 기간 확장 전후의 향후 6개월(SONDJF)에 대한 ENSO 확률예측 결과를 비교해보면(Figure 4.26), 두 버전 모두 ENSO 중립 발생 가능성을 가장 높게 예측하였으나, 확장된 기간(1993-2016년) 적용 시 라니냐 발생 확률이 더 높게 산정하는 경향이 확인된다. 특히, OND(10-12월) 기간에서 기존 중립 발생 확률이 우세하였던 것과 달리, 확장 버전에서 라니냐 발생 확률이 상대적으로 높아지며 ENSO 위상이 전환되는 특징이 나타난다. 이러한 차이는 최근 열대 해수면 온도의 변동성이 예측에 반영된 결과로 해석된다.




Figure 4.26. Probabilistic ENSO forecasts (%) for 2025 SONDJF based on hindcast periods 1991-2010 (top) and 1993-2016 (bottom).

또한 Figure 4.27은 SON(9-11월) 기간에 대해 hindcast 기후값 기간 확장 전후의 기온 확률 예측 차이(%)를 전지구적으로 나타낸 것이다. 좌측 그림은 평년 대비 기온이 높을때의 확률 차이를 보여주고, 우측 그림은 평년 대비 기온이 낮을때의 확률 차이를 나타낸다. 기간 확장 버전에서는 대부분 지역에서 고온(above-normal) 발생 확률이 감소하고 저온(below-normal) 발생 확률은 증가하는 경향이 확인되며, 특히 열대 해양에서 해당 변화가 뚜렷하게 나타난다.

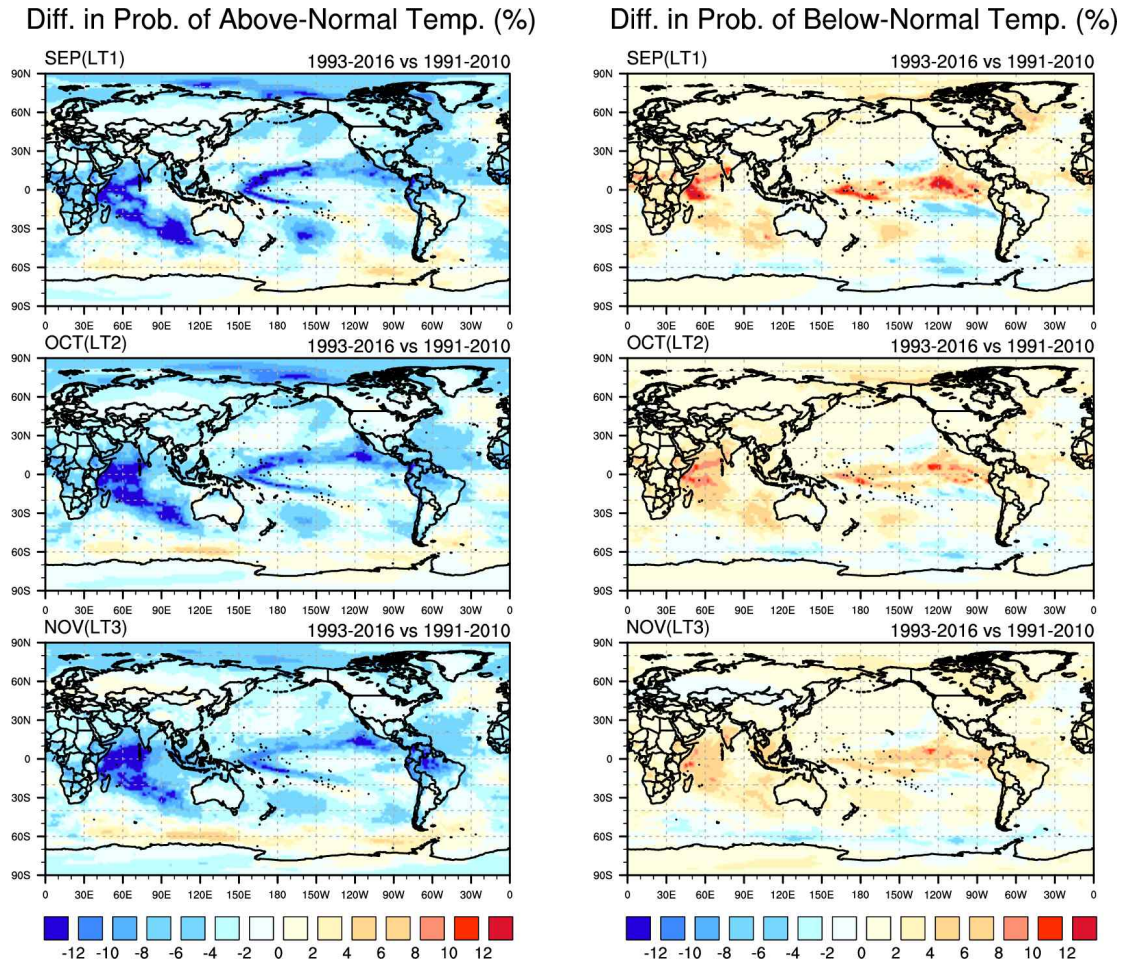


Figure 4.27. Differences in probability (%) of above-normal temperature (left) and below-normal temperature (right) in SON between hindcast periods 1991-2010 (top) and 1993-2016 (bottom).

2025년 SON 기간에 대해 우리나라 기온 확률예측을 비교한 결과(Figure 4.28), 두 버전 모두 3개월 내내 평년 대비 높은 기온을 예측하였으나, 확장 버전에서 기존 대비 9월 3%, 10월 1%, 11월 2% 낮게 산정되어 고온 발생 확률이 감소하였다. 이는 기존 버전에서 기후값 기간(1991-2010년)이 이미 과거 시점에 속하여 최근 가속되는 지구 온난화 경향을 충분히 반영하지 못하고, 결과적으로 예측이 고온 쪽으로 편향되었기 때문으로 판단된다. 반면, 확장 버전 기후값 기간(1993-2016년) 적용은 온난화 영향이 더 강하게 나타나는 최근 해양-대기 상태를 반영함으로써, 상대적으로 고온 편향이 완화되는 효과가 나타나는 것으로 보인다.




Figure 4.28. Probabilistic forecasts (%) for temperature (left) and precipitation (right) in SON for hindcast periods 1991-2010 (top) and 1993-2016 (bottom).

4.1.3.4 고해상도 검증 정보 제공

APCC는 2022년 9월부터 제공된 고해상도 예측자료를 적극 활용하여 예측 성능 평가의 정확성을 강화하고, 검증 서비스의 질적 향상을 도모하기 위해 기존의 MME 저해상도(2.5°) 검증시스템을 고해상도(1.0°) 기반으로 전환하였으며, 2025년 10월부터 고해상도 검증결과를 APCC 홈페이지를 통해 정식 배포하고 있다.

고해상도 검증시스템은 MME AFS(Automated Forecast System) 기반의 독립 운영 환경에서 구성되었으며, 서버 주소는 10.100.9.116, 운영 경로는 /data02/OPER/Hres_AFS이다. 시스템 내부 디렉터리 구조는 Figure 4.29와 같이 구성된다. “STD_OBS”은 고해상도 재분석자료 전처리, “RUN”은 고해상도 예측자료에 대한 검증 수행, “DATA”은 고해상도 검증 입출력 자료 저장, “FIG”은 검증 결과 그림 저장과 관련된 디렉터리이다. 이와 함께 Hindcast 기간 변경에 따른 검증 조건 차등 적용, 특정 지역의 데이터 처리 연속성 확보, 해수면 온도 지수 검증에 활용되는 모델 확대 등을 포함하는 다양한 개선 사항이 적용되었다.




Figure 4.29. Directory structure of the high-resolution verification system.

현재, APCC는 실시간 예측(Forecast) 및 과거기후예측(Hindcast)에 대한 단정예측 및 확률예측 검증 결과를 홈페이지를 통해 제공하고 있다. 실시간 예측 검증 항목으로는 강수, 2m 기온, 850hPa 기온, 500hPa 지위고도에 대한 ACC(Anomaly Correlation Coefficient), RMSE(Root Mean Square Error), 그리고 Reliability Diagram, ROC Curve, HSS(Heidke Skill Score), RPSS(Ranked Probability Skill Score) 등이 포함된다. 또한 해수면 온도(SST) 영역의 검증을 위해 Nino3.4, Nino3, Nino4, Nino1+2, WIOD, EIOD 등 다양한 SST 지수에 대한 ACC 검증 결과를 제공한다. 과거기후예측 검증에서는 단정예측 기준 ACC, RMSE, MSSS(Mean Squared Skill Score), GSS(Gilbert Skill Score)와 함께, 확률예측 기준 Reliability Diagram, ROC Score, BSS(Brier Skill Score) 등을 서비스하고 있다. 공식 서비스되는 검증 콘텐츠의 구성 및 제공 항목은 기존과 동일한 체계를 유지하고 있다.

2025년 9월 개선된 고해상도 검증시스템을 실시간 시범 운영하여 1~3개월 선행 예측자료에 대한 검증 결과를 비교 분석하였다. 해당 비교는 시스템 전환에 따른 차이를 확인하기 위한 단일 사례 분석이며, 저해상도와 고해상도 검증에 활용된 관측자료 구성의 차이가 존재하므로 결과의 직접적인 성능 우위 판정이나 일반화 결론 도출에는 주의가 필요하다.

여름철(6-8월) 기온·강수 실시간 단정예측 검증 결과(Figure 4.30; Figure 4.31), 기온의 ACC가 대부분 지역에서 향상되고 RMSE는 감소하는 경향을 보인다. 강수의 경우 전지구 ACC는 증가하나 지역별 편차가 크고 RMSE가 증가하는 경향이 나타난다.

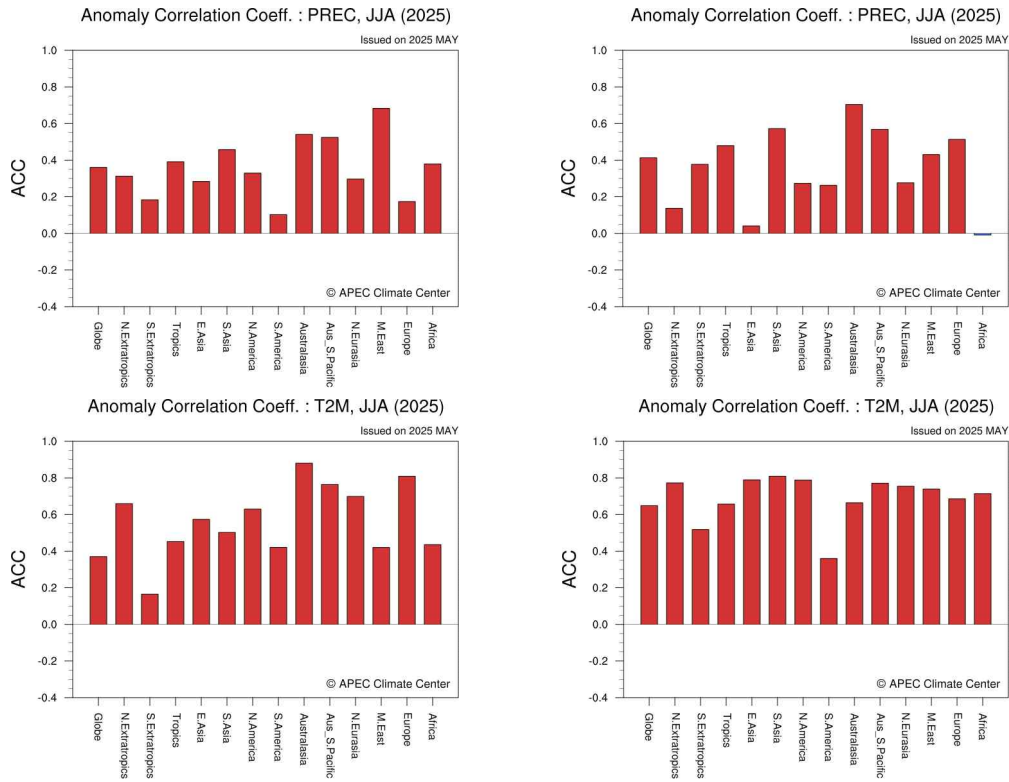


Figure 4.30. Regional ACC of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right).




Figure 4.31. Regional RMSE of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right).

여름철 해수면 온도 지수 실시간 검증 결과(Figure 4.32), 고해상도와 저해상도 검증 결과는 유사한 수준을 보이지만, 고해상도 검증에는 예측모델 수가 확대 적용되었다는 점에서 해석에 주의가 필요하다.

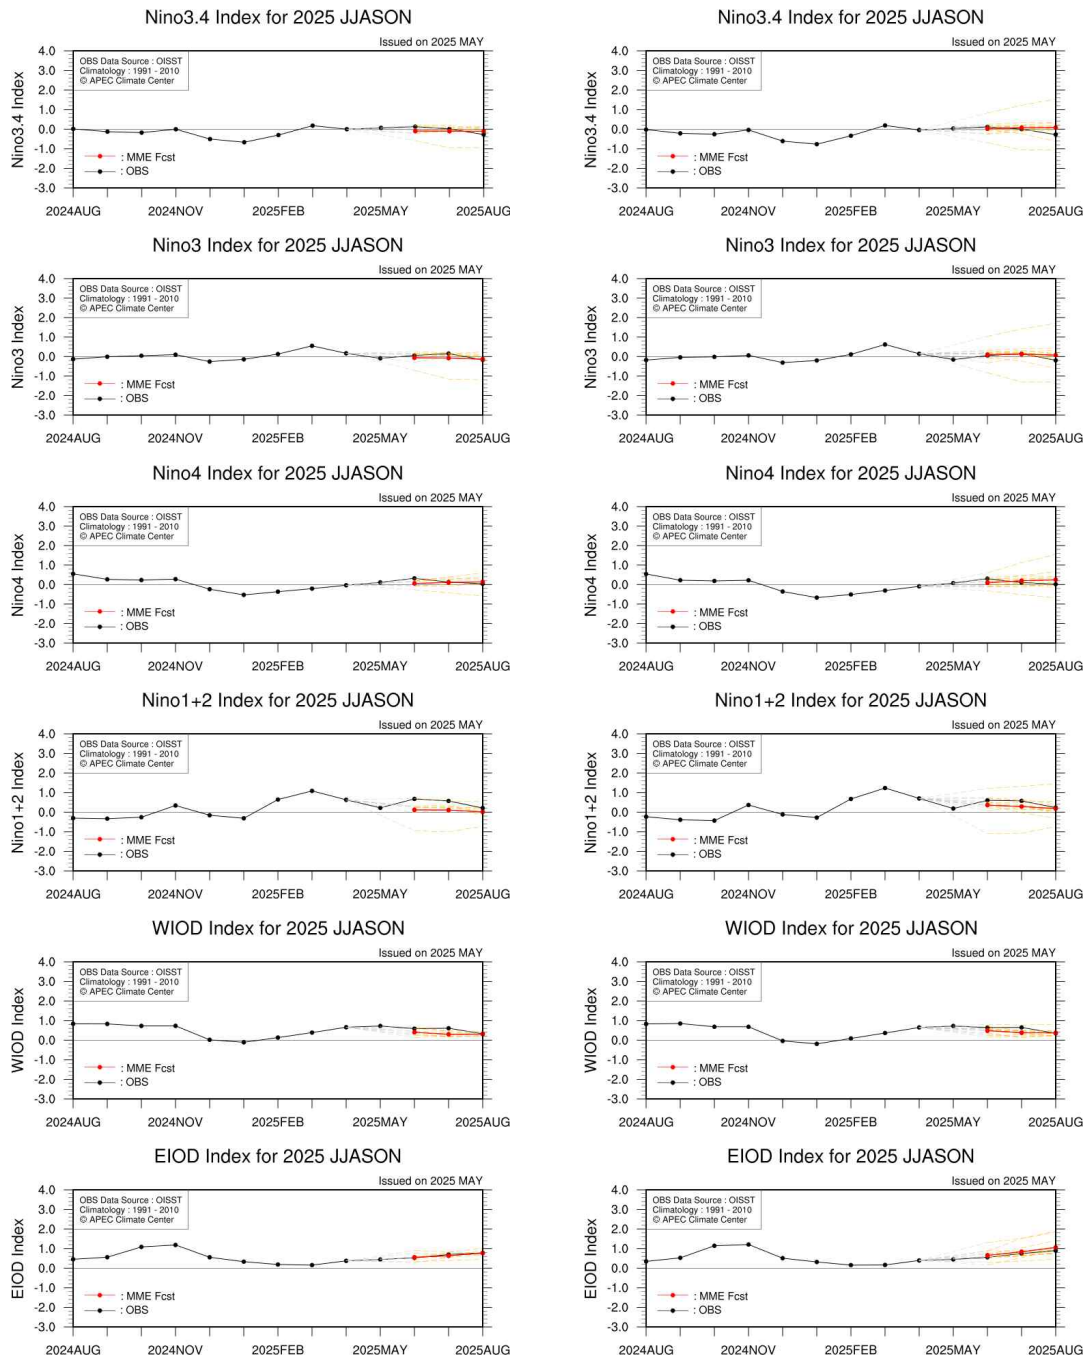


Figure 4.32. Tropical SST indices for 2025 JJASON real-time forecasts (low-resolution: left, high-resolution: right). Red = MME, black = observations, orange dotted = individual models.

여름철 기온·강수 실시간 확률예측 검증 결과(Figure 4.33; figure 4.34), 기온의 ROC Score 및 RPSS는 전반적으로 증가하고, 강수 RPSS는 동아시아를 제외한 대부분 지역에서 증가한다.

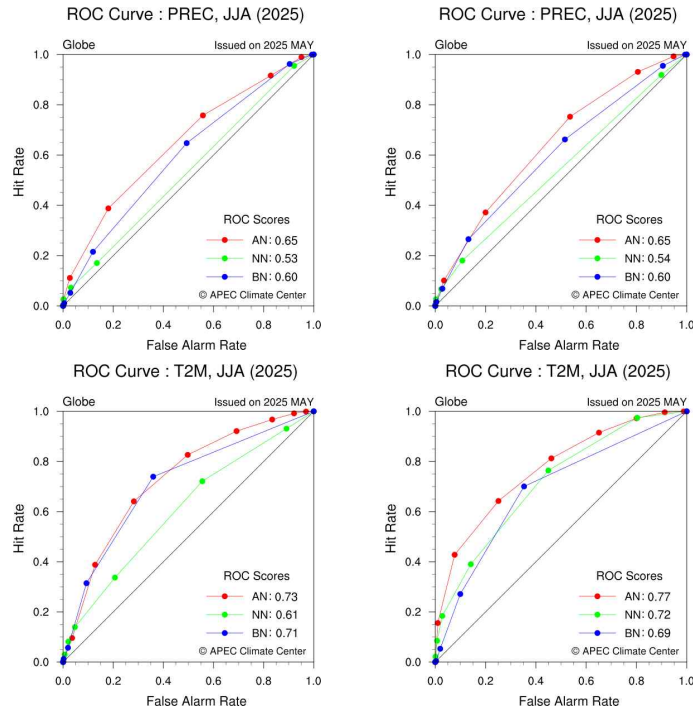


Figure 4.33. Global ROC curve of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right).

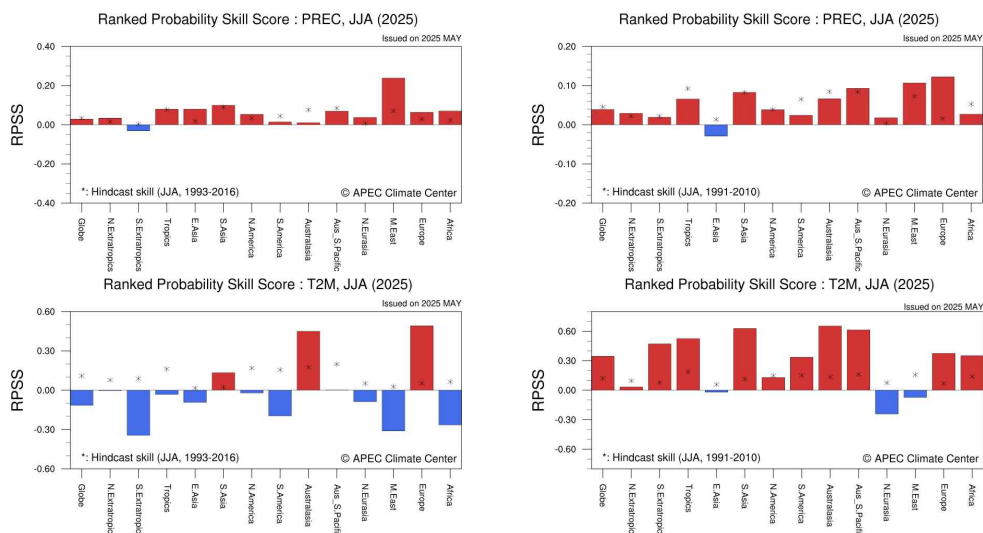


Figure 4.34. Regional RPSS of precipitation (top) and T2M (bottom) for 2025 JJA real-time forecasts: low-resolution (left) vs. high-resolution (right).

가을철(10-12월) 과거기후 단정예측 검증 결과(Figure 4.35; Figure 4.36), 기온 및 강수 ACC의 차이는 크지 않다. 또한, 강수 MSSS는 극지역·해양에서 향상되고, 기온 MSSS는 열대 서태평양에서 감소하는 반면 동태평양에서 증가하는 양상이 나타난다.

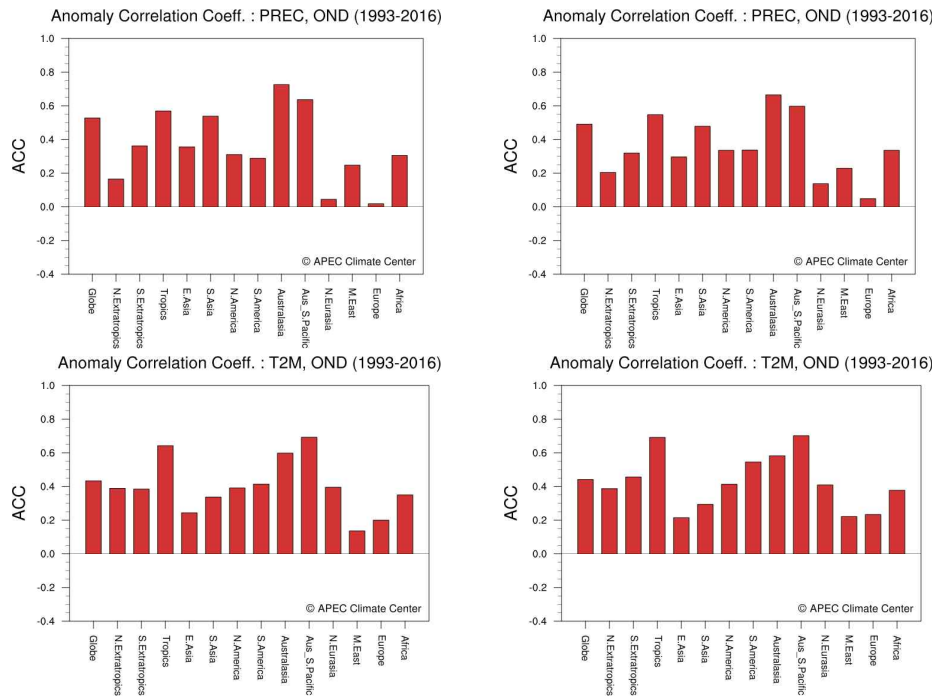


Figure 4.35. Regional ACC of precipitation (top) and T2M (bottom) for OND hindcasts: low-resolution (left) vs. high-resolution (right).

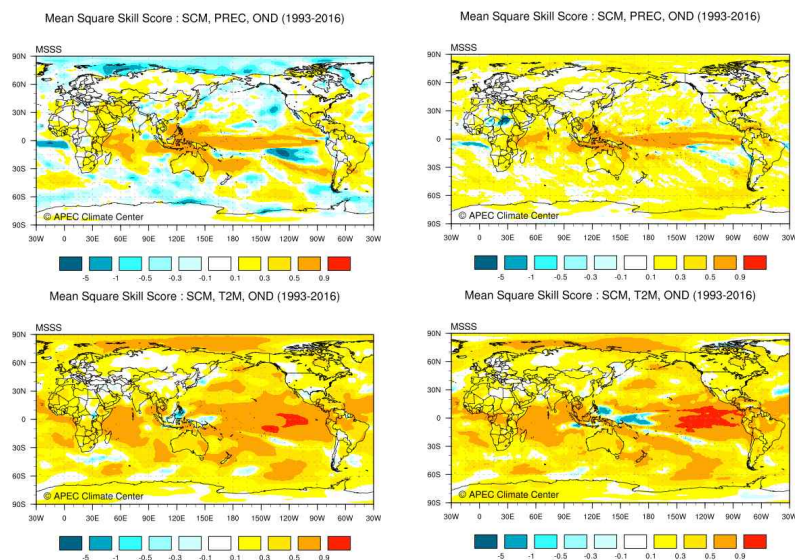


Figure 4.36. Global MSSS maps of precipitation (top) and T2M (bottom) for OND hindcasts: low-resolution (left) vs. high-resolution (right).

가을철 과거기후 확률예측 검증 결과(Figure 4.37), 강수 ROC Score는 극지역과 해양에서 높으나 남태평양 일부 지역에서 감소하고, 기온 ROC Score 및 BSS는 뚜렷한 차이가 나타나지 않는다.

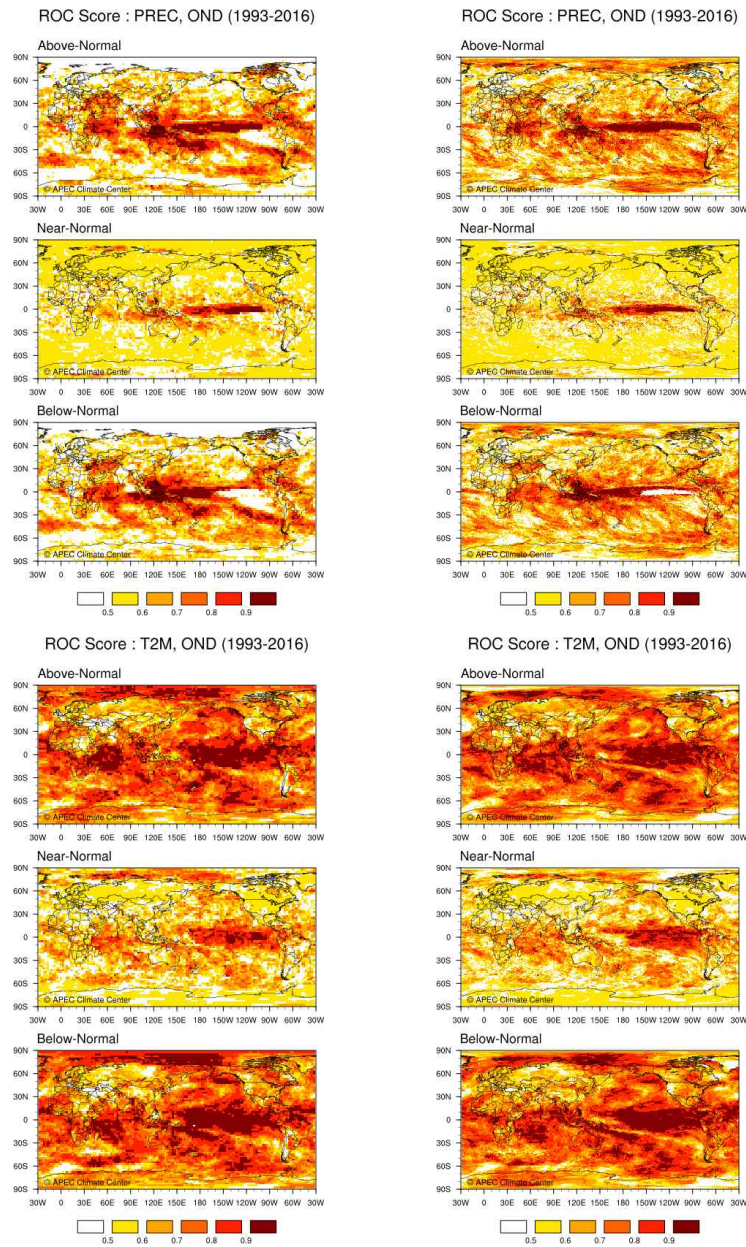


Figure 4.37. Same as Figure 4.41, but for ROC Score.

저해상도 검증 대비 고해상도 검증 결과의 차이를 종합해보면, 여름철 기온 예측 성능은 전반적으로 향상된 반면 강수는 지역적 차이가 크게 나타나며, 가을철의 경우 강수 예측은 극지방과 해양에서 뚜렷한 향상을 보였으나 기온 예측 성능은 큰 차이가 없는 것으로 확인된다. 향후 예측자료 품질 향상 및 사용자 활용성 제고를 위해 추가적인 분석과 검증기법

고도화를 지속적으로 추진할 예정이다.

4.1.3.5 ENSO 예측지수 개선사항 검토

현재, APCC는 전통적인 Niño-3.4 index 기반 ENSO 감시 및 예측 정보를 생산·제공하고 있다. 이 지수는 Niño-3.4 지역(5°N-5°S, 170°W-120°W)의 평균 해수면 온도(sst)가 기후값에서 벗어난 정도를 정의한 지수이며(Barnston et al., 1997), 오랜 기간 ENSO 진단의 핵심 지표로 활용되어 왔다. 그러나 전 지구적 온난화로 인한 열대 해양의 배경장(background state) 변화 때문에, 기존 지수는 ENSO 강도를 과대 또는 왜곡할 수 있다는 문제가 제기되고 있다. 이에 대응하여, van Oldenborgh et al.(2021)은 열대 해양의 온난화 추세를 제거하여 ENSO의 상대적 강도를 정규화하는 ‘Relative Niño index’를 제안하였다. 해당 연구는 이 상대적 지수가 ENSO 변동성과 원격상관 대기 반응을 보다 일관성 있게 설명함을 보여준다.

최근, L’Heureux et al.(2024)은 Relative Niño-3.4 index를 실시간 감시 및 예측 시스템에 적용 가능한 형태로 재정의하고, 현업 운영 환경에서의 안정적 적용 가능성을 검증하였다. 이 연구는 기존의 단순 smoothing 및 선형추세 제거 방식은 물리적 근거가 부족하고 미래 외삽시 불확실성이 크다고 지적하였다. 새로운 지수는 Niño-3.4 anomaly에서 열대 평균 SST anomaly를 제거하고, Niño-3.4 anomaly의 분산과 일치하도록 스케일링 계수를 적용하여 상대적 강도를 산출하는 방식으로 구성된다. 본 연구에서는 L’Heureux et al.(2024)의 방법론을 적용하여 ENSO 감시 및 예측 지수를 산출하고, 그 적용 결과를 제시하였다.

Relative Niño index의 도입 필요성은 연구 분야뿐만 아니라 현업 예보기관에서도 공식적으로 인정되기 시작하였다. 미국 NOAA 기후예측센터(CPC)는 Relative Oceanic Niño Index(RONI)를 월별·계절별 ASCII 형식의 감시자료로 제공하고 있으며, 호주기상청(BOM)은 2025년 9월부터 ENSO 감시 체계에 Relative Niño index를 공식적으로 포함하여 Niño1-4 및 Niño-3.4 영역에 대해 주별 평균된 자료를 매주 제공해 준다. 또한, 월별 Relative Niño-3 index 또는 Relative Niño-3.4 index가 +0.8°C 이상 지속되면 엘니뇨, -0.8°C 이하로 지속되면 라니냐의 전형적인 조건으로 판단한다. ECMWF 역시 상대적 지수 접근을 활용한 ENSO 평가 연구를 확대하고 있어(L’Heureux et al., 2024), Relative Niño index가 향후 ENSO 표준 지표로 자리잡을 가능성이 높음을 시사한다.

본 연구의 분석 결과에서도 Relative Niño index의 필요성을 보여준다. Figure 4.38는 지난 20년 이동평균된 SOI와 Niño-3.4 index 간 표준편차 비율 변화를 비교한 결과로, 노란색 실선은 Niño-3.4가 양(+) 상태(엘니뇨), 파란색 실선은 음(-) 상태(라니냐)일 때의 결과이며, 검은 점선은 두 지수 간 회귀계수를 보여준다. 두 지수의 선형관계는 크게 변하지 않지만 2000년대 이후 라니냐 상태일 때 SOI의 상대적 진폭이 증가하고, 엘니뇨 상태일 때는 감소하는 비대칭성이 뚜렷해졌다. 즉, 약한 라니냐에서도 실제 대기 반응이 크게 나타나고, 강한 엘니뇨에서도 과거만큼의 대기 반응이 나타나지 않는 경향이 확인되었다. 이는 ENSO-대기 상호작용이 단순 Niño-3.4 절대값만으로 설명되기 어렵고, 상대적 강도 개념의 ENSO 평가가 필요함을 의미한다.




Figure 4.38. 20-year sliding standard deviation ratio and regression slope between SOI and NINO3.4. Yellow lines indicate periods when NINO3.4 is positive, and blue lines indicate periods when NINO3.4 is negative.

실제 사례 분석에서도 이러한 결과가 재확인되었다. Figure 4.39에서 2023/24 겨울은 전통 Niño-3.4 기준으로 +1.5°C 이상의 강한 엘니뇨로 판정되지만, Relative Niño-3.4 index는 더 약한 강도를 나타냈다. 반면 2024/25에는 Niño-3.4 index는 중립에 가까우나 Relative Niño-3.4 index는 뚜렷한 라니냐 상태를 보였다.




Figure 4.39. Observed Oceanic Niño Index (Dotted Line) and Relative ONI (Solid Line) from 2023 DJF to 2025 JAS.

이를 검증하기 위해 9-10월 라니냐 해 합성장과 실제 2024년 관측 편차장을 비교한 결과(Figure 4.40), 2024년 9-10월 열대 서태평양 고수온 및 강수 증가와 우리나라부터 일본 동쪽 해역 주변으로 고기압성 순환이 강화되는 등 전형적인 라니냐 원격상관 패턴이 확인되었다. 이와 함께 우리나라도 라니냐 시기에 일반적으로 관측되는 강수량 증가(9월 77.4%tile, 10월 84%tile)와 기온 상승(9월 +4.2°C, 10월 +1.8°C)이 뚜렷하게 나타났다.

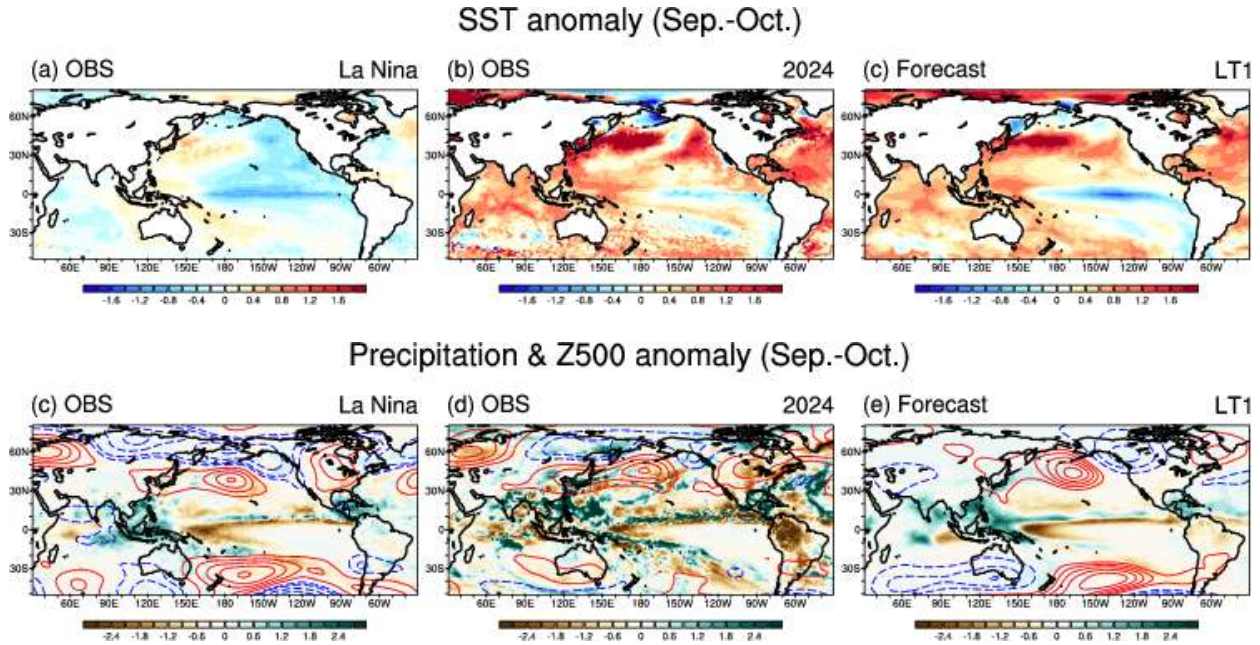


Figure 4.40. September–October anomaly maps of SST (top), precipitation, and Z500 (bottom). Panels show La Niña conditions (left), 2024 observations (center), and 1-month lead forecasts (right).

예측 사례에서도 유사한 결과가 도출되었다. 2024년 8월 초기화 실시간 예측(Figure 4.41)에서 전통 Niño-3.4 index는 약한 라니냐를 유지하지만, Relative Niño-3.4 index는 보다 강한 라니냐를 예측하였고, 실제 관측된 SST·대기 반응(Figure 4.40)과 매우 유사한 예측 패턴을 보였다.




Figure 4.41. Observed (gray) and forecast (green) Niño-3.4 index (dotted) and relative Niño-3.4 index (solid).

Figure 4.42는 1992년부터 2010년까지 과거기후예측(hindcast)의 Relative Niño-3.4 index(막대)와 Niño-3.4 index(실선)을 비교하여 나타낸 것이다. 예측지수는 1개월 선행 예측 결과로써, 1991-2010년을 기후값 기준 기간으로 산출하였다. 전반적으로 Relative Niño-3.4 index에서 음의 값이 더 크게 나타나는 경향이 보인다. 특히, 세 해의 여름철 라니냐 상태가 지속되었던 triple-dip 라니냐(1998-2001년), 호주 동부의 기록적인 폭우 및 홍수를 유발한 2010/11 라니냐 및 double-dip 라니냐(2010-12) 시기에 Relative Niño-3.4 index가 보다 더 큰 진폭을 보인다. 이는 온난화 신호 제거를 통해 ENSO 강도의 상대적 변동을 반영하는 Relative Niño-3.4 index가 보다 실효적 지표임을 보여준다.




Figure 4.42. Hindcast relative Niño-3.4 index(bar) and Niño-3.4 index(solid-line) for the period 1992-2010.

종합하면, 전통적인 Niño-3.4 index는 warming bias 및 배경장 변동에 민감하며, 온난화 조건에서 ENSO 강도 및 영향 평가에서는 한계가 존재한다. 반면 Relative Niño-3.4 index는 물리적·실용적 측면에서 더 견고한 대안이며, ENSO 감시 및 예측 서비스의 정확성과 활용도 향상에 기여할 것으로 기대된다. 따라서 APCC는 향후 실시간 Relative Niño-3.4 index 기반 감시 및 예측 정보를 공식 서비스로 생산하는 방향으로 발전시키는 것을 목표로 하고자 한다.

4.2. 기후감시시스템

지난 기후예측정보의 예측성능을 검증하고, 최근 기후상태의 변동 추이를 제때 감시하고 향후 기후예측정보의 생산에 제대로 활용하기 위해서는 매월 정기적으로 최근 기후를 감시하고 분석할 필요가 있다. 이에 아태기후센터에서는 자동화된 기후감시시스템(Climate Monitoring System, CMS)을 매달 운영하여 생산된 최근 기후감시자료를 아태기후센터 국·영문 홈페이지에 게재 및 기후전망에 포함하고 있다. CMS를 통해서 매월 생산되는 콘텐츠는 Table 4.11과 같다.

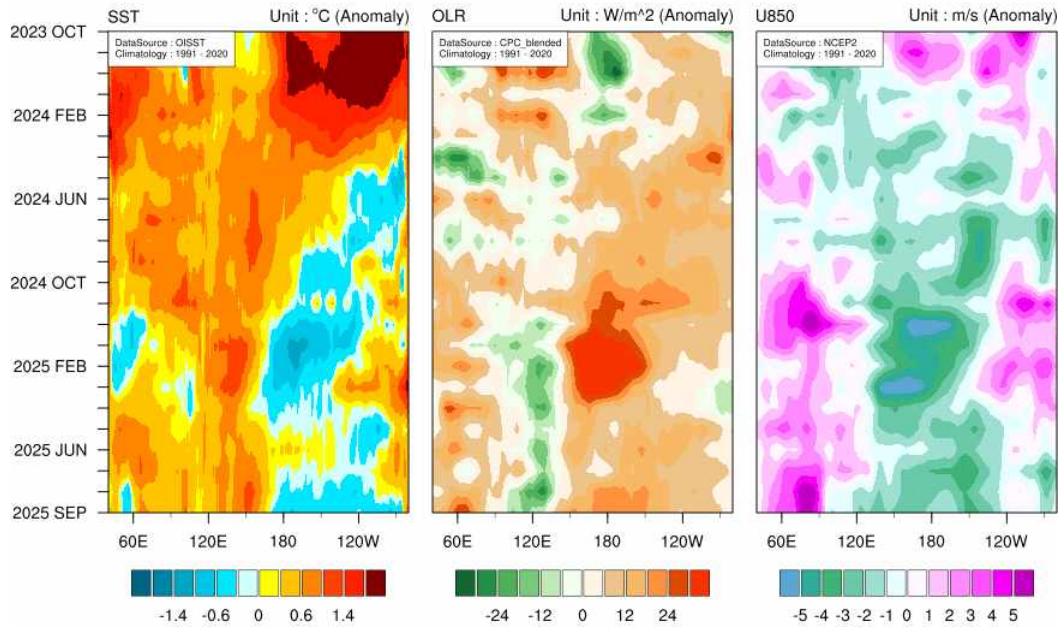
Table 4.11. Contents of CMS and related services.

	콘텐츠	관련 서비스
기후지수	<ul style="list-style-type: none"> - 월 기후지수 - 대상: 태평양·인도양·대서양 해수면 온도 지수 11종, 대기 지수 8종, 몬순 지수 5종 	(국문 홈페이지) 기후현황 - 기후지수 (영문 홈페이지) Climate Monitoring - Climate Indices
기후분석장	<ul style="list-style-type: none"> - 월 평균 기후분석장 - 지역: 전지구, 동아시아 - 변수: 850hPa 기온, 지표 기온, 500hPa 지위고도, 상향장파복사, 강수, 해수면온도, 850hPa 동서풍 	(국문 홈페이지) 메인 - 기후현황 (영문 홈페이지) 메인 - Climate Monitoring (국문 기후전망) 최근 기후 상태 (영문 기후전망) Current Climate Conditions
	<ul style="list-style-type: none"> - 월 평균 과거 2년 기후분석장 및 해수면온도 전체·편차 - 지역: 적도(5N-5S 평균) - 변수: 해수면온도, 상향장파복사, 850hPa 동서풍 	(국문 기후전망) 최근 기후 상태 (영문 기후전망) Current Climate Conditions
가뭄지수	<ul style="list-style-type: none"> - 월 가뭄지수 	(국문 홈페이지) 기후현황 - 가뭄지수 (영문 홈페이지) Climate Monitoring - Global Drought

2025년 당해 연도에는 다음의 4가지 이슈가 있었고, 그에 대한 장애를 다음과 같이 조치하였다. 특히, 이슈 (4)의 NECP2 자료 미갱신은 미국 내 불안정한 정세 및 shutdown 사태에 기인하며, 국·영문 기후전망에 예기치 못한 영향을 주어 NCEP1 자료를 활용하여 생산할 수 있도록 임시방편으로 우회 조치하였다. 양 자료간의 최근 주요 기후상태가 크게 다르지 않음 확인하고, 변경된 자료 출처를 명기하여 기후전망에 포함하였다 (Figure 4.1 참조).

- (1) 월기후지수의 이상치 발생 및 기준을 수동 수정을 자동화
- (2) ONI 전월값의 undefined value에 원인 파악 및 매뉴얼 작성
- (3) 관측자료 상시 미갱신으로 인해 CMS 운영일 변경(매월 10일→12일) 및 매뉴얼 반영
- (4) NCEP2 미갱신으로 인한 기후분석장 미생산 및 NCEP1으로 임시 우회조치

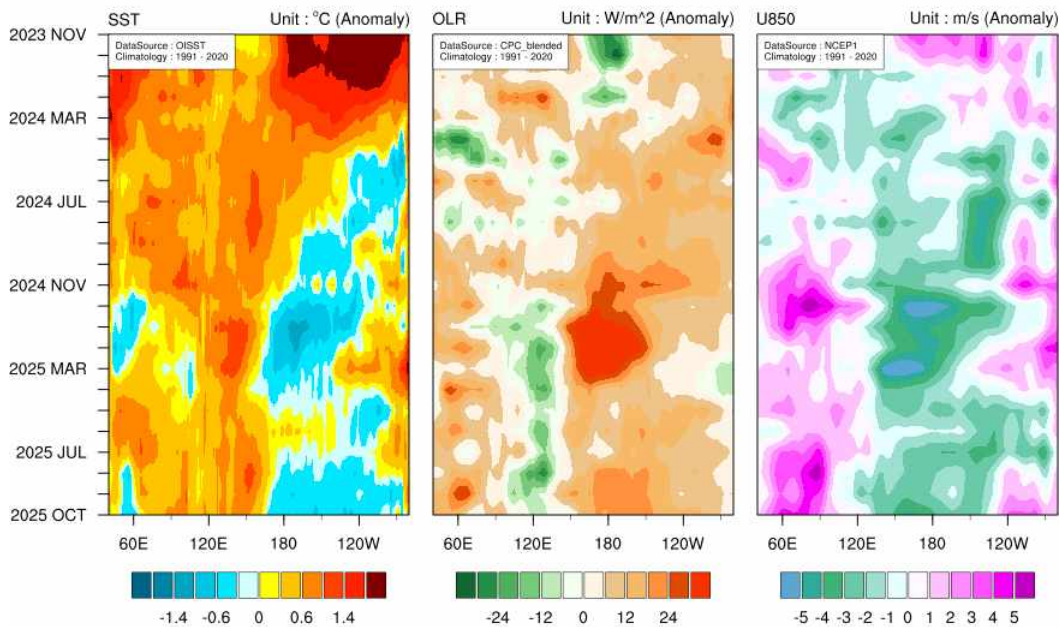
Sea Surface Temperature / Outgoing Longwave Radiation / U-wind at 850hPa



* Anomalies are averaged between 5°S and 5°N.

© APEC Climate Center

Sea Surface Temperature / Outgoing Longwave Radiation / U-wind at 850hPa



* Anomalies are averaged between 5°S and 5°N.

© APEC Climate Center

Figure 4.43. Hovmöller diagrams of SST, OLR, U850 issued in Oct (upper) and Nov 2025 (bottom).

4.3. 기후전망(Climate Outlook) 생산 자동화

4.3.1. 서론

기후전망(Climate Outlook)은 계절 규모의 변동성을 이해하고 미래의 기상·기후 위험을 대비하기 위한 핵심 자료로 활용된다. 다양한 국가와 지역의 수요자들은 Outlook을 통해 향후 수개월 동안의 기온 및 강수 변화, ENSO 상황, 불확실성 정보를 종합적으로 이해하고 의사결정에 반영한다. 이러한 중요성에도 불구하고, Outlook 생산 과정은 오랜 기간 동안 높은 수작업 의존도를 기반으로 운영되어 왔다. 이는 전문 인력의 판단과 경험에 기반한 정성적 요소가 많다는 장점이 있으나, 동시에 시간적 부담과 일관성 저하라는 구조적 문제를 낳아왔다.

우선, Outlook 제작 과정은 여러 단계의 분석과 편집 절차가 연속적으로 연결된 복합적 작업이다. 각 단계에서 서로 다른 데이터 소스와 소프트웨어 환경을 오가야 하고, 신호 탐지, 지역 매칭, 문장 구성, 문서 편집 등 상당 부분이 사람의 수작업에 의존한다. 이러한 구조는 매월 반복되는 생산 주기에서 담당자에게 큰 시간적 부담을 주며, 때로는 수 시간에 걸친 집중적인 노동을 요구한다. 기본적인 분석 과정뿐 아니라 텍스트 작성과 문서 편집까지 모두 수작업으로 수행될 경우, 전체적인 제작 속도는 담당자의 개인 역량과 여건에 크게 좌우될 수밖에 없다.

둘째, 담당자 의존도가 높으면 결과물의 일관성을 유지하기 어렵다. Outlook에 포함되는 신호 판단이나 지역 선택은 담당자의 경험, 선호, 지리적 이해에 따라 달라질 가능성이 있다. 같은 데이터라도 서술 방식이나 강조점이 매번 달라지면 수요자는 Outlook을 장기적으로 비교·활용하기 어렵게 된다. 지역별 기후 리스크와 예측 신뢰도를 고려해야 하는 기관 입장에서도 문장 구조나 서술 논리의 일관성 부족은 불편을 초래하며, 때로는 혼란을 야기하기도 한다. Outlook은 정보 제공 서비스인 만큼, 재현성과 객관성이 중요한데 수작업 중심의 체계에서는 이를 보장하기 어렵다.

셋째, 조직 운영 측면에서도 한 개인의 전문성에 과도하게 의존하는 구조는 안정성과 지속 가능성을 저해한다. 기상·기후 분야의 전문 인력은 이동이 잦고, 교체가 발생할 수밖에 없다. 특정 담당자가 부재하거나 다른 업무로 이동하게 되는 경우, Outlook 생산 체계가 흔들리거나 품질이 저하될 위험이 있다. 장기적 관점에서 조직은 특정 개인의 암묵지에 의존하지 않고, 표준화된 절차와 자동화된 시스템을 통해 안정적인 서비스를 제공할 수 있어야 한다.

이 같은 문제를 해결하기 위해서는 Outlook 생산 전반을 포괄하는 자동화 체계 구축이 필수적이다. 자동화는 단순한 시간 절감을 넘어, 정보 생산의 정확성·일관성·재현성을 확보하기 위한 기반이 된다. 신호 탐지부터 텍스트 생성, 문서화에 이르는 전체 과정이 규칙 기반 처리와 데이터 기반 모델에 의해 작동하게 되면, 사람에 의한 편차가 줄어들고 결과물의 품질을 일정 수준 이상으로 유지할 수 있다. 특히 기후정보는 공공성과 책임성이 강조되는 분야이기 때문에, 이러한 자동화는 장기적으로 기관 신뢰도 향상에도 기여한다.

또한 최근에는 대규모 언어모델(LLM)의 발전으로, 과거 사람이 직접 작성하던 서술적 설명을 일정 수준 정량화된 정보로부터 자동으로 생성하는 것 또한 가능해지고 있다. 이는 기존 Outlook 생산 과정에서 가장 시간 소모가 크고 개인 역량에 의존하던 문장 작성 단계의 부담

을 획기적으로 낮출 수 있다. 동시에 LLM 기반 자동화는 서술 구조의 통일성과 문장 품질의 안정성을 높여, 서비스 제공자가 전달하고자 하는 메시지를 명료하게 정리해주는 역할을 한다. 이러한 기술의 적용은 기후정보 서비스가 보다 현대적이고 효율적인 형태로 진화하는 데 중요한 전환점이 된다.

Outlook 생산 자동화는 단순히 내부 업무 효율화라는 관점에만 머무르지 않는다. 예측 정보가 보다 안정적인 품질로 빠르게 생산될 수 있다면, 기관은 수요자와의 상호작용을 더욱 강화하고 새로운 콘텐츠 개발에 시간을 투자할 수 있다. 이는 나아가 기후서비스 제공 역량을 전반을 향상시키며, 지역사회와 파트너 기관의 의사결정 지원 기능 강화로 이어진다. 자동화된 시스템은 사람의 판단을 대체하는 것이 아니라, 반복적이고 구조화된 작업을 기술에 위임함으로써 전문가가 더 높은 수준의 분석과 해석에 집중할 수 있도록 돕는 역할을 한다.

결국 Outlook 자동화는 지속가능한 기후서비스 제공의 필수적인 요소이다. 정보 생산 체계를 표준화하고 자동화함으로써, 기관은 담당자 교체나 업무 환경 변화에도 흔들리지 않는 안정성을 확보할 수 있다. 동시에 예측정보의 전달 속도와 품질이 개선되어 수요자는 더 신뢰할 수 있는 데이터를 적시에 받아볼 수 있다. 본 보고서는 이러한 문제의식과 필요성을 바탕으로 설계한 자동화 시스템의 개념적 구조와 구축 과정, 구성 요소별 구현 전략을 제시하며, 기후서비스의 효율성과 일관성을 향상시키기 위한 하나의 모범 사례를 제시하고자 한다.

4.3.2. 기존 Outlook 분석 및 자동화 설계 방향

APCC의 기후전망은 오랜 기간 운영하면서 문서 구조와 작성 방식이 점차 정형화되어 왔다. 전지구 영문 및 국문 Outlook, Pacific Islands Outlook은 각각 다른 지역을 다루지만, 세 문서를 자세히 보면 기본 골격이 같고 서술 방식도 비슷한 패턴을 따른다는 걸 알 수 있다. 이런 일관성 덕분에 안정적으로 기후정보를 전달할 수 있었다. 하지만 매달 이 문서들을 손으로 작성하다 보니 담당자에게 시간 부담이 크고, 작성자마다 표현이 조금씩 달라지는 문제도 있었다. 자동화를 만들려면 먼저 문서가 어떤 구조로 되어 있는지, 어떤 규칙으로 작성되는지, 어느 부분을 자동화할 수 있는지를 살펴봐야 한다. 이번 장에서는 세 Outlook을 분석해서 구조적 특성을 정리하고, 자동화가 가능한 반복 요소들을 찾아본다.

4.3.2.1. Outlook 문서의 구성 방식

(1) Summary의 구조와 역할

Summary는 Outlook의 핵심이다. 세 문서 모두 맨 앞에 배치되어 있고, 해당 시즌의 예측 내용을 가장 간단하게 요약한다. 특히 ENSO 상태는 Summary에서 제일 먼저 다뤄진다. ENSO Alert 단계(예: WATCH, ALERT), 앞으로 강해질지 약해질지, Niño3.4 지수 경향 등이 항상 비슷한 방식으로 설명된다. 기온과 강수 전망 요약도 정해진 틀을 따른다. 예측 확률이 높으면 “strongly enhanced probability for above normal“, 좀 낮으면 “enhanced probability for“ 또는 “a tendency for“ 같은 표현이 반복된다. 계절명이나 지역명, 확률값만 바뀔 뿐 문장 구조는 거의 똑같다. 이런 반복성 때문에 Summary는 자동화하기 쉬운 부분이다.

(2) Climate Monitoring, ENSO 전망, Climate Forecast의 공통점

Climate Monitoring은 Global Outlook과 Korean Outlook에서는 문서 두세 번째 섹션에 나온다. 최근 한 달이나 한 계절 동안 관측된 기후 변화를 요약하는 부분이다. Pacific Outlook에서는 생략되어 있다. 이 부분 역시 관측 분석 방식이 매우 정형화되어 있다. SST anomaly 지도는 항상 같은 색깔과 투영법으로 나오고, 설명도 “above normal SST anomalies were observed“, “negative anomalies extended across“ 같은 비슷한 문장으로 반복된다. 관측된 이상 현상은 지역별로 나뉘어서 간단히 요약하는데, 자료가 바뀌어도 서술 패턴은 유사하게 유지된다.

ENSO 전망 섹션은 Outlook 중에서 구조가 가장 안정적이다. ENSO Alert을 제시하고, 예측된 SST anomaly 지도를 설명하고, Niño3.4 지수 전망과 ENSO phase 확률을 보여주는 순서가 절대 안 바뀐다. 서술 방식도 일정하다. Niño3.4 전망은 항상 “Niño3.4 index is expected to…”로 시작하고, ENSO phase 확률은 가장 높은 확률의 상태를 중심으로 설명하며, 필요하면 변화가능성(transition이나 weakening)을 덧붙인다. 이런 규칙성 때문에 ENSO 섹션은 데이터만 넣으면 문장이 자동으로 만들어지기 좋은 구조다.

Climate Forecast 섹션은 기온·강수 예측을 사용자 입장에서 해석하는 문장들이 많아서 텍스트가 가장 많은 부분이다. 하지만 자세히 보면 여기도 신호 강도, 방향, 지역이라는 세 요소의 조합으로 일정한 틀을 반복한다. 확률값이 70% 이상이면 “strongly enhanced probability for above/below normal“, 50~70%면 “enhanced probability for“, 40~50%면 “a tendency for“라는 표현을 쓴다. 지역 표현도 제한된 목록에서 계속 재사용된다. 글로벌 Outlook에서는 Arctic, East Africa, northern North Pacific 같은 큰 단위가 자주 나오고, Pacific Outlook에서는 Micronesia, Melanesia, Polynesia가 반복된다. 문장 구조는 안 바뀌고, 바뀌는 건 지역명과 신호 강도, 방향뿐이다.

예측 결과를 보여주는 그림들도 형식이 일정하다. MME 예측장은 “Temperature at 2m for SEASON“, “Precipitation for SEASON“ 같은 고정된 제목과 같은 범례를 쓰고, 계절명 표기(MAMJJA, NDJ-FMA 등)도 전체적으로 동일하다. 이런 요소들은 LaTeX 템플릿으로 자동 편집하기에 딱 맞다.

4.3.2.2. Outlook 작성 규칙의 언어 구조

세 Outlook의 문장들을 분석해보면 언어 구성도 명확한 패턴이 있다. 모든 Outlook은 현재 상태→향후 전망→변화 방향→확률 판단→지역 범위 순서로 설명한다. 이런 흐름은 특히 ENSO 섹션에서 뚜렷하고, 기온·강수 전망에서도 똑같이 나타난다. 사용된 문장은 사실상 “데이터를 채워넣는 템플릿“ 형태다. ENSO 전망에서 Niño3.4 설명은 언제나 “Niño3.4 index is expected to gradually increase/decrease…” 형태로 반복된다. Climate Forecast에서는 “is predicted for [region]“ 구조가 계속 나오고, 바뀌는 건 지역명과 확률 강도뿐이다. Outlook에서 쓰는 지역명은 문서마다 약간 다르지만 그 목록이 계속 재사용된다. 이걸 지역명을 자동으로 분류하거나 선택하는 알고리즘을 만들 때 매우 유리하다. 지역 표현이 무한히 늘어나지 않고 정해진 범주 안에서 돌아가기 때문이다. 지역 표현 자체가 매달 새로 만드는 것이 아니라 정해진 용어 체계 안에서 반복되는 구조라서, 자동화할 때 이 목록을 기반으로 신호와 지역을 연결하는 체계를

만들 수 있다. 또한 Outlook은 무엇보다 “신호 “ 중심의 문서다. 지도의 확률 패턴에서 중요한 신호만 뽑아내고, 그 신호를 대표하는 한두 개 지역명을 골라서 문장으로 만드는 방식이다. 이 작업이 지금까지는 사람의 직관으로 이뤄져 왔지만, 실제로는 확률값, 면적, 패턴 연속성 같은 정량적 기준으로 바꿀 수 있는 구조다. 그래서 자동화할 때 신호 검출 규칙이 핵심이 된다.

4.3.2.3. Outlook 자동화를 위한 설계 방향

Outlook 문서의 구성과 서술 방식은 겉보기엔 사람이 직접 판단한 것처럼 보이지만, 안을 들여다보면 일관된 규칙과 반복이 있다. 이 규칙성을 바탕으로 자동화를 수행하려면 해결해야 할 중요한 요소가 세 가지 있다. 첫 번째는 지도의 확률 예측에서 의미 있는 신호를 정량적으로 뽑아내는 규칙을 만드는 것이다. 이걸 담당자가 수년간 해온 주관적인 시각 판단 과정을 알고리즘으로 바꾸는 작업이다. 확률 절댓값뿐 아니라 신호의 공간 연속성, 면적, 강도 등을 체계적으로 고려해야 한다. 특정 확률 기준으로 신호를 분류하고, 작은 노이즈를 제거하는 과정까지 포함해야 한다.

두 번째는 지역 매칭 체계를 만드는 것이다. Outlook 문장의 핵심은 결국 “어디에서 어떤 신호가 나타나는가“를 설명하는 것이어서, 신호와 지역명을 연결하는 과정이 매우 중요하다. 기존 Outlook에서 반복적으로 쓰는 지역명을 정리하고, 이를 바탕으로 지역 mask를 만들어서 신호가 어느 지역에 해당하는지 정량적으로 판단하는 알고리즘을 만들어야 한다. 지역 매칭은 단순히 공간 겹침만 계산하는 게 아니라, 신호 중심과 지역 중심을 비교하거나 여러 지역에 걸쳐 있을 때 우선순위를 정하는 등 다양한 상황을 다룰 수 있어야 한다.

세 번째는 자연어 생성 체계를 만드는 것이다. Outlook 문장 표현은 규칙적이지만, 규칙만으로는 미세 조정이 어려운 경우가 많다. 이런 점에서 경량 LLM을 쓰면 정형성과 유연성 사이에서 균형을 잘 잡을 수 있다. LLM은 확률 신호 해석 결과와 지역 정보를 받아서 Outlook 문체를 유지하면서도 자연스러운 문장을 만들 수 있고, 특정 표현을 강조하거나 불필요한 부분을 줄이는 세밀한 조정도 가능하다. 이를 위해 프롬프트 구조를 Outlook 기존 문체에 맞게 다듬는 작업이 필요하며, 이게 앞으로 자동화에서 중요한 역할을 한다.

마지막으로 편집 및 출력 자동화를 위한 LaTeX 기반 템플릿 설계도 필수이다. 앞서 말한 것처럼 Outlook은 문서 구성과 그림 배치가 고정되어 있어서, LaTeX를 쓰면 문서 편집 시간을 획기적으로 줄일 수 있다. 텍스트와 이미지 파일만 정해진 위치에 넣으면 완성된 문서가 자동으로 만들어지는 구조가 된다. 이것은 Outlook 자동화의 마지막 단계이면서 완성도를 결정하는 과정이다.

정리하면, 기존 Outlook 문서를 분석한 결과 문서 생성 과정이 단순한 주관적 판단이 아니라 규칙 기반 해석과 반복적인 서술로 이뤄져 왔다는 것을 확인했다. 이런 구조적·언어적 규칙성은 자동화를 가능하게 할 뿐 아니라, 자동화된 결과물이 기존 Outlook의 형식과 논리에서 벗어나지 않게 해주는 기반이 된다. 이번 장에서 찾아낸 요소들은 다음 장에서 다룰 신호 검출 규칙과 자동 문장 생성 전략의 출발점이 된다.

4.3.3. 지역 추출 및 masking

Outlook 자동화 시스템을 만들 때, 예측 신호가 나타나는 지역을 일관되게 정의하고 자동으로 판정하는 지역 체계를 만드는 것은 중요한 작업 중 하나다. 기존 Outlook 문서에서는 지역 선택이 작성자 판단에 크게 의존했기 때문에, 같은 신호라도 표현 방식과 지역명 선택이 달라지는 경우가 있었다. 자동화하려면 이런 지역 선택 과정을 정량적으로 재현할 수 있어야 하고 기존 Outlook과의 이질감을 최소화 할 필요가 있다. 이를 위해 APCC 영문 Outlook과 WMO GSCU 약 5년치를 기반으로 지역명을 추출하고, 이를 바탕으로 신호-지역 matching을 하도록 subregion 체계를 구성하였다.

4.3.3.1. Outlook 문서 기반 지역명 추출 및 정리

APCC와 WMO의 Outlook 문서에 나오는 지역명은 범위가 넓고, 같은 지역이 여러 표현으로 쓰이는 경우가 많았다. 예를 들어 North Atlantic은 “North Atlantic“, “the northern part of the Atlantic“, “subtropical North Atlantic“ 등 여러 형태로 나타났고, Southeast Asia도 “Southeast Asia“, “the SE Asian region“, “the Maritime continent and Southeast Asia“ 등 상황에 따라 다르게 표현되었다. 이런 표현상 차이를 없애고 지역 판정 기준을 만들기 위해, 5년치 Outlook에 나온 모든 지역명을 모은 뒤 의미가 비슷한 것끼리 하나의 지역명으로 통합했다.

또한 Outlook 신호 해석에 거의 안 쓰이거나 너무 넓은 지역, 또는 너무 작은 지역은 빼서 분석 효율성과 실무 적용성을 높였다. 이 과정을 거쳐 아래 표와 같이 최종적으로 66개의 지역(region)을 뽑아냈다. 이 66개 지역은 자동화된 문장 생성과 신호추출 알고리즘에서 공통적으로 쓰는 기본 단위가 된다.

Table 4.12. List of 66 Regions frequently appeared in the APCC Climate Outlook and WMO GSCU

Central Africa	East Africa	North Africa
Sahel	South Africa	West Africa
Antarctic	Southern Ocean	Arctic
Barents Sea	Bering Sea	East Siberian Sea
Kara Sea	Laptev Sea	Maritime Continent
Arabian Peninsula	Central Asia	China
East Asia	India	Indonesia
Middle East	Mongolia	Papua New Guinea
Russia	Siberia	South Asia
West Asia	Southeast Asia	Arabian Sea
Bay of Bengal	Philippine Sea	Equatorial Atlantic
North Atlantic	South Atlantic	Subtropical North Atlantic
Subtropical South Atlantic	Tropical North Atlantic	Tropical South Atlantic
Central America	Europe	Equatorial Indian Ocean
Indian Ocean	South China Sea	Alaska
Canada	Caribbean	Mexico
North America	USA	Coral Sea
Equatorial Pacific	New Zealand	Australia
North Pacific	South Pacific	Subtropical North Pacific
Subtropical South Pacific	Tropical Pacific	Tropical North Pacific
Tropical South Pacific	Brazil	South America

4.3.3.2. 지역 세분화와 단독 지역 처리 방식

66개 지역을 그대로 쓰는 대신, 좀 더 정밀한 지역 판정을 할 수 있도록 방향(prefix) 기반의 subregion으로 확장했다. 예측 신호는 지역 안에서도 특정 부분에 집중되는 경우가 많기 때문에, 동·서·남·북이나 중심부 등으로 나누는 게 신호 분포의 공간적 특징을 반영하는 데 유리하다. 예를 들어 South America는 북부와 남부의 기후 특성이 크게 달라서 north-south 분할이 의미 있지만, Caribbean 같은 해역에서는 이런 분할이 실제 해석상 큰 의미가 없다.

prefix 확장은 지역의 모양, 면적, 지리적 연속성, 주변 기후 시스템과의 관계 등을 고려해서 적용했다. 이런 규칙을 바탕으로 총 343개의 subregion을 만들었다. 각 subregion은 격자 기반 mask 자료로 저장되고, 신호가 어느 subregion에서 가장 뚜렷하게 나타났는지를 계산하는데 쓰인다.

한편 일부 지역은 prefix 분할을 안 하고 단일 subregion으로 뒀다. 총 23개의 이런 지역은 대부분 다음 같은 특징을 갖는다:

- 해역이나 해분 단위로 자연 경계가 명확해서 추가 분할이 적절하지 않은 경우 (예: Kara sea)
- 너무 넓지 않은 국가 또는 단위 지역이라 분할의 분석적 가치가 크지 않은 경우 (예: Alaska)

이런 지역은 단독 subregion으로 두어 지역별 특성과 해석의 일관성을 유지하였다. 도출된 343개의 subregion의 영역은 아래 그림과 같다.

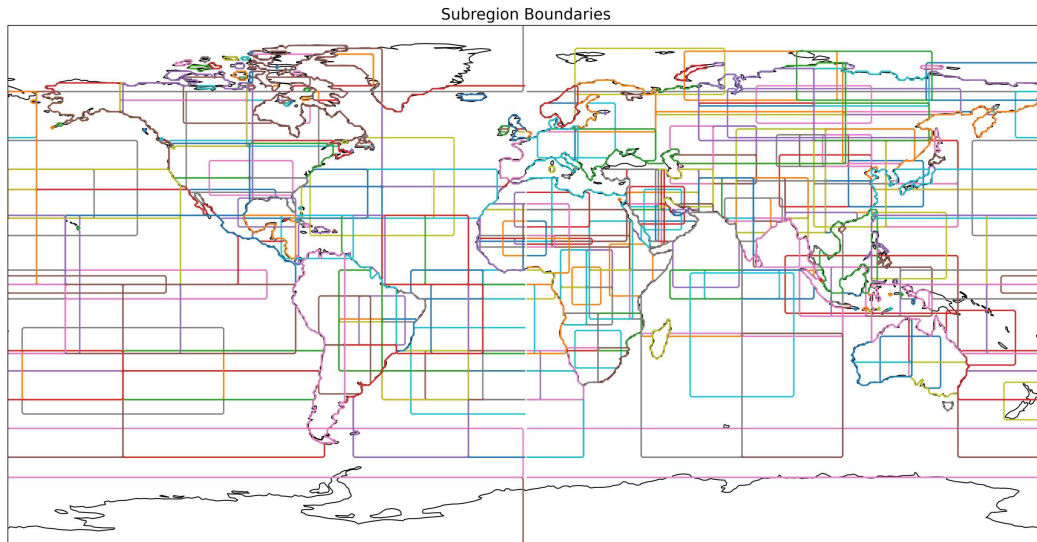


Figure 4.44. Boundaries of 343 subregions for global outlook

4.3.3.3. 태평양(Pacific) 지역 체계 구축

Pacific Outlook은 전지구 Outlook과는 별도로 태평양의 독특한 지리·문화·기후 특성을 반영한 지역 체계가 필요하다. 태평양 도서국은 Melanesia, Micronesia, Polynesia 세 문화권으로 나뉘고, 실제 기후서비스 사용자와 현지 기관에서도 이 문화권 구분을 기본으로 사용다. 또한 태평양 지역은 SPCZ(South Pacific Convergence Zone), ENSO의 직접적인 영향 등 전형적인 기후 패턴이 강하게 작용해서, 지역 체계도 이런 기후 구조를 반영할 필요가 있다.

초기 단계에서는 국가 EEZ 경계를 기반으로 문화권과 적도 해역을 세밀하게 나눠서 약 39개의 subregion을 만들었으나 이것은 실무 측면에서 너무 복잡하고 의미가 없다고 판단하였다. 예측 신호가 실제로 넓은 영역에 걸쳐 나타나는 특성, Outlook 문장에서 자주 쓰는 지역 등을 종합적으로 보면, 더 단순하면서도 기후학적으로 의미 있는 지역구분을 적용하는 것이 합리적이다. 이를 바탕으로 최종적으로 17개의 subregion으로 축소하였다. 이 과정에서 각 문화권을 똑같은 방식으로 나눈 게 아니라, 지역의 면적·모양·국가 분포·예측 신호의 실제 패턴(SPCZ 위치, ENSO teleconnection 패턴 등)을 고려해서 문화권별로 분할 개수를 다르게 정했다.

Table 4.13. List of 17 subregions in the Pacific

Northern Melanesia	Southern Melanesia
Northeastern Micronesia	Northwestern Micronesia
Southeastern Micronesia	Southwestern Micronesia
Northeastern Polynesia	Northwestern Polynesia
Southeastern Polynesia	Southwestern Polynesia
Western Equatorial Pacific	Central Equatorial Pacific
Eastern Equatorial Pacific	Central Off-Equatorial North Pacific
Eastern Off-Equatorial North Pacific	Central Off-Equatorial South Pacific
Eastern Off-Equatorial South Pacific	

예를 들어 Melanesia는 북서쪽에서 남동쪽으로 늘어선 배치이므로 남북 혹은 동서 방향의 분할은 의미있으나 남서 혹은 북동 지역은 의미가 없다. SPCZ의 남북 이동이 주된 변동임을 감안하여 Melanesia는 남북방향의 분할만을 고려하였다. 반면 Polynesia와 Micronesia는 군도가 넓게 퍼져 있고 동-서-남-북으로 구분되는 기후 변동 구조가 뚜렷해서 네 방향 분할을 유지했다. Equatorial Pacific과 Off-Equatorial Pacific은 ENSO 신호와 해양·대기 상호작용의 연속성이 강해서 중앙·동부 중심의 영역 구분을 유지했다. western Off-equatorial pacific은 기존 문화적 지역구분(Micronesia 및 Melanesia)와의 중첩이 심해 제외하였다. 또한 outlook 수신자인 태평양 도서국이 주로 태평양 중서부에 위치함을 고려해 동태평양 지역에는 불필요한 subregion을 설정하지 않았다. 선정된 subregion의 영역은 아래 그림과 같다. 이런 조정을 통해 너무 복잡하지 않으면서도 예측 신호의 특징, 지역 사용 빈도, 기후체계 구조를 균형 있게 반영한 Pacific subregion 체계를 만들었다. 이 구조는 Pacific Outlook의 예측 신호 서술에 맞춰져 있고, Outlook 자동화를 위한 signal 추출 및 지역 판정 알고리즘의 기반으로 쓰인다. 이렇게 만들어진 지역 구분은 mask.nc 파일로 저장하여 signal 추출 및 지역 matching에 활용한다.

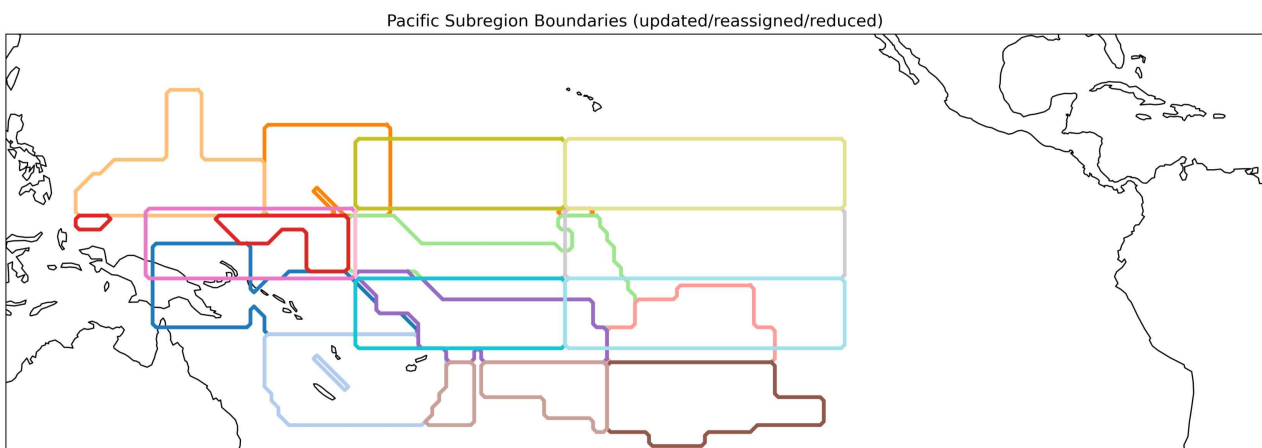


Figure 4.45. Boundaries of 17 subregions for the Pacific outlook

4.3.4. 확률 예측 신호 검출 및 텍스트 생성 알고리즘

Outlook 자동화의 핵심은 3-category 확률 예측장에서 의미 있는 신호를 정량적으로 추출하고, 이를 지역명과 매칭하여 자연어 문장으로 변환하는 과정이다. 본 장에서 설명하는 알고리즘은 기존 Outlook 작성자가 수행해온 시각적 판독 과정을 정량화한 것으로, 확률 임계값, 면적 비율, 신호 강도라는 세 가지 기준을 조합하여 신호를 검출하고 지역별로 통합하는 체계를 구축한다. 이후 신호검출과 완성단계까지는 태평양지역 outlook 만을 대상으로 진행하였다. 태평양 outlook을 대상으로 한 시범작업을 통해 개발의 안정성과 효과성을 먼저 검증하고나서 향후 global outlook에 적용하는 것이 타당할 것이다.

4.3.4.1. 신호 검출의 기본 구조

태평양 지역은 활용되는 지역명이 거의 확정적이므로 매 subregion에 대해 어떤 예측 signal이 있는지를 확인하는 지역우선 신호추출 방식을 적용하였다. 신호 검출 알고리즘은 MME 확률 예측 자료(NetCDF 형식)와 subregion mask 자료를 입력으로 받아, 각 subregion에서 나타나는 신호를 판정한다. 확률 예측은 above normal, near normal, below normal의 세 범주로 구성되며, 각 범주의 확률값 분포를 기반으로 신호 강도를 결정한다. 신호 강도는 Strong, Enhanced, Tendency 세 단계로 분류되며, 각각 확률 임계값 70%, 50%, 40%를 기준으로 한다. 이러한 임계값 구분은 기존 Outlook에서 사용해온 표현 체계를 반영한 것으로, 70% 이상의 확률은 “Strongly enhanced probability”로, 50~70%는 “Enhanced probability”로, 40~50%는 “A tendency for”라는 문구로 대응된다.

알고리즘은 각 subregion 내에서 세 범주별로 Strong($\geq 70\%$), Enhanced(50~70%), Tendency(40~50%) 조건을 만족하는 격자의 면적 비율과 평균 확률값을 계산한다. 이 과정에서 두 개의 조정 가능한 파라미터(tunable parameter)가 사용된다. 첫 번째는 Strong 신호 판정을 위한 최소 면적 비율(A, 기본값 15%)이고, 두 번째는 Enhanced 또는 Tendency 신호 판정을 위한 최소 면적 비율(B, 기본값 50%)이다.

파라미터 A는 Strong 신호가 선택되기 위한 최소 공간적 일관성을 정의한다. 15%라는 기본값은 subregion 내에서 70% 이상의 높은 확률값이 충분히 넓은 면적에 걸쳐 나타나야 한다는 기준을 반영한다. 만약 A 값을 낮추면(예: 10%) Strong 신호가 더 자주 선택되어 Outlook에서 강한 표현이 증가하지만, 실제로는 작은 영역에만 집중된 신호도 포함될 위험이 있다. 반대로 A 값을 높이면(예: 20%) Strong 신호 선택이 더 엄격해져서 정말 뚜렷한 신호만 강조되지만, 의미 있는 신호를 놓칠 수 있다.

파라미터 B는 Enhanced와 Tendency 신호의 선택 기준을 결정한다. 50%라는 기본값은 해당 범주의 신호가 subregion의 절반 이상에서 나타나야 의미 있다고 판단하는 기준이다. B 값을 낮추면(예: 30%) 더 많은 약한 신호가 Outlook에 포함되어 정보량은 증가하지만 신호 품질이 떨어질 수 있다. B 값을 높이면(예: 70%) 매우 일관된 신호만 선택되어 Outlook이 간결해지지만, 지역적으로 중요한 신호가 누락될 수 있다. 실무에서는 예측 시스템의 신뢰도와 사용자 요구를 고려해 이 파라미터들을 조정할 수 있으며 현재의 기본값은 몇 차례 실행을 통해 조정되었다.

4.3.4.2. 신호 선택 로직과 설계 원리

신호 선택은 2단계 우선순위 체계로 이뤄진다. 이 설계는 기존 Outlook 작성 관행과 기후 예측의 불확실성 특성을 함께 반영한 것이다. 1단계에서는 세 범주(above, near, below) 중 Strong 조건을 만족하는 면적 비율이 A% 이상인 범주가 있는지 확인한다. Strong 신호를 우선적으로 선택하는 이유는 명확하다. 계절 예측에서 70% 이상의 확률은 모델이 매우 높은 신뢰도로 특정 범주를 예측한다는 의미이며, 이는 사용자에게 가장 중요한 정보다. 기존 Outlook 작성 과정에서도 담당자는 항상 가장 강한 신호를 먼저 식별하고 이를 문서의 핵심으로 배치했다. 자동화 시스템도 이 원칙을 따라 Strong 신호가 존재하면 다른 약한 신호는 고려하지 않는다.

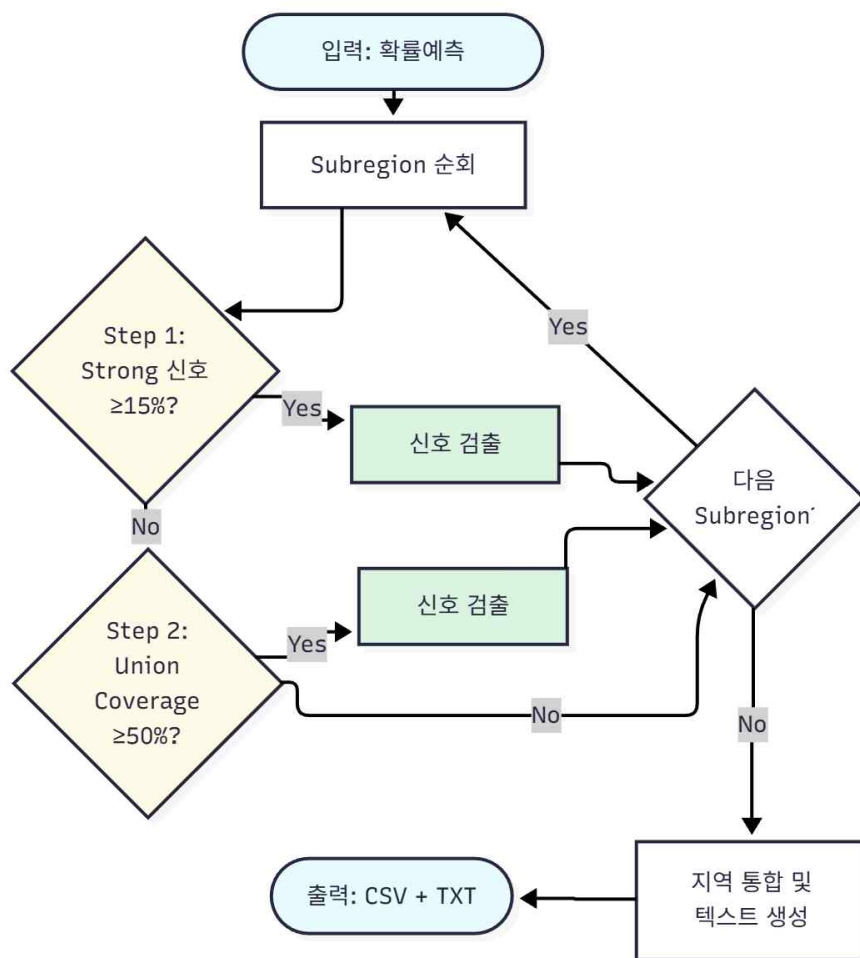


Figure 4.46. Process flow of forecast signal detection for the Pacific outlook

만일 Strong 조건을 만족하는 범주가 여러 개라면, 면적 비율이 가장 큰 범주를 선택한다. 이는 신호의 공간적 일관성과 뚜렷함을 중요하게 생각하는 접근이다. 같은 70% 확률이라도 subregion의 20%에서 나타나는 신호와 40%에서 나타나는 신호는 다르다. 더 넓은 면적을 차지하는 신호는 국지적 노이즈가 아니라 대규모 기후 패턴을 반영할 가능성이 크다. 면적이 비슷하면(오차 범위 내) 평균 확률값이 높은 범주를 선택한다. 면적이 같다면 확률값의 크기가 신호 강도의 추가적인 판단 기준이 되는 것이다. 예를 들어 한 범주는 평균 72%, 다른 범주는 평균 78%라면 후자가 더 강한 신뢰를 보인다고 해석할 수 있다. 이 단계에서 선택되면 해당 subregion은 “Strongly enhanced probability of [Above/Near/Below] normal“로 분류된다.

1단계에서 선택되지 않으면 2단계로 넘어간다. Strong signal이 존재하지 않는 경우인 2단계의 접근은 범주를 먼저 정하고, 그 안에서 강도를 결정한다는 것이다. 기존 Outlook 작성자는 지도를 볼 때 먼저 “이 지역은 above normal 경향이 있는가, below normal 경향이 있는가“를 판단하고, 그 다음에 “얼마나 강한가“를 평가했다. 이를 재현하기 위해 2단계에서는 Enhanced와 Tendency 조건을 만족하는 격자를 합친 면적 비율(union coverage)을 범주별로 계산하고, 그 비율이 가장 큰 범주를 먼저 선택한다. 이는 40% 이상의 확률을 보이는 모든 영역을 고려하여 어느 범주가 가장 지배적인지를 판단하는 과정이다.

선택된 범주 내에서 합쳐진(Enhanced + Tendency) 면적의 영역이 B% 미만이면 신호 자체를 기각한다. 이는 신호가 너무 약하거나 일관성이 부족하다는 의미다. B% 이상이면, Enhanced 면적 비율과 Tendency 면적 비율을 비교해 더 큰 쪽을 최종 신호 강도로 결정한다. 면적이 비슷하면 평균 확률값을 비교한다. 이 로직은 같은 범주 안에서도 50~70% 확률 영역이 넓으면 “Enhanced“로, 40~50% 확률 영역이 넓으면 “Tendency“로 구분하여 신호의 세기를 정확히 표현하려는 의도이다.

범주 선택 시 동점이 발생하면 above > below > near 순서로 우선순위를 적용한다. 이는 기존 Outlook에서 극값(above/below) 신호가 중립(near) 신호보다 사용자에게 더 유용한 정보로 간주되었던 관행을 반영한 것이고 Above와 Below 사이의 우선순위는 편의를 위해 임의로 결정하였다. 계절 예측의 사용자들은 대부분 평년 수준의 기후보다는 평년보다 높거나 낮은 극한 상태에 관심을 갖기 때문에, 자동화 시스템도 이를 우선적으로 포착하도록 설계되었다.

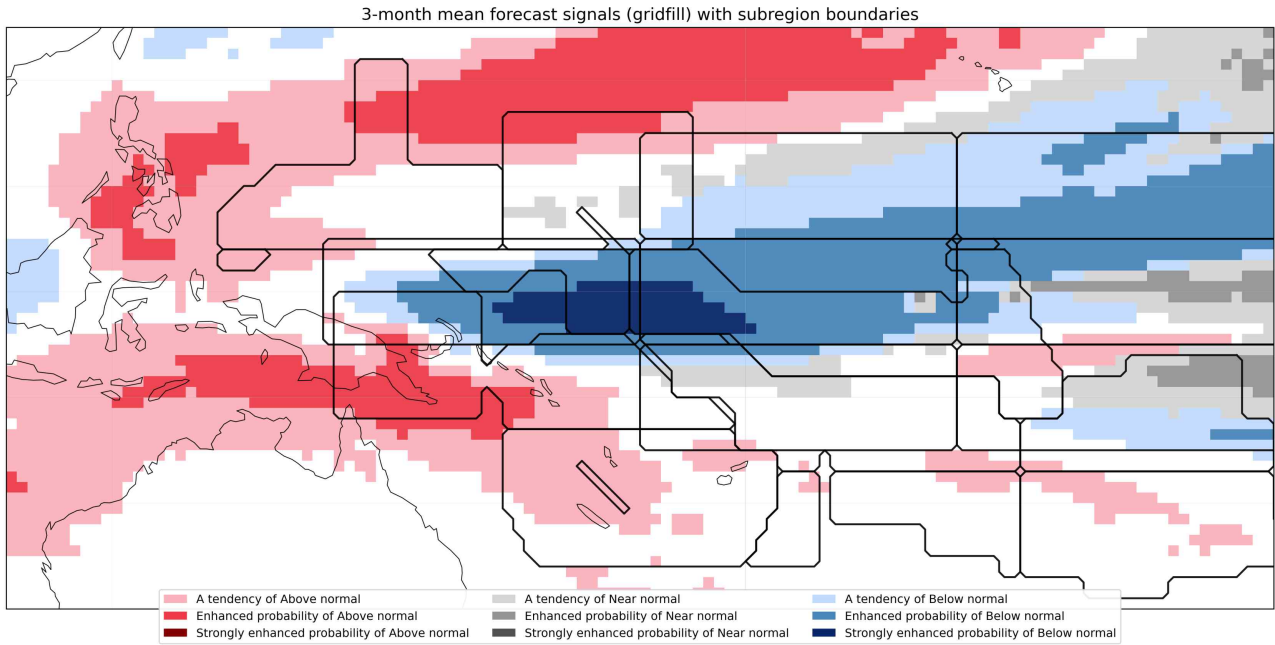


Figure 4.47. Example of forecast signals mapped over the subregion masks. Different colors correspond to different signals (category/strength)

4.3.4.3. 지역 통합 및 텍스트 생성

신호 검출이 완료되면 동일한 신호를 가진 subregion들을 지역(region) 단위로 통합한다. 이 과정은 Outlook 문장이 너무 길어지거나 중복되지 않도록 하면서도, 신호의 공간 분포를 정확히 전달하기 위한 것이다. 통합 규칙은 다음과 같다.

첫째, 어떤 region의 모든 subregion이 같은 신호로 선택되면 region 이름만 표기한다. 예를 들어 Micronesia의 northeastern, northwestern, southeastern, southwestern이 모두 같은 신호를 보이면 “Micronesia”로만 표현한다. 이는 불필요한 세부 정보를 줄이고 가독성을 높인다.

둘째, 방향별 subregion(northeastern, northwestern 등) 중 일부만 선택되었을 때는 방향 조합 규칙을 적용한다. 예를 들어 northeastern과 northwestern이 모두 선택되면 “northern [region]”으로 병합하고, southeastern과 southwestern이 선택되면 “southern [region]”으로 병합한다. 동일하게 eastern과 western 조합도 처리된다. 이 규칙은 공간적으로 인접하고 의미적으로 연관된 subregion들을 간결하게 표현하기 위한 것이다.

셋째, 한 region에서 하나의 subregion만 제외하고 나머지가 모두 선택되었고, 선택된 subregion이 3개 이상이며, 방향 병합이 적용되지 않는 경우, “region except for [direction] part” 형태로 표현한다. 이는 “거의 전체 지역에서 신호가 나타나지만 특정 부분만 예외”라는 정보를 효율적으로 전달한다. 넷째, 위 조건에 해당하지 않으면 선택된 subregion들을 나열한다.

태평양 지역의 경우 추가적인 인접 병합 규칙이 적용된다. Equatorial Pacific의 western, central, eastern 세 subregion이 모두 같은 신호로 선택되면 “Equatorial Pacific“으로 통합되고, off-equatorial 영역도 동일한 방식으로 통합된다. 또한 특정 subregion 간 중복 처리 규칙이 적용되는데, 예를 들어 central_equatorial_pacific과 southeastern_micronesia가 같은 신호로 선택되면 지리적으로 겹치는 southeastern_micronesia는 제거된다. 이는 태평양 지역의 복잡한 지리적 특성과 문화권 구분을 고려한 처리 방식이다.

최종적으로 생성되는 텍스트는 “[Signal strength and category] [variable] : [region list]“ 형태로 구성된다. 예를 들어 “Strongly enhanced probability of Above normal temperature : northern Micronesia, Equatorial Pacific“와 같은 형식이다. 신호는 Above normal > Below normal > Near normal 순서로, 각 범주 내에서는 Strong > Enhanced > Tendency 순서로 정렬되며, 지역 목록 내에서는 Equatorial Pacific 관련 지역이 off-equatorial 지역보다 앞에 배치된다. 이러한 정렬 순서는 기존 Outlook에서 극값 신호를 먼저 언급하고, 태평양 적도 지역을 먼저 다루던 관행을 그대로 따른 것이다.

알고리즘은 pre-merge 상태의 상세 CSV 파일과 최종 통합된 TXT 파일 두 가지를 출력한다. 상세 CSV는 각 subregion별 신호를 모두 기록하여 검증과 디버깅에 사용되며, TXT 파일은 실제 Outlook 문서에 삽입될 핵심 문장 내용을 담는다.

4.3.5. 해수면온도 신호 추출 및 해석 알고리즘

태평양 도서국 대상 Outlook에서는 적도 태평양과 동부 인도양의 해수면온도(SST) 이상 패턴이 계절 예측의 가장 중요한 요소다. ENSO 신호를 중심으로 한 SST 이상은 태평양 전역의 강수와 기온 패턴에 직접적인 영향을 미치기 때문에, 예측된 SST anomaly 지도에서 주요 신호를 자동으로 추출하고 그 시간 변화를 설명하는 체계가 필요하다. 본 장에서 설명하는 알고리즘은 3개월 평균 SST 예측장에서 아래 그림과 같은 적도 지역(5° S~5° N, 90° E~270° E)의 이상 신호를 검출하고, 지역별·부호별로 강도를 판정하여 주 신호(primary signal)와 부가 신호(additional signal)를 구분하여 텍스트로 출력한다.

4.3.5.1. 신호 추출의 기본 구조 및 지역 구분

알고리즘은 적도 인도양-태평양 영역을 네 개 지역으로 나눈다. 동태평양(Eastern Pacific, 210° E~270° E), 중태평양(Central Pacific, 170° E~210° E), 서태평양(Western Pacific, 120° E~170° E), 동인도양(Eastern Indian Ocean, 90° E~120° E)이며, ENSO 신호의 중요도를 고려해 이 순서대로 우선순위가 부여된다. 이는 기존 Outlook에서 ENSO 신호를 설명할 때 Niño3.4 지역(중태평양)이나 Niño3 지역(동태평양)을 가장 먼저 언급하고, 서태평양이나 인도양 신호는 부차적으로 다루지던 관행을 반영한 것이다.

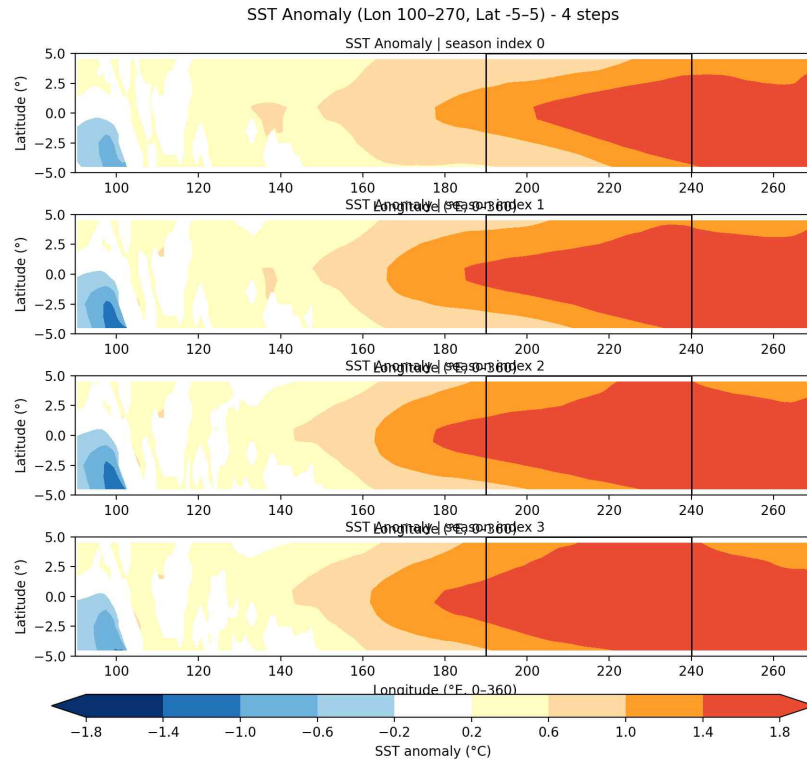


Figure 4.48. Example of 4 seasonal SST anomalies of interest for the outlook generation

각 지역에서 신호를 검출할 때는 클러스터링 방법을 사용한다. SST anomaly 필드에서 특정 임계값(기본값 0.5° C) 이상의 양/음 이상을 보이는 연속된 영역을 클러스터로 정의하고, 그 클러스터가 전체 영역 대비 2% 이상의 면적을 차지해야 의미 있는 신호로 간주한다. 이 두 파라미터는 조정 가능하다(threshold, min_area_frac). 임계값을 낮추면(예: 0.3° C) 약한 신호도 포착되지만 노이즈가 증가할 수 있고, 임계값을 높이면(예: 0.7° C) 강한 신호만 선택되어 중요한 약한 신호를 놓칠 수 있다. 면적 비율도 마찬가지로, 낮추면(예: 1%) 작은 국지 신호도 포함되고, 높이면(예: 5%) 광역 신호만 선택된다.

4.3.5.2. Robust Peak 기반 신호 강도 판정

기존 방식에서는 클러스터 내 최댓값을 신호 강도로 사용했는데, 이는 단일 극단값에 민감해서 불안정할 수 있다. 이 알고리즘은 robust peak 개념을 도입했다. 클러스터 내 모든 격자의 이상값 절댓값을 구하고, 그 중 95 백분위수(95th percentile)를 신호 강도로 정의한다. 이렇게 하면 한두 개 극단 격자에 영향을 덜 받으면서도 클러스터의 전반적인 강도를 잘 대표할 수 있다.

Robust peak 값을 기준으로 신호는 다섯 단계로 분류된다. 0.2° C 이하는 none(신호 없음), 0.2~0.6° C는 weak, 0.6~1.0° C는 moderate, 1.0~1.5° C는 strong, 1.5° C 초과는 very strong이다. 이 구분은 기존 Outlook에서 SST anomaly를 서술할 때 사용하던 표현 강도와 대응되도록 설계되었다. Strong 이상($\geq 1.0^{\circ}$ C)의 신호는 기후학적으로 명확한 영향을 미치는 수준으로, 알

고리즘은 이를 기준으로 주요 신호를 우선 판정한다.

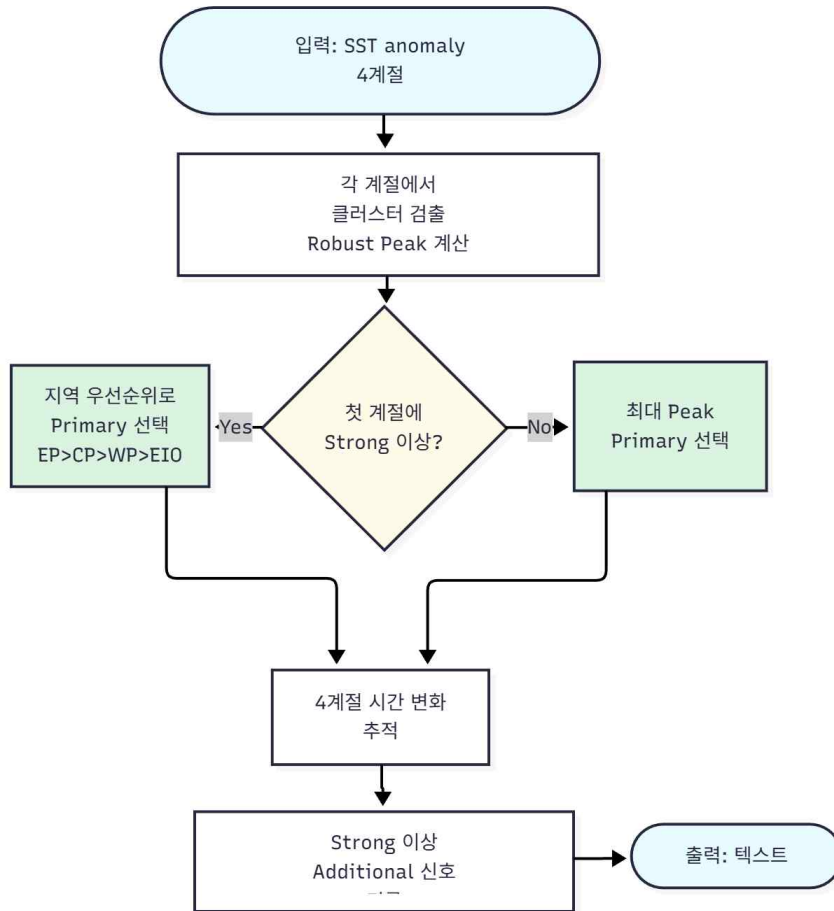


Figure 4.49. Process flow of SST anomaly signal detection

4.3.5.3. Primary Signal 선택 로직

Primary signal은 예측 전체를 대표하는 가장 중요한 신호로, Outlook의 구조상 가장 가까운 미래(첫 번째 계절)의 SST 상태에 초점을 맞춘다. 기존 Outlook에서도 ENSO 전망은 항상 다음 계절의 상태를 먼저 설명하고, 그것이 이후 어떻게 변화하는지를 서술하는 방식을 따랐다. 따라서 이 알고리즘은 첫 번째 계절($t=0$)에서만 primary signal을 찾는다.

선택 로직은 2단계로 구성된다. 첫 번째 단계에서는 첫 계절에서 strong 이상(robust peak $\geq 1.0^\circ\text{C}$) 신호가 존재하는지 확인한다. 만약 있다면, 동태평양 \rightarrow 중태평양 \rightarrow 서태평양 \rightarrow 동인도양 순서로 우선순위를 적용해서 가장 먼저 해당하는 지역을 primary로 선택한다. 해당 지역 내에서 robust peak가 가장 큰 부호(positive 또는 negative)를 primary polarity로 정한다.

동태평양을 가장 우선하는 이유는 이 지역의 SST 이상이 기후학적으로 더 비정상적(more abnormal)이고, 따라서 태평양 전역에 미치는 영향이 크기 때문이다. 동태평양은 평상시 냉수

용승이 활발한 지역이라 SST 이상이 나타나면 그 신호가 강하게 작용하며, ENSO의 가장 전형적인 패턴도 이 지역에서 두드러진다. 중태평양, 서태평양, 인도양 순으로 우선순위가 낮아지는 것은 SST 변동의 기후 영향력 차이를 반영한 것이다.

만약 첫 계절에서 strong 이상 신호가 없다면, 두 번째 단계로 넘어간다. 첫 계절의 모든 지역, 모든 부호를 통틀어 robust peak가 가장 큰 조합을 primary로 선택한다. 동률이면 지역 우선순위로 결정한다. 이는 “약한 신호만 있을 때는 그중 가장 뚜렷한 것을 택한다”는 보수적 접근이다.

4.3.5.4. 신호의 시간 변화 및 Additional Signal

Primary signal이 정해지면 4개 계절에 걸친 시간 변화를 추적한다. 시작 계절(예: OND)부터 다음 3개 계절(NDJ, DJF, JFM)까지 총 4개 시점에서 primary 지역·부호의 robust peak 값을 계산하고, 각 시점마다 카테고리(weak, moderate, strong 등)를 판정해서 출력한다. 이는 “ENSO 신호가 시간에 따라 강해지는가, 약해지는가”를 보여주는 중요한 정보다. 기존 Outlook에서도 ENSO 전망 섹션에서 항상 “gradually increase”, “remain strong”, “weaken” 같은 시간 변화를 언급했는데, 이를 자동화하기 위한 신호이다.

추가로, primary 외의 지역에서 strong 이상 신호가 발생하면 additional signal로 별도 언급한다. 이때 중요한 점은 첫 계절에서는 나타나지 않았지만 이후 계절에서 새롭게 등장(emerge)하는 신호도 포착된다는 것이다. 예를 들어 primary가 첫 계절의 동태평양 positive인데, 세 번째 계절에서 서태평양에 strong negative 신호가 새로 나타나면 이를 additional signal로 기록한다. 이는 SST 패턴이 시간에 따라 변화하는 복잡한 역학을 놓치지 않기 위한 장치다. 다만 moderate 이하의 약한 신호는 additional로 언급하지 않아서 문장이 불필요하게 복잡해지지 않도록 한다.

4.3.5.5. 출력 구조 및 활용

알고리즘은 세 부분으로 구성된 텍스트를 생성한다. 첫째, Primary signal selection 섹션에서 어느 지역의 어느 부호 신호가 대표로 선택되었는지 명시한다. 둘째, Evolution of primary signal 섹션에서 4개 계절 각각의 카테고리과 강도를 나열한다. 셋째, Additional signals 섹션에서 primary 외 strong 이상 신호를 시준별로 기록한다. 이 텍스트는 header 파일(프롬프트)과 결합되어 LLM 입력으로 사용되어, Outlook 문서에 적용된다.

이 알고리즘의 장점은 작성자의 주관을 배제하고 정량적 기준으로 일관되게 신호를 판정한다는 점이다. 동일한 예측 자료에 대해서는 항상 같은 결과를 출력하며, 파라미터 조정을 통해 민감도를 제어할 수 있다. 특히 태평양 도서국 Outlook처럼 적도 SST 신호가 핵심인 문서에서는 이 자동화 체계가 작성 시간을 크게 줄이고 신호 해석의 객관성을 높일 수 있다.

4.3.6. 과거예측 skill (HSS) 신호 추출 및 지역 판정

과거예측 skill(Heidke Skill Score, HSS)은 과거 기간에 대한 예측 성능을 평가한 지표로, Outlook에서 예측의 신뢰도를 전달하는 중요한 정보다. HSS 자동 해석 알고리즘은 기본적으로 4.3.4절의 확률 예측 신호 검출 방식과 동일한 구조를 따른다. 즉, subregion별로 신호를 판정하

고, 동일 수준의 기술을 보이는 지역들을 통합하여 텍스트로 출력한다. 다만 HSS는 확률 예측과 달리 단일 값(skill score)을 다루며, 범주가 above/near/below가 아니라 high/moderate/low skill로 구분된다는 점에서 차이가 있다. 본 장에서는 forecast signal 검출 알고리즘과의 차이점을 중심으로 HSS 자동화 체계를 설명한다.

4.3.6.1. 신호 판정 기준의 차이: 확률값 → skill score

확률 예측 신호 검출에서는 70%, 50%, 40%라는 확률 임계값을 사용했지만, HSS 신호 검출에서는 skill score 자체의 범위를 기준으로 한다. HSS 값은 연속 수치로 주어지며, 음수(≤ 0)는 poor, 0~20은 reasonable, 20~40은 good, 40 이상은 very good으로 분류된다. 이 4단계 분류는 subregion 내 격자별로 적용되며, 지역별로 각 범주에 속하는 격자의 비율을 계산하여 해당 지역의 과거예측 정확도를 추출한다. 최종적으로 subregion을 high/moderate/low skill로 판정하는 로직은 다음과 같다.

1) poor 비율이 30% 이상이거나 평균 HSS가 5 이하면 무조건 low skill로 분류한다. 이는 예측 품질이 낮은 지역을 명확히 식별하기 위한 보수적 기준이다.

2) very good 비율이 30% 이상이거나, (very good + good) 비율이 60% 이상이면서 평균 HSS가 30 이상이면 high skill로 분류한다.

3) (very good + good + reasonable) 비율이 70% 이상이고, poor 비율이 20% 미만이며, 평균 HSS가 10 이상이면 moderate skill로 분류한다. 이 외에는 모두 low skill로 처리된다.

이는 대체로 예측 성능이 높은 태평양 지역의 특성을 감안해 특별히 예측 성능이 낮으니 주의가 필요한 지역 선정에 초점을 맞춘 것으로, 이 기준들은 모두 조정 가능한 파라미터(tunable parameter)로 설계되었다. 예를 들어 --esp-v-frac 0.30은 very good 비율 30%를 의미하고, --reliable-cov 0.70은 moderate 판정을 위한 전체 coverage 70%를 의미한다. 파라미터를 엄격하게 설정하면(예: esp-v-frac 0.50) high skill 판정이 까다로워지고, 느슨하게 하면(예: 0.20) 더 많은 지역이 high skill로 분류된다. 이는 사용자의 신뢰도 기준과 Outlook의 보수성 정도에 따라 조정될 수 있다.




Figure 4.50. Example of HSS distribution of different category mapped over the subregion masks

4.3.6.2. 지역 통합 및 텍스트 생성

확률 예측과 마찬가지로, 동일한 skill level(high/moderate/low)을 보이는 subregion들은 통합된다. 태평양 적도 영역의 western-central-eastern 조합, off-equatorial 영역의 남북 조합 등 인접 지역 병합 규칙이 적용된다.

다만 출력 형식에는 중요한 차이가 있다. 확률 예측에서는 “[Signal] [variable] : [regions]” 형태였지만, HSS에서는 각 변수(temperature/precipitation)별로 skill level 순으로 나열한다.

4.3.7. 언어모델 기반 Outlook 자동화 체계 구축

본 장에서는 계절예측 Outlook 작성 과정의 마지막 단계인 서술 자동화(narrative generation)를 고도화하기 위한 언어모델(LLM) 기반 시스템 구축 과정을 다룬다. 기존 Outlook 문서는 신호 탐지 및 지역 매핑 절차가 충분히 정형화되어 있음에도 불구하고, 최종 서술 작성 단계는 담당자의 경험적 판단과 문체적 선택에 크게 좌우되었다. 이로 인해 문서 간 일관성 유지가 어렵고, 문서 생산 과정이 장시간 수작업에 의존하는 한계가 있었다. 본 연구는 이러한 문제를 해결하기 위해, 예측 신호 해석 이후의 자연어 기술을 내부 환경에서 독립적으로 실행 가능한 경량 언어모델 기반 자동 생성 체계로 전환하고자 하였다. 이 장에서는 이러한 체계 구축의 기술적 배경과 적용 과정, 그리고 오프라인 기반 LLM 운용 방식을 설명한다. 우선 오프라인 LLM 실행 환경 구축의 세부 과정과 기술적 제약을 다루고, 그 다음에는 모델 적용 및 프롬프트 설계·튜닝 전략을 간략히 정리하였다.

4.3.7.1. 오프라인 LLM 구축

계절예측 Outlook 자동화에 언어모델을 도입하기 위해 가장 먼저 해결해야 했던 문제는, APCC 내부 시스템의 제약을 충족하면서도 안정적으로 작동할 수 있는 오프라인 LLM 실행 환경을 구축하는 것이었다. 내부 시스템은 외부 네트워크 접속이 제한적이며, 최신 개발 패키지를 손쉽게 설치하기 어려운 환경이다. 또한 GPU 자원을 사용할 수 없기 때문에, Python 기반

대규모 학습 프레임워크(PyTorch, TensorFlow 등)를 그대로 적용하는 것은 현실적이지 않았다. 이러한 조건 속에서는 CPU 기반에서 가볍고 안정적으로 작동하는 경량 언어모델과, 최소 의존성을 갖는 추론 엔진을 통해 독립적인 실행 구조를 확보하는 것이 핵심 과제가 되었다.

본 연구에서는 먼저 온라인 환경에서 여러 공개 모델을 비교·평가하였다. Phi-2, Phi-3, Llama-3, Llama-3.1, Qwen-2.5 등 다양한 모델을 대상으로 Outlook 문장 생성 실험을 수행한 결과, Llama-3.1-8B 모델의 Q4 GGUF 버전이 반응 속도, 문장 구조의 안정성, 프롬프트 준수 정도 측면에서 가장 우수한 성능을 보였다. 특히 Outlook 서술은 복잡한 추론이 필요하기보다는, 탐지된 신호를 일정한 규칙에 따라 정확하고 간결하게 기술하는 기능이 핵심이므로, 과도한 창의성을 발휘하지 않는 분석적이고 안정적인 모델이 더 적합하다. 이러한 점에서 Llama-3.1-8B 모델은 계절예보 문장 자동화에 매우 실용적인 선택이었다. 모델 파일은 HuggingFace에서 제공하는 GGUF(Q4) 버전을 그대로 사용하였다.

추론 엔진은 C/C++ 기반 경량 실행 구조를 갖는 llama.cpp를 선택하였다. llama.cpp는 단일 실행 파일과 GGUF 모델 파일만으로 추론이 가능하며, 외부 패키지 설치 부담이 거의 없어 내부 시스템과의 적합성이 높다. 다만 APCC 내부 시스템은 다소 오래된 리눅스 배포판을 사용하고 있어, 최신 llama.cpp 버전이 요구하는 컴파일 환경과의 호환성 문제가 존재했다. 이를 해결하기 위해, 동일한 운영체제를 갖춘 별도의 CentOS 7.4 가상머신(Virtual Machine)을 구축하여 외부 의존성을 최소화한 형태로 실행 파일을 컴파일하였다. 이러한 방식으로, 추가 패키지 설치 없이 내부 시스템에서도 즉시 실행 가능한 독립형 llama.cpp 기반 LLM 환경이 구축되었다.

내부 시스템에서의 언어모델 실행은 매우 단순한 방식으로 이루어진다. 모델 파일과 실행 바이너리를 동일 디렉토리에 배치한 뒤, 프롬프트 파일을 표준 입력으로 전달하여 추론을 수행한다. Outlook 자동화 파이프라인에서 실제로 사용하는 명령 구조는 다음과 같다.

```
./llama-run -t [사용할 스레드 수] llama-3.1-8B-Q4.gguf < prompt.txt
```

이 방식은 신호 탐지 결과를 기반으로 Python 스크립트가 자동으로 프롬프트 파일을 생성하고, 이를 LLM에 전달하여 서술 문장을 생성하는 프로세스를 자연스럽게 통합할 수 있게 해준다. 별도의 패키지 설치나 복잡한 설정 없이 바로 사용할 수 있기 때문에 유지보수 측면에서도 안정적이다.

이와 같이 구축된 오프라인 LLM 환경은 Outlook 자동화의 완결성을 확보하는 중요한 요소이다. 외부 네트워크 연결이 불가능한 환경에서도 언어모델 기반 문장 생성을 수행할 수 있으며, 특정 모델과 프롬프트 구조를 고정함으로써 전문 인력의 교체 여부와 관계없이 문서의 서술 구조와 톤을 일정하게 유지할 수 있다. 또한 외부 API 호출 비용이 발생하지 않고, 예측 자료가 외부 시스템으로 전송되지 않기 때문에 보안 측면에서도 유리하다. 결과적으로 본 시스템은 계절예보 정보 생산의 자동화 흐름을 마지막 단계까지 확장시키며, 예측-해석-서술-출력 과정이 내부 환경에서 모두 재현 가능한 자체 완결형 기후정보 생산 체계를 실현하였다.

4.3.7.2. LLM 적용 및 프롬프트 조정(Prompt Tuning)

오프라인 LLM 환경이 갖추어진 이후, 이를 실제 Outlook 자동화 과정에 적용하기 위해서는 예측 신호를 자연어로 정확하고 일관된 방식으로 변환하는 프롬프트 구조를 정교하게 설계하는 작업이 필요하였다. Outlook 문서는 객관적인 예측 정보를 간결하게 제시해야 하고, 모델이 임의로 해석을 추가하거나 과장된 표현을 생성해서는 안 되기 때문에, 프롬프트는 모델의 자율적 추론을 최대한 억제하고 제공된 정보만을 기반으로 문장을 구성하도록 설계되었다. 특히 계절예보 문장 생성에서는 의미 확장이 거의 필요 없으며, 신호 탐지 알고리즘이 만들어낸 구조화된 결과를 일정한 형식의 문장으로 단순히 변환하는 기능이 중요하므로, 프롬프트 설계의 방향은 “모델이 할 수 있는 것을 줄이는 것”에 초점이 맞추어졌다.

이러한 목적을 위해 본 연구에서는 Outlook 문서에 필요한 문장의 톤, 단락 길이, 표현 규칙, 금지해야 할 문장 유형 등을 상세히 규정한 prompt header를 구성하였다. Prompt header는 LLM이 생성해야 할 문단의 목적과 스타일을 명시하는 동시에, 불필요한 설명이나 메타 언급을 하지 말 것, 주어진 정보 이외의 내용을 추론하지 말 것, 단락 수를 늘리지 말 것 등과 같은 구체적인 제약사항을 포함한다. 이로써 모델은 어떤 작업을 수행해야 하는지를 명확히 이해하게 되고, 구조화된 예측 신호 텍스트를 Outlook 문서에 적합한 자연어 단락으로 변환하는 기능을 안정적으로 수행할 수 있게 된다.

Signal detection 결과는 지역·카테고리 조합을 통해 얻은 신호 목록이며, 이는 header 뒤에 그대로 이어 붙여 모델의 입력으로 제공된다. Prompt는 “header + 신호 목록”이라는 단순한 구조이지만, 이 방식은 모델 출력의 일관성을 크게 높여주고, 다양한 신호 조합에서도 일정한 형식의 문장을 생성하도록 유도하는 데 효과적이다. Forecast 문단, Summary 문단, SST anomaly 분석, 기술지수(HSS) 설명 등 Outlook을 구성하는 서로 다른 문단들은 각각 목적과 요구하는 톤이 다르므로, 이들 문단마다 별도의 prompt header가 준비되었다. 각 header는 서로 다른 표현 규칙을 가지지만 공통적으로 모델의 임의 해석을 제한하는 구조를 유지하며, 신호 리스트는 단순히 재배열되고 문장화되는 과정만 수행하도록 설계되었다.

한편 ENSO 관련 일부 문단의 경우에는 구조적 접근이 조금 달랐다. Nino3.4 지수, ENSO alert status, ENSO 발생 확률과 같은 항목들은 별도의 신호 탐지 알고리즘을 거치지 않고, 관측·예측 데이터를 직접 읽어 텍스트 형태로 정리한 뒤 prompt header에 삽입하였다. 이러한 수치는 해석이 단순하고 정보 구조가 명확하기 때문에, LLM이 이 데이터를 근거로 하나의 간결한 설명 문단을 생성하도록 하는 방식이 가장 효율적이었다. 따라서 ENSO 문단에서는 “data → 간단한 텍스트 → header와 결합 → 문장 생성”이라는 비교적 단순한 흐름을 유지하되, 문체와 서술 강도는 다른 문단과 동일하게 header 규칙에 의해 통제되도록 하였다.

```

Write one very short sentence summarizing the following ENSO probability forecast
(the most probable state of ENSO and its probability) result for coming seasons.
- DO NOT replace month ranges (e.g., "December-February") with words like "winter" or
"summer".
- These ranges refer to forecast periods covering both hemispheres.
- Keep month ranges exactly as written in the input.
- Start with mentioning the most probable ENSO phase and its probability and describe
notable change until the end and finish with description of the last season.
- Do not say what you did
Results:
NDJ: La Niña (60.0%)
DJF: La Niña (48.3%)
JFM: Neutral (57.0%)
FMA: Neutral (59.5%)

```

Figure 4.51. Example of LLM prompt for ENSO probability forecast. Prompt consists of header and signals (after “Results:”)

전체적으로 prompt header 기반 입력 구조는 Outlook 문서의 다양한 구성 요소가 서로 다른 목적을 지니고 있음에도 불구하고, 문서 전체의 통일성과 형식적 안정성을 확보하는 데 매우 효과적인 방식이 되었다. 헤더가 요구하는 문장 형식과 제한 조건이 명확했기 때문에, LLM은 신호 조합이 크게 달라지더라도 일정한 문체와 단락 구조를 유지하였고, 모델 출력의 변동성도 크게 낮아졌다. 또한 신호 탐지 단계에서 만들어지는 텍스트 파일은 prompt header와 독립적으로 유지되므로, 신호 탐지 알고리즘이 변경되거나 지역 정의가 조정되더라도 prompt 구조는 그대로 활용할 수 있어 장기적 운영에서도 유연성을 갖는다.

```

La Niña is the most probable ENSO phase, with a probability of 60.0% in NDJ,
decreasing to 48.3% in DJF, before shifting to a neutral phase with 57.0% and 59.5%
probabilities in JFM and FMA, respectively, indicating a notable decrease in La Niña
probability from NDJ to DJF

```

Figure 4.52. Description of ENSO probability forecast generated by LLM

이러한 프롬프트 설계와 적용 방식을 거쳐 생성된 자연어 결과물은 각각의 문단별로 독립된 텍스트 파일 형태로 저장되며, Outlook 생산 파이프라인의 다음 단계에서 LaTeX 문서 조립 과정에 자동으로 삽입된다. 결국 LLM은 Outlook 문서 구성의 최종 서술 단계가 담당하던 반복적이고 시간이 많이 소요되는 작업을 대체하게 되었고, 전체 생산 흐름은 신호 탐지-프롬프트 생성-LLM 출력-문서 조립이라는 구조적이고 자동화된 체계를 갖추게 되었다.

4.3.8. LaTeX 기반 Outlook 문서 자동 생성 체계 구축

계절예측 Outlook 자동화의 마지막 단계는 탐지된 신호와 LLM이 생성한 서술 결과물을 기존 Outlook 문서 형식에 맞추어 통합하는 과정이다. 본 연구에서는 문서 작성의 일관성을 확보하고 수작업 편집을 최소화하기 위해 LaTeX 기반의 자동 조립 시스템을 구축하였다. 여기에서 중요한 원칙은 새로운 형식을 창출하거나 시각적 요소를 재설계하는 것이 아니라, 기존 Outlook 문서가 유지해 온 구조·레이아웃·표현 방식에 최대한 가깝도록 LaTeX 템플릿을 구성하는 것이었다. 즉, LaTeX 템플릿의 목적은 문서의 재디자인이 아니라 기존 제품의 형식을 정확하게 복제하고 기계적으로 갱신할 수 있도록 만드는 것이었다.

이를 위해 먼저 Outlook 문서 전체를 구성하는 요소들을 세분화하였고, 각 요소를 기존 문서의 구성에 맞추어 LaTeX 내에서 대응되는 구조로 재현하였다. 표지 페이지, 요약(Summary), ENSO 분석, SST 분포 설명, 기온 및 강수 예측, 부록 형태의 월별 예측 그래픽 등 기존 문서에서 사용되던 순서와 구성을 그대로 유지하였다. 본문을 여러 파일로 분리해 구성한 것은 운영을 용이하게 하기 위함이지, 문서 구조를 변경하기 위한 조치가 아니었다. 이 방식은 LLM이 생성한 문장이나 월별 그래픽 파일이 특정 위치에 정확히 배치되어야 한다는 Outlook 특성에도 적합하다. 사용자는 생성된 텍스트 파일을 지정된 디렉토리에 배치하기만 하면, LaTeX 문서가 기존 Outlook과 동일한 구조를 자동으로 재현한다.

이미지 삽입 방식 역시 기존 Outlook 문서의 파일명 규칙을 그대로 따라가기 위해 설계되었다. 다만 매월 파일명이 바뀌는 예측 그래픽을 일일이 수정할 필요가 없도록, LaTeX 내에서 시즌 코드로부터 이미지 파일명을 자동으로 구성하는 매크로를 사용하였다. 예를 들어 사용자가 특정 시즌 코드를 입력하면, 그 코드에 대응되는 첫 번째·두 번째 시즌의 그래픽 파일 경로가 자동으로 생성되도록 설정하였다. 이 역시 문서의 시각적 형태를 바꾸기 위한 것이 아니라, 기존 Outlook 파일명 규칙에 맞는 이미지를 정확한 위치에 자동으로 삽입하기 위함이다.

문서의 레이아웃, margin, 글자 크기, 제목 형식, 색상 등은 기존 Outlook 문서의 형식을 가능한 한 그대로 따랐다. 일부 항목은 LaTeX 환경상 동일한 표현이 불가능하여 기술적으로 근접한 형식으로 재현되었으나, 기본적인 구성과 시각적 구조는 원본 Outlook 문서를 따르는 것을 원칙으로 삼았다. 특히 표지 페이지는 새로운 디자인을 도입한 것이 아니라, 기존 Outlook 표지에 포함된 요소(제목 배치, 발행 시기, 로고, 배경 요소 등)를 LaTeX 내에서 기술적으로 동일하게 재구성한 것이다. Summary 페이지 또한 기존의 설명 형식, 워딩의 간결함, 그래픽 배치 규칙 등을 그대로 유지하도록 설계되었으며, LaTeX 템플릿은 이를 반복적으로 재현하는 역할을 수행한다.

자동화의 실질적 핵심은 LLM이 생성한 자연어 결과물과 그림 파일을 수동 편집 없이 문서 조립 단계로 연결하는 것이다. 이를 위해 LaTeX 템플릿은 `\input{}` 구조를 사용해 텍스트 파일을 그대로 불러오며, 해당 파일 이름과 위치는 매월 동일한 규칙을 따르도록 설정하였다. 이로써 LLM이 생성한 문단이 텍스트 파일로 저장되기만 하면, 문서 내부에서 해당 위치에 자동으로 삽입된다. Season 정보, 발행 연월, 설명에 필요한 기간 단위(예: “April-June”) 등 메타데이터 역시 사용자가 별도 수정하지 않아도 자동으로 생성되도록 정리하였다.

LaTeX 문서를 최종적으로 PDF로 컴파일하는 과정은 Shell 스크립트(build.sh)를 통해 자동화하였다. 사용자는 단순히 시즌 코드와 언어(영문/국문)를 지정하면 되며, 스크립트는 필요한 텍스트 파일과 그래픽 파일을 읽어 LaTeX 문서를 컴파일해 최종 Outlook 문서를 생성한다. 빌드 시스템의 목적은 생산자의 의사결정을 줄이는 것이 아니라, 기존 Outlook 형식이 매월 동일하게 재현되도록 보장하는 것이다.

결과적으로 본 연구에서 구축된 LaTeX 자동화 체계는 Outlook 문서의 형태를 변경하거나 재해석하는 것이 아니라, 기존 Outlook 문서의 형식적 요구사항을 충실히 재현하면서도 반복 작업을 자동화하는 데 의의를 둔다. 이 시스템은 신호 탐지-LLM 텍스트 생성-문서 조립으로 이어지는 전체 워크플로우를 하나의 연결된 자동 과정으로 통합하며, Outlook 생산의 안정성과 반복 가능성을 크게 향상시켰다.

4.3.9. 통합 자동화 파이프라인 구축

앞선 장들에서 신호 탐지, 지역 마스크 구성, 오프라인 LLM 적용, LaTeX 템플릿 설계까지 각각의 구성요소를 분리해서 살펴보았다면, 이 절에서는 이 모든 요소를 하나의 작업 흐름으로 묶어 주는 통합 자동화 파이프라인에 대해 정리한다. 이 파이프라인은 하나의 셸 스크립트로 구현되어 있으며, 사용자는 시즌 정보만 지정하면 데이터 읽기, 신호 탐지, 자연어 문장 생성, LaTeX 조립과 PDF 생성까지의 전 과정을 한번에 수행할 수 있다. 즉, 사람이 하던 “여러 개의 산발적인 작업 단계” 를 하나의 재현 가능한 배치 작업으로 통합한 것이며, 현재는 Pacific Islands Outlook 생산을 대상으로 구축되어 있다.

파이프라인의 입력은 매우 단순하다. season.info 파일에 예를 들어 2025 NDJ와 같이 연도와 시즌 코드를 한 줄로 명시하면, 스크립트는 이를 읽어 1번째 시즌과 2번째 시즌 코드를 계산하고, 각 시즌에 대응되는 세 달의 실제 월 이름과 연도(예: “November 2025 - January 2026” , “February 2026 - April 2026”)를 자동으로 생성한다. 이 과정에서 시즌 코드 간 관계(예: NDJ 다음은 FMA 등)를 미리 정의해 두고, 이를 이용해 3개월씩 이동한 다음 시즌을 구하는 로직이 포함되어 있다. 또한 첫 달 약어(NOV, FEB 등)를 이용해 예보·검증 데이터가 저장된 디렉터리 경로를 자동으로 구성하고, 설정된 디렉터리 구조를 기준으로 각종 NetCDF 파일(t2m.nc, prec.nc, ENSO 관련 파일 등)의 위치를 자동으로 찾아낸다. 이렇게 해서 ENSO, 예측, 검증(HSS) 각 블록에서 사용할 데이터 파일 경로가 모두 할당된다.

그 다음 단계에서는 Python 기반 신호 탐지 모듈과 ENSO 관련 스크립트들이 차례로 호출된다. ENSO 블록에서는 ENSO alert, Nino3.4 시계열, ENSO 확률, 계절별 SST anomaly map을 읽어 각각 텍스트 형태의 요약 결과를 만든다. 일부 항목은 별도의 신호 탐지 알고리즘 없이 데이터에서 직접 파생되고, 일부는 앞에서 정의한 규칙에 따라 신호를 뽑아 텍스트로 정리된다. 이렇게 얻어진 ENSO 관련 텍스트들은 prompt header와 결합되어 LLM에 전달되고, LLM은 각 요소별 설명 문장을 생성한 뒤, 마지막에는 ENSO 전체를 요약하는 단락(ENSO SUMMARY)까지 자동으로 만들어낸다. 예측(FORECAST) 블록에서는 1·2번째 시즌의 기온(t2m)과 강수(prec) 예측 NetCDF 파일을 읽어 region/subregion 마스크에 따라 신호를 탐지하고, 앞 장에서 설명한 규칙에 따라 season1/season2, t2m/prec 각각에 대한 신호 리스트를 생성한다. 이 신호 리스트는 다시 forecast용 prompt header와 결합되어 LLM 호출을 통해 서술 문장으로 변환되

고, 두 시즌에 대한 예측 설명 문단과 온도·강수 요약 문단이 차례대로 생성된다. HSS 섹션 또한 유사한 구조를 따르는데, 검증 지수 파일을 읽어 지역별 skill 정보를 요약한 뒤, 전용 prompt header를 통해 LLM에 전달하여 검증 결과를 기술하는 단락을 생성한다. 이 과정에서 스크립트는 LLM 출력에 남아 있을 수 있는 제어문자, 줄바꿈, UTF-8 인코딩 문제 등을 정리하는 보정 함수도 함께 호출하여, 최종 텍스트 파일이 LaTeX에 바로 투입될 수 있는 상태가 되도록 정리한다.

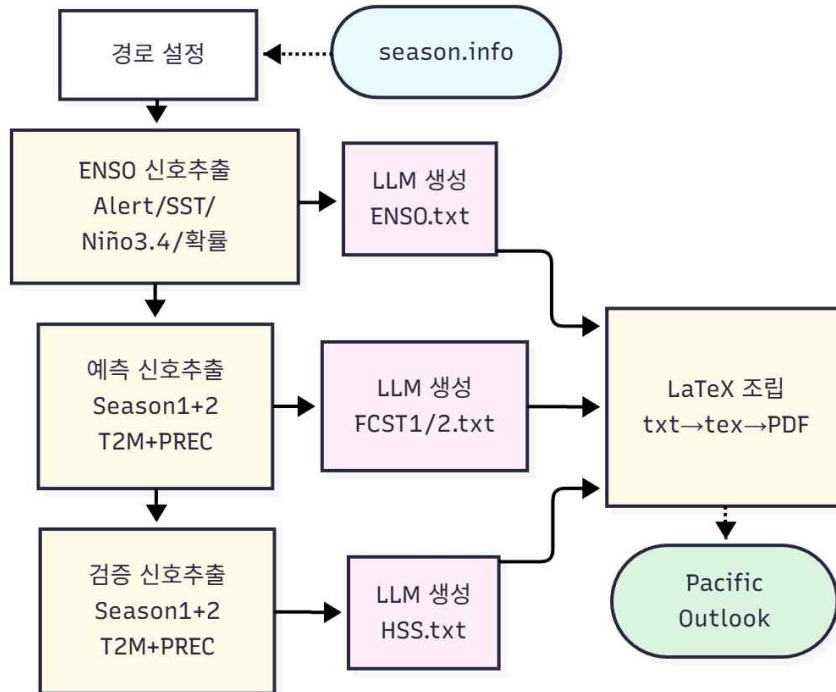


Figure 4.53. Process flow of integrated outlook generation script (build_outlook_script.sh)

이렇게 ENSO, 예측, 검증에 대해 생성된 텍스트 결과물은 지정된 출력 디렉터리에 ENSO.txt, FCST_SEASON1.txt, FCST_SEASON2.txt, HSS.txt, FCST_SUMMARY_T2M.txt, FCST_SUMMARY_PRE.txt 등 정해진 파일명으로 저장된다. 파이프라인의 마지막 단계에서는 이 텍스트 파일들을 LaTeX 작업 디렉터리의 txt 폴더로 복사하고, 텍스트→TeX 변환 스크립트와 매크로 생성 스크립트를 순서대로 실행한다. 그 결과 ENSO, forecast, summary, HSS 등의 각 섹션에 대응하는 .tex 파일이 자동으로 생성되고, 시즌 코드와 연도에 맞는 LaTeX 메인 파일 이름이 만들어진다. 이어서 XeLaTeX을 두 번 실행함으로써 교차 참조와 목차 등을 안정적으로 반영한 최종 Pacific Islands Outlook PDF가 생산된다. 사용자의 입장에서 보면, 시즌 정보만 업데이트한 뒤 이 셸 스크립트를 한 번 실행하는 것만으로, 데이터 읽기부터 신호 탐지, 자연어 서술 생성, 문서 조립과 PDF 생성까지 전체 작업이 순차적으로 완료되도록 구성된 셸이다.

이 통합 자동화 파이프라인의 구축으로, 그동안 여러 사람이 나누어 수행하던 다단계 작업이 하나의 일관된 배치 프로세스로 정리되었다. 각 단계는 여전히 개별 Python 스크립트와 LaTeX 템플릿, 오프라인 LLM에 의해 수행되지만, 셸 스크립트가 이들을 중간에 꿰뚫어 연결함으로써, 재현성과 효율성이 동시에 확보되었다. 또한 특정 단계에서 알고리즘이나 템플릿이 개선되더라도, 통합 스크립트의 인터페이스는 유지되므로, 전체 시스템을 매번 다시 설계할 필요 없이 부분적인 교체와 업그레이드가 가능하다. 이러한 구조는 향후 Pacific Outlook뿐 아니라 다른 지역·제품으로 확장할 때에도 동일한 자동화 프레임워크를 재사용할 수 있는 기반을 제공한다.

4.3.10. 요약 및 의의

본 보고서에서 제시한 Outlook 자동화 체계는 기존의 수작업 중심 생산 과정이 갖고 있던 구조적 한계와 비효율성을 해소하고, 예측-해석-서술-문서화의 전 과정을 하나의 재현 가능한 데이터 기반 워크플로우로 통합하려는 시도였다. 지역 정의, 신호 탐지 규칙, 서술 구조는 모두 기존 Outlook 문서의 형식·논리를 유지하되, 이를 정량적 기준과 자동화 가능한 알고리즘으로 재구성하여 담당자 의존도를 최소화하는 것을 목표로 삼았다. 특히 Pacific Islands Outlook을 대상으로 한 시범 구축을 통해, 확률 예측 신호와 SST 패턴의 정량적 판독, 지역별 기술 판단, LLM 기반 자연어 생성, LaTeX 문서 자동 조립이 서로 꿰뚫어 연결되는 생산 파이프라인을 실현하였다. 실제 적용 결과 기존에는 수작업으로 1시간 이상이 소요되던 Outlook 생산 시간이 3분 남짓한 시간내에 완료될 수 있었다.

본 시스템은 완결형 자동화의 방향성을 제시하지만, 동시에 남아 있는 과제도 분명하다. 우선, LLM이 생성하는 자연어 문장은 높은 일관성을 보이지만, 특정 상황에서는 여전히 문맥 조정이나 어휘 선택의 미세한 보완이 필요할 수 있다. 이는 Outlook 문서 특유의 간결한 문체와 표현 규칙을 완전히 기계적으로 재현하는 데에 남아 있는 불가피한 영역이며, 향후 prompt header의 조정이나 텍스트 후처리(post-processing) 모듈을 추가함으로써 안정성을 높일 수 있을 것이다. 또한 신호 탐지 알고리즘 역시 파라미터 설정에 따라 결과가 일부 달라질 수 있기 때문에, 예측 시스템의 특성과 사용자 요구에 맞는 지속적인 보정 작업이 필요하다. 그러나 이는 임의적 편집이 아니라 명시된 규칙과 수치적 기준을 기반으로 이루어지는 조정이라는 점에서, 기존의 주관적 해석과 비교할 때 훨씬 높은 투명성과 재현가능성을 가진다.

이러한 점을 감안하면, 본 연구에서 구축한 자동화 체계는 단순히 문서 생산 시간을 줄이는 기술적 도구를 넘어, 계절예측 Outlook을 보다 객관적이고 재현가능한 형태로 전환하는 중요한 전환점이라고 할 수 있다. 신호 탐지 기준은 명확히 정의되고, LLM은 동일한 구조의 문장을 안정적으로 생성하며, LaTeX 템플릿은 매월 동일한 형식의 문서를 보장한다. 담당자의 교체나 운영 환경 변화에도 흔들리지 않는 Outlook 생산 체계를 갖추었다는 점에서, 기관적·서비스적 지속가능성 또한 크게 향상되었다. 향후 본 시스템은 Pacific Islands Outlook을 넘어 Global Outlook, Korean Outlook 등 다른 outlook에도 확장될 수 있으며, 신호 탐지 로직과 LLM 출력을 개선하고, 사용자 요구에 맞춘 맞춤형 요약 및 도식화 기능과 결합한다면, 계절예측 정보의 활용성과 접근성을 더욱 높일 수 있을 것이다.

종합하면, 본 자동화 시스템은 “Outlook 생산의 일상적 부담을 줄이는 기술적 도구”를 넘어, 기후정보 서비스의 방식 자체를 데이터 기반·규칙 기반·재현 가능한 구조로 바꾸는 기반이라고 할 수 있다. 이러한 변화는 향후 기후서비스의 품질, 신뢰성, 지속가능성을 높이는 기반이 될 것이다.

4.4. ENSO 경보시스템 개선

4.4.1. 배경 및 목적

아태기후센터(APCC)는 NINO3.4(Nino3.4 지역(5S~5N, 170W~120W) 해수면 온도 편차의 영역 평균) 지수, ONI (Oceanic NINO index; 3개월 평균 Nino3.4 지수) 지수, MME 예측 결과 등을 이용한 민감도 실험(강도, 지속 기간 등)을 통해 주관적 해석을 배제하고 객관적 정보 위주의 ENSO (El Nino-Southern Oscillation) 사전경보 기준 도출을 수립하여 2020년 11월부터 3단계 경보(주의 → 경계 → 엘니뇨/라니냐)를 제공하였고, 2022년 4월부터 기존의 경보 기준을 재검토하여 감시보다는 사전 경보로서의 기능을 강화하여 ENSO 경보를 제공하고 있다.

그러나 현 ENSO 경보시스템은 ENSO의 발달(developing) 및 쇠퇴(decaying) 과정과 관계없이 ENSO의 발달기와 쇠퇴기에 동일한 기준 조건을 적용하여 엘니뇨와 라니냐 각각에 대해 3단계 경보를 제공하고 있다. 이러한 차이를 고려하지 않을 경우, ENSO 발달 단계별 위험 인지 및 대응 체계에 대한 시의성과 신뢰도가 제한될 수 있다는 점이 지적되었다. 따라서 ENSO 경보 기준을 재검토하여 ENSO의 시간적 진화(발달기와 쇠퇴기) 양상을 반영한 것보다 정교한 경보 체계로 개선을 통해 APCC ENSO 경보의 과학적 타당성과 활용성을 증진할 필요가 있다.

4.4.2. 자료 및 방법

APCC ENSO 경보시스템에서 사용된 자료는 기본적으로 개선 전의 경보시스템과 동일하다. 예측 발표 달(Issued month)에서부터 과거 6개월까지 관측된 NOAA OISST 자료로 계산된 ONI와 NINO3.4 지수를 입력자료로 사용하고, APCC MME에서 예측된 향후 6개월간의 ONI와 NINO3.4의 확률 강도를 이용하여 매달 ENSO 발달 상황을 엘니뇨/라니냐 주의, 엘니뇨/라니냐 경계, 엘니뇨/라니냐 7단계 카테고리 분류한다.

Table 4.14는 ENSO 경보시스템의 기준의 개선 전과 후를 비교한 표이다. 기존 시스템에서는 엘니뇨 및 라니냐의 발달과 쇠퇴 구분이 명확히 정의되지 않아, ENSO 이벤트가 종료 단계에 접어들더라도 경보가 단계적으로 축소·하향 발표되는 방식으로 운영되었다. 이로 인해 사용자 입장에서는 실제 ENSO 사건의 진행 상황과 경보 체계 간 불일치가 발생하거나, 쇠퇴기 해석 과정에서 혼란이 야기될 가능성이 존재하였다.

그러나 개선된 기준에서는 ONI의 시간적 변화를 반영하여 기울기(slope) 조건을 추가하여 ENSO 발달 및 쇠퇴 단계를 명확히 구분하였다. 가장 최근 1개월간 ONI와 향후 예측된 1개월간 ONI의 차이를 계산하여 엘니뇨와 라니냐 각각 그 기울기의 부호에 따라 쇠퇴기와 발달기를 구분하였다. 이에 따라 먼저 엘니뇨 및 라니냐가 발달 또는 쇠퇴 단계를 먼저 구분하고 발달 단계에서는 ‘주의(Watch)’, ‘경계(Alert)’, ‘엘니뇨/라니냐’로 이어지는 체계적 경보 발령을 하고, 쇠퇴 단계에서는 ‘엘니뇨 종결’ 또는 ‘라니냐 종결’ 경보를 제공하도록 조건문이 개선되었다. 이를 통해 특히 엘니뇨 및 라니냐 피크 이후에는 더 이상 ‘주의’나 ‘경계’ 단계로의 단계적 축소가 아닌 명확한 종결 경보로 발표됨으로써 사건 종료를 직관적으로 전달할 수 있게 되었다.

Table 4.14. Comparison of the ENSO Alert system criteria before and after the revision.

	기존	변경
ENSO 발달과 쇠퇴기 구분	없음	<ul style="list-style-type: none"> - 가장 최근 1개월간 ONI와 향후 예측된 1개월간 ONI의 차이(slope)를 계산¹⁾ • (엘니뇨 경보 3단계) <ul style="list-style-type: none"> - slope<0 : 엘니뇨 쇠퇴 - slope>0 : 엘니뇨 발달 • (라니냐 경보 3단계) <ul style="list-style-type: none"> - slope>0 : 라니냐 쇠퇴 - slope<0 : 라니냐 발달 - 최근 1개월간 ONI 계산²⁾
El Niño Watch (주의)	(관측) 최근 1개월간 NINO3.4 구역의 SST가 평년보다 0.5°C 이상, 최근 1개월간 ONI가 중립 (예측) 향후 4개월 중 2개월이라도 NINO3.4 구역의 SST가 0.5°C 이상이거나, 연속 3개월간 50% 이상의 확률로 엘니뇨 상태 전망	- 엘니뇨 발달 단계이고, (관측) 최근 1개월간 NINO3.4 구역의 SST가 평년보다 0.5°C 이상, 최근 1개월간 ONI가 중립 (예측) 향후 4개월 중 2개월이라도 NINO3.4 구역의 SST가 0.5°C 이상이거나, 연속 3개월간 50% 이상의 확률로 엘니뇨 상태 전망
	Definition: 최근 1개월에 SST가 0.5°C 이상 상승, 향후 3-4개월 이내에 엘니뇨 발생 가능성이 50% 이상	Definition: 최근 1개월에 SST가 0.5°C 이상 상승, 향후 3-4개월 이내에 엘니뇨 발생 가능성이 50% 이상
El Niño Alert (경계)	(관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 0.5°C 이상, 최근 1개월간 ONI가 0.5°C 이상 (예측) 향후 2개월간 ONI가 0.5°C 이상이거나, 연속 3개월간 60% 이상의 확률로 엘니뇨 상태 전망	- 엘니뇨 발달 단계이고, (관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 0.5°C 이상, 최근 1개월간 ONI가 0.5°C 이상 (예측) 향후 2개월간 ONI가 0.5°C 이상이거나, 연속 3개월간 60% 이상의 확률로 엘니뇨 상태 전망
	Definition: 최근 2-3개월에 SST가 0.5°C 이상 상승, 향후 3-4개월 이내에 엘니뇨 발생 가능성이 60% 이상	Definition: 최근 2-3개월에 SST가 0.5°C 이상 상승, 향후 3-4개월 이내에 엘니뇨 발생 가능성이 60% 이상
El Niño (엘니뇨)	(관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 0.5°C 이상, 최근 1개월간 ONI가 0.5°C 이상 (예측) 향후 연속 3개월간 ONI가 0.5°C 이상 전망	- 엘니뇨 발달 단계이고, (관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 0.5°C 이상, 최근 1개월간 ONI가 0.5°C 이상 (예측) 향후 연속 3개월간 ONI가 0.5°C 이상 전망 단, 엘니뇨 쇠퇴 단계이고, 최근 1개월간

		ONI가 0.5°C 이상 및 엘니뇨 주의/경계 조건을 만족할 때 엘니뇨로 정보 종결
	Definition: 최근 2-3개월에 SST가 0.5°C 이상 상승, 향후 3개월 동안 엘니뇨 지속 전망	Definition: 최근 2-3개월에 SST가 0.5°C 이상 상승, 향후 3개월 동안 엘니뇨 지속 전망
Inactive 중립	향후 6개월 이내에 엘니뇨/라니냐 발달에 대해 설정된 정보 기준을 만족하지 않을 것으로 전망	향후 6개월 이내에 엘니뇨/라니냐 발달에 대해 설정된 정보 기준을 만족하지 않을 것으로 전망
	Definition: 향후 6개월 이내에 엘니뇨 혹은 라니냐의 발달 가능성이 없을 것으로 전망	Definition: 향후 6개월 이내에 엘니뇨 혹은 라니냐의 발달 가능성이 없을 것으로 전망
La Niña Watch (주의)	(관측) 최근 1개월간 NINO3.4 구역의 SST가 평년보다 -0.5°C 이하, 최근 1개월간 ONI가 중립 (예측) 향후 4개월 중 2개월이라도 NINO3.4 구역의 SST가 -0.5°C 이하이거나, 연속 3개월간 50% 이상의 확률로 라니냐 상태 전망	- 라니냐 발달 단계이고, (관측) 최근 1개월간 NINO3.4 구역의 SST가 평년보다 -0.5°C 이하, 최근 1개월간 ONI가 중립 (예측) 향후 4개월 중 2개월이라도 NINO3.4 구역의 SST가 -0.5°C 이하이거나, 연속 3개월간 50% 이상의 확률로 라니냐 상태 전망
	Definition: 최근 1개월에 SST가 0.5°C 이상 하강, 향후 3-4개월 이내에 라니냐 발생 가능성이 50% 이상	Definition: 최근 1개월에 SST가 0.5°C 이상 하강, 향후 3-4개월 이내에 라니냐 발생 가능성이 50% 이상
La Niña Alert (경계)	(관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 -0.5°C 이하, 최근 1개월간 ONI가 -0.5°C 이하 (예측) 향후 2개월간 ONI가 -0.5°C 이하이거나, 연속 3개월간 60% 이상의 확률로 라니냐 상태 전망	- 라니냐 발달 단계이고, (관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 -0.5°C 이하, 최근 1개월간 ONI가 -0.5°C 이하 (예측) 향후 2개월간 ONI가 -0.5°C 이하이거나, 연속 3개월간 60% 이상의 확률로 라니냐 상태 전망
	Definition: 최근 2-3개월에 SST가 0.5°C 이상 하강, 향후 3-4개월 이내에 라니냐 발생 가능성이 60% 이상	Definition: 최근 2-3개월에 SST가 0.5°C 이상 하강, 향후 3-4개월 이내에 라니냐 발생 가능성이 60% 이상
La Niña (라니냐)	(관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 -0.5°C 이하, 최근 1개월간 ONI가 -0.5°C 이하 (예측) 향후 연속 3개월간 ONI가 -0.5°C 이하 전망	- 라니냐 발달 단계이고, (관측) 최근 2개월간 NINO3.4 구역의 SST가 평년보다 -0.5°C 이하, 최근 1개월간 ONI가 -0.5°C 이하 (예측) 향후 연속 3개월간 ONI가 -0.5°C 이하 전망 단, 라니냐 쇠퇴 단계이고, 최근 1개월간 ONI가 -0.5°C 이하 및 라니냐 주의/경계

		조건을 만족할 때 라니냐로 경보 종결
	Definition: 최근 2-3개월에 SST가 0.5°C 이상 하강, 향후 3개월 동안 라니냐 지속 전망	Definition: 최근 2-3개월에 SST가 0.5°C 이상 하강, 향후 3개월 동안 라니냐 지속 전망

4.4.3. 결과

Figure 4.54는 APCC를 포함한 태평양 지역기후센터³⁾ ENSO Tracker 참여기관⁴⁾의 최근 11년간 (2014년 01월~2024년 12월) ENSO 경보 및 NINO3.4 및 SOI 지수를 나타낸 결과이다. 그림 상단에서 ‘APCC’는 기존의 경보 기준, ‘APCC_NEW’는 개선된 경보 기준을 적용한 경보 결과인데, 최근 11년 간의 사례에서 살펴보면 하면 기존에 엘니뇨/라니냐의 쇠퇴기에(화살표 표기) 단계적으로 감소하여 발표된 “경계”, “주의” 경보가 화살표로 표기된 시점과 같이 “엘니뇨”, “라니냐” 경보로 변경 발표되는 차이를 확인할 수 있다.

1) ONI 차이(slope) = 가장 최근 1개월 예측 ONI - 가장 최근 1개월 관측 ONI

2) $ONI \geq 0.5^{\circ}C$: 엘니뇨, $ONI \leq -0.5^{\circ}C$: 라니냐

3) 태평양 지역기후센터: Pacific Regional Climate Center

4) BOM(Bureau of Meteorology, 호주 기상청), NIWA(National Institute of Water and Atmospheric Research, 뉴질랜드 해양연구소), NOAA(National Oceanic and Atmospheric Administration, 미국 기상청)




Figure 4.54. (Top) ENSO alert from other institutions and APCC before(APCC) and after revision (APCC_NEW), (Middle) NINO3.4, and (Bottom) SOI index. (Period: 2014.01.-2024.12.)

또한 현 태평양 지역기후센터 ENSO Tracker에 표출되는 APCC ENSO 경보(Figure 4.55)에 (기간: 2023.08.~2025.07.) 변경된 기준을 적용하면 2023-2024년 겨울(2024 JF기간)에 발생한 엘니뇨에 대한 “주의” 경보가 “엘니뇨” 경보로 변경 발표되는 차이를 확인 할 수 있다. 이러한 개선은 해수면 온도의 시간적 변화를 나타내는 ONI의 변동을 탐지하고 이를 ENSO의 발달 및 쇠퇴 과정에 반영하는 조건을 추가함으로써 가능해졌다. 이를 통해 개선된 시스템은 ENSO의 발달기부터 피크(peak), 그리고 쇠퇴 및 종료에 이를 전 과정을 보다 일관되게 묘사할 수 있게 되었으며, 특히 이벤트 종료 이후에도 명확한 종결 경보를 제공함으로써 이전 시스템의 한계를 보완하였다.

개선된 ENSO 경보시스템은 2025년 10월 예보부터 반영되어 APCC 홈페이지와 기후전망을 통해 기존과 같이 월 2회(15일 및 말일) 제공되고 있으며 태평양 지역기후센터 ENSO Tracker에도 매월 제공되고 있다.




Figure 4.55. ENSO alerts, NINO3.4 and SOI index from other institutions and APCC as displayed in the Pacific Regional Climate Centre ENSO Tracker (Top: before the revision of criteria, Bottom: after the revision, period: 2023.08~2025.07).

4.4.4. 요약 및 결론

ENSO 경보시스템 개선을 통해 사용자가 ENSO 경보를 해석하는 과정에서 혼선을 줄이고, 실제 기후 현상을 반영한 경보 제공으로 경보의 직관적 이해와 활용도를 높이는 데 기여할 것으로 기대된다.

그리고 향후 고려되어야 할 사항으로는 현재 개선된 경보시스템은 ENSO 발달 및 쇠퇴 과정을 반영하도록 설계되었으나, 강도가 약한 엘니뇨/라니냐가 발생할 경우, 경보가 민감하게 반응하여 쇠퇴기에 경보가 바로 종결되지 않고 Figure 4.54의 2018년 2월 ~ 2018년 3월 기간의 경보와 같이 “경계” 경보를 거쳐 다시 “엘니뇨”, “라니냐” 경보로 전환된 후 종결되는 사례가 있다. 따라서 이러한 한계점을 극복하기 위해서는 NINO3.4 외 다각적인 지표 및 접근 방법을 고려하여 보다 안정적이고 일관성 있는 경보를 제공하는 방안 모색이 필요하다.

5. BSISO 계절내예측시스템 운영 및 개선

5.1. BSISO 계절내예측시스템 운영

5.1.1. 배경 및 목적

여름철 계절내 진동(BSISO, Boreal Summer Intraseasonal Oscillation)은 15~60일 주기로 적도 인도양에서 발생하여 점진적으로 북동진하며 아시아지역의 여름 몬순과 대기 순환, 날씨에 영향을 주는 대규모 대류현상이다. APCC는 아시아지역의 BSISO 지수의 감시 및 예측정보를 매년 5~10월의 기간에 홈페이지를 통해 제공하고 있다. 예측운영과에서는 매년 5월부터 10월까지 매일 BSISO 현업시스템을 운영하고 실시간 현업 모니터링을 통해 안정적인 서비스를 제공하였다.

5.1.2. 자료 및 방법

BSISO 계절내예측시스템의 입력장은 일별 OLR과 850hPa 수평바람장이 이용된다. 그러나 2013년 9월부터 기존에 사용하던 NOAA OLR 자료 제공 중단에 따라 2023년까지는 NOAA OLR 자료, 2024년 이후로 CPC blended OLR와 NCEP 850hPa 수평 바람장을 이용하여 북반부 여름철 5월에서 10월까지 매일 감시, 예측, 검증 BSISO 자료를 생산하고 홈페이지를 통해 실시간으로 제공되고 있다. Figure 5.1은 APCC BSISO 운영체계 및 현업 일정을 모식화 한 그림이다. 먼저 FTP 외부망을 통해 재분석자료 및 예측자료를 수집하고 1차 자료 품질확인을 거쳐 감시 및 예측 시스템에 입력되어 구동된다. 그리고 실시간 현업 모니터링과 함께 현업 일지를 작성하여 당일 현업 이슈를 기록한다. 재분석자료의 자료 수집은 제공기관에서 공식 자료 업데이트까지의 시간 지연이 있기 때문에 감시 기준 날짜는 현재 날짜 기준 평균 3일의 지연이 있으며 감시 날짜를 기준일로 하여 예측 및 검증 자료가 생산된다.

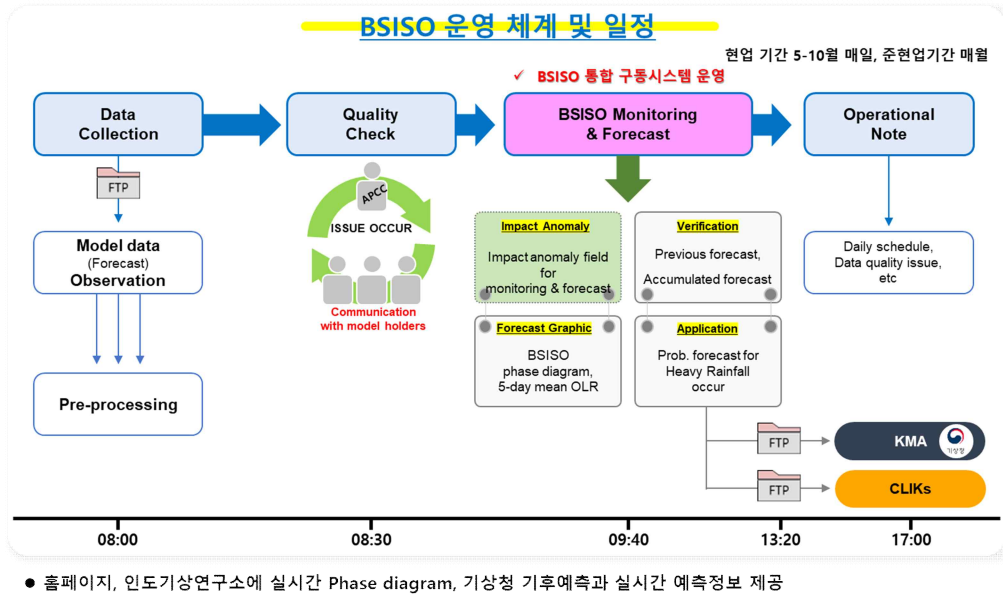


Figure 5.1. APCC BSISO operating system.

현재 BSISO 현업시스템의 예측 참여모델은 Table 2와 같다. 각 기관별로 NCEP에서 2개, 호주 기상청 1개, ECMWF 1개, 대만 기상청 1개 모델이 참여하여 총 5개의 참여모델 예측 자료를 이용하여 APCC BSISO 개별 모델 예측을 수행하고 있다. 그리고 올해 5월부터 CWA의 모델이 TCWB1T1.1에서 CWACFSv2로 변경되면서 수평 및 수직 해상도가 증가하였다.

Table 5.1. Participant model description of APCC BSISO forecast system.

Institute	Model	Ensemble Size	Forecast Period	Update frequency	Resolution
NCEP	Climate Forecast System	4	40 days	Once a day	T126 L64
	Global Forecast System	1	16 days	Once a day	T574, T190 L64
Australia	Australian Community Climate and Earth-System Simulator Seasonal 2	33	30 days	Once a day	N216 L85
ECMWF	ECMWF Ensemble Prediction System	101	40 days	Once a day	36km L137
CWA	CWA Climate Forecast System version 2	3	40 days	Every 5 days	TL359 L60

5.1.3. 결과

여름철 계절내 진동(BSISO, Boreal Summer Intraseasonal Oscillation)은 15~60일 주기로 적도 인도양에서 발생하여 점진적으로 북동진하며 아시아지역의 여름 몬순과 대기 순환, 날씨에 영향을 주는 대규모 대류현상이다. APCC는 아시아지역의 BSISO 지수의 감시 및 예측정보를 매년 5~10월의 기간에 홈페이지를 통해 제공하고 있다. 예측운영과에서는 매년 5월부터 10월까지 매일 BSISO 현업시스템을 운영하고 실시간 현업 모니터링을 통해 안정적인 서비스를 제공한다. 올해는 4월 21일부터 4월 30일까지 약 2주간 준 현업기간을 거쳐 현업시스템 구동의 안정성을 확보하고 5월 3일에 현업을 시작하였다.

BSISO 현업서비스의 주요 내용은 감시, 예측, 검증 정보가 있으며 BSISO 모드별, 기간별 평균 특징을 살펴볼 수 있는 합성장을 제공하고 있다(Figure 5.2 ~ Figure 5.7). 감시정보는 실시간 BSISO의 입력자료가 되는 가장 최신의 재분석자료의 날씨를 기준으로 현재 날씨보다 3일 전의 감시 자료가 생산되며, 생산되는 감시 콘텐츠로는 BSISO 지수를 포함하여 BSISO 위상도, 시계열, 재구성장, BSISO 영향 편차장, 상향장파복사 및 850hPa 수평바람 편차장이 있다. 생산된 모든 감시 정보는 홈페이지를 통해 실시간 제공되고 있다. BSISO 예측정보는 BSISO 감시날짜를 기반으로 생산되며 예측에는 총 4개 기관(NCEP, BOM, ECMWF, CWB)의 5개 개별 모델 자료가 이용된다. 생산되는 예측 콘텐츠로는 BSISO 예측 지수를 포함하여 BSISO 위상도, 상향장파복사 편차장, BSISO 영향 편차장, 극한강수 발생확률, 검증이 있다. 생산된 모든 예측 정보는 홈페이지를 통해 실시간 제공되고 있다. BSISO 합성장은 과거 30년 기간(1991-2020년, 단 강수의 경우 1997-2020년 자료를 사용) 동안 BSISO 강도가 강했을 때에 대해 2개 모드 및 8개 위상과 관련된 주요 변수를 합성한 것이다. BSISO 합성장은 같은 기후 기간 사용중에는 동일하며 BSISO에 대한 일반적인 변수들의 특징을 보여준다. BSISO 합성장은 BSISO 정의 페이지에 표출되고 있다. 또한 과거 BSISO 감시 및 예측 지수는 CLIK (CLimate Information toolKit; <http://cliks.apcc21.org>)을 통해 홈페이지에 제공되고 있고 실시간 BSISO 지수는 홈페이지 BSISO 메뉴 내 실시간 제공되고 있다.

BSISO

아래 그림은 BSISO 관련 변동성을 살펴보기 위해 과거 30년 기간(1991~2020년) 동안 강한 BSISO가 발생한 경우에 대해 2개의 모드 및 8개의 위상과 관련된 주요 변수의 합성장을 나타낸 것이다. (단, 강수의 경우 1997~2020년 자료를 사용하였음)

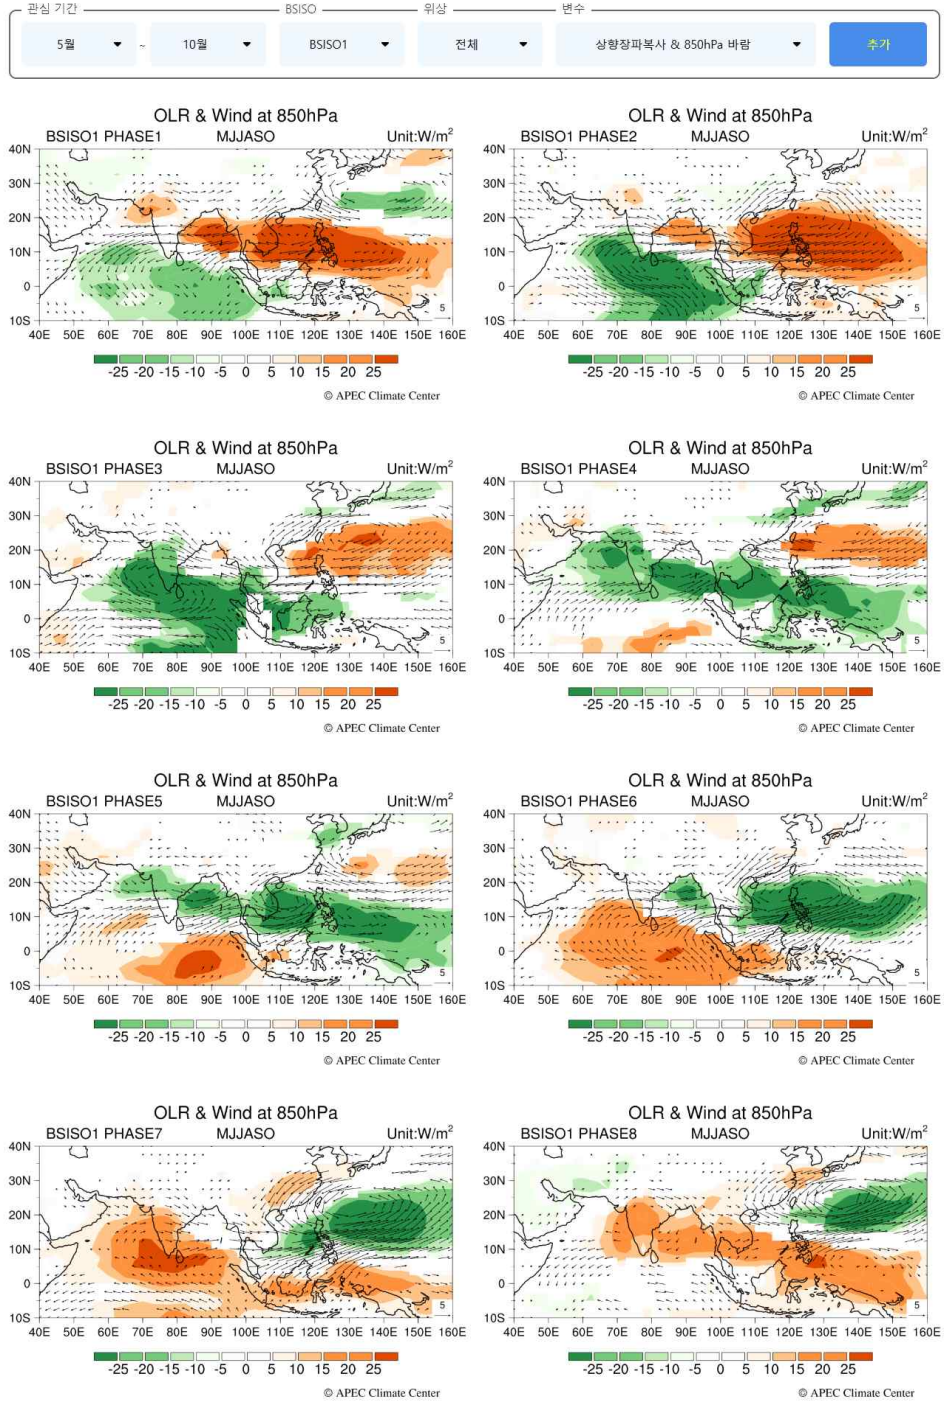


Figure 5.2. Example of BSISO composite map displayed on the website.

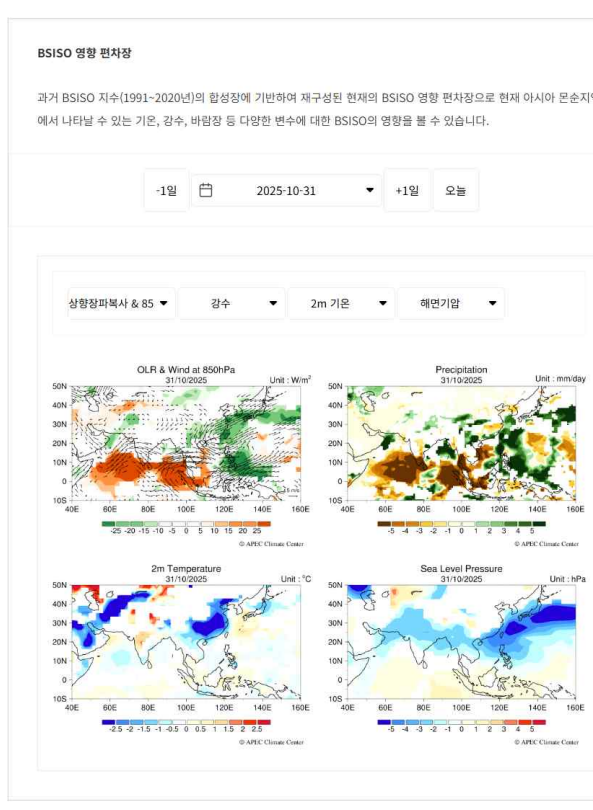
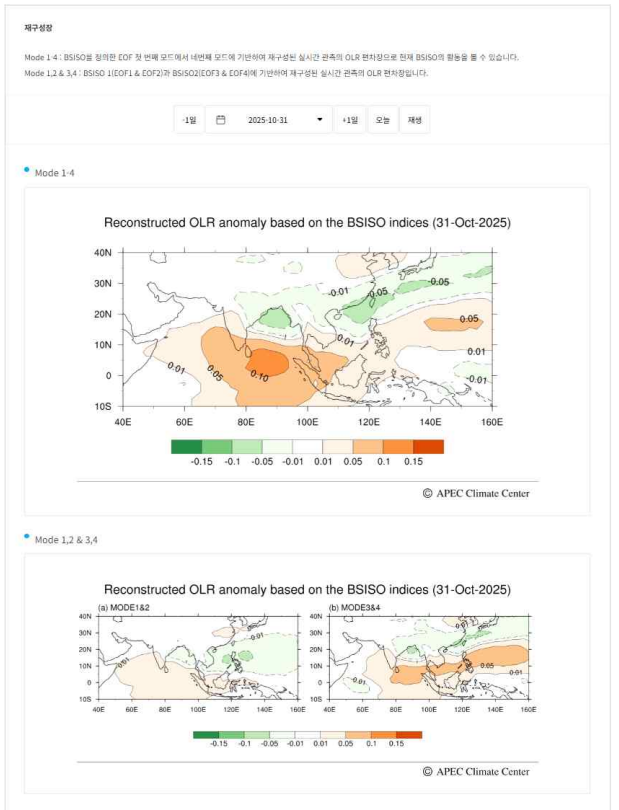
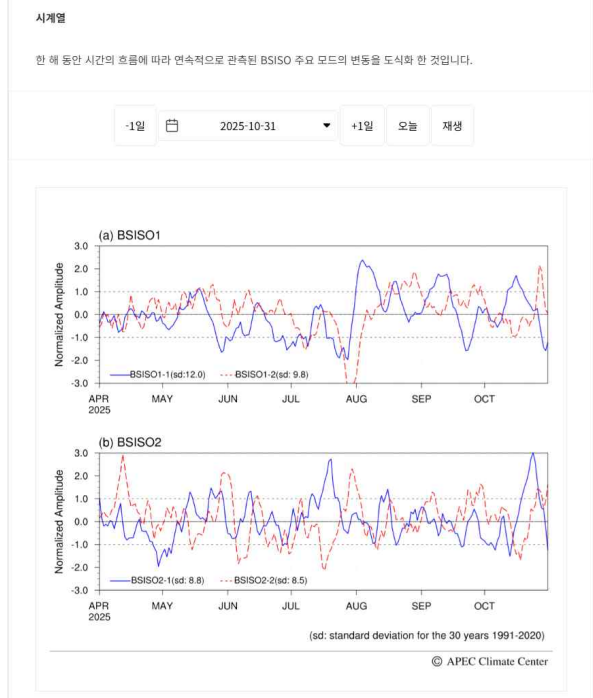
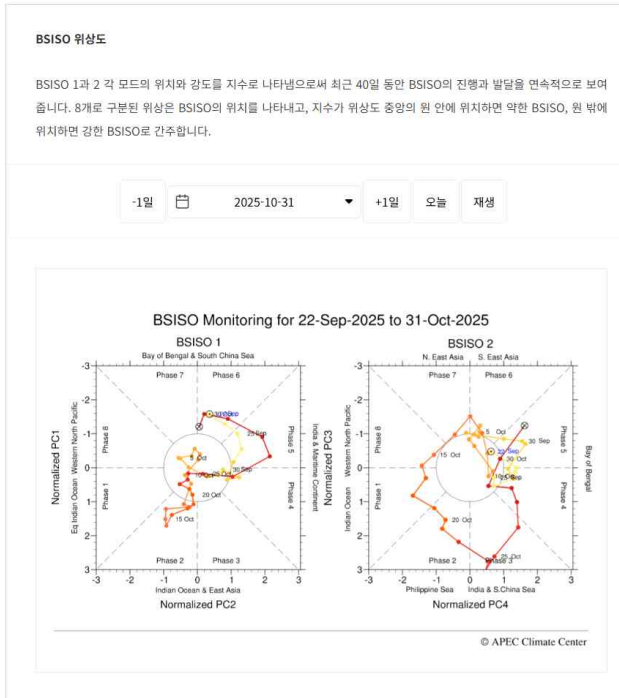


Figure 5.3. Contents of BSISO monitoring.

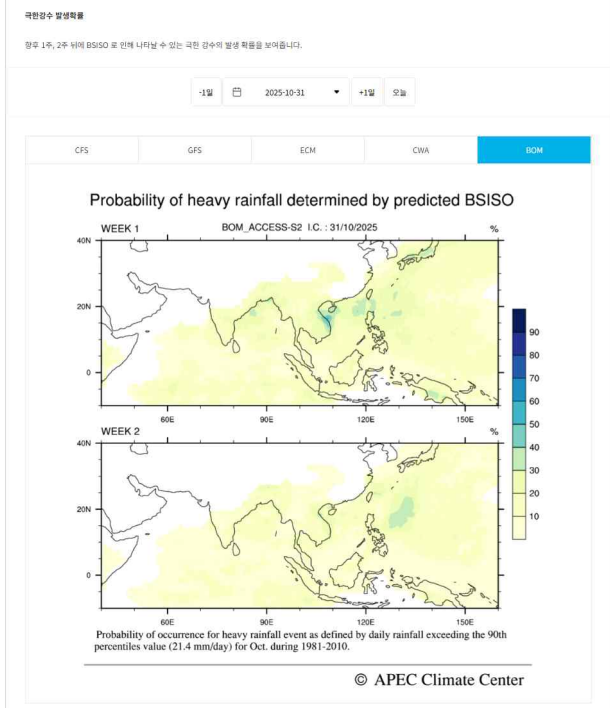
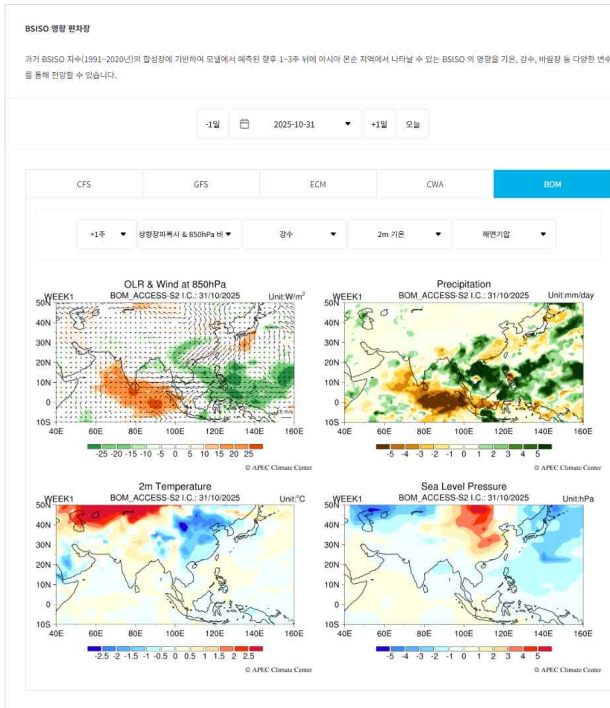
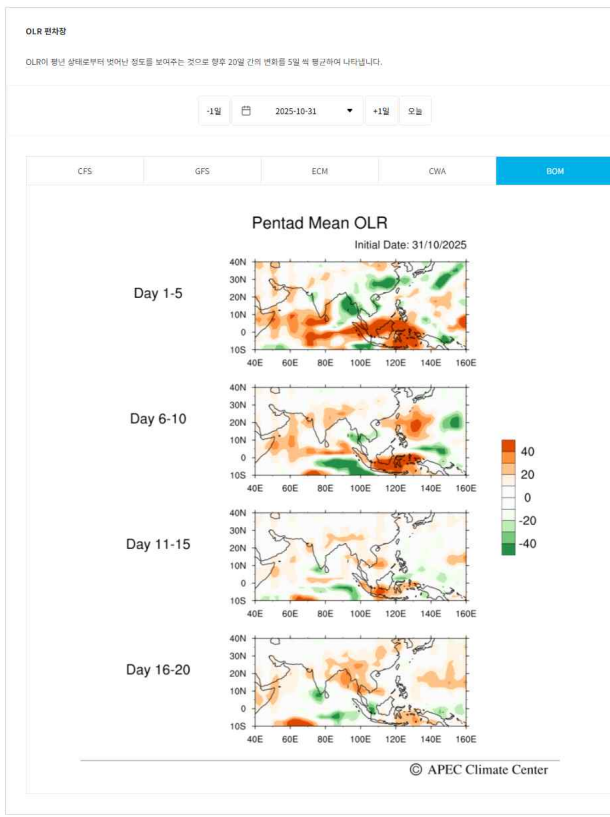
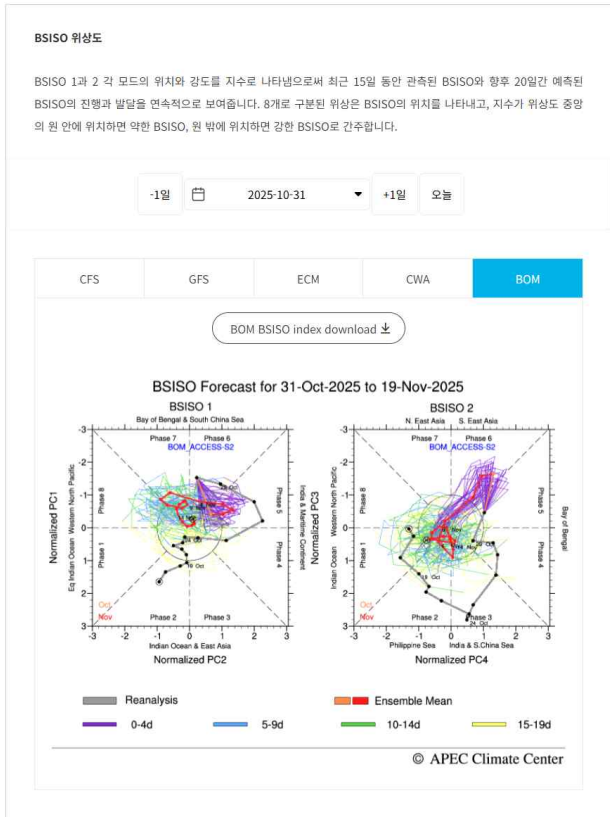


Figure 5.4. Contents of BSISO forecast.

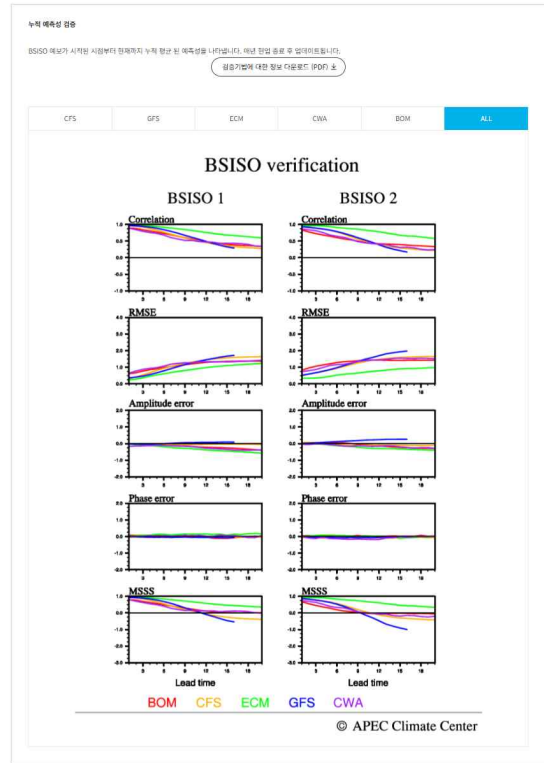
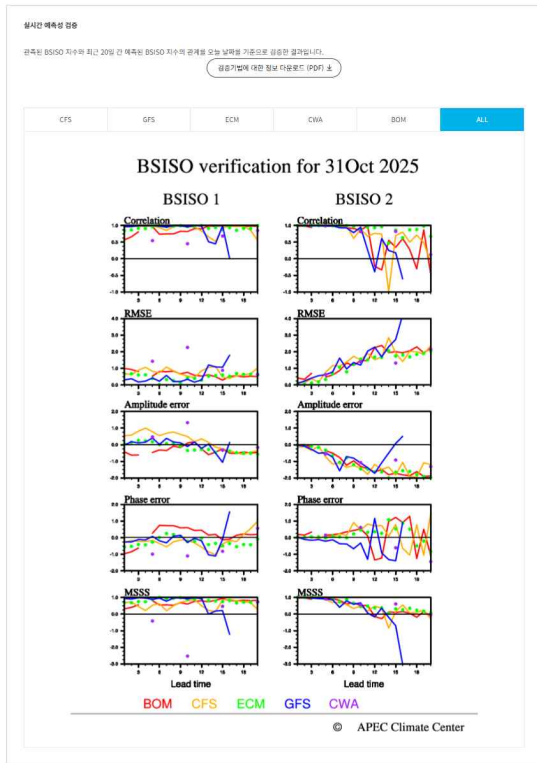


Figure 5.5. Contents of BSISO verification.

APCC의 BSISO 정보는 국내에서는 기상청 기후예측과에 BSISO 지수, 위상도, 영향장을 매주 제공하여 1개월 예보에 활용되고 있고, 기상청 기후예측-분석통합시스템에 실시간 조기 제공되고 있다. 국외에서는 인도 기상연구소에서 예측 정보를 실시간 활용하여 홈페이지에 제공하고 있고 베트남 기상청에서도 BSISO 영향장을 활용하고 있다. 2025년 초에는 국/내외 연구진 및 APCC BSISO 현업 담당자의 협업에 의해 APCC BSISO 지수를 활용한 ENSO 영향에 대한 분석 관련 연구논문이 1건 출판되었다.

5.2. BSISO 계절내예측시스템 개선 (BSISO 참여모델 활용을 위한 전처리 체계 구축)

5.2.1. 배경 및 목적

APCC BSISO 현업서비스의 예보 활용성을 높이기 위해 다양한 측면에서의 개선을 해왔다. 현재 BSISO의 모든 참여 기관은 APCC에서 요청한 BSISO 입력자료의 형식에 맞게 모형 자료를 재처리하여 제공해오고 있다. APCC의 요청 입력자료 형식에 따라 참여기관 중 ECMWF는 매년 데이터 라이선스 갱신과 함께 해당 입력자료를 제공해왔으나, 2024년 내부 자료 제공 정책 변경에 따라 라이선스 종료(~2025년 중) 이후 라이선스 재갱신 및 자체 자료 제공 불가를 통보하였다. 이에 따라 BSISO의 매일 현업 일정에 맞춰 ECMWF 계절내예측자료의 실시간 수집 및 재처리 과정을 구축하고 BSISO 입력 자료에 필요한 재분석 자료를 재가공하고 이를 자동화하는 입력자료 처리 체계 구축이 필요하였다.

5.2.2. 자료 및 방법

입력 자료 처리는 BSISO 현업시스템의 주요 수행 과정 (Figure 5.6) 중 빨간색 점선으로 표시된 단계에서 수행되어야 하는 과정으로 데이터 수집과 함께 현업시스템의 가장 첫 단계에서 이루어져야 하는 과정이다.

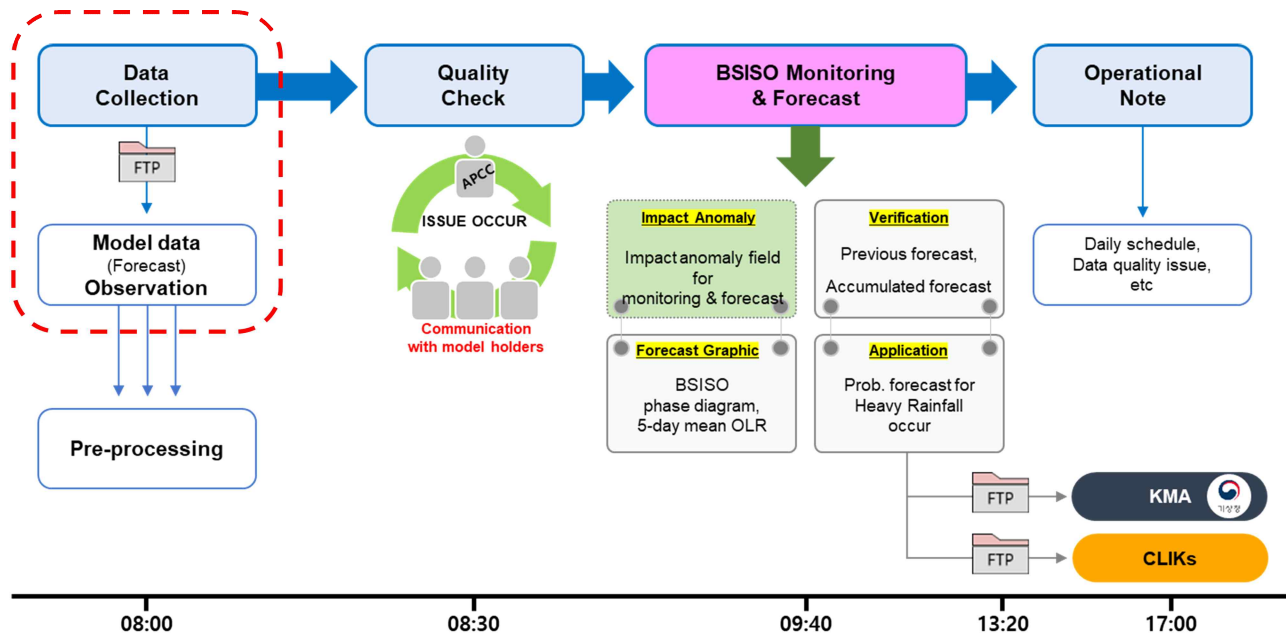


Figure 5.6. Flow chart of producing the APCC BSISO operation system.

현재 APCC에서 각 참여기관에 요청한 BSISO 입력 자료(모델 예측자료) 제공 양식은 Figure 5.7와 같다. 모든 참여기관은 아래의 양식과 같이 ‘YYYYMMDD_KKCC_VAR_BSISO’ 파일명으로 BSISO 영역에서의 재분석자료와 모델 예측값을 각 변수(OLR, U850)에 대해 추출하여 텍스트 파일 형태로 제공 중이다. 그리고 이렇게 가공된 입력자료 파일을 각각 모델의 예측 제공 주기에 맞춰 실시간으로 APCC FTP 서버를 통해 수집되고 있다.

입력자료의 양식을 살펴보면, 먼저 예측시작일 기준으로 과거 120일간의 재분석 자료가 먼저 작성되고 이후에 예측 자료가 하나의 파일에 작성된다. 재분석 자료와 예측 자료는 날짜를 기준으로 순차적으로 작성되며 각 해당 시점(time step)에서 가로 방향으로 경도(longitude) 값이 기록되며, 이어서 세로 방향으로 위도(latitude) 값이 배열된다. 이러한 경·위도 격자의 묶음이 하나의 시점을 구성하며, 재분석일 수, 예측일 수만큼 동일한 구조가 순차적으로 나열된다. 예측자료의 경우 앙상블이 다수일 경우 경·위도·시점의 묶음이 앙상블 개수만큼 구성된다.

따라서 입력자료 처리시스템 구축을 위해서는 예측 원시자료의 자동 수집을 시작으로 해당 자료를 재가공하여 Figure 5.7의 양식을 추출하기 위한 작업이 포함되어야 한다. 자료의 수집은 ECMWF 데이터 서버에서 제공하는 ECMWF API를 통해 이루어지고 파이썬 스크립트를

활용한다. 그리고 추후 MME 계절내예측 현업 예정에 따라 참여 모델 확대를 고려한 범용적이고 효율적인 시스템을 만들고자 입력자료 처리시스템 내 모든 언어는 Python을 사용하고 YAML을 이용하여 초기 입력값 (날짜, 변수 등)을 설정하였다.

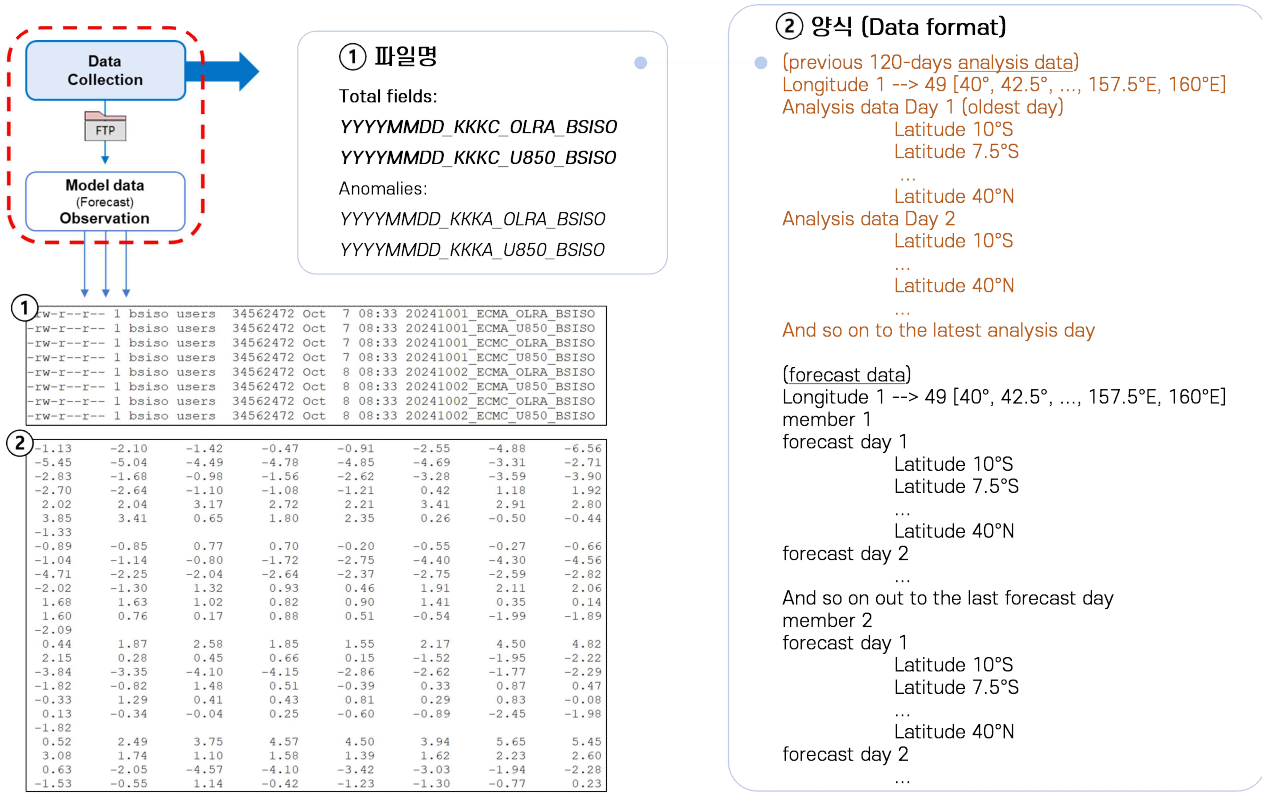


Figure 5.7. Data format of input data for APCC BSISO forecast system.

BSISO 입력자료 처리시스템 구동을 위해 필요한 필수 사양은 외부망 FTP 서버에서 python/anaconda-3.8, ecmwfapi 모듈이고 내부망 현업 서버에서는 python/3.7-anconda, xarray(pynio 패키지 포함), netcdf4, xesmf 가 있다.

5.2.3. 결과

BSISO 입력자료 처리시스템을 통해 BSISO 입력자료를 생산하기 위해서는 모델 예측자료 및 재분석 자료 수집, 해상도 변환(2.5도), 영역 추출, 형태 변환 등이 필요하고 매일 운영되어야 하는 BSISO 현업의 특성상 모든 과정은 자동화가 필수적이다. 그리고 단계별로 코드의 처리 속도 및 효율적 공간 자원 관리를 고려하여 시스템을 구축하고자 하였다.

Figure 5.8은 구축된 BSISO 입력자료 처리시스템의 모식도이다. 모식도 상에서 ①~④로 표시된 코드가 시스템을 구성하는 주요 코드이고 코드별 역할은 다음과 같다. 먼저 ① ECMWF_FCST.py 코드에서 ECMWF 데이터서버(DS)로부터 APCC FTP 서버(외부망)로 ECMWF

계절내 예측자료 수집한다. ECMWF에서 제공하는 API를 통해 ECMWF DS로부터 BSISO의 입력 변수가 되는 OLR(Outgoing Longwave Radiation) 및 U850 (850hPa U-wind) 변수를 매일 수집한다. 그리고 ② FCST_ftp_ECM_manual.CSH 코드를 통해 APCC FTP 서버(외부망)에서 현업 서버(내부망)로 수집된 자료 실시간 이전하게 된다. 그리고 APCC 내부망 현업 서버에 수집된 원시자료는 ③의 코드들에 의해 자료 전처리가 이루어지게 된다. 전처리 과정에서는 먼저 모델 원시 해상도에서 2.5도 수평해상도로 내삽(interpolation)을 하고 모델 타입별 자료(cf, pf)를 한 파일로 통합한다. 그리고 파일 형식을 grib에서 netCDF로 변환한다. 이를 변환하지 않을 시 record 오류가 발생하는 것을 확인하였다. 그리고 최근 120일의 재분석자료를 BSISO 감시자료인 NCEP R1(Reanalysis 1)으로부터 추출하고 추출된 재분석자료와 ECMWF 예측자료를 한 파일로 통합한다. 그리고 최종적으로 BSISO 영역 및 입력자료 양식에 맞춰 ASCII 파일 형태로 추출하게 된다. 그리고 ③의 코드들은 ④ FCST_RUN_LY_ECM_manual.CSH 셸을 통해 순차적으로 구동된다.

BSISO 입력자료 처리시스템 구동의 시간 및 공간 자원의 측면에서 외부망에서 원시자료 입수부터 BSISO 입력자료 추출까지 계산 소요 시간은 약 11분으로 매일 현업이 구동되는 데 있어 문제가 없는 것으로 판단하였다. 그리고 저장 공간은 외부망 FTP 서버에서 매일 약 520MB(GRIB)의 파일이 입수되고 이는 입력자료 생산 즉시 삭제 예정이다. 그리고 내부망 현업 서버에서 매일 약 66MB(ASCII)의 파일이 생산되고 이는 현업 서버 내 보관될 예정이다.

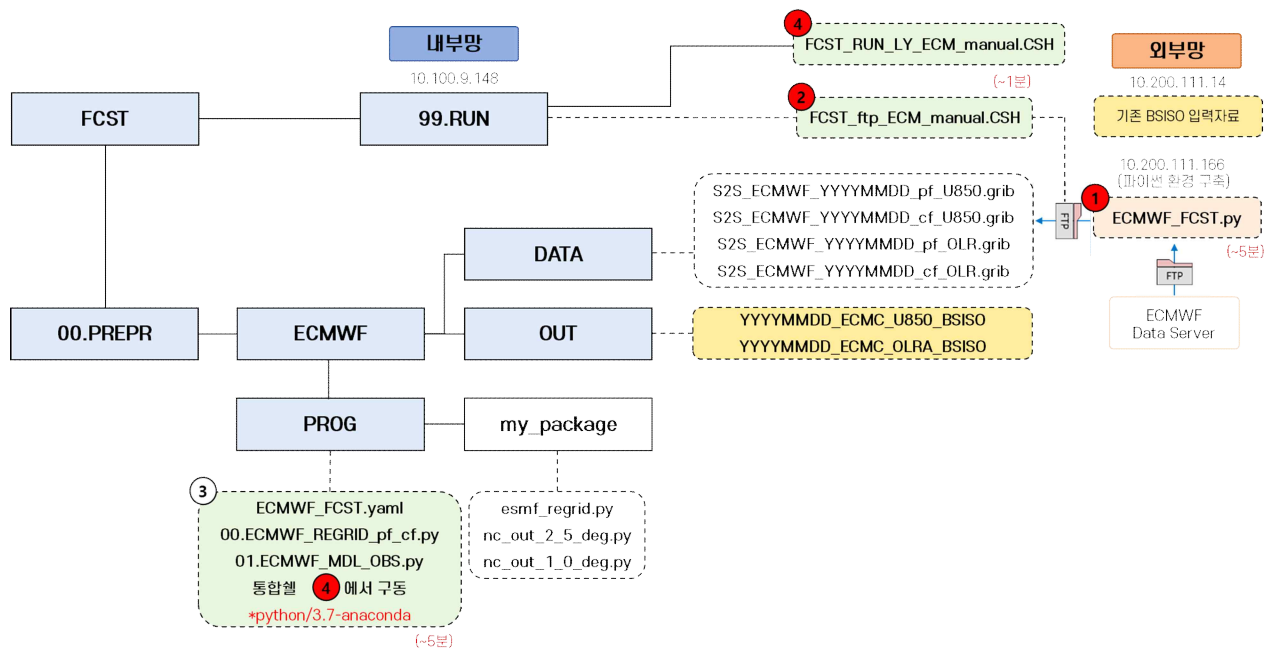


Figure 5.8. Diagram for pre-processing system for BSISO input data.

BSISO 입력자료 처리시스템의 검증을 위해 2024.10.01.~2024.10.31. 1개월간 BSISO 입력자료 처리시스템을 구동하여 모델 예측자료 수집, 전처리 등을 통해 BSISO 예측자료를 생산하는

시스템 검증 실험을 진행하였고 Figure 5.9은 검증 결과 중 일부이다.

BSISO 예측 지수의 경우, 120일간의 재분석장이 기존의 ERA5에서 NCEP R1으로 변경되었는데 이는 실시간 자료 입수가 가능한 자료를 사용하기 위해 변경되었고 그에 따라 차이가 발생하지만 유의미한 정도는 아닌 것으로 확인하였다(Figure 5.9). 그리고 Pentad mean OLR 패턴은 거의 일치하지만 그 강도에서 일부 차이가 있으나 이는 전처리 과정에서 interpolation 등의 기법 차이로 인한 것으로 판단되며, 그 차이가 유의미한 정도는 아닌 것으로 확인하였다.

검증 실험을 완료하고 자체적으로 생산한 ECMWF 입력자료를 실제 현업에 적용하기 이전에 검증 실험 결과는 ECMWF 실무자 측에도 전달을 완료하였으며, 참여 기관측으로부터 향후 ECMWF 입력자료는 새로 구축된 APCC 입력자료 체계를 이용하여 BSISO 예측 결과 생산을 지속하는 것에 동의를 얻었다.

BSISO 입력자료 처리시스템의 특이 사항은 Table 5.2과 같다. 기존과 현재 ECMWF 입력자료 생산 체계를 비교했을 때 주요하여 변경된 사항은 제공 방식, 제공 시기, 재분석 자료 종류이다. 제공 방식은 기존에 ECMWF에서 제공하던 방식이 아닌 자체적으로 자료 수집부터 입력자료 처리까지 하게 되었고, 자료 수집 방식 변경으로 인해 기상청 기후예측과에 조기 제공 가능한 예측자료의 초기장 날짜는 기존의 1일 전이 아닌 3일 전으로 변경되었다. 그리고 BSISO 입력자료에 사용된 재분석자료는 자체적으로 실시간 수집이 가능한 NCEP R1 자료로 변경되었다.

5.2.4. 요약 및 결론

BSISO 입력자료 처리시스템 구축을 통해 자체적으로 ECMWF 모델의 APCC BSISO 현업시스템 참여모델로 활용 가능한 체계가 완성되었고 이를 토대로 기상청 기후예측과에 1개월 예보도의 참고 자료로 ECMWF BSISO 예측 정보를 지속적으로 제공할 수 있게 되었다. 또한 향후 APCC MME 계절내예측의 현업화가 계획되어 있음에 따라 계절내 예측자료의 원시자료 수집이 가능하다면 자체적으로 예측 자료를 BSISO 입력자료로서 활용할 수 있는 기반을 마련했기 때문에 APCC BSISO 현업 참여 모델 확대 가능성 또한 증가하였다.

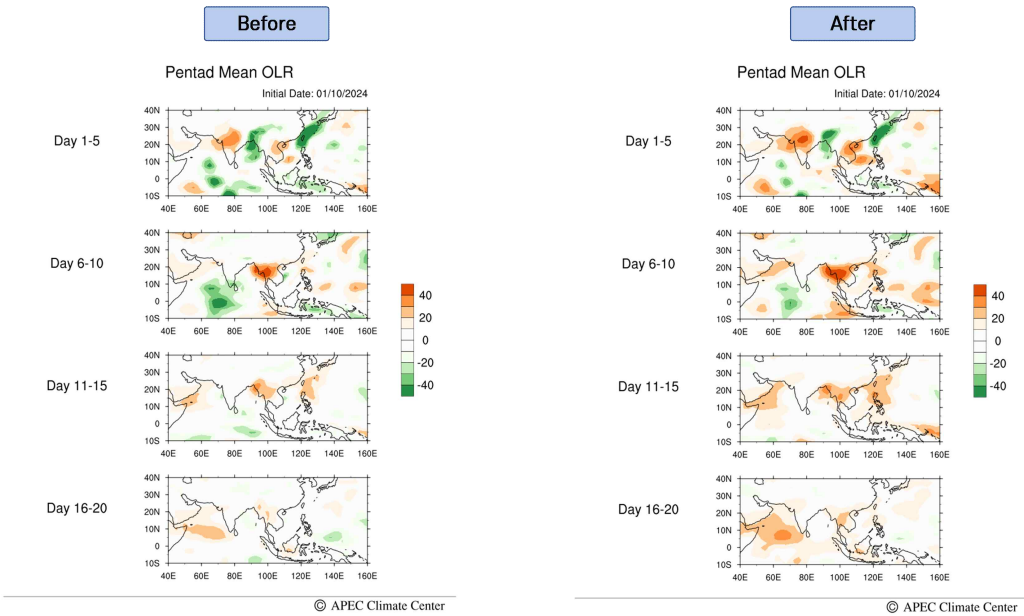
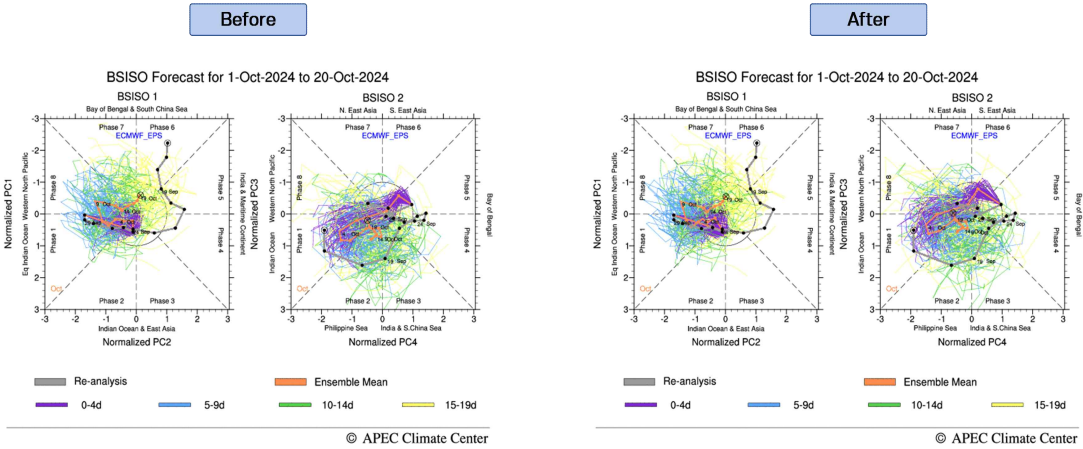


Figure 5.9. BSISO phase diagram and pentad mean OLR before (left) and after (right) construction for pre-processing of ECMWF input data.

Table 5.2. Differences in the BSISO input data pre-processing system before(previous) and after(current) implementation.

	기존	현재
제공 방식	ECMWF→APCC 업로드	APCC→ECMWF 다운로드
제공 주기	매일	매일
조기 제공 (for 기상청)	매일	매일
조기 제공 사용 초기장	D-1	D-3
재분석 자료 (120일)	ERA5 (+5일~3개월)	NCEP R1 (+3일)

6. APCC 자체 예측모델(SCoPS) 운영 및 예측정보 제공

6.1. 배경 및 목적

SCoPS는 계절 및 계절내 예측을 목표로 개발된 대기-해양-해빙 결합 모델이며, 약 80km의 높은 수평해상도를 가진 APCC 자체 예측모델로써 현재까지는 2017년 11월부터 매달 APCC MME 계절예측의 참여모델로 활용되고 있다.

6.2. 자료 및 방법

Figure 6.1은 APCC 자체 계절예측 모델인 SCoPS (Seamless Coupled Prediction system)의 운영 체계 및 현업 일정을 모식화 한 그림이다. SCoPS는 매월 7일경 초기 입력자료인 NCEP CFSR(Climat Forecast System Reanalysis) 및 Argo 자료를 수집하여 초기장을 만들고 대기-해양 초기화를 통해 6개월 예측자료를 생산한다. 생산된 예측자료는 후처리를 통해 예보도의 자료를 만들어 현업 팀 내 공유를 하고 매달 생산된 자료에 문제가 없다고 판단되면 APCC MME 참여모델로써 활용되고 있다.

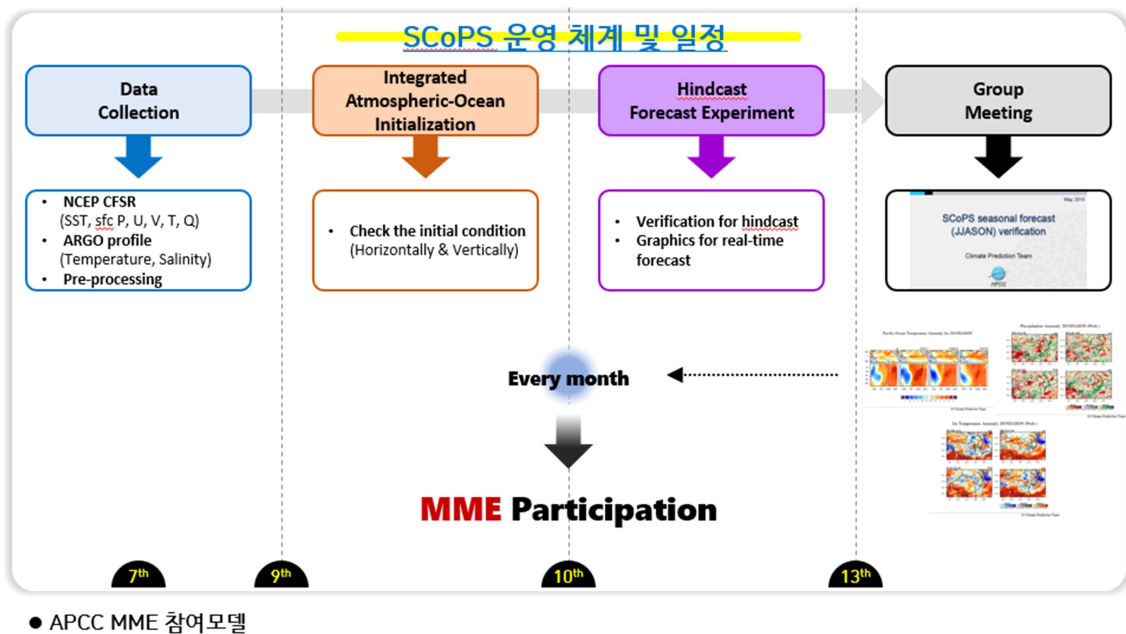


Figure 6.1. APCC in-house model (SCoPS) operating system.

6.3. 결과

SCoPS의 초기조건은 NCEP CFS (National Centers for Environmental Prediction Climate Forecast System) 재분석자료와 Argo (Array for Real-time Geostrophic Oceanography) 자료를

이용하고 대기 초기조건은 3차원 넷징(nudging), 해양 초기조건은 EAKF (Ensemble Adjustment Kalman Filter) 기법을 이용하여 3차원 넷징으로 생산된다. 매달 1, 5일에 생산된 총 10개 앙상블을 이용하여 매월 6개월 계절 예측자료를 생산한다.

현업 운영 일정은 매월 7일경 초기장 생산을 위한 재분석자료를 다운로드하고 자료 전처리를 거쳐 3차원 넷징 및 초기화 기법을 적용시킨다. 그리고 생산된 초기장을 이용하여 6개월 계절 예측 자료를 만들고 이는 후처리를 거쳐 매월 10~12일경 APCC MME에 참여모델로써 제공된다. 또한 SCoPS 자체 예보토의 자료 생산을 위해 계절별 예측 자료 검증 및 주요 변수의 결정론 및 확률론적 예보 공간장을 생산하여 센터 내부에 공유하고 있다.

SCoPS 예보토의 자료에 표출되는 콘텐츠는 2025년 9월 예보부터 적용된 APCC MME Hindcast 기간 변경(1991~2010년 → 1993~2016년)에 따라 Hindcast 기간을 변경 적용하여 생산하였다. Figure 6.2 ~ Figure 6.4는 매달 SCoPS 예보토의 자료에서 생산되는 Hindcast 검증 자료 중 SON 계절에 대한 예시를 Hindcast 기간 변경 전과 후로 나타낸 것이다. Figure 6.2는 Z500, SLP, T2M, PREC의 각 Hindcast 기간에 대한 평균 TCC와 RMSE이다. 대부분의 지역에서 TCC 스킬이 유사하지만 순환장에서 나타났던 북위 60도 이상의 고위도 지역에서의 음의 상관관계가 줄어들고 기온에서는 양의 상관 관계가 증가한 것이 큰 계절적 특징이다.

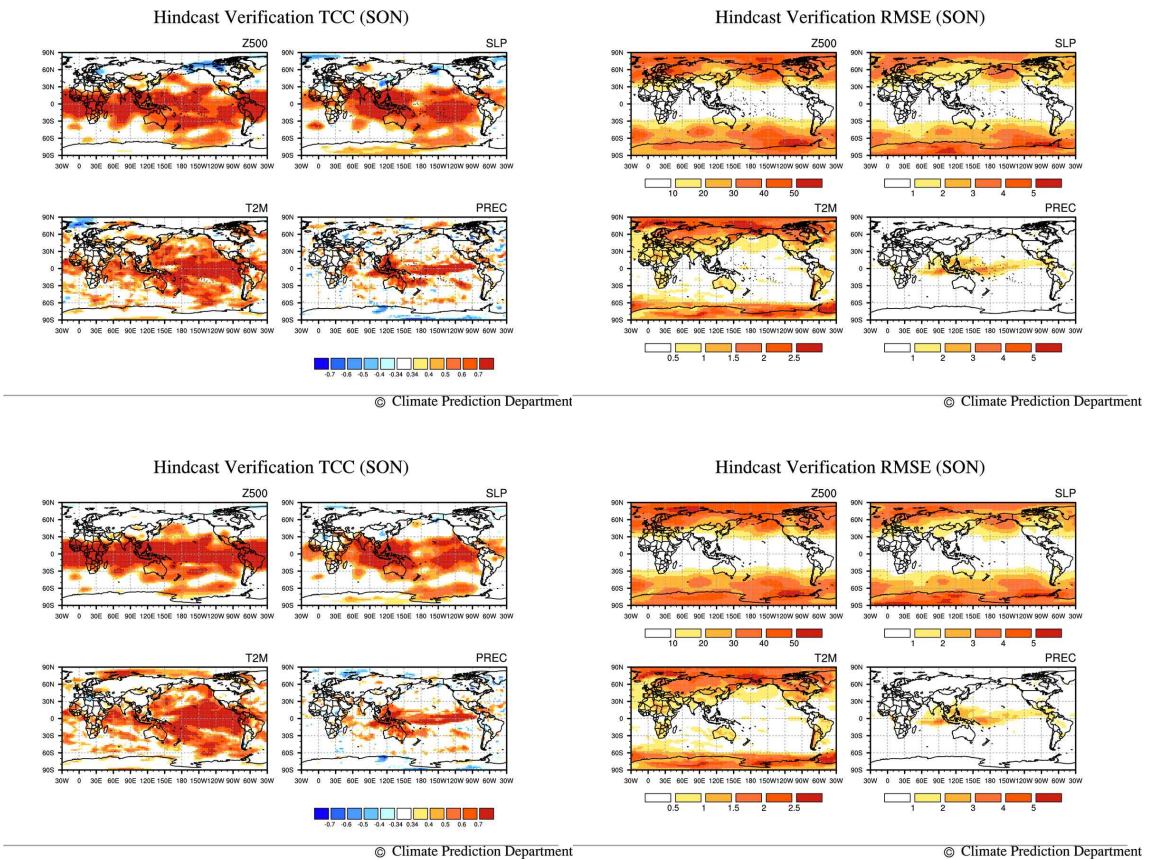






Figure 6.2. Verification of TCC and RMSE for the SON season by hindcast period (top: 1991~2010, bottom: 1993~2016).

Figure 6.3은 NINO3.4 지수에 대한 각 Hindcast 기간에 대한 평균 TCC와 RMSE이다. Hindcast 기간이 최근으로 변경됨에 따라 선행시간 1개월 차에 9월 예보의 평균 TCC가 상대적으로 낮아지고 RMSE가 높아지는 특징이 있다. Figure 6.4에서 Hindcast 기간의 연도별 NINO3.4 예측에서 보면, 1993~2016년 기간에 포함된 상대적으로 최근에 발생한 엘니뇨 사건이 비정상적이고 예측이 어려워 예를 들어 2014~2015년 엘니뇨에서도 많은 모델들이 이를 강한 엘니뇨로 과대 모의하면서 TCC가 감소하고 RMSE가 커지는 특징이 있었는데 이런 오차가 일부 영향을 미쳤을 가능성이 있어 보인다.



© Climate Prediction Department

© Climate Prediction Department

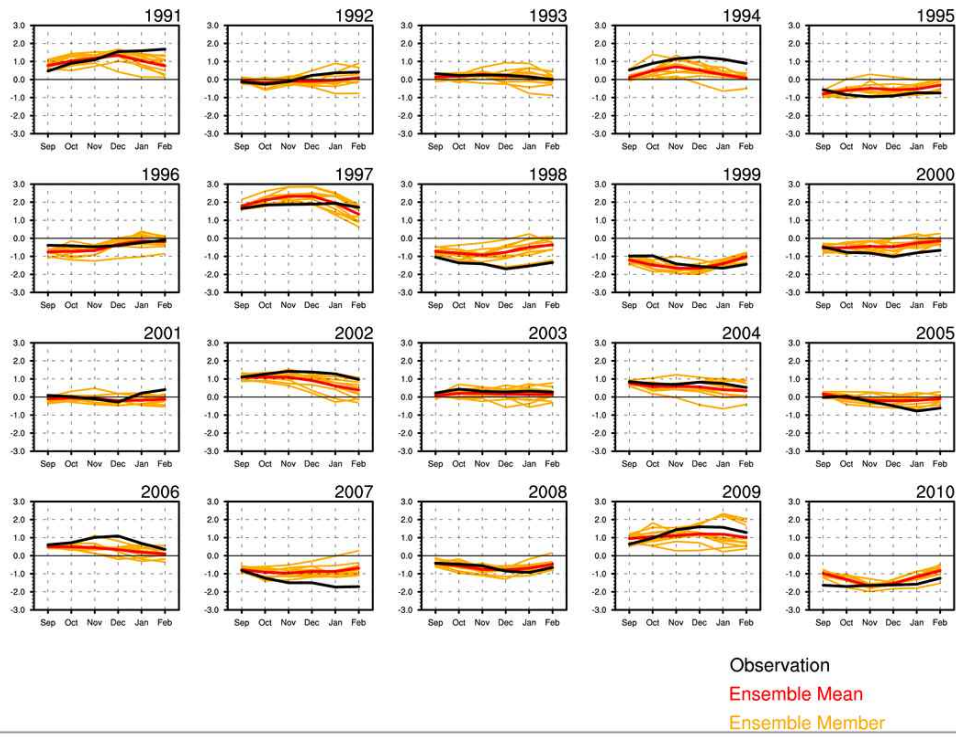


© Climate Prediction Department

© Climate Prediction Department

Figure 6.3. Verification of TCC and RMSE for NINO3.4 during the SON season by hindcast period (top: 1991~2010, bottom: 1993~2016).

Hindcast Nino3.4 Timeseries SONDJF



Hindcast Nino3.4 Timeseries SONDJF

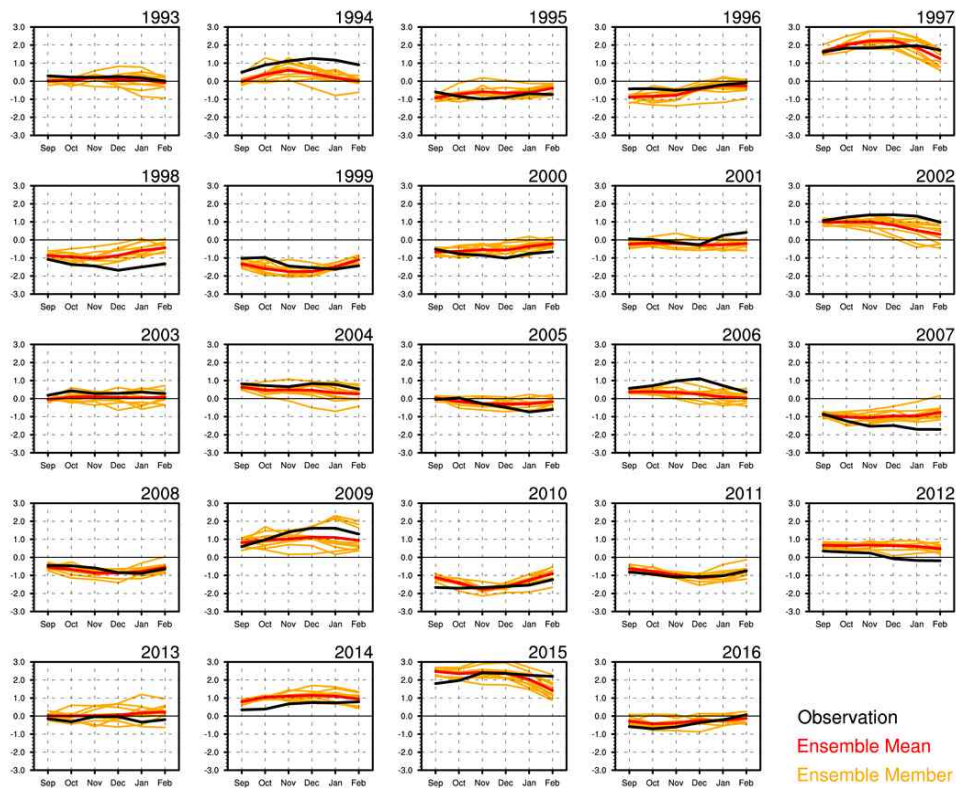


Figure 6.4. NINO3.4 index for the SON season by hindcast period (top: 1991~2010, bottom: 1993~2016)

7. 국내외 협력 및 지원

7.1. 기상청 3개월 전망 지원

아태기후센터는 기상청의 기후예측 업무를 지원하기 위해 매월 내부토의를 거쳐서 MME의 한반도 기온, 강수 예측에 대한 전문가들의 다양한 의견을 수렴하여 결론을 도출하고 이를 바탕으로 기상청과의 예보토의를 통하여 해당 예측정보를 전달한다. 이를 위해 수년 간 모델뿐 아니라 관측 기반의 계절예측정보를 분석해 왔는데, MME의 예측에 최근 관측자료 변동 추이 및 분석결과를 바탕으로 한 통계예측을 더하는 방식으로 예측에 신뢰도를 더해왔다. 이에 더해 올해는 모델 기반의 분석을 좀 더 면밀히 하여 계절예측에 대한 예보토의를 지원하고 있다.

강수 예측에 대한 신뢰도를 더욱 확보하기 위해 우리나라 관측소 강수를(Figure 7.1) 타겟으로 하여 3분위로(above normal, AN; near normal, NN; below normal BN) 나누고, 각 분위에 대한 모델과 관측의 강수, 하층 바람 합성장을 비교하여 모델 예측을 분석하고 신뢰도를 더하였다(Figures. 7.2, 7.3). 관측소 강수는 기상청 기후 예측-분석 통합시스템에 있는 월별 강수 자료이고, 평년 비슷 범위도 시스템에 제시된 값을 따른다.




Figure 7.1. December cumulative precipitation (mm month⁻¹) over south Korea since 1973 from station observations. Climatology period is 1991-2020, and the three categories are divided by ± 0.43 standard deviation. Blue dots indicate the below normal (BN) category, gray dots indicate the near normal (NN) Category, and red dots indicate the above normal (AN) category.

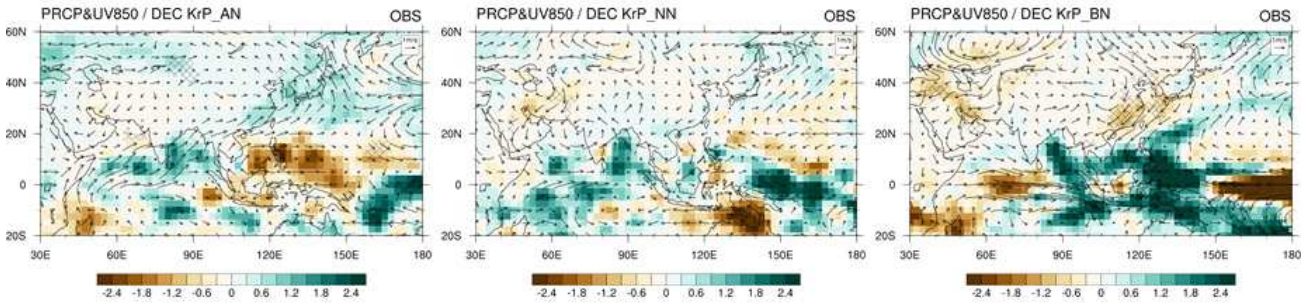


Figure 7.2. December composite patterns of anomalies of precipitation and 850-hPa horizontal wind anomalies for the AN, NN, and BN categories from observations (GPCP, NCEP2). The composite period is 2008–2024 and climatological period is 1991–2020. The cross-hatched areas indicate precipitation anomalies that are significant at the 95% level based on a t-test.

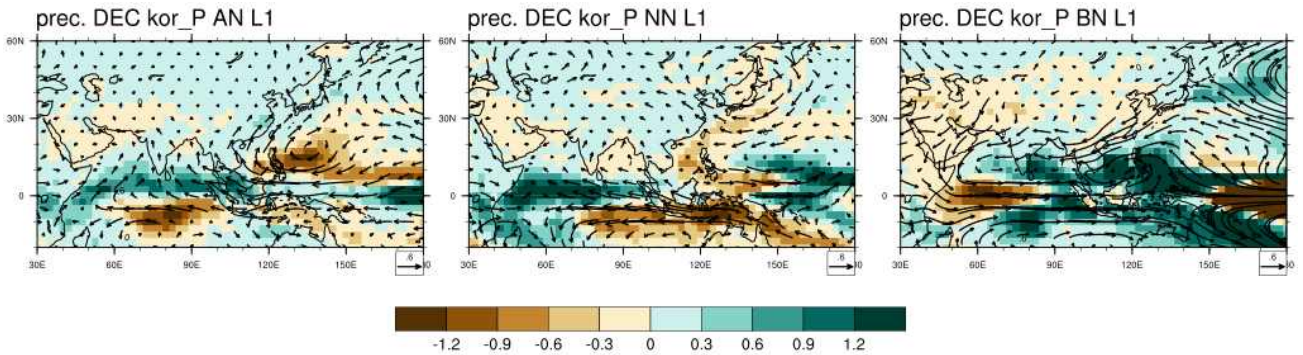


Figure 7.3. December composite patterns of anomalies of precipitation and 850-hPa horizontal wind anomalies for the AN, NN, and BN categories from real-time SCM MME forecasts during 2008–2024.

12월 강수가 평년보다 많을 때(AN) 서태평양, 필리핀 부근에서는 고기압성 바람이 형성되고 건조 영역이 발달하는데, 평년보다 적을 때는(BN) 이와 반대로 서태평양, 필리핀 부근에서 저기압성 바람이 형성되고 대류활동이 활발하여 강수가 많다. 회귀분석에 비해 합성장 분석은 판별해야 할 그림 수는 많지만 변수들 간의 비선형적인 관계를 볼 수 있고 아울러 중립일 경우도 설명가능하다는 이점이 있다. 12월 강수와 바람 합성장 패턴은 관측과 모델예측에 공통적으로 나타나고 모델의 서태평양, 필리핀해 부근 강수 TCC 예측스킬이 상대적으로 높기에(Figure 7.4) 모델의 서태평양 부근 대류활동은 신뢰할 수 있다. 여기에 12월은 한반도 남쪽 해상에서의 강수 TCC 스킬이 높아서 한반도 강수 예측에 활용할 수 있다.




Figure 7.4. Temporal correlation coefficient of precipitation between SCM MME and observation (GPCP) during real-time forecast period, 2008-2024.

실제로 12월 강수 모델 합성장을 계절예측에 활용한 예시를 Figure 7.5에 제시하였다. 모델 강수는 한반도와 그 남쪽에 건조 신호를 예측하였고, 서태평양, 필리핀해 부근은 강한 대류 활동과 저기압성 패턴을 예측하였다. 과거에 한국 강수가 평년보다 적을 때의 패턴과 모델 예측, 관측 합성장이 유사하고, 서태평양과 한반도 남쪽의 TCC 예측 스کیل이 높기에 모델 예측을 신뢰할 수 있을 것으로 판단하여 종합적으로 한국 강수를 평년보다 적음으로 예측하였다(Figure 7.6).

기상청은 우리나라 기온 강수에 대한 계절예측 뿐 아니라 2025년 11월부터 한반도 주변 해양에 대한 해수면온도 예측정보도 시범 생산하고 있고 2026년 11월부터는 정식 생산할 계획이다. 아태기후센터는 이를 위해 올해 10월부터 동아시아 영역의 해수면온도 그래픽 자료를 기상청 해양기상기후과에 전달하고 있다. Figure 7.7은 실제 해수면온도 예측이며 대부분 모델이 한반도 근처 남해, 동해 서해에 대해 평년보다 높은 해수면 온도를 예측한다. 아태기후센터는 해수면온도 예측을 지원하기 위해 내년에 분석을 통해 더 많은 정보를 전달할 계획이다.

12월 강수 모델 합성장

➤ 12월 우리나라 강수[AN, BN, NN]에 따른 합성장

서태평양 대류활동 활발
한반도 남쪽 건조 BN

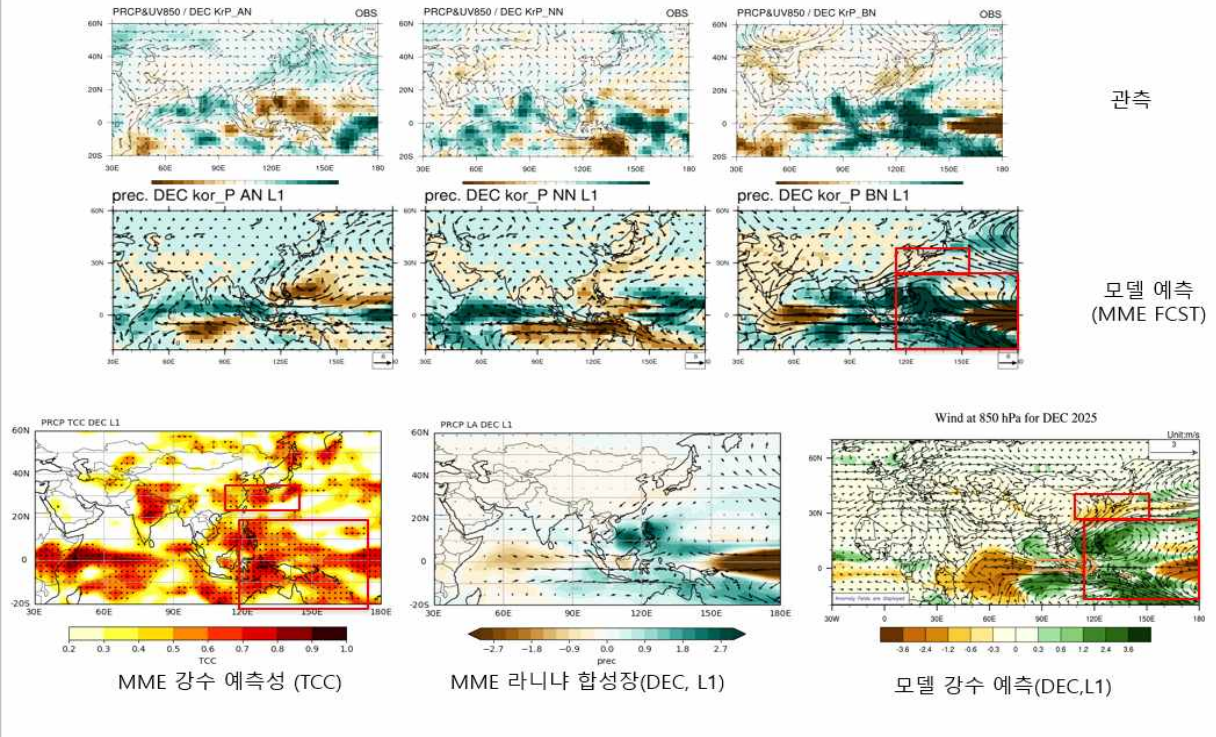


Figure 7.5. An example slide for the December 2025 precipitation forecast over South Korea, showing composite patterns of convection and horizontal winds for the three categories based on observations and SCM MME forecasts.

Summary

APCC MME FORECAST TABLE

		TEMP			PREC		
		12	1	2	12	1	2
OBS	MEAN	1.1	-0.9	1.2			
	Range(lower/upper)	0.5/1.7	-1.5/-0.3	0.6/1.8	19.8/28.6	17.4/26.8	27.6/44.9
Forecast	SCM ANO	0.76	1.13	1.04	-12.77	-3.87	1.00
	PMME(B/N/A)	17/32/51	14/29/57	14/29/57	53/35/11	39/36/25	32/34/34
TCC	OBS vs SCM	0.37*	0.32	0.27	0.38*	-0.20	-0.07
ROC	OBS vs PMME	0.60/0.50/0.40	0.65/0.50/0.35	0.50/0.50/0.42	0.42/0.50/0.49	0.55/0.53/0.41	0.43/0.50/0.49
HSS	OBS vs PMME	-0.01	-0.02	-0.06	-0.05	-0.08	-0.12
Trend	OBS trend	-0.40	0.57	0.94	20.12	-4.60	-2.44
[93-23]	SCM trend	0.95*	1.19*	1.04*	-1.66	3.77	-1.41
Cor TvsP	OBS				0.21	0.43*	0.40*
	SCM				0.52*	0.50*	0.26
WMO	Seasonal(PMME)	+ (54%)	+ (58%)	+ (59%)	- (55%)	EC	EC
	ECMWF(Seasonal)	+ (46%)	+ (58%)	+ (54%)	- (55%)	EC	EC
	ECMWF(S2S)	8/29/63			49/30/22		
Total Forecast		0+	0+	0+	-	0-	0

DJF mme 기온 관측보다 온난화(기온 ↓)

12월	(MME) ①한반도 저기압성 편자 영향(eddy), ②하층 북서태평양 저기압성, 대륙 고기압성 편자 영향, ③북(동)풍 편자 영향, ④서태평양 대류활동 활발 (강수-) (관측) ①라니냐&IOD[0] (강수-), ②라니냐, 바렌즈/카라해 해빙, 랍테프 해빙, 눈덮임 속도 (기온-) ③라니냐vs기온 변동성 큼 (기온 +/-) ④ 최근 경향(기온+)	기온 평년 비슷 또는 높음 (0+) 강수 적음 (-)
1월	(MME) ①한반도 저기압성 편자 영향(eddy), ②하층 저기압성 편자 영향, ③서태평양 대류활동 (강수-) (관측) ①라니냐&IOD[0] (기온0) ②최근 기온 낮지 않은 경향(기온0+) ③기온, 강수 상관관계 (기온 ↓)	기온 평년 비슷 또는 높음 (0+) 강수 평년 비슷 또는 적음 (0-)
2월	(MME) ①한반도 저기압성 편자 영향(eddy), ②서태평양 대류활동 (강수0-) (관측) ①라니냐&IOD[0] (기온-, 강수-) ②바렌즈/카라해 해빙(기온-) ③기온, 강수 상관관계 (강수 ↑)	기온 평년 비슷 또는 높음 (0+) 강수 평년 비슷 (0)

Figure 7.6. Summary of the APCC MME seasonal forecasts. The consensus forecasts are produced using MME forecasts, model analyses, and observational statistical forecasts.

Sea Surface Temperature Anomaly(GAUS)

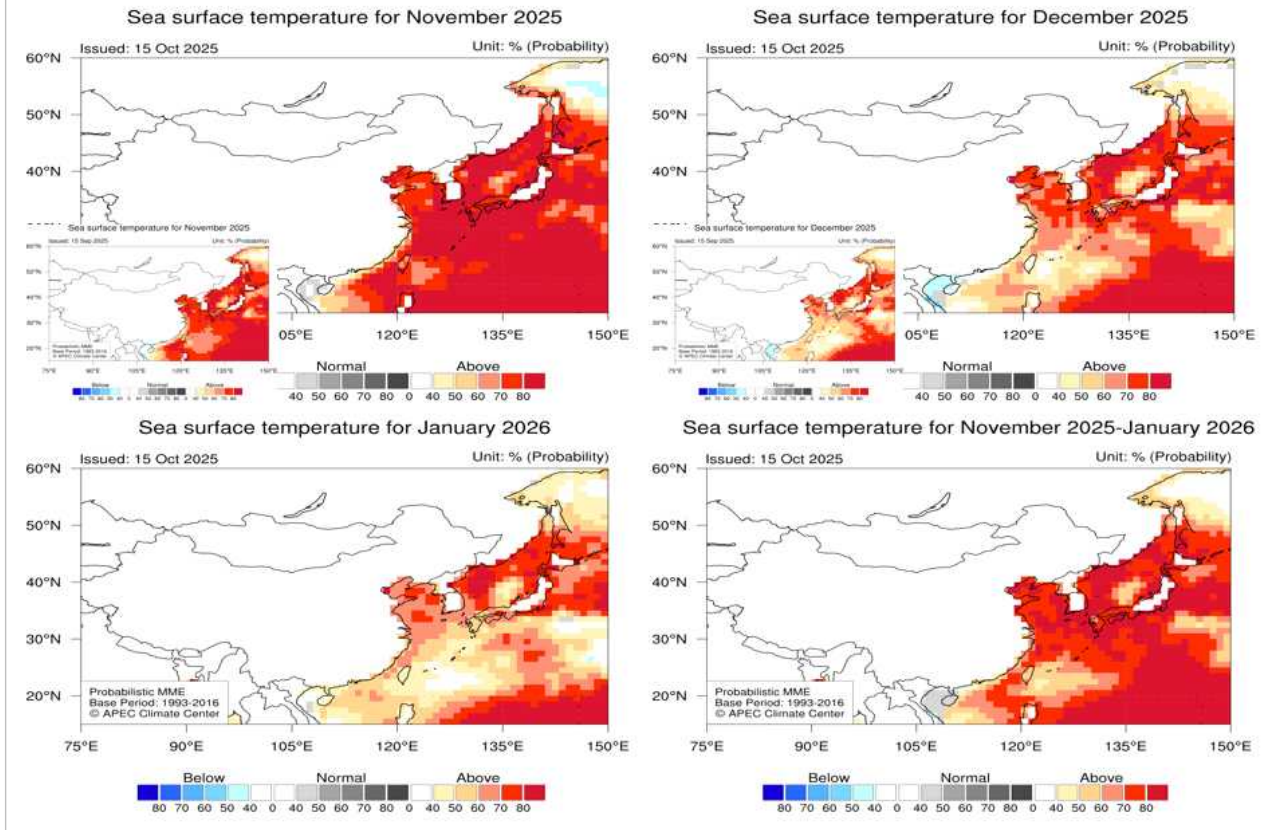


Figure 7.7. SST PMME forecasts over East Asia for November 2025–January 2026, issued in October 2025.

7.2. WMO 계절예측 선도센터 운영 및 개선

7.2.1. 개요

2006년 11월, 대한민국 기상청은 세계기상기구(WMO, World Meteorological Organization)로부터 전 지구 장기 예측자료 생산센터(GPC, Global Producing Centre for Long-Range Forecast)로 공식 지정되었다. 이는 기상청이 국제적으로 장기에보 생산 능력을 인정받았음을 의미하며, 한국의 기후 예측 기술이 세계적 수준에 도달했음을 보여주는 것으로 이어서 2009년 4월에는 다중모델 앙상블(MME, Multi-Model Ensemble) 예측 기술력을 국제적으로 공인받아, 미국기상청(NCEP)과 함께 세계기상기구 기후 예측 다중모델 앙상블 선도센터(LC-LRFMME, WMO Lead Centre for Long-Range Forecast Multi-Model Ensemble)로 지정되었다. 이는 2025년부터 LC-LRFMME에서 LC-SPMME (WMO Lead Centre for Seasonal Prediction Multi-Model Ensemble)로 변경되었다.

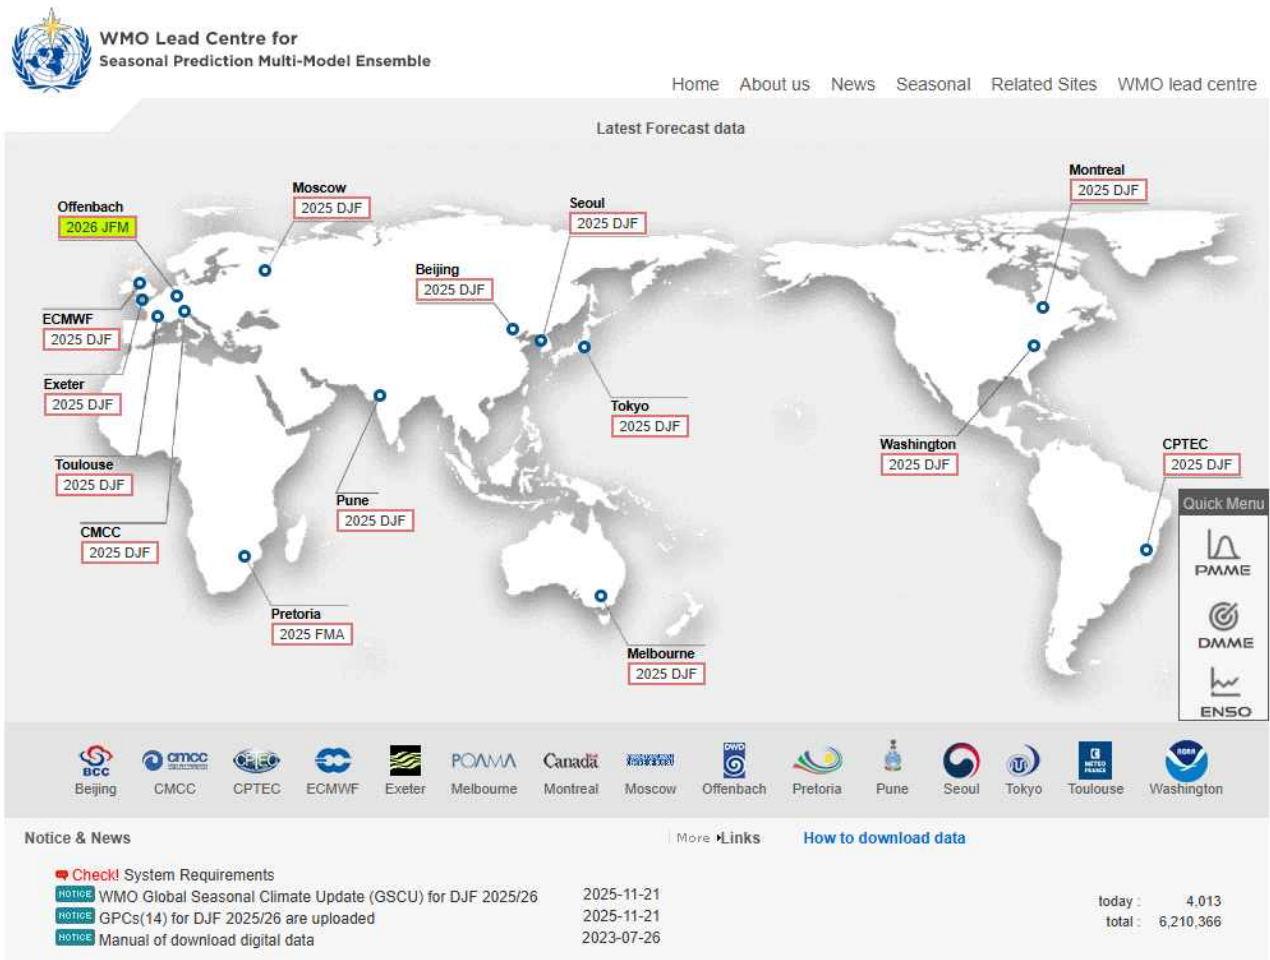


Figure 7.8. Data produced by 15GPCs are collected and standardized, and the resulting seasonal prediction information is provided through the WMO-LC website

세계기상기구 기후 예측 다중모델 앙상블 선도센터는 단순히 예측자료를 생산하는 기관이 아니라, 전 세계 GPC에서 생산하는 장기예보 자료를 집약하고 이를 표준화된 형태로 제공하는 글로벌 허브(one-stop shop) 임무를 수행한다. 각국의 예측자료는 모델 구조, 해상도, 변수 형식 등이 달라서 이를 통합적으로 활용하기 위해서는 공통된 데이터 포맷과 처리 체계가 필요하다. 선도센터는 이러한 과정을 통해 회원국들이 더욱 쉽게 자료를 활용할 수 있도록 지원하며, 동시에 MME 기법을 개발·고도화하여 예측 정확성을 높이는 데 이바지한다(Graham et al., 2011).

매월 15일경, 선도센터는 각 GPC로부터 최신 기후 예측자료를 수집하고 이를 기반으로 MME 예측자료를 생산한다. 생산된 결과는 디지털 데이터 파일과 시각화된 그림 형식으로 가공되어 선도센터 공식 누리집(www.wmolc.org)을 통해 공개된다. 이러한 과정은 단순한 데이터 제공을 넘어, 국제 사회가 공통으로 활용할 수 있는 공식 계절 예측 정보를 생산하는 절차로 이어진다. 실제로 선도센터에서 생산된 계절 예측 정보는 WMO의 공식 자료로서 실시간으로 WMO 누리집(WMO Seasonal Forecasts)과 대한민국 기상청 누리집(기상청 계절 예측)을 통해 전 세계 사용자에게 제공된다.

선도센터의 핵심은 다중모델 앙상블(MME) 기법이다. 이는 단일 모델의 불확실성을 보완하기 위해 여러 예측 모델을 결합하여 평균화하거나 가중치를 부여하는 방식으로, 예측의 신뢰도를 높이는 방법이다. 각 GPC에서 생산된 자료는 선도센터에서 공통된 격자와 변수 체계로 변환되며, 품질 검증 과정을 거쳐 최종적으로 회원국에 제공된다. 이러한 표준화 과정은 국제협력의 기반을 마련하고, 기후예측과의 일관성과 신뢰성을 확보하는 역할을 하고 있다.

선도센터는 매월 각 GPC에서 생산되는 계절 예측자료를 수집하여 예측 정보를 생산하고 제공하는데 수행되는 절차는 다음과 같다.

1. 자료 수집: 각 GPC에서 생산한 장기예보 자료를 수집.
2. 자료 표준화: 서로 다른 형식의 자료를 공통된 격자와 변수 체계로 변환.
3. MME 생산: 다중모델 앙상블 기법을 적용하여 예측 정확성을 향상.
4. 품질 검증: 예측 결과의 신뢰성을 확보하기 위한 검증 과정 수행.
5. 정보 제공: 디지털 데이터와 시각화된 그림을 선도센터 누리집에 공개.
6. 공식 발표: WMO와 각국 기상청을 통해 회원국 및 일반 사용자에게 WMO 웹사이트를 통해 실시간 제공.

WMO 선도센터 운영은 자료 수집 → 처리 및 앙상블 → 품질 검증 → 정보 제공이라는 순환 구조를 갖추고 있으며, 매월 반복적으로 수행된다. 이를 통해 선도센터는 국제 사회가 신뢰할 수 있는 계절 예측 정보를 안정적으로 공급하는 체계를 유지하고 있다.

세계기상기구(WMO) 기후 예측 다중모델 앙상블 선도센터(LC-LRFMME)는 초창기에는 11개의 전 지구 장기 예측자료 생산센터(GPC, Global Producing Centre)로부터 계절 예측자료를

수집하며 운영을 시작하였다. 이후 참여 기관은 점차 확대되었는데, 2010년 6월에 브라질 CPTEC(Centre for Weather Forecasts and Climate Studies, GPC CPTEC)이 참여하여 총 12개 GPC 체제로 운영되었으며 2017년에 독일 기상청(Deutsche Wetterdienst, GPC Offenbach)이 추가되어 13개 GPC 체제로 발전하였으며 2021년에 CMCC(Centro Euro-Mediterraneo sui Cambiamenti Climatici)가 GPC로 지정되며 14개 GPC 체제 확립되었다. 2023년에 인도 기상청(GPC Pune)이 승인되어 현재는 총 15개 GPC에서 계절 예측자료를 제공받고 있다 (Table 2.18)

이러한 참여 확대는 선도센터의 자료 다양성과 예측 신뢰성을 높이는 기반이 되었으며, 국제적 협력의 폭을 넓히는 계기가 되었다.

WMO 선도센터는 15개 GPC에서 제공하는 forecast와 hindcast 자료는 선도센터에서 표준화 과정을 거친다. 표준화가 완료된 후, 9개 주요 변수에 대해 계절 예측이 수행된다. 변수 목록은 다음과 같다.

2m 기온, 강수, 해수면 온도(SST), 해면기압(SLP), 850hPa 온도, 500hPa 지위고도, 850hPa u, 850hPa v, 해빙. (단, SST, 850hPa u/v, 해빙 자료는 제공되는 GPC에 한함)

예측은 결정론적 MME 기법과 확률론적 MME 기법을 병행하여 수행하고 있으며 결정론적 MME 기법은 Simple Composite Method (SCM), Simple Linear Regression (SLR), Singular Value Decomposition (SVD), Genetic Algorithm (GA) 을 제공하고 있으며 확률론적 MME 기법: Min et al. (2009)에서 제안된 방법을 적용하였으며 매월 이들 기법을 통해 3개월 계절 예측자료가 생산되며, hindcast 기간은 GPC 간 공통 기준인 1993-2009년을 사용한다.

또한, WMO 선도센터는 생산된 예측자료의 성능을 정기적으로 검증한다. 검증 대상은 6개 변수(2m 기온, 강수, 해수면 온도, 해면기압, 850hPa 온도, 500hPa 지위고도)이며, 해수면 온도는 제공되는 GPC에 한해 포함된다. 결정론적 예측 검증은 아노말리 상관계수(ACC, Anomaly Correlation Coefficient), 평균 제곱근 오차(RMSE, Root Mean Square Error), MSSS (Mean Square Skill Score), Gerrity Skill Score (GSS)을 사용하고 있으며 확률론적 예측 검증은 Reliability Diagram, ROC Curve 및 ROC Score, ROC Map, Brier Score (BS), Brier Skill Score (BSS)을 제공하고 있다.

검증은 WMO 장기예보 표준 검증 체계(WMO LRF-SVS, Long-Range Forecast Standardised Verification System)에 따라 수행되며, hindcast 검증 역시 공통 기준 기간인 1993-2009년에 대해 계산된다. 검증에 사용되는 재분석 관측자료는 forecast와 hindcast에 따라 달리 적용된다.

선도센터는 단순히 예측자료를 생산하는 데 그치지 않고, WMO 회원국의 요구를 만족하는 고품질 서비스를 안정적으로 제공한다. 각국 GPC의 자료를 통합하여 ‘one-stop shop’ 형태로 제공, 회원국들이 손쉽게 활용할 수 있도록 지원하며 계절 예측 정보의 활용성을 높이기 위해 국내 연구기관 및 국내·외 협력을 통해 생산된 계절 예측 정보는 WMO 공식 누리집과 각국 기상청 누리집을 통해 실시간으로 제공되어, 농업·수자원·재난관리·에너지 산업 등 다양한 분야에서 활용된다.

2025년 WMO 선도센터 운영 성과는 다음과 같다.

- GPC Beijing의 자료 파일 포맷 변경으로 인해 프로그램 코드 수정이나 자료 생산에 필요한 구성 정보 제공(2월)
- GPC Pretoria의 시스템 해킹으로 인해 제공자료의 바이러스 점검 시행(2월)
- GPC Pune의 Member 자료 누락 점검 및 재생산 요청(2월)
- GPC Beijing 모델 CPSv3 업그레이드로 인한 구성 정보 재설정(2월)
- GPC Melbourne의 System 교체로 자료 누락 및 수정요청(3월)
- GPC Offenbach의 모델 업데이트(system4)로 인한 자료구조 정보 요청 및 프로그램 수정(4월)
- GPC CPTEC의 자료전송 문제로 인해 시스템 구성 분석 및 해결 방안 논의(4월)
- GPC Toulouse 모델 업데이트(system 9)로 인한 자료구조 정보 요청 및 프로그램 수정(5월)
- GPC Offenbach의 gcf s22 자료 누락으로 인한 수정요청 및 반영(5월)
- GPC Pune의 SST 파일 문제로 인한 검토 요청 및 수정 반영(5월)
- GPC 시스템 기능 강화를 위한 웹 서버 점검 및 각 GPC 접속 테스트 진행(6월)
- GPC CMCC의 모델 업데이트(sps4.0)로 인한 시스템 코드 수정 및 반영(7월)
- GPC CMCC의 Hindcast 자료 오류로 인한 계절 예측자료 결과 문제 발생으로 원인 분석(8월)
- GPC Exter Hindcast 자료 누락으로 수정요청 및 자료 재생산

2025년 WMO 선도센터를 운영하면서 다양한 오류를 접하게 되었고 GPC자료 업데이트로 인한 프로그램 수정을 통해 서비스의 안정화를 진행하였다. 다음은 WMO 선도센터의 오류사례와 개선한 내용에 관해 설명한다.

- GPC-Beijing의 모델이 기존 CMACSMv1.1에서 CMACPSv3로 업데이트되면서 자료구조 변경에 따른 자료 처리 코드를 개선하고 자료 처리, 표준화, 시각화 프로그램을 개발하였다. GPC_Beijing Forecast and Hindcas 표준화 오류에 대해 자료 처리 코드를 수정하여 신규 파일 포맷으로 변경하였다. 파일구조는 기존 NetCDF-3에서 HDF-5 변경되었고 Hindcast기간 확대와 앙상블 멤버가 24개에서 21개로 감소하였다.

```
def data_read_Beijing(self):
    os.environ['HDF5_USE_FILE_LOCKING'] = 'FALSE' #Add by JM Han 250221
    for ivar in range(len(self.var_fi)):
        in_dir = f'{self.dir+in_dir+in_dir}'
        f = sorted(glob.glob(self.in_dir+in_dir))
        tempdata = []
        ncfile = nc.MFDataset(f)
        for file in f:
            ncfile = nc.Dataset(str(f[0]), mode='r') #modified by JN Han 250221
            data = ncfile.variables[self.var_in[ivar]][:]
            tempdata.append(data)
        outdata = np.concatenate(tempdata, axis=0)
        #print(outdata)
        self._setattr__(self.var_out[ivar], outdata)
```

```
def data_read_Beijing(self):
    os.environ['HDF5_USE_FILE_LOCKING'] = 'FALSE' #Add by JM Han 250221
    in_dir = f'{self.dir+in_dir+in_dir}'
    for ivar in range(len(self.var_fi)):
        in_dir = f'{self.dir+in_dir+in_dir}'
        f = sorted(glob.glob(self.in_dir+in_dir))
        tempdata = []
        ncfile = nc.MFDataset(f)
        for file in f:
            ncfile = nc.Dataset(str(f[0]), mode='r') #modified by JN Han 250221
            data = ncfile.variables[self.var_in[ivar]][:]
            tempdata.append(data)
        outdata = np.concatenate(tempdata, axis=0)
        self._setattr__(self.var_out[ivar], outdata)
```

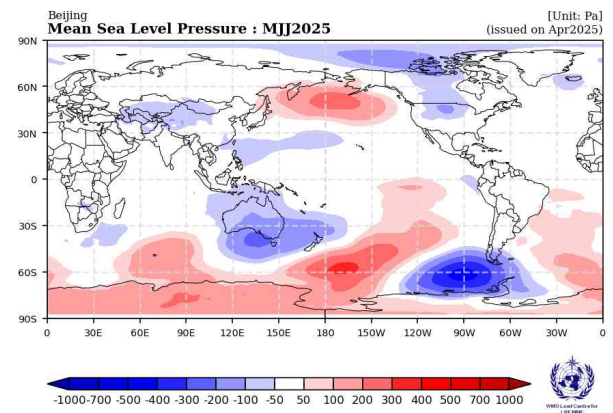
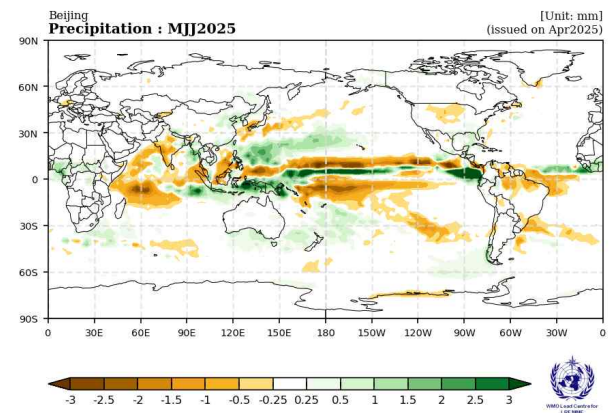


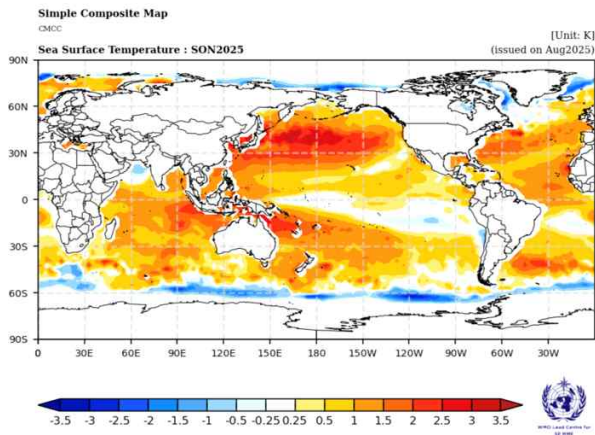


Figure 7.9. During the process of improving each GPC's model, changes in the model file structure and hindcast data period required enhancement to the WMO-LC seasonal prediction production program codes

- GPC-CMCC hindcast 변경으로 해수면 온도에 대한 결괏값이 정상적으로 표출되지 않아 자료 처리 코드와 이미지 생성 프로그램을 수정하여 적용하였다. 또한, 태평양 NINO3.4 지역의 인덱스 값이 높게 나타나는 경향이 발생하여 자료 처리 프로그램을 재수정하였다.

수정 전



수정 후



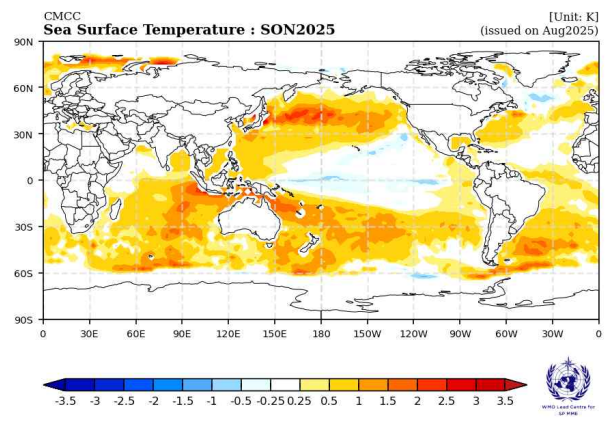


Figure 7.10. As the GPC-CMCC model and hindcast data were modified, errors occurred in data standardization, which led to inaccuracies in map-based SST information and resulted in large deviations in index values for certain regions.

Table 7.1. Description of WMO-LC Seasonal Prediction models

	GPC	Institute	Country	System name	System	Data Format	Forecast			Hindcast			Resolution
							Forecast Periods	Raw Forecast Periods	Ensemble Size	Hindcast Periods		Ensemble Size	
1	Beijing	BCC	China	CSM1.1m	Coupled	NetCDF	7 month	13 month	21	2001	2020	21	2.5°X2.5°
2	CMCC	CMCC	Italy	CMCC-SPS4	Coupled	NetCDF	6 month	6 month	50	1993	2022	30	1.0°X1.0°
3	CPTEC	CPTEC	Brazil		2-tier	GRIB1	5 month	6 month	15	1981	2010	10	2.5°X2.5°
4	ECMWF	ECMWF	United Kingdom	SEAS5	Coupled	GRIB1	5 month	7 month	51	1993	2016	25	1.0°X1.0°
5	Exeter	UKMO	United Kingdom	GloSea6-GC3.2	Coupled	GRIB2	5 month	6 month	42	1993	2016	28	1.0°X1.0°
6	Melbourne	BoM	Australia	ACCESS-S2	Coupled	NetCDF	5 month	6 month	11	1981	2018	3	N216L85
7	Montreal	MSC	Canada	CanSIPsv2.1	Coupled	GRIB2	12 month	12 month	20	1980	2020	20	2.5°X2.5°
8	Moscow	HMC	Russia	SL-AV	2-tier	GRIB2	3 month	4 month	41	1991	2015	11	0.9°x0.72°
9	Offenbach	DWD	Germany	GCFS 2.1	Coupled	GRIB1	5 month	6 month	50	1993	2019	30	2.5°X2.5°
10	Pretoria	SAWS	South Africa		Coupled	GRIB1	3 month	9 month	40	1982	2009	10	2.5°X2.5°
11	Pune	IMD	India		Coupled	GRIB2	6 month	9 month	20	2003	2017	12	
12	Seoul	KMA	Korea	GloSea6-GC3.2	Coupled	GRIB2	6 month	6 month	84	1993	2016	28	2.5°X2.5°
13	Tokyo	JMA	Japan	JMA/MRI-CPS3	Coupled	GRIB2	6 month	7 month	50	1991	2020	10	1.25°X1.25°
14	Toulouse	Met France	France	System9	Coupled	GRIB1	5 month	7 month	51	1993	2024	31	1.0°X1.0°
15	Washington	NCEP/CPC	United States	CFSv2	Coupled	GRIB1	9 month	9 month	40	1982	2010	20	2.5°X2.5°

7.3. 산불 예측 시스템 운영

7.3.1. 산불 예측 시스템 운영 및 예측 정보 제공

7.3.1.1. 산불 예측 시스템 운영

동남아시아에서 발생하는 산불로 인한 연무(스모그)는 심각한 환경문제 중 하나이며, 이러한 산불을 예방하고 그 영향을 완화하기 위해 화재 및 연무 조기경보 시스템(FHEWS)의 필요성이 제기되고 있다. APCC는 2017년부터 동남아시아 해양 국가 중 지리적 중심에 자리 잡은 아시아 최대 섬인 보르네오섬의 4개 지역(Barat, Selatan, Tengah, Timur)에 대한 화재 및 연무의 조기 경보시스템 (FHEWS, Fire and Haze Early Warning System)을 개발하여 보르네오섬의 건기에 해당하는 8~10월 기간에 대한 가뭄 상태를 예측하고 매년 4~7월 사이에 산불 예측 조기경보 정보를 아태기후센터의 영문 홈페이지를 통해 제공하고 있다. 또한 2023년부터는 말레이시아 지역의 2~4월 건기에 대해 매년 10~1월 사이에 인도네시아 지역에 제공하는 동일한 예측 정보를 확장하여 서비스하고 있다(Figure 7.3.1).

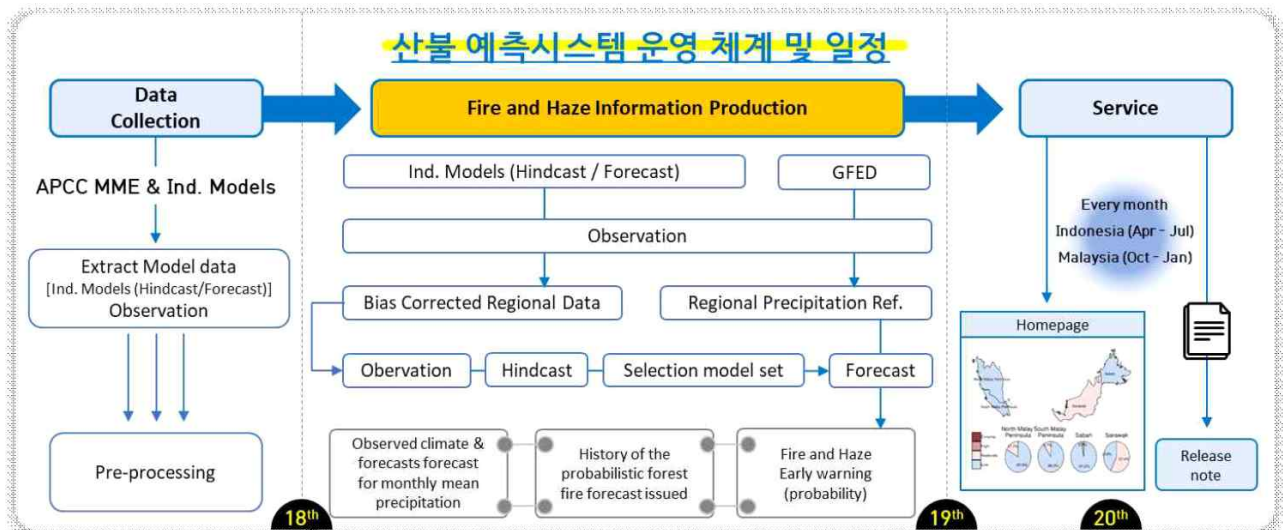


Figure 7.11. APCC Fire and Haze Early Warning System (FHEWS).

7.3.1.2. 산불 예측 정보생산 및 제공

산불 예측 시스템 예보를 위해서는 각 지역의 월평균 강수량을 예측하기 위해 통계적다운 스케일링 모델을 구축하고 ASO(8~10월) 총강수량과 CO2 배출량 간의 관계를 기반으로 화재 위험 등급 체계의 범주 수와 해당 범위를 결정한다. 예측된 강수량을 바탕으로 확률적 산불 위험 등급을 예측한다. 다운 스케일링 된 계절 기후 예보의 품질에 대한 높은 수준의 신뢰가 확보되지 않으면 산불 예측의 효용성을 보장할 수 없다. 따라서 EWS의 전체 계절 기후 예측 기법은 전 지구 모델에서 생산된 동적 예측 데이터를 활용하는 정도로 결합한다. 15개의 개별 전 지구 기후모델에 기반한 월별 예측 데이터(각 3개월에서 11개월 선행 예보)는 2.5x2.5 해상도로 제격 자화되었으며, 단순 평향보정 (Simple Bias Correction, SBC)방법을 사용하여 편향 보정

에 활용하였다.

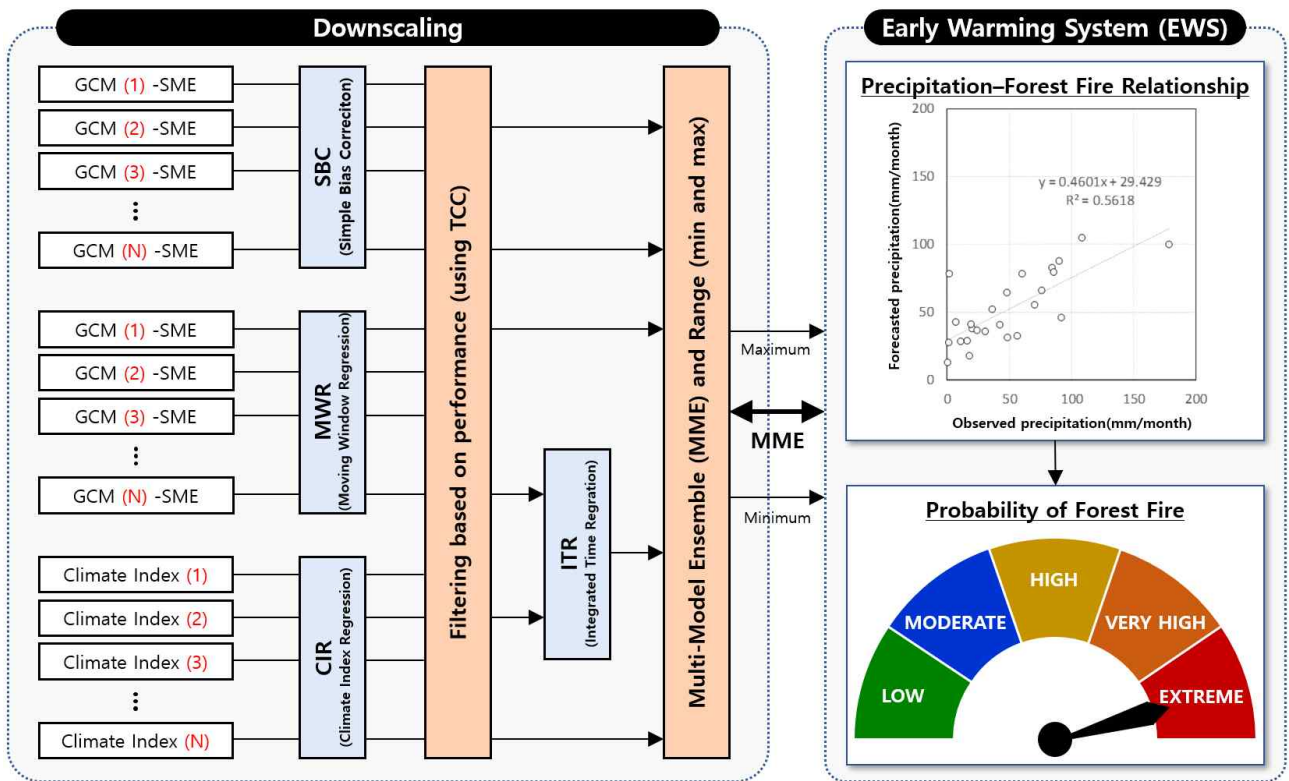


Figure 7.12. Chart of Downscaling and Early Warning Stage Settings in the Early Warning System

4월부터 7월까지 인도네시아 네 개 지역(Barat, Selatan, Tengah, Timur)의 산불 예측의 결과는 다음과 같다. APCC MME에서 예측한 월별 강수량을 활용하여 ASO(8~10월) 기간 동안 보르네오섬의 네 개 주에서 발생할 산불 확률이다. 강수량은 목표 3개월 강수량을 이용해 산불 위험 등급을 극심, 높음, 보통, 낮음으로 구분하고 산불 예측 지도는 각 지역에서 네 가지 범주 중 가장 높은 확률을 가진 위험 등급에 해당하는 색상을 표시한다. 만약 산불 위험 등급의 예측 확률이 동일한 수준으로 (33%, 33%, 33%) 나타날 경우, 지도에서는 회색으로 표시된다.

Monthly History of Dominant Probabilistic Forest Fire Forecast for 2025

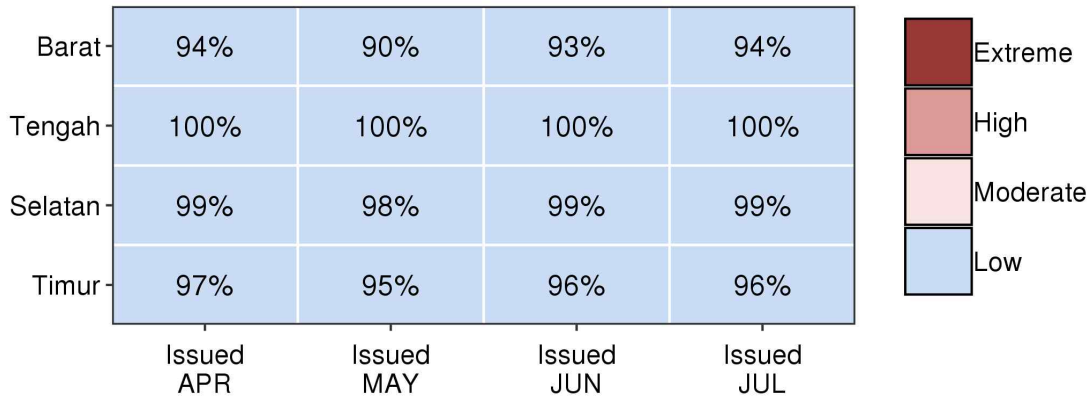


Figure 7.13. Monthly History of Dominant Probabilistic Forest Fire Forecast for 2025

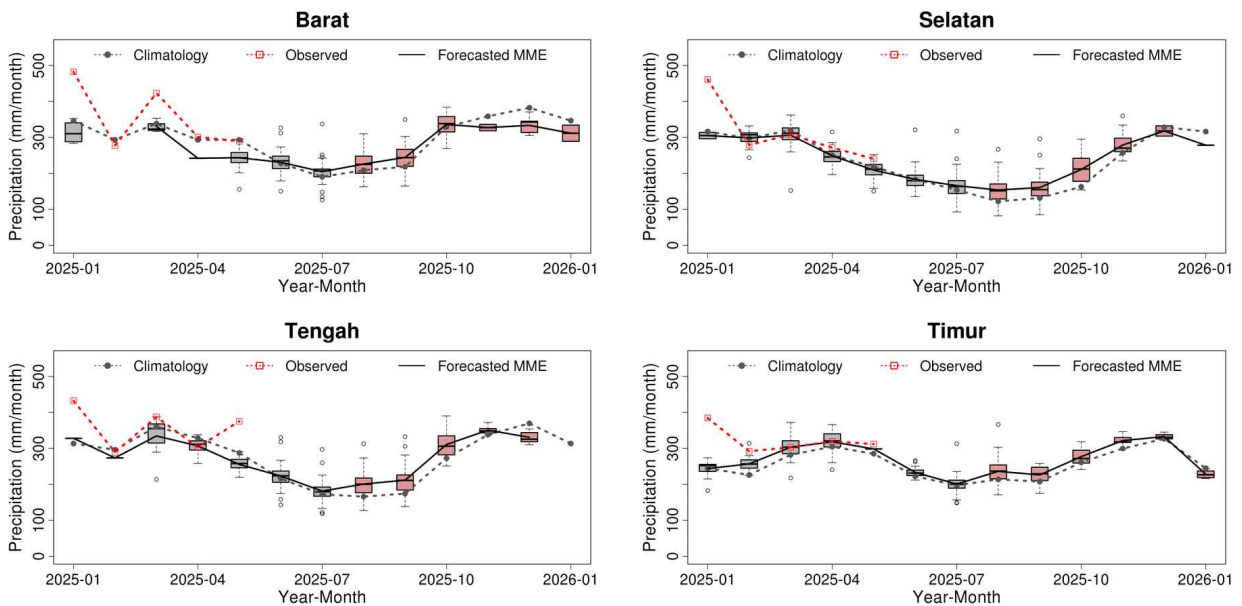


Figure 7.14. 6-month Precipitation Forecast for Jan2025–Jan2026 (issude:2025.07).

10~1월까지 말레이시아 네 개 지역(North Malay Peninsula, South Malay Peninsula, Sabah, Sarawak)의 산불 예측 결과는 다음과 같다. 인도네시아 지역 예측과 같이 APCC MME에서 예측한 월별 강수량을 활용하여 말레이시아 네 개 지역에서 발생할 산불 확률 정보를 제공한다. 강수량은 목표 3개월 강수량을 이용해 산불 위험 등급을 극심, 높음, 보통, 낮음으로 구분하고 산불 예측 지도는 각 지역에서 네 가지 범주 중 가장 높은 확률을 가진 위험 등급에 해당하는 색상을 표시한다. 만약 산불 위험 등급의 예측 확률이 동일한 수준으로 (33%, 33%, 33%) 나타날 경우, 지도에서는 회색으로 표시된다.

Monthly History of Probabilistic Forest Fire Forecast for 2026




Figure 7.15. Monthly History of Probabilistic Forest Fire Forecast for 2025

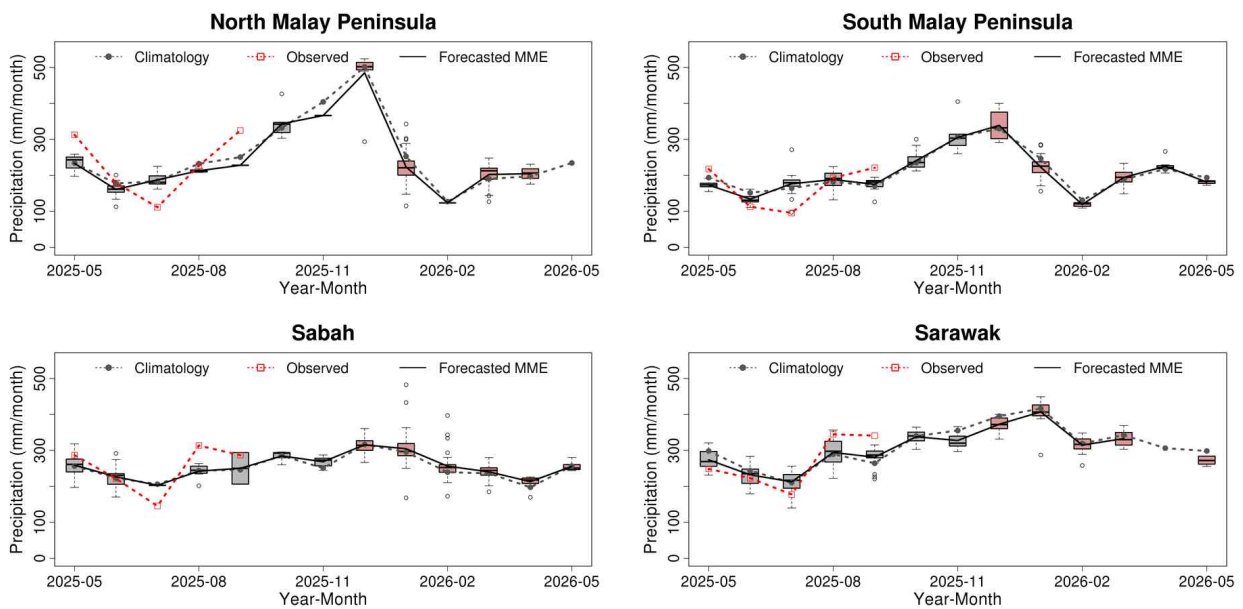


Figure 7.16. 6-month Precipitation Forecast for May2025-May2026 (issue:2025.11)

7.3.2. 고해상도 산불 예측 시스템 시범 운영

산불 예측 시스템은 현재 4개의 지역으로 정보를 나누어 제공하고 있다. 하지만, 산불 발생 위험은 지역이 아니기 때문에 공간에 대한 예측 정보 제공이 필요하다. 더 정확한 정보를 제공하기 위해 지역별 정보를 1X1 격자별로 자료를 생산하기 위해 현재의 FHEWS 프로세스를 새롭게 구성하였다. FHEWS의 격자 정보 생산을 위해서는 크게 관측자료의 처리와 Hindcast 자료 처리, Forecast 자료 처리를 통해 격자 정보 결과를 생산하였다. 관측자료는 강수 관측자료

인 CHIRPS의 일 자료를 수집하고, 월 자료로 산출하여 지역별, 격자별 월 자료를 생산한다. 생산된 CHIRPS와 APCC의 개별모델의 Hindcast 기간을 대상으로 오차 보정을 수행하고, 평가지수 산출을 통해 Forecast에서 활용하기 위한 개별모델을 산출한다. 이후에 Forecast 기간의 개별모델 자료를 오차 보정을 수행하고, Hindcast 기간의 평가를 통해 선정된 개별모델 자료를 활용하여 최종 격자 자료를 생산하였다. 고해상도 산불 예측 정보를 제공하기 위해 산불 예측 시스템 격자 정보 생산을 위한 구조 설계하고 관측자료의 처리가 Province 기반에서 격자 기반으로 변경됨에 따라 자료 처리 방법과 관리 체계를 재설계하였으며 고해상도 격자 자료의 처리 및 생산 효율화를 위해 자료 저장 및 처리 방식에 대한 새로운 설계 방식을 추가하였다. Hindcast와 Forecast 자료 처리 방식 또한 격자 정보 생산 처리를 위한 방식으로 변경되고, 자료 저장 방식 및 처리 방식에 대한 새로운 설계가 필요하여 구축하였다. Hindcast와 Forecast의 오차 보정을 통해 최종 산출물인 산불 예측 격자 정보 생산을 수행하고, 격자 정보들의 경보 기준은 기존의 해당 지역을 기준으로 생산되도록 하였다.

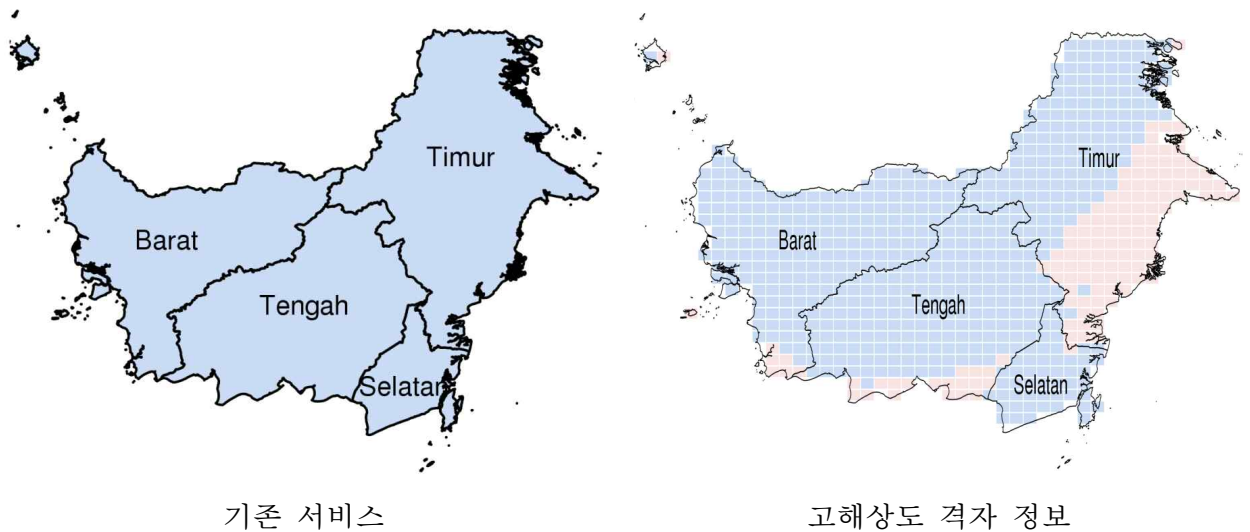


Figure 7.17. Map providing High-Resolution Grid information for Moroneo Island

고해상도 격자 기반 예측 정보 시범 생산은 인도네시아 보르네오섬과 말레이시아 지역에 대해 실시하였다. 자료 처리 및 예보생산에 사용되는 전산 자원과 시간이 많이 요구되고 있어 자료 처리의 경량화 작업이 필요하다. 말레이시아 지역에 대한 예측에 대한 최적화 작업도 필요한 것으로 나타났다.

7.4. 지역기후포럼(Regional Climate Outlook Forum) 참석

7.4.1. 동남아시아 기후 전망 포럼(ASEANCOF 24, 25)

아세안 기후 전망 포럼(ASEANCOF)은 지역 규모에서 합의 기반의 계절 기후 전망과 관련 정보를 공동으로 개발하기 위한 행사로 포럼의 전망과 활동은 아세안 전문 기상센터(ASMC)의 주요 역할 중 하나인 아세안 지역의 기후 및 계절 예측 수행에 기여하고 있으며 이는 아세안 회원국의 국가 기상·수문 서비스(NMHSs)의 전문성을 결집하여 이뤄진다.

2021년에는 ASEANCOF의 장기적 발전을 안내하고 지원하기 위해, 특히 객관적 전망의 구현과 관련하여 ASEANCOF 워킹그룹이 설립되었으며 아세안 전문 기상센터(ASMC)의 주최로 2025년도에 제 24차 ASEANCOF(ASEANCOF-24)와 제 25차 ASEANCOF(ASEANCOF-25)이 진행되었다. 제 24차 ASEANCOF(ASEANCOF-24)는 캄보디아 수자원·기상부(MOWRAM), RIMES, ASMC, ASEANCOF 워킹그룹, 세계기상기구(WMO)가 공동으로 주최했다. 본 회의(COF proper)에서는 아세안 회원국 NMHSs 참가자들이 아세안 지역 2025년 북반구 여름 몬순에 대한 합의 전망을 작성했습니다. 2025년 6~8월(JJA) 전망은 NMHSs의 발표, 설문, 그리고 동남아시아의 현재 기후 상황 및 예측에 관한 논의를 포함한 하이브리드 세션을 통해 합의되었다. ASEANCOF-24의 주제는 기후 서비스와 폭염 건강(Heat Health)이었으며 마지막 날에는 글로벌 건강 정보 네트워크(GHHIN) 동남아시아 허브가 공유 세션을 진행했으며, 이어서 유엔 아시아태평양경제사회위원회(UN ESCAP), FAO, 라오스와 캄보디아의 농업 및 보건 대표 등 다양한 분야의 대표와 생산자들이 참여한 일반 공유 세션이 열렸다.

WMO 계절예측 선도센터는 24차 동남아시아 기후 전망 포럼 (ASEANCOF-24)와 25차 동남아시아 기후전망 포럼(ASEANCOF-25)에 참석하여 WMO 선도센터의 아세안 지역 계절 예측 전망을 발표하였다.



Figure 7.18. Participated in ASEANCOF and delivered a presentation on WMO's seasonal prediction outlook

7.4.2. 남아시아 기후 전망 포럼(SASCOF)

남아시아 기후 전망 포럼(SASCOF)은 2009년에 설립되었으며 인도 기상청(IMD)이 주최한다. 이 포럼은 아프가니스탄, 방글라데시, 부탄, 인도, 몰디브, 미얀마, 네팔, 파키스탄, 스리랑카를 포함하며, 각국이 순환 방식으로 포럼을 개최하고 있다. 세계기상기구(WMO)는 2010년부터 남아시아 국가들이 남아시아 계절 기후 전망 포럼(SASCOF)을 개최하는 것을 지원하고 있으며 포럼의 목적은 지역 규모에서 합의된 계절 기후 정보를 마련하여 국가 차원의 전망을 준비하는 데 일관된 기반을 제공하는 것이다.

SASCOF 플랫폼은 또한 사용자 부문과의 상호작용을 통해 기후 정보 활용을 이해하고 강화하는 역할을 하며, 이는 세계 기후 서비스 프레임 워크(GFCS)가 구상하는 것과 일치한다. SASCOF의 CSUF 특별 세션은 물, 농업, 재해 위험 감소, 보건 분야의 사용자들과의 접점을 중점적으로 다루며, 계절 기후 정보를 해석하고 각 분야의 특정 요구를 이해하여 기후 정보를 더욱 맞춤화하는 데 목적을 두고 있다.

포럼의 목적은 지역 규모에서 합의된 계절 기후 정보를 마련하여 국가 차원의 전망을 준비하는 데 일관된 기반을 제공하는 것입니다. 이러한 플랫폼은 또한 사용자 부문과의 상호작용을 통해 기후 정보 활용을 이해하고 강화하는 역할을 합니다.

25년도에 제31차 남아시아 기후 전망 포럼(SASCOF-31)은 2025년 4월 28~30일 인도 푸네에서 개최되었고 인도 기상청(IMD) 푸네 지역 기후센터(RCC), 영국 기상청(UKMO), 아시아·아프리카 지역 통합 다중위험 조기경보 시스템(RIMES), 유엔 아시아태평양경제사회 위원회(UNESCAP), 세계기상기구(WMO)가 공동으로 주관하였다. 제32차 남아시아 기후 전망 포럼(SASCOF-32)은 2025년 9월 25일에 온라인으로 진행되었으며 인도, 아프가니스탄, 방글라데시, 부탄, 몰디브, 네팔, 파키스탄, 스리랑카, 미얀마 등이 참여하였다.

WMO 계절 예측 선도센터는 31차 남아시아 기후 전망 포럼 (SASCOF-31)와 32차 남아시아 기후전망 포럼 (SASCOF-32)에 참석하여 WMO 선도센터의 남아시아 지역 계절 예측 전망을 발표하였다.



Figure 7.19. Participated in ASEANCOF and delivered a presentation on WMO's seasonal prediction outlook

8. 요약 및 결론

이상기후에 대응하기 위해서 기존의 월평균 단정예측이나 삼분위 확률예측으로는 충분하지 않다. 따라서 이상기후 대응을 위한 새로운 예측 콘텐츠를 개발하고자 하며, 목표로 하는 신규 콘텐츠는 이상치(Extreme) 및 물리량 기준의 계절예측 정보, 월강수와 일강수의 특성을 연계한 자료이다. 이상치(Extreme) 및 물리량 기준의 계절예측 정보는 원시 역학 및 그랜드 앙상블의 기후예측자료 분포가 관측자료의 분포와 상이할 경우 제대로된 이상기후 대응 정보를 산출할 수 없다. 따라서, 1차년도인 2025년 당해년도에는 관측 및 기후예측자료의 자료 분포 특성을 먼저 분석하고, 관측과의 자료 분포 차이를 만드는 역학 모델 및 그랜드 앙상블 자료에 내재된 기후학적 바이어스(평균, 범위, 형태)를 살펴보았다. 또한, 서로 다른 바이어스를 가진 다량의 앙상블 자료의 분포를 관측의 물리량 분포에 적합하게 만들기 위해서 다양한 보정 방법을 적용하였다. 보정 전후 자료 분포의 변화를 살펴보고, 이러한 변화가 이상치(Extreme) 및 물리량 기준의 계절예측에 어떻게 작용하는지 살펴보았다. 다양한 보정은 원시 기후예측자료의 기후학적 분포를 관측과 유사하게 매칭하였다. 그러나, 이상치(Extreme) 및 물리량 기준의 계절예측의 예측성능에 있어서는 다소 상이한 결과를 도출하였다. 따라서, 2차년도에는 이상치(Extreme) 및 물리량 기준의 계절예측을 위한 기법을 개발하기 위해서 좀 더 심도있는 연구를 진행할 예정이다. 즉, 기존에는 Hindcast 자료만을 활용하여 보정 및 예측을 시행한 반면, 내년에는 Forecast 자료까지 활용하여 자료의 독립성을 확보할 예정이다. 또한, 기존에는 확률분포 추시 자료내 순위를 매기는 방법을 사용하였으나, 샘플의 한계 등을 극복하기 위해 내년에는 자료 특성을 반영한 모수화 등을 고려할 예정이다.

월강수와 일강수의 특성을 연계하기 위해서, 월 총강수량과 일강수의 특성에 대한 기초분석을 수행하였다. 월 총강수량은 기본적으로 강수일수와 강수강도의 조합으로 구성될 수 있다. 따라서, 1997년부터 2014년까지의 월 총강수량에 대한 강수일수와 강수강도에 대한 각각의 상관관계를 분석하였다. 지역에 따라 서로 다른 상관관계를 보였으나, 전반적으로 강수일수보다 강수강도가 총강수량 변동을 더 크게 지배하는 경향을 확인하였다. 또한 두 상관관계의 차이에 대한 유의성을 평가하여 극한강수 발생 가능지역을 도출하였으며, 이를 해당 지역과 시기의 강수 특성을 바탕으로 해석하였다. 2차년도에는 관측 분석의 신뢰도를 향상하고 예측 정보와의 결합 가능성을 고려하고자 한다. 즉, 다른 강수 관측자료에 기반한 분석을 통해 분석 결과에 대한 신뢰도를 확보하고, 도출된 극한강수 발생 가능 지역에 대한 예측 성능을 평가할 예정이다.

계절예측모델에서 생산되는 예측 정보는 기온, 강수, 지위고도 등의 변수에 대한 결정론적 또는 확률론적 예측 정보이며 예측성 평가도 이러한 변수에 대한 스코어를 중심으로 이루어져 왔다. 또한 실제 기후시스템에서 나타나는 주요 기후모드에 대한 모델의 재현성에 관한 분석이 개별적인 변동모드를 중심으로 산발적으로 이루어져 왔으나 APCC MME 예측시스템을 중심으로 한 체계적이고 종합적인 분석은 부족했고, hindcast 기간에 대한 분석 위주로 되어 최근 예측 기간에 대한 분석은 부족했다. 따라서 APCC MME 예측에서 최근 기후변동성을 고려한 모델의 주요 기후모드에 대한 예측성을 평가하고 분석된 정보를 종합적으로 파악할 수 있는 해석 가이드 체계를 구축해 예측에서 APCC MME의 실무 활용도를 높이고자 하였다. 1차년도인

2025년에는 해양과 대기의 주요 기후모드를 선정하고 모델 hindcast 기간과 실시간 예측 기간에 대한 예측성을 분석해 모델의 기본적인 기후모드 예측 성능에 대한 기반 정보를 구축하였다.

해양 기후모드는 열대 태평양의 ENSO와 북대서양 해수면온도의 변동성, 인도양 IOD와 IOB를 선정해 분석하였다. ENSO의 예측성을 다양한 Nino지수에서 평가했는데, Nino3.4 지수는 hindcast와 실시간 예측에서 높은 예측성을 나타냈다. 그러나 이전 연구들에서 제시했던 봄철 예측 장벽은 여전히 존재했고 실시간 예측에서 Nino3.4 지수의 늦봄~여름철 예측성은 hindcast보다 낮았다. ENSO 지수로 널리 쓰이는 Nino3.4 지수 외의 다른 지역 지수의 예측성은 대양의 중앙보다 대륙에 가까울수록 낮아 Nino1+2 지수와 NinoW 지수에서 다른 지역보다 예측성이 낮았다. NinoW 지수는 실시간 예측에서 예측성이 특히 낮아 모델의 서태평양 변동성 예측에 어려움이 있는 것으로 나타났다. 북대서양에서는 해수면온도의 tripole 패턴으로부터 변동성이 큰 중위도와 고위도 지역을 선정해 예측성을 분석하였다. 모델에서 중위도의 해수면온도 지수는 hindcast에서는 준수한 예측성을 보였으나 실시간 예측에서는 예측성이 낮았다. 고위도의 해수면온도 지수는 hindcast와 실시간 예측에서 일정 수준의 예측성이 있었다. 우리나라 기온과 직접적인 관련이 높은 지수는 중위도 지수였는데 실시간 예측에서는 예측성이 낮아 예측에 직접적인 활용은 어려워 보였다. 인도양의 기후모드는 ENSO에 비해서는 예측성이 떨어지지만 높은 예측성을 보여주었다. IOD는 여름, 가을에 우수한 스킵을 보여주면서 계절에 따라 예측력에 큰 차이가 있는 특징이 있고, IOB는 전반적으로 스킵이 좋으나 여름에는 선행시간이 길어질수록 스킵이 하락했다. 인도양은 지구온난화의 영향을 가장 민감하게 반영하는 대양으로, 2010년대 이후 지속적으로 높은 해수면 온도를 기록하고 있다. 이러한 장기적인 온난화 경향은 IOB에 뚜렷하게 나타났다.

대기 기후모드는 AO, NAO, NP, PNA, WP, SOI 지수의 hindcast 기간 예측성을 분석하였다. AO, NAO와 같이 고위도 기후 모드는 일부 계절(특히 겨울철)에만 제한적으로 유의미한 예측성을 보였으며, 전반적으로 예측성이 낮은 것으로 나타났다. 반면, 북태평양 및 북서태평양을 대표하는 NP, PNA, WP 지수는 주로 겨울철과 봄철에 상대적으로 높은 예측성을 보여 이는 실제 동아시아 지역 예보에 중요한 예측 인자로 활용될 가능성을 지닌 것으로 판단된다. 공간 상관 분석 결과도 유사한 경향이 나타나는데, 대부분의 대기 지수에서 겨울철의 공간 패턴 모의성을 비교적 양호하였으나, 전반적으로 관측에 비해 패턴의 강도가 약한 한계가 있었다. 그리고 모델에서는 ENSO의 중위도 반응을 과대모의 하는 특징이 공통적으로 나타났다. 이로 인해 대기 지수와 ENSO 간의 상관성이 모델에서 실제 관측보다 높게 나타나고, 모델 원격 반응에서도 ENSO의 영향이 과대하게 반영되고 있음을 확인하였다. 이러한 ENSO 과대 의존성을 제거하기 위해 회귀분석을 통해 ENSO 반응을 선형적으로 제거한 결과, 대기 지수의 고유한 변동성까지 함께 제거될 수 있음을 시사하며, 모델의 대기 반응 특성을 진단하거나 보정하기 위해서는 보다 복합적이고 비선형적인 접근이 필요함을 제시하였다. 이 연구에서 확인된 대기 기후모드의 지수별, 계절별 예측 특성은 향후 모델의 기후모드에 대한 해석 가이드라인 수립 및 MME 모델 개선 혹은 보정에 기초자료로 활용될 수 있을 것이다. 그러나 APCC MME 시스템은 기후 평균 기간에서 대기 기후 모드의 독립적인 변동성을 충분히 재현하지 못하는 한계가 있으며 향후 연구에서는 ENSO와의 상호작용을 정량적으로 구분할 수 있는 비선형적 통계적 보정 등을 통해 예측 신뢰도를 향상시킬 방안을

모색할 필요가 있다.

APCC 계절예측은 전 세계 11개국 16개 기상청 및 주요 기관으로부터 수집한 전지구 예측모델의 500개 이상의 앙상블 자료를 기반으로 다중모델앙상블(Multi-Model Ensemble, MME) 기법을 적용하여 생산된다. 각 참여기관으로부터 예측 자료를 수집하고, 품질관리와 자료처리 과정을 거쳐 향후 6개월까지의 계절예측 정보를 생산하며, 감시 및 검증 정보와 함께 매월 APCC 홈페이지 및 이메일을 통해 제공하고 있다. APCC는 MME 계절예측시스템의 성능 향상을 위해 매년 지속적인 개선을 추진하고 있으며, 금년에는 참여모델 확대 및 hindcast 기후값 기간 확장, 고해상도(1°) 검증정보 제공 등 다양한 개선이 이루어졌다. 특히 MME 예측성능은 참여 모델의 개별 성능에 비례하므로 우수 모델의 확보가 중요하며, 이를 위해 8월 개최된 제6차 Model Providers Meeting에서 모델 운영현황과 향후 개선 계획이 공유되었다. 이 과정에서 HMC의 hindcast 기간 확장 소식이 있었고, 개선 모델 자료를 조속히 확보하여 9월 예측부터 즉시 반영하였다. 또한 CWA(2월), CMCC(8월), METFR(5월) 기관의 모델이 개선되었고, 2월부터 PKNU 모델이 신규 참여하여 MME 모델 구성이 강화되었다. 모델 개선에 따른 자료 수집 및 전처리 시스템도 함께 고도화하였으며, 개선 전·후 예측성능 비교 분석을 통해 개선 효과를 검토하였다. 9월에는 hindcast 기후값 기간이 최근 시점까지 확장되어 1993-2016년으로 변경되었고, 10월에는 새롭게 개선된 ENSO 경보 정보를 제공하기 시작하였으며, 12월에는 고해상도 검증자료 제공을 개시하였다. 더불어 참여기관 모델 예측자료의 오류를 발견하고 피드백을 제공함으로써, APCC가 예측자료 검증 및 품질관리 측면에서 협력 플랫폼으로서의 기능을 수행하고 있음을 확인하였다. 이러한 일련의 개선 결과, 기온과 강수 MME 예측 모두에서 2017년 이후 뚜렷한 성능 향상 추세가 나타났으며, 2015-2017년 평균 대비 2023-2025년 평균 ACC는 기온이 약 8.8%, 강수가 약 8.1% 향상된 것으로 분석되었다. 또한 ENSO 예측 신뢰도 향상을 위해 기후변화 영향을 고려한 relative Niño index 분석을 수행하여 해당 지수의 도입 타당성과 현업 적용 가능성을 제시하였다. 아울러 국내 기후예측 협력 체계의 효율성 강화를 위해 APCC 3개월 전망 생산시스템을 자동화하였으며, 이를 통해 현업 운영에 소요되는 시간을 50% 이상 단축하고 우리나라 강수 및 기온 예측정보를 고해상도 기반으로 전환하였다.

2025년 BSISO 현업 운영에서는 대만 기상청(CWA) 참여모델 변경에 따라 수평 및 연직 해상도가 증가하여 BSISO 예측장의 공간 표현력과 물리적 정합성이 향상되었다. 이를 통해 아시아 몬순 및 대류 활동과 관련된 계절내 변동성 예측 성능 개선이 기대된다. 또한 BSISO 입력자료 처리시스템을 자체적으로 구축하여, 기존 외부 입력자료 의존 구조에서 벗어나 ECMWF 모델 예측장을 APCC BSOSP 현업 참여모델로 직접 활용할 수 있는 운영 체계를 확립하였다. 이를 통해 ECMWF BSISO 예측 정보가 기상청 기후예측과의 1개월 예보 회의에 참고 자료로 지속 제공되고 있다. 아울러 향후 APCC BSISO 계절내예측의 현업화에 대비하여 원시 예측자료가 확보될 경우 APCC 자체 계절내 예측 자료를 BSISO 입력자료로 직접 활용할 수 있는 기반도 함께 마련하였다. 이를 통해 BSISO 현업 참여모델 확대 가능성과 예측 정보의 자립적 활용 체계가 한층 강화되었다.

세계기상기구 기후 예측 다중모델 앙상블 선도센터(LC-SPMME)의 운영의 안정성은 예측자료의 다양성과 신뢰성을 높이는 중요한 기반이 되었다. WMO 선도센터는 각 GPC에서 생산된

forecast와 hindcast 자료를 표준화하여 2m 기온, 강수, 해수면 온도, 해면기압 등 주요 변수에 대한 다중모델 앙상블(MME) 예측을 매일 생산하고 있으며, 단순 합성(SCM), 선형회귀(SLR), 특이값분해(SVD), 유전알고리즘(GA) 등 다양한 결정론적 기법과 확률론적 기법을 병행하고 예측 정확성을 제고하고 있다. WMO 선도센터 검증 체계에 따라 ACC, RMSE, MSSS, GSS 등 결정론적 지표와 Brier Score, ROC Curve, Reliability Diagram 등 확률론적 지표를 활용하여 예측 결과를 검증하였다. 이를 통해 생산된 계절 예측 정보의 신뢰성을 확보하고, WMO 회원국과 국제 사회에 공식적으로 제공된다. WMO 선도센터를 운영하면서 각 GPC의 모델들의 서비스 확대, 예측 기법 고도화, 검증 체계 강화 통해 계절 예측 정보의 활용성을 지속적으로 높여 나가고 있으며 오류 발견 때 즉시 해결하면서 WMO 회원국뿐 아니라 전 세계에 신뢰성 있는 정보 전달에 핵심적 역할을 담당하게 될 것이다.

산불 예측 정보 생산 및 제공 체계는 지역별 강수량 예측을 기반으로 확률적 산불 위험 등급을 산출하여, 인도네시아와 말레이시아 주요 지역에 대해 실질적인 조기경보 정보를 제공하는 데 목적을 두고 있다. 통계적 다운스케일링 모델과 단순 편향 보정(SBC) 기법을 활용하여 전 지구 기후모델 기반의 예측자료를 지역 맞춤형으로 변환함으로써, 산불 위험을 극심·높음·보통·낮음의 네 가지 범주로 구분하고 이를 지도 형태로 시각화하여 사용자에게 직관적으로 전달할 수 있도록 하였다. 이러한 접근은 산불 발생 가능성을 사전에 파악하고 대응 전략을 마련하는 데 중요한 기반을 제공한다. 또한 기존의 지역 단위 예측을 넘어, 1×1 격자 기반의 고해상도 산불 예측 시스템을 시범 운영함으로써 공간적 정밀성을 향상시켰다. CHIRPS 강수 관측자료와 APCC 개별모델의 Hindcast 및 Forecast 자료를 결합하여 오차 보정과 성능 평가를 수행하고, 이를 통해 격자 단위의 예측 정보를 생산하였다. 이 과정에서 자료 처리 방식과 저장 체계를 새롭게 설계하여 효율성을 높였으며, 격자 기반 산불 위험 정보를 제공함으로써 더욱 세밀한 지역별 대응이 가능해졌다. 고해상도 산불 예측 시범 운영 결과, 인도네시아 보르네오섬과 말레이시아 지역에서 고해상도 예측이 성공적으로 수행되었으나, 전산 자원과 처리시간이 많이 요구되는 한계가 확인되었다. 따라서 향후 자료 처리의 경량화 및 최적화 작업이 필수적이며, 특히 말레이시아 지역에 대한 예측 정확도를 높이기 위한 추가적인 개선이 필요하다.

WMO 선도센터의 지역 기후 포럼(Regional Climate Outlook Forum) 참석을 통해 지역 기후 전망을 발표하는 것은 WMO 다중모델 앙상블 예측 정보의 확대에 큰 역할을 수행하고 있다. 동남아시아 기후 전망 포럼(ASEANCOF)과 남아시아 기후 전망 포럼(SASCOF)은 지역 규모의 계절 기후 전망을 마련하고, 이를 각국의 국가 기상·수문 서비스(NMHSs)가 활용할 수 있도록 지원하는 중요한 플랫폼으로 자리매김하였다. ASEANCOF-24와 ASEANCOF-25에서는 아세안 전문 기상센터(ASMC)와 WMO를 비롯한 다양한 국제기구가 협력하여 폭염 건강(Heat Health)과 기후 서비스라는 주제를 중심으로 논의를 진행하였으며, 회원국들이 공동으로 여름 몬순 전망을 작성함으로써 지역 차원의 대응 역량을 강화하였다. SASCOF-31과 SASCOF-32 역시 인도 기상청(IMD)과 WMO의 주관 아래 개최되어, 남아시아 국가들이 합의된 계절 기후 정보를 마련하고 농업, 수자원, 보건, 재해 위험 감소 등 다양한 분야의 사용자들과의 연계를 통해 기후 정보 활용성을 높이고자 하였다.

Acknowledgement

본 연구는 APCC의 지원을 통해 수행되었습니다.

연구에 사용된 다중모델 앙상블 자료는 APCC MME Producing Centres (PCs)에 의해 생산된 hindcast/forecast 자료를 바탕으로 APCC가 수집, 재가공하였으며 자료를 생산/제공해주신 아시아·태평양경제협력체 기후센터(APCC, APEC Climate Center)에 감사드립니다.

References

- 김선태, 이윤영, 오지현, 임아영, 2018: APCC MME 계절 예측 자료 특성 분석: 기후변동모드, 영향, 그리고 다중 모형 비교. *APEC 기후센터 연구보고서*, APEC기후센터.
- 김유진, 김형진, 민영미, 송봉근, 이현주, 임아영, 임창묵, 정다운, 정임국, 최재원, 2023: APCC 기후정보 활용성 강화를 위한 고해상도 MME 계절내-계절예측시스템 기반구축 및 웹 콘텐츠 다양화, *APEC 기후센터 연구보고서* APEC기후센터.
- 김유진, 김형진, 송봉근, 이현주, 임아영, 임창묵, 정다운, 정임국, 최재원, 2022: APCC 기후정보 활용성 강화를 위한 고해상도 MME 계절내-계절예측시스템 기반구축 및 웹 콘텐츠 다양화. *APEC 기후센터 연구보고서* APEC기후센터.
- 이현록, 김상철, 신지현, 정주형, 2024: APCC 동적 기후정보서비스 시스템 구축. *APEC 기후센터 연구보고서* APEC기후센터.
- Barnston, A. G., M. K. Tippett, M. L. L'Heureux, S. Li, D. G. DeWitt, 2012: Skill of real-time seasonal ENSO model predictions during 2002-11: Is our capability increasing? *Bull. Am. Meteor. Soc.*, **93(5)**, 631-651, <https://doi.org/10.1175/BAMS-D-11-00111.1>
- Barnston, A. G., M. Chelliah, and S. B. Goldenberg, 1997: Documentation of a highly ENSO-related SST region in the equatorial Pacific: Research note. *Atmos.-Ocean*, **35**, 367-383, <https://doi.org/10.1080/07055900.1997.9649597>.
- Chen L., G. Li, J. Duan, 2024: Changed Relationship between the Spring North Atlantic Tripole Sea Surface Temperature Anomalies and the Summer Meridional Shift of the Asian Westerly Jet. *Atmosphere*, **15(8)**:922, <https://doi.org/10.3390/atmos15080922>
- Chen, Z., R. Wu, and Z. Wang, 2019: Impacts of Summer North Atlantic Sea Surface Temperature Anomalies on the East Asian Winter Monsoon Variability. *J. Climate*, **32(19)**, 6513-6532, <https://doi.org/10.1175/JCLI-D-19-0061.1>
- Doblas-Reyes, F. J., M. Deque, and J. P. Pielieuvre, 2000: Multi-model spread and probabilistic seasonal forecasts in PROVOST, *Quarterly Journal of the Royal Meteorological Society*, **126(567)**, 2069-2087.
- Guo, F., Liu, Q., Yang, J. et al., 2018: Three types of Indian Ocean Basin modes. *Clim. Dyn.*, **51**, 4357-4370, <https://doi.org/10.1007/s00382-017-3676-z>
- Hersbach, H. et al., 2020: The ERA5 global reanalysis, *Q.J.R. Meteorol. Soc.*, **146**, 1999-2049.
- Kharin, Viatcheslav V., and Frances W. Zwiers, 2003: On the ROC Score of Probability Forecasts in the Gaussian Setting. *J. Climate*, **16(24)**, 4145-4156.

- L'Heureux, Michelle L., Michael K. Tippett, Matthew C. Wheeler, Hanh Nguyen, Sugata Narsey, Nathaniel Johnson, Zeng-Zhen Hu, Andrew B. Watkins, Chris Lucas, Catherine Ganter, Emily Becker, Wanqiu Wang, and Tom Di Liberto. 2024. "A Relative Sea Surface Temperature Index for Classifying ENSO Events in a Changing Climate." *Journal of Climate* **37**(4): 1197-1211.
- Lee, Y.-H., S.-W. Yeh, J.-H. Kim, M.-K. Kim, 2024: The role of the North Atlantic Ocean on the increase in East Asia's spring extreme hot day occurrences across the early 2000s. *Sci. Rep.*, **14**, 9872. <https://doi.org/10.1038/s41598-024-59812-y>
- Lim, W.-I. and K.-H. Seo, 2019: Physical-Statistical Model for Summer Extreme Temperature Events over South Korea. *J. Climate*, **32**(6), 1725-1742, <https://doi.org/10.1175/JCLI-D-18-0201.1>
- Min, Y.-M., V.-N. Kryjov, and C.-K. Park, 2009: A probabilistic multimodel ensemble approach to seasonal prediction, *Weather and Forecasting*, **24**(3), 812-828.
- Monerie, P.-A., J. Robson, B. Dong, D. Hodson, 2021: Role of the Atlantic multidecadal variability in modulating East Asian climate. *Clim. Dyn.*, **56**, 381-398, <https://doi.org/10.1007/s00382-020-05477-y>
- Palmer, T. N., A. Alessandri, and U. Andersen, P. Cantelaube, M. Davey, P. Délecluse, M. Déqué, E. Díez, F. J. Doblas-Reyes, H. Feddersen, R. Graham, S. Gualdi, J.-F. Guérémy, R. Hagedorn, M. Hoshen, N. Keenlyside, M. Latif, A. Lazar, E. Maisonave, V. Marletto, Ap. P. Morse, B. Orfila, P. Rogel, J.-M. Terres, and M. C. Thomson, 2004: Development of a European multimodel ensemble system for seasonal-to-interannual prediction (DEMETER), *Bulletin of the American Meteorological Society*, **85**(6), 853-872.
- Peng, P., A. Kumar, H. van den Dool, and A. G. Barnston, 2002: An analysis of multi-model ensemble predictions for seasonal climate anomalies, *Journal of Geophysical Research: Atmospheres*, **107**(D23), ACL-18.
- Saji, N., Goswami, B., Vinayachandran, P. et al. 1999: A dipole mode in the tropical Indian Ocean. *Nature*, **401**, 360-363, <https://doi.org/10.1038/43854>.
- Sohn, S.-J., 2016: Diagnostics of the multi-model ensemble seasonal forecast of the APEC Climate Center: Forecast skill and predictability of ENSO and its response. *APCC Research Report*, APEC Climate Center.
- Tippett, M. K., M. Ranganathan, M. L'Heureux, A. G. Barnston, and T. DelSole, 2019: Assessing probabilistic predictions of ENSO phase and intensity from the North American Multimodel Ensemble. *Clim. Dyn.*, **53**, 7497-7518, <https://doi.org/10.1007/s00382-017-3721-y>
- van Oldenborgh, G. J., H. Hendon, T. Stockdale, M. L'Heureux, E. C. de Perez, R. Singh,

and M. van Aalst, 2021: Defining El Niño indices in a warming climate. *Environ. Res. Lett.*, **16**, 044003, <https://doi.org/10.1088/1748-9326/abe9ed>.

Wang, B., J.-Y. Lee, I.-S. Kang, J. Shukla, C.-K. Park, A. Kumar, J. Schemm, S. Cocke, J.-S. Kug, J.-J. Luo, T. Zhou, B. Wang, X. Fu, W.-T. Yun, O. Alves, E. K. Jin, J. Kinter, B. Kirtman, T. Krishnamurti, N. C. Lau, W. Lau, P. Pegion, T. Rosati, S. Schubert, W. Stern, M. Suarez, and T. Yamagata, 2009: Advance and prospectus of seasonal prediction: assessment of the APCC/CliPAS 14-model ensemble retrospective seasonal prediction (1980–2004), *Climate Dynamics*, **33**, 93–117.

World Meteorological Organization (WMO). 2017. WMO Guidelines on the Calculation of Climate Normals. WMO-No. 1203.

Xie, T., H. Gao, T. Ding, X. Chen, and W. Wang, 2025: Decadal variability of summer extreme heat in central-eastern China and its synergistic effects by the North Atlantic and tropical western Pacific SST. *npj Clim. Atmos. Sci.*, **8:201**, <https://doi.org/10.1038/s41612-025-01092-y>

Xu, S., Y. Fang, Y. Lin, X. Sun, X. Yang, and Z. Gong, 2023: Enhanced Impact of Autumn North Tropical Atlantic Sea Surface Temperature Anomalies on Subsequent Winter Snowfall in Northeast China after 2001. *J. Climate*, **36(2)**, 663–675. <https://doi.org/10.1175/JCLI-D-22-0333.1>

Yao J., L. Cen, M. Zheng, M. Sun, J. Yin, 2025: Contrasting Impacts of North Pacific and North Atlantic SST Anomalies on Summer Persistent Extreme Heat Events in Eastern China. *Atmosphere*, **16(8)**:901. <https://doi.org/10.3390/atmos16080901>

Zhang, C., Z. Zheng, S. Qiao, S. Lail, L. He, S. Chen, H. Lu, H. He, W. Qin, S. Yang, 2023: The interannual impact of the North Atlantic sea surface temperature on the surface air temperature over southern China in February. *Climate Dynamics*, **61**, 4849–4865, <https://doi.org/10.1007/s00382-023-06829-0>