

**이음새없는 예측을 위한 계절내-계절 통합 활용 기술 개발**

**Development of advancing  
subseasonal-to-seasonal forecasting approaches  
enabling seamless prediction**

**민영미, 송봉근, 양신일, 윤순조, 함수련**

**기후사업본부 예측기술개발과**

**2025.12.**

**아시아·태평양경제협력체 기후센터**

# Executive Summary

Since 2017, the Asia-Pacific Economic Cooperation Climate Center (APCC) has established a robust collaborative framework to support the Korea Meteorological Administration (KMA)'s operational 1-month forecast by collecting, processing, and providing the latest subseasonal prediction information. This study describes the stable operation of the subseasonal prediction system and the deep learning-based probabilistic temperature forecasting system tailored for this purpose. In addition, the migration and improvement of data collection and forecast production servers were carried out to enhance operational efficiency. Through a case study of August 2025, which recorded the second-highest temperatures on record, the system's performance in predicting detailed weather variability—which cannot be identified through monthly mean values alone—was verified. The results demonstrate the high utility of subseasonal prediction information in capturing intra-monthly variability. To address the limitation of seasonal prediction information in a rapidly changing climate, APCC pursued the development of a subseasonal prediction system designed to enhance the value of utilization.

To develop the APCC subseasonal prediction system, a wide range of global subseasonal-to-seasonal (S2S) prediction datasets were systematically collected and standardized. Using these datasets, it is confirmed that the Multi-Model Ensemble (MME) provides stable and superior performance within the subseasonal prediction range. In addition, prediction skill of SubC and S2S models, together with APCC's in-house model, SCoPS, was rigorously compared and validated. The group comprising the largest number of models exhibited the highest prediction skill, demonstrating that including a broad set of models can enhance MME performance. We also confirmed that the SubC project model due to the various component model composition can further increase the overall contribution to the MME. Also, we evaluated parametric probabilistic prediction methods for temperature and precipitation in order to identify methodologies optimized for the statistical characteristics of each variable. The results indicate that parametric methods outperform non-parametric approaches in terms of quantitative predictive skill and can effectively reduce spatial noise arising from an insufficient ensemble size. For precipitation in particular, we taken into account a hybrid gamma algorithm for the high frequency of dry events that automatically switches to a nonparametric method when the effective ensemble size is insufficient.

Building on these research findings, we established the model configuration and probabilistic methods required for a APCC subseasonal prediction system. The system ingests weekly forecast data from 10 models (including APCC's SCoPS, BOM, NCEP, HMC, etc.), to generate subseasonal prediction products. Data acquisition employs various methods, such as FTP, the ECMWF API, and the IRI Data Library, depending on the provider. A critical component of the MME system is the automated pre-processing system. All individual model

data is standardized to a 1-degree resolution, transformed into various mean fields (weekly, 1-4 week mean, etc.), and converted into the NetCDF format. For the final MME production, the Simple Composite Method (SCM) is used for deterministic forecasts, while the Hybrid Gamma (Mixed Gamma + Quantile) method is employed for probabilistic forecasts. This integrated system allows for the production and display of MME prediction results, initialized to start every Monday.

To diversify and enhance the usability of subseasonal information, the study explored and identified seamless content that integrates subseasonal (weekly) and monthly forecast information. We identified products that can be delivered immediately such as integrated monthly/weekly probability distributions and weekly variability information, as well as more advance products requiring additional technical development including probabilities of intramonthly extreme events. By distinguishing these contents, we provides a clear roadmap for APCC to become a leading provider of integrated subseasonal-seasonal climate information. The approaches and findings presented herein are expected to enhance APCC's competitiveness and expand its role in next-generation climate services.

To include SCoPS as one of the contributing models, we developed a real-time subseasonal forecast system that produces 60-day forecasts every week, based on seasonal forecasts every month. To facilitate this, initial fields are produced by automatically collecting CFS analysis fields and ARGO ocean observation data every Thursday for the preceding week (Wednesday to Tuesday). SCoPS performs the 60-day forecast with 10-ensemble member from every Tuesday, and the processes including initial, forecast, post-processing production are completed by Friday. This forecast result is then utilized as an input for the MME subseasonal forecast performed the following Monday. However, given the relatively old development baseline of SCoPS and its lower skill compared with other MME participating models, there is clear need to reduce its systematic errors. This study therefore focused on reducing errors in the initial conditions first for SCoPS and, in turn, decreasing subseasonal forecast errors.

To reduce land-related initial errors, which are critical for subseasonal prediction, we developed a soil moisture initialization technique for SCoPS and quantitatively evaluated its impact. Using the Ensemble Adjustment Kalman Filter (EAKF) algorithm with ERA5-Land reanalysis data, we conducted hindcast experiments for 2003-2016. Initialization achieved 99.3% global RMSE reduction within 10-12 days, with soil moisture memory persisting 30-40 days. Land-atmosphere coupling strengthened significantly over mid-latitude continental regions, particularly Central US and Southeastern Europe. Temperature forecast skill improved 10-60% regionally for 16-30 day lead times, with sustained improvements up to 60 days over regions with strong coupling. Precipitation showed no significant response, consistent with its primary control by atmospheric circulation rather than land surface conditions. The causal chain from initialization → memory → coupling → predictability was quantitatively established,

demonstrating that soil moisture initialization effectively contributes to subseasonal prediction through physically consistent mechanisms.

We also examined how improvements in oceanic and atmospheric initial conditions influence prediction performance on both subseasonal and seasonal time scales. The ocean-initialized experiment effectively reduced the long-standing warm biases and overly deep thermocline in the eastern Pacific, but it has only a limited and weakly time-evolving impact on atmospheric variables and subseasonal prediction skill. In contrast, the atmosphere-initialized experiment shows a more rapid and direct response: global, tropical, and East Asian mean near-surface temperature errors are consistently reduced across lead times, and the large-scale lower- and upper-tropospheric circulation is improved. These changes in temperature and wind fields enhance lower-tropospheric humidity and precipitation forecasts associated with the East Asian summer monsoon.

On the basis of these results, we have initiated pilot operations that newly established APCC subseasonal prediction to provide enhanced forecast information. We plan to develop display systems for weekly prediction products, select highly useful contents for operational dissemination. New products such as forecasts based on improved SCoPS initial conditions and probabilities of intramonthly extreme events will be incorporated on a continuing basis. Through these enhancements and expansions, the subseasonal prediction information developed in this study is expected to strengthen forecast support for KMA and improve climate prediction services across the Asia-Pacific region.

## 국문 요약

아태기후센터(Asia-Pacific Economic Cooperation Climate Center, APCC)는 2017년부터 기상청의 1개월 전망 업무를 지원하기 위해 최신 계절내예측 정보를 수집하고 이를 가공하여 제공하는 협력 체계를 공고히 해왔다. 이 연구에서는 기상청 1개월 전망 지원을 위한 계절내예측 시스템과 딥러닝 기술을 적용한 기온 확률예측 시스템을 운영하였으며, 시스템 운영의 효율성 제고를 위해 자료 수집 및 예측 생산 서버의 이전과 개선 업무를 수행하였다. 또한, 역대 두 번째로 높은 기온을 기록했던 2025년 8월의 사례 분석을 통해, 단순 월평균 값만으로는 파악하기 어려운 상세한 기상 변동성에 대한 예측 성능을 검증하였다. 이를 통해 월내 변동성 파악을 위해 계절내예측 정보가 높은 유효성을 가지고 있음을 확인하였다. 그러나 현재 생산하는 결과만으로는 차별화된 계절내예측 정보를 생산하기에 어려움이 있으며 APCC 홈페이지를 통해 제공되는 계절예측 정보를 보완하기에는 무리가 있다. 급변하는 기후 특성들을 고려하고 계절예측 정보의 한계를 극복하기 위해 APCC는 계절내예측 시스템을 구축하여 그 활용 가치를 높여 보고자 하였다.

이를 위해 전세계 다양한 계절내(Subseasonal to Seasonal, S2S) 예측정보를 체계적으로 수집·표준화하였으며, 기후값 및 다양한 예측력 평가를 통해 계절내예측에서의 다중모델앙상블(Multi-Model Ensemble, MME) 활용성을 확인하였다. 또한 다양한 모델 자료와 APCC 자체모델을 그룹으로 구성하여 예측력을 비교·검증하고, 모델 간 상대적인 예측력 평가 및 MME 기여 정도를 정량적으로 분석하였다. 최대한 많은 모델이 포함된 그룹의 예측성이 가장 높게 나타났으며, 다양한 모델 성분으로 구성된 SubC 프로젝트 모델 자료가 MME의 기여도를 높일 수 있음을 확인하였다. 또한, 변수별 통계적 특성에 최적화된 확률예측 방법론을 선정하기 위해 기온과 강수에 대한 모수화 방법을 검증하였다. 그 결과, 기온과 강수량 모두에서 모수화 방법이 비모수적 방법 대비 정량적 예측 성능에서 우위를 점하고, 앙상블 부족으로 인한 공간적 노이즈를 개선할 수 있음을 확인하였다. 특히 강수량의 경우 무강수 빈도가 높은 분포 특성을 고려하여, 유효 앙상블 부족 시 자동으로 비모수적 방법으로 전환하는 하이브리드 감마 알고리즘을 도입해 전 지구적 예측 안정성을 확보하였다.

이러한 연구 결과들을 기반으로 APCC 계절내예측 시스템의 필요한 모델 구성 및 확률 방법을 정립하였다. APCC in-house 모델인 SCoPS(Seamless Coupled Prediction System)를 포함한 총 10개 모델의 예측자료를 매주 수집하여 계절내예측 정보를 생산할 수 있는 MME 계절내예측 시스템을 구축하였다. 자료 수집은 FTP, API 등의 방식을 활용하며, 이는 외부망의 FTP 서버를 통해 자동으로 이루어진다. 수집된 자료는 내부망의 HPC 서버로 다운로드되어 전처리 과정을 거친다. 전처리시스템은 모든 개별 모델 자료를 1도 해상도로 표준화하고, 주평균, 1~4주 평균 등 다양한 형태로 가공하며, 파일 형식은 모두 NetCDF로 변환한다. 최종 MME 예측에는 단정예측을 위한 SCM(Simple Composite Method)과 확률예측을 위한 Hybrid Gamma 기법이 사용되며, 이 시스템을 통해 매주 월요일 예측 시작일 기준의 4주 예측 정보가 생산 및 표출된다.

계절내예측 정보의 다양화와 활용성을 위해 계절내-계절(월) 정보를 자연스럽게 연결하는 seamless 콘텐츠를 발굴하였다. 월/주간 통합 확률 분포 및 주간 변동 정보를 비롯한 즉시 서

비스 가능한 콘텐츠와 월내 극한발생 확률 등을 정보를 포함하는 기술 개발이 필요한 콘텐츠를 단계적으로 제시하여, 향후 APCC에서 계절내-계절 간 연계 정보 서비스를 제공할 수 있는 기반을 마련하고자 하였다. 본 연구에서 제시한 예측 정보들은 APCC 예측서비스의 확장성과 경쟁력을 강화할 수 있을 것으로 기대한다.

한편, APCC 계절내예측 시스템의 참여 모델로 SCoPS를 포함하기 위해서는 SCoPS 계절내 예측 자료를 매주 생산해야 한다. 기존 월 단위로 운영되던 기존 모델을 매주 60일 예측장을 생산하는 실시간 계절내예측 시스템을 구축하였다. 이를 위해 CFS 분석장 및 ARGO 해양관측 자료를 매주 목요일에 지난 일주일 단위(수요일~화요일)로 자동으로 수집하여 초기장을 생산한다. SCoPS는 매주 화요일 초기장을 사용하여 총 10개의 앙상블로 60일 예측을 수행하며, 표준화 과정을 거쳐 금요일에 계절내예측 자료가 생산된다. 이 예측 결과는 다음 월요일에 수행되는 MME 계절내예측의 입력 자료로 활용된다. 다만, SCoPS의 개발 시점이 오래된 점과 다른 참여 모델과의 성능 비교에서의 한계 등을 고려하였을 때 계통적 오차를 줄이는 방안이 필요하다고 판단된다. 따라서, 본 연구에서는 SCoPS 초기장의 오차를 감소시키고 계절내예측의 오차를 줄여보고자 하였다.

계절내예측에 중요한 요소인 지면 관련 초기 오차를 감소시키기 위해 SCoPS를 위한 토양 수분 초기화 기술을 개발하고 그 효과를 정량적으로 평가하였다. ERA5-Land 재분석 자료와 EAKF(Ensemble Adjustable Kalman Filter) 자료동화 기법을 활용하여 2003-2016년 여름철 hindcast 실험을 수행하였다. 그 결과, 토양 수분 초기화는 토양 수분 초기장의 RMSE를 99.3% 감소시켰다. 또한, 토양 수분 메모리 길이는 전지구 평균  $39 \pm 16$ 일, 미국 중서부와 남동유럽에서 약 30일로 나타났으며, 이 길이는 초기화 여부보다는 모형의 특성으로 결정됨을 확인하였다. 지면-대기 결합 특성은 미국 중서부에서 16-60일 리드타임 동안 46-101% 강화되었으며, 이는 전이대(transition zone)의 특성과 높은 증발 요구도에 기인한다. 이러한 결합 강화는 기온 예측 성능을 10-60% 증가시키지만, 강수 예측 성능은 유의미한 변화가 없었다. 본 연구는 초기화부터 예측 성능으로 이어지는 물리적 인과관계를 정량적으로 설명하였다.

또한, 해양 및 대기 초기 조건을 개선하고, 그 영향이 계절내-계절 규모 예측 성능에 어떻게 나타나는지를 조사하였다. 해양 연직 초기자료를 변경한 실험은 동태평양 수온약층이 전 연도에 걸쳐 과도하게 깊고 따뜻하게 모의되는 계통적 온난 오차를 효과적으로 감소시키지만, 대기 변수에 미치는 영향은 상대적으로 제한적이다. 두 실험의 차이가 리드타임 전 구간에 걸쳐 전반적으로 작고, 뚜렷한 시간적 변화 패턴도 확인되지 않으므로 해양 초기화 개선 효과가 계절내 예측에는 큰 영향을 주지 못하는 것으로 판단할 수 있다. 다만, 해양-대기 상호작용이 영향을 주는 계절 규모에서 해수면 온도를 약간 변화시킨다. 반면, 대기 초기자료의 변경으로 인한 영향은 빠르고 직접적으로 나타난다. ERA5 기반 대기 초기 조건을 적용한 실험에서는 전지구 및 열대, 동아시아 기온 성능이 기존 실험 대비 전 리드타임 구간에서 일관되게 감소하였고, 상하층 대규모 순환의 초기 상태를 안정화할 수 있음을 확인하였다. 계절내 규모와 함께 계절 규모에서도 고위도 및 서안경계류 주변의 SST 오차를 완화하는 등 개선 영향을 유지할 수 있음을 확인하였다.

이러한 결과들을 기반으로 새롭게 구축된 APCC 계절내예측 시스템을 활용하여 새로운 정

보를 제공하기 위한 시험운영을 시작하였다. 추후 주별 예측 정보 제공을 위한 표출 체계 및 활용성 높은 콘텐츠들을 선정하여 정식 서비스를 목표로 하고 있으며, 초기자료가 개선된 SCoPS 및 월내 극한 확률 등의 새로운 콘텐츠들이 계속해서 적용될 것이다. 이를 통해 개선, 확장된 계절내예측 정보는 기상청 및 아태지역 기후 예측 지원을 강화할 수 있을 것으로 기대한다.

# 목차

Executive Summary .....	i
국문 요약 .....	iv
목차 .....	vii
표 차례 .....	viii
그림 차례 .....	x
1. 서론 .....	1
2. 계절내예측 활용체계 구축 .....	5
2.1. 1/3개월 계절내-계절 예측 정보 생산 및 지원 .....	5
2.2. 최적의 확률 예측 방안 구성 .....	12
2.3. 최적의 MME 참여모델 구성 .....	40
2.4. 계절내예측 시스템 구축 .....	60
2.5. 계절내-계절 통합 활용 콘텐츠 발굴 .....	73
3. SCoPS 운영 및 개선 .....	85
3.1. SCoPS 계절내예측 실시간 운영 .....	85
3.2. 지면초기화 기술 개발 .....	97
3.3. 대기/해양 초기자료 최적화 .....	124
4. 요약 및 결론 .....	149
4.1. 계절내예측 활용 체계 구축 .....	149
4.2. SCoPS 운영 및 개선 .....	151
사사 .....	154
References .....	155
부록 A. MME 계절내예측 시험운영 결과(2025.11.24. 이후) .....	158

## 표 차례

Table 2.1. Characteristics of Models for KMA 1-Month prediction. ....	5
Table 2.2. Characteristics of Models for KMA 1-Month prediction. ....	14
Table 2.3. Comparison of precipitation parameterization methods. ....	17
Table 2.4. Quantitative comparison of RPSS differences for temperature (Gauss minus Quantile). ....	22
Table 2.5. Quantitative comparison of RPSS differences for precipitation (Hybrid_Gamma minus Quantile). ....	23
Table 2.6. Quantitative comparison of spatial noise reduction for temperature (Gauss minus Quantile). ....	29
Table 2.7. Quantitative comparison of spatial noise reduction for precipitation (Hybrid_Gamma minus Quantile). ....	30
Table 2.8. Comprehensive comparison of probabilistic forecast methodologies. ....	38
Table 2.9. Descriptions of S2S Project models. ....	41
Table 2.10. Descriptions of SubC Project models. ....	42
Table 2.11. Experimental design for sensitivity tests evaluating MME forecast skill across different model combinations. ....	57
Table 2.12. Strategic roadmap for APCC' s development of subseasonal-monthly seamless prediction contents. ....	73
Table 2.13. Strategic roadmap for APCC' s development of subseasonal-monthly seamless prediction contents. ....	75
Table 2.14. Three-phase strategic framework for APCC' s development of subseasonal-monthly seamless prediction contents. ....	75
Table 2.15. Summary of proposed quick-win subseasonal-monthly seamless prediction contents. .....	76
Table 2.16. Summary of proposed technical growth subseasonal-monthly seamless prediction contents. ....	76
Table 2.17. Summary of proposed next-phase subseasonal-monthly seamless prediction contents. ....	77
Table 2.18. Description of potential contents to bridge subseasonal and seasonal (monthly) forecasts. ....	77
Table 2.19. Z-score thresholds used to quantify the relative magnitude of week-to-week changes. ....	79
Table 2.20. Signal-to-noise thresholds used to quantify the relative reliability of week-to-week changes. ....	79
Table 3.1. Land surface initialization methods for soil moisture in S2S project participating institutions. (website= <a href="https://confluence.ecmwf.int/display/S2S/Models">https://confluence.ecmwf.int/display/S2S/Models</a> ) ....	98
Table 3.2. Comparison of global land surface reanalysis datasets for soil moisture initialization.	

.....	100
Table 3.3. Summer (JJA) hindcast configuration (2003–2016) with start dates and analysis lead times for the Northern Hemisphere. ....	108
Table 3.4. Statistics of RMSE reduction [%] and spatial correlation improvement (LAND minus CTRL) between model and ERA5 during the initialization period for the Global, Central United State (CUS), and Southeastern Europe (SEE) region. ....	111
Table 3.5. Soil moisture memory characteristics (e-folding time) for LAND and CTRL experiments. Values represent the time scale at which autocorrelation of initial soil moisture anomalies decays to 1/e (~0.37), averaged across all forecast initialization dates (n=112). ....	115
Table 3.6. Land-atmosphere coupling strength for different lead periods. Terrestrial coupling index (ISM,LH) represents correlation between soil moisture and latent heat flux. Atmospheric coupling index (ISM,T2m) represents correlation between soil moisture and 2-meter temperature. Values are averaged over 14-day windows centered at each lead period. ....	117
Table 3.7. Forecast skill (R2) for 2-meter temperature prediction at different lead periods. Skill is calculated against ERA5 reanalysis using anomaly correlation over all 112 hindcast cases (2003–2016 JJA season). Statistical significance is assessed using bootstrap method (n=1000, p < 0.05). ....	120

## 그림 차례

Figure 2.1. Sample of APCC 1 month forecast charts. ....	6
Figure 2.2. Sample of subseasonal model output for APCC 3-month forecast. ....	7
Figure 2.3. Week 3 and Week 4 forecast produced by the deep learning-based probabilistic temperature prediction system, initialized on 22 Sep 2025. ....	8
Figure 2.4. Time series of (left) daily mean temperature and (right) daily accumulated precipitation in Korea for August 2025. ....	9
Figure 2.5. Time-latitude Hovmöller diagram of 500hPa geopotential height anomalies averaged over 126°E–135°E, initialized on 28 July 2025. ....	9
Figure 2.6. Comparison of the monthly mean forecast (left) and weekly forecasts (right) for temperature and precipitation in August 2025, initialized on 28 July 2025. ....	10
Figure 2.7. The East Asia Extreme Climate Monitoring System on the APCC website. ....	11
Figure 2.8. Schematic diagram of the three probabilistic forecasting methodologies. ....	16
Figure 2.9. Global distribution of RPSS differences for temperature (T2M) forecasts (Gauss minus Quantile) across four S2S models. The maps display the difference in RPSS for ECMWF, APCC, ECCC, and NCEP models. Red regions (positive values) indicate areas where the Gauss method demonstrates higher predictive skill compared to the Quantile method. ....	19
Figure 2.10. Global distribution of RPSS differences for precipitation (PREC) forecasts (Hybrid_Gamma minus Quantile) across four S2S models. The maps display the difference in RPSS for ECMWF, APCC, ECCC, and NCEP models. Red regions (positive values) indicate areas where the Hybrid_Gamma method demonstrates higher predictive skill compared to the Quantile method. ....	20
Figure 2.11. Temporal evolution of RPSS differences for temperature (Gauss minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia). ....	21
Figure 2.12. Temporal evolution of RPSS differences for precipitation (Hybrid_Gamma minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia). ....	23
Figure 2.13. Temporal evolution of ROC AUC scores for extreme temperature events (>90th percentile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia). ....	24
Figure 2.14. Temporal evolution of ROC AUC scores for extreme precipitation events (>90th percentile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia). ....	25
Figure 2.15. Spatial distribution of Week 3 precipitation probability forecasts for S2S models (ECMWF, ECCC, NCEP, APCC) using the Quantile method. ....	26
Figure 2.16. Spatial distribution of Week 3 precipitation probability forecasts for S2S models	

(ECMWF, ECCO, NCEP, APCC) using the Hybrid_Gamma method. ....	26
Figure 2.17. Temporal evolution of spatial noise for temperature (Gauss minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia). ....	28
Figure 2.18. Temporal evolution of spatial noise for precipitation (Hybrid_Gamma minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia). ....	29
Figure 2.19. Global distribution of Kolmogorov-Smirnov (K-S) test failure rates for temperature forecast using the Gauss method. ....	32
Figure 2.20. Q-Q plots of ECMWF temperature Week 3 hindcast data for selected grid points. ....	33
Figure 2.21. Histograms of ECMWF temperature Week 3 hindcast data with fitted Gaussian curves for selected grid points. ....	33
Figure 2.22. Time series comparison of ECMWF temperature Week 3 probability forecasts at an ENSO-affected grid point(0°, 195°E). ....	34
Figure 2.23. Global distribution of Kolmogorov-Smirnov (K-S) test failure rates for precipitation forecast using the Mixed_Gamma method. ....	35
Figure 2.24. Histograms of ECMWF precipitation Week 3 hindcast data with fitted Mixed_Gamma curves for selected grid points. ....	36
Figure 2.25. Time series comparison of ECMWF precipitation Week 3 probability forecasts at an extreme dry grid point(30°, 60°E). (Top) Quantile method (Bottom) Mixed_Gamma method. ....	37
Figure 2.26. Time series comparison of ECMWF precipitation Week 3 probability forecasts at an extreme dry grid point(30°, 60°E). (Top) Quantile method (Bottom) Hybrid_Gamma method. ....	37
Figure 2.27. Mean bias in climatology for 2m temperature at four weeks for 19 models. ....	43
Figure 2.28. Mean bias in climatology for precipitation at four weeks for 19 models. ....	44
Figure 2.29. Temporal evolution of biases in long-term mean (LTM) and standard-deviation (LTS) of temperature, precipitation, and geopotential height over globe and East Asia increasing lead days from 1 to 32 for 19 models. Biase is defined as a mean value of differences relative to the observed LTM and LTS during all year around. ....	45
Figure 2.30. Schematic illustrating the harmonization of weekly forecast periods across individual models with differing initialization days. ....	46
Figure 2.31. Spatial distribution of temporal correlation coefficients for 2m temperature of individual models and DMME at 3-4 week means. ....	47
Figure 2.32. Spatial distribution of temporal correlation coefficients for precipitation of individual models and DMME at 3-4 week means. ....	48
Figure 2.33. Anomaly pattern correlation coefficient for temperature and precipitation of individual models and MME at 1-8 weeks, 3-4 and 1-4 week means. ....	49
Figure 2.34. Anomaly pattern correlation coefficient for temperature and precipitation of S2S	

and Sub project models and APCC at 1-8 weeks, 3-4 and 1-4 week means. ....	49
Figure 2.35. Accumulated Anomaly pattern correlation coefficient for temperature and precipitation of individual models, MME, and MME@v2024 at 1-8 weeks, 3-4 and 1-4 week means. ....	50
Figure 2.36. Spatial distribution of prediction skill difference between the MME including APCC and the MME excluding APCC. Positive values indicate regions where the inclusion of APCC enhances forecast skill, while negative values denote regions where their inclusion results in reduced skill. ....	51
Figure 2.37. MME skill difference in terms of anomlay pattern correlation coefficient over globe between the MME including APCC and the MME excluding APCC at each week and 3-4 & 1-4 week means. MME skill difference in terms of APCC at 3-4week means for each region. ....	52
Figure 2.38. Anomaly pattern correlation coefficient over South Asia and Australia for temperature and precipitation of individual models (blue line) and APCC (red line) at 1-8 weeks, 3-4 and 1-4 week means. ....	52
Figure 2.39. Spatial distribution of prediction skill difference between the MME including SubC models and the MME excluding SubC models. Positive values indicate regions where the inclusion of Sub models enhances forecast skill, while negative values denote regions where their inclusion results in reduced skill. ....	54
Figure 2.40. Anomaly pattern correlation coefficients between the MMEs including and excluding SubC models, and mean skill of participating models in MMEs including and excluding SubC models. MME efficiency for each variable and lead time is displayed with histograms. ....	55
Figure 2.41. Anomaly pattern correlation coefficient for MME summer prediction of global temperature and precipitation with different number of participating models based on Monte-Carlo simulation. ....	56
Figure 2.42. Anomaly pattern correlation coefficient for MMEs over globe at each week and 3-4/1-4 week means. Skill difference relative to MME is displayed with histograms (%). .....	57
Figure 2.43. Spatial distribution of prediction skill in MME and skill difference between the various MMEs and MME at 1-4 week mean. ....	58
Figure 2.44. MME skill difference of MME_APCC_SubC relative to MME_APCC, MME_S2S, and MME_KMA. ....	59
Figure 2.45. List of individual models participating in MME subseasonal forecast. ....	61
Figure 2.46. Data qcquisition from an internal network FTP server and preprocessing on an external network HPC server. ....	63
Figure 2.47. Schematic Diagram of the MME subseasonal forecast system, incuding data acquisition, preprocessing, MME execution, and graphic display processes. ....	66
Figure 2.48. Lead times of 10 individual models based on the MME forecast initial date of July 28, 2025. ....	67

Figure 2.49. Weekly mean MME deterministic forecast results (temperature) for the 4-week period from July 28 to August 24, 2025. ....	69
Figure 2.50. Weekly mean MME deterministic forecast results (precipitation) for the 4-week period from July 28 to August 24, 2025. ....	70
Figure 2.51. MME deterministic forecast results (temperature and precipitation) for the mean of weeks 1-4 and the mean of weeks 3-4, covering the period from July 28 to August 24, 2025. ....	70
Figure 2.52. Weekly mean MME probabilistic forecast results (temperature) for the 4-week period from July 28 to August 24, 2025. ....	71
Figure 2.53. Weekly mean MME probabilistic forecast results (precipitation) for the 4-week period from July 28 to August 24, 2025. ....	71
Figure 2.54. MME probabilistic forecast results (temperature and precipitation) for the mean of weeks 1-4 and the mean of weeks 3-4, covering the period from July 28 to August 24, 2025. ....	72
Figure 2.55. Proposed development pathway for seamless prediction systems, designed to ensure continuous and consistent forecast information across subseasonal and seasonal timescales. ....	74
Figure 2.56. Example products of week-to-week changes relative to last week means (20240101-07). ....	80
Figure 2.57. Example products of weekly and monthly probability distributions. ....	81
Figure 2.58. Time series of monthly means and daily temperature for Korea in July 2022. Distributions of correlation between monthly mean temperature and frequency of upper 90% temperature in July. ....	83
Figure 2.59. Example of time series with same means but different daily variations (extremes). ....	84
Figure 2.60. Example products of quantile-based extreme probability prediction. ....	84
Figure 3.1. Shell script for downloading CFSv2 data. ....	86
Figure 3.2. Python program for downloading CFSv2 temperature. ....	87
Figure 3.3. Shell script for downloading ARGO data. ....	88
Figure 3.4. Schematic diagram for generating 10 ensemble initial conditions and performing forecasts. ....	89
Figure 3.5. Comparison of PCC, RMSE, and DIFF (difference) for sea surface temperature between the CFS analysis and the 10-member ensemble SCoPS restart files on January 1, 2017. ....	90
Figure 3.6. Comparison of PCC, RMSE, and DIFF (difference) for sea surface temperature between the CFS analysis and the 10-member ensemble SCoPS restart files on January 5, 2017. ....	91
Figure 3.7. Ensemble distribution of the Nino3.4 index and the Nino3.4 region-averaged sea surface temperature in the 60-day forecast initialized on January 5, 2017. ....	92
Figure 3.8. Ensemble distribution of the East Asiaon region-averaged precipitation, ....	

temperature, geopotential height at 500hPa, and sea surface temperature in the 60-day forecast initialized on January 5, 2017. ....	93
Figure 3.9. Comparison of PCC, RMSE, and DIFF (difference) for sea surface temperature between the CFS analysis and the 10-member ensemble SCoPS restart files on January 1 2022. ....	94
Figure 3.10. Ensemble distribution of the Nino3.4 index and the Nino3.4 region-averaged sea surface temperature in the 60-day forecast initialized on January 1, 2022. ....	95
Figure 3.11. Ensemble distribution of the East Asiaon region-averaged precipitation, temperature, geopotential height at 500hPa, and sea surface temperature in the 60-day forecast initialized on January 1, 2022. ....	95
Figure 3.12. Sensitivity of initial soil wetness differences and temperature forecast bias to initialization timing and dataset choice (January 2014 case). ....	100
Figure 3.13. Spatial distribution of soil texture classes and corresponding porosity values in APCC SCoPS and ERA5-Land. ....	101
Figure 3.14. Comparison of maximum soil water capacity between MERRA2 and APCC SCoPS configurations. ....	102
Figure 3.15. Data conversion workflow for land surface initialization from reanalysis to model data. ....	103
Figure 3.16. Time series comparison of area-weighted global mean soil wetness by region for validation of soil moisture unit conversion across datasets (MERRA2, ERA5, CFSv2). ..	104
Figure 3.17. Schematic diagram of the APCC Subseasonal-to-Seasonal (S2S) Prediction System. ....	105
Figure 3.18. Parallel efficiency [%] and computational time [min] as a function of ECHAM5 core allocation. ....	107
Figure 3.19. Time series of global mean soil wetness [m] during each initialization period for ERA5 (black), LAND (orange), and CTRL (blue) experiments, respectively. RMSE is calculated between model and ERA5. Exponential decay fitting shows e-folding time of approximately 1.74-1.78 days for LAND experiment. Shaded areas represent $\pm 1$ standard deviation across 14 periods. ....	110
Figure 3.20. Spatial distribution of soil moisture at (left) Day 1 of initialization period and (right) D-day (end of initialization period) for (top) ERA5, (middle) CTRL, and (bottom) LAND-CTRL. Spatial correlation coefficients are indicated in panel. All values averaged over 112 samples. ....	112
Figure 3.21. Spatial distribution of soil moisture difference between LAND and CTRL experiments from Day 1 of initialization period to the end of initialization period for each start date, respectively. ....	113
Figure 3.22. Soil moisture memory comparison between LAND and CTRL experiments. (left) Time series of persistence of soil moisture memory [days] (autocorrelation) across 112 samples. (right) Spatial distribution of LAND soil moisture memory length (shadings) [days] with difference between LAND and CTRL experiments (markers mostly over $\pm$	

1.0 standard deviation). .....	114
Figure 3.23. Spatial distribution of land-atmosphere coupling strength for 16-30 day lead period. (top) Terrestrial coupling index (ISM,LH, W m <sup>-2</sup> ) for CTRL experiment. (bottom) Same for LAND experiment showing enhanced coupling over mid-latitude continental regions. ....	118
Figure 3.24. Spatial distribution of forecast skill for 16-30 day lead period. (left) temperature skill difference (LAND minus CTRL). (right) Same for precipitation skill difference. Stippling indicates statistical significance (p<0.05, bootstrap test with 1000 iterations). Statistical significance indicated robust improvements in regions with strong land-atmosphere coupling. ....	121
Figure 3.25. Schematic of the initialization procedure for the SCoPS system. ....	124
Figure 3.26. Workflow of the daily ENKF-based initialization for atmospheric and oceanic fields. ....	124
Figure 3.27. Comparison of ocean vertical temperature initial condition on May 1 for the years 2017-2019. (left) GODAS-based temperature anomaly, (middle) OPER-driven temperature anomaly, and (right) difference between OPER and OCNR experiments. ....	126
Figure 3.28. Vertical distribution of (left) temperature and (right) salinity differences between OPER and ONCR experiments at four depth levels (5m, 96m, 190m, and 380m). ....	127
Figure 3.29. Lead-time evolution (1-100 days) of the OCNR - OPER differences in (top) temperature and (bottom) salinity for eastern Pacific region. ....	128
Figure 3.30. Lead-time evolution (1-100 days) of the OCNR - OPER differences in (top) near-surface air temperature, and (bottom) 850 hPa specific humidity for the (left) eastern Pacific and (right) East Asia regions. The solid black line represents the ensemble mean and grey lines denote individual ensemble members. ....	129
Figure 3.31. Spatial distribution of the change in T2M RMSE difference rate (dRMSE) for the OCNR experiment. Negative values indicate reduced errors relative to the OPER experiment, whereas positive values denote increased errors. ....	130
Figure 3.32. Comparison of ocean surface and subsurface temperature initial condition on May 1 for the years 2017-2021. (left) GODAS-based temperature, (middle) OPER-driven temperature, and (right) difference between OPER and ATMR experiments. ....	131
Figure 3.33. Time series of the (top) global, (middle) tropics, and (bottom) east Asian for 2017-2021 averaged 2m temperature RMSE values for the OPER(blue) and ATMR(magenta) experiments over a 1-365-day period. ....	132
Figure 3.34. Spatial distribution of the RMSE difference rate between the two experiments for six atmospheric variables initial condition for 2017-2021 May. Colors indicate improvement (blue) or degradation (red) in ATMR experiment relative to the OPER experiment. ....	133
Figure 3.35. Spatial distribution of the RMSE difference rate between the two experiments for six atmospheric variables initial condition for 2017-2021 November. Colors indicate	

improvement (blue) or degradation (red) in ATMR experiment relative to the OPER experiment. ....134

Figure 3.36. Hovmoller diagrams of equatorial Pacific sea surface temperature(SST) for (left) observation(OBS), (middle) the OPER - OBS, and (right) the EXPR - OPER difference. The panels show the longitude-time evolution of SST along the equator from January(bottom) to December(top). ....135

Figure 3.37. Evolution of ocean and atmospheric temperature difference between OPER and ATMR experiments as a function of lead time (1-100 days). (top) Subsurface temperature represents at 3m (black), 96 m (purple), and 190 m (cyan). (bottom) Highlighting black line indicates a pronounced SST response for the ensemble mean and gray lines for each individual experiment. ....136

Figure 3.38. Spatial distribution of the change in T2M RMSE difference rate (dRMSE) for the ATMR experiment. Negative values indicate reduced errors relative to the OPER experiment, whereas positive values denote increased errors. ....137

Figure 3.39. Vertical profiles of experiments - observation differences for (left) temperature and (right) zonal wind over the East Asia region at 16-30 day lead time. Black, blue, and red lines represent the OPER, OCNR, ATMR experiment, respectively. ....138

Figure 3.40. Comparison of precipitation distribution and biases over East Asia. (top) Observed mean precipitation with atmospheric circulation(850hPa wind vectors). (bottom-left) Precipitation biases from the OPER experiment. (bottom-right) Differences between the ATMR and OPER experiments. ....138

Figure 3.41. Vertical humidity distribution and local Hadley circulation over the western Pacific-East Asia region for (top) Observed humidity (shading) and meridional-vertical circulation (vectors), (bottom-left) OPER experiment, and (bottom-right) difference between ATMR and OPER. ....139

Figure 3.42. Improvement rates of forecast skill in the ATMR experiment relative to the OPER experiment for 1-15 days, 16-30 days lead time and Global, Tropics, and East Asia regions. Positive values indicate an enhancement in forecast performance, while negative values represent degradation. ....140

Figure 3.43. Sea surface temperature distribution over the North Atlantic region. (left) Difference between the OPER and observation. (right) Difference between the ATMR and OPER experiments. ....141

Figure 3.44. Sea surface temperature distribution over the East Asian coastal region. (left) Difference between the OPER and observation. (right) Difference between the ATMR and OPER experiments. ....142

Figure 3.45. 2m temperature difference distribution (left) between the OPER and observation, and (right) between the ATMR and OPER experiments. ....143

Figure 3.46. Surface precipitation difference distribution (left) between the OPER and observation, and (right) between the ATMR and OPER experiments. ....143

Figure 3.47. Comparison of the (left) seasonal evolution and (right) its biases of East Asian

summer monsoon precipitation. Latitude-time sections of precipitation (mm/day) from observation, OPER, and ATMR(EXPR) experiments during May-August. ....144

Figure 3.48. Comparison of Walker circulation and upper-level divergence fields for (left) 1-15 day mean and (right) JJA mean. ....145

Figure 3.49. Vertical profiles of experiments - observation temperature differences over the (left) global and (right) East Asia region at JJA lead time. Black, blue, and red lines represent the OPER, OCNR, ATMR experiment, respectively. ....146

Figure 3.50. Improvement rates of forecast skill in the ATMR experiment relative to the OPER experiment for JJA, DJF lead time and Global, Tropics, and East Asia regions. Positive values indicate an enhancement in forecast performance, while negative values represent degradation. ....147

Figure 3.51. Distribution of root-mean-square error(RMSE) of 2m temperature at a 1 day lead time from (left) OPER and (right) ATMR experiments. ....148

# 1. 서론

계절내예측(Subseasonal-to-Seasonal, S2S)은 2주에서 8주 사이의 예측정보를 제공하는 영역으로, 재해 예방, 농업 관리, 수문·에너지 운영 등 다양한 분야에서 활용 가치가 빠르게 증가하고 있다(Mariott et al. 2018; White et al. 2017). 그러나 예측기간의 특성상 초기장 민감도와 외부 강제력 신호가 모두 약해 예측 난이도가 높은 영역이기도 하다(Meehl et al. 2021). 이러한 가운데, 아태기후센터(Asia-Pacific Economic Cooperation Climate Center, APCC)는 기존 월·계절예측 중심의 서비스에서 확장하여 계절내-계절을 아우르는 seamless 예측 서비스 구축을 전략적으로 추진하고 있다(Min et al. 2025). 또한, APCC는 2017년부터 기상청의 1개월 전망 업무를 지원하기 위해 최신 계절내예측 정보를 수집하고 이를 가공하여 제공하는 협력 체계를 공고히 해왔다. 특히, 3주에서 6주 후를 예측하는 1개월 전망은 단순한 월평균 값을 넘어 주 단위의 월내 변동성을 파악하기 위한 중요한 자료로 사용된다. 이 연구에서는 1개월 전망 업무를 지원하기 위한 계절내 예측 시스템의 원활한 운영과 함께 ECMWF 기반의 딥러닝 기온 확률예측 시스템 운영을 수행하고, 시스템의 운영 효율성을 제고하기 위한 시스템 이전 및 개선 내용을 기술하였다. 아울러, 역대 두 번째로 높은 기온을 기록했던 2025년 8월의 사례 분석을 통해 월내 변동성을 포착하는 데 있어 현 시스템이 가지는 유효성을 검증하고, 이를 통해 계절내예측 정보가 향후 장기예보 실무에서 어떻게 활용되고 기여할 수 있는지를 제시하고자 한다. 또한, 현재 제공하는 계절내예측의 한계를 극복하고 계절예측 정보를 보완하여 급변하는 기후 특성들에 대응하기 위해 APCC는 계절내예측 시스템을 구축하여 그 활용 가치를 높여보고자 하였다.

기존의 월·계절예측 서비스만으로는 사용자 요구를 충분히 충족시키기 어렵다는 점을 인식하고, 계절내-계절을 연속적으로 연결하는 seamless 예측 프레임워크 구축의 필요성이 야기되어 왔다. 이를 위해 전 세계 SubC/S2S 프로젝트 모델 및 APCC 자체 모델 SCoPS(Seamless Coupled Prediction System; Ham et al. 2019)가 계절내 시간규모에서 어떤 기후값과 예측력을 보이는지 종합적으로 파악하는 과정이 필수적이다(Vitart et al. 2017). 또한 다양한 예측정보를 상호 비교·결합할 수 있는 기반을 마련하고, 이를 APCC의 강점인 다중모델앙상블(Multi-Model Ensemble, MME) 체계로 확장할 수 있는지 평가할 필요가 있다. 따라서 본 연구에서는 APCC 계절내예측 시스템 구축을 위해, 전 세계 SubC/S2S 프로젝트 모델과 APCC 자체모델의 계절내 예측 정보의 체계적으로 수집, 개별모델의 기후값과 예측력의 정량적 평가, MME 적용 시의 효율성과 기여 정도 분석을 수행하였다. 한편, 계절내예측은 월평균 변동성을 주로 다루는 계절예측과 달리, 일 또는 주 단위의 정보 제공을 주요 목적으로 한다. 이러한 평균 기간의 차이는 확률론적 예측 수행 시 필수적인 예측 변수의 확률분포 특성에 영향을 미친다. 상대적으로 짧은 평균 기간으로 인해 강수량과 같은 변수는 정규분포를 따르지 않는 비대칭적 특성이 강화되며, 앙상블 멤버 부족 시 발생하는 표본 오차는 예측 결과의 공간적 불연속성과 신뢰도 저하를 야기하는 주요 원인이 되고 있다. 이에 본 연구에서는 계절내예측 현업 운영의 효율성과 정확도를 동시에 제고하기 위해, 변수별 통계적 특성에 최적화된 모수화 방법과 비모수화 방법의 예측 성능 및 공간적 안정성을 체계적으로 비교 분석하고, 이를 기반으로 객관화된 고품질 확률예측 정보를 생산할 수 있는 최적의 방법론을 정립하여 현업 시스템에 적용하고자 한다. 이를 통해 APCC 계절내예측 시스템의 필요한 모델 구성 및 확률 방법을 정립하고, SCoPS를 포

함한 다양한 참여 모델의 예측자료를 매주 수집하여 계절내예측 정보를 생산할 수 있는 MME 계절내예측 시스템을 구축하고자 한다.

더불어, 계절내예측 시스템 구축은 주간-월간-계절 정보를 자연스럽게 활용할 수 있도록 예측 시간 규모 간의 연계성을 강화한 콘텐츠를 발굴·개발하는 과정 역시 중요하다(Vitart et al. 2025). 특히 최근에는 예측 범위가 바뀔 때 정보가 단절되지 않고 부드럽게 이어지는 서비스에 대한 수요가 커지고 있어, 계절내-계절 간 정보 연계를 지원하는 새로운 콘텐츠 개발이 중요한 과제로 대두되고 있다(Meehl et al. 2021). 따라서 APCC 계절내예측 시스템 구축과 함께 계절내-계절(월)을 연결하는 seamless 콘텐츠의 발굴 및 제공 가능성을 평가하고자 한다. 이러한 일련의 작업은 향후 APCC가 차세대 계절내예측 시스템을 구축하고, 계절내-계절을 아우르는 통합 기후서비스를 제공하기 위한 기반을 마련하는 중요한 첫걸음이 될 것이다.

한편, 계절내예측은 기상 예측(NWP)과 계절 예측(1-3개월)의 중간 영역에 속하며, 예측 연속성을 확보하기 위해 연구 및 현업 기관들을 통해 다양한 노력이 이루어지고 있다. 특히 2주에서 2개월 사이의 기간은 초기 조건의 영향과 내부 변동성, 느린 해양 및 육지 경계면의 상호작용이 동시에 작용하는 예측의 어려움이 잘 알려져 있다. 이 구간의 예측 정확도를 높이기 위해서는 초기장의 오차를 줄이는 것이 필수적이라 할 수 있다. 현재 대부분의 계절예측 시스템은 대기 초기장에 비해 해양 및 경계면 초기장에 대한 정보의 부정확함이 잘 알려져 있다. 특히, 해수면 온도, subsurface 열용량 구조, 대기 저층의 수증기 및 에너지 플럭스는 계절내예측의 핵심 변수임에도 불구하고 초기의 미세한 불확실성이 누적되어 예측 성능의 감소를 초래할 수 있다. 대기-해양 초기장의 오차를 줄이는 것은 단순히 수치예측 모델의 정확도를 높이는 수준을 넘어, 예측 가능성(predictability)의 한계를 확장하는 데 기여한다. 예측의 정확도는 초기 조건의 질에 직접적으로 비례하며, 초기장이 정밀해질수록 예측모델은 내부 변동성과 외부 강제력을 보다 효과적으로 모사할 수 있다. 특히, 계절내예측에서 중요한 대기-해양 상호작용 신호(MJO, 인도양 dipole, ENSO 발달 및 쇠퇴 등)는 초기 오차가 상대적으로 작을 때 예측 기간이 더 길어진다는 연구 결과가 수차례 보고되고 있다. 예를 들어, Lin et al. (2010)은 북대서양 진동(NAO) 예보의 정확도가 초기 조건에서 MJO 강도와 위상에 따라 향상될 수 있다고 언급했다. 또한, Vitart et al. (2019)는 다양한 대기 재분석 데이터를 사용하여 실험을 초기화하면 4주차까지의 예측 성능을 향상시킬 수 있다고 밝혔다.

최근 들어 전 세계적으로 여러 현업센터에서는 이음새 없는 예보를 위하여 중단기 날씨-계절예보를 비롯하여 긴 시간 규모를 가지는 기후예측까지 할 수 있는 시스템을 개발해오고 있다. 이에 따라, 계절내-계절 시간 규모 예측에서도 지면, 대기 등의 짧은 시간 규모에서 중요하게 여겨지던 초기조건들의 영향이 주목받고 있다. 계절예측 시스템에서의 초기조건은 크게 대기, 지면, 해양/해빙으로 나눌 수 있다. 여기서 대기 조건은 날씨 규모에서 가장 중요한 강제력이며, 계절내예측 특히 열대 진동 및 성층권 순환 등에 영향을 줄 수 있는 것으로 알려져 있다. 그에 비해 지면 초기 조건은 토양 수분 및 눈 상태 등을 통해 계절내예측에서 계절예측까지 영향을 미치며, 해양/해빙 등의 조건은 해수면 온도 및 해빙 상태 등을 통해 계절 예측 및 좀 더 긴 규모의 기후예측에서 영향을 미치는 것으로 알려져 있다. 따라서, 대부분의 계절예측 시스템에서는 해양의 초기장에 대한 중요성이 잘 알려져 왔으며, 최근 들어, 지면 및 해빙의 초기장의 중요성이 언급되어 오고 있다. 지면 초기화는 특히 계절예측에서 예측성이 아주 낮게

나타나는 지면 온도에 영향을 미치는 것으로 알려져 있으며 (Koster et al. 2011), 서은교 등 (2016)에 따르면, GloSea5에 토양 수분 초기화에 대한 영향을 살펴본 결과, 지면 온도의 1개월 예측에 있어서 특히 중위도 지역에서 예측 성능의 뚜렷한 개선을 보인 바 있다. 다만, 지면 초기화 효과에 따른 예측 성능 개선 효과는 각각의 모델마다, 그리고 지역별로 차이를 보이고 있어 다양한 모델 및 계절/지역별로 검증되어야 할 것이다. 정영운 등(2016)에 따르면, 대기-해양 접합이 단기 기후예측에 긍정적으로 작용하고 있으며, 우리나라 근해에서 더 많은 관측 자료를 자료 동화에 사용한 결과 더 현실적인 예측값을 가져올 수 있음을 나타낸 바 있다. 이처럼 현재 지면, 해빙과 더불어 대기-해양 초기화 등 여러 초기 조건들의 개선을 위해 학계 및 현업 기관에서 많은 연구를 진행하고 있다.

지면 상태 중에서도 토양 수분은 육지-대기 상호작용의 핵심 변수로 지표면 에너지 수지와 수문 순환에 직접적으로 영향을 미친다. 토양 수분은 증발산을 통해 대기로 전달되는 잠열과 지표 가열에 기여하는 현열의 분배를 조절하며, 이는 다시 기온, 습도, 강수 등 근지표 기상 변수의 변동성을 결정한다. 특히 토양 수분은 상대적으로 긴 메모리 특성이 있어, 초기 조건의 영향이 수 주에서 수 개월까지 지속될 수 있다(Koster et al., 2011). 선행 연구들은 북미 중서부, 유럽, 중앙아시아 등 중위도 대륙성 기후 지역에서 토양 수분 메모리가 2주 이상 유지되며, 이러한 메모리가 기온 예측 성능 향상에 기여할 수 있음을 보고한 바 있다(Koster et al., 2010; Van Den Hurk et al., 2012; Dirmeyer et al., 2013; Dirmeyer and Halder, 2016; Ardilouze et al., 2019; Duan et al., 2025; Day et al., 2025). 그럼에도 불구하고 전통적인 계절예측시스템은 대기 재분석 자료로부터 모델 넛징을 통해 지면 상태를 간접적으로 생성하거나, 기후값을 사용하는 등 제한적인 접근을 취해왔다. 이는 관측 기반의 토양 수분 자료가 시공간적으로 제한적이고, 서로 다른 모델과 재분석 자료 간 토양 수분 표현 방식이 달라 직접적인 이식이 어렵기 때문이다. 최근 들어 오프라인 지면 모델을 활용하거나 자료 동화 기반의 고해상도 위성 관측 자료를 활용한 토양 수분 초기화 연구가 활발히 진행되고 있으나(Draper et al., 2012; De Rosnay et al., 2013; Rodríguez-Fernández et al., 2019), 초기화가 실제 예측 성능에 미치는 영향을 정량적으로 평가하고 그 물리적 메커니즘을 규명한 연구는 여전히 제한적이다.

초기조건 개선을 위한 많은 노력에도 불구하고, 현업 기후예측모델에서 초기 조건과 관련한 다른 한계가 존재한다. 전 세계의 현업 운영 기관 및 연구 센터에서는 실시간 forecast의 시간적 제약으로 인해 hindcast와 초기조건이 다르게 처방되는 경우가 많다. 예를 들어, 기상청에서 운영하는 계절내 및 계절 예측 시스템은 hindcast의 경우 대기 초기조건으로 재분석자료를 사용하지만, forecast의 경우 기상예측모델의 분석자료를 사용한다. 실시간 예측장인 forecast와 과거재현자료인 hindcast의 초기조건 불일치는 결국 기후값을 제거하고 변동성을 살펴보는 anomaly에 직접적인 영향을 미칠 수 있지만 현실적으로 많은 기관에서 그대로 사용하고 있다. 또한, 이러한 현상은 hindcast의 예측 성능이 좋은 것에 비해 forecast의 예측성능의 불안정성에도 크게 연관될 수 있다. 최근에는 이러한 불일치로 인한 차이 역시 조사되어 오고 있다. 예를 들어, Ham et al. (2021)은 기상청 기후예측시스템인 GloSea6의 초기조건 불일치를 민감도 실험으로 분석하여 hindcast의 재분석자료를 forecast에 처방할 경우 예측성능이 증가할 수 있음을 밝혔다. 이러한 결과는 초기 상태와 데이터가 예측성을 개선하고 불확실성을 줄이는데 중요한 역할을 함을 시사한다. 즉, 전 세계적으로 S2S 예측 성능 향상을 위한 다양한 시도가 이루어지고 있으며 특히 초기화 기술의 고도화는 예측 정확도 개선의 핵심 요소로 주목받고 있

다.

본 연구에서는 기존 월 단위로 운영되던 SCoPS 모델을 매주 60일 예측장을 생산하는 실시간 시스템으로 개선하여 APCC 계절내예측 시스템의 참여모델로 활용하고자 한다. 이를 위해 초기장 생산을 위한 입력 자료(CFS 분석장, ARGO 해양관측)의 주간 자동 수집하고 10개 forecast 앙상블 멤버를 구성함으로써 예측의 불확실성을 고려한 안정적인 초기장 및 예측장 생산 기반을 확보하고자 하였다. 또한 초기 오차를 줄이는 방안으로 토양 수분 초기화 체계를 도입하고, 여름철 기온 및 강수에 대한 계절내 예측 성능에 미치는 영향을 체계적으로 평가하고자 하였다. 초기화 기법으로는 운영 효율성을 고려하여 기존 SCoPS가 대기-해양 결합 초기화에 활용하고 있는 Ensemble Adjustment Kalman Filter (EAKF) 기법(Anderson et al., 2001)을 적용하여 관측 기반 재분석 자료의 토양 수분 필드를 사용하였다. 마지막으로, 대기-해양 초기장의 문제점을 파악하여 초기 오차의 개선이 계절내-계절 규모의 예측성능에 어떠한 영향을 줄 수 있는지 알아보하고자 하였다. 해양초기화의 불일치 및 대기-해양 초기조건의 개선이 계절내, 계절예측에 미치는 효과를 민감도 실험을 통해 살펴보고자 한다.

## 2. 계절내예측 활용체계 구축

### 2.1. 1/3개월 계절내-계절 예측 정보 생산 및 지원

#### 2.1.1. 1/3개월 전망 지원을 위한 예측시스템 운영

APCC에서는 우리나라 기상청의 1개월 전망 지원을 위해 최신의 다양한 계절내예측 정보를 수집·통합하여 다중모델앙상블(MME) 예측결과 및 다양한 예측 콘텐츠로 가공하여 매주 제공하고 있다. 기상청의 1개월 전망은 매주 목요일 오전에 향후 3주에서 6주 사이의 우리나라 기온과 강수량에 대한 예측정보를 발표하는 것이다. APCC는 이 기상청의 1개월 전망 지원을 위해 2017년 8월부터 이러한 1개월 전망 예측시스템을 운영해오고 있다. 이때 사용하는 예측정보는 ECMWF Sub-seasonal to Seasonal (S2S) data portal (Vitart et al., 2017)로부터 수신하고 있다. 해당정보는 기상청 등 일부 기관만 3주의 엠바고 없이 사용가능하므로 APCC 자체의 계절내예측 시스템과는 별도로 운영되고 있다. 현재 사용하고 있는 모델의 2025년 12월 기준 특성은 Table 2.1에 간략히 나타내었다.

이렇게 별도의 1개월 전망 예측시스템을 운영함으로써 인해 우리나라 기온과 강수량 예측성 향상에 초점을 맞춘 모델 세트를 구성할 수 있었으며, 예보관의 요구사항에 맞춘 예측 콘텐츠를 지속적으로 추가하여 제공하기 위한 노력을 하고 있다. 또한 예측 결과에 대한 실시간 검증 을 수행하고 있으며, 이를 위해 별도의 관측자료를 수신하여 활용하고 있다. 생산한 예측정보 는 Figure 2.1과 같은 PPT 파일 형식으로 가공하여 기상청으로 매주 화요일 오후에 전송한다.

Table 2.1. Characteristics of Models for KMA 1-Month prediction.

GPC name (Center)	Forecast Frequency	Forecast Time range	Forecast Ens. Size	Hindcast Frequency	Hindcast Ens. Size	Hindcast length
<b>ECMWF</b> (ECMWF)	daily	0~46 days	101	Odd-numbered days (excluding 29 Feb)	11	past 20 years
<b>Exeter</b> (UKMO)	daily	0~60 days	4	4/month (1,9,17,25)	7	1993~2016
<b>Montreal</b> (ECCC)	weekly (Thu)	0~39 days	21	2/week (Mon, Thu)	4	2001~2020
<b>Seoul</b> (KMA)	daily	0~60 days	8	4/month (1,9,17,25)	7	1993~2016
<b>Washington</b> (NCEP)	daily	0~44 days	16	daily	4	1999~2010

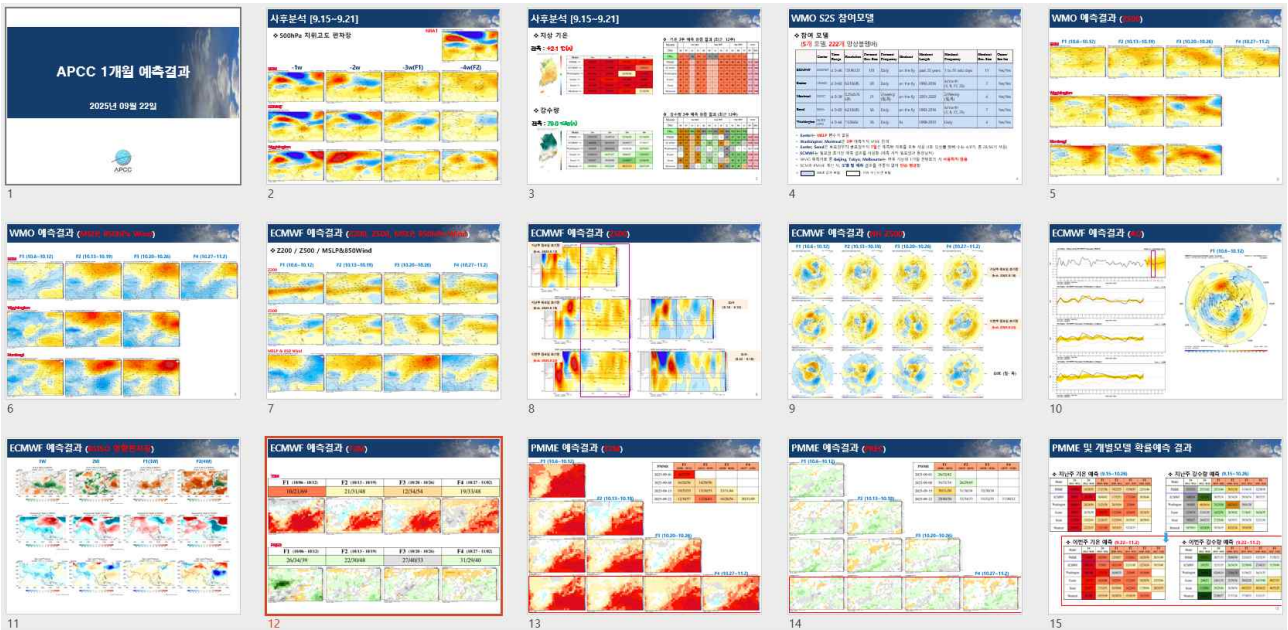


Figure 2.1. Sample of APCC 1 month forecast charts.

1개월 전망 예측자료 중 예측성이 가장 우수하며, 가장 빠르게 최신의 예측결과를 수집할 수 있는 ECMWF 계절내예측 모델 결과를 활용하여 기상청 3개월 전망을 위한 예측콘텐츠를 생산하고 있다. 이 정보는 계절예측 모델이 반영하지 못하는 가장 최근의 초기조건을 기반으로 예측을 수행한 결과이기 때문에 다음달 초반의 예측경향을 파악하는데 중요한 참고자료가 된다. 단, ECMWF 계절내 예측 모델은 최대 +46일 예측자료를 제공하며, 3개월 예보토의는 매일 15일 전후에 진행하므로 예보토의 전 가장 최신의 ECMWF 계절내 예측자료는 11일에서 15일 사이의 초기장을 사용한 결과가 된다. 따라서 다음달 전체에 대한 예측정보를 제공하지는 못하며, 다음달의 마지막주가 제외된 2/3의 평균 값에 대한 예측만 가능하다.

Figure 2.2는 ECMWF 계절내예측를 활용한 기상청 3개월 전망 예측콘텐츠 샘플이다. ECMWF 계절내예측 모델의 결과를 사용하여 다음 달 1일부터 예측 마지막 주까지 평균한 기간에 대한 예측을 계산한 자료이며, 동아시아 영역에 대하여 500hPa 지위고도와 해면기압, 850hPa 바람장, 기온 확률 예측, 강수량 확률 예측 분포를 제공한다. 추가적으로 한반도 영역에 해당하는 5개 격자점을 평균한 기온과 강수량의 확률예측 결과값도 동시에 제공한다. 이 자료는 기존의 3개월 전망 예측모델 보다 최근의 기압계 변화 등을 반영한 최신 예측결과이므로 최근 모델 초기조건에 따른 모델 예측결과의 변화 경향을 파악하는데 중요한 참고자료로 활용하고 있다.

# ECMWF Sub-Seasonal (init. : 2025-08-11)

ECMWF	09/01 - 09/21
T2M	2/19/79
PREC	21/37/41

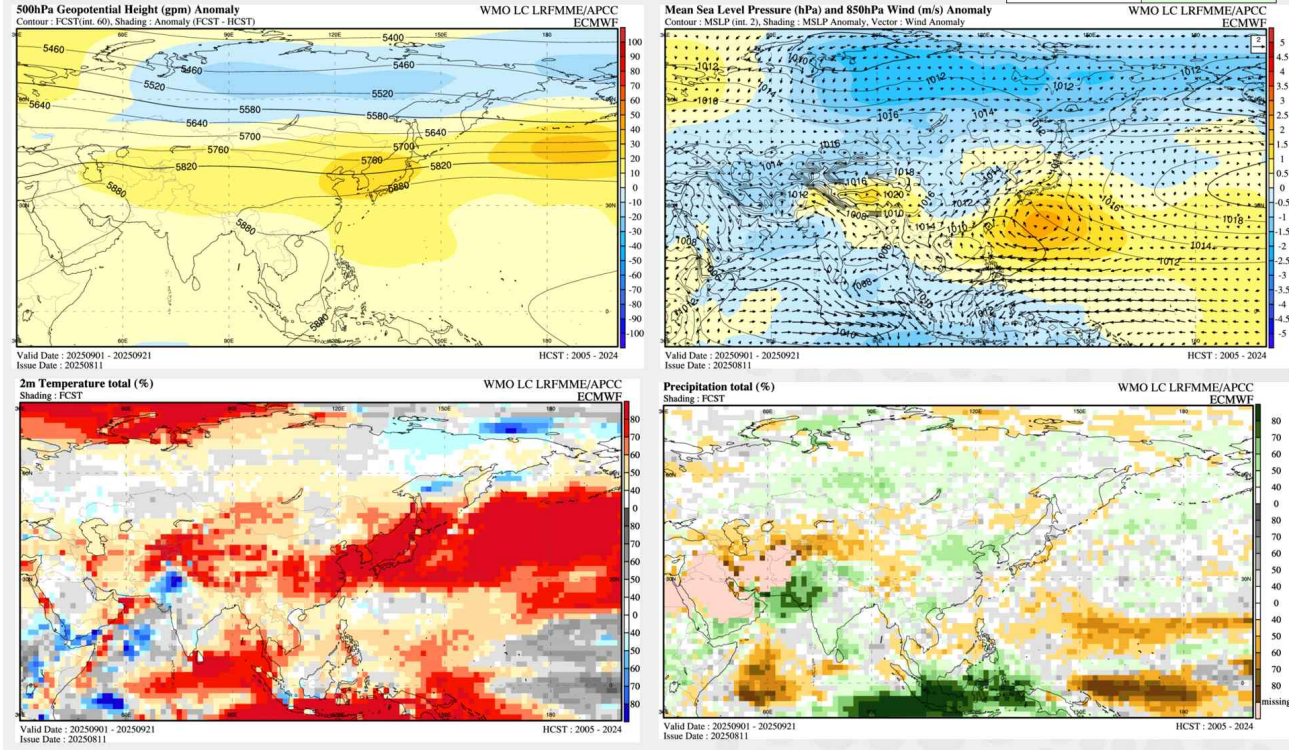


Figure 2.2. Sample of subseasonal model output for APCC 3-month forecast.

추가로 1개월 전망 예측자료 중 ECMWF의 계절내예측 정보를 바탕으로 딥러닝을 활용한 1개월 기온 확률예측 시스템을 운영하고 있다. 해당 시스템은 매주 월요일 기준으로 예측되는 ECMWF의 계절내 예측정보를 사용하며, 인공지능 기법 중 하나 CNN (Convolutional Neural Networks) 기반의 U-Net 아키텍처 및 어텐션 메커니즘을 활용하여 향후 3주와 4주 이후의 기온 확률예측 분포도를 계산한다. Figure 2.3과 같은 예측정보를 최종적으로 산출하며, 해당 콘텐츠는 기상청의 기후예측-분석 통합시스템에 매주 업로드 된다.

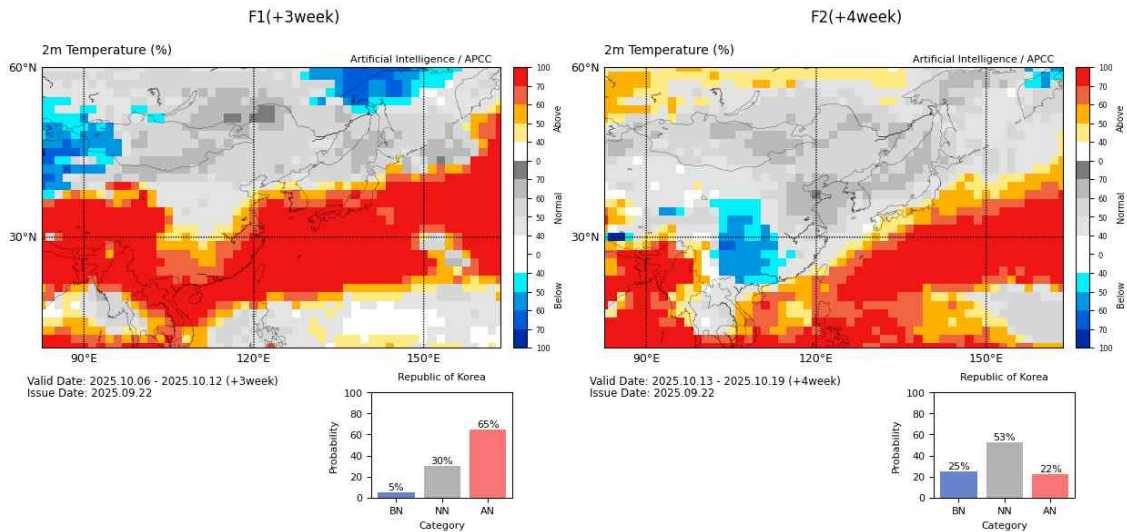


Figure 2.3. Week 3 and Week 4 forecast produced by the deep learning-based probabilistic temperature prediction system, initialized on 22 Sep 2025.

### 2.1.2. 예측시스템 이전 및 개선

현재 기상청 1개월 전망 예측시스템은 WMO 장기예보 선도센터의 서버에서 운영되고 있다. 해당 서버의 노후화와 누적된 자료의 처리, 운영의 효율화를 위해 자료수집은 APCC 외부 망 FTP 서버로 이전하였으며, MME 및 예측 콘텐츠의 생산은 APCC 내부망 HPC로 이전하는 작업을 수행하였다. 자료 수집과 예측시스템의 이전과 함께 기존의 시스템 운영 구조를 대대적으로 개선하였으며, 이를 통해 보다 효율적으로 시스템 유지보수 및 운영이 가능하도록 하였다.

### 2.1.3. 1개월 전망 활용 사례 분석

2025년 8월 우리나라의 기후 특성을 분석한 결과, 월평균 기온은 27.1°C로 평년보다 2.0°C 높았으며 2024년에 이어 역대 두 번째로 높은 기온을 기록하였다. 월누적 강수량은 187.2mm였으며, 강수량 백분위로 26.5 퍼센타일을 기록하여 평년보다 적은 경향을 보였다. Figure 2.4는 우리나라 8월의 ASOS 관측 시계열 자료이다. 월 전체 평균값은 고온 건조한 특성을 나타내지만, 실제 월내 변동성으로 시기에 따라 다른 패턴을 보였다. 8월 전반부에는 평년과 비슷한 기온 분포와 함께 잦은 강수가 집중된 반면, 후반부로 갈수록 강수량은 급격히 감소하고 기온이 상승하여 고온 건조한 날씨가 지속되는 뚜렷한 기상 패턴 변화가 관측되었다.




Figure 2.4. Time series of (left) daily mean temperature and (right) daily accumulated precipitation in Korea for August 2025.

이러한 8월 후반의 기온 상승과 건조 경향은 선행된 수치 모델 예측 결과에서도 유의미하게 포착되었다. 7월 28일 초기장을 이용한 ECMWF 모델의 500hPa 지위고도(Z500)의 Hovmöller diagram 분석 결과, 예측 기간 후반부인 8월 중순 이후 북서태평양 지역에서 Z500의 양의 편차가 강화되는 패턴이 나타났다(Figure 2.5). 또한, 여기에는 나타내지 않았지만 7월 21일 초기장에서 동일한 패턴을 보였다. 이는 북서태평양 고기압이 8월 후반 우리나라 주변으로 확장 및 강화될 것을 나타내는 신호로, 모델은 이러한 대기 순환의 역학적 변화를 통해 8월 후반부의 한반도 기온 상승 가능성을 사전에 성공적으로 탐지하였다.

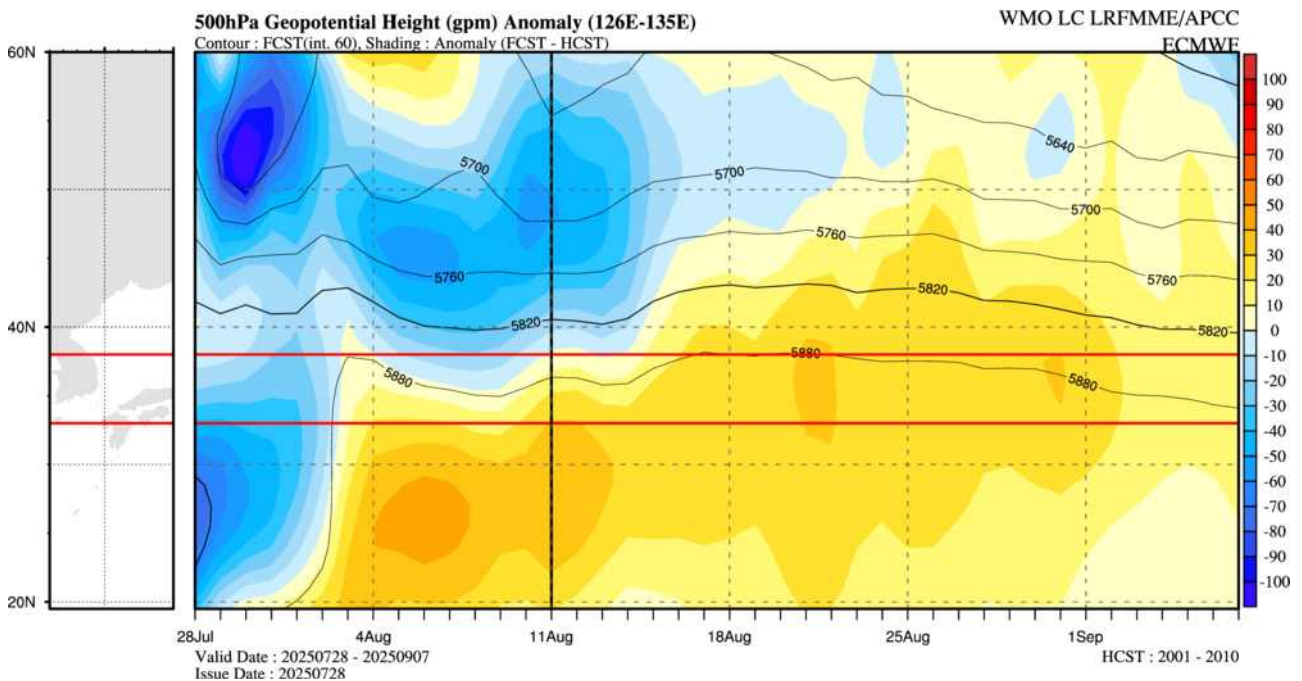


Figure 2.5. Time-latitude Hovmöller diagram of 500hPa geopotential height anomalies averaged over 126°E-135°E, initialized on 28 July 2025.

특히 7월 28일 초기장 기반의 ECMWF 계절내예측 결과는 8월의 전반부와 후반부 사이의 급격한 월내 변동성을 일정부분 정확하게 모의하였다. Figure 2.6에서 확인할 수 있듯이, 모델

은 8월 초순의 많은 강수를 예측한 데 이어, 중순 이후 급격히 건조해지며 기온이 상승하는 패턴의 전환을 효과적으로 재현하였다. 다만 8월 초순의 기온을 높게 예측하는 경향이 있었으나, 한반도 북쪽으로 상층의 골이 발달하는 부분을 모의하면서 예보관에게 기온 하강 시그널을 주었다.

본 사례 분석은 월평균 예측장만으로는 확인할 수 없는 상세 시계열 정보의 중요성을 입증한다. 만약 월평균 예측 정보에만 의존했다면 8월 초순의 집중 호우 가능성이나 후반의 폭염 지속성을 구분하여 대응하기 어려웠을 것이다. 결론적으로, 계절내예측 시스템이 제공하는 주별 변동성 정보는 월간 날씨의 흐름을 파악하고 시기별 맞춤형 방재 대책을 수립하는 데 있어 필수적인 정보를 제공한다. 이는 향후 장기 예보의 활용성을 극대화하는 핵심 요소가 될 것으로 판단된다.

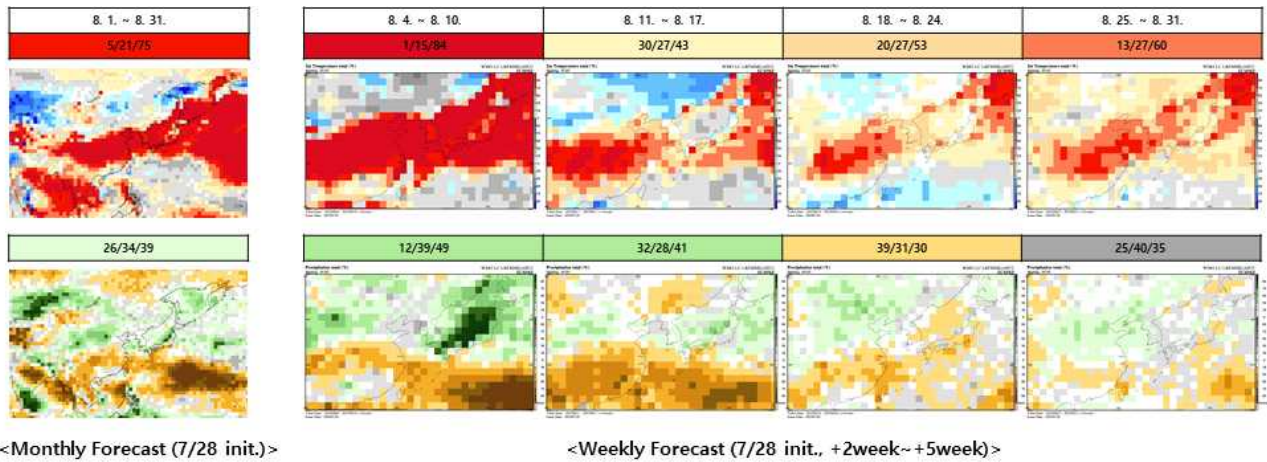


Figure 2.6. Comparison of the monthly mean forecast (left) and weekly forecasts (right) for temperature and precipitation in August 2025, initialized on 28 July 2025.

#### 2.1.4. 동아시아 이상기후 모니터링 시스템 운영

APCC 홈페이지에서는 동아시아 이상기후 모니터링 서비스를 제공하고 있다. 해당 서비스는 동적 페이지로 구성되어 있으며, 이상기후에 대한 시각적인 분포도 뿐만 아니라 해당 지점의 입력값 정보를 수치적으로 확인 할 수 있도록 구성되어 있다(Figure 2.7). 이 페이지에는 “이상기후 통합정보”와 함께 “이상고온 발생일수”, “이상저온 발생일수”, “최대 강수 사상 재현 기간”, “가뭄 통합 정보”를 확인 할 수 있다.

이 페이지에 입력되는 정보를 생산하기 위해서 매일 GDAS (Global Data Assimilation System) 자료의 수신과 함께 매주 LIS (Land Information System) 모델의 운영, 매월 이상기후 관련 모니터링 지수의 계산을 수행하고 있다. 2025년에는 이 시스템의 안정적으로 운영하였으며, LIS 모델의 수행과 관련한 병렬화 설정 부분을 일부 개선하는 작업을 수행하였다.

관심 기간 2025년 5월

이상기후 통합정보    이상고온 발생일수    이상저온 발생일수    최대 강수 사상 재현 기간    가뭄 통합 정보

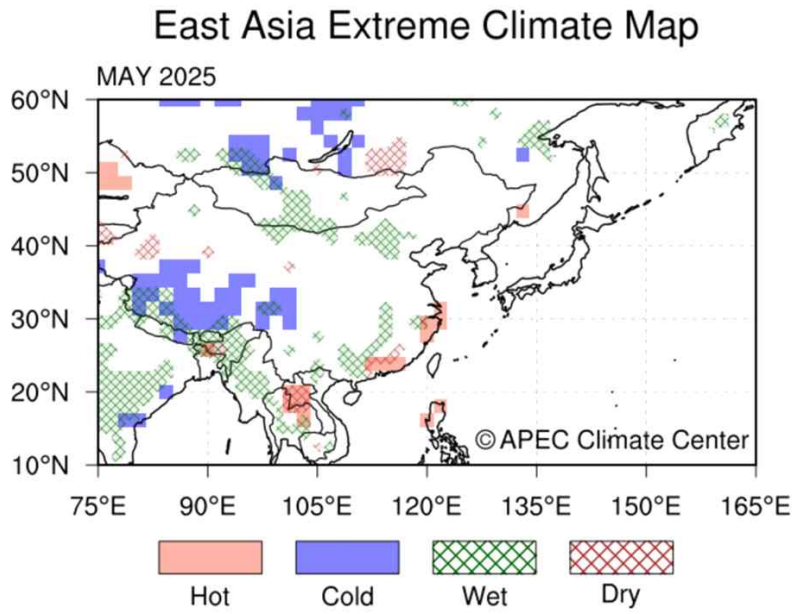


Figure 2.7. The East Asia Extreme Climate Monitoring System on the APCC website.

## 2.2. 최적의 확률 예측 방안 구성

### 2.2.1. 배경 및 목적

#### 2.2.1.1. 연구 배경

APCC는 다양한 기후예측 모델 자료를 수집하여 계절예측 정보를 안정적으로 생산하고 있으며, 이를 바탕으로 계절내예측을 위한 파일럿 시스템 구축하였다. 계절내예측과 계절예측은 모두 중기예측(+14일) 범위를 넘어서는 시간 규모를 다루기 때문에, 모델의 불확실성을 줄이기 위해 앙상블 기법을 적용하고 과거 재예측(Hindcast) 자료를 활용하여 계통오차를 보정하는 등 결정론적 예측 정보를 생산하는 방법론은 유사하다. 그러나 이러한 유사성은 결정론적 예측에 국한되며, 불확실성을 정량화하는 확률론적 예측을 고려할 경우 접근 방식에 차이가 발생한다.

계절내예측은 월평균 변동성을 주로 다루는 계절예측과 달리, 일 또는 주 단위의 기상 변동성과 극한 현상에 대한 정보 제공을 주요 목적으로 한다(Robertson et al., 2015; Vitart et al., 2017). 이러한 평균 기간의 차이는 확률론적 예측 수행 시 필수적인 예측 변수의 확률분포 특성에 영향을 미친다. 기온과 같은 변수는 중심극한정리에 따라 정규분포를 가정할 수 있으나, 강수량은 최솟값이 0으로 고정되고 왜도(Skewness)가 큰 분포 특성을 보인다. 특히 주별 평균 이하로 시간 규모가 짧아질수록 무강수 사례의 비중이 증가하여 정규분포 가정은 물론, 모수화(Parameterization)를 위한 분포 적합 자체가 불안정해지는 문제가 발생한다(Husak et al., 2007). 따라서 상대적으로 시간 규모가 짧은 계절내 예측 변수에 대해 기존의 모수화 방법이 유효한지, 혹은 비모수화(Non-parametric) 방법이 더 적합한지에 대한 검증이 필요하다.

현재 널리 사용되는 비모수적 방법인 분위수 카운팅(Quantile counting)은 앙상블 멤버 수가 적을 경우 표본이 모집단을 충분히 대변하지 못하여 필연적으로 표본 오차(Sampling error)를 유발하며, 이는 확률 예측의 정확도를 저하시키는 원인이 된다(Ferro, 2007). 이러한 오차는 인접 격자 간 예측 확률의 급격한 불연속성을 야기하여 결과 표출 시 공간적인 노이즈(Spatial noise) 형태로 나타나는데, 이는 예보관의 기상 패턴 분석 효율을 떨어뜨리고 예측 정보의 신뢰도를 저하하는 요인으로 지적된 바 있다(Hamill and Whitaker, 2006). 이에 이 연구에서는 모수화 방법과 비모수화 방법의 예측 성능 및 공간적 안정성을 비교 분석하여, 계절내예측 현업 운영에 최적화된 확률예측 방법론을 선정하고 이를 적용한 현업 시스템을 개발하고자 한다.

#### 2.2.1.2. 타기관 사례 및 연구 동향

국내외 주요 기상·기후 기관들은 각기 다른 통계적 접근 방식을 통해 확률예측 정보를 생산하고 있으며, 크게 모수화 방법과 비모수화 방법, 그리고 관측 오차를 보정하는 통계적 후처리 방법으로 구분된다. 기상청(KMA)과 NMME(North American Multi-Model Ensemble)는 기온 변수에 대해 가우시안 피팅(Gaussian Fitting)을 적용하여 각 카테고리의 확률을 산출하는 반면, 강수량에 대해서는 과거 자료의 누적분포함수(CDF) 상의 분위수(Quantile)를 기준으로 직접 앙상블 멤버를 카운팅하는 비모수적 방법을 사용한다. 이는 Hindcast 자료의 누적분포함수에서 33번째 및 66번째 백분위수(Percentile)를 임계값으로 설정하고, 실시간 예측 앙상블 멤버들이

각 구간에 포함되는 빈도수를 직접 계수하여 확률을 산출하는 방식이다. 유럽중기예보센터(ECMWF)는 기온과 강수량 두 변수 모두에 대해 비모수적 방법을 채택하고 있다. 이는 모수적 가정 없이 과거 Hindcast 자료의 누적분포 3분위 지점(Tercile)을 기준으로 앙상블 멤버의 분포 비율을 계산하는 방식으로, 데이터 자체의 경험적 분포(Empirical distribution)를 중시하는 접근법이다.

반면, ECCC(Environment and Climate Change Canada)는 두 예측 모델(GEM-NEMO, CanCM4)의 앙상블 평균 아노말리를 산출한 후, 기온뿐만 아니라 강수량에 대해서도 모수화를 적용한다. 특히 강수량의 경우 감마(Gamma) 분포의 매개변수를 추정된 뒤 이를 정규분포로 변환(Transformation)하고, Kharin and Zwiers (2003)가 제안한 공식을 적용하여 확률을 산출한다. 이는 강수량의 비정규성을 통계적으로 보정하여 모수화의 이점을 활용하려는 시도로 해석된다. IRI(International Research Institute for Climate and Society)는 확장 로지스틱 회귀(Extended Logistic Regression, ELR) 모델을 사용하여 관측자료와의 오차를 보정하는 통계적 기법을 활용하고 있다. Vigaud et al. (2017)에 의해 제시된 이 방법은 hindcast 자료와 관측 자료 간의 상관성을 기반으로 예측 확률을 보정함으로써, 모델이 가진 계통적 오차를 줄이고 예측성을 향상시키는 통계적 기법이다.

이 연구에서는 이러한 타 기관의 다양한 방법론을 벤치마킹하되, APCC의 다중모델 앙상블(MME, Multi-Model Ensemble) 환경에 최적화된 방법론을 선정하는 데 중점을 두었다. 특히 다양한 모델의 자료를 활용해야 하는 MME 예측의 특성상 모든 모델에서 사용가능한 방법론인지 중점적으로 검토하였다.

## 2.2.2. 자료 및 실험 방법

### 2.2.2.1. 연구자료 및 실험 방법

이 연구에서는 APCC가 생산하고 있거나 실시간으로 수집하고 있는 주요 4개 기관(ECMWF, ECCC, NCEP, APCC)의 계절내 예측 모델과 이들을 결합한 다중모델 앙상블(MME) 자료를 사용하였다(Table 2.2). 여기서 특이점은 NCEP 자료의 경우 ECMWF data portal (Vitart et al., 2017)에서 제공하는 hindcast 자료와 IRI의 SubC (Subseasonal Consortium) hindcast 자료를 합쳐서 사용하였으며, APCC 모델의 경우 forecast 자료가 생산되기 전이므로 2022년부터 2024년 기준으로 생산한 hindcast 자료를 forecast 자료로 활용하였다.

검증 대상 변수는 지상 2m 기온(T2M)과 강수량(PREC)이며, 검증 기간은 2022년 1월 3일부터 2024년 11월 11일까지 총 150회의 예측 사례를 대상으로 수행하였다. 예측 시간 단위는 매주 월요일을 기점으로 1주(Week 1), 2주(Week 2), 3주(Week 3), 4주(Week 4)의 주별 평균과 1-4주(Week 1-4), 3-4주 평균(Week 3-4) 예측을 포함한다. 각 모델의 hindcast 기간은 언급이 없는 부분에서는 각 모델에서 가용한 전체 기간의 자료를 사용하였으며, forecast 시작 날짜와 인접한 하나의 샘플 날짜에 해당하는 hindcast 자료를 사용하였다. 이 연구에서 사용하는 PMME (Probabilistic Multi-Model Ensemble) 예측 방법은 기존 계절예측과 동일하게 구성하였다. 이는 각 개별모델의 확률예측 결과를 평균하면서 가중치는 각 모델의 앙상블 개수의 제곱

근으로 하는 것이다. 앙상블 풀링(Pooling) 방법을 사용하는 경우와 극한기후 예측을 위한 실험에서는 방법론의 특성상 공통 hindcast 기간을 사용하였다. 이때의 공통 Hindcast 기간은 2003년(또는 2004년)부터 2015년까지이다.

Table 2.2. Characteristics of Models for KMA 1-Month prediction.

Center name	Forecast Frequency	Forecast Time range	Forecast Ens. Size	Hindcast Frequency	Hindcast Ens. Size	Hindcast length
ECMWF	daily	0~46 days	51	2/week (Mon, Thu)	11	past 20 years
			101 (After Jun 27, 2023)			
ECCC	weekly (Thu)	0~32 days	21	2/week (Mon, Thu)	4	2001~2020
		0~39 days (After Jun 13, 2024)				
NCEP	daily	0~44 days	16	daily	4	1999~2015
APCC	weekly (Wed)	0~60 days	10	6/month (1,5,10,15,20,25)	10	2003~2015

검증을 위한 관측 기준 자료는 ECMWF의 ERA5 일 자료를 사용하였으며, 기후 평년값은 1991년부터 2020년까지 30년 기간을 설정하였다. 이때, 표본의 부족으로 인한 통계적 변동성을 줄이고 기후학적 분포의 신뢰도를 확보하기 위해, 검증 대상 시점( $t$ )을 기준으로 전후 1주 ( $t-1, t, t+1$ )의 주평균 자료를 함께 사용하는 시간적 풀링(Temporal pooling) 기법을 적용하여 표본 수를 3배로 확충하였다. 확률예측 성능 평가는 예측의 정확도와 변별력을 종합적으로 판단하기 위해 RPSS(Ranked Probability Skill Score), ROC(Receiver Operating Characteristic) AUC(Area Under Curve) 지수를 사용하였으며, 모수화 분포의 적합성을 판단하기 위해 Kolmogorov-Smirnov(K-S) test를 수행하였다. 각 방법론의 수식적 정의는 다음과 같다.

RPSS는 다중 카테고리 확률예측에서 예측된 확률분포가 관측된 실황과 얼마나 일치하는지를 평가하는 지수이다. 먼저 Ranked Probability Score (RPS)는 아래 식 (2.1)과 같이 정의된다 (Epstein, 1969; Murphy, 1971).

$$RPS = \sum_{k=1}^K (Y_k - O_k)^2 \quad [2.1]$$

여기서  $K$ 는 카테고리의 수,  $Y_k$ 는 예측된 누적 확률( $Y_k = \sum_{i=1}^k p_i$ ),  $O_k$ 는 관측된 누적 확률(해당 카테고리 발생 시 1, 미발생 시 0)을 의미한다. RPSS는 기준 예측(Climatology) 대비 모델 예측의 개선도를 나타내며 식 (2.2)와 같다.

$$RPSS = 1 - \frac{\overline{RPS}_{forecast}}{\overline{RPS}_{reference}} \quad [2.2]$$

$\overline{RPS}$ 는 검증 기간 동안의 평균값을 의미한다. RPSS가 양수이면 기준 예측보다 성능이 우수함을, 음수이면 떨어짐을 의미한다.

ROC 곡선은 확률예측 시스템이 특정 사건을 감지하는 능력을 평가하기 위해, 적중률(Hit Rate,  $H$ )과 오경보율(False Alarm Rate,  $F$ )의 관계를 나타낸 곡선이다 (Mason, 1982). ROC 곡선 아래의 면적인 AUC는 식 (2.3)과 같이 적분으로 정의된다.

$$AUC = \int_0^1 H(F) dF \quad [2.3]$$

AUC 값이 0.5이면 무작위 예측(No skill)을, 1.0이면 완벽한 예측(Perfect skill)을 의미한다. 이 연구에서는 Above, Normal, Below 각 카테고리에 대해 이분법적으로 접근하여 AUC를 산출하였으며, 지면관계상 세 카테고리의 점수를 평균하여 제시하였다.

K-S test는 표본 데이터의 경험적 누적분포함수와 가정된 이론적 누적분포함수 간의 최대 거리를 측정하여 적합도를 검정하는 비모수적 방법이다. 검정 통계량  $D_n$ 은 식 (2.4)와 같다 (Massey, 1951).

$$D_n = \sup_x |F_n(x) - F(x)| \quad [2.4]$$

여기서  $F_n(x)$ 는  $n$ 개의 앙상블 멤버로 구성된 경험적 누적분포함수,  $F(x)$ 는 검정하고자 하는 이론적 분포를 의미한다.  $D_n$ 이 임계치보다 클 경우 귀무가설을 기각한다.

이 연구에서는 계절내 확률예측 성능을 비교 분석하기 위해, 변수의 통계적 분포 특성과

모수화 여부에 따라 Quantile (비모수형), Gauss (모수형, 정규분포), Hybrid\_Gamma (모수형, 혼합분포)의 세 가지 방법론을 적용하였다. Figure 2.8은 각 방법론이 hindcast 자료와 forecast 자료를 활용하여 각 카테고리(Below, Normal, Above)의 확률을 산출하는 과정을 도식화한 것이다.

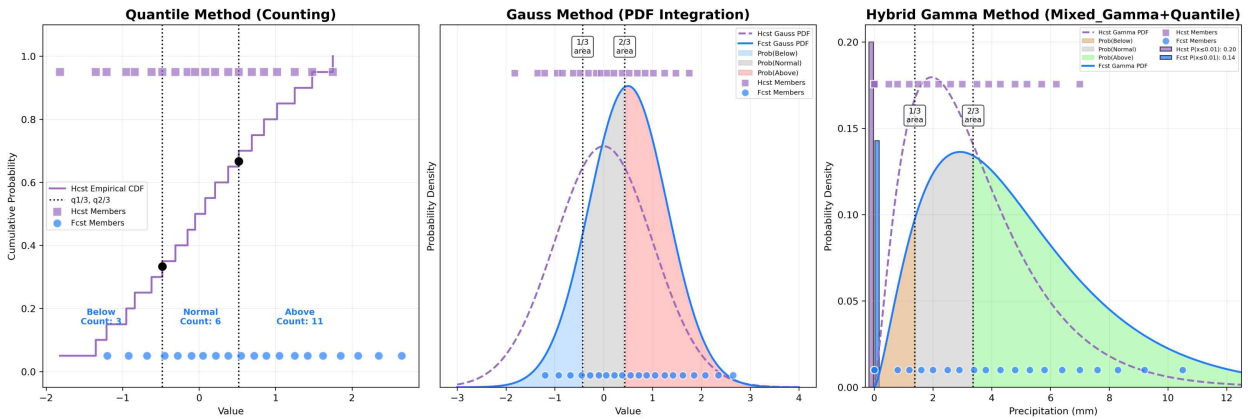


Figure 2.8. Schematic diagram of the three probabilistic forecasting methodologies.

첫 번째, Quantile은 가장 기본적인 비모수적 접근 방식으로, 데이터의 분포를 특정 함수로 가정하지 않고 앙상블 멤버 자체의 빈도를 활용한다. Figure 2.8 좌측과 같이 hindcast 자료(보라색 사각형)로부터 경험적 누적분포함수(Empirical CDF)를 생성하여 33.3%(1/3)와 66.7%(2/3) 지점에 해당하는 임계값( $q_{1/3}$ ,  $q_{2/3}$ )을 설정한다. 이후 forecast 앙상블 멤버(파란색 원)들이 각 임계값 사이의 구간에 몇 개가 위치하는지를 직접 카운팅하여 해당 카테고리의 발생 확률을 계산한다. 이 방식은 계산이 직관적이고 데이터의 분포 형태에 구애받지 않으나, 앙상블 멤버 수가 적을 경우 계단형 분포로 인해 확률값의 해상도가 낮아지고 표본 수에 의존적인 단점이 있다.

두 번째, Gauss는 기온과 같이 좌우 대칭적인 연속 확률분포를 보이는 변수에 적합한 모수적 방법이다. Figure 2.8 중앙과 같이 hindcast 자료와 forecast 자료가 정규분포를 따른다고 가정하고, 각 앙상블 멤버의 평균( $\mu$ )과 표준편차( $\sigma$ )을 통해 확률밀도함수(PDF)를 추정한다. Hindcast PDF(보라색 점선)에서  $\mu \pm 0.4307\sigma$  지점을 기준으로 임계값을 산출하며, 이를 기준으로 Forecast PDF(파란색 실선)의 면적을 적분하여 각 카테고리의 확률을 산출한다. 이 방법은 벡터화 연산을 통해 계산 속도를 매우 빠르게 할 수 있으며, 적은 앙상블 멤버로도 부드러운 확률 곡선을 얻을 수 있어 비모수적 방법 대비 이상치의 영향을 줄이고 예측의 안정성을 높이는 효과가 있다.

세 번째, Hybrid\_Gamma (Mixed\_Gamma + Quantile) 방법은 0 값이 많고 오른쪽으로 꼬리가 긴 강수량 데이터의 특성을 반영하기 위한 최적화된 모수화 방법이다. Figure 2.8 우측과 같이 이 연구에서는 0.01mm를 강수 유무의 임계값으로 설정하고, 전체 멤버 중 강수량이 임계값 이하인 비율을 건조 확률( $p_0$ )로 별도 분리한다. 강수가 있는 습윤 멤버에 대해서는 최대우도

법(MLE)을 통해 감마 분포의 형상(shape)과 척도(scale) 매개변수를 추정하여 결합하는 혼합(Mixed) 방식을 취한다. 특히, 이 연구에서는 예측 안정성을 확보하기 위해 ‘하이브리드(Hybrid)’ 알고리즘을 적용하였다. 이 방법은 기후학적으로 매우 건조하여 유효 습윤 멤버의 수가 분포 추정에 불충분한 경우, 자동으로 비모수적 방법인 Quantile 방법으로 전환한다. 이를 통해 강수량 모수화 과정의 계산 실패를 방지하고, 건조 지역과 다우 지역 모두에서 최적의 확률 예측값을 생산할 수 있도록 설계하였다.

### 2.2.2.2. 강수량 모수화 최적화 방안

기온은 일반적으로 정규분포를 따르는 것으로 가정할 수 있으나, 강수량은 0 값이 다수 포함되어 있고 분포의 왜도가 커서 단순한 모수화 적용이 어렵다. 이 연구에서 최적의 강수량 모수화 방법론을 찾기 까지 Table 2.3과 같은 4가지 방법론에 대하여 실험을 수행하였다. 초기 실험 단계에서 검토한 Gamma\_MoM 이나 Gamma\_MLE+MoM 방식은 0을 초과하는 데이터에 대해서만 매개변수(shape, scale)를 추정하므로, 강수 유무를 결정하는 핵심 요소인 건조 확률( $p_0$ )을 반영하지 못한다는 구조적 한계가 있었다. 그 결과 실제 강수 현상의 물리적 특성을 온전히 모의하지 못하여, 무강수가 빈번한 건조 지역 예측에서 부적합한 것으로 나타났다.

Table 2.3. Comparison of precipitation parameterization methods.

Category	Parameter Estimation	Dry/Wet Treatment	Key Features & Stability
Gamma_MoM	Method of Moments •shape = $\text{mean}^2 / \text{var}$ •scale = $\text{var} / \text{mean}$	•Uses only data $> 0$ •Does not reflect Dry Probability ( $p_0$ )	Pros: Fast calculation speed (vectorization possible) Cons: Unsuitable for data with many 0mm precipitation events
Gamma_MLE+MoM	MLE + MoM •Attempt MLE first •Use MoM if MLE fails	•Uses only data $> 0$ •Does not reflect Dry Probability ( $p_0$ )	Pros: Uses MLE, which is theoretically more precise than MoM Cons: Cannot model $p_0$ (similar to Gamma_MoM)
Mixed_Gamma	$p_0 + (\text{MLE} + \text{MoM})$ • $p_0$ : Ratio of dry members •MLE/MoM for wet members	•Explicitly separates Dry Probability ( $p_0$ ) • $CDF = p_0 + (1 - p_0) \times F_\gamma$	Pros: Realistically models dry events Cons: Gamma fitting is unstable if wet members are few
Hybrid_Gamma	$p_0 + (\text{MLE} + \text{MoM})$ + Empirical •Mixed_Gamma method •Fallback when wet members are insufficient	•Same as Mixed_Gamma •Uses Empirical method upon fallback	Pros: Retains Mixed_Gamma benefits; Ensures stability in dry regions Cons: Increased computational complexity

이를 보완하기 위해 도입된 Mixed\_Gamma 방법은 전체 앙상블 멤버 중 무강수 멤버의 비

을을 건조 확률( $p_0$ )로 명시적으로 분리하고, 강수가 존재하는 습윤 멤버에 대해서만 감마 분포를 적용하는 결합 방식( $CDF = p_0 + (1 - p_0) \times F_\gamma$ )을 취한다. 이 방식은 건조 이벤트를 현실적으로 모델링할 수 있다는 장점이 있으나, 습윤 멤버의 개수가 지나치게 적을 경우 감마 분포 피팅 자체가 불안정해지거나 실패할 위험이 상대적으로 높아지는 문제점이 있다.

따라서 이 연구에서는 이론적 정교함과 운영의 안정성을 동시에 확보하기 위해 Hybrid\_Gamma 방법을 최종적인 강수량 변수의 모수화 확률예측 방안으로 채택하였다. Hybrid\_Gamma 방식은 기본적으로 Mixed\_Gamma 로직을 따르되, 유효 습윤 멤버 수가 분포 추정에 불충분할 경우 자동으로 비모수적 방법으로 전환하는 알고리즘이다. 이를 통해 극심한 건조 지역이나 앙상블 분산이 적은 사례에서도 확률 계산의 실패가 없는 안정성을 확보할 수 있다. 다만, 알고리즘 복잡성 증가로 인한 연산 속도 저하 문제는 병렬화 프로그래밍(MPI)을 통해 해결하였다.

### 2.2.3. 확률예측 방법론 별 예측성 비교

#### 2.2.3.1. 전체적인 확률 예측 성능 평가(RPSS)

확률예측의 전반적인 정확도를 평가하기 위해 기후값 대비 예측 모델의 개선 정도를 나타내는 RPSS를 산출하여, 모수화 방법(기온: Gauss, 강수: Hybrid\_Gamma)과 비모수화 방법(Quantile) 간의 예측 성능을 정량적으로 비교해 보았다. 검증기간은 2022년 1월부터 2024년 11월까지의 150회 예측 사례를 대상으로 수행하였다. 먼저 모수화 방법론 적용 전후의 성능 변화를 공간적으로 분석하였다.

기온에 대해 Gauss 방법을 적용한 결과, 전 지구 대부분의 영역에서 양의 RPSS 차이( $Gauss - Quantile > 0$ )가 관측되었다. Figure 2.9를 살펴보면, 붉은색으로 표시된 영역이 지배적으로 나타나 모수화 방법의 우위가 확인된다. 특히, 앙상블 멤버 수에 따른 성능 향상 폭의 차이가 두드러지게 나타났다. 총 51개(2023년 6월 27일 이후 101개)의 가장 많은 앙상블 멤버를 보유한 ECMWF 모델의 경우, 비모수적 방법으로도 모집단의 분포를 어느 정도 묘사할 수 있어 모수화 방법 적용에 따른 이득이 상대적으로 적게 나타났다. 반면, 상대적으로 앙상블 멤버 수가 적은 ECCO(20개) 모델에서부터 APCC(10개) 모델로 갈수록, 모수화를 통해 표본 부족으로 인한 불확실성을 보정함으로써 예측 성능이 획기적으로 향상되는 것을 확인할 수 있다. 이는 모수화 방법이 적은 앙상블 자원을 가진 모델의 확률예측 품질을 높이는 데 매우 효과적인 도구임을 시사한다.

예측 시간 경과에 따른 변화를 보면, 예측 시간이 길어질수록(Week 1 → Week 4) 모델의 앙상블 스프레드가 커지며 예측성이 전반적으로 하락하는 것이 일반적이라 할 수 있지만, Figure 2.9에서 보여주는 바와 같이 모수화 방법과 비모수화 방법 간의 성능 격차는 거의 유지되는 경향을 보인다.

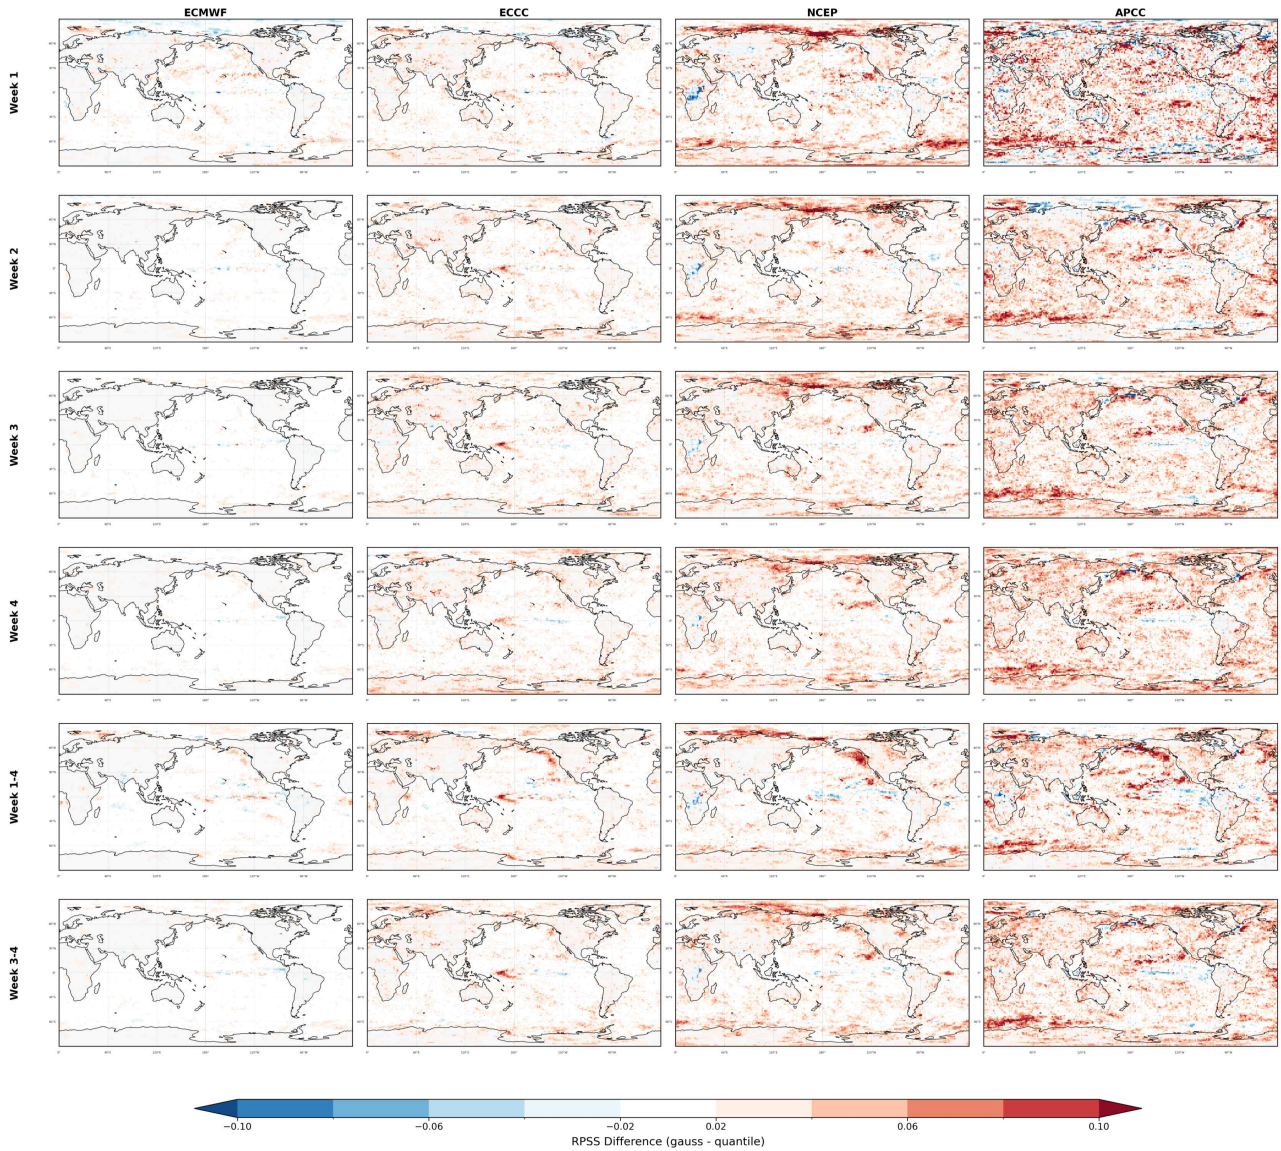


Figure 2.9. Global distribution of RPSS differences for temperature (T2M) forecasts (Gauss minus Quantile) across four S2S models. The maps display the difference in RPSS for ECMWF, APCC, ECCO, and NCEP models. Red regions (positive values) indicate areas where the Gauss method demonstrates higher predictive skill compared to the Quantile method.

강수량에 대해 Hybrid\_Gamma 방법을 적용한 결과 또한 Quantile 방법 대비 긍정적인 성능 향상을 보였다. Figure 2.10에서 나타나듯, 강수 변동성이 큰 열대 지역과 중위도 해양지역을 중심으로 뚜렷한 성능 개선이 확인되었다. 강수량 예측 역시 앙상블 멤버 수가 적은 모델(ECCO, NCEP, APCC)에서 성능 향상 효과가 더 크게 나타났다. 특히 강수량 데이터는 '0' 값이 많고 오른쪽으로 긴 꼬리를 갖는 비대칭 분포를 보이는데, 단순 Quantile 방식은 이러한 꼬리 부분의 확률을 섬세하게 표현하는 데 한계가 있다. 반면, 하이브리드 감마 방식은 강수가 존재하는 구간에 대해 이론적 분포를 적합시킴으로써, 열대 수렴대나 중고위도 해양지역과 같이 강수가 잦은 지역에서의 확률 분해능을 높여 RPSS 점수 향상에 기여한 것으로 판단된다. 다만, 극히 건조한 사막 지역이나 특정기간에 건기가 존재하는 지역 등에서는 두 방법론 간의 차이

가 미미하거나 오히려 모수화 방법의 성능이 낮은 결과를 보였다. 이러한 부분은 데이터 부족으로 인한 모수화의 어려움이 반영되어 성능 차이가 혼재된 양상을 보였다. 또한, ECMWF 모델에서 나타나는 하와이 동쪽 해상 같이 모수화 방법의 예측성 하락하는 지역은 일부 hindcast 샘플에서 나타나는 많은 강수량에 의해 Quantile 방법 대비 오른쪽 꼬리가 길게 모수화 하였기 때문이다. 특히, 이 연구에서는 검증 기준이 되는 관측자료의 분위수를 Quantile 방법을 사용하기 때문에 일정부분 비모수화 방법이 예측성 평가에서 유리한 부분이 존재한다.

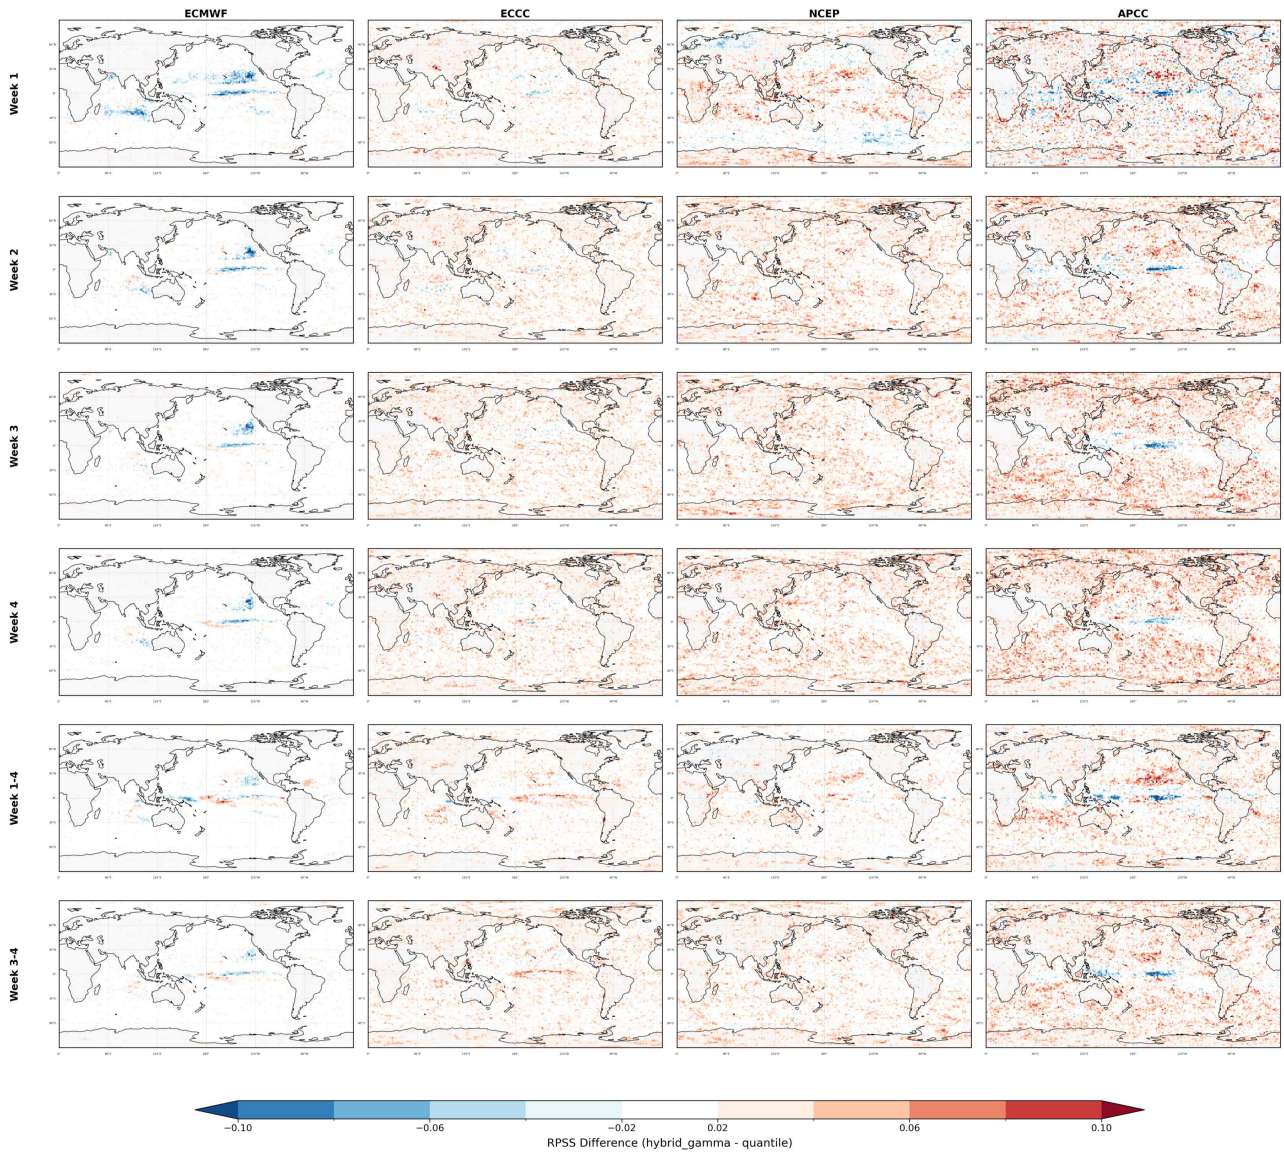


Figure 2.10. Global distribution of RPSS differences for precipitation (PREC) forecasts (Hybrid\_Gamma minus Quantile) across four S2S models. The maps display the difference in RPSS for ECMWF, APCC, ECCO, and NCEP models. Red regions (positive values) indicate areas where the Hybrid\_Gamma method demonstrates higher predictive skill compared to the Quantile method.

앞서 확인한 공간적 분포의 특징을 보다 정량적으로 파악하기 위해, 전구(Global)와 열대(Tropics,  $-20^{\circ} \sim +20^{\circ}$ ), 동아시아(East Asia,  $100^{\circ} \sim 150^{\circ} E, 10^{\circ} \sim 60^{\circ} N$ ) 영역에 대해 예측 기간 별(Week 1~4, Week 1-4, Week 3-4) RPSS와 모수화/비모수화 간의 차이의 평균값을 산출하여 비교 분석하였다. 이 분석에서부터 PMME (Probabilistic Multi-Model Ensemble) 예측결과에 대한 검증은 같이 보였다.

기온 변수의 경우, 모든 모델과 모든 예측 기간에서 Gauss 방법이 Quantile 방법보다 우수한 예측 성능을 보였다. Figure 2.11과 Table 2.4에 제시된 바와 같이, 전구 평균 기준으로 APCC 모델은 Week 1에 +0.0242의 다른 모델 대비 가장 큰 성능 향상을 기록하였으며, Week 4에도 +0.0271로 그 격차가 소폭 상승하는 경향을 보였다. 이는 앙상블 멤버 수가 적은 모델일 수록 모수화 적용 효과가 극대화됨을 수치적으로 보여주고 있다. 반면, 앙상블 멤버가 가장 많은 ECMWF 모델은 전구 평균 약 +0.004~0.006 수준의 성능 향상을 보여주고 있으며, 이는 모수화 방법이 대규모 앙상블 시스템에서도 비등한 예측수준을 제공함을 확인하였다. 특히 동아시아 지역에서는 NCEP과 APCC 모델이 3~4주 차 장기 예측에서 +0.02 이상의 높은 RPSS 개선 폭을 보여, 중위도 지역의 계절내예측 신뢰도 확보에 Gauss 방법을 통한 예측성 향상 가능성을 보여준다.

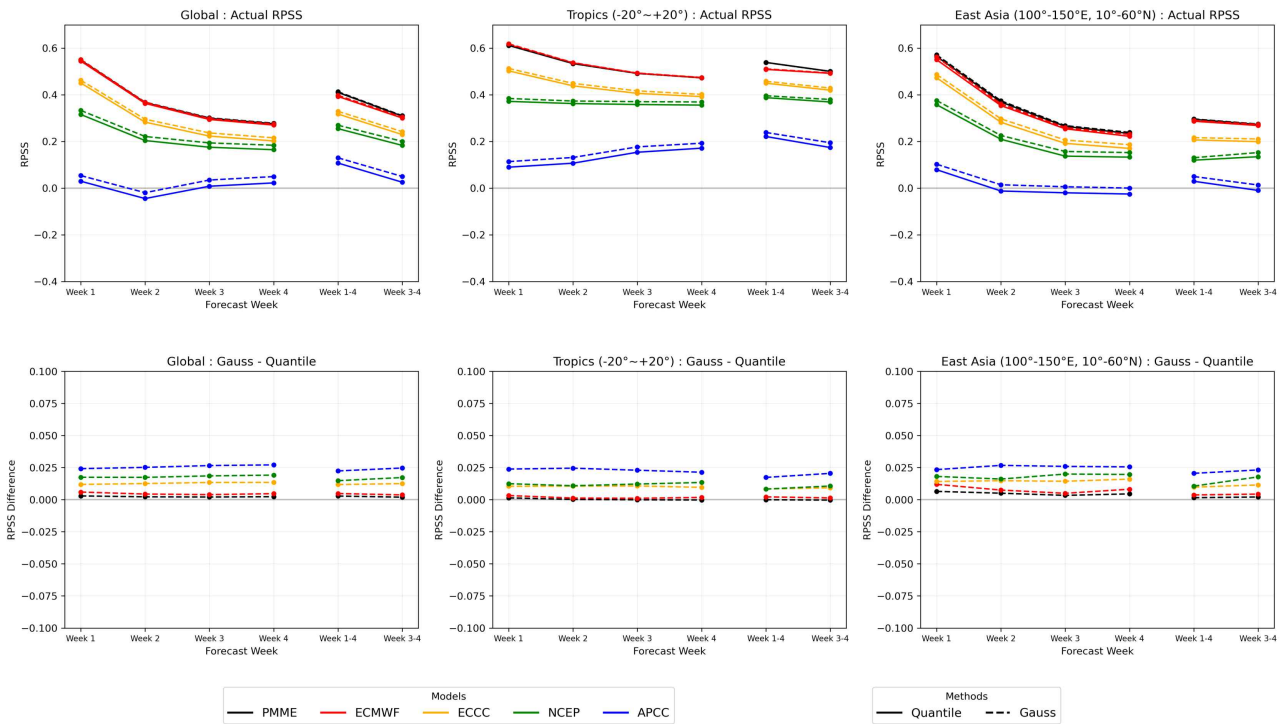


Figure 2.11. Temporal evolution of RPSS differences for temperature (Gauss minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia).

Table 2.4. Quantitative comparison of RPSS differences for temperature (Gauss minus Quantile).

Region	Model	week 1	week 2	week 3	week 4	week 1-4	week 3-4
Global	PMME	0.0029	0.0022	0.0021	0.0023	0.0028	0.0019
	ECMWF	0.0059	0.0044	0.0039	0.0047	0.0048	0.0037
	ECCC	0.0119	0.0126	0.0134	0.0134	0.0117	0.0125
	NCEP	0.0175	0.0174	0.0185	0.0191	0.0148	0.0172
	APCC	0.0242	0.0252	0.0266	0.0271	0.0224	0.0246
Tropics (-20° ~ +20°)	PMME	0.0014	0.0002	-0.0001	-0.0003	-0.0001	-0.0003
	ECMWF	0.0032	0.0012	0.0011	0.0017	0.0022	0.0014
	ECCC	0.0104	0.0105	0.0107	0.0096	0.0083	0.0092
	NCEP	0.0124	0.0108	0.0122	0.0134	0.0082	0.0106
	APCC	0.0238	0.0245	0.0229	0.0214	0.0173	0.0205
East Asia (100° ~ 150° E, 10° ~ 60° N)	PMME	0.0064	0.0050	0.0033	0.0045	0.0015	0.0021
	ECMWF	0.0119	0.0075	0.0050	0.0081	0.0037	0.0043
	ECCC	0.0142	0.0148	0.0143	0.0160	0.0097	0.0115
	NCEP	0.0181	0.0161	0.0200	0.0196	0.0105	0.0177
	APCC	0.0234	0.0267	0.0259	0.0256	0.0205	0.0232

강수량 예측에서도 모수화 방법인 Hybrid\_Gamma 방법이 전반적으로 우세를 보였다. Figure 2.12와 Table 2.5를 살펴보면, ECCC와 NCEP 모델은 전구 및 모든 지역에서 Week 1부터 Week 4까지 일관되게 +0.01 이상의 뚜렷한 성능 향상을 기록하였다. APCC 모델의 경우, 예측 초기인 Week 1에는 전구 평균 +0.0095 수준의 향상을 보였고, 예측 시간이 길어질수록 성능 개선 폭이 2배 이상 증가하는 특징을 보였다. 이는 앙상블 수가 적은 모델의 강수량 분포를 감마 함수가 효과적으로 보정했기 때문으로 분석된다.

한편, PMME와 ECMWF 결과에는 Week 1에 미세한 음의 값(-0.0046 ~ -0.0004)을 보이거나 예측성 향상정도가 미미한 것으로 나타났다. 그럼에도 불구하고 대다수 단일 모델 결과에서는 Hybrid\_Gamma 방법이 명확한 우위를 점하고 있어, 현업 적용 시 충분한 경쟁력을 갖춘 것으로 평가된다.

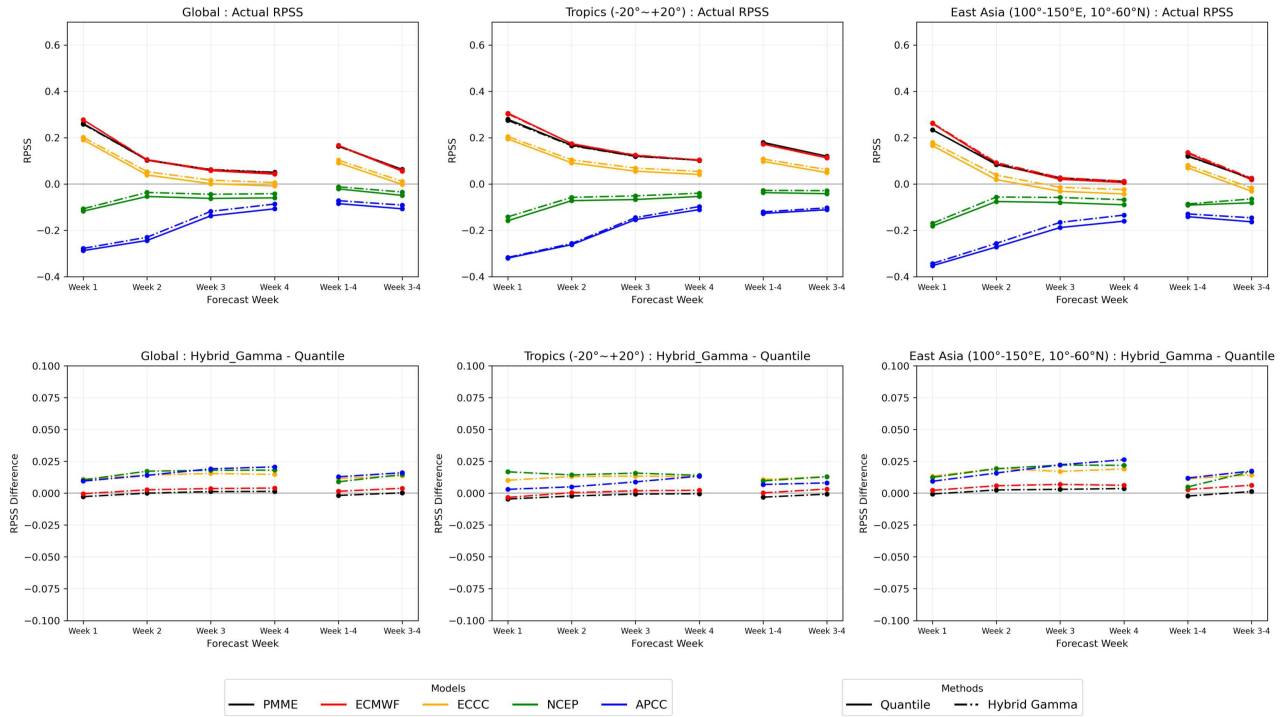


Figure 2.12. Temporal evolution of RPSS differences for precipitation (Hybrid\_Gamma minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia).

Table 2.5. Quantitative comparison of RPSS differences for precipitation (Hybrid\_Gamma minus Quantile).

Region	Model	week 1	week 2	week 3	week 4	week 1-4	week 3-4
Global	PMME	-0.0027	0	0.0013	0.0014	-0.0018	0.0002
	ECMWF	-0.0004	0.0027	0.0037	0.0040	0.0015	0.0039
	ECCC	0.0110	0.0142	0.0155	0.0148	0.0115	0.0136
	NCEP	0.0104	0.0173	0.0180	0.0181	0.0089	0.0147
	APCC	0.0095	0.0140	0.0191	0.0207	0.0129	0.0161
Tropics (-20° ~ +20°)	PMME	-0.0046	-0.0022	-0.0007	-0.0004	-0.0031	-0.0007
	ECMWF	-0.0033	0.0004	0.0019	0.0023	0.0002	0.0033
	ECCC	0.0102	0.0131	0.0134	0.0130	0.0107	0.0130
	NCEP	0.0168	0.0143	0.0158	0.0140	0.0096	0.0130
	APCC	0.0030	0.0050	0.0089	0.0134	0.0068	0.0081
East Asia (100°~150°E, 10°~60°N)	PMME	-0.0006	0.0025	0.0030	0.0036	-0.0022	0.0013
	ECMWF	0.0022	0.0058	0.0069	0.0062	0.0030	0.0063
	ECCC	0.0133	0.0195	0.0171	0.0190	0.0113	0.0143
	NCEP	0.0124	0.0192	0.0221	0.0219	0.0049	0.0170
	APCC	0.0094	0.0158	0.0223	0.0263	0.0119	0.0174

### 2.2.3.2. 이상기후에 대한 예측성 분석

최근 기후변화로 인해 빈번해지는 이상기후에 대한 예측 성능을 평가하기 위해, 상위 10%(P90) 이상의 극한 사상에 대한 ROC 분석을 추가로 수행하였다. 기존의 비모수화 방법은 앙상블 멤버 수의 물리적 한계로 인해 10% 미만의 최소 확률을 표현하는 데 구조적 제약이 따른다. 예를 들어, 앙상블 멤버가 10개인 모델의 경우 최소 표현 가능한 확률 단위는 10%로 고정되므로, 1%나 5%와 같은 극단적인 확률을 세밀하게 구분해 낼 수 없다. 반면, 모수화 방법은 앙상블 멤버들의 통계적 특성을 이용하여 확률밀도함수(PDF)를 추정하고, 이를 통해 꼬리 부분의 확률을 수학적으로 외삽할 수 있다. 이는 모델이 직접 모의하지 못한 범위의 값이라 하더라도 이론적 확률 분포를 통해 극한 사상의 발생 가능성을 정교하게 산출할 수 있음을 의미한다.

극한 기온(상위 10% 고온)에 대한 ROC AUC 분석 결과(Figure 2.13), Gauss 방법이 Quantile 방법 대비 전반적으로 높은 예측 성능을 기록하였다. Figure 2.13 하단의 차이값 그래프를 보면, 전 지구(Global) 및 동아시아(East Asia) 지역에서 모든 모델이 양의 값을 나타내면서 Gauss 방법이 우위에 있음을 보여준다. 특히 주목할 점은 앙상블 멤버 수가 적은 NCEP(녹색)과 APCC(파란색) 모델에서 성능 향상 폭이 가장 크다는 것이다. 이는 앙상블 멤버가 부족하여 극한값을 직접 포함하지 못하는 경우에도, 가우시안 분포가 꼬리 부분을 효과적으로 추정하여 이상기후 감지 능력을 보완해 주고 있음을 시사한다.

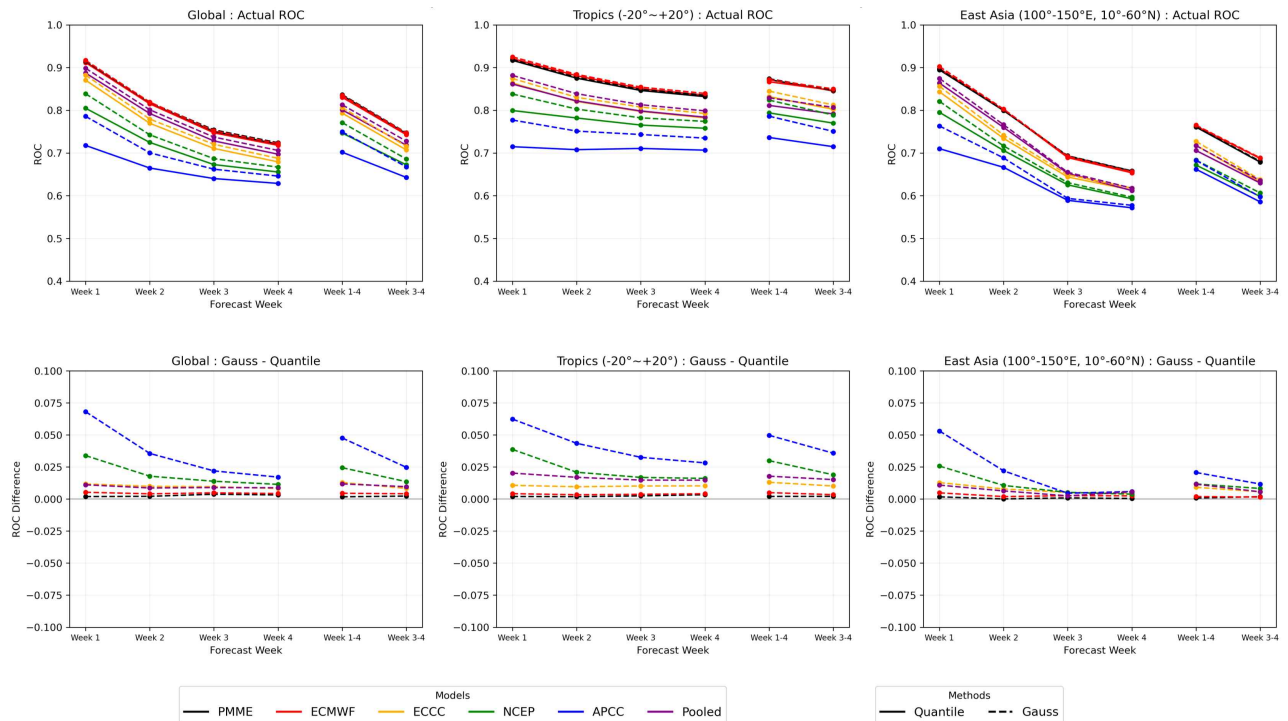


Figure 2.13. Temporal evolution of ROC AUC scores for extreme temperature events (>90th percentile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia).

극한 강수(상위 10%) 예측에서도 Hybrid\_Gamma 방법의 우위가 확인되었다(Figure 2.14). 강수량은 기온보다 분포의 왜도(Skewness)가 커서 꼬리 부분의 확률 추정이 더욱 난해함에도 불구하고, Hybrid\_Gamma 방법은 Quantile 방법 대비 안정적인 ROC 점수를 유지하였다. 특히 열대 지역에서 앙상블 수가 적은 세 모델(ECCC와 NCEP, APCC)의 예측성 향상이 두드러지게 나타났는데, 이는 비모수적 카운팅으로는 놓치기 쉬운 열대 지역의 국지적 호우 가능성을 감마 분포가 성공적으로 포착했기 때문으로 판단된다.

종합적으로, 모수화 방법은 앙상블 멤버가 포착하지 못한 범위의 이상기후 가능성까지 이론적으로 추정하여, 조기 경보(Early Warning) 관점에서의 활용 가치가 비모수적 방법보다 월등히 높은 것을 알 수 있다. 따라서 향후 현업 시스템에서 극한 기후 감시 및 전망 정보를 생산하는 데 있어 모수화 방법론의 적용은 필수적이라 판단된다.

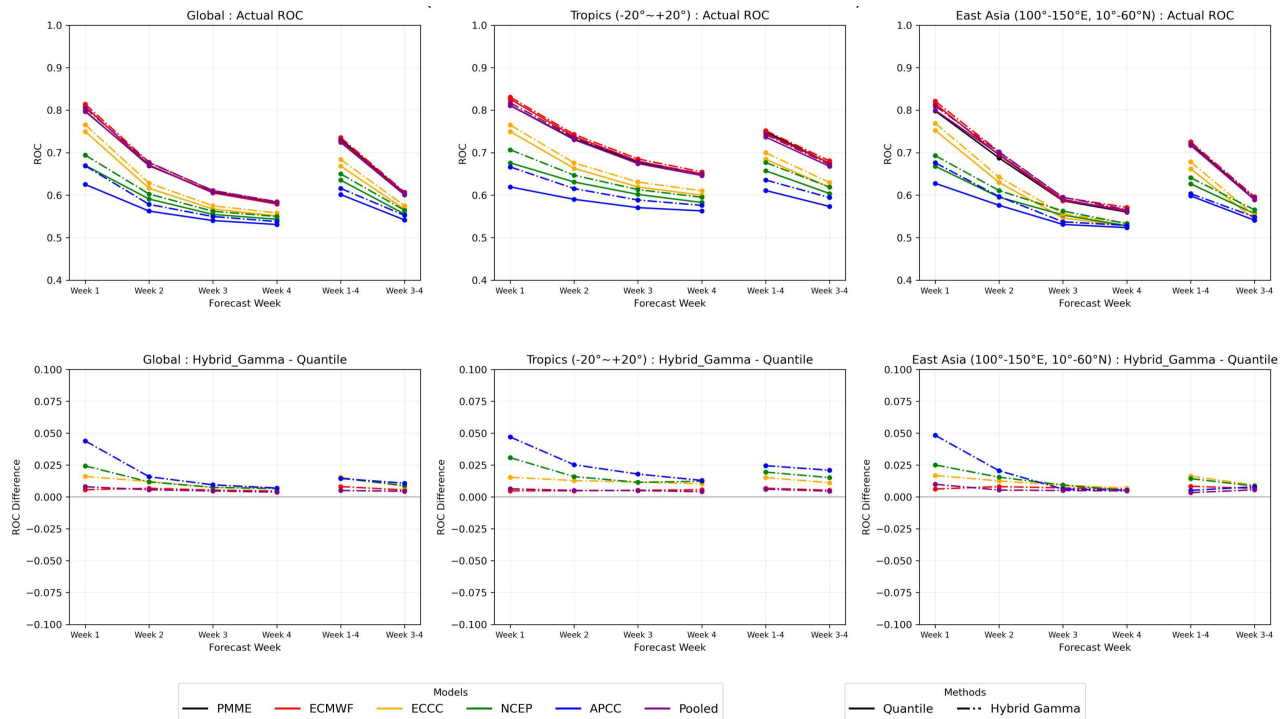


Figure 2.14. Temporal evolution of ROC AUC scores for extreme precipitation events (>90th percentile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia).

## 2.2.4. 확률예측 방법론 별 공간적 노이즈 비교

### 2.2.4.1. 확률예측 표출 시 공간적 불연속성의 문제점

이 연구에서는 단순한 예측 정확도 평가를 넘어, 현업 예보관이 직관적으로 해석하고 신뢰할 수 있는 예측 정보를 생산하기 위해 결과의 공간적 일관성(Spatial Coherence)을 핵심 평가 지표로 선정하였다. 수치적 검증 점수가 유사하더라도 공간적으로 불연속적이거나 지저분한 예

측장은 정보의 신뢰도를 떨어뜨리므로, 모수화 방법론이 이러한 공간적 노이즈를 얼마나 효과적으로 개선하는지 정량적·정성적으로 검증하였다.

기온이나 대규모 강수 시스템과 같은 기상 물리 변수는 일반적으로 공간적으로 연속적인 분포 특성을 가진다. 그러나 앙상블 확률예측 시, 제한된 수의 앙상블 멤버를 단순히 카운팅하는 비모수적 방법을 적용할 경우, 인접한 격자점 간에 포함되는 멤버 수가 우연에 의해 달라지는 샘플링 노이즈(Sampling Noise)가 발생한다. 이는 실제 물리적 현상의 변동이 아님에도 불구하고, 예측 결과 표출 시 마치 자글자글한 점묘화 같은 공간적 불연속성으로 나타나 예보 분석을 방해하는 주요 원인이 된다.

이러한 공간적 노이즈 문제의 정성적인 평가를 위해 4개 모델 전부에 대하여 확률예측 결과를 비교하였다. Figure 2.15는 Quantile 방법을 적용한 Week 3 강수량 확률예측 결과이다. 그림에서 확인할 수 있듯이, 앙상블 멤버 수가 가장 많은 ECMWF부터 상대적으로 적은 NCEP과 APCC 모델에 이르기까지 모든 모델에서 공통적으로 공간적 노이즈가 관찰된다. 특히 강수 활동이 활발한 열대 해상에서 확률 분포가 매끄럽게 연결되지 못하고, 파편화된 튀는 값이 나타났다. 이러한 불연속적인 정보는 예보관이 대규모 강수 시스템의 위치와 강도를 파악하는 데 혼란을 주며, 현업 자료로서의 가독성을 크게 저해한다.




Figure 2.15. Spatial distribution of Week 3 precipitation probability forecasts for S2S models (ECMWF, ECCO, NCEP, APCC) using the Quantile method.




Figure 2.16. Spatial distribution of Week 3 precipitation probability forecasts for S2S models (ECMWF, ECCO, NCEP, APCC) using the Hybrid\_Gamma method.

반면, 동일한 모델 자료에 대해 Hybrid\_Gamma 방법을 적용한 결과는 시각적으로 확연히 다른 특성을 보여준다(Figure 2.16). 모든 모델의 예측장에서 나타나던 노이즈가 제거되고, 강수 구역의 중심부에서 주변부로 이어지는 확률의 변화가 부드럽고 연속적으로 표현되고 있다.

특히 주목할 점은 앙상블 멤버 수가 적은 모델에서의 개선 효과이다. 비모수적 방법에서는 표본 부족으로 인해 확률값이 급격하게 변하는 현상이 발생했으나, 모수화 방법을 적용함으로써 ECMWF와 유사한 수준의 공간적 일관성을 확보하였다. 이는 모수화 과정이 통계적 추론을 통해 부족한 표본 정보를 보완하고, 물리적으로 타당한 확률 분포를 재구성함으로써 모델 간의 품질 격차를 줄이는 데에도 기여함을 시사한다. 따라서 다양한 모델의 예측결과를 현업 예보관에게 제공하는 APCC의 예측 시스템에서는 확률예측 시 모수화 방법론의 도입의 장점이 크다고 할 수 있다.

#### 2.2.4.2. 공간적 노이즈 정량화 방법

예측 결과 표출 시 나타나는 시각적 거칠기와 불연속성을 객관적으로 수치화하기 위해, 2차원 격자장에 대한 공간적 라플라시안 지수(Spatial Laplacian Index)를 고안하여 적용하였다. 이는 각 격자점의 확률값이 주변 격자점들의 값과 얼마나 급격하게 차이가 나는지를 미분 연산자를 통해 정량화하는 방법이다.

확률 예측장의 임의의 격자점 (i, j)에서의 공간적 노이즈는 2차원 이산 라플라시안 (Discrete Laplacian,  $\nabla^2$ )의 절댓값으로 정의된다. 이 연구에서는 대각선 방향을 포함한 인접 8개 격자점을 모두 고려하기 위해 다음 식 2.5와 같은 3x3 커널을 사용한 합성곱(Convolution) 연산을 수행하였다.

$$K = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad [2.5]$$

이에 따른 격자점 (i, j)에서의 라플라시안 값  $\nabla^2 P_{i,j}$ 는 식 2.6과 같이 표현된다.

$$\nabla^2 P_{i,j} = \left( \sum_{(x,y) \in neighbors} P_{x,y} \right) - 8P_{i,j} \quad [2.6]$$

이 수식은 해당 격자점의 값( $P_{i,j}$ )과 주변 8개 격자점 합을 계산하는 것으로, 물리적으로는 해당 지점의 값이 주변 평균으로부터 벗어난 정도에 비례한다. 값이 평탄한 구역에서는 0에 가까운 값을 가지며, 노이즈가 심하거나 값이 튀는 지점에서는 큰 절댓값을 갖는다. 최종적인 공간적 노이즈 지수는 3개 카테고리(Below, Normal, Above) 각각에 대해 계산된 라플라시안 절댓값의 평균으로 정의되며, 이를 전체 검증 기간에 대해 평균하여 방법론별 노이즈 수준을 비교하였다.

### 2.2.4.3. 확률예측 방법론에 따른 공간적 노이즈 분석

앞서 정의한 공간적 라플라시안 지수를 활용하여 각 확률예측 방법론의 공간적 노이즈를 정량적으로 분석해 보았다. 먼저 기온 변수의 Gauss 방법과 Quantile 방법에 따른 확률예측 결과에 대하여 공간적 노이즈 지수를 각각 계산하여 비교하였다(Figure 2.17, Table 2.6). Table 2.6에 제시된 바와 같이, 모든 모델에서 음의 값으로 노이즈 감소 결과가 나타났으며 예측 시간이 길어질수록 그 효과는 더욱 뚜렷해졌다.

전구 평균 기준으로, 앙상블 멤버 수가 적은 NCEP 모델(녹색)은 Week 1에  $-0.111$ , Week 4에는  $-0.189$ 의 노이즈 감소를 기록하였다. APCC 모델(파란색) 또한 Week 1에  $-0.096$ 에서 Week 4에는  $-0.248$ 로 감소 폭이 급격히 증가하였는데, 이는 예측 후반부로 갈수록 앙상블 스프레드가 넓어지며 발생하는 불확실성을 가우시안 분포가 안정적으로 제어하고 있음을 보여준다. 지역별로 살펴보면, 동아시아 지역에서의 개선 효과가 두드러진다. 특히, APCC 모델의 경우 Week 4 예측에서  $-0.2778$ 의 노이즈 감소를 기록하여, 전구 평균( $-0.2484$ )보다 더 높은 개선 효과를 보였다.

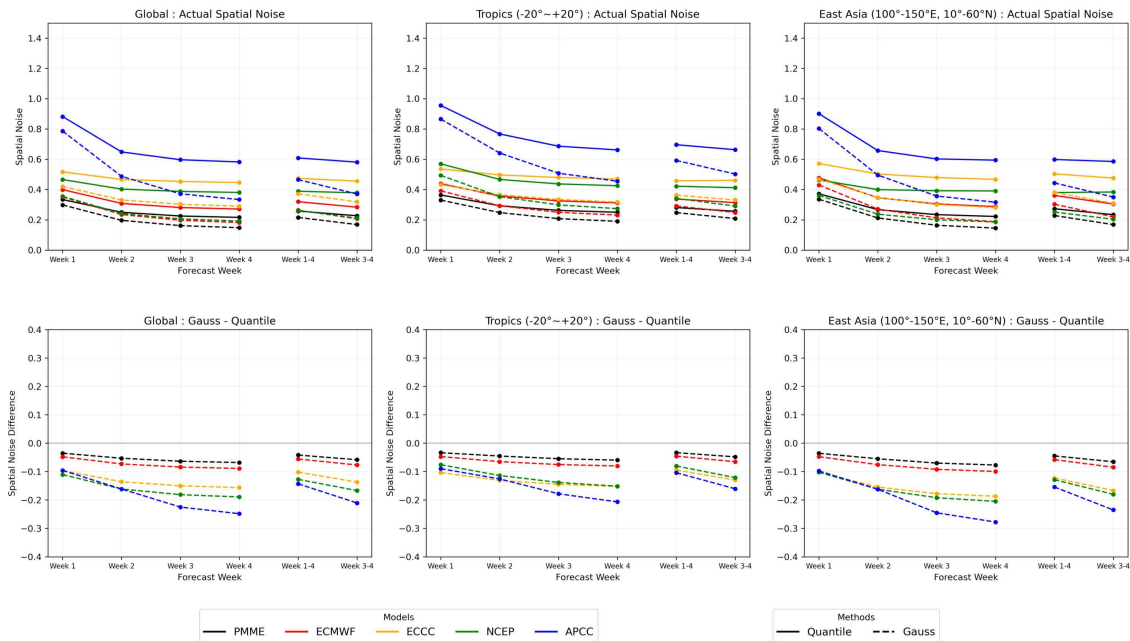


Figure 2.17. Temporal evolution of spatial noise for temperature (Gauss minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia).

Table 2.6. Quantitative comparison of spatial noise reduction for temperature (Gauss minus Quantile).

Region	Model	week 1	week 2	week 3	week 4	week 1-4	week 3-4
Global	PMME	-0.0353	-0.0531	-0.0637	-0.0681	-0.0419	-0.0582
	ECMWF	-0.0481	-0.0732	-0.0841	-0.0890	-0.0559	-0.0768
	ECCC	-0.0965	-0.1357	-0.1502	-0.1565	-0.1021	-0.1372
	NCEP	-0.1109	-0.1614	-0.1814	-0.1894	-0.1274	-0.1671
	APCC	-0.0960	-0.1613	-0.2250	-0.2484	-0.1431	-0.2106
Tropics (-20° ~ +20°)	PMME	-0.0337	-0.0453	-0.0547	-0.0597	-0.0335	-0.0481
	ECMWF	-0.0472	-0.0650	-0.0753	-0.0803	-0.0457	-0.0653
	ECCC	-0.1036	-0.1311	-0.1450	-0.1522	-0.0947	-0.1297
	NCEP	-0.0761	-0.1138	-0.1383	-0.1516	-0.0803	-0.1213
East Asia (100°~150°E, 10°~60°N)	PMME	-0.0358	-0.0549	-0.0701	-0.0770	-0.0449	-0.0655
	ECMWF	-0.0476	-0.0755	-0.0921	-0.0996	-0.0581	-0.0847
	ECCC	-0.1028	-0.1546	-0.1779	-0.1868	-0.1226	-0.1665
	NCEP	-0.1023	-0.1621	-0.1920	-0.2049	-0.1288	-0.1801
	APCC	-0.0978	-0.1623	-0.2452	-0.2778	-0.1544	-0.2351

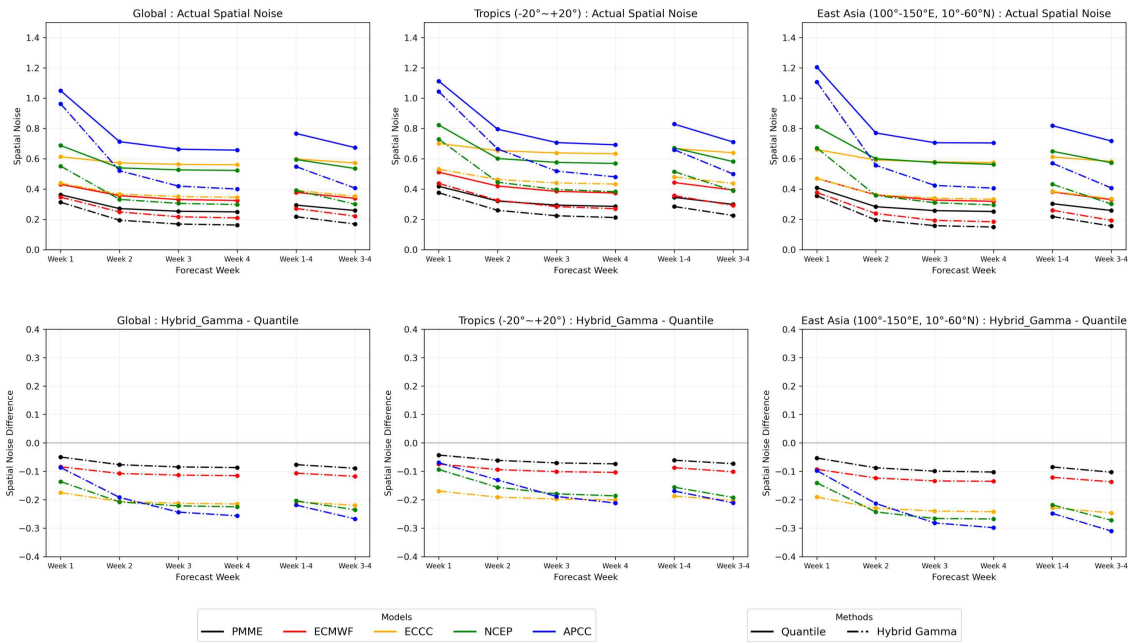


Figure 2.18. Temporal evolution of spatial noise for precipitation (Hybrid\_Gamma minus Quantile) by forecast week (Week 1 to Week 4, plus averaged periods) and region (Global, Tropics, and East Asia).

Table 2.7. Quantitative comparison of spatial noise reduction for precipitation (Hybrid\_Gamma minus Quantile).

Region	Model	week 1	week 2	week 3	week 4	week 1-4	week 3-4
Global	PMME	-0.0497	-0.0766	-0.0845	-0.0867	-0.0765	-0.0890
	ECMWF	-0.0840	-0.1075	-0.1133	-0.1151	-0.1064	-0.1176
	ECCC	-0.1749	-0.2058	-0.2123	-0.2147	-0.2070	-0.2196
	NCEP	-0.1360	-0.2077	-0.2213	-0.2249	-0.2038	-0.2353
	APCC	-0.0866	-0.1917	-0.2435	-0.2565	-0.2187	-0.2672
Tropics (-20° ~ +20°)	PMME	-0.0427	-0.0613	-0.0703	-0.0736	-0.0608	-0.0731
	ECMWF	-0.0741	-0.0940	-0.1009	-0.1037	-0.0871	-0.1016
	ECCC	-0.1695	-0.1908	-0.1973	-0.2004	-0.1874	-0.2022
	NCEP	-0.0936	-0.1562	-0.1791	-0.1863	-0.1558	-0.1919
	APCC	-0.0694	-0.1305	-0.1882	-0.2116	-0.1693	-0.2109
East Asia (100° ~150° E, 10° ~60° N)	PMME	-0.0533	-0.0875	-0.0993	-0.1024	-0.0847	-0.1029
	ECMWF	-0.0928	-0.1234	-0.1337	-0.1351	-0.1210	-0.1368
	ECCC	-0.1903	-0.2296	-0.2397	-0.2420	-0.2278	-0.2464
	NCEP	-0.1407	-0.2430	-0.2657	-0.2677	-0.2180	-0.2722
	APCC	-0.0976	-0.2130	-0.2815	-0.2982	-0.2480	-0.3100

강수량 예측에서도 Hybrid\_Gamma 방법의 노이즈 감소 효과는 명확하게 확인되었다. Figure 2.18, Table 2.7을 보면, 전 모델과 전 기간에서 예외 없이 음의 값이 도출되었다. 특히 앙상블 멤버가 적은 NCEP과 APCC 모델에서 개선정도가 컸으며, 지역적으로는 동아시아 지역이 모든 모델에서 개선의 정도가 가장 크게 나타났다. 비교적 강수량 예측의 정확도가 높은 열대 지역에서는 다른 지역대비 개선의 정도가 낮았지만 여전히 모든 모델의 전체 예측시간 결과에서 노이즈가 감소함을 보였다.

이러한 결과를 통해 모수화 방법론은 비모수화 방법론 대비 모든 변수와 예측 기간, 그리고 전 지역에서 획기적인 노이즈 감소 효과를 보임을 정량적으로 확인 하였다. 이는 모수화 과정이 앙상블 멤버들의 개별적인 위치보다는 모집단의 분포 특성을 추정함으로써, 샘플링에 의한 무작위 오차를 효과적으로 필터링했음을 의미한다.

공간적 노이즈의 제거는 단순히 보기 좋은 그림을 만드는 것을 넘어 예보관의 의사결정 효율성을 높이는 데 기여한다. 노이즈가 제거된 부드러운 예측장은 예보관이 대규모 기후 패턴을 직관적으로 인지할 수 있게 하며, 국지적인 노이즈를 유의미한 신호로 오인할 가능성을 차단한다. 결론적으로 모수화 방법론은 정량적인 예측 성능(RPSS)을 유지하면서도 현업 활용성 측면에서 필수적인 공간적 안정성을 확보해 준다.

## 2.2.5. 모수화 방법 사용 시 주의점

### 2.2.5.1. 분포 적합도 검정(Goodness-of-Fit) 실험 설계

앞선 장에서의 비교 분석을 통해 모수화 방법론이 비모수화 방법 대비 전반적인 예측 성능과 공간적 노이즈 측면에서 우수함을 확인하였다. 그러나 모수화 방법은 관측 및 모델 데이터가 특정 이론적 분포(기온의 정규분포, 강수량의 감마분포)를 따른다는 강한 수학적 가정을 전제로 한다. 만약 실제 기상 데이터가 이러한 가정을 충족하지 못할 경우, 강제적인 분포 적합은 오히려 예측 정보를 왜곡할 위험이 존재한다. 따라서 본 연구에서는 통계적 검정을 통해 이러한 이론적 한계가 나타나는 시공간적 영역을 규명하고, 이에 대한 정보 제공과 보완하기 위한 기술적 해결책을 논의하고자 한다. 이를 위해 본 연구에서는 hindcast 기간 동안의 모델 앙상블 데이터가 가정된 확률밀도함수에 얼마나 적합한지를 통계적으로 판단하기 위해 K-S Test를 수행하였다.

실험의 구체적인 설계 및 판정 기준은 다음과 같이 설계하였다. K-S test는 전 지구 모든 격자점에 대하여 개별적으로 수행하며, 각 격자점에서는 hindcast 기간의 전체 앙상블 멤버를 하나의 표본 집단으로 간주하고, 이를 각각 정규분포(기온) 및 혼합 감마분포(강수량)로 피팅하였다. 이후 데이터 자체의 경험적 누적분포함수(ECDF)와 추정된 이론적 누적분포함수(CDF) 간의 최대 거리를 산출하여 적합도를 평가하였다. 귀무가설( $H_0$ )은 “해당 격자점의 데이터 분포는 가정된 이론적 확률분포를 따른다.” 이다. 대립가설( $H_1$ )은 “해당 격자점의 데이터 분포는 가정된 이론적 확률분포를 따르지 않는다.” 이다. 판정 기준은 유의수준 0.05를 기준으로 산출된 p-value가 0.05 미만일 경우 귀무가설을 기각하였다. 본 연구에서는 전체 검증 사례 중 귀무가설이 기각된 비율을 기각률로 정의하였다. 기각률이 높게 나타나는 지역은 모수화 가정이 통계적으로 유효하지 않음을 의미하며, 해당 영역에서는 확률예측 값 사용 시 주의가 요구되거나 비모수적 방법으로의 전환과 같은 보완책이 필요함을 의미한다.

### 2.2.5.2. 기온 변수의 모수화 한계 및 지역적 특성

기온(T2M) 변수에 대해 정규분포 가정을 적용한 모수화 적합도 검정(K-S Test) 결과, Week3 이상의 예측일 경우 전 모델, 전 지구 대부분의 영역에서 낮은 기각률을 보여 가우시안 모수화가 대체로 타당함을 확인하였다(Figure 2.19). 하지만 특정 기후학적 메커니즘이 지배하는 일부 구역에서는 뚜렷한 한계가 있음을 보였으며, 모델별로도 특성에 따른 차이가 있음을 확인하였다.

ECMWF 모델은 타 모델 대비 가장 많은 앙상블 멤버와 긴 hindcast 기간을 보유하여 표본 크기가 매우 크다. 이는 통계적 검정력을 높여 이론적 분포와의 미세한 차이만으로도 귀무가설을 기각하게 되므로, ECMWF의 높은 기각률(Week 1 기준 15.0%)이 반드시 예측 성능의 저하를 의미하는 것은 아님을 고려해야 한다. 반면, APCC 모델의 Week 1 예측에서 나타나는 높은 기각률(21.3%)은 예측 초기의 앙상블 스프레드가 충분히 확산되지 못하여 분포 추정에 실패하거나 과소분산된 결과에 기인한 것으로 분석된다.

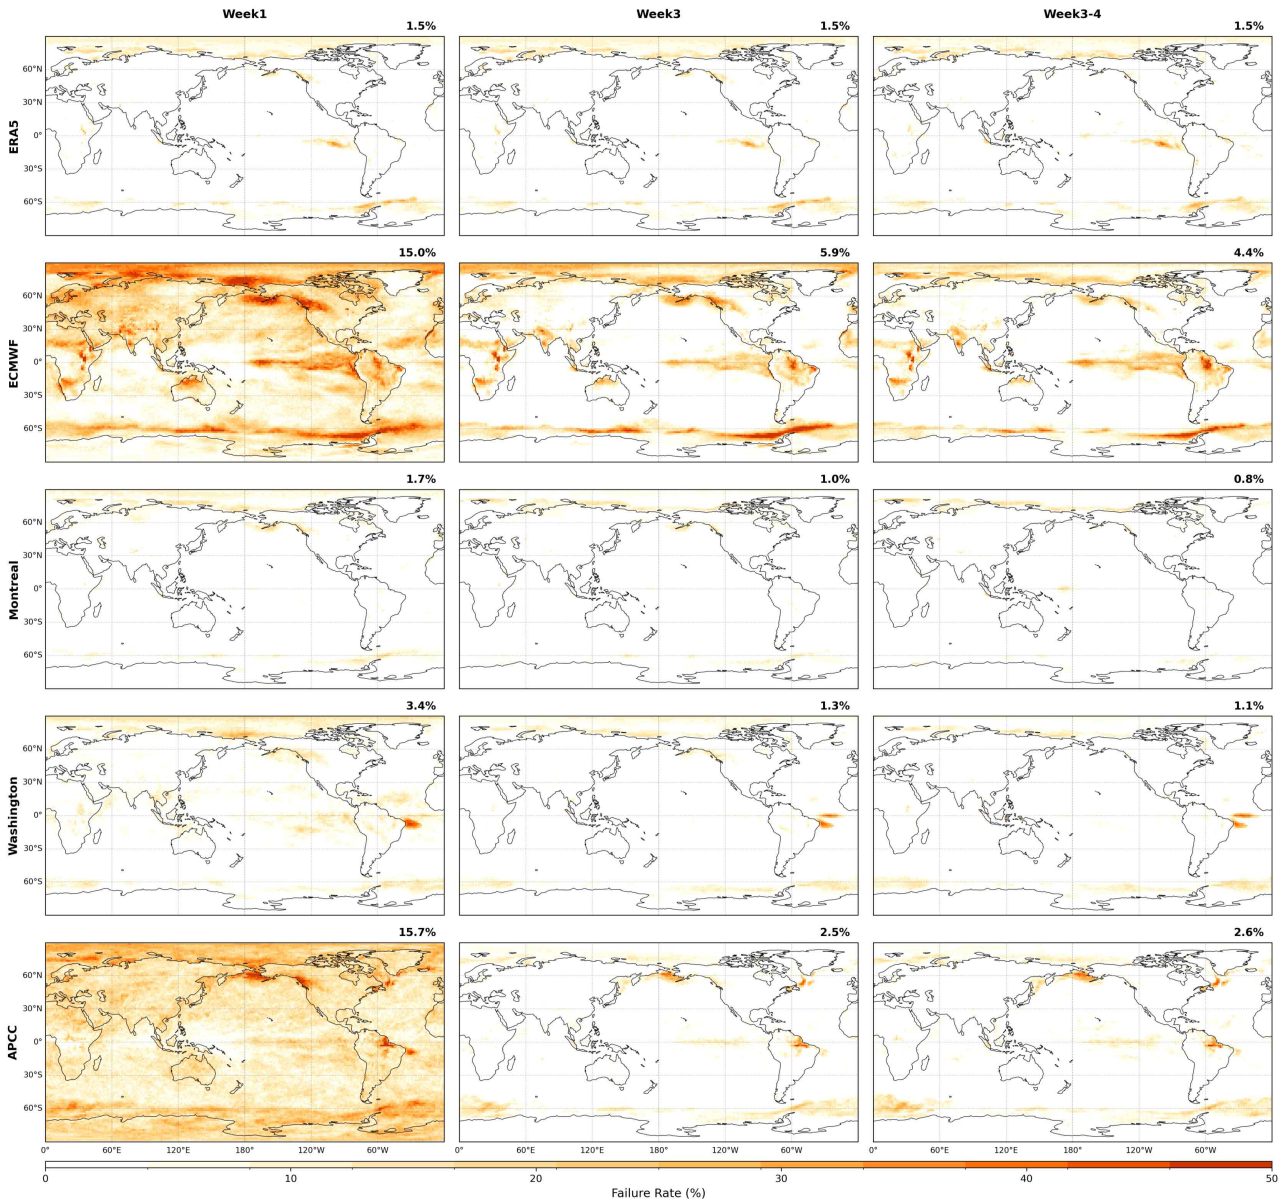


Figure 2.19. Global distribution of Kolmogorov-Smirnov (K-S) test failure rates for temperature forecast using the Gauss method.

지역적인 특징을 보면, 눈덮임과 해빙의 영향을 받는 고위도 지역 일부에서 정규분포 가정이 흔들리는 것으로 나타났다. Figure 2.20과 Figure 2.21은 ECMWF 모델의 2024년 11월 11일 기준의 hindcast Week 3 예측에서 세 곳의 분포도를 Q-Q plot과 히스토그램으로 나타낸 것이다. 먼저 Grid point 1(51°N, 81°E)은 해당 시점에 대륙 내부의 눈덮임 현상이 발생하는 구역이다. 눈덮인 지표면에서는 융해열로 인해 기온이 0°C 이상으로 상승하는 것이 억제된다. 즉, 0°C가 일종의 상한선으로 작용하여 분포의 오른쪽 꼬리가 잘리고, 반대로 복사 냉각에 의한 저온 현상은 제한 없이 발생할 수 있다. 이로 인해 분포는 왼쪽으로 긴 꼬리를 가지는 비대칭 형태가 된다.

Grid point 2(75°N, 189°E)는 해빙이 형성되는 시점의 해양의 구역이다. 해양에서는 얼음

아래의 바닷물이 대기로 열을 공급하는 열원 역할을 한다. 이는 기온이 극도로 떨어지는 것을 막는 하한선으로 작용하여 분포의 왼쪽 꼬리를 자르는 효과를 낸다. 반면, 난기 이류 등으로 인한 기온 상승은 상대적으로 자유로워, 분포는 오른쪽으로 긴 꼬리를 가지게 된다. 이러한 분포의 꼬리 절단(Tail Truncation) 현상은 정규분포 모수화 시 극값의 확률을 과소 또는 과대 모의하는 오차 원인이 될 수 있다.




Figure 2.20. Q-Q plots of ECMWF temperature Week 3 hindcast data for selected grid points.

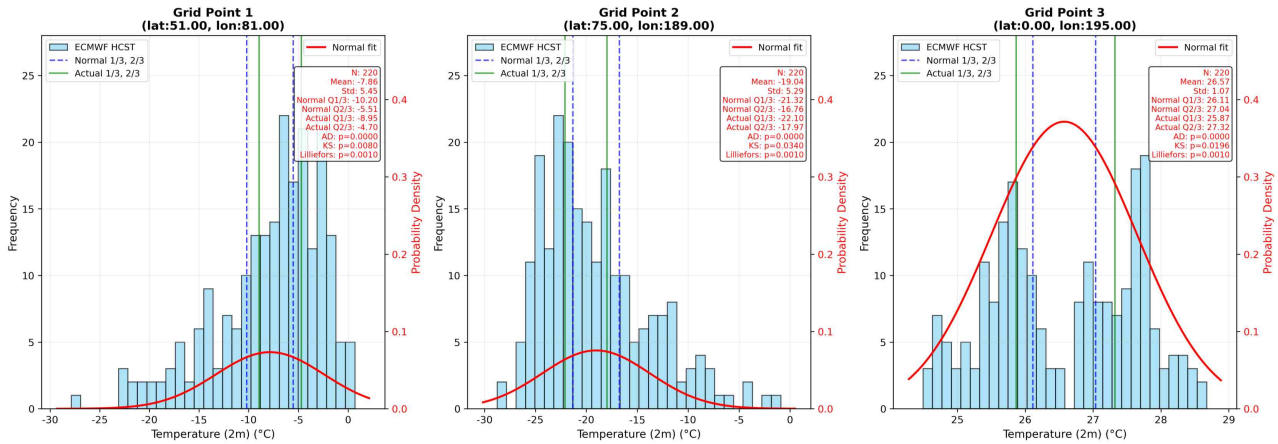


Figure 2.21. Histograms of ECMWF temperature Week 3 hindcast data with fitted Gaussian curves for selected grid points.

가장 높은 기각률(붉은색)이 집중된 적도 태평양 Grid point 3(0°N, 195°E)의 경우, 엘니뇨(El Niño)와 라니냐(La Niña)라는 두 가지 상반된 상태가 번갈아 나타나면서 기온 분포가 Bimodal 형태를 띤다. Figure 2.21의 우측 히스토그램을 보면, 두 개의 정점(Peak)이 명확히 분리되어 있어 단일 정점인 정규분포 곡선으로는 이를 제대로 모의할 수 없음을 알 수 있다. 이로 인해 Figure 2.20과 같이 Q-Q Plot에서는 이론적 분위수와 실제 샘플 분위수가 양쪽 끝단에서 S자 형태로 벗어나고 있으며, 삼분위수 지점을 보면 이론적 분위수 대비 실제 분위수의 하한은 보다 작은 값으로, 상한은 보다 큰 값으로 나타난다. 그 결과 Near Normal 확률을 실제보

다 과소하게 산출하거나, 양극단의 확률을 왜곡하는 문제가 발생할 수 있다. 실제 확률예측 시 계열을 비교해보면(Figure 2.22), Quantile 방법(상단)에 비해 Gauss 방법(하단)은 ENSO 전환 시기에 Near Normal 확률(회색)을 다소 과소하게 산출하고 있으며, 해당 시점의 예측 실패 요인이 된다. 이는 ENSO 감시 및 전망 시 모수화 결과 해석에 주의가 필요함을 시사한다. 다만, ENSO의 판정 기준은 과거 관측의 분포에서 정규분포를 가정하여 판정하므로, 이 연구에서 검증 기준으로 삼은 비모수적 방법을 사용 하였을 때와는 다른 결과를 보일 것이다.




Figure 2.22. Time series comparison of ECMWF temperature Week 3 probability forecasts at an ENSO-affected grid point(0°, 195°E).

### 2.2.5.3. 강수량 변수의 모수화 한계 및 지역적 특성

강수량 변수에 대해 Mixed\_Gamma 가정을 적용한 K-S test 결과, 기온 변수에 비해 모수화 적용의 제약 조건이 시공간적으로 뚜렷하게 드러났다. Figure 2.23의 기각률 분포도를 살펴보면, 기각률이 높게 나타나는 곳(녹색 영역)은 사하라 사막, 아라비아 반도, 호주 내륙 등 연중 건조한 기후 지역이나 계절적 건기 지역과 정확히 일치한다. 이러한 모수화 실패의 근본 원인은 유효 습윤 멤버의 부족이다. Mixed\_Gamma 방법은 전체 표본 중 무강수 비율( $p_0$ )을 분리하고 나머지 습윤 멤버에 대해 감마 분포를 적합시키는데, 극히 건조한 지역에서는 대다수 이상분 멤버가 무강수를 예측하여 습윤 멤버의 부족으로 감마분포의 형상(Shape)과 척도(Scale) 매개변수를 안정적으로 추정하기 어려워진다.

All Models Precipitation Mixed Gamma KS Test p-value Failure Rate (20220103~20241111)

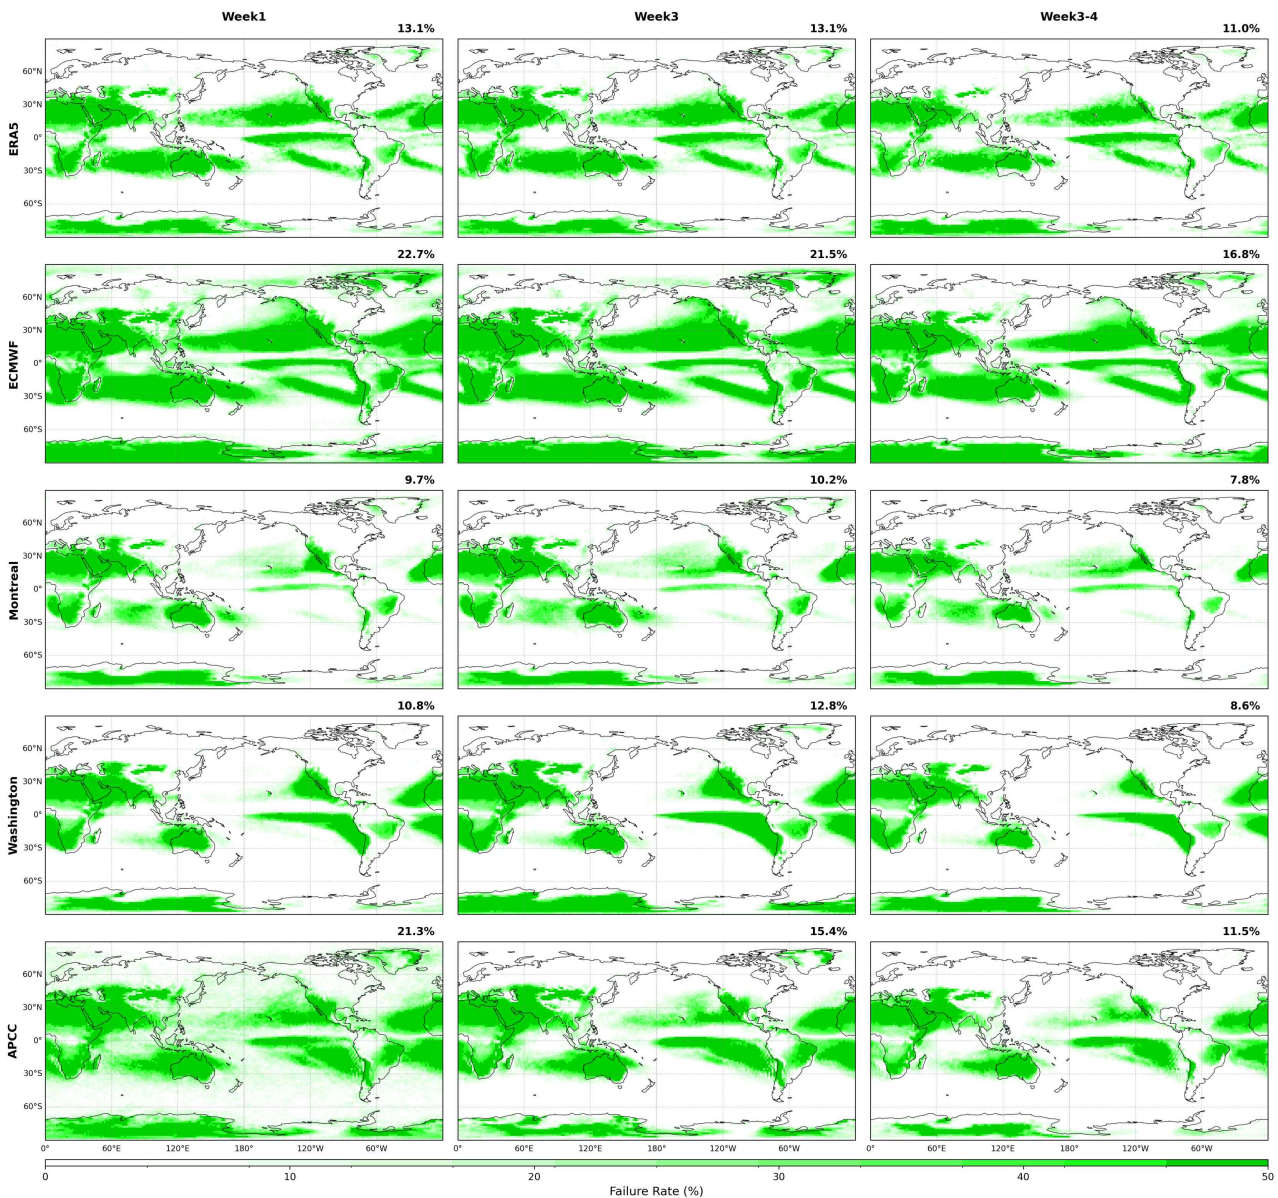


Figure 2.23. Global distribution of Kolmogorov-Smirnov (K-S) test failure rates for precipitation forecast using the Mixed\_Gamma method.

강수량 변수의 모수화와 관련하여 건조 비율의 영향은 Figure 2.24의 히스토그램 분석 결과에서 잘 보여주고 있다. 강수가 많은 열대지역( $0^{\circ}\text{N}$ ,  $120^{\circ}\text{E}$ )과 중위도의 강수가 빈번한 지역( $30^{\circ}\text{N}$ ,  $120^{\circ}\text{E}$ )은 건조 비율이 각각 0.000, 0.141로 낮아, 충분한 수의 습윤 멤버를 바탕으로 감마 분포 곡선(붉은 실선)이 데이터의 분포를 효과적으로 모사하고 있다. 반면, 중동의 극심한 건조 지역( $30^{\circ}\text{N}$ ,  $60^{\circ}\text{E}$ )의 경우 건조 비율이 0.545에 달해 전체 데이터의 절반 이상이 0값(회색 막대)에 집중되어 있다. 비록 감마 피팅 자체는 수행되었으나, 꼬리 부분(Tail)을 구성하는 습윤 멤버의 수가 상대적으로 빈약하여 극값 추정의 신뢰도가 저하될 위험이 높다.

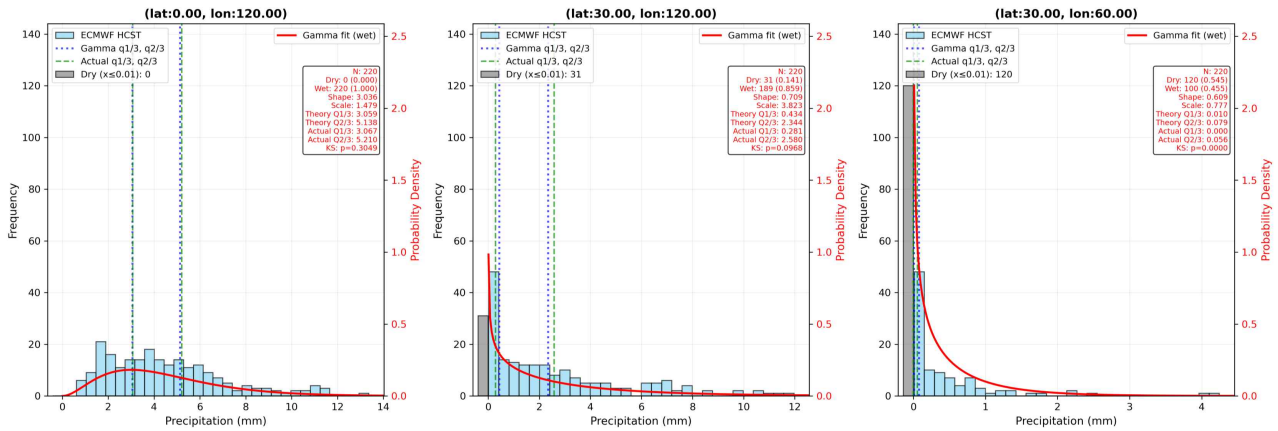


Figure 2.24. Histograms of ECMWF precipitation Week 3 hindcast data with fitted Mixed\_Gamma curves for selected grid points.

순수 모수화 방법인 Mixed\_Gamma 모델은 극심한 건조 시기나 습윤 멤버의 수가 부족할 경우 확률 계산이 불가능하여 예보 정보의 단절을 초래한다. Figure 2.25의 시계열 그래프를 보면, 하단 패널의 Mixed\_Gamma 결과에서 다수의 공백이 발생하는 것을 볼 수 있다. 반면 상단 패널인 Quantile 방법의 경우 건조 시기에도 확률값을 산출하여 정보의 연속성을 유지한다. 다만, Quantile 방법 역시 극히 건조한 시기에는 삼분위 기준값( $q_{1/3}$ ,  $q_{2/3}$ ) 모두 0mm가 되는 경우가 발생한다. 이 경우 건조한 상태가 평년과 같다고 판단할 수 있지만, 이러한 정보는 이 지역에서 유용하지 않을 것이다. 오히려 강수 유무에 대한 확률예측 정보가 더 유용한 정보라고 판단하였다. 따라서 이 연구에서는 극히 건조한 지역 또는 시기에는 평년보다 강수량이 적을 확률( $p_0$ )과 평년보다 강수량이 많을 확률( $1-p_0$ )로 이중화한 예측정보를 생산하도록 설계하였다.

또한, 이 연구에서는 강수량 모수화 방법에서 나타나는 건조지역의 한계를 극복하기 위해 Hybrid\_Gamma 방법을 도입하였다. Figure 2.26의 하단 패널에서 확인할 수 있듯이, Hybrid\_Gamma 방법은 습윤 멤버가 부족하여 모수화가 불가능한 시점에는 자동으로 Quantile 방법으로 전환함으로써, 예측 데이터의 공백 없이 연속적이고 안정적인 확률 정보를 생산해낸다. 이는 모수화 방법론이 갖는 이론적 한계를 시스템적으로 보완하여 현업 적용성을 확보한 핵심 결과라 할 수 있다.

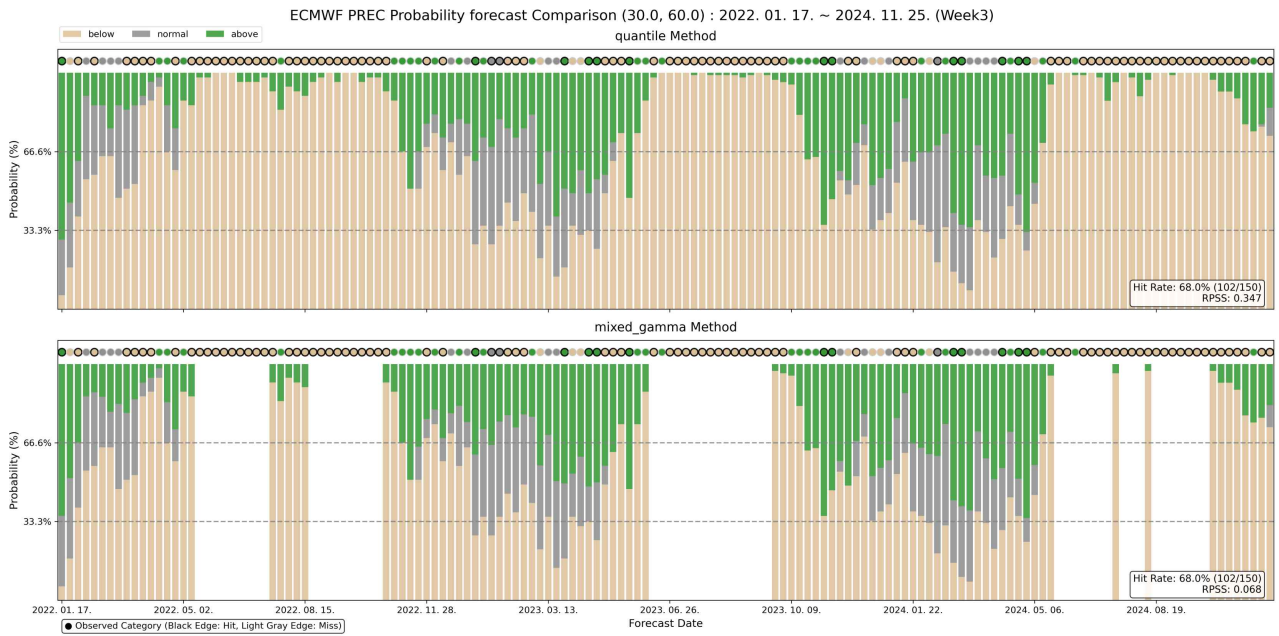


Figure 2.25. Time series comparison of ECMWF precipitation Week 3 probability forecasts at an extreme dry grid point(30°, 60°E). (Top) Quantile method (Bottom) Mixed\_Gamma method.




Figure 2.26. Time series comparison of ECMWF precipitation Week 3 probability forecasts at an extreme dry grid point(30°, 60°E). (Top) Quantile method (Bottom) Hybrid\_Gamma method.

### 2.2.6. 최종 현업 확률예측 방법론 선정

앞선 수행한 정량적 검증(RPSS, ROC), 정성적 검증(공간적 노이즈), 그리고 이론적 적합도 평가(K-S Test) 결과를 종합하여 APCC의 계절내 확률예측 시스템에 적용할 최종 방법론을 선정하였다. 선정 기준은 예측 정확도, 현업 활용성, 극한 사상에 대한 확장성, 그리고 시스템 운영 효율성을 다각도로 고려하였다. Table 2.8은 기온과 강수량 변수에 대해 각 항목의 비모수화 방법과 모수화 방법에 따른 상대적인 값을 비교한 것이다.

Table 2.8. Comprehensive comparison of probabilistic forecast methodologies.

	T2M		PREC	
	Non-parametric (Quantile)	Parametric (Gauss)	Non-parametric (Quantile)	Parametric (Hybrid_Gamma)
Tercile Skill	Low	High	Low	High
Extreme Skill (Extensibility)	Low	High	Low	High
Spatial Noise	High	Low	High	Low
Computation Speed	Fast (8 min)	Fast (3 min)	Fast (8 min)	Slow (16 min)
Final Selection	Parametric (Gauss)		Parametric (Hybrid_Gamma)	

기온 변수에 대해서는 Gauss 방법을 최종 현업 방법론으로 선정하였다. 그 선정 근거는 다음과 같다. 첫 번째로 예측성 및 확장성의 우위를 들 수 있다. RPSS 분석 결과, 가우시안 방법은 전 지구적으로 비모수화 방법 대비 높은 예측 성능을 보였다. 특히 상위 10% 이상의 극한 고온 예측 시, 확률밀도함수를 통한 외삽이 가능하여 극한 기후 감시를 위한 서비스 확장성이 뛰어났다. 두 번째로 공간적 품질을 확보할 수 있다. 적은 앙상블 멤버로 인한 샘플링 노이즈를 획기적으로 줄여, 물리적으로 타당하고 부드러운 예측장을 제공함으로써 예보관의 분석 신뢰도를 높일 수 있다. 세 번째로 운영상의 효율성을 들 수 있다. 수학적 적분 방식을 사용하는 가우시안 방법은 벡터화 연산을 통해 실험조건에서 계산 속도가 약 3분으로, 신속한 현업 정보 생산에 적합하다.

강수량 변수에 대해서는 Hybrid\_Gamma 방법을 최종 선정하였다. 그 선정 근거는 다음과 같다. 첫 번째로 강수량의 분포 특성이 잘 반영 되었으며 그로인한 예측성 향상을 들 수 있다. 강수량 고유의 비대칭적 분포와 0 값의 빈도를 반영할 수 있는 혼합 감마 분포를 적용함으로써, 열대 및 해양 지역에서 비모수화 방법 대비 뚜렷한 스킬 향상을 확인하였다. 두 번째로 안정적이며 공간적 일관성이 유지된 예측정보의 생산할 수 있다. 건조 지역이나 습윤 멤버가 부

속한 사례에서 발생할 수 있는 모수화 실패 문제를 Quantile Fallback 알고리즘으로 보완하여 시스템의 안정성을 확보하였다. 또한, 기온과 마찬가지로 공간적 노이즈를 크게 감소시켜 대규모 순환과 관련된 예측정보의 구역 경계를 명확하게 표현할 수 있다. 세 번째로 계산 시간의 확보를 들 수 있다. 현업화의 가장 큰 문제점은 적시에 예측정보를 생산하는 것을 들 수 있다. Hybrid\_Gamma 방법은 복잡한 알고리즘과 반복적인 피팅 과정을 거친다. 이로 인해 단순 병렬화를 통한 12개 cpu 사용시 150분에 달하는 계산 시간의 소요는 현업화 방법론의 선정에 큰 장애로 작용하였다. 하지만 병렬화(MPI) 최적화를 통해 계산 시간을 20분 이내로 단축하였으며, 이를 통해 현업화 적용이 가능한 수준으로 도달 할 수 있었다. 이러한 결과는 예측 정확도와 공간적 품질의 향상이 계산 비용의 증가를 상쇄할 만큼 충분한 가치가 있다고 판단하였다.

## 2.3. 최적의 MME 참여모델 구성

### 2.3.1. 계절내예측자료 구축

계절내예측 연구 및 운영 시스템 구축을 위해서는 다양한 모델에서 산출되는 예측자료를 통합적으로 확보하고, 서로 다른 해상도·변수·포맷을 가지는 자료를 표준화하는 과정이 필수적이다. APCC는 계절내예측 시스템 개발의 첫 단계로 전 세계 주요 S2S 및 SubC 예측모델, APCC 자체모델까지 포함한 총 19개의 모델의 예측 자료를 수집하여 데이터베이스를 구축하고, 이를 기반으로 기후값 및 예측력 평가를 수행할 수 있는 공통 분석 프레임워크를 마련하였다. 수집된 자료는 기관마다 변수명·격자체계·단위가 다르기 때문에 다양한 모델 정보의 일관된 분석을 위해 격자는  $1.5^{\circ} \times 1.5^{\circ}$  공통격자로 표준화하고, 공통변수 (2m 기온, 강수, 500hPa 지위고도, 해수면온도)에 대해서 분석하였다. 본 연구는 아래 기술한 자료 수집 및 표준화 작업을 통해 전 세계 주요 S2S/SubC/자체모델 자료의 통합 확보, 모든 모델을 동일 체계에서 분석 가능한 표준화 데이터 구축, MME 평가 및 예측력 비교를 위한 공통 프레임워크 구현, 향후 seamless S2S 콘텐츠 개발을 위한 자료 기반을 확립하였다.

#### 2.3.1.1. S2S 프로젝트 모델

세계기상기구(WMO) S2S 프로젝트는 전 세계 11개 예측센터(GPC) 및 2개의 현업센터의 계절내예측 정보를 ECMWF 데이터포털을 통해 제공하고 있다. CPTEC은 2023년 12월부터 예측자료 제공을 시작하여 올해부터 hindcast 분석에 새로 추가된 모델이다. 2024년 연구에서 12개 모델의 hindcast 예측자료를 수집하였으나, 이 중 4개 모델(BOM, NCEP, JMA, MetFR)을 제외하고는 hindcast 실험이 on-the-fly이거나, 모델이 새로 개선되면서 총 13개 모델의 hindcast를 새로 수집하였다 (Table. 2.9).

Table 2.9. Descriptions of S2S Project models.

GPC	Center/ Model	Forecast Frequency	Forecast Time Range	Forecast Ens. Size	Hindcast Frequency	Hindcast Ens. Size	Hindcast PEriod
Beijing	CMAA/ BCC-CPS-S2Sv2	2/week	0-60	4	2/week	4	past 15 years
ECMWF	ECMWF/ CY49R1	Daily	0-46	101	2/week	11	past 20 year
Exeter	UKMO/ GloSea6	Daily	0-60	4	16/month	7	1993-2016
Montreal	ECCC/ GEPS8	Weekly	0-39	21	2/week	4	2001-2020
Seoul	KMA/ GloSea6-GC3.2	2/week	0-60	8	4/month	7	1993-2016
Moscow	HMCR/ RUM55	Weekly	0-46	41	Weekly	11	1991-2015
-	IAP/ CAS-FGOALS-f2	Daily	0-65	49	Daily	4	1999-2018
-	CNR-ISAC/ GLOBO	Weekly	0-35	41	Every 5 days	8	2001-2020
Melbourne	BoM/ POAMA P24	2/week	0-62	33	6/month	33	1981-2013
Washington	NCEP/CPS3	Daily	0-44	16	Daily	4	1999-2015
Tokyo	JMA/CPS3	Daily	0-34	5	2/month	5	1991-2020
Toulouse	MetFR/ CNRM-CM 6.1	Week/y	0-47	25	Every 7 days	10	1993-2017
CPTEC	CPTEC/BAM-1.2	2/week	0-35	11	Every 7 days	11	1999-2018

### 2.3.1.2. SubC 프로젝트 및 APCC 모델

이번 연구에서는 기존의 S2S 프로젝트 모델 뿐만 아니라, SubC 프로젝트 모델의 예측정보를 IRI 데이터포털을 통해서 수집하였다 (Table. 2.10). SubC는 총 7개의 모델이 참여하고 있지만 S2S 프로젝트에 공통으로 참여하고 있는 2개 모델(ECCC, NCEP)을 제외한 5개 모델을 수집하였으며, 이는 APCC 다중모델앙상블 계절내예측 활용성 제고를 위해 수집하였다. SubC는 3-4일 정도의 자료 지연을 가지고 있어서 대부분의 모델이 앰바고가 걸려있는 S2S 모델에 비해 실시간 운영성이 높은 것이 특징이다. 또한, 이번 연구에서 추가된 APCC는 '25년 수행된 과제를 통해 생산된 APCC 자체모델 (SCoPS)의 full-hindcast 예측정보도 활용하였다.

Table 2.10. Descriptions of SubC Project models.

GPC	Center/Model	Forecast Frequency	Forecast Time Range	Forecast Ens. Size	Hindcast Frequency	Hindcast Ens. Size	Hindcast Period
ECCC	GEPS8	Weekly	0-38	21	Weekly	4	2001-2020
NOAA/NCEP	NCEP/CFSv2	Daily	0-44	16	Daily	4	1999-2016
NOAA/EMC	GEFS	Weekly	0-35	4	Weekly	11	2999-2019
NOAA/ESRL	FIMr1p1	Weekly	0-32	4	Weekly	4	1999-2016
US. NRL	NESM	4/week	0-45	1	4/week	1	1999-2016
NCAR/RSMAS	CCSM4	Weekly	0-45	9	Weekly	3	1999-2016
NOAA/GMAO	GEOS_V2p1	Every 5 days	0-45	21	Every 5 days	2	1999-2015
APCC	SCoPS	Weekly	0-60	10	6/month	10	2003-2015

### 2.3.2. 개별모델 및 MME 예측력 평가

#### 2.3.2.1. 기후값 분석

전 세계 총 19개 계절내예측의 표준화된 예측자료를 활용하여 개별모델의 장기 기후값 분석을 수행하였다. 이때 개별모델의 공통기간(2003-2015년, 13년)을 사용하였으며, 기후값 기간이 상이한 2개 모델 CMA(2008-2022, 14년)와 BOM(1994-2003, 17년)은 각각의 기후값을 활용하였다. 본 연구에서는 ‘24년 연구대비 추가된 모델(SubC, APCC)에 대한 상대적인 분석을 중점적으로 분석하였다. 우선, 기온에 대한 개별모델 및 관측의 장기 기후값 차이를 살펴보면 대부분의 모델은 대륙에서 과소모의하는 경향을 보이며, 선행시간이 증가할수록 관측과의 오차는 증가하는 전형적인 특성을 확인할 수 있다 (Figure 2.27). IAP, BOM의 경우 북극지역에서 강한 음의 편차가 나타나며, 또한 저해상도 모델들은 내륙 고산지역 및 아프리카 지역의 강한 양의 편차를 보인다. 새로 추가된 SubC 모델은 전반적으로 S2S 모델과 유사한 정도의 기후값 편차를 보이며, APCC 자체모델의 경우 북미를 제외하고는 대륙에서 강한 음의 편차를 보이며, 이는 선행시간이 길어지면서 유지되는 것으로 확인된다. 강수의 경우 대부분의 모델은 강한 대류 활동으로 강수 변동성이 큰 열대지역에서 관측과의 오차가 크게 나타나며, 아프리카 지역의 강수 과소 모의하는 경향을 보인다 (Figure 2.28). 대기 모델(예, HMCR, ISAC)은 다른 모델에 비해 해양에서 관측과의 오차가 크게 나타난다. SubC 모델들은 기온과 마찬가지로 S2S 모델들과 유사한 기후값 편차를 보이며, APCC 모델은 초기 선행시간에서 열대지역에서 음의 편차가 강하게 나타나며 이는 initial shock으로 보여진다.

SubC 및 APCC 모델의 기후값 상대적 평가를 위해 장기간 평균 및 변동성 오차 분석 또한 수행하였다 (Figure 2.29). 선행시간이 증가할수록 오차는 증가하고, 예측의 변동성은 감소하는 경향이 뚜렷하다. 초기 선행시점의 성능 및 선행시간에 따른 예측력 감소 폭을 종합적으로 고려하면, 전 세계 계절내예측 모델 중 단연 ECMWF가 독보적인 기후값 재현 능력을 보인다. SubC 및 APCC 모델은 S2S 모델의 기후값 평균 및 변동성 오차와 유사한 정도를 보이고 있음을 확인할 수 있었다. 이를 통해, 예측특성이 상이한 19개 개별모델의 안정적인 자료처리 확

인 및 기후 재현성 기반 모델의 특성을 진단하였다. 특히, SubC, APCC 모델은 S2S 모델에 대한 상대적인 기후값 재현능력을 확인하였다.

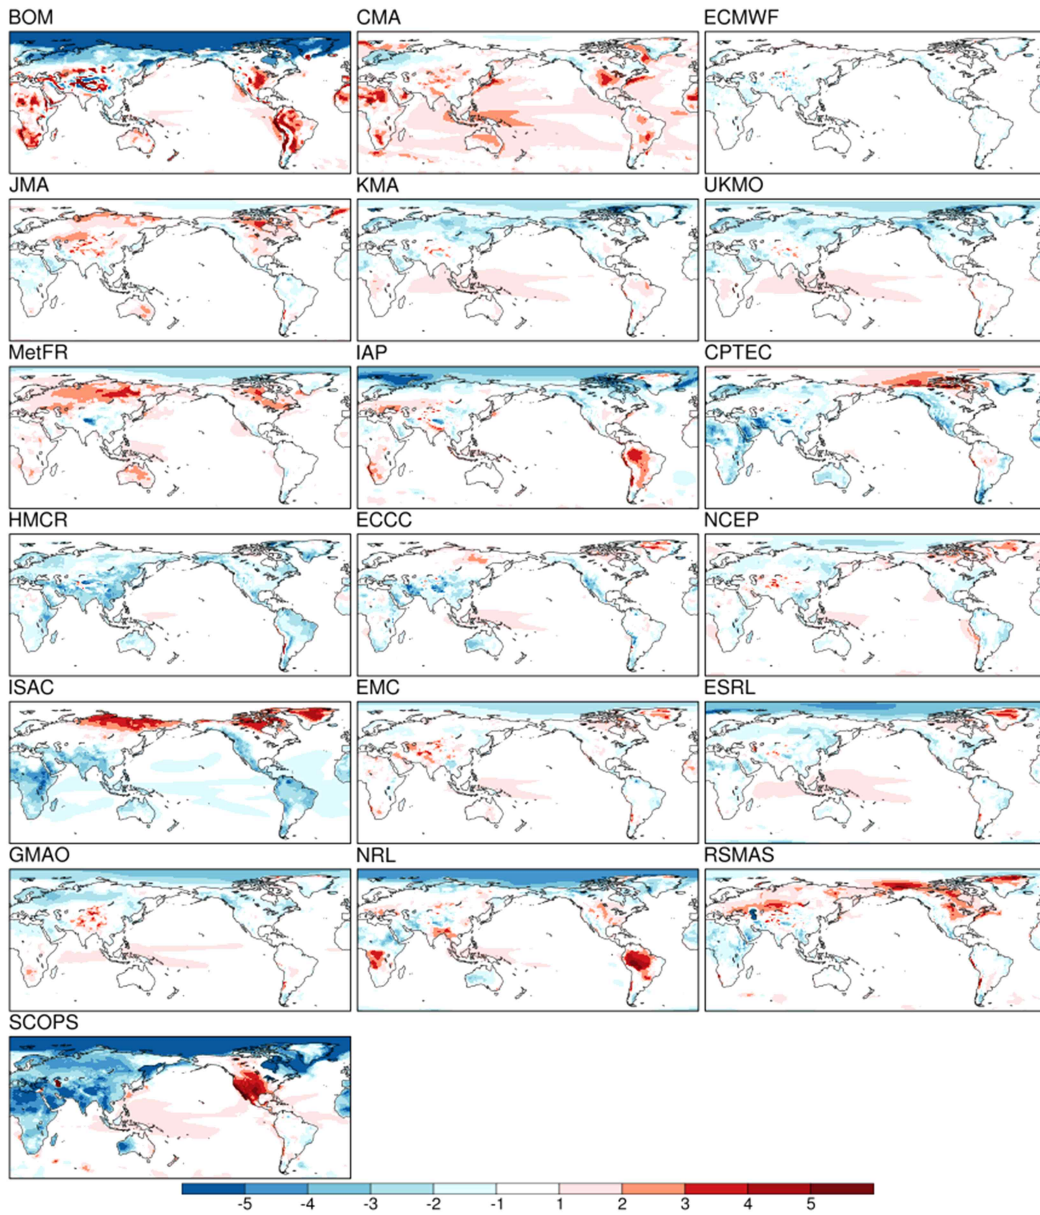


Figure 2.27. Mean bias in climatology for 2m temperature at four weeks for 19 models.

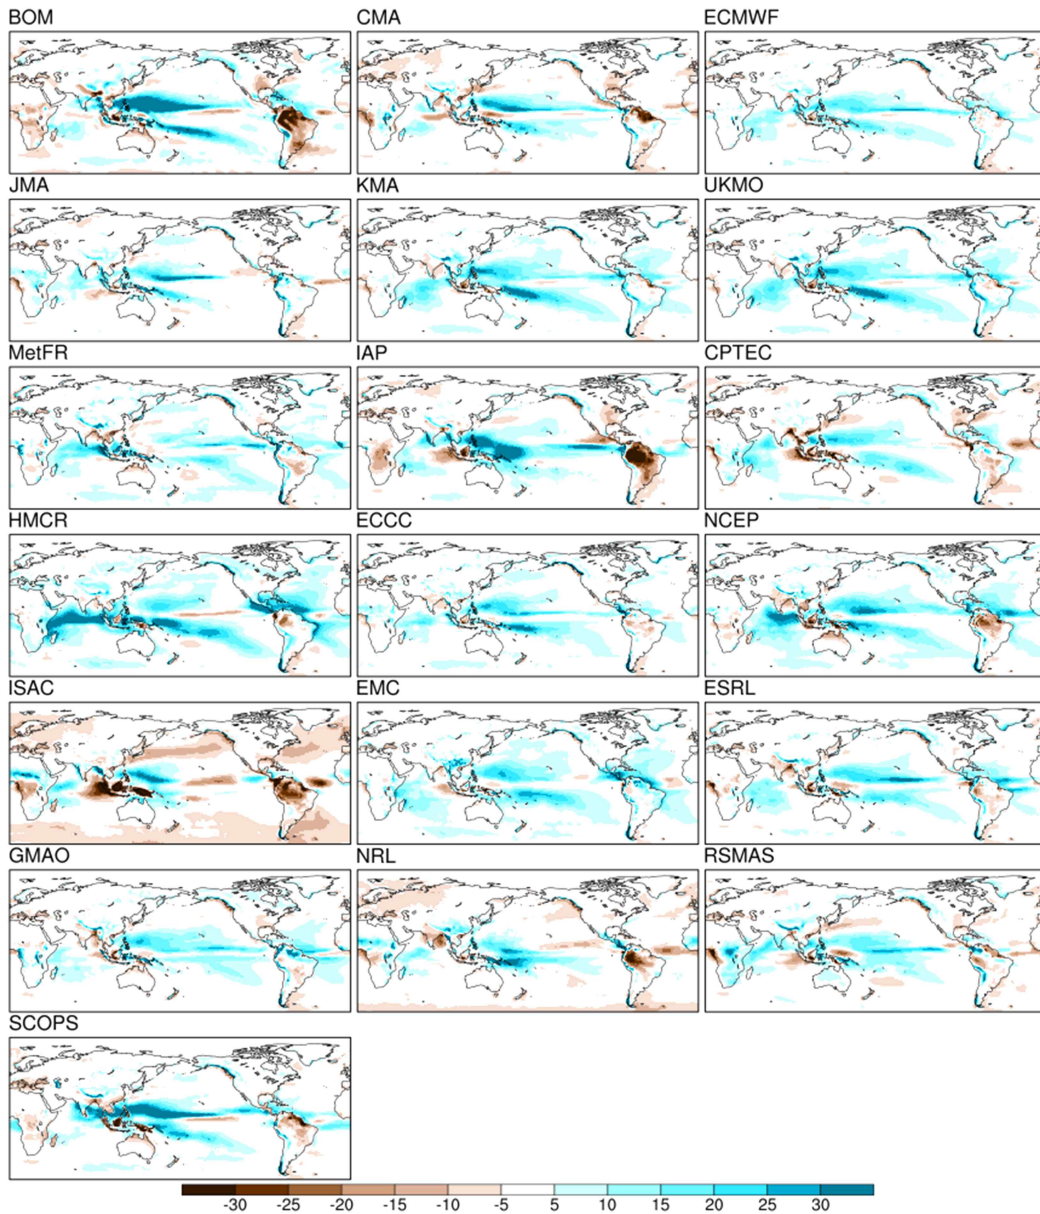


Figure 2.28. Mean bias in climatology for precipitation at four weeks for 19 models.

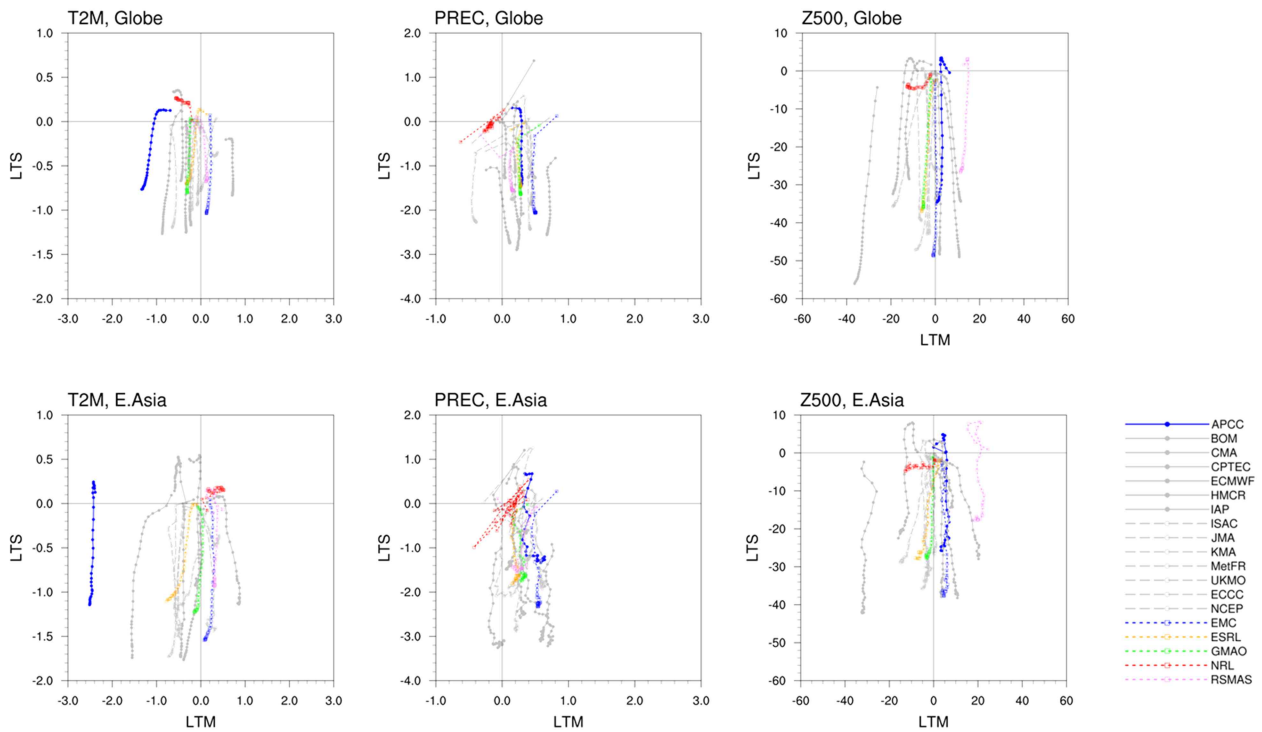


Figure 2.29. Temporal evolution of biases in long-term mean (LTM) and standard-deviation (LTS) of temperature, precipitation, and geopotential height over globe and East Asia increasing lead days from 1 to 32 for 19 models. Bias is defined as a mean value of differences relative to the observed LTM and LTS during all year around.

### 2.3.2.2. 계절내예측 개별모델 및 MME 예측력 평가

개별모델 및 MME의 주별 예측력 평가를 위해, 공통기간을 가지는 17개 모델을 사용하였다(CMA, BOM 제외). 이때, 예측일이 상이한 17개 모델을 활용한 MME 생산을 위해 모든 예측일을 월요일 기준으로 월~일요일 평균을 1주로 정의하였다. 또한 기후값은 MME 예측일(월요일)을 기준으로 가장 가까운 reforecast 자료를 활용하였으며, 17개 모델의 단순 평균으로 구성하였다 (Figure 2.30). MME 예측일 및 기후값 정의 방법은 '24년 다양한 민감도 실험 결과로 선정되었다.

Figure 2.31-2.32 는 3-4주 평균 기온 및 강수의 개별모델 및 MME의 경년변동에 대한 상관도 분포이다. 기온의 경우, ECMWF는 0.46까지 예측력을 유지하며 개별 모델 중에서 가장 높은 예측력을 보이고 있으며, 강수의 경우 3-4주가 되면 유의한 예측력은 중태평양 지역에서 남아있는 반면 ECMWF와 MME는 대부분의 열대지역까지 확장된 예측력을 보이면서 높은 예측력을 나타낸다. 개별모델 및 MME의 1-8주 및 3-4주/1-4주 평균 예측력을 살펴보면 (Figure 2.33), 모든 변수 및 선행시간에서 개별모델에 비해 MME의 높은 예측력을 확인 할 수 있다. 이러한 MME 예측력의 우수성은 3-4주 및 1-4주 평균장에서도 나타난다. SubC 및 APCC 모델의 예측력을 좀 더 살펴보기 위해, S2S/SubC 프로젝트 모델들의 예측력 범주를 APCC와 함께 나타

내었다 (Figure 2.34). S2S 프로젝트는 모델수가 상대적으로 많기 때문에 선행시간 초기에는 예측성 변동폭이 크게 나타나지만 3~4주로 갈수록 SubC 모델에 비해 상대적으로 예측력이 높은 것으로 나타나며, 3-4주/1-4주 평균에서도 동일한 결과를 보인다. APCC는 1~4주 전반에 걸쳐서 두 프로젝트 모델들의 예측성 범주에 속하고 있으며, 1~4주 누적 예측력을 살펴보면 (Figure 2.35) 전구 기온 및 강수에 대해서 중/하위 그룹에 포함되는 것을 확인하였다. 여기서 특이할 점은 작년 8개 모델을 활용한 MME (MME@v2024)의 경우 1주는 ECMWF와 유사한 예측력을 보였는데 반해, 17개 모델을 활용한 MME의 경우 1주부터 ECMWF에 비해 높은 예측력을 보이고 있다. 이는 작년 대비 일부 모델이 개선되었고, 또한 참여모델 수가 8개에서 17개로 확대되면서 나타나는 결과로 참여모델의 개선 및 확대에 따른 MME 예측력 향상을 확인 할 수 있다.

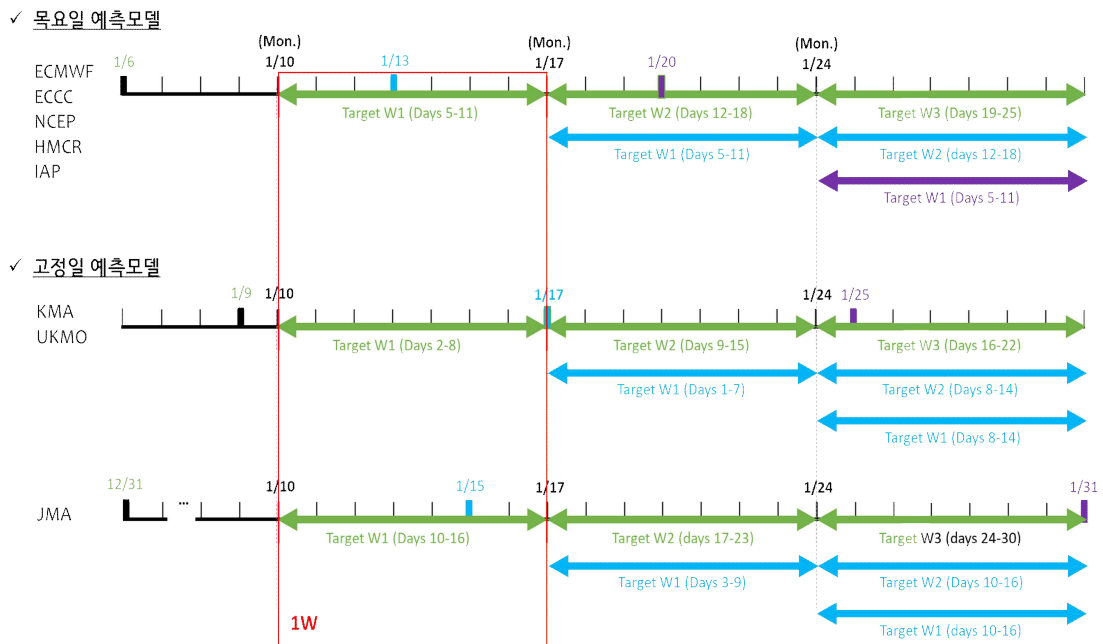


Figure 2.30. Schematic illustrating the harmonization of weekly forecast periods across individual models with differing initialization days.

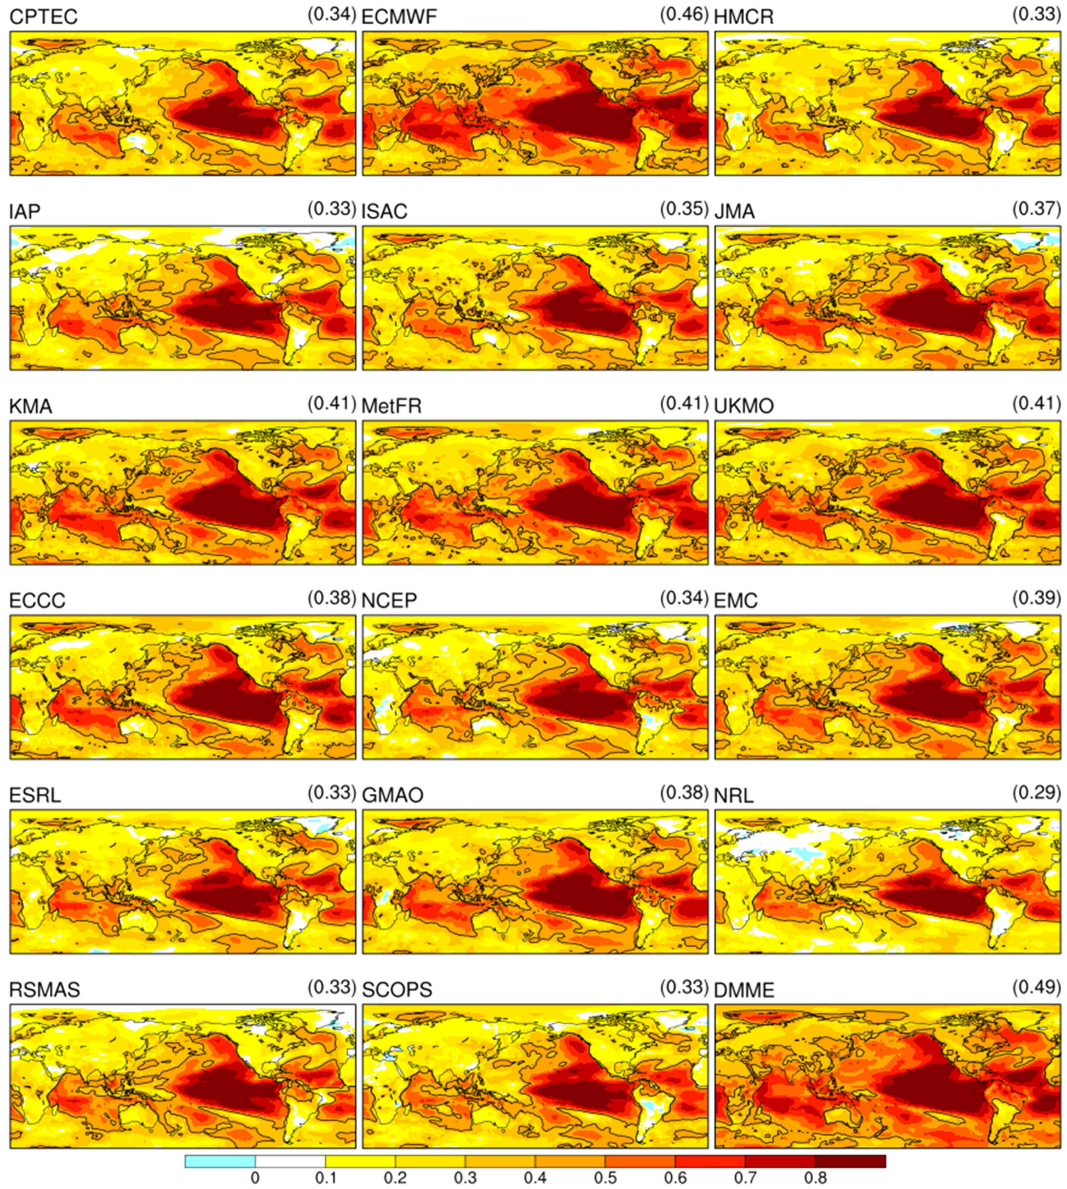


Figure 2.31. Spatial distribution of temporal correlation coefficients for 2m temperature of individual models and DMME at 3-4 week means.

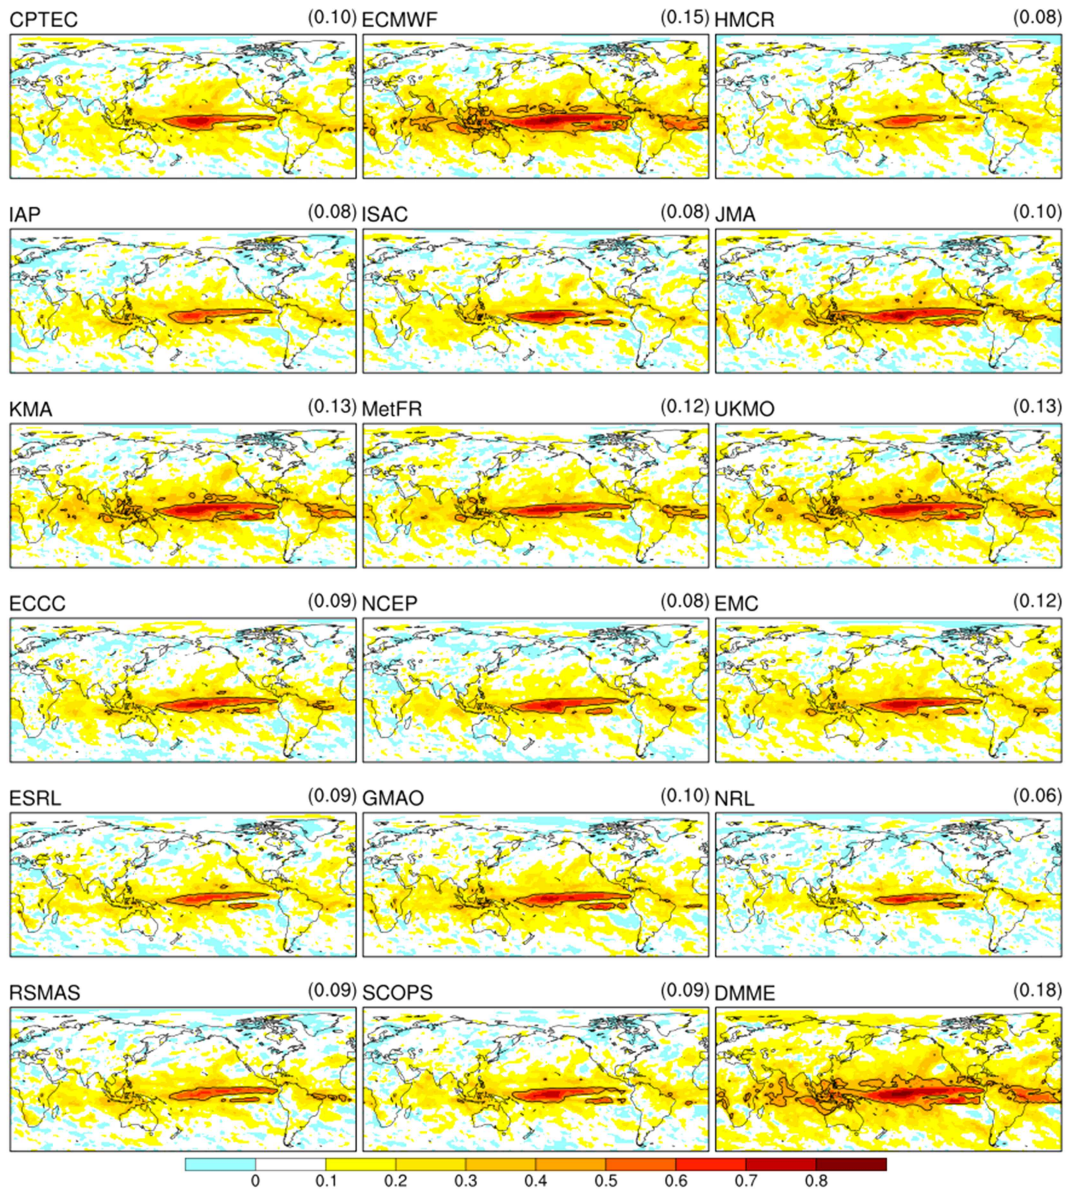


Figure 2.32. Spatial distribution of temporal correlation coefficients for precipitation of individual models and DMME at 3-4 week means.

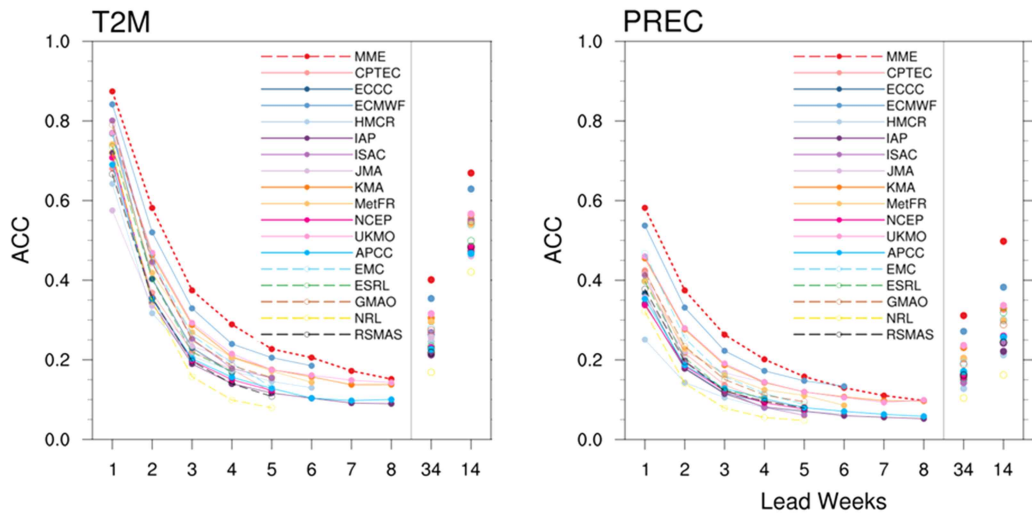


Figure 2.33. Anomaly pattern correlation coefficient for temperature and precipitation of individual models and MME at 1-8 weeks, 3-4 and 1-4 week means.

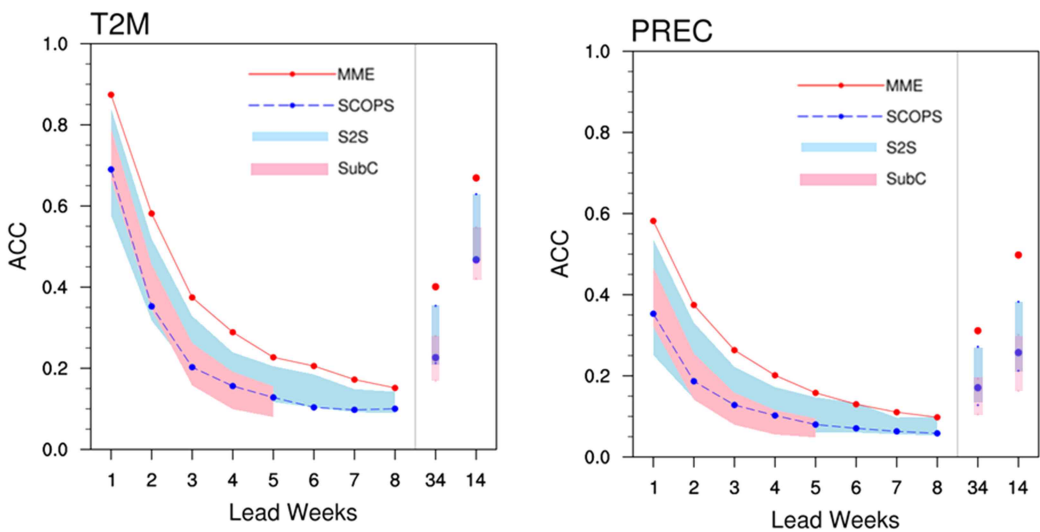


Figure 2.34. Anomaly pattern correlation coefficient for temperature and precipitation of S2S and Sub project models and APCC at 1-8 weeks, 3-4 and 1-4 week means.




Figure 2.35. Accumulated Anomaly pattern correlation coefficient for temperature and precipitation of individual models, MME, and MME@v2024 at 1-8 weeks, 3-4 and 1-4 week means.

### 2.3.2.3. APCC 모델 참여에 따른 MME 예측력 기여도 분석

APCC 모델의 예측력은 S2S/SubC 프로젝트에 참여하는 모델의 예측 범주에 속하고 있으며, 개별모델의 예측력의 중/하위 그룹에 포함하고 있음을 앞서 확인하였으며, 본 장에서는 APCC 모델 참여가 실질적으로 MME 예측력에 어떠한 영향을 미치는지 분석하기 위해, APCC 참여여부에 따른 MME 예측력 차이를 살펴보았다. Figure 2.36은 APCC 모델을 참여했을 경우 (총 17개 모델)와 하지 않았을 경우의 MME (총 16개 모델) 예측력 차이를 기온 및 강수에 대해서 1, 2, 3, 4주, 3-4주 및 1-4주 평균으로 살펴보았다. 예측력 차이의 공간분포를 살펴보면, 기온의 경우 MME 예측력의 차이가 유의하지 않은 반면, 강수의 경우 전반적으로 MME 예측력 향상에 긍정적인 기여를 하는 것으로 보인다. 이러한 결과는 모든 선행시간, 지역적으로 변동성이 있긴 하지만 전반적으로 동일한 결과를 보이고 있다 (Figure 2.37). 특히, 남아시아 및 호주 지역의 강수 예측력을 살펴보면 3주부터 상대적으로 moderate 예측력을 유지하면서 (Figure 2.38) 이는 추후 BSISO 참여모델 확대에도 기여할 수 있을 것으로 판단된다. 결과적으로 APCC는 S2S, SubC 프로젝트 참여모델의 평균 예측력보다 다소 낮거나 유사한 정도의 예측력을 보이며, APCC가 참여할 경우 MME 예측력 향상에 긍정적으로 기여함으로써 이는 APCC 계절내예측 MME 참여모델로써 활용 가능성을 다시 한번 더 확인 할 수 있다. 이러한 연구 결과를 바탕으로, APCC는 매주 실시간 예측자료를 생산하고 있으며, 계절내예측 MME 시범운영에 참여하고 있다.

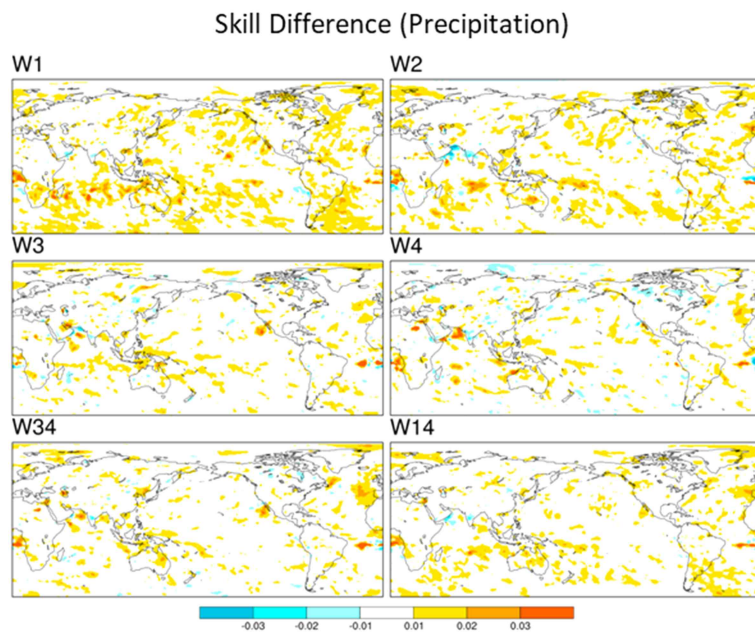
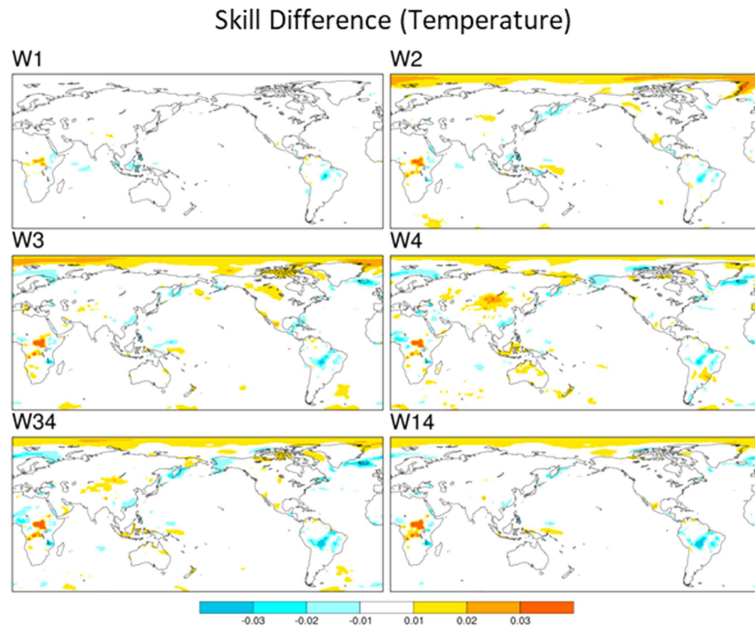


Figure 2.36. Spatial distribution of prediction skill difference between the MME including APCC and the MME excluding APCC. Positive values indicate regions where the inclusion of APCC enhances forecast skill, while negative values denote regions where their inclusion results in reduced skill.

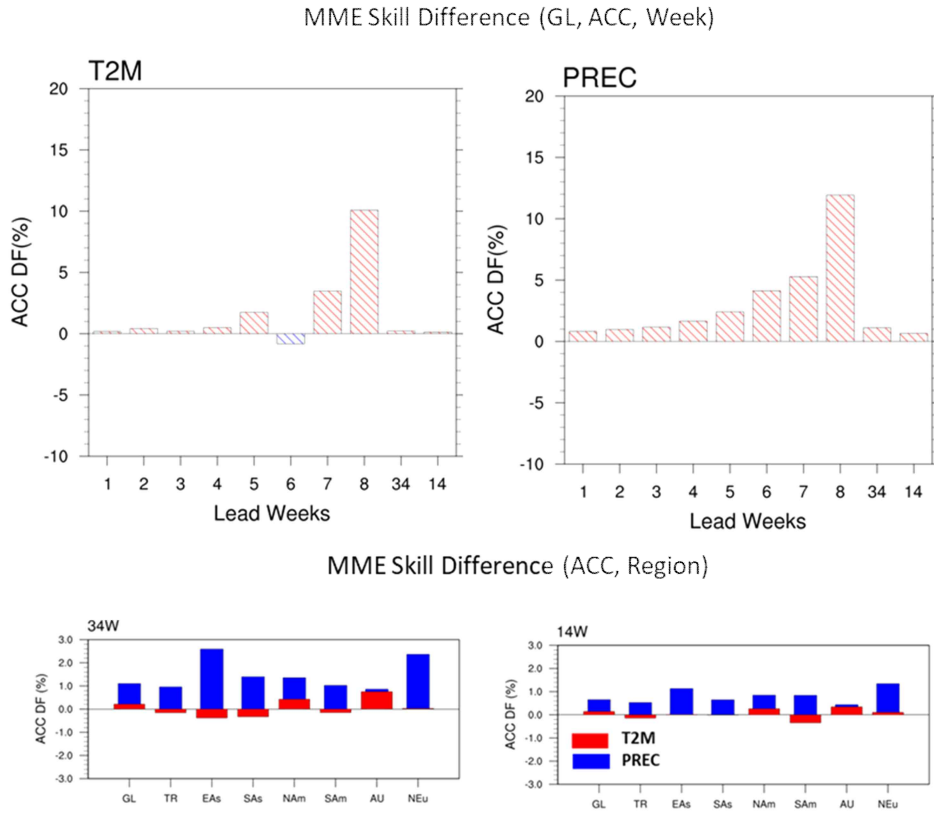


Figure 2.37. MME skill difference in terms of anomaly pattern correlation coefficient over globe between the MME including APCC and the MME excluding APCC at each week and 3-4 & 1-4 week means. MME skill difference in terms of APCC at 3-4week means for each region.

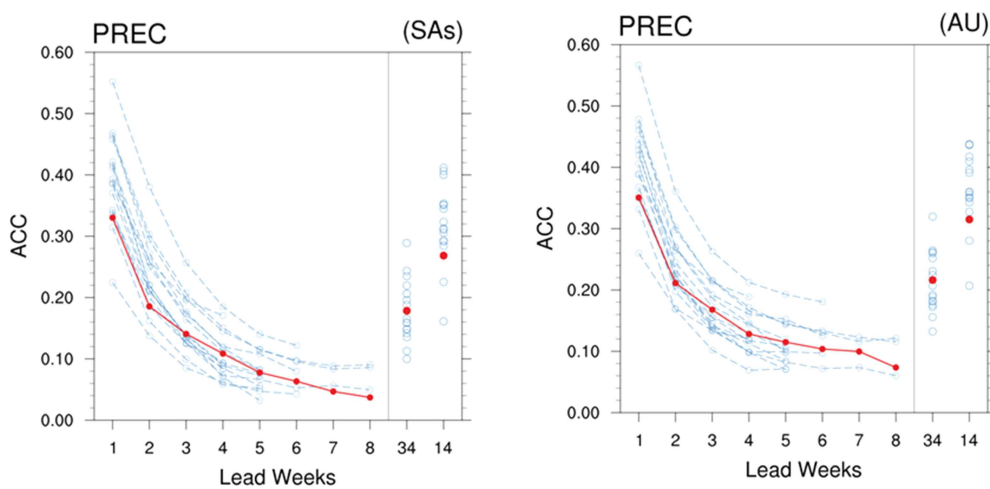


Figure 2.38. Anomaly pattern correlation coefficient over South Asia and Australia for temperature and precipitation of individual models (blue line) and APCC (red line) at 1-8 weeks, 3-4 and 1-4 week means.

#### 2.3.2.4. SubC 모델 참여에 따른 MME 예측력 기여도 분석

SubC 프로젝트 모델의 예측력은 기존의 S2S 프로젝트에 참여하는 모델의 예측 범주에 속하고 있으며, 상대적으로 중위권 정도의 예측력을 보이고 있음을 앞서 확인하였으며, 본 장에서는 SubC 모델 참여에 따른 MME 예측력 기여도를 분석하고자 한다. Figure 2.39는 SubC 모델을 참여했을 경우와 하지 않았을 경우의 MME 예측력 차이를 기온 및 강수에 대해서 1, 2, 3, 4주, 3-4주 및 1-4주 평균으로 살펴보았다. 참여모델 수의 차이로 인해 앞선 APCC 참여여부에 따른 예측력 차이는 크게 나타나며, 기온 및 강수 대부분의 지역에서 MME 예측력이 높아지는 것을 확인 할 수 있다. 특히, signal이 강해 예측력이 높은 열대지역보다 예측력이 noise가 강한 고위도 대륙지역에서 예측력 향상이 크게 나타난다는 점이 상당히 의미있는 결과라 할 수 있다. 그 결과, SubC 모델을 추가한 경우 MME 예측성은 약 ~5%, MME 효율성은 5~20% 정도 향상되며, 이는 개별모델의 평균 예측력 향상보다는 SubC 모델을 참여함으로써 참여모델 수 확대 및 다양화에서 기인한 MME 효과인 것으로 보인다 (Figure 2.40).

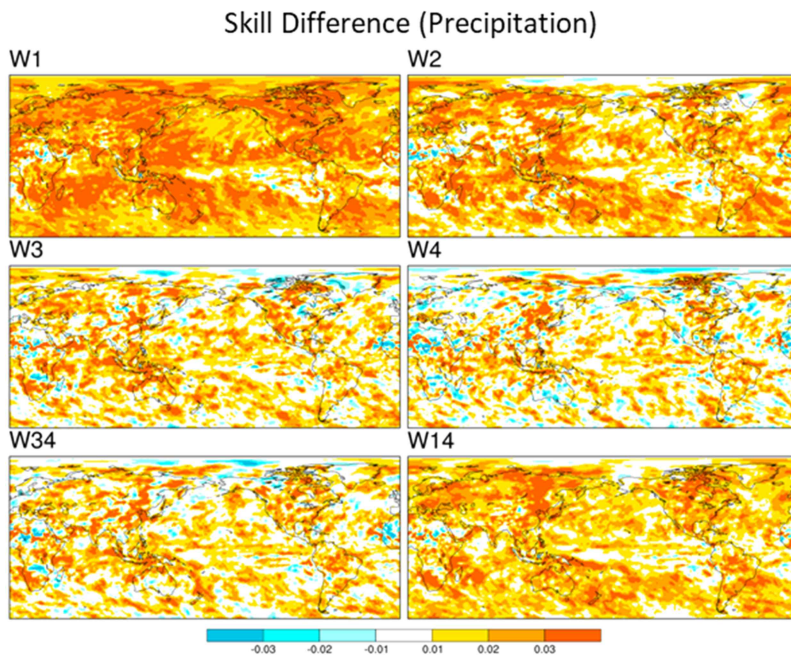
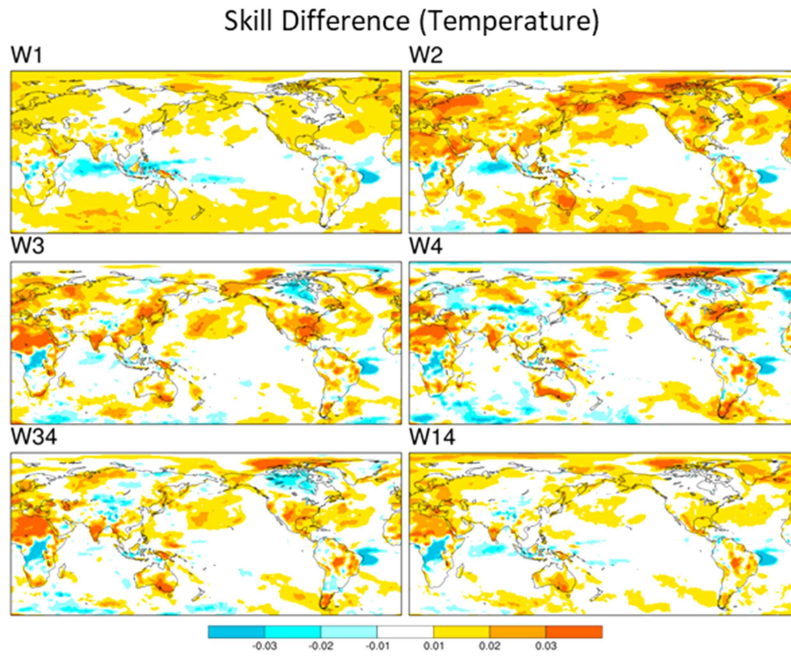


Figure 2.39. Spatial distribution of prediction skill difference between the MME including SubC models and the MME excluding SubC models. Positive values indicate regions where the inclusion of Sub models enhances forecast skill, while negative values denote regions where their inclusion results in reduced skill.

### MME Skill & Efficiency (%)

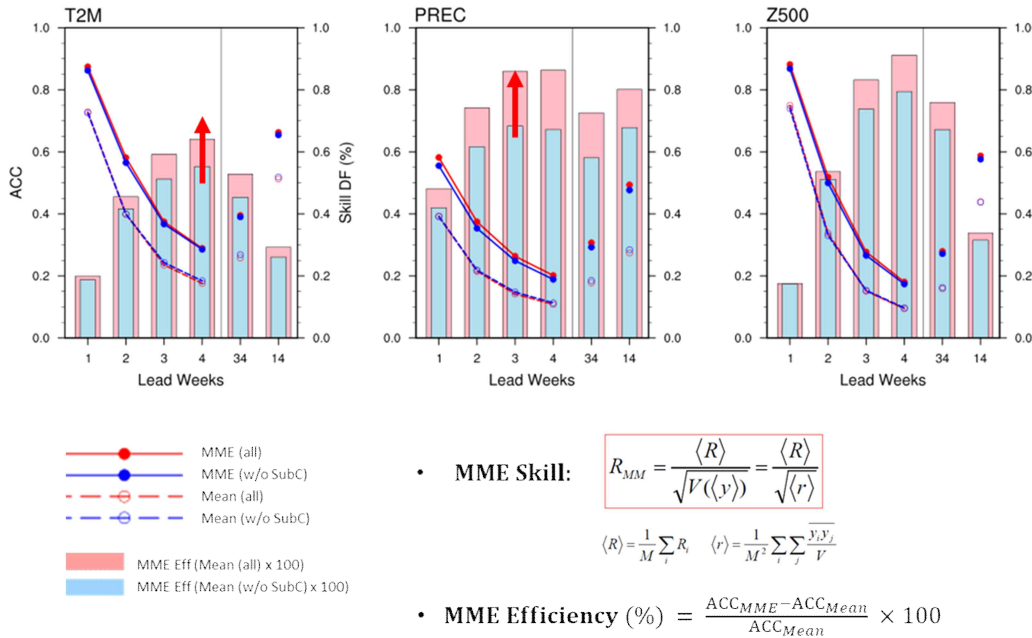


Figure 2.40. Anomaly pattern correlation coefficients between the MMEs including and excluding SubC models, and mean skill of participating models in MMEs including and excluding SubC models. MME efficiency for each variable and lead time is displayed with histograms.

### 2.3.3. 계절내예측 자료방안 마련

지금까지 분석한 총 17개 모델을 활용한 MME의 경우 전세계적으로 수집 가능한 모든 모델의 hindcast 자료를 활용했으며, 사실상 현업으로 이 모든 모델의 예측정보를 실시간으로 활용 가능하냐는 또 다른 문제이다. ‘24년 연구결과에 따르면 적어도 모델 7~8개가 되면 계절내 전구 기온 및 강수에 있어서 MME 예측력이 수렴 될 것으로 보였는데 (Figure 2.41), 이는 현재 APCC 자료제공기관 및 APCC 모델 수 (5개)로는 예측력을 기대하기 어려운 상황이며, 그렇다면 APCC의 현실적인 예측력은 어느 정도이며 경쟁력은 있는가라는 질문에 해답을 찾기 위해 다양한 조합에 따른 MME 예측력 비교평가를 수행하였다.

Table 2.11은 민감도 실험을 위한 다양한 조합에 따른 MME 구성을 나타낸다. 즉, 총 17개 모델을 활용한 이론적 MME, 현재 ECMWF에서 운영중인 WMOLC SPPMME의 모델 구성의 MME\_S2S, NOAA/CPC 3-4주 예보에 활용되는 MME\_SubC, APCC가 매월 기상청에 제공하고 있는 MME\_KMA, 그리고 현재 APCC 참여모델 기관으로부터 계절내예측자료 수집 중인 5개 모델을 활용한 MME\_APCC, 여기에 SubC 모델을 활용한 MME\_APCC\_SubC 이렇게 총 6개의 모델 구성으로 이루어진 MME 예측력을 비교하였다. 그 결과, 당연히 참여모델 수가 가장 많은 MME가 모든 변수, 선행시간에서 가장 높은 예측력을 보이고 있으며, MME\_APCC는 MME\_SubC, MME\_KMA와 함께 하위 그룹에 포함되는 결과를 보인다 (Figure 2.42). 이에 반해, SubC 모델을 활용했을 경우 전구 평균 기온 및 지위고도는 MME\_APCC에 비해 약 10%, 강수

는 약 20% 정도의 예측력 향상을 보이며, MME\_S2S와 유사한 예측력을 확인 할 수 있다. 이러한 결과를 좀 더 지역적으로 살펴보면, 기온의 경우 APCC 자료제공기관 모델과 함께 SubC 모델을 활용한 경우 MME\_S2S와 유사한 정도의 예측력이 향상되며, 강수의 경우 심지어 동아시아를 포함한 일부 지역에서는 17개 모델을 활용한 MME보다 높은 예측력을 보이며 나머지 MME에 비해 상당히 높은 예측력을 보이는 결과를 보인다 (Figure 2.43). 정리하자면 SubC 모델을 활용했을 경우, APCC 참여모델만 활용했을 경우에 비해 1-4주 평균 기온 및 강수 모두 지역에서 높은 예측력을 보이며, 특히 강수의 경우 ECMWF에서 운영중인 S2S 보다 적도지역을 제외하고는 모든 지역에서 높은 예측력을 보이는 고무적인 결과를 확인하였다 (Figure 2.44). 또한 현재 APCC가 매주 기상청에 제공해주고 있는 MME\_KMA 대비 3-4주 평균 예측에 대해서 대부분의 지역에서 높은 예측력을 확인함으로써 APCC MME 계절내예측 현업운영의 당위성을 설명할 수 있을 것이다. 이를 통해, APCC MME 계절내예측의 안정적인 예측력을 위해서는 APCC MME 자료제공기관의 지속적인 자료제공 독려 뿐만 아니라 SubC 자료 활용을 최우선적으로 고려해야 함을 의미한다. 이러한 연구결과를 바탕으로 IRI 데이터포털에서 3~4일 지연으로 실시간 예측정보를 수집할 수 있는 Subc 모델을 APCC MME 계절내예측 시스템에 구축하여 매주 예측자료를 수집, MME에 활용하게 되었다. 본 연구를 통해 예측성과 운영 가능성을 고려한 APCC에 가장 적합한 (현실적인) MME 모델 조합을 제시하였고, MME 계절내예측 현업운영체계 예측력 기반 국제 수준의 경쟁력 확보에 대한 근거를 마련하였다.




Figure 2.41. Anomaly pattern correlation coefficient for MME summer prediction of global temperature and precipitation with different number of participating models based on Monte-Carlo simulation.

Table 2.11. Experimental design for sensitivity tests evaluating MME forecast skill across different model combinations.

Type	No. models	Models	Note
MME	17	S2S + SubC+ SCOPS	Theoretical MME configuration
MME_S2S	9	CPTEC, ECMWF, ECCC, HMCR, JMA, KMA, MetFR, NCEP, UKMO, (BCC)	WMOLC SSPMME model configuration operated by ECMWF
MME_SubC	6	ECCC, NCEP, EMC, ESRL, GMAO, RSMAS	Model configuration used for NOAA/CPC week 3-4 outlooks
MME_KMA	5	ECMWF, ECCC, UKMO, KMA, NCEP	Model configuration participating in APCC's weekly subseasonal forecasts provided to KMA
MME_APCC	5	ECMWF, ECCC, NCEP, HMCR, SCOPS	Model configuration currently collected by APCC
MME_APCC_SubC	9	MME_APCC + SubC(EMC, ESRL, GMAO, RSMAS)	Model configuration with SubC models included in MME_APCC


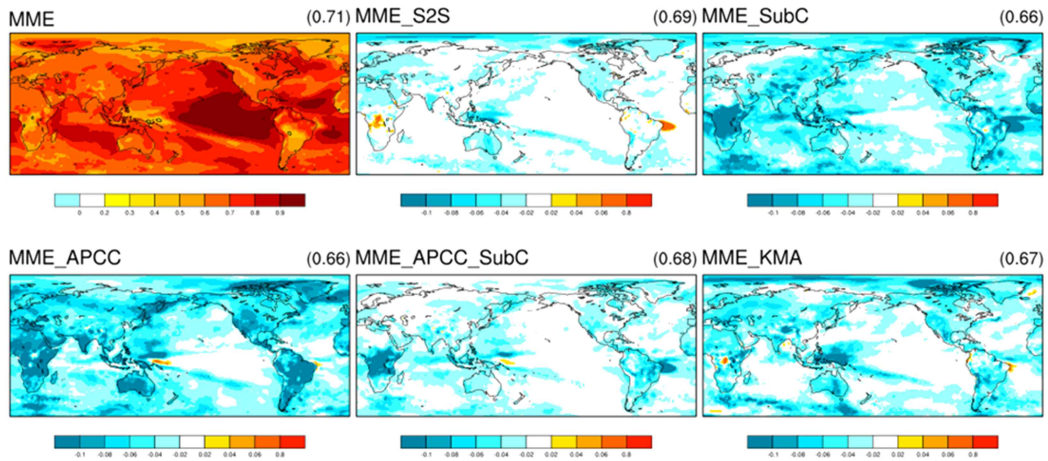


Figure 2.42. Anomaly pattern correlation coefficient for MMEs over globe at each week and 3-4/1-4 week means. Skill difference relative to MME is displayed with histograms (%).

### MME Skill & Difference (T2M, TCC, W14, Relative to MME)



### MME Skill & Difference (PREC, TCC, W14, Relative to MME)

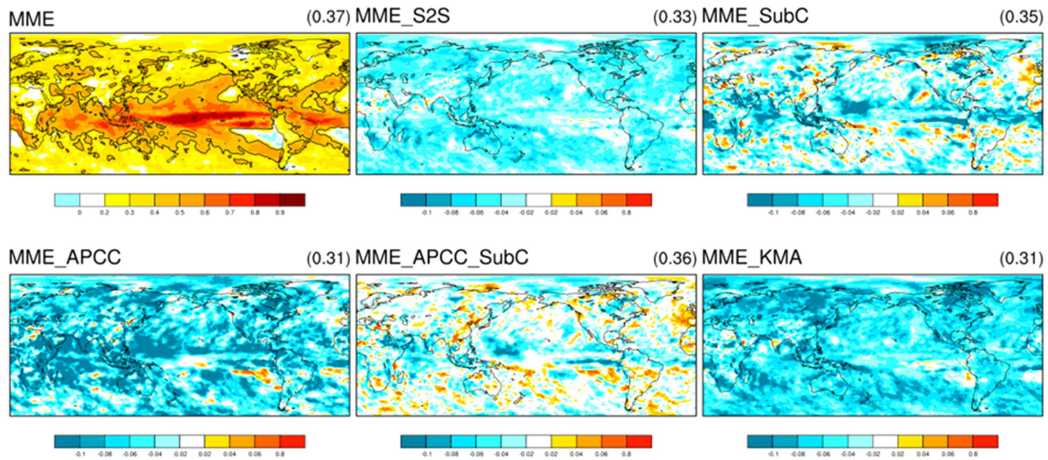



Figure 2.43. Spatial distribution of prediction skill in MME and skill difference between the various MMEs and MME at 1-4 week mean.

MME Skill Difference of MME\_APCC\_SubC (14W, ACC, %)



MME Skill Difference of MME\_APCC\_SubC (34W, ACC, %)




Figure 2.44. MME skill difference of MME\_APCC\_SubC relative to MME\_APCC, MME\_S2S, and MME\_KMA.

## 2.4. 계절내예측 시스템 구축

### 2.4.1. 다중모델앙상블 계절내예측 개별모델 자료 수집

APCC는 계절내예측 정보 생산체계를 구축하기 위하여 수년 전부터 APCC MME 모델제공기관과의 자료 제공 협력 및 논의를 진행해 왔다. 다음의 내용은 현재까지 자료 제공 관련 주요 추진 현황을 나타낸다.

- 제5차 APCC MME 모델제공기관 회의(2023년 8월 29~31일, 부산) : 계절내예측자료 자료 제공 협의
  - 자료 제공 동의 : BOM, HMC, ECCC, NCEP
  - 자료 생산 후 추후 제공 : APCC, CMCC
  - 내부 논의 필요 : KMA, JMA
  - 수집 가능 : ECMWF
- 계절내예측 자료 공식 요청을 위한 Data Requirement, Model Description 요청서 발송 (2024년 1월)
- 2024년 아태 기후정보서비스 및 연구개발 사업 : 개별모델 자료 수집 및 Pilot 시스템 개선
  - HMC, NCEP forecast/hindcast 자료 수집
  - APCC hindcast 자료 생산
- 제6차 APCC MME 모델제공기관 회의(2025년 8월 5~6일, 부산) : MME 계절내예측 시스템 진행 상황 및 향후 계획 공유
- 2025년 아태 기후정보서비스 및 연구개발 사업 : 개별모델 자료 추가 수집 및 Pilot 시스템 개선
  - APCC forecast 자료 생산(앙상블 10개)
  - BOM, ECMWF, ECCC, HMC, NCEP forecast/hindcast 자료 수집
  - SubC 모델(EMC, ESRL, GMAO, RSMAS) forecast/hindcast 자료 수집
  - 개별모델 전처리 시스템 개선 및 전처리 자료 생산
  - Hybrid Gamma (Mixed Gamma + Quantile) 확률예측 기법 적용

현재까지 수집되고 있는 모델은 APCC 자체모델인 SCoPS를 포함해 BOM ACEESS-S2, ECCC GEPS8, ECMWF CY49R1, EMC GEFSv12-CPC, ESRL FIMr1p1, HMC SL-AV, GMAO GEOS-V2p1, NCEP CFSv2, RSMAS CCSM4로 총 10개 모델이다. 여기서 NCEP과 HMC는 2024년부터 자료 수집이 되어왔고, 2025년에 나머지 8개 모델의 자료가 수집되었다.

Figure 2.45는 10개 개별모델의 forecast와 hindcast에 대한 자료 생산주기, 예측기간, 앙상블 수 등을 나타낸다. 노란색 테이블의 APCC forecast/hindcast는 자체생산이고, 녹색 테이블의 BOM forecast/hindcast, HMC forecast/hincast, NCEP forecast는 FTP를 통해 자료를 수집 중이다. 파란색 테이블의 ECMWF forecast/hindcast, NCEP hindcast, ECCC hindcast는 ECMWF Data Portal로부터 ecmwfapi를 이용해 자료를 다운로드하게 된다. 나머지 빨간색 테이블의 ECCC forecast, EMC forecast/hindcast, ESRL forecast/hindcast, GMAO forecast/hindcast, RSMAS

forecast/hindcast는 IRI Data Libray로부터 ncl을 이용하여 다운로드하고 있다.

※ 2025. 11. 1

Center	Model Name	Forecast Frequency	Forecast Time Range	Forecast Ensemble Size	Hindcast Frequency	Hindcast Period	Hindcast Ensemble Size	Data Collecting by
APCC	SCoPS	Weekly (Tuesday)	0-59	10	6/month (1,5,10,15,20,25) fixed	2003-2016	5	In-House
BOM	ACCESS-S2	Weekly (Thursday)	0-42	33	5-daily (from the 1 <sup>st</sup> day of every month) (1,6,11,16,21,26,31) Fixed	1981-2018	3	FTP, HTTP (get)
ECMWF	CY49R1	Weekly (Thursday)	0-46	101	16/month (1,3,5,7,9,11,13,15,17,19,21,23,25,27,29,31 excluding 29 February) on the fly	past 20 years (2005-2024)	11	ECMWF Data Portal (get: API)
HMC	SL-AV	Weekly (Thursday)	0-46	41	Weekly (Thursday) on the fly	1991-2020	11	FTP (put)
NCEP	CFSv2	Weekly (Wednesday, Thursday)	0-44	16 + 16 (32)	Daily fixed	1999-2016	4	FTP (get)
ECCC	GEPS8	Weekly (Thursday)	0-38	21	Week (Thursday) on the fly	2001-2020	4	
EMC	GEFSv12-CPC	Weekly (Thursday)	1-34 (Hindcast: 0-34)	31	Weekly (Wednesday) fixed	1989-2018 (19890104-20190828)	11	
ESRL	FIMr1p1	Weekly (Wednesday)	0-31	4	Weekly (Wednesday) fixed	1999-2016 (19990106-20170628)	4	
GMAO	GEOS-V2p1	5 Daily (from the 1 <sup>st</sup> day of every year)	0-44	4	5-daily (from the 1 <sup>st</sup> day of every year) (1,6,11,16,21,26,...) Fixed	1999-2016 (19990101-20161227)	4	
RSMAS	CCSM4	Weekly (Sunday)	0-44	9	(total 2042 common dates) Fixed	1999-2016 (19990107-20161231)	3	IRI Data Library (get: NCL)

※ Collecting Variables (14) : t2m, sst, maxt2m, mint2m, prec, olr, mslp, t850, u200, u850, v200, v850, z200, z500 → Each model dataset has different variables.

Figure 2.45. List of individual models participating in MME subseasonal forecast.

자체생산 중인 APCC를 제외하고는 모든 자료는 APCC FTP 서버로 업로드되거나 crontab을 이용하여 자동으로 수집되고 있다. 다음 2가지 예시는 ECMWF Data Portal로부터 ecmwfapi를 이용하여 forecast 자료를 다운로드 하는 방법과 IRI Data Libray로부터 ncl을 이용하여 forecast 자료를 다운로드 하는 방법의 일부를 나타낸다.

### ECMWF forecast (ECMWF Data Portal)

#### ■ 자동실행 셸 및 Python 파일

```
ECMWF_FORE.sh
ECMWF_FORE.py
```

#### ■ 자동실행 : ECMWF\_FORE.sh를 crontab에 등록하여 실행

```
#!/bin/bash --login

python /data02/songbg/ECMWF/ECMWF_FORE.py
```

#### ■ 수동실행 : ECMWF\_FORE.py의 today 수정 후 실행

```

#!/usr/bin/env python

import dateutil.relativedelta as rdelta
import datetime

import os
from ecmwfapi import ECMWFDataServer

#=====
# today date: ex) YYYY-MM-DD
today = datetime.date.today()

#today = datetime.date(2025, 11, 24) # for manual

# last THURSDAY: ex) YYYY-MM-DD
last_thursday = today + rdelta.relativedelta(days=-1, weekday=rdelta.TH(-1))

# Real-time forecast date
-----

fdate = str(last_thursday) # ex) today: 2025-02-24 --> fdate: "2025-02-20"

print(" ")
print("=====")
print(" Preprocessing : ECMWF Forecast", )
print("=====")
print("-----")
print(" Initial Date:", fdate)
print("-----")
print(" ")

#-----

```

## ECCC forecast (IRI Data Library)

### ■ 자동실행 쉘 및 Python 파일

```

ECCC_FORE.sh
ECCCC_FORE.ncl

```

- 자동실행 : ECCC\_FORE.sh를 crontab에 등록하여 실행
- 수동실행 : ECCC\_FORE.sh의 YYY, YYYYMMDD 수정 후 실행

```

#!/bin/bash --login

YYYY=$(date -d 'last thursday' +%Y)
YYYYMMDD=$(date -d 'last thursday' +%Y%m%d)

#YYYY="2025"
#YYYYMMDD="20251120"

sed -e s/yyyymdd/$YYYYMMDD/g /data02/songbg/ECCC/ECCC_FORE.ncl >

```

```

/data02/songbg/ECCC/ECCC_FORE_imsi.ncl

ncl /data02/songbg/ECCC/ECCC_FORE_imsi.ncl
rm -f /data02/songbg/ECCC/ECCC_FORE_imsi.ncl

```

### 2.4.2. 다중모델앙상블 계절내예측 개별모델 전처리 시스템 구축

APCC는 보안을 위해 내부망과 외부망으로 네트워크를 분리해서 운영 중으로 수집된 개별 모델 자료는 외부망의 APCC FTP 서버에 저장이 된다. 따라서 모델 자료를 전처리하기 위해서는 HPC가 있는 내부망으로 자료를 다운로드해야 한다. Figure 2.46은 외부망 FTP 서버에서 내부망 HPC 서버로 자료를 다운로드하고 HPC 서버에서 전처리가 수행되는 과정을 보여준다. 외부망에서의 자료 수집, 내부망에서의 자료 다운로드 및 전처리는 모두 crontab을 사용하여 자동으로 처리되게 된다. 개별모델 자료가 전처리를 거치게 되면 1도로 표준화된 자료를 재생성하게 되며 주평균, 1~4주평균, 3~4주평균 자료도 함께 저장이 된다. 파일 형식은 GRIB 또는 NetCDF에서 모두 NetCDF 형식으로 변환이 된다.

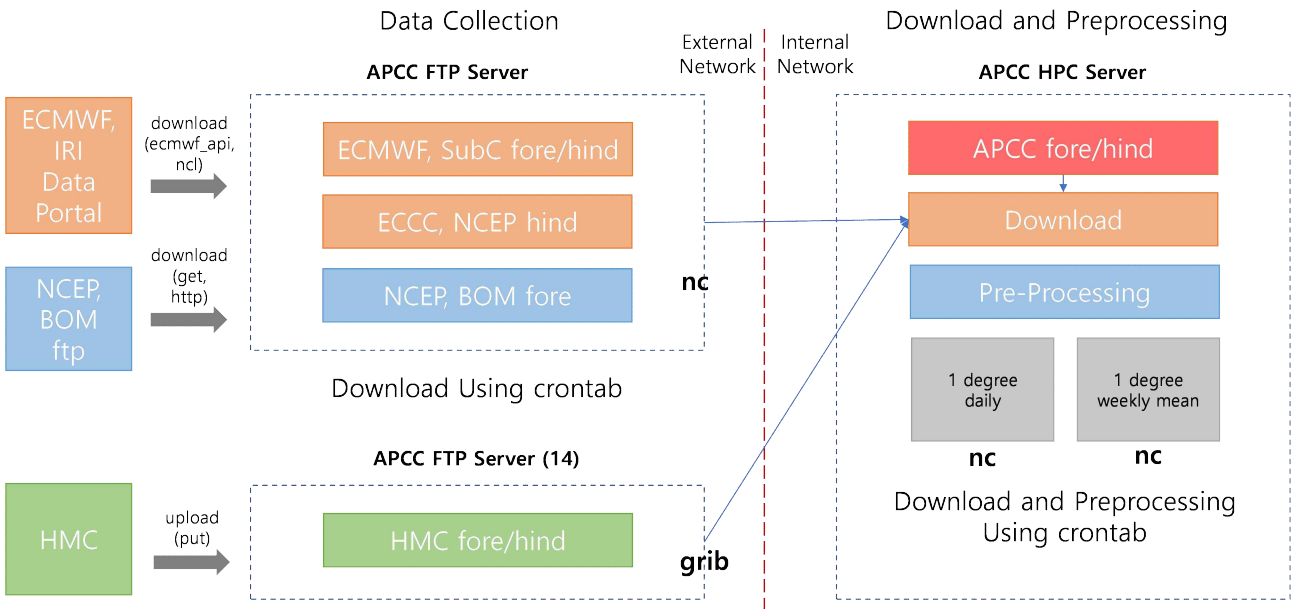


Figure 2.46. Data acquisition from an internal network FTP server and preprocessing on an external network HPC server.

다음의 예시는 BOM forecast 자료 수집, 다운로드, 전처리 과정을 보여준다.

## BOM forecast

### ■ 자동실행 쉘 및 Python 파일

```
ftp_pre_BOM_FCST.sh  
ftp_pre_BOM_FCST.py
```

### ■ 자동실행 : ftp\_pre\_BOM\_FCST.sh를 crontab에 등록하여 실행

```
#!/bin/bash --login  
  
python /ifs/data07/songbg/S2S_MME/RUN/ftp_pre_BOM_FCST.py
```

### ■ 수동실행 : ftp\_pre\_BOM\_FCST.py의 today 수정 후 실행

```
import datetime  
import dateutil.relativedelta as rdelta  
from my_package import run_command  
  
#-----  
#-----  
  
# today date: ex) YYYY-MM-DD  
today = datetime.date.today()  
  
#today = datetime.date(2025, 11, 16) # for manual  
  
# last THURSDAY: ex) YYYY-MM-DD  
last_thursday = today + rdelta.relativedelta(days=-1, weekday=rdelta.TH(-1))  
  
fdate = str(last_thursday) # ex) today: 2025-11-16 (Sun) --> fdate: "2025-11-13"  
  
date_split = fdate.split('-')  
YYYY = date_split[0]  
MM = date_split[1]  
DD = date_split[2]  
  
#-----  
  
forecast_year = YYYY  
initial_date = MM + "-" + DD
```

```

ftp_python_path = "/ifs/data07/songbg/S2S_MME/FTP/"
pre_python_path = "/ifs/data07/songbg/S2S_MME/PRE/BOM/"

#-----

# downloading from APCC FTP server =====
FCST = """
DataList:

- Institution_name : BOM
  Model_name       : ACCESS-S2
  Forecast_year    : {0}
  Initial_date     : {1}
"""
.format(forecast_year, initial_date)

with open(ftp_python_path + "BOM_FCST.yaml", "w") as file:
    file.writelines(FCST)

run_command.run_python(ftp_python_path + "BOM_FCST_download.py")

# preprocessing of forecast data =====

PRE_FCST = """
DataList:

- Institution_name : BOM
  Model_name       : ACCESS-S2
  Variable_name    : t2m prec olr maxt2m mint2m slp t850 z500 z200 u850 u200 v850 v200
  Forecast_year    : {0}
  Initial_date     : {1}
"""
.format(forecast_year, initial_date)

with open(pre_python_path + "BOM_FCST.yaml", "w") as file:
    file.writelines(PRE_FCST)

run_command.run_python(pre_python_path + "BOM_FCST.py")

```

### 2.4.3. 다중모델앙상블 계절내예측 생산 및 표출 체계 원형 구축

MME 계절내예측시스템은 앞서 설명한 자료 수집, 전처리 과정을 모두 포함하며, 여기에 MME 수행, 그래픽 표출 과정도 함께 포함된다. Figure 2.47은 자료 수집, 전처리, MME, 그래픽 표출 과정에 대한 모식도를 나타낸다.

MME 계절내예측에 사용된 기법은 단정예측의 경우 SCM (Simple Composit Method)을 사용하였고, 확률예측의 경우에는 앞의 2.2.2에서 기술된 바와 같이, Gauss와 Hybrid\_Gamma (Mixed\_Gamma + Quantile) 방법을 사용하였다.

그래픽은 개별모델의 1~4주 주평균, 1~4주평균, 3~4주평균 아노말리와 MME 1~4주 주평균, 1~4주평균, 3~4주평균 예측결과에 대해 표출하게 된다.

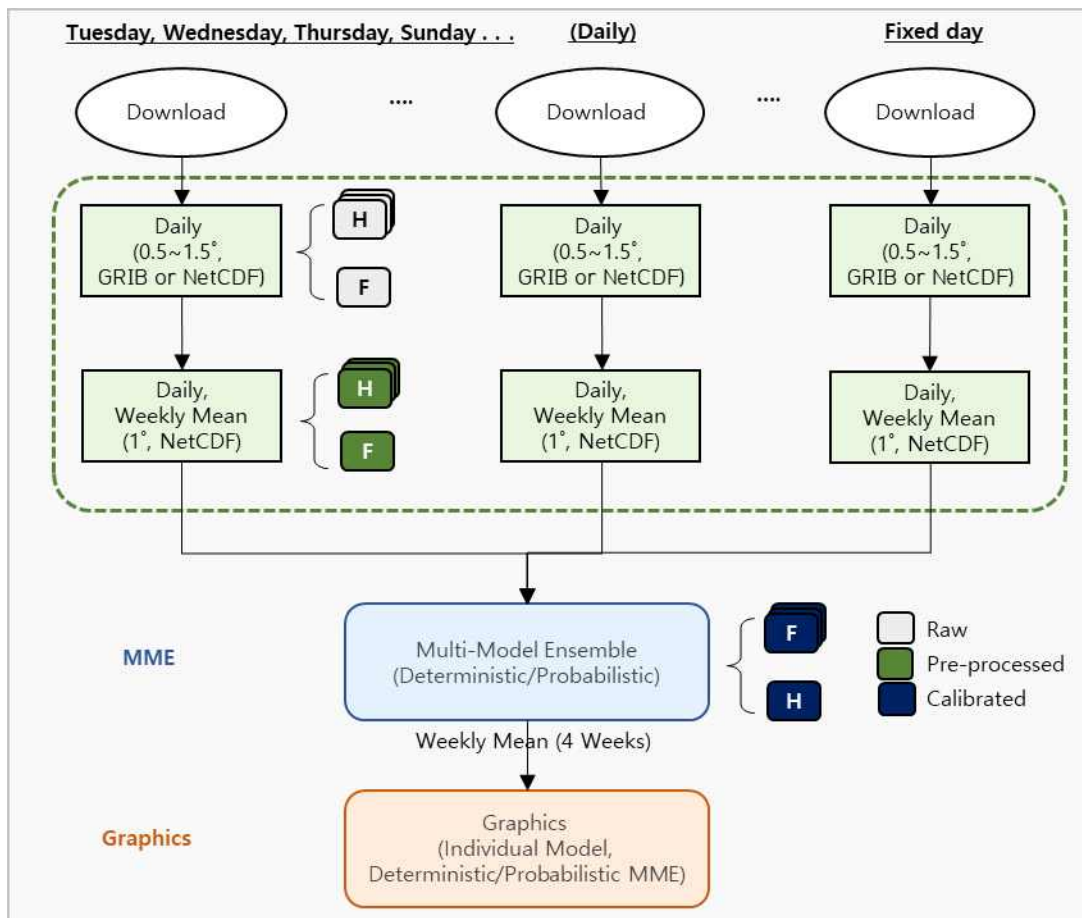


Figure 2.47. Schematic Diagram of the MME subseasonal forecast system, including data acquisition, preprocessing, MME execution, and graphic display processes.

MME 수행 시에는 개별모델의 1~4주 주평균 자료가 사용되는데 개별모델의 초기장 시작날짜가 모델마다 다르기에 월요일 ~ 일요일까지의 일주일 단위로 총 4주까지를 예측하게 된다. Figure 2.48은 2025년 7월 28일을 MME 예측시작 기준으로 해서 나타낸 10개 개별모델의 예측기간을 나타낸다. 모델의 예측시작 요일은 BOM, ECCC, ECMWF, EMC, HMC, NCEP은 목요일, ESRL은 수요일, APCC는 화요일, RSMAS는 일요일이며 GMAO는 5-daily로 이에 해당하는 요일이 선택되게 된다.

❖ 현업운영 기준 전처리 수행일 : 2025년 7월 28일(월)

\* hindcast : forecast 예측시작일과 가장 가까운 연도별 날짜 선택




Figure 2.48. Lead times of 10 individual models based on the MME forecast initial date of July 28, 2025.

다음의 예시는 2025년 7월 28일(월) 기준으로 MME를 수행하는 과정을 보여준다.

### MME 단정예측

#### ■ Yaml, Python 파일

```
FCST_SCM_MME_weekly.yaml
FCST_SCM_MME_weekly.py
FCST_SCM_MME_week1-4_mean.py
FCST_SCM_MME_week3-4_mean.py
```

#### ■ FCST\_SCM\_MME\_weekly.yaml를 수정하여 실행

```
DataList:
- Model_name      : APCC_SCoPS
                  : BOM_ACCESS-S2
```

```

ECCC_GEPS8
ECMWF_CY49R1
EMC_GEFsv12-CPC
ESRL_FIMr1p1
GMAO_GEOS-V2p1
HMC_SL-AV
NCEP_CFSv2
RSMAS_CCSM4
Variable_name : prec t2m
Forecast_year : 2025
Forecast_date : 07-28

```

## MME 확률예측

### ■ PBS Shell, Yaml, Python 파일

```

FCST_PMME_mpi_run.sh
FCST_PMME_week1-4_mean_mpi_run.sh
FCST_PMME_week3-4_mean_mpi_run.sh
FCST_PMME_weekly.yaml
FCST_PMME_weekly_mpi.py
FCST_PMME_week1-4_mean_mpi.py
FCST_PMME_week3-4_mean_mpi.py

```

- FCST\_PMME\_weekly.yaml를 수정하여 FCST\_PMME\_mpi\_run.sh, FCST\_PMME\_week1-4\_mean\_mpi\_run.sh, FCST\_PMME\_week3-4\_mean\_mpi\_run.sh을 qsub

```

DataList:
- Model_name      : APCC_SCoPS
                  BOM_ACCESS-S2
                  ECCC_GEPS8
                  ECMWF_CY49R1
                  EMC_GEFsv12-CPC
                  ESRL_FIMr1p1
                  GMAO_GEOS-V2p1
                  HMC_SL-AV
                  NCEP_CFSv2
                  RSMAS_CCSM4
Variable_name     : prec t2m
Forecast_year     : 2025
Forecast_date     : 07-28

```

다음의 예시는 2025년 7월 28일(월) 기준으로 MME 결과를 그래픽 포출하는 과정을 보여준다.

### ■ Yaml, Python 파일

```

DMME_FCST_weekly.yaml
PMME_FCST_weekly..yaml
DMME_FCST_weekly.py
DMME_FCST_week1-4_mean.py
DMME_FCST_week3-4_mean.py

```

```

PMME_FCST_weekly.py
PMME_FCST_week1-4_mean.py
PMME_FCST_week3-4_mean.py

```

- DMME\_FCST\_weekly.yaml, PMME\_FCST\_weekly.yaml를 수정하여 해당 Python 프로그램 실행

< 예: DMME\_FCST\_weekly.yaml >

DataList:

```

- Variable_name : prec t2m
  Forecast_year : 2025
  Forecast_date : 07-28

```

Figure 2.49~2.54는 2025년 7월 28일(월) 예측시작 기준 MME 예측결과를 나타낸 것이다. 그림에서 보는 바와 같이 1~4주 주평균, 1~4주평균, 3~4주평균에 대한 단정예측과 확률예측을 표출하였다.

본 과제에서 구축된 MME 계절내예측시스템은 2025년 11월 24일 예측시작 기준으로 매주 월요일에 MME 예측결과를 시험 생산하고 있다. 2025년 11월 24일 이후 생산된 예측결과는 부록 A에 나타내었다.

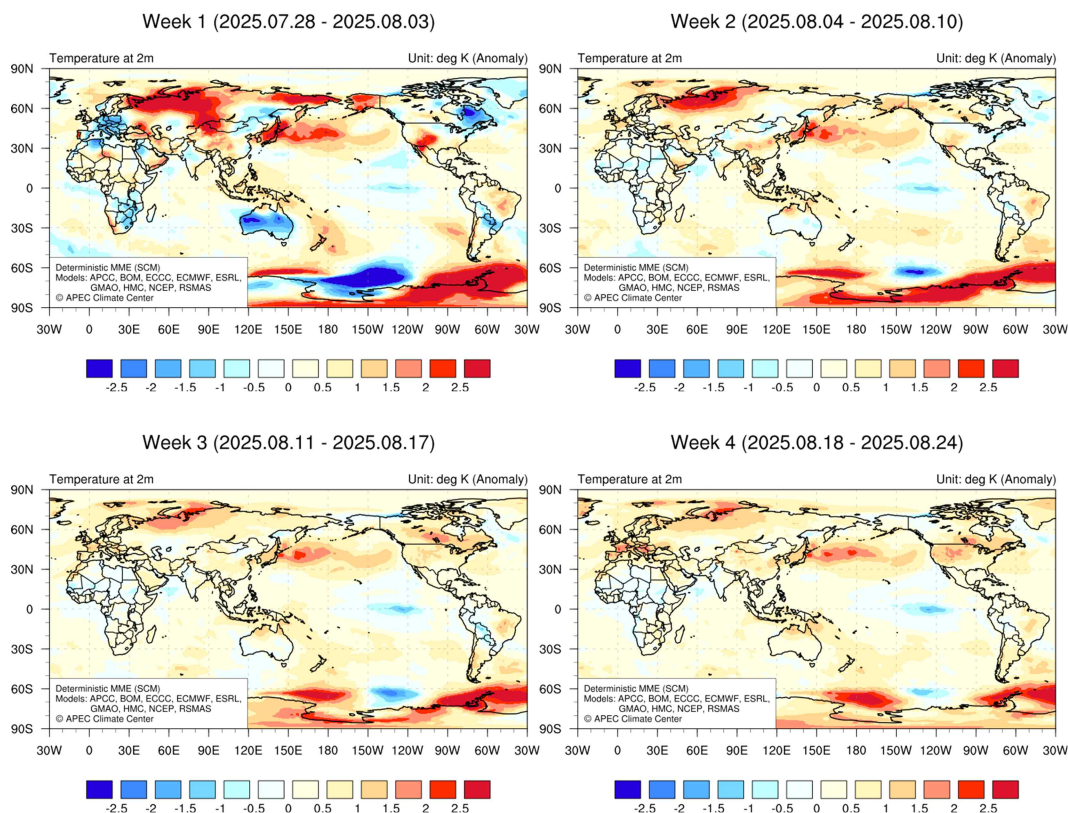


Figure 2.49. Weekly mean MME deterministic forecast results (temperature) for the 4-week period from July 28 to August 24, 2025.

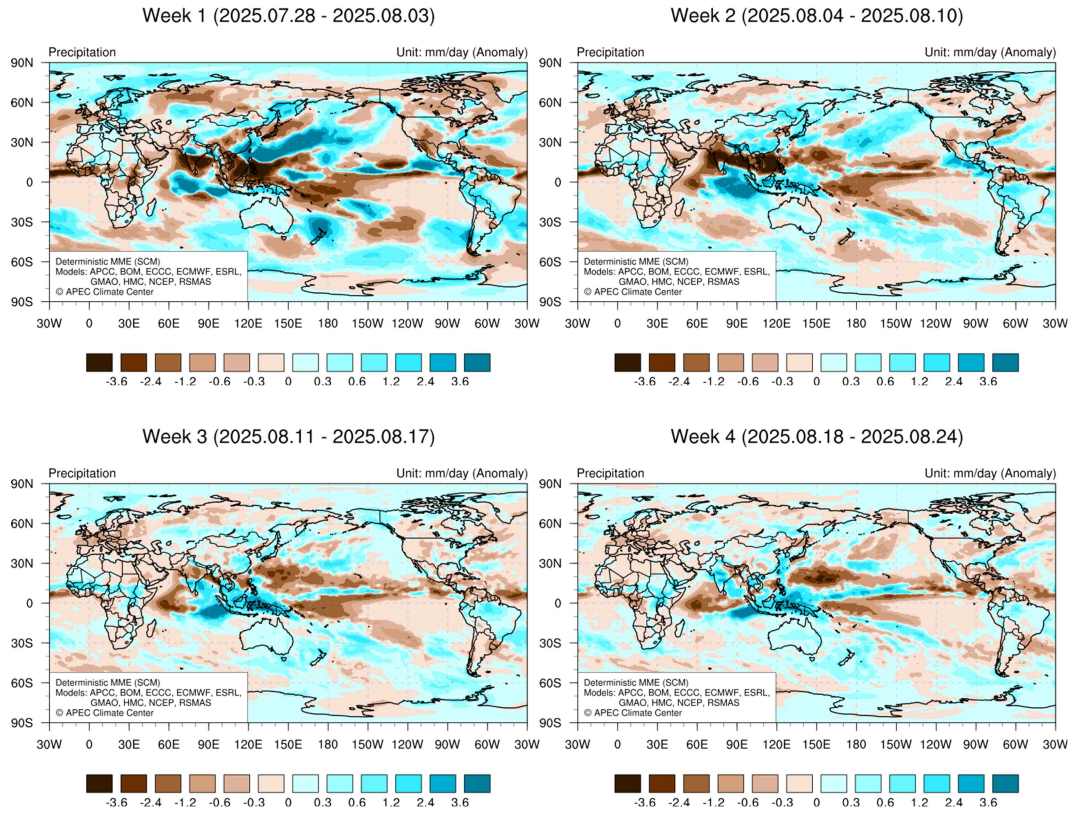


Figure 2.50. Weekly mean MME deterministic forecast results (precipitation) for the 4-week period from July 28 to August 24, 2025.

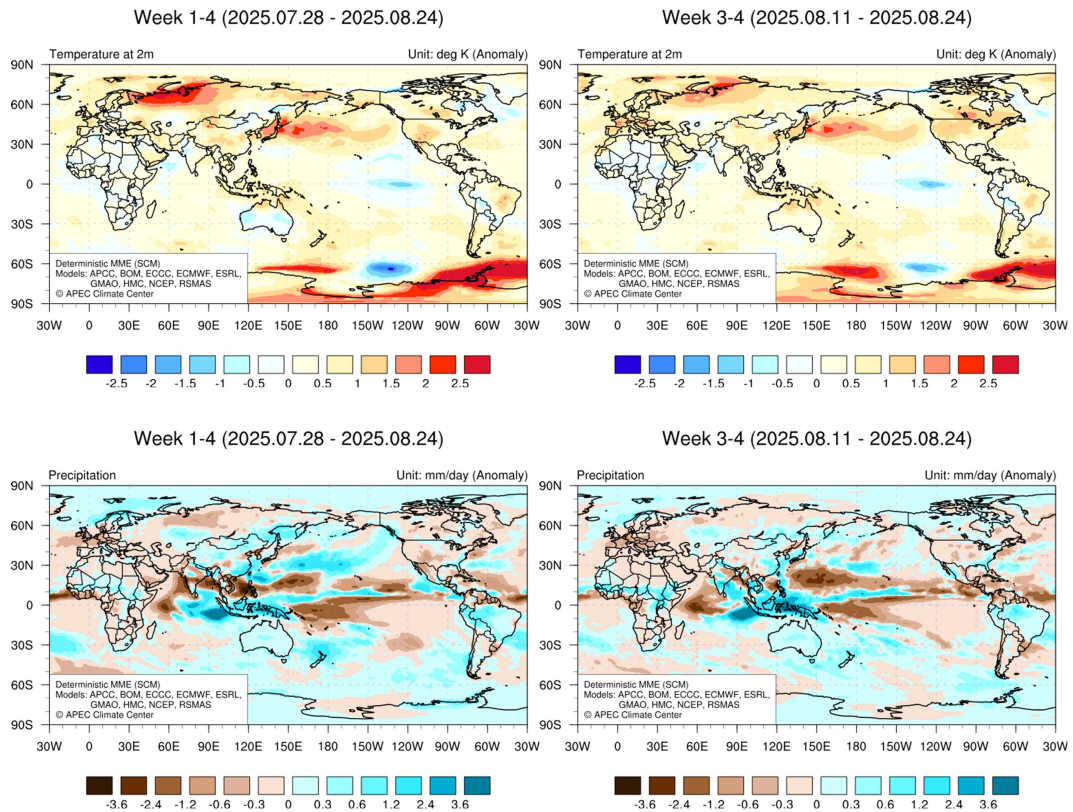


Figure 2.51. MME deterministic forecast results (temperature and precipitation) for the mean of weeks 1-4 and the mean of weeks 3-4, covering the period from July 28 to August 24, 2025.

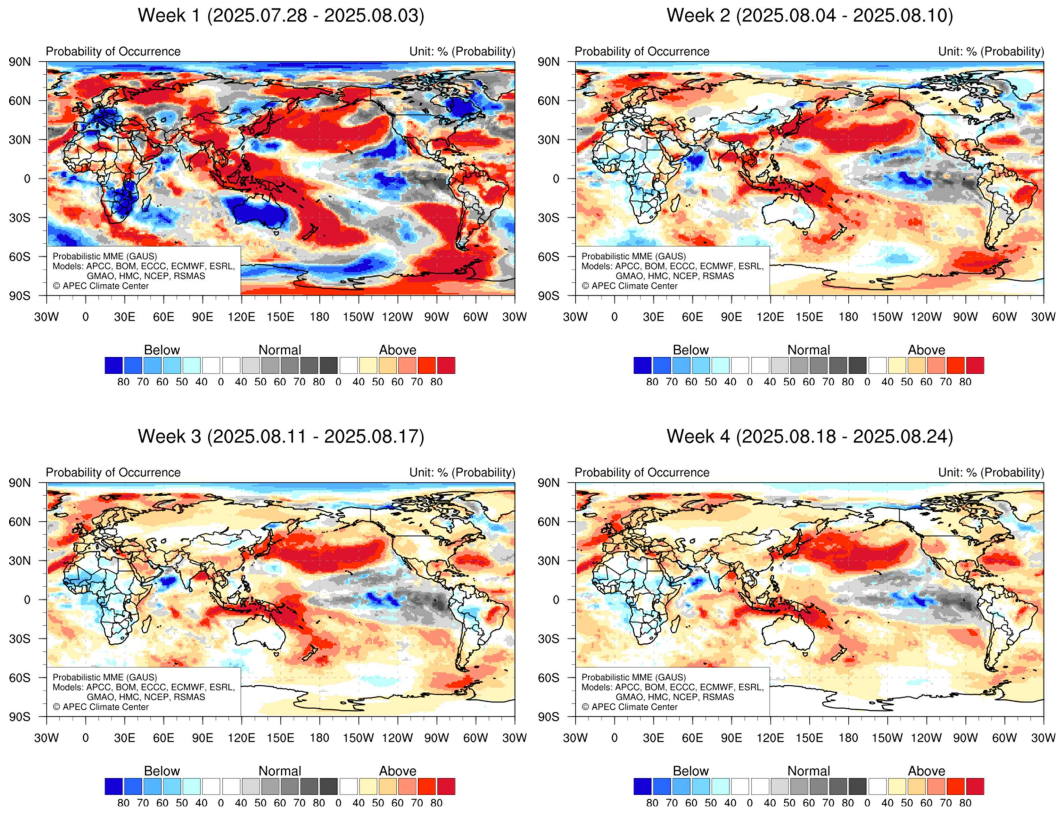


Figure 2.52. Weekly mean MME probabilistic forecast results (temperature) for the 4-week period from July 28 to August 24, 2025.

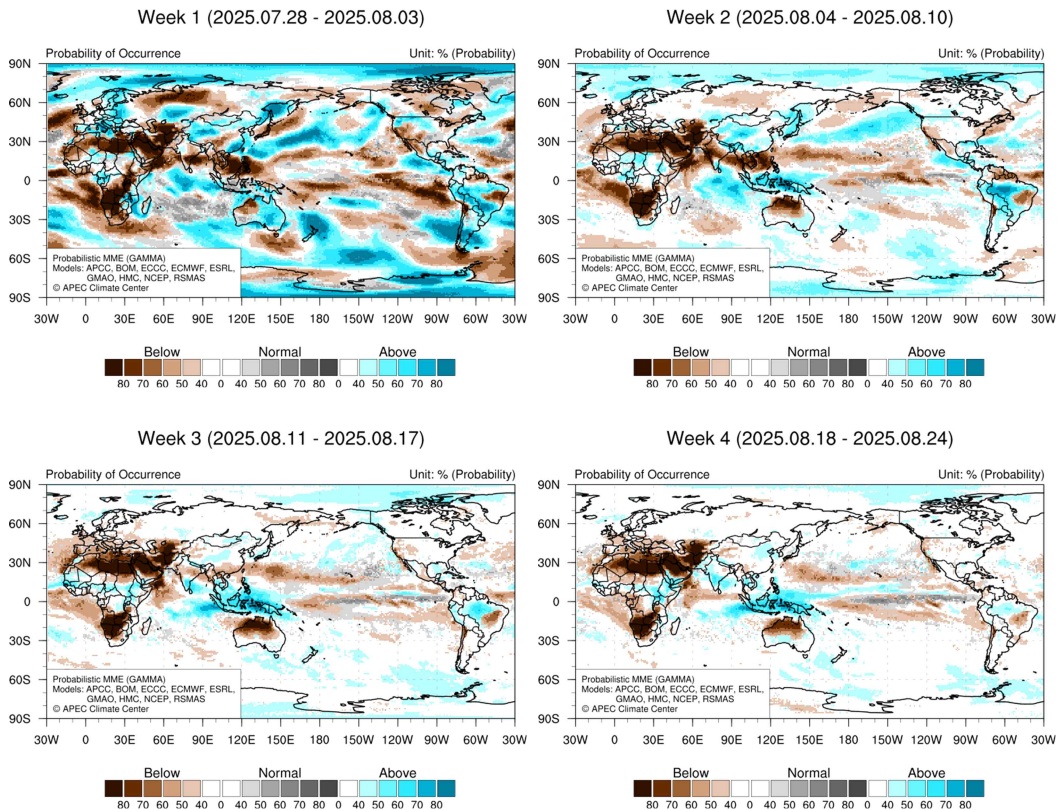


Figure 2.53. Weekly mean MME probabilistic forecast results (precipitation) for the 4-week period from July 28 to August 24, 2025.

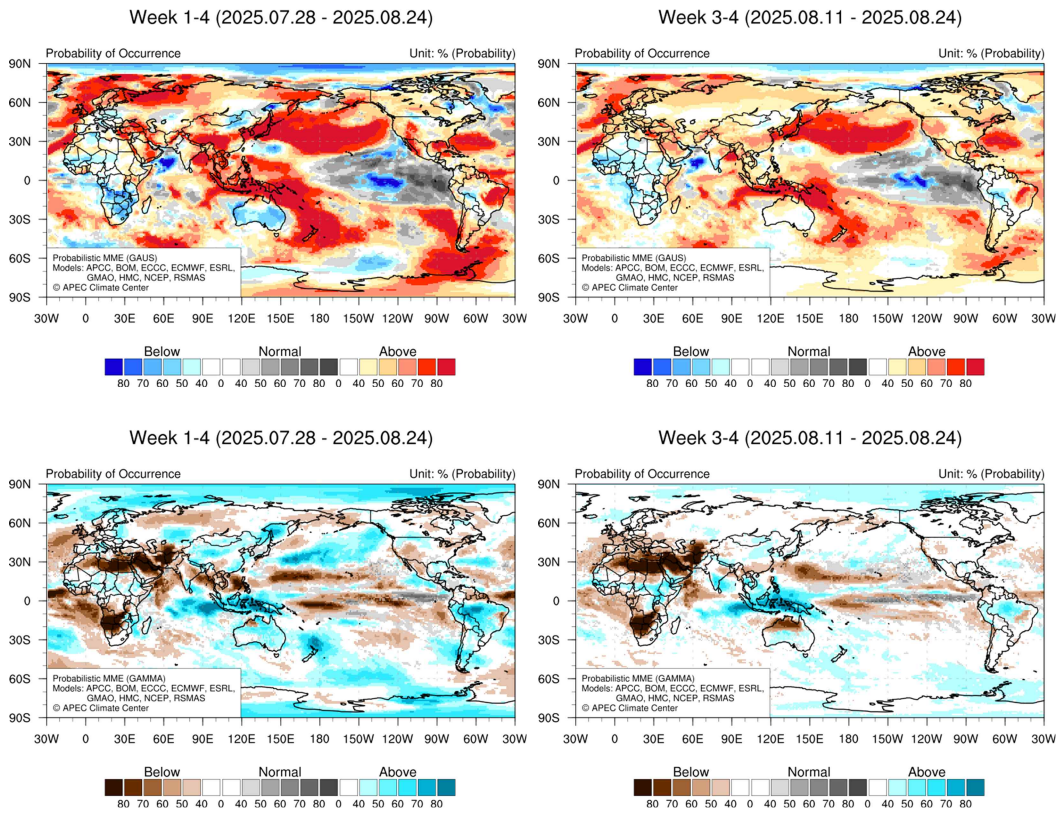


Figure 2.54. MME probabilistic forecast results (temperature and precipitation) for the mean of weeks 1-4 and the mean of weeks 3-4, covering the period from July 28 to August 24, 2025.

## 2.5. 계절내-계절 통합 활용 콘텐츠 발굴

### 2.5.1. 계절내 예측정보를 제공하는 연구 및 현업 센터의 현황 파악

현재 다양한 기관(ECMWF, WMOLC-SSPMME, IRI, NOAA, NCEP, CW3E)에서 계절내 예측 정보를 제공하고 있다 (Table 2.12). 대부분의 센터들은 원자료 기반의 “평년대비” 를 제공하고 있으며, 일부 기관에서는 Regime 일부 측면 (NJO, NAO, 블로킹 등)에 대해 확률적 예측을 제공하거나 연구 차원에서 전환 확률을 탐구하고 있다. 그러나 Regime Shift Probability (RSP) 자체를 현업으로 제공하고 있는 기관은 현재 없으며 APCC가 기후값이 아닌 전주 대비 또는 RSP 개발하여 현업으로 운영화한다면 차별화된 콘텐츠가 될 수 있을 것이다. 또한 '24년 연구의 주요결과인 예측성이 높은 1-4주 평균(월) 예측정보를 매주 제공하되, 계절/월 전망에서 제공되지 않는 정보를 담아내는 bridge content를 발굴하면 APCC 계절내예측의 차별화된 콘텐츠가 될 수 있을 것으로 보인다.

Table 2.12. Strategic roadmap for APCC's development of subseasonal-monthly seamless prediction contents.

기관	예측기간	특징/제공형식
ECMWF	최대 약 46일	- 앙상블, 주간 변화 강조(기후값 대비 편차)
WMOLC-SSPMME	1-4주	- 개별모델 및 MME 평년대비 편차 및 확률정보
IRI (Experimental)	1-4주	- 평년대비 확률기반 (tercile) 예측
IRI Map Room (SubC)	1-40일(주간/격주)	- 보정된 확률지도(기온, 강수)
NOAA CPC	3-4주, 1개월, 계절	- 운영예보, 미국전역(기온, 강수) 평년대비 편차
NCEP CFSv2	주 단위 최대 3주	- 전지구 기온, 강수 평년대비 편차
CW3E (Center for Western Weather and Water Extremes)	1-6주 (겨울 한정)	- 캘리포니아 지역 강수 및 대기의 강 정보

### 2.5.2. 계절내-계절 통합 콘텐츠 발굴

현재 대부분의 현업기관(예, ECMWF, IRI, NOAA 등)은 주로 원자료 기반의 주별 편차 예측정보를 제공하고 있으며, APCC는 계절내예측 MME 후발주자로 모델 개발, 참여모델 확대 및 기술 개발에 장기적 투자가 필요한 실정이다. 따라서 타 기관과의 차별성을 갖기 위해서는 단 기간에 실행 가능한 목표를 세워야 한다. 이를 위해 APCC의 강점(계절과 계절내 운영 경험 및 국제 협력)과 틈새시장(계절내-계절 연결하는 bridge forecast)에 맞춰 계절내-계절(월)을 연결하는 seamless 예측 콘텐츠에 집중하고자 한다. 따라서, 7단계 과제에서는 이음새없는 예측을 위한 콘텐츠를 발굴, 기술개발을 통해 예측정보 제공을 최종 목표로 한다(Figure 2.55).



Figure 2.55. Proposed development pathway for seamless prediction systems, designed to ensure continuous and consistent forecast information across subseasonal and seasonal timescales.

APCC의 현 위치와 강점을 현실적으로 고려한 접근은 단기에는 “기술자체의 개발보다 콘텐츠 혁신”, 중장기에는 “기술 개발 및 통합 시스템 구축”으로 이어지는 단계적 로드맵을 구상하였다 (Table 2.13). 이를 위해, 계절내-월 정보를 연속적이고 직관적으로 연결해주는 콘텐츠 중심으로 사용자 체감형 정보 seamless 콘텐츠를 발굴하고자 하였으며 (Table 2.14), 콘텐츠별 개발 시급성 및 난이도를 고려하여 단계별로 분류하였다 (Table 2.15-2.17). 단기 예측 콘텐츠는 계절내예측자료를 활용하여 사용자 체감형 정보 seamless 정보를 생성할 수 있는 콘텐츠이며, 증가는 계절내-월간 일간성, 신뢰도, 극한 가능성을 통계 기반으로 확장하여 지속적 제공을 위한 자동화와 검증 체계 구축이 핵심인 콘텐츠이다. 마지막으로 장기로 고려해볼 콘텐츠는 seamless 정보 제공을 시스템 차원으로 확장하는 것으로, 예측-검증-정보 전달이 하나의 주기 내에서 자동화 형태로 연결되는 콘텐츠이다. 일부 콘텐츠에 대한 자세한 설명은 Table 2.18에 추가하였다.

Table 2.13. Strategic roadmap for APCC’s development of subseasonal-monthly seamless prediction contents.

구분	목표 방향	구체적 전략 포인트
2025	콘텐츠 중심의 차별화	<ul style="list-style-type: none"> <li>- 계절내-월 연관성 분석</li> <li>- 기존 계절예측의 한계를 보완할 수 있는 “계절내-계절 연결형 콘텐츠” 발굴</li> <li>- 콘텐츠별 개발 우선순위 분류</li> </ul>
2026	기술 확장	<ul style="list-style-type: none"> <li>- 일부 콘텐츠를 기술 기반으로 전환</li> <li>- 예측기반 핵심 기술 개발</li> <li>- 계절내-월 단기간 확률연결 및 추가변동 예측정보 시범 구축</li> </ul>
2027	통합형 예측정보 시스템 구축	<ul style="list-style-type: none"> <li>- 계절내-월 예측 통합 시스템 구축</li> <li>- APCC MME 계절내예측 콘텐츠 시범 운영</li> </ul>

Table 2.14. Three-phase strategic framework for APCC’s development of subseasonal-monthly seamless prediction contents.

구분	시급성	난이도	예시 콘텐츠	목적
즉시 제공형 (Quick Wins)	높음	낮음	<ul style="list-style-type: none"> <li>- 월/주간 통합 확률 분포</li> <li>- 주별 극값 발생 가능성</li> <li>- 주→월 전환 경향</li> <li>- 주별 편차 slope 시각화</li> </ul>	사용자가 “지금” 느낄 수 있는 새로운 정보 제공
중기 개발형 (Technical Growth)	중간	중간	<ul style="list-style-type: none"> <li>- 계절내-월 일관성(연속성) 지수</li> <li>- MME ensemble spread 기반 regime shift probability</li> <li>- 월내 극한 발생확률</li> </ul>	통계·후처리 기법으로 seamless 정보 강화
장기 R&D형 (Next-Phase)	낮음	높음	<ul style="list-style-type: none"> <li>- Seamless MME framework</li> <li>- User-oriented seamless bulletin 영향기반 지수 활용 콘텐츠</li> </ul>	기술적으로 seamless system 구현

Table 2.15. Summary of proposed quick-win subseasonal-monthly seamless prediction contents.

콘텐츠	주요 개념	제공 정보 예시	기대효과
• 주-월 변화확률 지도 (week-to-month transition probability)	최근 4주 편차경향이 다음달로 이어질 확률을 계산	다음 달에도 평년 이상 강수 지속 확률 65%	계절내와 월 예측 간 연속성 인식
• 이상전환지도 (anomaly shift map)	주별 편차 부호 변화 (+) → (-) 구간을 표시	2주 뒤 양의 편차 → 음의 편차 전환 가능 지역	변화 흐름 중심 콘텐츠
• fan-chart 형태의 주-월 통합 확률분포	주별 확률분포를 월 평균 분포와 연결 시각화	한달동안 온도 증가 경향 및 불확실성 범위	예측 신뢰도 직관화
• 주간 전환시그널	주단위 예측 변동성으로 전환기 탐지	anomaly slope > 1.5σ 전환 표시	급변 · 전환기 진단
• 예측 일관성 지도 (week-to-week consistency map)	연속 주차 간 편차 sign 동일 여부 표시	동일 경향 유지 지역 비율 70% 이상	예측 안정도 표시

Table 2.16. Summary of proposed technical growth subseasonal-monthly seamless prediction contents.

콘텐츠	주요 개념	제공 정보 예시	기대효과
• Coherence index (예측 일관성 지수)	계절내-월 편차 간 상관계수 기반 일관성 평가	기온 예측 coherence index = 0.68	주별-월별 연속성 진단
• Regime shift probability	ENSO/IOD 등 주요 모드 전환 확률을 기반으로 편차 전환 가능성 제시	다음 달 ENSO 전환기 영향 40%	주요 모드에 의한 예측 전환 경향 파악
• Ensemble spread map	주-월 예측 ensemble spread 계산	Spread 감소지역 → 높은 일관성	불확실성 기반 추가정보 제공
• Cross-scale verification dashboard	계절내예측과 월예측의 검증지표 병합 시각화	각 모델별, 리드타임별 skill 비교	기술 신뢰도 확보

Table 2.17. Summary of proposed next-phase subseasonal-monthly seamless prediction contents.

콘텐츠	주요 개념	제공 정보 예시	기대효과
• week-month-season seamless map	모든 주/월/계절 편차를 하나의 시계열 맵으로 통합 표시	4주 예측 + 월 평균 + 계절 평균 편차	통합 시각화
• Seamless verification portal	계절내-계절 연속 검증 체계	검증 정보의 연속 통합 그래프 제공	R2O 연결 콘텐츠
• User-tailored seamless bulletin	지역별/관심변수별 주-월 연속 요약 리포트	한국 남부지역, 향수 4주 고온 지속 가능성 70%	기관별·부문별 응용 콘텐츠

Table 2.18. Description of potential contents to bridge subseasonal and seasonal (monthly) forecasts.

Contents	Description
week-to-week change	<ul style="list-style-type: none"> <li>• 지난주 대비 이번주 전망 변화(예, 강수 발생 확률이 20% 상승)</li> <li>• 사용자는 절대적인 이상치보다 변화에 더 민감하게 반응</li> <li>• 지난주 대비 변화된 확률 또는 정규화된 이상값 제공</li> </ul>
Regime shift probability	<ul style="list-style-type: none"> <li>• 최근 기상상태가 반대로 바뀔 가능성(패턴 전환 가능성)을 확률로 제시</li> <li>• 급격한 패턴 변화는 대응 시간 확보에 중요</li> <li>• 부호 반전 확률 산출, 신뢰도 검증 후 지역별 지수 제공</li> </ul>
Window of opportunity	<ul style="list-style-type: none"> <li>• 현재 대기/해양 상태를 반영(특정 teleconnection 발생)하여, 예측정확도가 평소보다 높은 지역을 제시</li> <li>• 언제, 어디서 예측이 믿을만 한가를 사용자에게 제공</li> <li>• 과거 기후 인덱스(예, ENSO/MJO) 상태별 예측 스킬을 바탕으로 현재 영향권 내 예측 신뢰 지역 제시 → 신뢰 기반 예보 활용성 향상</li> </ul>
teleconnection-informed calibration	<ul style="list-style-type: none"> <li>• 모델 예측과 관측기반 teleconnection 패턴을 결합하여 후처리한 자료 제공(예, ENSO/MJO regression fields)</li> <li>• 모델 teleconnection 편향을 줄이고 신뢰도 향상</li> <li>• 다양한 보정기법 활용(예, bayesian model averaging, analog regression)</li> </ul>
Extreme early warning	<ul style="list-style-type: none"> <li>• 각 sector/region 중요한 지수 및 극한 현상의 threshold를 초과할 확률예측</li> <li>• 다양한 분야의 대응 및 계획 수립 반영</li> <li>• 바이어스 보정 일자료 활용, 기준값을 초과할 확률 + 신뢰도에 대한 confidence 추가</li> </ul>

### 2.5.3. 계절내-계절 통합 콘텐츠 선정

앞서 계절내-계절(월)을 연결하기 위한 다양한 콘텐츠를 발굴하였고, 콘텐츠별 개발 시급성 및 난이도, 센터 내 상황을 고려하여 내년 사업을 위해 즉시 제공가능한 콘텐츠와 기술개발

이 필요한 콘텐츠를 다음과 같이 선정하였다.

### 2.5.3.1. 즉시 제공 가능한 콘텐츠

#### 2.5.3.1.1 week-to-week change

주간 변화 탐지정보는 APCC가 즉시 제공할 수 있는 가장 실용적인 quick-win 콘텐츠로 계절내예측에서 가장 중요한 “전환점과 변화의 흐름”을 시각적으로 제공할 수 있는 콘텐츠이다. 이 콘텐츠를 선정한 이유는 다음과 같다.

- (1) 계산 부담이 낮고, 비교적 자동화가 쉽고 운영 안정성이 높아서 quick-win으로 도입하기에는 최적이라고 판단됨
- (2) 예측이 강해지는지/약해지는지, 편차가 양→음 또는 반대 전환되는지, 특정 지역에서 급변이 존재하는지 등의 변화 시그널을 사용자에게 명확히 전달함으로써 기존 월예보에 없는 실질적인 정보일 뿐만 아니라 사용자 의사결정에 가장 직접적이고 현업 예보에 가장 실용적인 정보임
- (3) 계절내 예측의 고질적 문제인 급격한 변동 해석을 가능하게 하며 이는 예측 안정성을 직접적으로 평가하여 주간 변화율 자체가 예측 불확실성의 지표가 됨
- (4) 주간 변동예측은 사용자의 의사결정에 가장 직접적이고 실용적인 정보를 제공함
- (5) 월 및 계절 예보에서 주간 신호의 근거를 설명하는 자료로 활용가능하여 사용자 신뢰도 향상에 도움이 됨

즉, 대부분의 예보는 기후값에 대한 편차장인 반면, 사용자는 실질적으로 지난주 대비 기온이 얼마나 올라가는지, 낮은지 즉, 절대적인 이상치보다 변화에 더 민감하게 반응하기 때문에 사용자가 체감할 수 있는 정보 전달이 보다 유용하게 활용될 수 있다. 또한 장기간 기후값 기반 편차나 절대값 차이에 의존하지 않는다는 장점도 있다. 하지만 real signal evolution 보다 모델의 drift 또는 noise가 반영되어 있는 예측정보이기 때문에 지난주(관측) 대비 이번주(예측) 값 직접 비교는 체계적인 오차나 모델-관측 간 차이로 인해 직접 비교가 어려울 수 있다. 이러한 문제점을 극복하기 위한 하나의 방안으로 본 연구에서는 관측-예측을 일관된 방식으로 연결하고, 주간변화 정보를 신뢰성 있게 제공하기 위해 관측과 예측정보를 표준화하여 (normalization)모델 편향을 제거하고, 진짜 신호 변화에 주목하여 상대적인 변화량(Z-score; Table 2.19)을 정량적으로 표현하고자 하였다. 또한, signal-to-noise (SNR) 변화가 큰 경우만 함께 표시함으로써 신뢰도 높은 정보를 전달하고자 하였다 (Table 2.20).

2024년 1월 초~중순까지 평년보다 따뜻한 기온을 유지하다가, 1월 22일~23일 정도에 한차례 추운 날씨가 지속된 경우를 선정하여 테스트하였다 (Figure 2.56). 관측에서 나타나는 바와 같이, 1월 상순~중순 대륙고기압의 약화 및 이동성 고기압 발달로 인해 남풍을 타고 따뜻한 공기가 유입되어 평년보다 따뜻하다 1월 하순 시베리아의 베링해에서 기압능이 발달하여 북극에서 유입된 찬 공기가 정체되면서 한반도 및 동아시아 지역이 평년보다 낮은 기온을 보였다. 이러한 주간변동성을 관측에서 확인 할 수 있으며, 2024년 1월 첫주(1월1일~7일) 대비 2, 3, 4주

의 기온 차이 또한 뚜렷하게 나타나고 있다. 이러한 현상을 역학모델에서도 잘 모의하는지 확인하기 위해 ECMWF 예측자료를 활용하였다. 그 결과, 1월 첫주 대비 1, 2주의 고온 현상을 관측과 유사한 형태로 잘 모의하고 있으며, 3주차의 기온 하강은 관측에 비해 강도가 크진 않지만 적절하게 모의하고 있음을 알 수 있다. 이러한 예측 콘텐츠는 다양한 경우에 대한 테스트를 통한 안정성 및 표현 방법에 대한 추가적인 연구를 진행하면 충분히 APCC만의 독창적인 예측 콘텐츠가 될 수 있을것으로 판단된다.

Table 2.19. Z-score thresholds used to quantify the relative magnitude of week-to-week changes.

Z Value	Interpretation
+2.0	Strong signal toward warming compared to last week
+1.0	Moderate shift toward warmer-than-last week
0	No significant change relative to last week
-1.0	Shift toward cooler condition
-2.0	Strong signal toward cooling

Table 2.20. Signal-to-noise thresholds used to quantify the relative reliability of week-to-week changes.

SNR Value	Interpretation
< 1	Low signal, high uncertainty
1-2	Moderate signal
> 2	Strong signal, more trustworthy
> 3	Very strong and confident signal

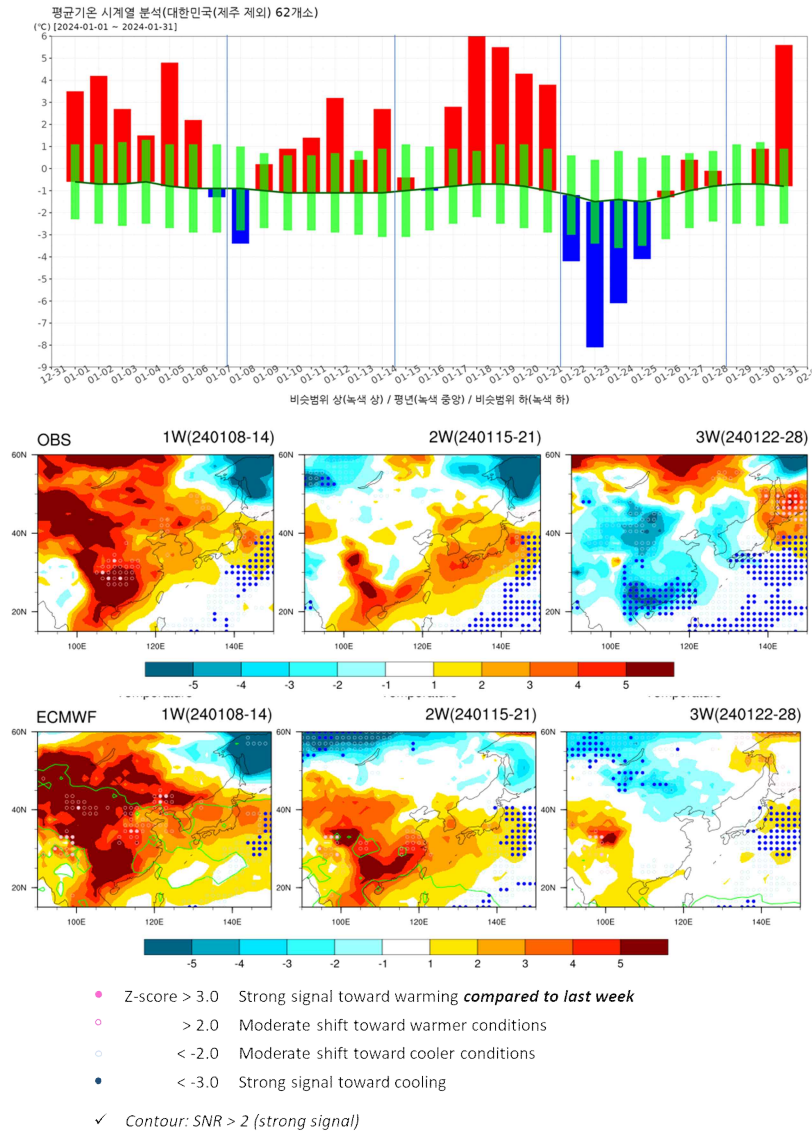


Figure 2.56. Example products of week-to-week changes relative to last week means (20240101-07).

### 2.5.3.1.2 주 1/2/3/4 + 월 확률분포 콘텐츠

1/2/3/4주 및 1-4주 평균(월) 확률을 하나의 시간 축으로 연결하는 콘텐츠로 계절내-월 정보를 자연스럽게 잇는 seamless 콘텐츠라고 할 수 있다. 이러한 콘텐츠를 선정한 이유는 다음과 같다.

- (1) 세계 유수 현업기관에서는 주간과 월 예보가 독립적으로 분리된 시스템으로 운영되고 있으며 이는 APCC가 다중모델앙상블 기반으로 계절내와 월을 통합 할 수 있는 세계적으로 희소한 차별화 콘텐츠 제공이 가능함
- (2) 시간 스케일 간 정보 연결을 실질적으로 구현함으로써 1주→2주→3주→4주→월 확률변화의 흐름이 한눈에 보이는 장점이 있으며 이는 월평균 예보의 근거를 사용자는 직관적으로

이해 할 수 있음

(3) 예측 신뢰도 (불확실성)의 시간적 구조 분석이 가능하여 예측의 강·약 및 일관성을 시간 구조로 설명 가능

이러한 콘텐츠는 계절내와 계절(월)을 연결하는 확률기반 seamless 정보 (Figure 2.57)로 확률 계절예측을 안정적으로 운영해 온 확률정보 중심 기관이라는 브랜드와 일치하는 발전 방향으로 APCC를 대표하는 최적화된 콘텐츠라고 할 수 있다.

Weekly and Monthly Probability Distributions

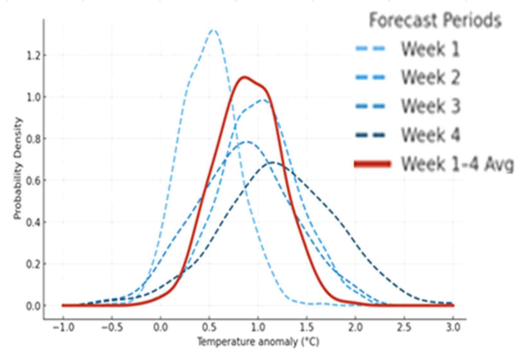


Figure 2.57. Example products of weekly and monthly probability distributions.

Week-to-week change는 APCC가 즉시 제공할 수 있는 가장 실용적인 quick-win 콘텐츠로 계절내예측에서 가장 중요한 전환점과 변화의 흐름을 시각적으로 제공하며, MME 기반 타 기관 대비 안정적이고 예측성이 높은 변화 신호를 제공할 수 있다. 1-4주 및 월 확률분포는 APCC만이 구현할 수 있는 희소한 seamless probability 콘텐츠로 시간 스케일 간 단절을 해소하고, 예측 신호의 방향성·강도·불확실성을 하나의 시간축으로 전달하는 독보적인 예측 콘텐츠이며 월예보의 신뢰도·불확실성에 대한 이해를 크게 향상시킬 수 있는 전략 콘텐츠이다.

#### 2.5.2.2. 기술개발을 위한 핵심 콘텐츠

발굴한 다양한 콘텐츠 중 월내 극한발생 확률 예측 콘텐츠는 일자료 기반(예, 상위 90% 이상)으로 1/2/3/4주 및 월 평균 극한현상의 발생 확률 정보를 매주 업데이트하는 APCC 신규 개발형 콘텐츠이다. 이 콘텐츠를 선정한 이유는 계절 및 월 예보는 평균 중심의 정보를 제공하여 극한일수/극한 강도 등 분포의 tail에 대한 정보 제공에는 한계가 있다. 즉, 월 예보는 평균이 낮다/높다는 정보만 제공할 뿐 실제 위험이 언제 발생하는지는 제공이 어렵다. 하지만 계절내 예측의 경우 일단위·주단위 역학모델의 예측정보를 제공하므로 극한 등의 tail 정보를 전달 가능하며, 주간 신호를 그대로 반영하여 월 평균에서 희석되는 단기의 강한 신호를 전달할 수 있다. 또한, 매주 업데이트된 최신의 계절내 예측정보를 반영하여 위험도 변화 또한 예측이 가능하여 극한위험 조기경보 및 선제대응이 가능한 시계열 예측체계를 구성할 수 있다.

이를 위해 우선적으로 월평균과 계절내 극한과의 연과성 분석을 수행하였다. Figure 2.58

은 월 평균과 월 평균 내 극한 발생빈도와와의 관련성을 나타낸 것으로, 2022년 7월 한반도 상위 90% 극한 고온 발생빈도는 7월 평균 기온을 결정짓는 주요 요인이며, 전구로 봤을때도 평균 기온과 상위 90% 극한 고온 발생과는 높은 상관도가 있음을 알 수 있다. 하지만, 월 평균과 극한은 서로 다른 분포를 가지며 월 평균과의 관계로 월내 극한 발생 빈도를 대체할 수 없다. 즉, Figure 2.59에서 확인 할 수 있듯이, 동일한 평균을 가진다고 하더라도 일자료의 분포는 서로 상이하기 때문에 월평균에 대한 연관성으로 극한발생빈도를 추정하는 것은 일변동, 비대칭성, 지속성 등 신호를 반영하지 못하게 된다. 따라서, 극한 예측을 위해서는 일자료 기반이 필수적이라고 할 수 있다.

이는 타 기관이 모두 계절과 계절내 시스템이 완전히 분리되어 운영되는데 반해 APCC만의 차별화된 콘텐츠로 주간-월 단위의 극한 확률분포를 하나의 프레임에서 제공하는 유일한 예측정보가 될 수 있다. 즉, 월내 극한 발생확률 예측은 월예보가 제공하지 못하는 극한 위험 발생시기를 제공하고, 계절내 예측이 제공할 수 있는 최신 역학 모델의 예측정보를 반영함으로써 계절내-계절(월)을 잇는 APCC만의 독창적 전략 콘텐츠가 될 수 있다 (Figure 2.60). 이렇게 선정된 콘텐츠들은 내부적으로 좀 더 논의를 거친 뒤, ‘26년 현업운영에 즉시 반영되거나 추가적인 기술개발을 통해 APCC 홈페이지를 통해 제공될 것으로 기대된다.





Figure 2.58. Time series of monthly means and daily temperature for Korea in July 2022. Distributions of correlation between monthly mean temperature and frequency of upper 90% temperature in July.




Figure 2.59. Example of time series with same means but different daily variations (extremes).

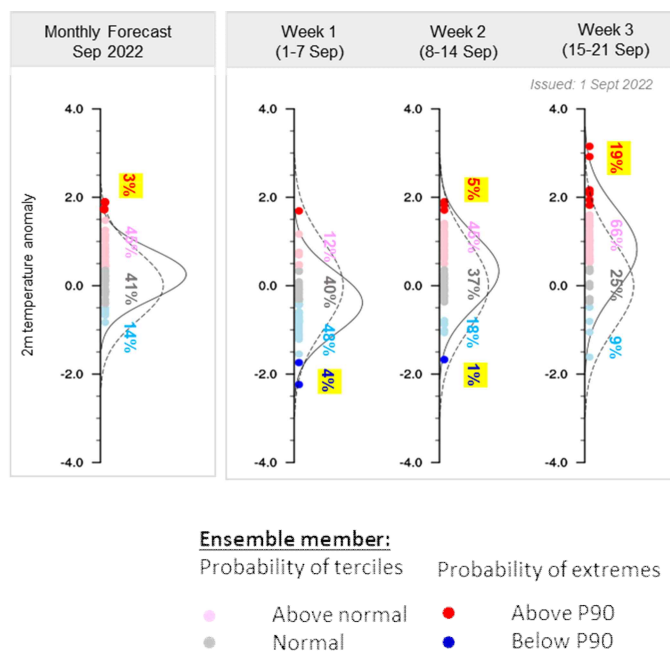


Figure 2.60. Example products of quantile-based extreme probability prediction.

### 3. SCoPS 운영 및 개선

#### 3.1. SCoPS 계절내예측 실시간 운영

현재 매월 계절예측자료를 생산 중인 SCoPS 모델을 매주 계절내예측자료를 생산하는 실시간 운영체제로 전환하기 위해 다음과 같은 주요 개선작업이 이루어졌다.

- 초기장 생산을 위한 입력장(CFS 분석장, ARGO 해양관측 자료)의 매주 수집 및 전처리
- hindcast 기간(2003 ~ 2016년) 이후 2017년부터 앙상블 10개로 구성된 초기장 생산

※ hindcast 자료는 2003 ~ 2016년까지 기존 계절예측과 동일한 5개 앙상블에 대해 일별 초기장을 생산 완료하였고, 매월 1, 5, 10, 15, 20, 25일 초기장을 사용하여 60일 예측장 생산을 완료하였음

- 매주 일주일 단위(지난 주 수요일 ~ 이번 주 화요일) 일별 초기장 생산, 매주 화요일 초기장을 사용한 60일 예측장 생산 및 후처리

##### 3.1.1. CFS 분석장, ARGO 해양관측 자료의 수집 및 전처리

일별 초기장 생산을 위해 사용된 자료는 CFS 분석장(NCEP Climate Forecast System Version 2 (CFSv2) 6-hourly Products, <http://gdex.ucar.edu/datasets/d094000>)과 ARGO 해양관측(Array for Real-Time Geostrophic Oceanography, <ftp://ftp.ifremer.fr/ifremer/argo/geo>) 이다.

자료 수집은 CFS 분석장의 경우 Python에서 `gdex_api_client`를 사용하여 다운로드하게 되며(Figure 3.1~3.2), `crontab`을 이용하여 매주 목요일에 일주일 단위(지난 주 수요일 ~ 이번 주 화요일)로 일별 자료를 자동으로 수집하게 된다. 수집 변수는 `psfc` (surface pressure), `shum` (specific humidity), `sst` (sea surface temperature), `temp` (temperature), `uwnd` (u-wind), `vwnd` (v-wind)의 6개 변수로 연직 자료(`shum`, `temp`, `uwnd`, `vwnd`)의 경우 37 level을 가지고 있다. ARGO 해양관측 자료의 경우 역시 `crontab`을 이용하여 매주 목요일에 일주일 단위(지난 주 수요일 ~ 이번 주 화요일)로 일별 자료를 자동으로 수집하게 되며, IFREMER (Institut Français de Recherche pour l'Exploitation de la Mer, 프랑스 해양 개발 연구소)의 ftp로부터 태평양, 인도양, 대서양 지역의 자료를 수집하게 된다(Figure 3.3).

위에서 수집된 자료 전처리에서는 SCoPS의 대기 및 해양 너징을 위한 자료 변환이 수행되며(`psfc`, `shum`, `sst`, `temp`, `uwnd`, `vwnd`), SCoPS의 EAKF를 위한 ARGO 자료 변환이 수행된다.

```

#!/bin/bash --login

START_YYYYMMDD=$(date -d '1 weeks ago last wednesday' +%Y%m%d)
END_YYYYMMDD=$(date -d 'last tuesday' +%Y%m%d)

# surface pressure
sed -e s/s/YYYYMMDD/$START_YYYYMMDD/g -e s/e/YYYYMMDD/$END_YYYYMMDD/g /data02/scops_s2s/SCOPS_INI/CFSR/RUN/CFSR_
download_psfc.py > /data02/scops_s2s/SCOPS_INI/CFSR/RUN/psfc_imsi.py
python /data02/scops_s2s/SCOPS_INI/CFSR/RUN/psfc_imsi.py
rm -f /data02/scops_s2s/SCOPS_INI/CFSR/RUN/psfc_imsi.py

# specific humidity
sed -e s/s/YYYYMMDD/$START_YYYYMMDD/g -e s/e/YYYYMMDD/$END_YYYYMMDD/g /data02/scops_s2s/SCOPS_INI/CFSR/RUN/CFSR_
download_shum.py > /data02/scops_s2s/SCOPS_INI/CFSR/RUN/shum_imsi.py
python /data02/scops_s2s/SCOPS_INI/CFSR/RUN/shum_imsi.py
rm -f /data02/scops_s2s/SCOPS_INI/CFSR/RUN/shum_imsi.py

# sea surface temperature
sed -e s/s/YYYYMMDD/$START_YYYYMMDD/g -e s/e/YYYYMMDD/$END_YYYYMMDD/g /data02/scops_s2s/SCOPS_INI/CFSR/RUN/CFSR_
download_sst.py > /data02/scops_s2s/SCOPS_INI/CFSR/RUN/sst_imsi.py
python /data02/scops_s2s/SCOPS_INI/CFSR/RUN/sst_imsi.py
rm -f /data02/scops_s2s/SCOPS_INI/CFSR/RUN/sst_imsi.py

# temperature
sed -e s/s/YYYYMMDD/$START_YYYYMMDD/g -e s/e/YYYYMMDD/$END_YYYYMMDD/g /data02/scops_s2s/SCOPS_INI/CFSR/RUN/CFSR_
download_temp.py > /data02/scops_s2s/SCOPS_INI/CFSR/RUN/temp_imsi.py
python /data02/scops_s2s/SCOPS_INI/CFSR/RUN/temp_imsi.py
rm -f /data02/scops_s2s/SCOPS_INI/CFSR/RUN/temp_imsi.py

# u-component of wind
sed -e s/s/YYYYMMDD/$START_YYYYMMDD/g -e s/e/YYYYMMDD/$END_YYYYMMDD/g /data02/scops_s2s/SCOPS_INI/CFSR/RUN/CFSR_
download_uwnd.py > /data02/scops_s2s/SCOPS_INI/CFSR/RUN/uwnd_imsi.py
python /data02/scops_s2s/SCOPS_INI/CFSR/RUN/uwnd_imsi.py
rm -f /data02/scops_s2s/SCOPS_INI/CFSR/RUN/uwnd_imsi.py

# v-component of wind
sed -e s/s/YYYYMMDD/$START_YYYYMMDD/g -e s/e/YYYYMMDD/$END_YYYYMMDD/g /data02/scops_s2s/SCOPS_INI/CFSR/RUN/CFSR_
download_vwnd.py > /data02/scops_s2s/SCOPS_INI/CFSR/RUN/vwnd_imsi.py
python /data02/scops_s2s/SCOPS_INI/CFSR/RUN/vwnd_imsi.py
rm -f /data02/scops_s2s/SCOPS_INI/CFSR/RUN/vwnd_imsi.py

```

Figure 3.1. Shell script for downloading CFSv2 data.

```

from gdex_api_client import gdex_client as gc
import time
import os

# Set start date and end date =====

sdate = sYYYYMMDD # for bash Shell, ex) 20250901
edate = eYYYYMMDD # for bash Shell, ex) 20250903

#sdate = 20250801
#edate = 20250803

#=====

# Make a function to keep checking if a request is ready. -----
def check_ready(rqst_id, wait_interval=120):
    # Checks if a request is ready.
    for i in range(100): # 100 is arbitrary. This would wait 200 minutes for request to complete.
        res = gc.get_status(rqst_id)
        request_status = res['data']['status']
        if request_status == 'Completed':
            return True
        print(request_status)
        print('Not yet available. Waiting ' + str(wait_interval) + ' seconds.')
        time.sleep(wait_interval)
    return False
#-----

# Download NetCDF file(s) =====
=====

control = {
    'dataset' : 'ds094.0',
    'date' : f'{sdate}0000/to/{edate}1800',
    'param' : 'TMP',
    'level' : 'ISBL:1000/975/950/925/900/875/850/825/800/775/750/700/650/600/550/500/450/400/350/300/250
/225/200/175/150/125/100/70/50/30/20/10/7/5/3/2/1',
    'oformat' : 'netCDF',
    'product' : 'Analysis',
    'gridproj' : 'latlon',
    'griddef' : '720:361:90N:0E:90S:359.5E:0.5:0.5'
}

response = gc.submit_json(control)
print(response)

assert response['http_response'] == 200
rqst_id = response['data']['request_id']

check_ready(rqst_id)
gc.download(rqst_id)

# Purge request
gc.purge_request(rqst_id)

#=====
=====

# move the downloaded data to specific directory
out_dir = "/data02/scops_s2s/SCOPS_INI/CFSR/DATA/temp/"
os.makedirs(out_dir, exist_ok=True)
os.system(f"mv cdas1.*pgrbh.grb2.nc {out_dir}")

# delete *.bat and *.csh files
os.system(f"rm -f *.nc *.bat *.csh")

```

Figure 3.2. Python program for downloading CFSv2 temperature.

```

#!/bin/bash --login

start_date=$(date -d '1 weeks ago last wednesday' +%Y-%m-%d)
end_date=$(date -d 'last tuesday' +%Y-%m-%d)

#start_date="2025-11-15"
#end_date="2025-11-15"

current_timestamp=$(date -d "$start_date" +%s)
end_timestamp=$(date -d "$end_date" +%s)

interval_seconds=$((24*3600))

while (( current_timestamp <= end_timestamp )); do
    date_list+=("${date -d "@$current_timestamp" +%Y%m%d}")
    current_timestamp=$((current_timestamp + interval_seconds))
done

for date in ${date_list[@]}; do
    YYYYMMDD=$date
    YYYY=${date:0:4}
    MM=${date:4:2}
    DD=${date:6:2}
    echo "=====
echo $YYYY $MM $DD
echo "=====

    for region in pacific_ocean indian_ocean atlantic_ocean; do
        outdir_path=/data02/scops_s2s/SCOPS_INI/ARGO/DATA/$region/$YYYY/$MM
        mkdir -p $outdir_path
        wget ftp://ftp.ifremer.fr/ifremer/argo/geo/$region/$YYYY/$MM/${YYYY}${MM}${DD}_prof.nc
        mv /*_prof.nc $outdir_path
    done
done

```

Figure 3.3. Shell script for downloading ARGO data.

### 3.1.2. 앙상블 10개로 구성된 초기장 생산

SCoPS 계절예측에서는 가우시안(Gaussian) 분포를 따르는 5개의 섭동장(perturbation)을 이용하여 매월 1, 5일에 해당하는 초기장에서 각 5개의 앙상블을 생성하여 총 10개의 앙상블 멤버를 구성하고 있다. 그러나 계절내예측에서는 초기장 날짜로부터 예측 타겟 기간까지의 선행 시간에 민감하게 반응하고 예측시작일부터의 0주 예측장도 사용될 수 있기에 계절예측에서 사용된 방법인 5일 간격의 시간지연을 이용한 앙상블 구성이 적절하지 않을 것으로 판단된다.

따라서 계절내예측에서는 기존 생산된 hindcast 계절내예측 5개 앙상블 초기장을 이용하여 같은 날짜의 forcing, rerun 파일을 사용하고 restart 파일만 하루 시간지연을 시켜 forecast 앙상블 10개를 구성하였다. 즉 hindcast 끝 기간의 2016년 12월 31일 forcing, rerun 파일을 2016년 12월 31일과 2017년 1월 1일의 restart 파일과 대응시켜 모델 적분을 이어나가서 현재까지의 초기장을 생성하는 방법이다. Figure 3.4는 앞서 설명한 내용에 대한 모식도이다. 2016년 12월 31일 restart 파일을 사용하여 생성된 초기장 앙상블은 1, 3, 5, 7, 9의 홀수로 지정하였고, 2017년 1월 1일 restart 파일을 사용한 것은 2, 4, 6, 8, 10의 짝수로 지정하였다. 짝수 앙상블의 경우는 기존 hindcast 5개 앙상블에 대응하여 계속해서 초기장이 생성되는 것으로 생각할 수 있다. 이렇게 2017년 1월 1일부터 계속해서 현재까지 10개 앙상블 초기장을 생성하게되며 2025년 1월부터 매주 화요일 초기장 10개 앙상블을 사용하여 60을 예측을 수행하게 된다.

❖ 10개 앙상블 적용 forecast 생산

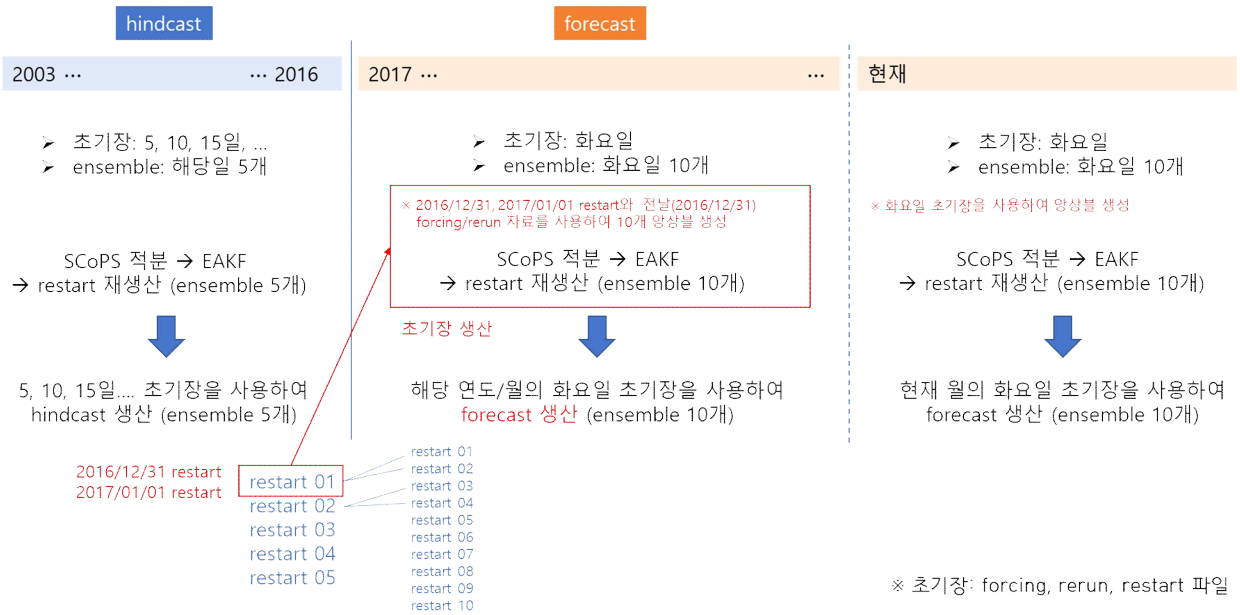
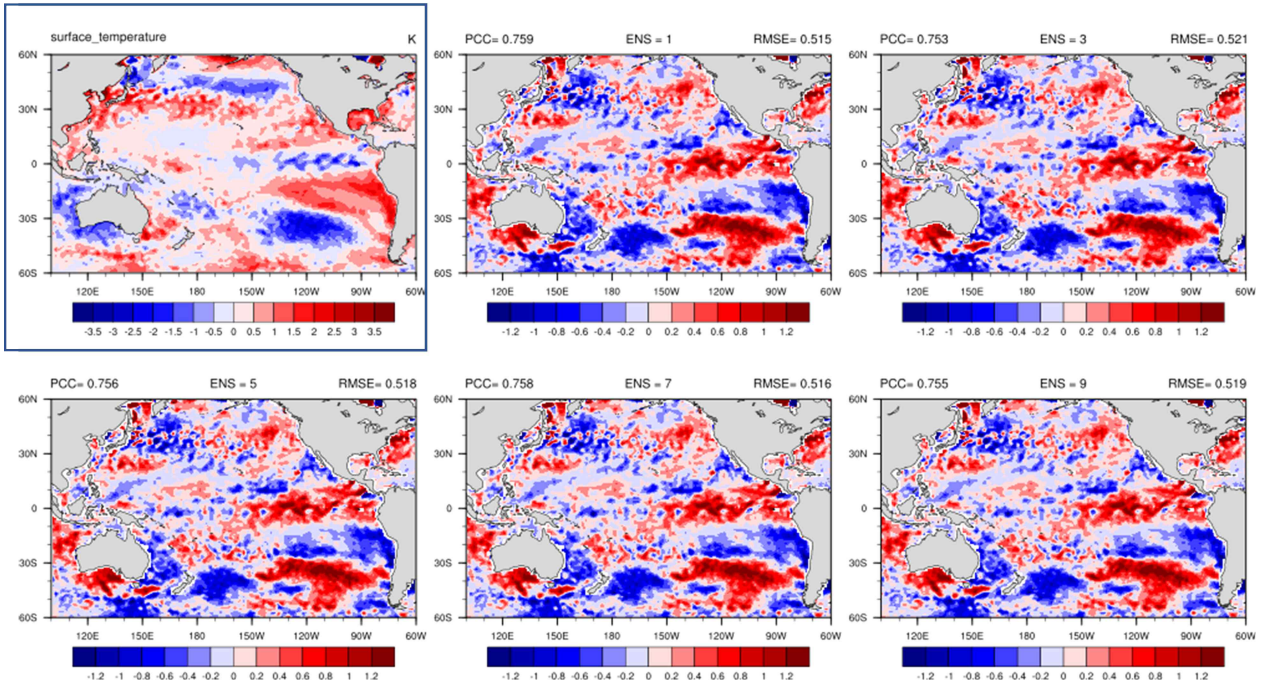


Figure 3.4. Schematic diagram for generating 10 ensemble initial conditions and performing forecasts.

Figure 3.5는 2017년 1월 1일의 CFS 분석장과 SCoPS 10개 앙상블 restart 파일의 해수면은도에 대한 PCC, RSME, DIFF (difference)를 계산한 결과이다. 위쪽은 그림은 1, 3, 5, 7, 9 홀수 앙상블, 아래쪽은 2, 4, 6, 8, 10 짝수 앙상블을 나타낸다. 홀수 앙상블에는 2016년 12월 31일 restart 파일을 사용했기 때문에 짝수 앙상블과 비교하여 상대적으로 PCC는 낮고 RMSE는 높고 DIFF는 크게 나타나는 것을 볼 수 있다. 하지만 5일 적분이 진행된 2017년 1월 5일의 결과를 보면(Figure 3.6), 홀수와 짝수 앙상블의 PCC, RMSE, DIFF 값이 모두 비슷한 것을 볼 수 있다. 따라서 시간이 지나면서 초기장 적분에 대한 하루 시간지연의 차이가 줄어들어가는 것을 알 수 있다.

YEAR = 2017 MON = 1 DAY = 1



YEAR = 2017 MON = 1 DAY = 1

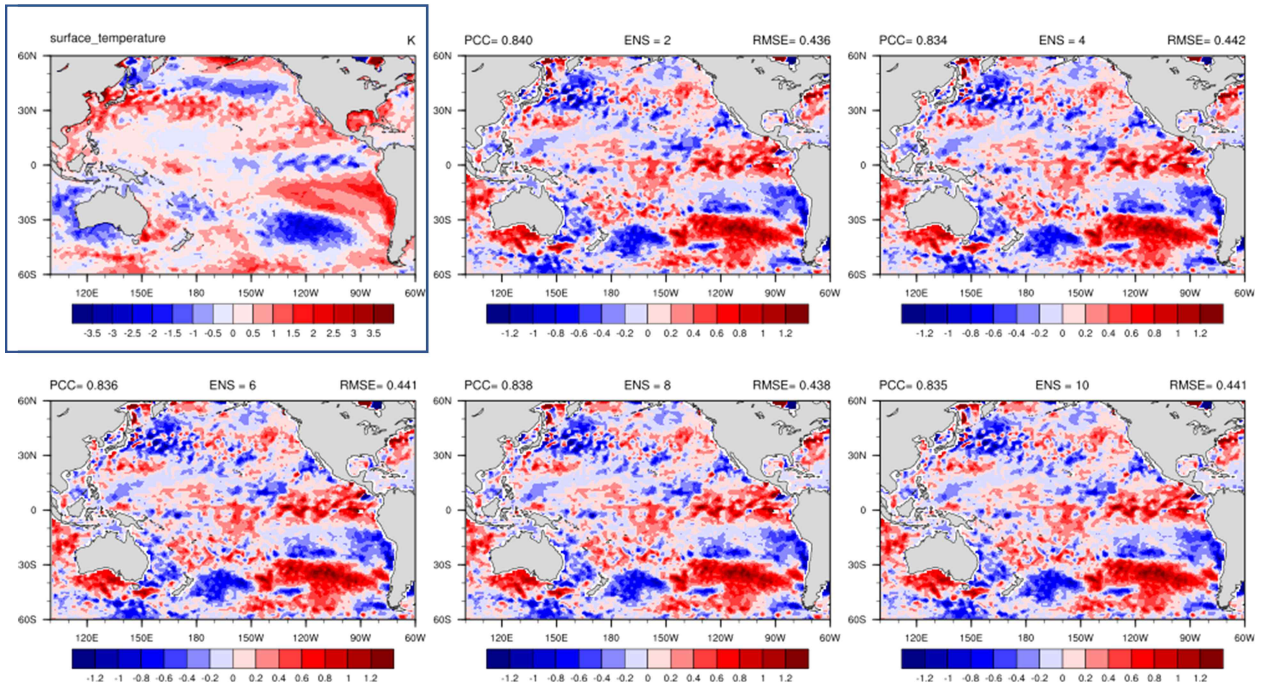
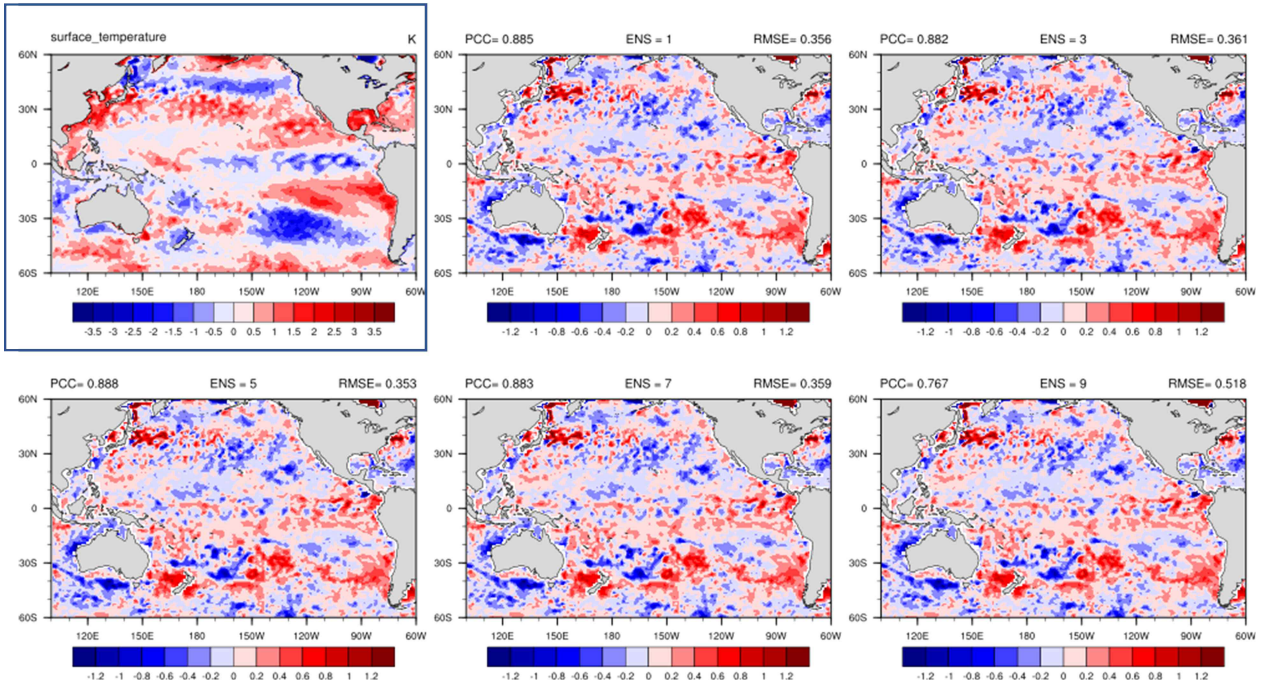


Figure 3.5. Comparison of PCC, RMSE, and DIFF (difference) for sea surface temperature between the CFS analysis and the 10-member ensemble SCoPS restart files on January 1, 2017.

YEAR = 2017 MON = 1 DAY = 5



YEAR = 2017 MON = 1 DAY = 5

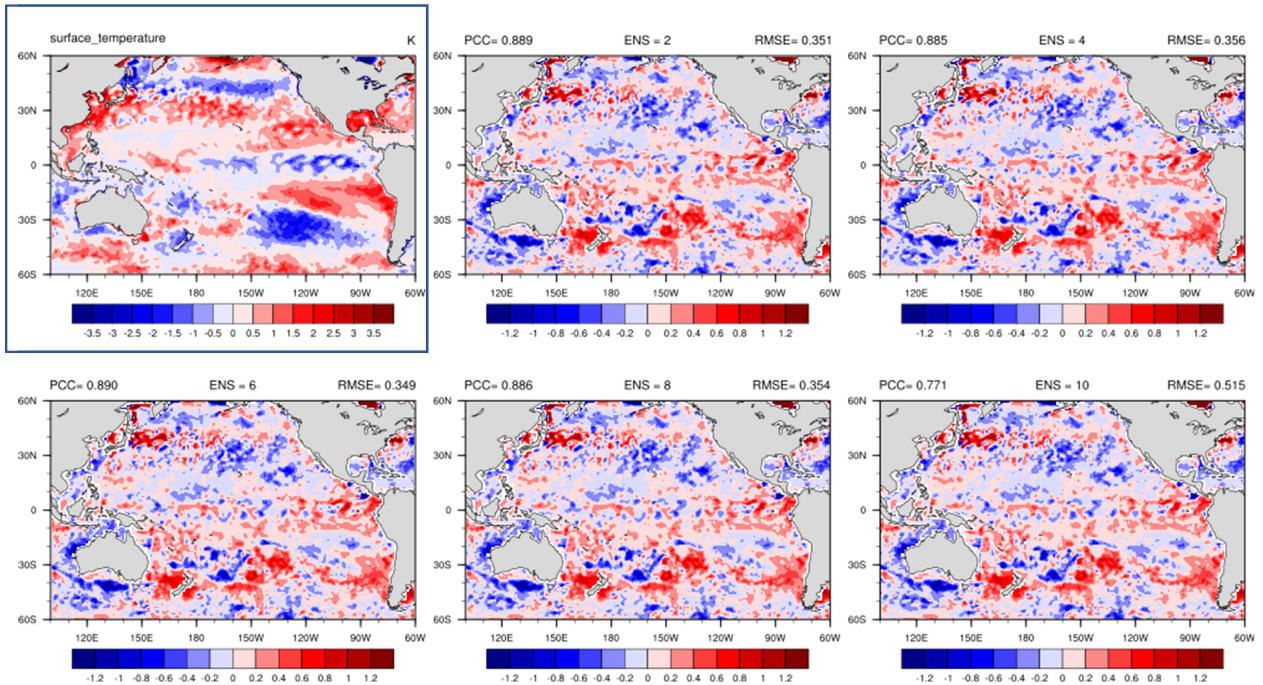


Figure 3.6. Comparison of PCC, RMSE, and DIFF (difference) for sea surface temperature between the CFS analysis and the 10-member ensemble SCoPS restart files on January 5, 2017.

Figure 3.7과 3.8은 2017년 1월 5일 초기장을 이용한 60일 예측장에서 Nino3.4 지수와 Nino3.4 지역평균 해수면온도, 그리고 동아시아 지역평균 강수, 기온, 500hPa 지위고도, 해수면 온도의 앙상블 분포를 보여준다. 빨간색 실선은 1, 3, 5, 7, 8 홀수 앙상블, 파란색 실선은 2, 4, 6, 8, 10 짝수 앙상블, 그리고 검은색 점선은 2003~2016년 기간 동안의 hindcast 5개 앙상블 평균을 나타낸다. 선행시간 1일을 시작으로 해서 시간이 지나면서 60일까지 앙상블 스프레드가 적절하게 분포하는 것을 볼 수 있다. 동아시아 지역평균 그림에서도 강수, 기온, 500hPa 지위 고도, 해수면온도의 앙상블 스프레드가 골고루 분포하는 것을 볼 수 있다.

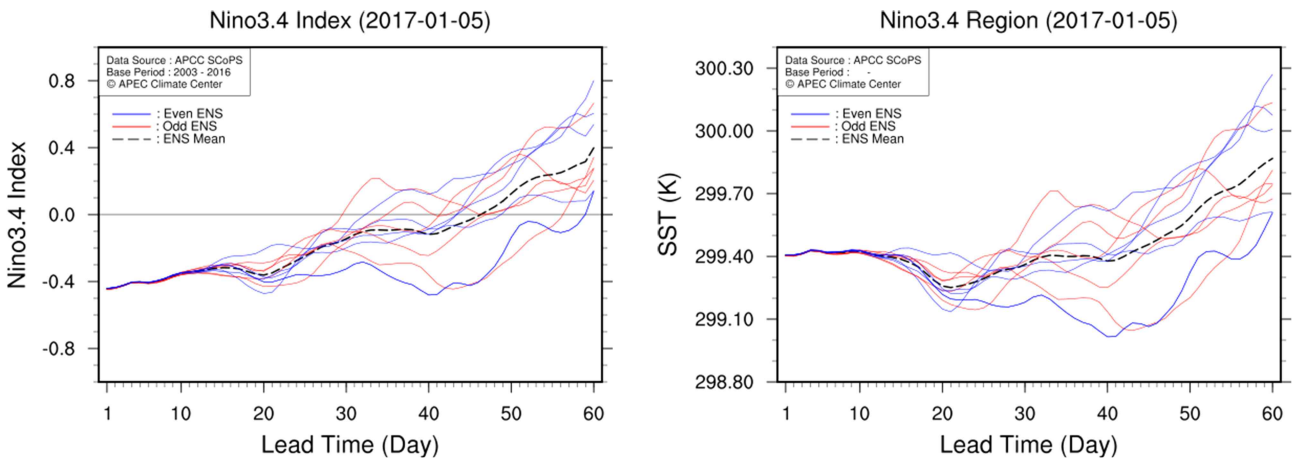


Figure 3.7. Ensemble distribution of the Nino3.4 index and the Nino3.4 region-averaged sea surface temperature in the 60-day forecast initialized on January 5, 2017.

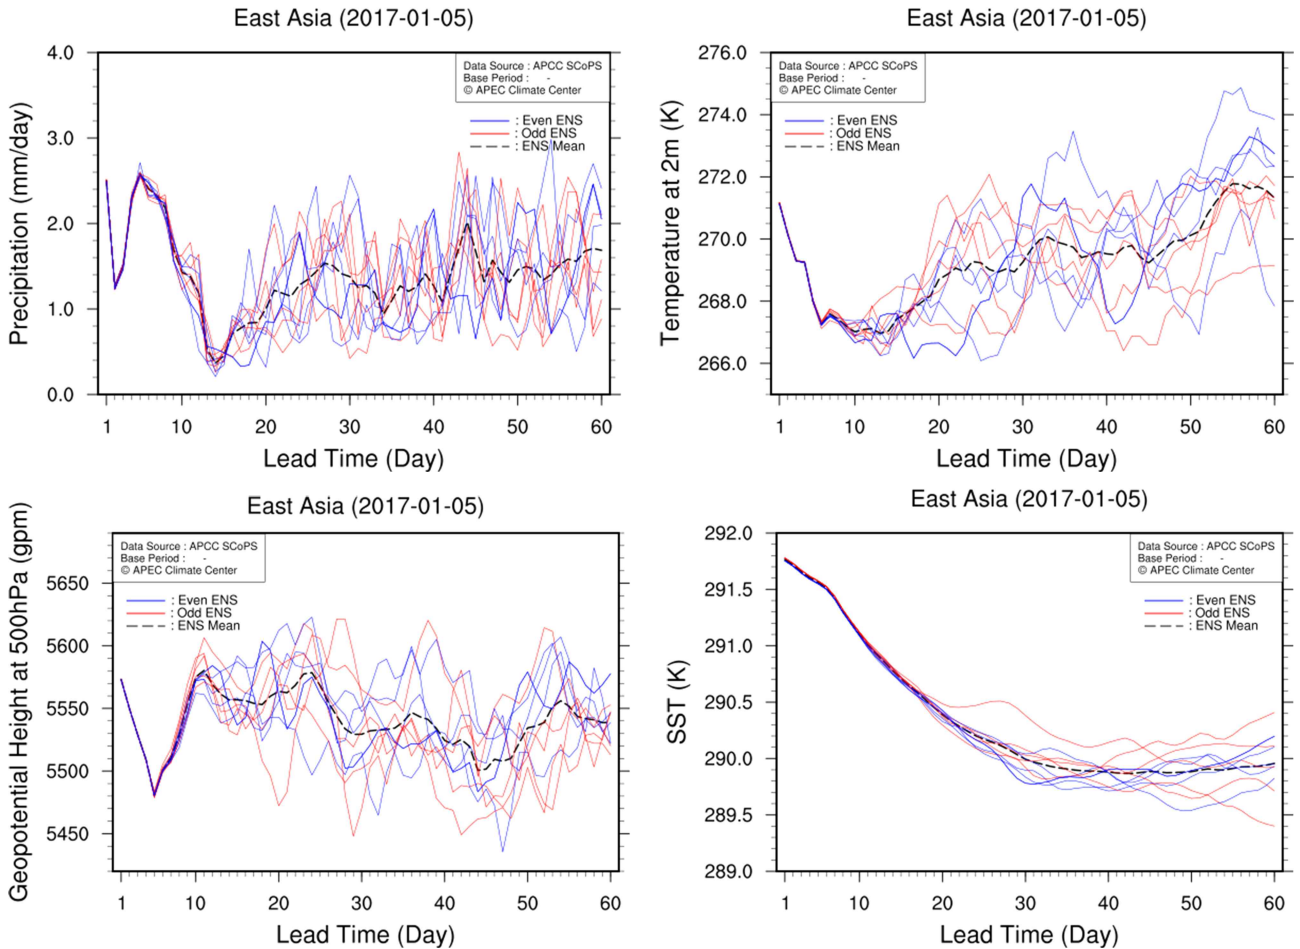
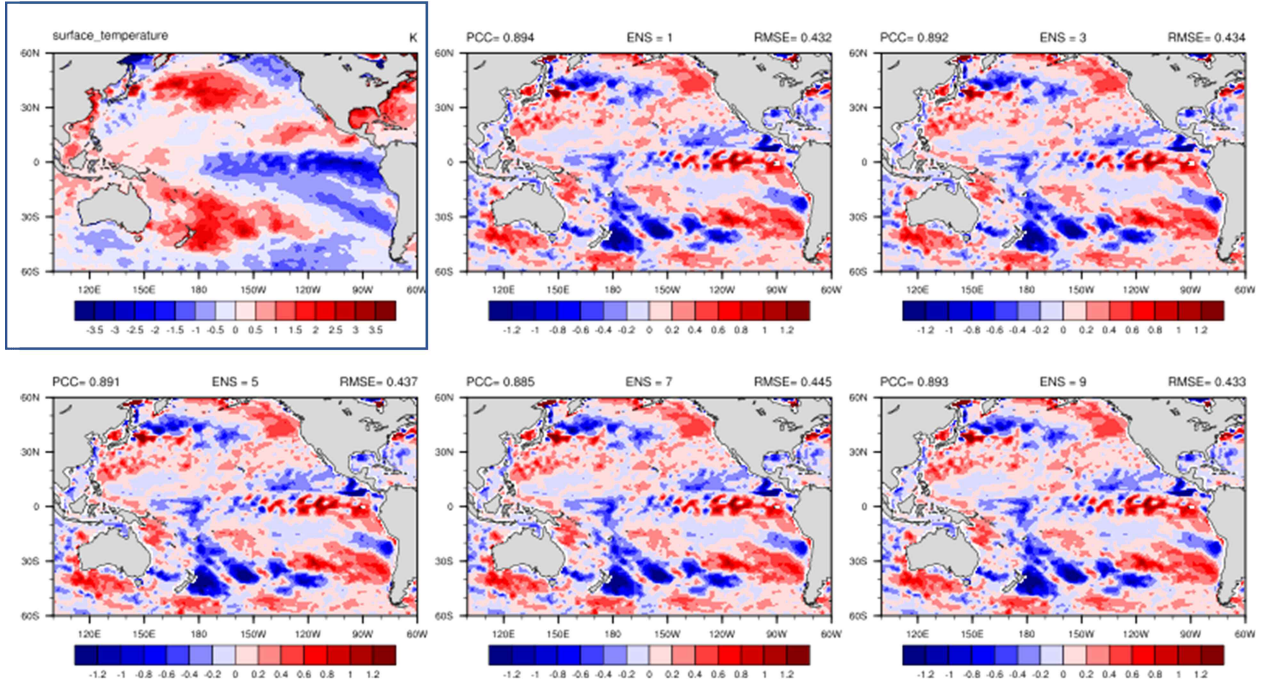


Figure 3.8. Ensemble distribution of the East Asia region-averaged precipitation, temperature, geopotential height at 500hPa, and sea surface temperature in the 60-day forecast initialized on January 5, 2017.

Figure 3.9~3.11은 앞서 기술한 것과 같이 2022년 1월 1일의 초기장을 사용한 60일 예측장의 앙상블 분포를 나타낸다. 여기에서도 앞선 그림과 마찬가지로 앙상블 분포가 적절하게 나타나고 있음을 볼 수 있다. 따라서 2016년 12월 31일 forcing, rerun 파일을 2016년 12월 31일과 2017년 1월 1일의 restart 파일과 대응시켜 모델 적분 이어나가면서 10개의 앙상블 초기장을 생성하는 방법이 적절하게 구현되고 있음을 알 수 있다.

YEAR = 2022 MON = 1 DAY = 1



YEAR = 2022 MON = 1 DAY = 1

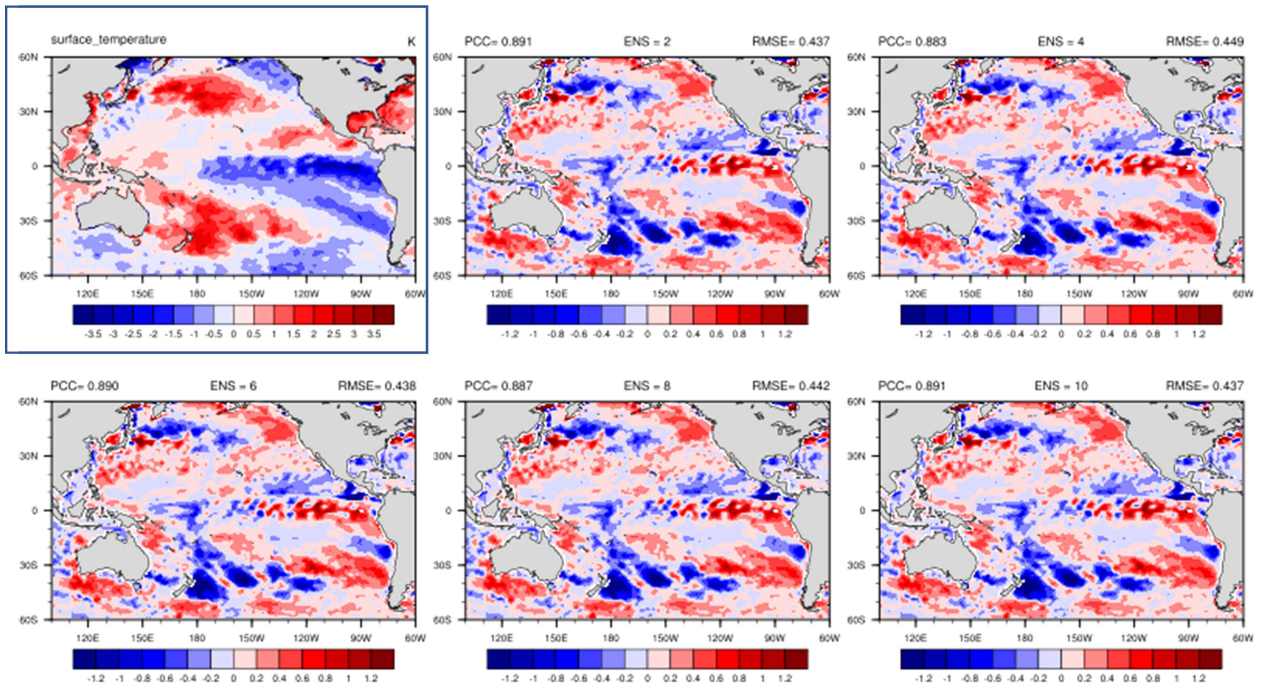


Figure 3.9. Comparison of PCC, RMSE, and DIFF (difference) for sea surface temperature between the CFS analysis and the 10-member ensemble SCoPS restart files on January 1 2022.




Figure 3.10. Ensemble distribution of the Nino3.4 index and the Nino3.4 region-averaged sea surface temperature in the 60-day forecast initialized on January 1, 2022.

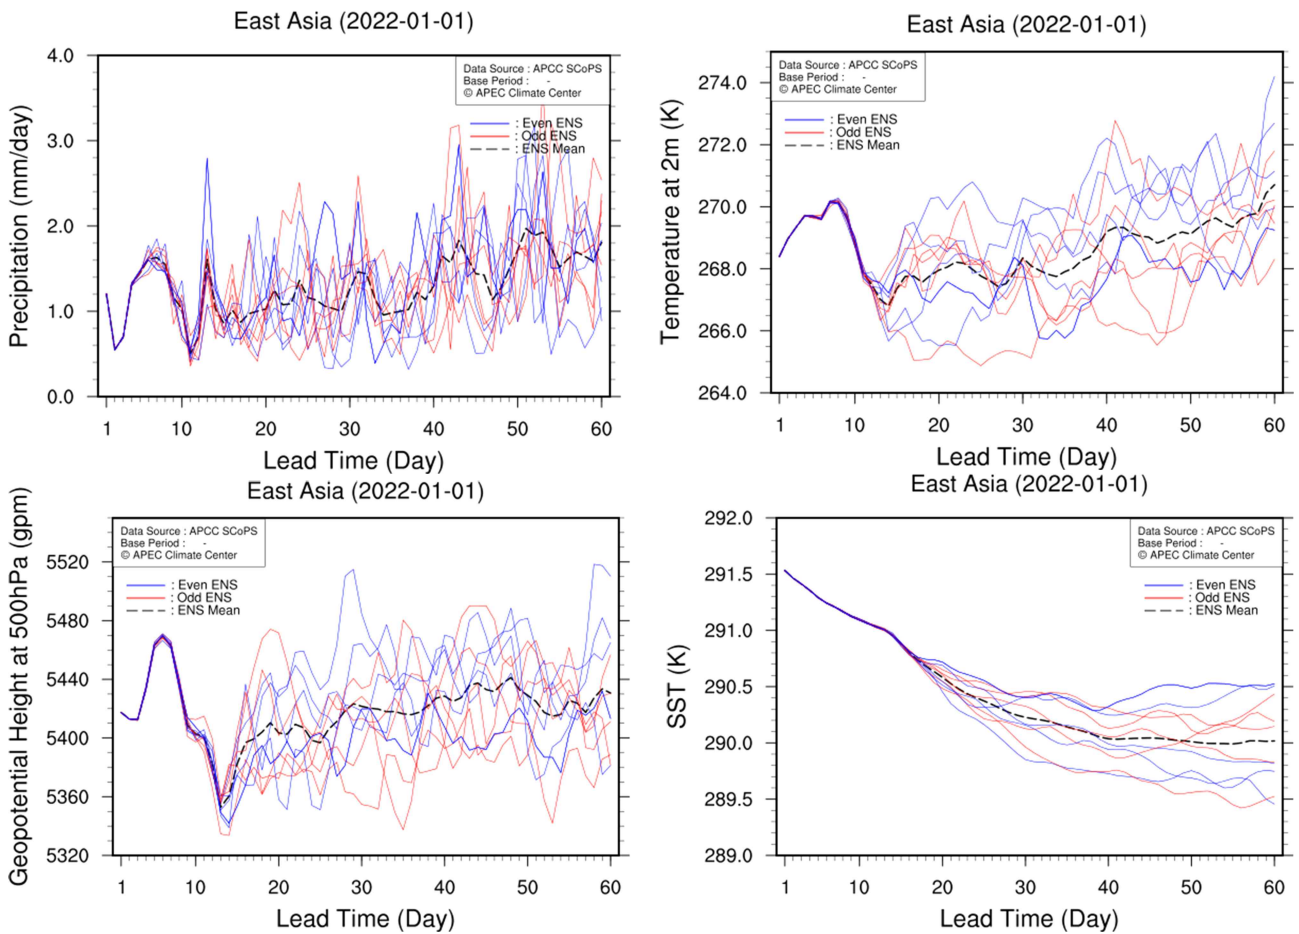


Figure 3.11. Ensemble distribution of the East Asia region-averaged precipitation, temperature, geopotential height at 500hPa, and sea surface temperature in the 60-day forecast initialized on January 1, 2022.

### 3.1.3. 초기장 및 60일 예측장 생산(매주 운영)

3.1.2에서 기술한 바와 같이 2017년 1월 1일부터 현재까지 초기장을 생산하고 있으며, 매주 화요일 초기장을 사용하여 60일 예측을 수행하고 있다. 계절예측과 다르게 매주 일주일 단위(지난 주 수요일 ~ 이번 주 화요일)의 CFS 분석장과 ARGO 해양관측 자료를 매주 목요일에 다운로드해서 초기장을 생산하고 이어서 예측장을 생산하게 된다.

일주일 분의 초기장 생산에 약 3시간 정도, 예측장 생산에는 약 10시간 정도, 예측장 후처리에는 약 2시간 정도 소요된다. 따라서 SCoPS 계절내예측 화요일 예측시작 자료 매주 금요일에 후처리까지 완료가 되며, MME 입력자료를 위한 전처리를 거쳐서 MME를 수행하게 된다. 즉, SCoPS에서 이번 주 화요일 초기장을 사용한 예측자료가 생산되면 실제 MME 계절내예측은 다음 주 월요일부터 시작하는 4주 MME 예측이 수행되게 된다.

향후 CFS 분석장과 ARGO 해양관측 자료를 대체한 초기장 개선 작업이 이루어지고 또한 HPC 성능 개선이 이루어진다면 화요일에서 목요일로의 선행시간을 좀 더 앞당겨 자료를 생산할 수 있을 것으로 기대해 본다.

## 3.2. 지면초기화 기술 개발

### 3.2.1. 개발 배경 및 목적

#### 3.2.1.1 연구 배경

계절내-계절(S2S) 예측은 2주에서 수개월 규모의 전망을 통하여 농업, 수자원 관리, 재난 대응 등 사회경제적 의사결정에 필수적인 정보를 제공한다. 특히 폭염, 가뭄, 집중호우 등 극한 기상은 농작물 생육 및 에너지 수요에 직접적인 영향을 미치므로, 2-4주 전부터 신뢰성 있는 예측이 요구된다. 그러나 S2S 규모는 중기 규모(~10일)와 계절 이상 규모 사이의 예측성 공백(predictability gap) 구간으로 알려져 있다. 이 구간에서는 대기 초기 조건의 영향이 빠르게 소멸하는 반면, 해수면 온도(SST) 등 느린 변화 성분의 영향은 아직 충분히 발현되지 않아 예측성능이 급격히 저하된다.

최근 연구들은 토양 수분이 S2S 예측성 공백을 완화할 수 있는 중요한 예측 인자임을 제시하였다. 토양 수분은 지면-대기 간 에너지 및 수분 교환을 조절하며, 그 메모리 시간 규모가 수 주에서 2개월로 S2S 예측 기간과 일치하여 초기 조건이 예측 기간 전반에 걸쳐 영향을 미칠 수 있다(Koster et al., 2010; Dirmeyer et al., 2013). 토양 수분은 증발산(evapotranspiration)을 통해 지표 에너지 수지를 조절하며, 이는 기온 및 강수 변동성에 영향을 준다. 특히 북미 Great Plains, 유럽 지중해 연안, 아프리카 사헬 등 반건조 기후의 전이대(transition zone)에서 지면-대기 결합(land-atmosphere coupling)이 강하며, 이 지역의 여름철 폭염 및 가뭄 예측에 토양 수분 초기화가 필수적이다(Seneviratne et al., 2010). 다중모델 결과들은 토양 수분 초기화가 북미 여름철 기온 예측 상관계수를 향상시키고(Koster et al., 2011), 유럽 폭염 예측에 유의한 기여함을 확인하였다(van den Hurk et al., 2012).

#### 3.2.1.2 APCC SCoPS 계절내예측시스템 개발 현황

APCC는 아시아-태평양 지역 기후 예측 및 서비스를 위해 SCoPS 계절내예측시스템을 운영하고 있다. SCoPS는 결합 대기-해양-해빙 모델 기반으로 2주-6개월 규모의 예측 정보를 생산하며, APCC MME(Multi-Model Ensemble)에 활용된다. 시스템은 ECHAM5 대기 모델(T159 해상도, ~75 km) (Roeckner et al., 2003), POP2 해양 모델(1도 해상도) (Smith et al 1992), CICE4 해빙 모델(1도 해상도) (Hunke and Lipscomb 2010)로 구성되며, 초기 날짜별로 5개의 앙상블 멤버를 갖는다. 현재 SCoPS 지면 초기 조건은 기후값(climatology) 기반으로 설정되며, 실시간 관측이나 재분석 정보를 반영하지 않는다. 월별 평년값을 사용하는 이 방식은 예측 시작일의 토양 수분 이상(anomaly)을 반영하지 못하여, 실제 상태와 큰 괴리를 보인다. 이러한 초기 조건 오차는 모델이 초기 2-4주간 spin-up에 소모되어 예측 가능 기간을 단축시키며, 토양 수분 이상과 밀접히 연관된 폭염/가뭄 등 극한 기상을 포착할 수 없게 만든다.

국제적 지면 초기화의 표준화 추세를 고려하여, APCC는 2024년부터 SCoPS 시스템 고도화 및 계절내예측시스템 개발 계획을 수립하였으며, 초기화 과정 개선을 핵심 개선 과제로 선정하였다. S2S 프로젝트에 참여하는 13개 센터는 이미 대부분 지면 초기화를 적용하고

있다(Table 3.1). CPTEC을 제외한 나머지 기관들은 LDAS-기반 SEKF 자료동화 기법(2개), 오프라인 지면 모델(4개), 지면 분석장(3개), 대기 넷징에 의한 간접 초기화(3개)를 활용하고 있다. APCC SCoPS는 기후값이나 간접초기화와 마찬가지로 지면 초기화를 적용하지 않는 시스템이기 때문에, 계절내 예측 성능을 국제 수준으로 향상시키기 위해 지면 초기화 개발은 필요한 상황이다.

Table 3.1. Land surface initialization methods for soil moisture in S2S project participating institutions. (website=<https://confluence.ecmwf.int/display/S2S/Models>)

Institute	Model Version	Resolution	Rfc period	Initialization of land surface (soil moisture)
CPTEC	BAM-1.2	TQ126 L42	1999-2018	Climatology
BoM	POAMA P24	T47 L17	1981-2013	Atmospheric nudging response (ERA-Interim)
IAP-CAS	CAS-FGOALS-f2-V1.4	C96 L32	1999-2018	Atmospheric nudging response (ECMWF)
CMA	BCC-CPS-S2Sv2	T266 L56	past 15 years	Atmospheric nudging response (ECMWF)
CNRM	S2S-SYS3	T359 L137	1999-2024	Realistic (ERA5)
CNR-ISAC	GLOBO	0.7° x0.5° L70	2001-2020	Realistic (GEFS)
NCEP	CFSv2	T126 L64	1999-2010	Realistic (CFSR + GLDAS)
ECCC	GEPS 8	0.25° L85	2001-2020	Offline forced run (ERA5)
KMA	GloSea6-GC3.2	N216 L85	1993-2016	Offline forced run (ERA5)
JMA	CPS3	T1319 L100	1991-2020	Offline forced run (JRA-3Q)
UKMO	GloSea6	N216 L85	1993-2016	Offline forced run (JRA-55)
HMCR	RUMS	0.9° x0.72° L70	1991-2020	Realistic (SEKF)
ECMWF	CY49R1	~32km	past 20 years	Realistic (LDAS-based SEKF)

### 3.2.1.3 연구 목적 및 범위

본 연구의 목적은 APCC SCoPS 계절내예측시스템에 토양 수분 초기화 체계를 구축하고, 북반구 여름철에 대한 14년(2003-2016) hindcast 실험을 통해 계절내규모 예측 성능 개선 효과를 정량적으로 평가하는 것이다. 세부 목적으로 첫째, 전 지구 지면 분석 자료 수집 및 토양 수분 변환(전처리), EAKF 기반 토양 수분 초기화 알고리즘 구현, APCC HPC 환경에 최적화 및 효율적 운영을 포함하는 프로토타입의 초기화 시스템 개발이다. 둘째, 토양 수분장 수렴 특성 및 초기 조건 품질 평가, 토양 수분 메모리 지속성 및 공간 분포 분석, 지면-대기 결합 강도 변화 진단을 통한 초기화 효과 정량화이다. 셋째, 전 지구 및 지역별 기온 예측 개선도 정량화, 리드타임별 성능 변화 분석, 강수 예측 영향 평가를 통한 예측 성능 평가이다.

### 3.2.2. 데이터 및 방법

본 연구에서 개발한 토양 수분 초기화 시스템은 다양한 지면 재분석 자료의 수집 및 전처리, EAKF 기반 동화 알고리즘 구현, HPC 환경에서의 운영 체계 구축의 세 단계로 구성된다. 본 절에서는 각 단계의 기술적 세부 사항과 방법론을 기술한다.

#### 3.2.2.1 입력 자료 구축

##### 3.2.2.1.1 다중 지면 분석 자료의 특성과 선택 기준

토양 수분 초기화를 위한 지면 분석장으로 수집이 가능한 전 지구 지면 분석 자료를 조사하였다(Table 3.2). NASA의 MERRA2는  $0.5^{\circ} \times 0.625^{\circ}$  해상도의 Catchment Land Surface Model (CLSM) 기반으로 뿌리층(Root Zone)에 대한 토양 습윤도[0-1, unitless]를 제공하며, 1980년부터의 장기간 안정적 품질을 특징을 보인다. NCEP의 CFSv2는  $0.5^{\circ}$  해상도의 Noah Land Surface Model (LSM) 기반으로 4개층(0-10, 10-40, 40-100, 100-200 cm)의 체적 토양 수분을 6시간 간격으로 제공한다. ECMWF의 ERA5-Land는  $0.1^{\circ}$  해상도(약 9 km)의 HTESSEL 지면 모델 기반으로 4개 토양층(0-7, 7-28, 28-100, 100-289 cm)의 체적 토양 수분[volumetric soil moisture,  $m^3 m^{-3}$ ]을 1시간 간격으로 제공한다. ECMWF의 IFS와 GLDAS의 경우 Hindcast 실험 기간 범위(2003-2016년)와 안정적인 현업 운영을 위한 짧은 Data latency (1주일 미만)를 고려하여 후보에서 제외하였다.

예비 평가 결과 ERA5-Land 데이터를 주 분석장으로 채택하였다(Figure 3.12). 선택 근거는  $0.1^{\circ}$  해상도로 MERRA2와 ERA5-Land, CFSR 데이터 중 가장 상세한 해상도를 가지며, 다수 선행 연구에서 우수성이 입증되었다. 또한, 약 5일의 짧은 Data latency와 상세한 시간 간격으로 일변화(diurnal cycle)를 재현할 수 있다는 점이 있다. 그럼에도 불구하고, MERRA2와 CFSv2는 비교 검증용으로 활용하기 위해 병행하여 처리하였다. CFSv2는 Data latency (약 1일)가 가장 짧지만 곧 서비스가 중단될 수 있으므로, 초기화 체계의 안정적인 운영을 고려하여 후보에서 제외하였다.

Table 3.2. Comparison of global land surface reanalysis datasets for soil moisture initialization.

Name/Institution	Temporal Coverage/Scale	Spatial Scale	Data Latency	Type and Unit of Soil Moisture
NASA MERRA2	1980 to present / 1 hr	0.5° × 0.625°	~1 month	“Unitless Soil Wetness (in fraction)” name = GWETROOT (for Root-Zone)
NCEP/NCAR CFSR (CFSv2)	1979 to present / 6 hr (real-time CFSv2 from 2011) 7 days available (real-time)	50 km 0.2° × 0.2°	monthly update ~1day	“Volumetric soil water” name = soilm[1-4], unit = m <sup>3</sup> m <sup>-3</sup> vertical layers = 0, 0.1, 0.4, 1, 2 m
ECMWF ERA5 Land	1950 to present / 1 hr	0.1° × 0.1°	~5 days	“Volumetric soil soilwater” name = swvl[1-4], unit = m <sup>3</sup> m <sup>-3</sup> vertical layers = 0, 0.07, 0.28, 1, 2.89 m
ECMWF IFS	2016 to present / 6 hr	0.07° × 0.07°	~5 days	“Volumetric soil soilwater” name = swvl[1-4], unit = m <sup>3</sup> m <sup>-3</sup> vertical layers = 0, 0.07, 0.28, 1, 2.89 m
NASA GLDAS Noah	2000 to present / 3 hr Early Product (~2 months)	0.25° × 0.25°	2 months 2 weeks	“Volumetric soil soilwater” name = SoilMoi_cm_inst, unit = kg m <sup>-2</sup> vertical layers = 0, 0.1, 0.4, 1, 2 m

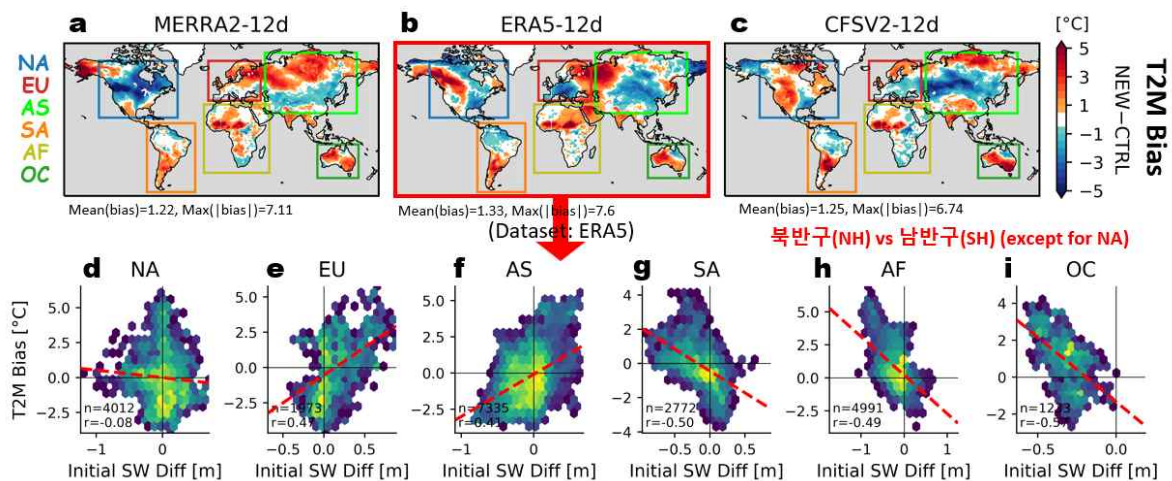


Figure 3.12. Sensitivity of initial soil wetness differences and temperature forecast bias to initialization timing and dataset choice (January 2014 case).

### 3.2.2.1.2 토양 분류 체계 차이와 공극률 산정

지면 데이터 수집은 Python 기반 스크립트를 작성하여 진행하였다. 각 데이터는 서로 층별 토양 깊이가 다르므로 층별 가중 평균을 적용하여 지면부터 1 m까지의 깊이에 해당하는 뿌리층(root zone)으로 통합하여 변환하였다. 또한, SCoPS의 지면 과정과 재분석 자료는 서로 다른 토양 분류(soil texture)와 공극률(porosity) 체계를 사용하므로 토양 수분 단위 변환 과정에서 신중하게 접근해야 한다. 예를 들어, SCoPS는 FAO Soil Texture Classification 기반 5개 유형(Coarse, Medium-Coarse, Medium, Medium-Fine, Fine)을 사용하며, ERA5-Land는 7개 유형(Coarse, Medium, Medium-Fine, Fine, Very Fine, Organic, Loamy)으로 세분화한다(Figure 3.13). 주요 차이점은 세분화 정도에서 ERA5-Land가 Fine을 Fine/Very Fine으로 세분하고 Organic 토양을 별도 분류하며, 공극률 범위가 더 넓고(0.403-0.766 vs 0.404-0.465), 면적 분포에서 Fine 토양 비율이 ERA5에서 1.5배 높으며(15.7% vs 10.5%), Organic과 Very fine, Loamy 토양 분류가 ERA5에만 별도로 존재(4.1%, 0.5%, 0.3%)한다는 점이다.

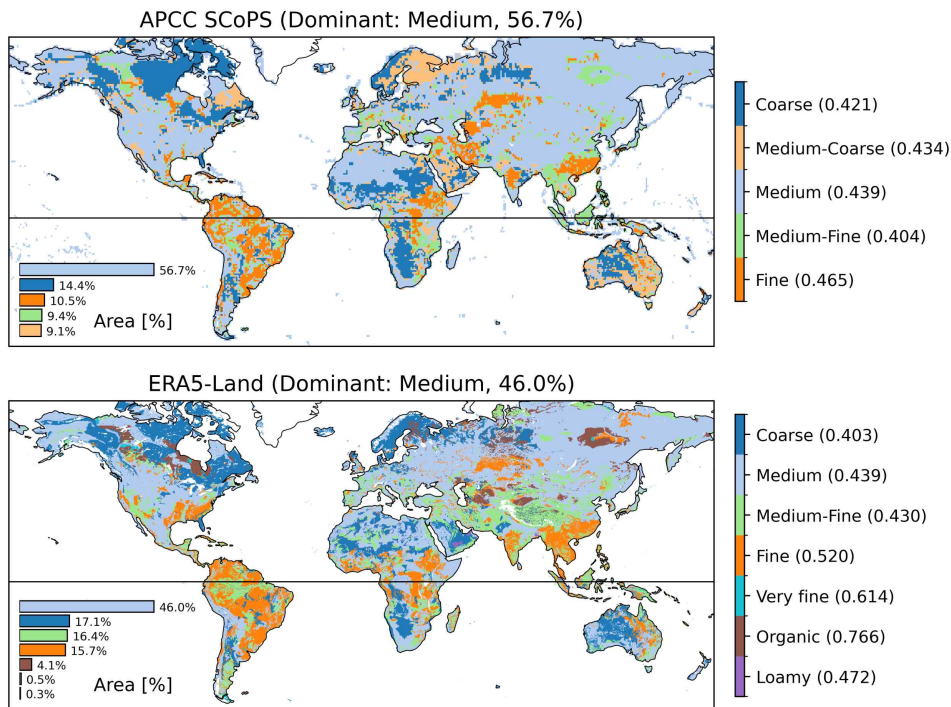


Figure 3.13. Spatial distribution of soil texture classes and corresponding porosity values in APCC SCoPS and ERA5-Land.

정교한 공극률 산정도 본 연구의 토양 수분 단위 변환의 핵심 매개변수이다. SCoPS 공극률은 Zobler (1986) 제안을 기반으로 산정하였으며, 공극률 공간 분포는 SCoPS가 5개 이산값(0.404-0.465)으로 대륙 규모 균질 분포를 보이는 반면, ERA5-Land는 7개 이산값(0.403-0.766)으로 고해상도 이질 분포를 나타낸다. 차이가 큰 지역은 북유럽(Organic 토양)과 아프리카 사헬(토양 분류 불일치)이다. 주요 지역별 특징은 사막 지역(Sahara,

Arabian)의 낮은 공극률(0.40-0.42, 모래질), 농업 지역(Great Plains, 팜파스)의 중간 공극률(0.43-0.44), 점토 지역(인도 Deccan, 중국 Loess Plateau)의 높은 공극률(0.46-0.52), 북유럽 습지의 매우 높은 공극률(Organic)이다.

### 3.2.2.1.3 토양 수분 단위 변환 체계의 구축과 검증

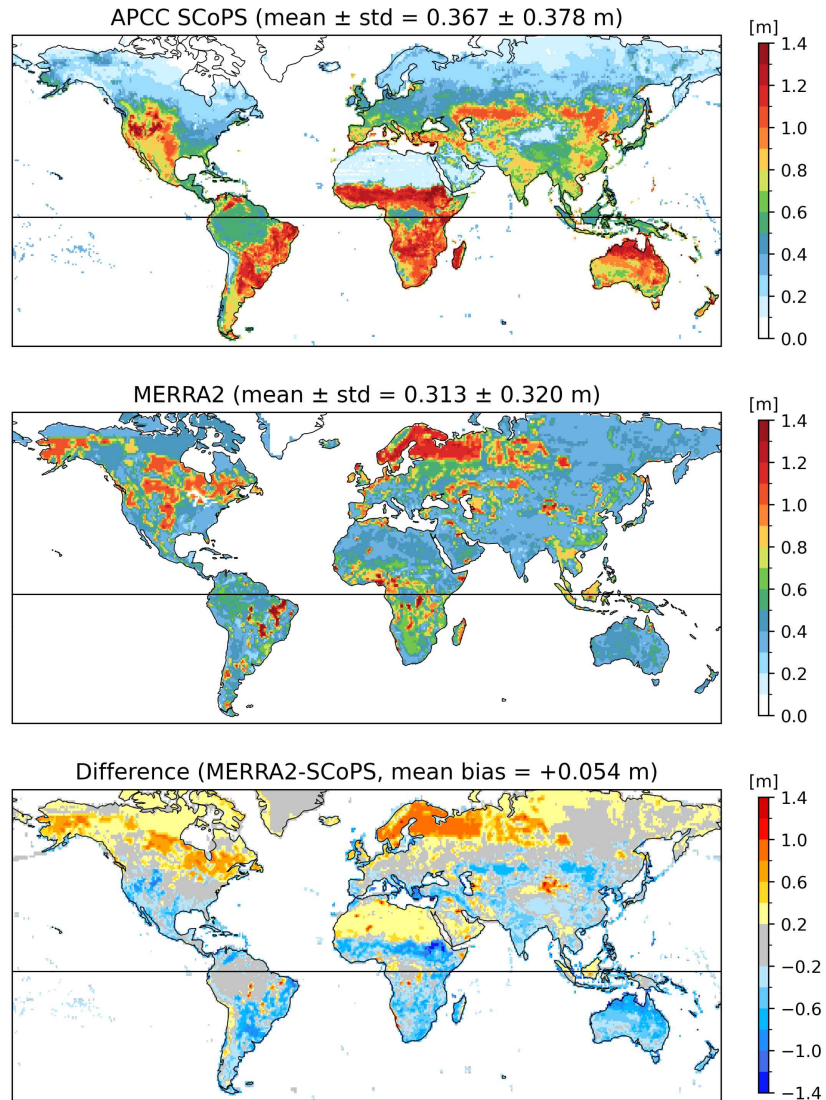


Figure 3.14. Comparison of maximum soil water capacity between MERRA2 and APCC SCoPS configurations.

공극률 외에도 재분석 자료의 체적 수분(volumetric soil moisture)  $[m^3 m^{-3}]$  형태를 SCoPS의 수분 포화 깊이(soil wetness, WS)  $[m]$  형태로 변환하려면 격자화된 최대 포화 함량(maximum water holding capacity, WSMX)  $[m]$ 의 분포가 필요하다(Figure 3.14). SCoPS는 단일 bucket 모델로 토양 수분을 수분 포화 깊이인  $m$  단위로 표현하며, 이는 토양층 내 수분의 증가 깊이를 의미한다. 포화 깊이의 물리적 범위는  $0 \leq WS \leq WSMX$ 이며, WSMX는 토양층

깊이×포장 용수량(field capacity)으로 계산된다. 예를 들어 1m 깊이 토양에서 포장 용수량이 0.283이면 WSMX가 0.283 m이고, 0.200 m의 WS는 70% 포화 상태를 의미한다. 본 연구는 SCoPS의 WSMX 분포(Hagemann, 2006)를 MERRA2가 제공하는 WSMX 분포로 대체하였다.

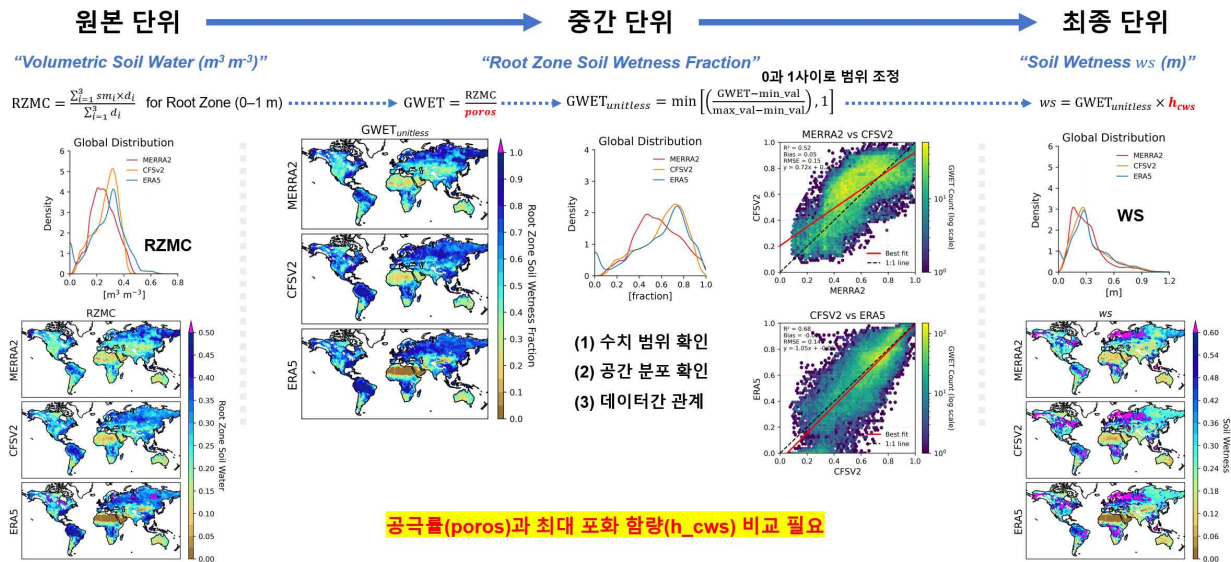


Figure 3.15. Data conversion workflow for land surface initialization from reanalysis to model data.

단위 변환은 3단계로 진행된다(Figure 3.15). 첫 번째 단계에서는 뿌리층(root zone)에 대한 체적 수분(Volumetric Soil Moisture) [ $m^3 m^{-3}$ ]을 1m 깊이까지 통합한다. MERRA2는 이미 Root Zone Soil wetness (GWET)라는 변수를 제공하기 때문에 그대로 사용한다. 두 번째 단계에는 격자마다 고유의 공극률을 나누어 Root Zone Soil Wetness Fraction (GWET) [0-1]의 형태로 정규화하며, 물리적 의미는 유효 수분 용량 대비 현재 수분 비율이다. 마지막 단계는 WSMX (또는  $h_{cws}$ )를 GWET에 곱하여 수분 포화 깊이로 변환한다.




Figure 3.16. Time series comparison of area-weighted global mean soil wetness by region for validation of soil moisture unit conversion across datasets (MERRA2, ERA5, CFSv2).

단계별 변환 과정에 대한 검증은 위해 공간 분포 비교, 전지구 평균 시계열, 지역별 검증을 통해 수행하였다. Figure 3.16은 2013년 12월 1일부터 2014년 5월 1일까지 4개월간 원본 단위와 최종 단위에 대한 전지구 및 주요 대륙에 대한 평균 시계열을 비교한다. 원본 ERA5는 중위도 0.2-0.4, 건조 지역 < 0.2를 나타냈고, 변환된 단위에서는 중위도 0.3-0.4 m, 건조 지역 < 0.30 m (중동의 경우 0.15 m 미만)로 공간 패턴 일치도  $r = 0.98$ 을 달성하였다. 2013년 12월-2014년 5월 시계열에서 ERA5의 경우 원본  $0.332 \pm 0.068 \text{ m}^3 \text{ m}^{-3}$ , 변환 단위는  $0.235 \pm 0.052 \text{ m}$ 로 변환 비율은 약 0.71이며, 이는 공극률/포장 용수량 비  $0.439/0.283 = 1.55$ 의 역수와 유사하다.

변환 과정에서의 불확실성 요인으로는 데이터 간의 토양 분류 불일치(5 vs 7 분류 차이로 인한 매핑 모호성), 공극률 추정 불확실성, MERRA2 WSMX 적용을 포함한다. 그러나 초기화 후 RMSE가 0.003 m로 감소하여 변환 체계가 효과적으로 작동함을 확인하였다.

### 3.2.2.2 초기화 알고리즘 구현

#### 3.2.2.2.1 EAKF 필터의 설계와 SCoPS 적용

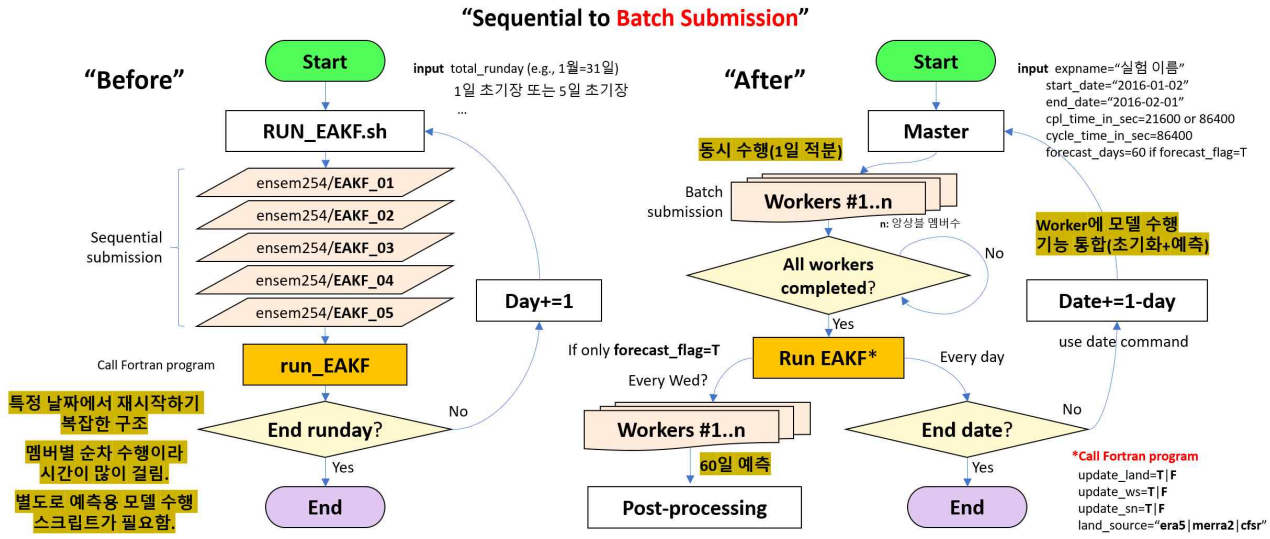


Figure 3.17. Schematic diagram of the APCC Subseasonal-to-Seasonal (S2S) Prediction System.

토양 수분 동화에 EAKF 필터를 적용하였다(Figure 3.17). EAKF는 앙상블 기반 칼만 필터의 일종으로, 관측 자료와 모델 예측 간 차이를 앙상블 공분산 구조를 활용하여 모델 상태 변수에 전파한다(Anderson et al., 2001). 칼만 필터의 갱신식은 분석장 = 배경장 +  $K \times$  (관측 - 배경장)이며,

$$\text{Kalman gain: } K = \sigma_f^2 / (\sigma_f^2 + \sigma_o^2),$$

$\sigma_f^2$ 는 배경장 오차 분산 행렬,  $\sigma_o^2$ 은 관측 오차 분산 행렬이다. EAKF의 앙상블 접근은 명시적 공분산 행렬 계산 대신 N개 앙상블 멤버 간 편차로 공분산을 추정하며, 전통적 EnKF의 관측 random perturbation 대신 앙상블 평균과 spread를 deterministic하게 조정하여 관측 섭동이 불필요하고 sampling error가 감소하는 장점이 있다.

SCoPS 적용에서 상태 벡터는 토양 수분만을 업데이트 대상으로 하며 격자점별 독립 처리한다. 관측 벡터는 ERA5-Land 토양 수분을 격자점별 1 대 1 매핑하며, 관측 연산자는 모델 변수와 관측이 동일하여 변환이 불필요하다. 토양 수분의 관측 오차는 ERA5-Land 불확실성 기반 0.01 m로 가정한다. 배경 오차는 앙상블 spread로 추정한다.

Localization과 Adaptive Inflation을 적용하여 앙상블 spread 과소 추정 문제를 해소하였다. 5개로 제한된 앙상블 크기로 인한 sampling error를 완화하기 위해 Gaspari-Cohn(1999) localization 함수를 적용하며, 수평 영향 반경 500 km로 설정하였다. 이는 토양 수분의 공간 상관 거리가 수백 km이므로(Koster et al., 2004) 대륙 규모 패턴을 고려하되 원거리 spurious correlation을 제거한다. Localization 효과는 적용 시 공간적으로 매끄러운 패턴을 나타낸다.

또한, Adaptive inflation은 각 앙상블 멤버를 평균으로부터 일정 비율 확장하며

$$\lambda = \lambda_0 \times \sqrt{d/(\sigma_f^2 + \sigma_o^2)},$$

d는 관측과 배경장의 차이,  $\lambda_0$ 는 initial inflation factor로 1.05를 사용한다.  $\lambda$ 의 범위는 1.0에서 1.5사이로 제한한다.

### 3.2.2.2.2 초기화 워크플로우와 수렴 진단

토양 수분 초기화는 예측 시작일(D-day) 약 10-12일 전부터 1일 주기로 초기화 워크플로우를 반복 수행한다. SCoPS의 hindcast 날짜는 1, 5, 10, 15, 20, 25일에 고정되어 있기 때문에 월별로 길이가 달라지면서 초기화 기간도 10일에서 12일로 차이가 발생한다. 초기화가 없는 SCoPS의 기본 5개 앙상블 멤버를 적분하고, 해당하는 날짜의 ERA5-Land 자료를 SCoPS 수분장에 맞춰 격자와 단위를 변환한다. 대기/해양 초기 조건은 기존 체계 사용하며 매일 전날 분석장이 배경장이 되어 다음날 00 UTC까지 1일 적분을 반복한다. 주요 과정으로는 ERA5-Land 해당 날짜 자료 불러오기, Inflation 적용(조건부 spread 확장), EAKF 업데이트(Kalman Gain 계산 및 앙상블 분포 업데이트), 물리적 제약 확인( $0 \leq WS \leq WSMX$  범위 강제), 분석장 저장을 순서대로 수행한다. Day 0(D-day, 예측 시작일)이 되면 최종 토양 수분 분석장을 SCoPS 초기 조건으로 설정하여 60일 예측을 수행한다.

초기화 수렴 진단을 수렴 과정을 추적 관찰하였다. 추적 지표는 전지구 평균 RMSE vs ERA5-Land(예: 목표 0.01 m 이하, 실제 Day -1에 0.003 m 달성), Increment 분석장-배경장(예: 초기 0.05-0.10 m 큰 조정, 최종 < 0.01 m 미세 조정), 공간 상관계수(목표 > 0.99)를 포함한다. 수렴 기준은 RMSE < 0.005 m와 spread = 0.01-0.02 m, increment < 0.01 m로 연속 3일 기준 충족 시 조기 종료 가능하나, 실제로는 안정성 확보를 위해 10일에서 12일인 전체 기간을 사용한다.

### 3.2.2.2.3 HPC 병렬 최적화와 효율성 분석

EAKF 기반 초기화 및 SCoPS 예측을 위한 모델 적분은 계산 집약적이므로 APCC HPC에서 MPI 병렬화를 수행하였다. HPC는 103개 노드, 노드당 CPU는 Intel Xeon X5690 프로세서(@3.47GHz, 6 cores)가 2개씩(즉, 노드당 12 cores), 메모리 32 GB, Lustre parallel filesystem을 갖추고 있다. 소프트웨어 환경은 CentOS 6.0 리눅스, PGI 11.10, openmpi 1.4.4, NetCDF 4.2.1을 사용한다.

제한된 HPC의 노드와 다양한 현업 작업이 혼재된 환경에서 효율적인 HPC 활용을 위해,

적절한 코어 수를 배정하여 다른 작업들과의 충돌을 최소화 하고 병렬 효율성을 극대화하고자 병렬 효율성(E, Parallel Efficiency) [%]을 분석하였다. 해양 모델(POP2)와 해빙 모델(CICE4)에 할당할 코어수를 12개와 2개로 각각 고정하고 대기 모델(ECHAM5)의 코어수를 조절하며 병렬 효율성을 계산하였다.

$$E = \left( \frac{T_1 \times C_1}{T_n \times C_n} \right) \times 100,$$

$C_1$ 과  $T_1$ 은 코어수 20개와  $C_1$ 에서의 소요시간(분)을 의미하며,  $C_n$ 은 30개, 40개, 48개, 60개, 80개, 120개, 240개까지로 구성하며,  $T_n$ 은  $C_n$ 에서의 소요시간(분)을 의미한다.

각 조합마다 30회 이상을 반복하여 1일 적분에 필요한 평균 소요시간과 병렬 효율성을 살펴본 결과, 20개(기준 코어수)는 약 10분(100%), 30개는 6.5분(102%), 40개는 5.3분(97%), 48개는 4.8분(93%), 60개는 4분(87%), 80개는 3.1분(83%), 120개는 2.3분(70%), 240개는 1.9분(48%)를 나타냈다(Figure 3.18). 병렬 효율성은 Speed-up과 코어 수 비율의 비율로 계산되기 때문에, 효율성이 80-100% 구간 내에 위치하는 최적의 구간은 40-80개(효율성 83-97%, 계산 시간 3-5분)이다. 80개 이상에서 효율성이 급감(통신 오버헤드 증가 예상)하며, 40개 미만은 계산 시간이 과다하여 현업 운영에 부적합해 보인다.




Figure 3.18. Parallel efficiency [%] and computational time [min] as a function of ECHAM5 core allocation.

HPC 규모를 보면 양상블 멤버가 10개일 경우 80개 코어까지 한 번의 배치 작업으로 모든

멤버를 동시에 적분할 수 있지만, 전체 노드의 64%를 점유하기 때문에 충돌을 최소화한다는 전제에 적절하지 않다. 40개 코어를 사용할 경우엔 전체 HPC에 32%를 점유하므로 40개 코어를 활용하였다. hindcast 실험을 위한 설정으로 40개 코어(총 54개 코어)로 11일 초기화 시 약 58분(실용적)이며, 병렬 효율성도 양호하고, 활용하는 노드 4개 이하로 경제적이다.

### 3.2.2.3 실험 설계 및 평가 방법

#### 3.2.2.3.1 Hindcast 및 Forecast 실험 구성

Hindcast 실험(2003-2016년)은 초기화 효과의 통계적 유의성 평가 및 기후학적 특성 파악을 목적으로 한다. 실험 기간은 2003-2016년 14년간 북반구 여름철(4-8월) 집중이며, 시작 날짜는 1일 및 15일(4월 15일, 5월 1일, 5월 15일, 6월 1일, 6월 15일, 7월 1일, 7월 15일, 8월 1일) 초기장의 총 8개 시작일을 포함한다. 총 실험은 112개(8개 시작일 × 14년)이며, 여름철 기간을 벗어나는 제외하였다(Table 3.3). 예측 기간은 60일이며 분석 구간은 15일씩 평균한 16-30일, 31-45일, 46-60일이다. 각 실험은 5개 앙상블 멤버를 갖는다.

Table 3.3. Summer (JJA) hindcast configuration (2003-2016) with start dates and analysis lead times for the Northern Hemisphere.

리드 타임 (Lead time)	초기 시작 날짜 (8 start dates)							
	04/15	05/01	05/15	06/01	06/15	07/01	07/15	08/01
16-30일	X	X	6월초	6월말	7월초	7월말	8월초	8월말
31-45일	X	6월초	6월말	7월초	7월말	8월초	8월말	X
46-60일	6월초	6월말	7월초	7월말	8월초	8월말	X	X

토양 수분 초기화에 의한 다양한 예측 민감도(메모리, 결합 강도, 예측성능 등)를 살펴보기 위해 CTRL (without initialization)과 LAND (with land surface initialization)를 함께 비교한다. CTRL 실험은 토양 수분 초기화 없이 기존 SCoPS 체계를 그대로 사용하며(대기: ERA5 T159 해상도, 해양: SCoPS POP initial data, 지면: 기후값 기반 월별 평년), LAND 실험은 토양 수분 EAKF 초기화를 적용하고(ERA5-Land 분석장 사용, 11일 동화 Day -11 ~ Day -1) 대기/해양은 CTRL과 동일하다. 차이점은 오직 토양 수분 초기 조건만 다르므로 초기화의 순수 효과 분리가 가능하다.

#### 3.2.2.3.2 평가 지표와 통계적 검정

메모리 지속성 평가는 E-folding time  $\tau$  (상관계수가 1/e로 감소하는 시간으로 메모리

특성 시간 규모), Autocorrelation (초기 패턴 지속성 평가), Zero-crossing time (상관계수가 0이 되는 시점) 등을 사용한다.

지면-대기 결합 강도 평가 진단을 위한 지표로는 Terrestrial Coupling Index (TCI,  $I_{SM,LH}$ ), Atmospheric Coupling Index (ACI,  $I_{SM,X}$ ), Two-legged total coupling(두 지표의 곱 또는  $I_{SM,X}$ )을 사용한다. 선행 연구에서는 ACI 지표의 X에 지표기온(T2m), 강수량(Precip), 경계층 고도 등의 사용한다(Dirmeyer, 2011; Day et al., 2025). 본 연구에서는 ACI 지표로 X에 T2m을 대입하여  $I_{SM,T2m}$ 을 사용하였다.

$$\text{TCI: } I_{SM,LH} = \sigma(LH) \rho(SM, LH)$$

$$\text{ACI: } I_{SM,X} = \sigma(X) \rho(SM, LH) \rho(LH, X)$$

예측 성능 평가는 결정계수( $R^2 = 1 - \text{SSE}/\text{SST}$ , SSE는 오차 제곱합 SST는 총 변동, 범위 0-1, 높을수록 설명력 높음),  $\Delta R^2$ (예측 개선도,  $\Delta R^2 = R^2_{\text{LAND}} - R^2_{\text{CTRL}}$ , 양수는 개선 음수는 악화), ACC(Anomaly Correlation Coefficient, 평년 편차 기준 상관계수로 계절 주기 제거 효과, 예:  $R_{\text{LAND}}$ )를 사용한다.

초기화 효과 평가를 위한 기본 통계 지표에는 RMSE(Root Mean Square Error, 작을수록 좋음), Bias(평균 편차, 양수는 과대평가 음수는 과소평가), 공간 상관계수(r, 범위 -1~1, 높을수록 패턴 일치도 높음) 등이 포함된다.

통계적 유의성 검정은 Bootstrap Method(1000회 재표본추출 resampling with replacement, 95% 신뢰구간 계산,  $p < 0.05$  통계적 유의), Student's t-test(LAND vs CTRL 평균 차이 검정), F-test(분산 비 검정으로 예측 불확실성 변화 평가)를 수행한다.

### 3.2.2.3.3 분석 영역 정의와 선정 기준

본 연구에서 전 지구 영역은 남극을 제외한 전체 육지 영역(위도 60° S-90° N)을 의미한다. Hotspot 지역은 미국 중서부 지역(Central United States, Great Plains 중심, 반건조 기후)와 남동 유럽(Southeastern Europe, 발칸반도~흑해 북부, 복잡 지형 장기 메모리)이다. 선정 기준은 선행 연구에서 지면-대기 결합이 강한 지역(Koster et al., 2004; Seneviratne et al., 2010), 토양 수분 변동성이 큰 지역, 초기화 효과가 클 것으로 예상되는 지역이다. 기타 관심 영역은 NA(North America 북미 전체), EU(Europe 유럽 전체), AS(Asia 아시아 전체), Monsoon regions(동아시아 남아시아 서아프리카 몬순 지역) 등이다. 모든 면적 평균은 cosine weighting을 적용하였다.

### 3.2.3 결과

#### 3.2.3.1 초기화 효과 분석

##### 3.2.3.1.1 토양 수분장의 수렴 특성

EAKF 기반 토양 수분 초기화를 통한 그 효과를 정량적으로 평가하기 위해, 전체 초기화 기간(10-12일)에 수렴 과정 동안의 SCoPS 모델의 토양 수분과 ERA5-Land 재분석 자료 간의 분포 특성을 분석하였다(Figure 3.19). 우선, 초기화 실험(LAND)과 대조 실험(CTRL)을 비교하여 EAKF 알고리즘의 초기화 성능을 검증하였다. LAND 실험에서 토양 수분의 RMSE는 초기화 시작 시점의  $0.292 \text{ m}^3 \text{ m}^{-3}$ 에서 5일 후  $0.002 \text{ m}^3 \text{ m}^{-3}$ 로 감소하여 99.3%의 개선을 보였다(Table 3.4). CTRL은 전 기간에 걸쳐 ERA5-Land 대비 Bias를 일관되게 유지하며, 약 0.12 m의 wet bias가 거의 변하지 않는다.




Figure 3.19. Time series of global mean soil wetness [m] during each initialization period for ERA5 (black), LAND (orange), and CTRL (blue) experiments, respectively. RMSE is calculated between model and ERA5. Exponential decay fitting shows e-folding time of approximately 1.74-1.78 days for LAND experiment. Shaded areas represent  $\pm 1$  standard deviation across 14 periods.

Table 3.4. Statistics of RMSE reduction [%] and spatial correlation improvement (LAND minus CTRL) between model and ERA5 during the initialization period for the Global, Central United State (CUS), and Southeastern Europe (SEE) region.

지역	실험	초기 RMSE [m <sup>3</sup> m <sup>-3</sup> ]	최종 RMSE [m <sup>3</sup> m <sup>-3</sup> ]	RMSE 감소율	초기 상관계수	최종(D-day) 상관계수	상관계수 개선
전 지구 (Global)	CTRL	0.292	0.293	-0.2%	0.290	0.280	-0.010
전 지구 (Global)	LAND	0.292	0.002	99.3%	0.290	1.000	+0.710
미국 중서부 (CUS)		0.371	0.002	99.5%	-	-	-
남동유럽 (SEE)		0.173	0.001	99.4%	-	-	-

이는 EAKF 기반 초기화가 모델 앙상블의 배경 오차 공분산을 효과적으로 활용하여 지면 분석 자료를 적절히 동화하고 있음을 의미한다. 반면 CTRL 실험은 초기화 기간 동안 RMSE가 0.292 m<sup>3</sup> m<sup>-3</sup> 수준을 유지하여 거의 변화하지 않았다(-0.2%). 지수 함수 적합(exponential fitting) 결과, LAND 실험의 e-folding time은 약 8-9일로 나타나 초기화 기간 대비 적절한 수렴 속도를 보였다. 지역별 분석 결과, 중부 미국(CUS)과 동남유럽(SEE)에서 모두 효과적인 초기화가 이루어졌다. CUS 지역의 RMSE는 0.371 m<sup>3</sup> m<sup>-3</sup> 에서 0.002 m<sup>3</sup> /m<sup>3</sup> 로 99.5% 감소하였으며, SEE 지역은 0.173 m<sup>3</sup> /m<sup>3</sup> 에서 0.001 m<sup>3</sup> /m<sup>3</sup> 로 99.4% 감소하였다(Table 1). CUS 지역의 초기 RMSE가 더 큰 것은 해당 지역의 토양 수분 공간 변동성이 크고, 모델 기후값과 관측 간의 초기 편차가 컸기 때문이다. 공간 상관계수 분석에서도 유사한 결과를 확인하였다.

Figure 3.20은 초기화 1일차와 예측 시작일(D-day)의 전지구 토양 수분 분포를 보여준다. 공간 분포 분석에서 LAND 실험은 초기화 1일 후부터 ERA5의 공간 패턴에 근접하기 시작하였다. LAND 실험의 ERA5-Land와의 공간 상관계수는 초기 0.290에서 10-12일 후 1.000으로 향상되어, 모델이 관측 자료의 공간 패턴을 완벽하게 재현하였다. 반면, CTRL 실험은 초기화 기간 내내 모델 고유의 기후학적 패턴을 유지하여 관측과 상당한 차이를 보였다. CTRL 실험의 상관계수는 0.280-0.290 수준을 유지하여 초기화 없이는 관측 패턴을 재현하지 못함을 보여주었다. CTRL 실험은 초기화를 적용하지 않았으므로 ERA5와 일관된 공간 패턴 차이를 보이며, 특히 북미 중서부와 동남아시아 지역에서 wet bias가 두드러진다. LAND 실험은 초기화 1일차에 이미 상당한 개선을 보이며, D-day에는 ERA5와 거의 구별할 수 없는 공간 분포를 나타낸다. 두 그림의 inset PDF 분포는 LAND가 ERA5의 통계적 특성까지 재현함을 보여준다. 특히 토양 수분 구배가 큰 중위도와 고위도 대의 전이대(transition

zone)에서 초기화의 효과가 두드러졌다.

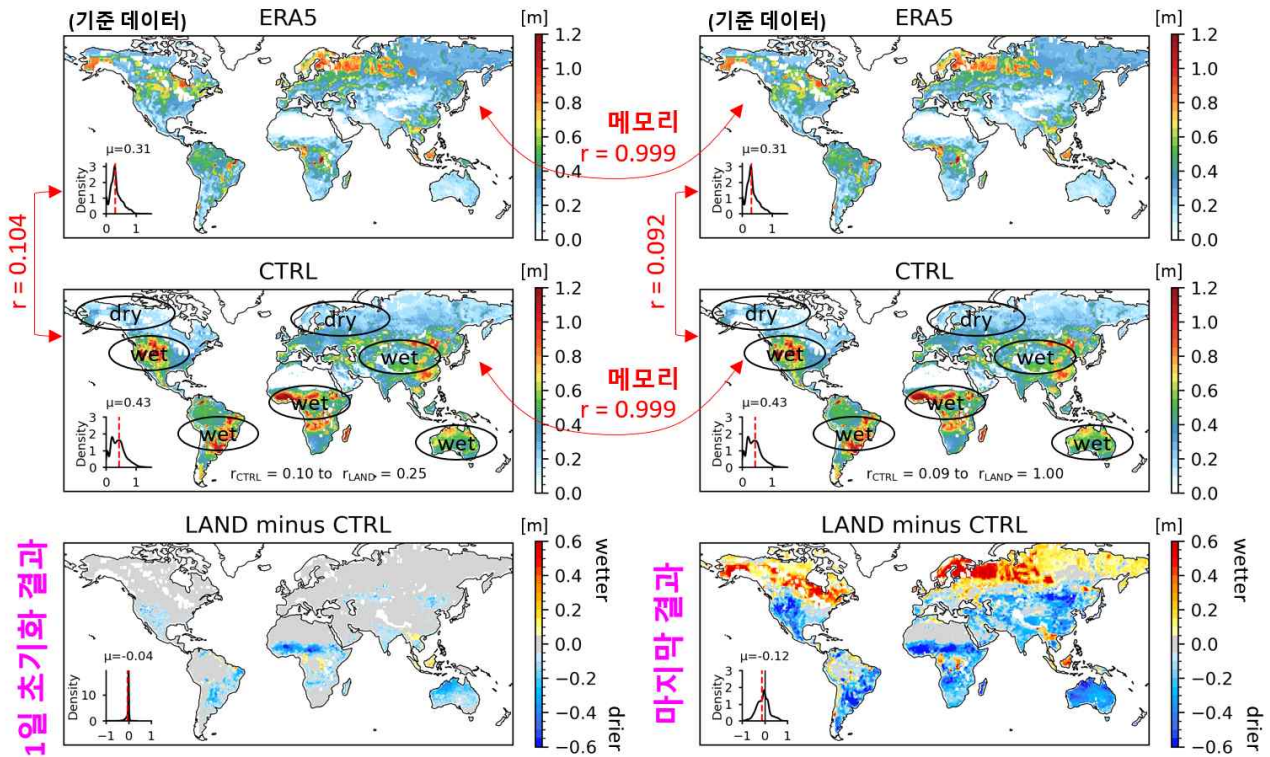


Figure 3.20. Spatial distribution of soil moisture at (left) Day 1 of initialization period and (right) D-day (end of initialization period) for (top) ERA5, (middle) CTRL, and (bottom) LAND-CTRL. Spatial correlation coefficients are indicated in panel. All values averaged over 112 samples.

Figure 3.21은 8개 시작 날짜별 전지구 평균 토양 수분 difference map의 temporal evolution을 보여준다. LAND는 첫 번째 동화 사이클 직후 차이를 보이며(bias=약 -0.04 m), 전 지구 평균 RMSE가 0.297 m에서 0.190 m로 감소하여 단 하루 만에 32-36%의 오차 감소를 달성한다. 이는 EAKF의 앙상블 공분산 구조가 효과적으로 관측 정보를 모델 상태 변수에 전파함을 의미한다. 실제 10-12일 초기화 적용 결과 최종 시작 날짜와 관계없이 일관되게 0.12 m 가량의 wet bias가 감소함을 확인하였다.

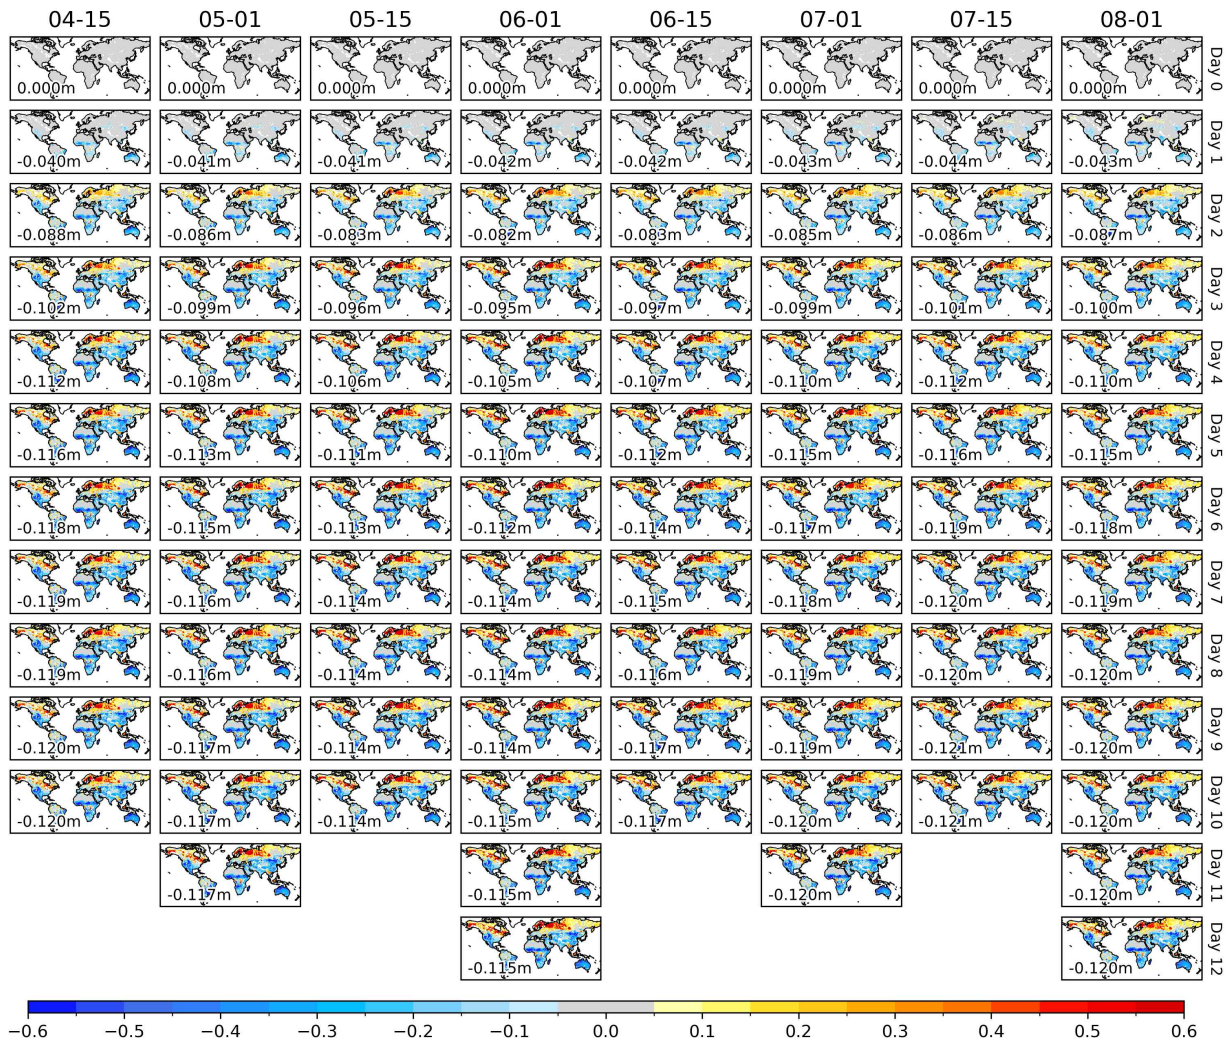


Figure 3.21. Spatial distribution of soil moisture difference between LAND and CTRL experiments from Day 1 of initialization period to the end of initialization period for each start date, respectively.

이상의 분석 결과는 EAKF 기반 토양 수분 초기화 시스템이 전 지구 및 지역 규모에서 모두 관측 자료를 효과적으로 동화하며, 10-12일간의 초기화 기간 내에 모델과 관측 간의 차이를 거의 완전히 제거함을 확인하였다.

### 3.2.3.2 메모리 분석

토양 수분의 시간적 지속성, 즉 메모리(memory)는 초기 조건 개선이 예측 성능 향상으로 전환되는 핵심 메커니즘이다. 토양 수분 메모리는 초기 토양 수분 편차가 시간에 따라 감쇠하는 특성 시간 규모로 정의되며, 계절 예측의 예측성 원천(predictability source)으로 작용한다. 메모리가 길수록 초기화의 영향이 장기간 유지되어 아계절 예측에 기여할 수 있다. 본 절에서는 LAND 및 CTRL 실험에서 토양 수분 메모리의 시간적 감쇠 특성과 공간 분포를

정량적으로 비교 분석하였다. 특히 초기화된 토양 수분 편차와 후속 기간 토양 수분 간의 자기상관계수(autocorrelation)를 분석하여 e-folding time (상관계수가 1/e로 감소하는 시간)으로 메모리를 정량화하였다. 이는 메모리 지속 기간의 특성 시간 규모(characteristic timescale)를 나타낸다.

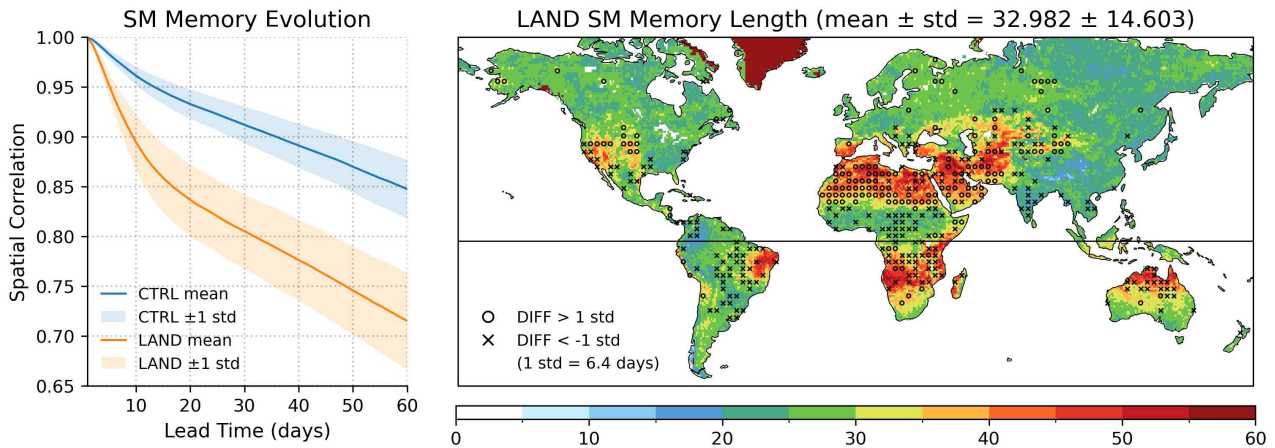


Figure 3.22. Soil moisture memory comparison between LAND and CTRL experiments. (left) Time series of persistence of soil moisture memory [days] (autocorrelation) across 112 samples. (right) Spatial distribution of LAND soil moisture memory length (shadings) [days] with difference between LAND and CTRL experiments (markers mostly over  $\pm 1.0$  standard deviation).

Figure 3.22의 메모리 진화는 초기 상태(D-day)와 이후 리드타임 1-60일 동안의 공간 상관계수(spatial correlation) 변화를 통해 평가하였으며, 상관계수가 높을수록 초기 패턴이 유지되고 있음을 의미한다. CTRL 실험은 Day 10에서  $r = 0.96$ 으로 거의 초기 상태 유지를 나타내며, Day 20에서  $r = 0.94$ , Day 30에서  $r = 0.91$ , Day 40에서  $r = 0.88$ , Day 50에서  $r = 0.865$ , Day 60에서  $r = 0.85$ 로 점진적인 완만한 감쇠를 보인다. 60일 동안 초기 패턴과의 상관계수가 0.85 이상을 유지하여 강한 메모리 지속성을 나타내며, 특히 처음 30일 동안은  $r > 0.9$ 로 초기 조건이 거의 그대로 유지되었다.

반면 LAND 실험은 현저히 다른 특성을 보인다. Day 10에서  $r = \sim 0.9$ 로 CTRL보다 0.05 이상 낮은 초기 상관을 나타내며, Day 20에서  $r = 0.84$ , Day 30에서  $r = 0.8$ , Day 50에서  $r = 0.75$ , Day 60에서  $r = 0.72$ 로 60일 동안 0.72-0.999 범위를 보이며, 20일 이후부터는 CTRL과 0.1 정도 차이가 유지되었다. LAND가 높은 초기 상관에서 점진적으로 감쇠하는 전형적인 메모리 감쇠 곡선을 보이는 반면, CTRL은 초기 상관에서 정체되어 메모리 개념이 적용되지 않는다. 60일 시점에서 LAND가 CTRL보다 수치적으로 낮으나, 이는 LAND가 실제 관측 패턴에서 떨어진 것이 아니라 자연적 변동성(natural variability)에 의한 패턴 변화를 반영한 결과이다.

공간 분포 분석 결과, 토양 수분 메모리는 위도대와 기후대에 따라 체계적인 차이를

보였다(Figure 3.22). 중위도 대륙 내부(30-50° N)는 대체로 30-50일의 긴 메모리를 보인 반면, 열대 습윤 지역과 고위도 한대 지역은 20-30일의 상대적으로 짧은 메모리를 나타냈다. 이러한 공간 패턴은 증발산율, 강수 변동성, 토양 깊이 등의 복합적 작용으로 설명될 것으로 예상된다.

LAND와 CTRL 실험 간 메모리 차이는 전 지역에서 매우 작았다. LAND 실험의 전지구 평균 토양 수분 메모리는  $39.1 \pm 15.5$ 일로 나타났으며, CTRL 실험( $39.3 \pm 15.7$ 일)과 거의 차이가 없었다(Table 3.5). 전 지구적으로 차이는 -0.2일, CUS는 +0.9일, SEE는 -0.6일로 모두 1일 이내였다. 두 실험 간 차이는 불과 0.2-0.9일로, 이는 토양 수분 초기화가 메모리의 시간 규모 자체를 변화시키지 않고 초기 상태의 정확도만을 개선함을 의미한다. 메모리의 공간적 표준편차가 약 15-16일로 큰 것은 지역별 기후, 토양 특성, 식생의 차이가 메모리에 강한 영향을 미침을 반영한다. 또한, 이는 토양 수분 메모리가 모델의 물리 과정(증발산, 토양 수문학, 지면-대기 교환)에 의해 결정되는 내재적 특성이며, 초기화는 이러한 물리적 메모리 시간 규모를 변화시키지 않음을 보여준다.

Table 3.5. Soil moisture memory characteristics (e-folding time) for LAND and CTRL experiments. Values represent the time scale at which autocorrelation of initial soil moisture anomalies decays to  $1/e$  ( $\sim 0.37$ ), averaged across all forecast initialization dates ( $n=112$ ).

지역	LAND 메모리 (일)	CTRL 메모리 (일)	차이 (일)
전 지구	$39.1 \pm 15.5$	$39.3 \pm 15.7$	-0.2
CUS	$29.9 \pm 5.5$	$29.0 \pm 5.7$	+0.9
SEE	$29.2 \pm 4.5$	$29.8 \pm 5.0$	-0.6

Note: Standard deviations represent spatial variability within each region. CUS = Central United States (25-50° N, 235-260° E), SEE = Southeast Europe (35-50° N, 15-35° E).

중부 미국(CUS)과 동남유럽(SEE) 두 주요 분석 지역은 유사한 메모리 특성을 보였다. CUS 지역의 메모리는  $29.9 \pm 5.5$ 일, SEE 지역은  $29.2 \pm 4.5$ 일로, 약 30일의 메모리를 가지며 공간 변동성이 작았다. 두 지역 모두 중위도 전이대에 위치하여 토양 수분이 지면-대기 상호작용을 증대하는 중요한 역할을 하는 지역이다. 이들 지역의 메모리가 전지구 평균(39일)보다 다소 짧은 것은, 여름철 활발한 증발산과 대류성 강수로 인해 토양 수분의 교란 빈도가 높기 때문이다. 그러나 30일의 메모리는 여전히 subseasonal (2주-2개월) 예측에 충분한 시간 규모이며, 초기 토양 수분 정보가 한 달 이상 예측성에 기여할 수 있음을 시사한다.

따라서 토양 수분 초기화의 효과는 메모리 자체를 연장하는 것이 아니라, 정확한 초기 상태 제공을 통해 메모리 기간 동안의 예측 정보를 최대한 활용하는 데 있다. 이는 다음 섹션에서 분석하는 결합 강도 및 예측 성능 개선과 직접적으로 연결된다.

### 3.2.3.3 지면-대기 결합 강도 분석

지면-대기 결합(land-atmosphere coupling)은 토양 수분 변화가 증발산, 에너지 플럭스, 경계층 발달을 거쳐 기온 및 강수에 영향을 미치는 상호작용 과정을 의미한다(Dirmeyer, 2011). 결합이 강한 지역일수록 토양 수분 초기 조건이 대기 상태에 미치는 영향이 크며, 따라서 초기화의 예측 성능 기여도가 높다. 지면-대기 결합은 다양한 pathway (예: 토양 수분, 지표기온, 강수, 비습, 경계층 고도 등)로 구성할 수 있다(Day et al., 2025). 토양 수분이 지면 플럭스 및 대기 변수에 미치는 영향을 정량화하기 위해, 지면 결합 지수(Terrestrial Coupling Index,  $I_{SM,LH}$ )와 대기 결합 지수(Atmospheric Coupling Index,  $I_{SM,T2m}$ )를 계산하였다.  $I_{SM,T2m}$  지수는 토양 수분 → 잠열 → 현열 분배 → 기온의 전체 경로를 포함하며, 토양 수분 초기화가 기온 예측에 기여할 수 있는 잠재력을 나타낸다. 이들 지수는 각각 토양 수분-잠열 플럭스 간 상관관계와 토양 수분-기온 간 상관관계를 나타내며, 결합 메커니즘의 강도를 직접 측정한다.

각 결합 지수는 리드타임 구간(16-30일, 31-45일, 46-60일)별로 계산되었다. 해당 리드타임 동안의 일별 토양 수분, 잠열, 기온 시계열을 추출하고, 격자점별 시간 상관계수와 시간 표준편차를 계산한 후, 상관계수와 표준편차의 곱으로 결합 지수를 산출하며, 전지구 또는 지역 평균을 계산한다.

16-30일 리드타임에서 전지구 평균 지면 결합 지수( $I_{SM,LH}$ )는 CTRL 실험이  $5.6 \text{ W m}^{-2}$  LAND 실험이  $4.4 \text{ W m}^{-2}$ 로 나타나 LAND 실험에서 21% 감소하였다(Table 3.6). 이러한 전지구 평균의 감소는 주로 열대 및 아열대 지역에서 초기화로 인한 토양 수분의 재분포가 증발산의 수분 제한(moisture limitation)을 완화시켰기 때문으로 해석된다(Figure 3.23).

Table 3.6. Land-atmosphere coupling strength for different lead periods. Terrestrial coupling index ( $I_{SM,LH}$ ) represents correlation between soil moisture and latent heat flux. Atmospheric coupling index ( $I_{SM,T2m}$ ) represents correlation between soil moisture and 2-meter temperature. Values are averaged over 14-day windows centered at each lead period.

지역	리드 타임 (days)	$I_{SM,LH}$ [단위: $W\ m^{-2}$ ]		$I_{SM,T2m}$ [단위: K]	
		CTRL	LAND	CTRL	LAND
전지구 (Global)	16-30	5.6	4.4 (-21%)	0.129	0.098 (-24%)
	31-45	5.0	4.4 (-11%)	0.120	0.100 (-17%)
	46-60	4.8	4.4 (-8%)	0.112	0.094 (-16%)
미국 중서부 (CUS)	16-30	8.5	12.4 (+46%)	0.243	0.455 (+87%)
	31-45	8.1	12.6 (+56%)	0.244	0.485 (+99%)
	46-60	7.9	12.3 (+56%)	0.224	0.449 (+101%)

Note: Percentage changes are calculated as  $(LAND-CTRL)/CTRL \times 100\%$ . Positive values indicate coupling strengthening, negative values indicate weakening. CUS = Central United States ( $25-50^\circ\ N$ ,  $235-260^\circ\ E$ ).

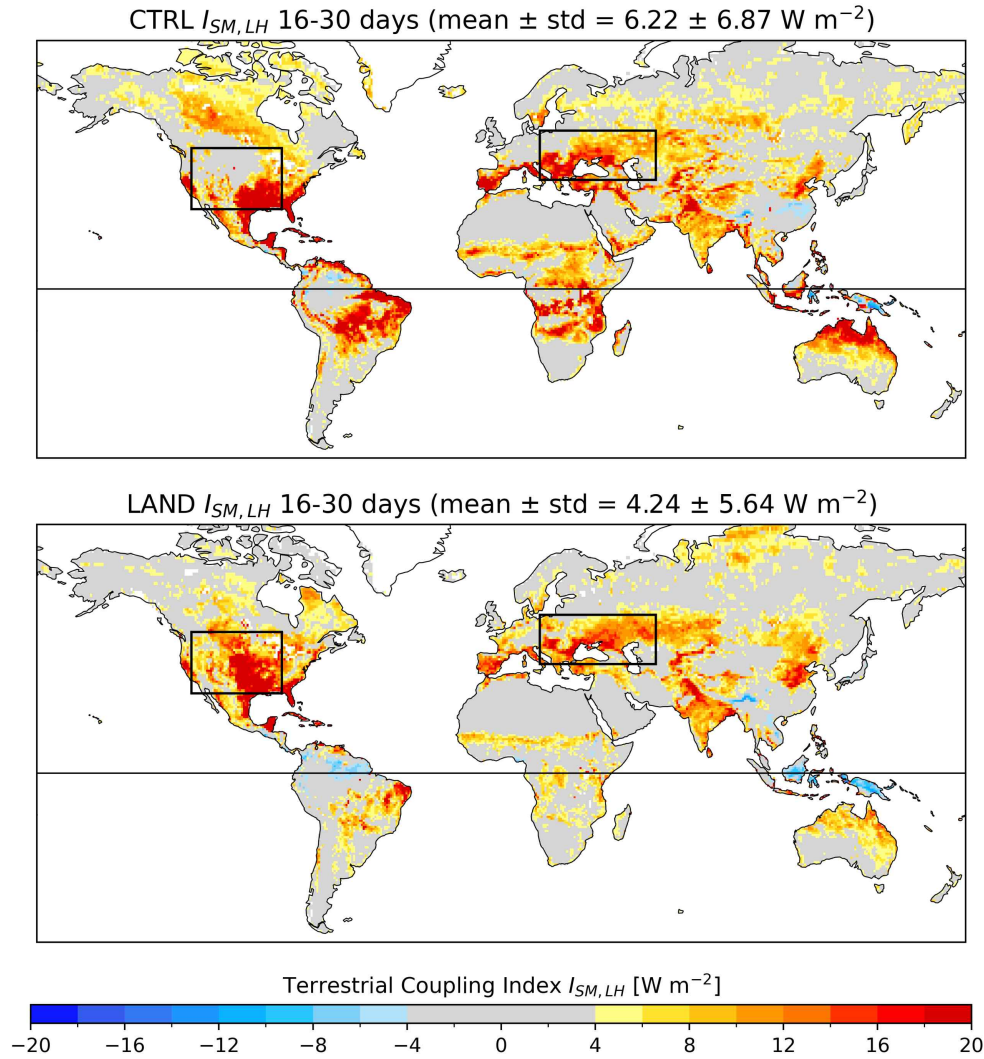


Figure 3.23. Spatial distribution of land-atmosphere coupling strength for 16-30 day lead period. (top) Terrestrial coupling index ( $I_{SM,LH}$ ,  $W m^{-2}$ ) for CTRL experiment. (bottom) Same for LAND experiment showing enhanced coupling over mid-latitude continental regions.

대기 결합 지수 ( $I_{SM,T2m}$ ) 역시 유사한 결과를 보이며, 전지구 평균이 CTRL 0.129 K에서 LAND 0.098 K로 24% 감소하였다. 전 지구 규모에서의 이러한 감소는 토양 수분 초기화가 지역별로 상반된 영향을 미치며, 결합 메커니즘이 강화되는 지역과 약화되는 지역이 공존함을 시사한다.

리드타임이 증가함에 따라 전지구 평균 결합 강도는 점진적으로 감소하였다. 지면 결합 지수는 31-45일에 CTRL 5.0  $W m^{-2}$ , LAND 5.0  $W m^{-2}$ 로, 46-60일에는 CTRL 4.8 5.0  $W m^{-2}$ , LAND 4.4 5.0  $W m^{-2}$ 로 감소하여, LAND 실험의 영향이 다소 약화되는 경향을 보였다.

전지구 평균과 대조적으로, 미국 중서부(CUS) 지역에서는 LAND 실험이 결합 강도를 크게 증가시켰다. 16-30일 리드타임에서 지면 결합 지수는 CTRL 8.5  $W m^{-2}$ 에서 LAND 12.4  $W$

m<sup>2</sup>로 46% 증가하였으며, 대기 결합 지수는 CTRL 0.243 K에서 LAND 0.455 K로 87% 증가하였다.

이러한 결합 강화는 31-45일( $I_{SM,LH}$ : +56%,  $I_{SM,T2m}$ : +99%)과 46-60일( $I_{SM,LH}$ : +56%,  $I_{SM,T2m}$ : +101%) 리드타임에서도 지속되어, CUS 지역의 토양 수분 초기화 효과가 2개월 예측 기간 동안 유지됨을 보여주었다. CUS 지역에서의 결합 강화는 다음과 같은 물리적 메커니즘으로 설명된다:

- 전이대 특성: CUS는 습윤-건조 기후 전이대에 위치하여 토양 수분이 증발산의 제한 인자로 작용
- 여름철 고온: 높은 대기 증발 수요(evaporative demand)로 인해 토양 수분 변동이 지면 플럭스에 직접 영향
- 깊은 토양층: 미국 중부의 비교적 깊은 토양이 초기화된 토양 수분 정보를 장기간 보존

남동 유럽(SEE) 지역의 결합 패턴은 CUS와 유사하나 변화 폭이 상대적으로 작았다. 16-30일 리드타임의 지면 결합 지수는 LAND 실험에서 소폭 증가하였으며, 대기 결합 지수는 약 30-40% 증가를 보였다. SEE 지역은 CUS보다 해양의 영향을 더 받아 토양 수분의 독립적 역할이 제한되는 것으로 해석된다.

공간 분포 분석 결과, 결합 강화 지역(hotspot)은 주로 중위도 대륙 내부에 집중되었으며, 특히 북미 중부, 유럽 동부, 중앙아시아 초원 지대에서 두드러졌다. 이들 지역은 공통적으로 (1) 토양 수분이 증발산의 주요 제어 인자이고, (2) 약 30일 이상의 토양 수분 메모리를 가지며, (3) 대기 순환의 영향이 상대적으로 작은 특징을 보인다.

초기화로 인한 결합 강도 변화의 공간 패턴(LAND - CTRL)은 리드타임에 따라 안정적으로 유지되어, 특정 지역에서의 결합 메커니즘 강화가 일관된 물리적 과정에 기인함을 시사한다.

### 3.2.3.4 예측 성능 평가

토양 수분 초기화가 실제 예측 성능에 미치는 영향을 정량적으로 평가하기 위해, 2003-2016년 hindcast 기간에 대한 LAND 및 CTRL 실험 결과를 ERA5 재분석 자료와 비교하여 기온 및 강수 예측 정확도를 분석하였다. 예측 성능은 결정계수( $R^2$ )로 측정하였으며, LAND와 CTRL 실험 간의 차이를 통해 초기화의 순 효과를 정량화하였다. 분석 기간은 예측 리드타임 16-30일, 31-45일, 46-60일의 세 구간으로 구분하여 수행하였다.

16-30일 리드타임에서 전지구 평균  $R^2$ 는 CTRL 0.126에서 LAND 0.158로 증가하여  $\Delta R^2 = +0.013$  (10% 개선)을 보였다(Table 3.7). 이는 계절내 예측에서 토양 수분 초기화가 기온 예측에 실질적 기여를 함을 의미한다.

Table 3.7. Forecast skill ( $R^2$ ) for 2-meter temperature prediction at different lead periods. Skill is calculated against ERA5 reanalysis using anomaly correlation over all 112 hindcast cases (2003-2016 JJA season). Statistical significance is assessed using bootstrap method ( $n=1000$ ,  $p < 0.05$ ).

지역	리드 타임 (일)	CTRL $R^2$	LAND $R^2$	$\Delta R^2$	개선율(%)
전지구 (Global)	16-30	0.126	0.158	+0.013*	+10.0
	31-45	0.082	0.133	+0.010*	+12.7
	46-60	0.089	0.072	+0.001	+1.4
미국 중서부 (CUS)	16-30	0.230	0.300	+0.035*	+15.3
	31-45	0.135	0.162	+0.004	+3.2
	46-60	0.217	0.255	+0.026*	+11.8
남동 유럽 (SEE)	16-30	0.127	0.310	+0.077*	+60.4
	31-45	0.094	0.102	-0.001	-1.3
	46-60	0.017	0.078	+0.007	+44.5

Asterisk indicates statistically significant improvement ( $p < 0.05$ ). CUS = Central United States ( $25-50^\circ$  N,  $235-260^\circ$  E), SEE = Southeast Europe ( $35-50^\circ$  N,  $15-35^\circ$  E).

지역별로는 뚜렷한 차이가 나타났다(Figure 3.24). CUS 지역은 CTRL 0.230에서 LAND 0.300으로  $\Delta R^2 = +0.035$  (15% 개선)을, SEE 지역은 CTRL 0.127에서 LAND 0.310으로  $\Delta R^2 = +0.077$  (60% 개선)을 보였다. SEE 지역의 높은 개선율은 지중해 기후의 여름철 건조 조건에서 토양 수분이 기온 변동성을 강하게 제어하기 때문으로 해석된다.

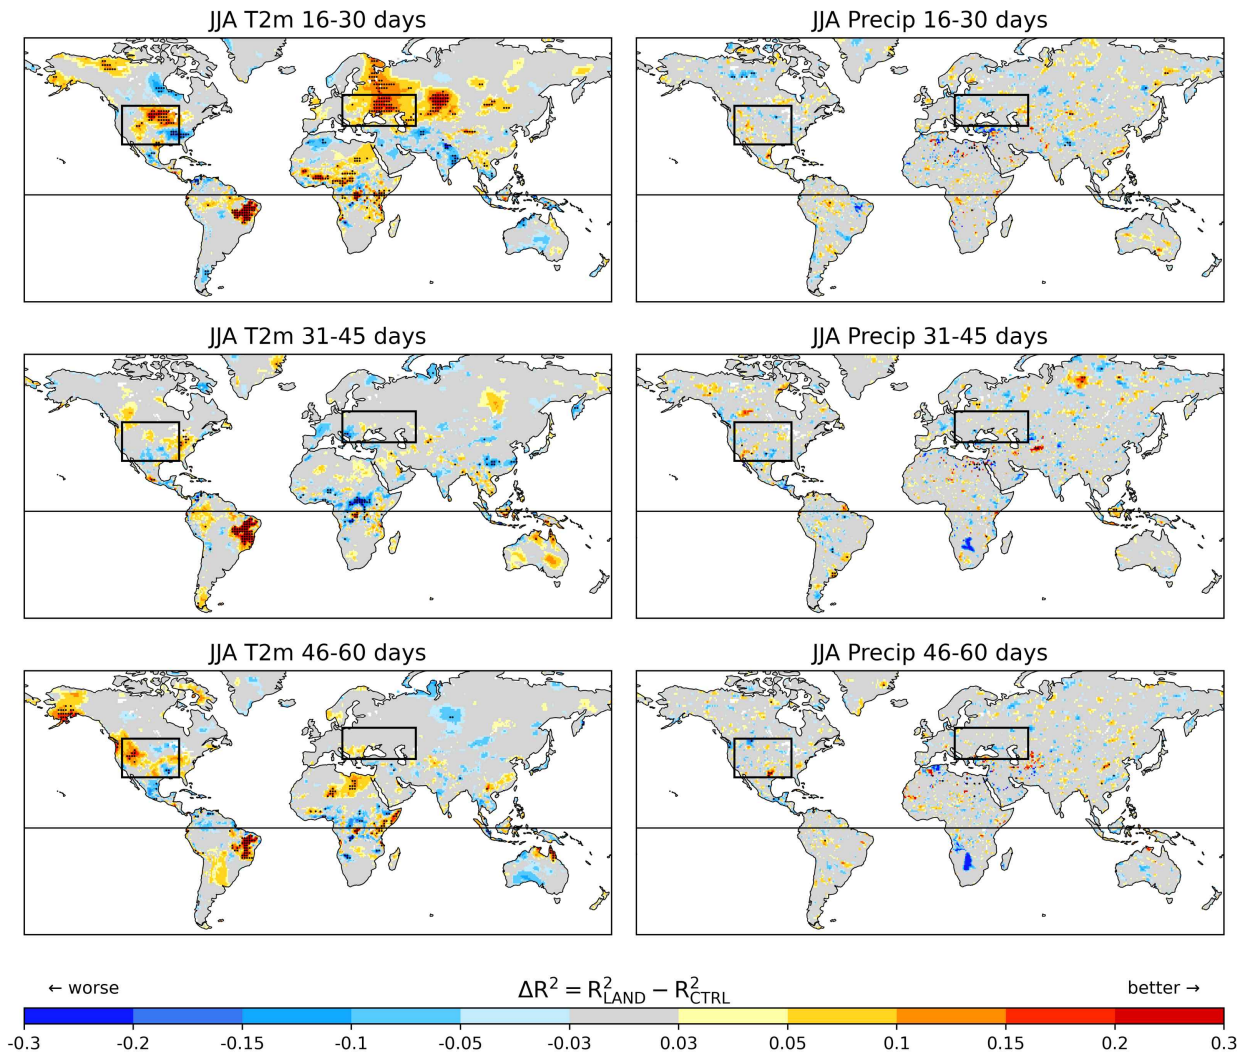


Figure 3.24. Spatial distribution of forecast skill for 16-30 day lead period. (left) temperature skill difference (LAND minus CTRL). (right) Same for precipitation skill difference. Stippling indicates statistical significance ( $p < 0.05$ , bootstrap test with 1000 iterations). Statistical significance indicated robust improvements in regions with strong land-atmosphere coupling.

31-45일 리드타임에서는 전지구 평균 개선이  $\Delta R^2 = +0.010$  (13% 개선)으로 다소 감소하였으나 여전히 양의 효과를 유지하였다. 그러나 CUS 지역의 개선은  $\Delta R^2 = +0.004$  (3% 개선)로 크게 감소하여, 한 달 이후에는 초기 토양 수분 정보의 영향이 약화됨을 보여주었다.

46-60일 리드타임에서 전지구 평균 개선 효과는  $\Delta R^2 = +0.001$  (1% 개선)로 매우 작아졌다. 이는 대부분 지역에서 2개월 후에는 초기 토양 수분 정보가 대기 변동성에 의해 희석됨을 의미한다. 그러나 CUS 지역은  $\Delta R^2 = +0.026$  (12% 개선)의 지속적인 개선을 보여, 토양 수분 메모리가 긴 중위도 대륙 지역에서는 장기 예측성 향상이 가능함을 시사한다.

CUS 지역에서 이러한 큰 개선이 나타나는 물리적 메커니즘은 반건조 기후(semi-arid climate) 특성과 관련이 있다. 이 지역은 토양 수분이 증발산을 제한하는 water-limited

regime에 속하므로, 토양 수분 초기 조건의 작은 차이가 증발산, 현열과 잠열의 분배, 그리고 기온에 연쇄적으로 큰 영향을 미친다. 초기화를 통한 토양 수분 개선(+0.185m bias 제거)이 이러한 결합 과정을 강화하여 예측 성능 향상으로 이어진 것으로 해석된다.

흥미로운 포인트로 CUS와 SEE 모두 31-45일에 비해 46-60일 구간에 리드타임 증가에 따른 개선률이 급증하는 매우 특이한 패턴을 보였다. 31-45일 개선도가 작은 이유는 CTRL 예측이 상대적으로 양호하여 초기화의 추가 기여가 제한적이었기 때문으로 보이며, 이후의 급증은 토양 수분 메모리가 증장기적으로 기여하는 지연 효과(delayed effect)로 추정된다.

또한, 16-30일과 46-60일 기간에 SEE 지역의 60%와 45%에 가까운 극단적 개선률에는 통계적 불확실성이 내재되어 있다. 절대값 기준으로는 여전히 의미 있는 개선이나, 개선률은 통계적 변동성을 고려해 신중히 해석할 필요가 있다.

극 주변 고위도 대륙(70-90° N)에서는 초기화 효과가 거의 없었는데, 이는 눈 덮임 및 토양 동결로 토양 수분의 영향이 제한적이기 때문으로 해석된다.

강수 예측 성능은 모든 리드타임에서 초기화의 영향을 거의 받지 않았다(Figure 3.24). 16-30일( $\Delta R^2 = +0.0003$ ), 31-45일( $\Delta R^2 = -0.0006$ ), 46-60일( $\Delta R^2 = -0.0018$ )로 변화량이 매우 작고 통계적으로 유의하지 않았다( $p > 0.50$ ). 이는 계절내-계절 시간 규모에서 강수가 주로 대기 순환과 대규모 해양-대기 상호작용(ENSO, MJO 등)에 의해 결정되며, 지면 조건의 영향은 제한적임을 의미한다.

기온 예측에서 큰 개선을 보인 hotspot 지역에서도 강수는 유의한 변화가 없었다. 이는 토양 수분-증발산-기온 결합 경로는 명확하나, 토양 수분-증발산-강수 피드백은 아계절 규모에서 약하거나 복잡한 비선형성으로 인해 개선 효과가 명확하지 않음을 시사한다.  $\Delta R^2$  공간 분포를 검토한 결과, 일부 격자점에서  $\pm 0.05$  범위의 변화가 나타났으나 공간적 일관성이 없고 통계적 유의성도 낮아( $p > 0.20$ ) 우연적 변동(random fluctuation)으로 판단된다. 예외적으로 일부 몬순 지역(인도 서북부, 서아프리카 사헬)에서 유의미한 변화가 관찰되었으나, 표본 수가 적고 연도별 변동성이 크며 물리적 메커니즘이 불명확하여 추가 연구가 필요하다.

강수 예측에 대한 토양 수분 초기화의 중립적 영향은 다음과 같이 해석된다. 첫째, 기온은 지면 플럭스(증발산, 현열)에 직접 영향을 받아 토양 수분과 강한 결합을 보이나, 강수는 대규모 대기 순환, SST, 대류 활동 등 다양한 요인에 지배되어 토양 수분의 기여가 상대적으로 작다. 둘째, 토양 수분에서 증발산, 수증기 공급, 강수로 이어지는 피드백은 비선형적이며 지역 및 계절에 따라 양의 피드백과 음의 피드백이 혼재한다. 아계절 규모에서는 이러한 피드백의 상쇄 효과로 인해 체계적 개선이 어려울 수 있다. 셋째, SCoPS의 대류 모수화(convective parameterization) 및 수평 해상도(T159) 한계로 인해 강수의 중규모 변동성을 정확히 재현하기 어렵다. 결론적으로 토양 수분 초기화는 기온 예측에 효과적이거나 강수 예측에는 유의한 영향을 미치지 않는다. 이는 선행 연구들(Koster et al., 2011; Roundy et al., 2013)과 일관된 결과이며, 아계절 예측에서 지면 초기화의 역할이 변수별로 차별화됨을 시사한다.

본 절의 결과는 앞선 세 절의 분석과 일관된 인과 체인을 형성할 수 있다: (1) 초기화 - EAKF 알고리즘이 12일 내에 토양 수분을 관측에 가까이 수렴(RMSE 99% 감소), (2) 메모리 -

초기화된 정보가 약 30-40일간 보존(e-folding time 기준), (3) 결합 - 주요 hotspot 지역에서 지면-대기 결합 강도 증가(최대 87-101%), (4) 예측성 - 결합이 강화된 지역에서 기온 예측 정확도 향상(최대 15-60%).

이러한 체계적 연결은 토양 수분 초기화가 물리적으로 일관된 메커니즘을 통해 계절내-계절 예측 성능을 개선함을 보여준다. 특히 미국 중서부와 남동 유럽 지역의 46-60일 개선은 토양 수분 메모리가 충분히 긴 지역에서 초기화 효과가 2개월까지 지속될 수 있음을 시사하며, 이는 계절 예측으로의 확장 가능성을 제시한다.

### 3.3. 대기/해양 초기자료 최적화

전 세계적으로 S2S 예측 성능 향상을 위한 다양한 시도가 이루어지고 있으며, 특히 초기화 기술의 고도화가 예측 정확도 개선의 핵심 요소로 주목받고 있다. 현재 구축되어 있는 APCC 자체모델(SCoPS; Ham et al. 2019)의 대기-해양 초기장의 문제점을 파악하여 초기 오차의 개선이 계절내-계절 규모의 예측성능에 어떠한 영향을 줄 수 있는지 알아보려고 하였다. 또한, 계절내 변동성에 매우 중요한 영향을 줄 수 있는 지면 상태의 개선을 위해 S2S 예측의 핵심 요소인 지면 초기화 기법을 개발하여 적용함으로써 신뢰도 높은 계절내예측 정보를 위해 자체모델을 활용하고자 한다.

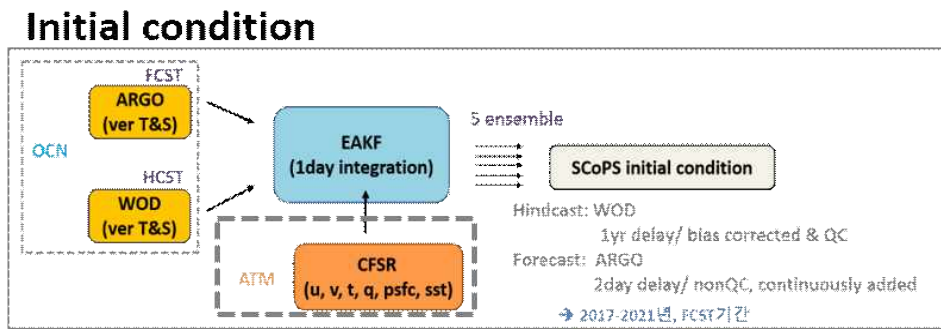


Figure 3.25. Schematic of the initialization procedure for the SCoPS system.

Figure 3.25은 SCoPS에 사용되는 초기화 절차의 흐름을 도식화한 것이다. 대기장과 해양장의 자료를 사용하여 EAKF 1일 적분을 수행하여 초기장을 생산하는 대기-해양 결합 초기화로 구성되어 있다. 해양의 연직 온도 및 염분장은 예측에서는 ARGO 자료, 과거재현에서는 WOD 자료를 활용한다. ARGO자료는 품질체크가 적용되지 않은 2일 지연의 실시간 자료를 활용하며, WOD자료는 1년 지연으로 품질 체크를 통해 오차가 제거된 자료를 활용한다. 대기 변수(연직 바람, 연직 온도, 연직 습도, 지표기압) 및 해수면온도는 CFSR 자료를 사용한다. 모든 자료는 대기-해양 결합 초기화를 통해 5개의 앙상블 초기장이 산출된다.

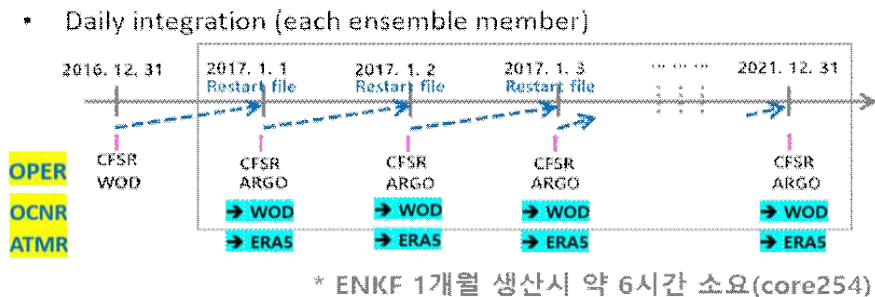


Figure 3.26. Workflow of the daily ENKF-based initialization for atmospheric and oceanic fields.

Figure 3.26은 대기 및 해양장을 대상으로 수행되는 일별 ENKF 초기화 과정의 흐름도를 나타낸다. 각 5개의 앙상블 멤버를 대상으로 2016년 12월 31일 초기 조건을 시작으로 ENKF 및 1일 적분을 통한 2017-2021년의 모델 초기장을 생산한다. 매일 초기 조건을 생산된 초기장에 업데이트하는 방식으로 일별 초기자료를 구축한다. 기존의 ARGO, CFSR 자료를 사용하던 OPER 실험과 비교하기 위해 해양 초기조건을 WOD로 대체하는 OCNR 실험과 대기 초기조건을 ERA5로 대체하는 ATMR 실험을 구성하여 총 3가지의 초기자료를 구축하였다. 이러한 ENKF 기반의 일 초기화 절차는 254코어 환경에서 한달분 초기자료를 생산하는데 약 6시간의 계산 시간이 소요된다. OPER, OCNR 실험의 비교를 통해 forecast와 hindcast의 자료 불일치 영향을 살펴보고, 해양 초기오차 개선을 통한 계절내 및 계절예측의 계통적 오차의 변화를 살펴보고자 한다. 또한 OPER, ATMR 실험의 비교를 통해 현재 종료 가능성이 있는 CFSR 서비스 대안을 마련하고자 하며, 추후 지면초기화와의 연계성을 고려해보고자 한다. 또한 대기 초기오차 개선을 통한 계절내 및 계절예측의 오차 변화를 조사해보고자 한다.

### 3.3.1. 해양 초기장의 영향

Figure 3.27은 GODAS 관측과 SCoPS 기존 실험의 해양 연직 초기장 분포와 두 실험간의 차이를 나타낸 그림이다. GODAS에서는 동태평양의 upwelling 및 ENSO의 신호들을 보이고 있다. 2017년은 중, 동태평양의 냉수역이 두드러지며, 2018년은 따뜻한 해수층이 강화된다. 2019년은 동태평양에서 온난역이 확대되며 서태평양 하부는 차가운 해수층이 강화되고 있다. 관측 자료 아노말리의 분포와 비교하였을 때, SCoPS의 기존 실험인 OPER는 동태평양 subsurface를 중심으로 연도에 관계없이 비교적 큰 양의 오차를 보이고 있다. 동태평양 upwelling 지역을 중심으로 온난층의 깊이가 과도하게 두껍게 나타나고 있다. ONCR 실험과 기존 실험과의 차이를 살펴보면 모든 해에 동일하게 기존 실험의 온난 오차를 완화하고 있으며, 특히 100-200m 수심대에서 가장 큰 차이를 보이고 있다. 즉, 해양 초기화 방법이 태평양 수온 약층의 깊이를 비롯해 해수층의 온도 오차를 효과적으로 줄일 수 있음을 알 수 있다.

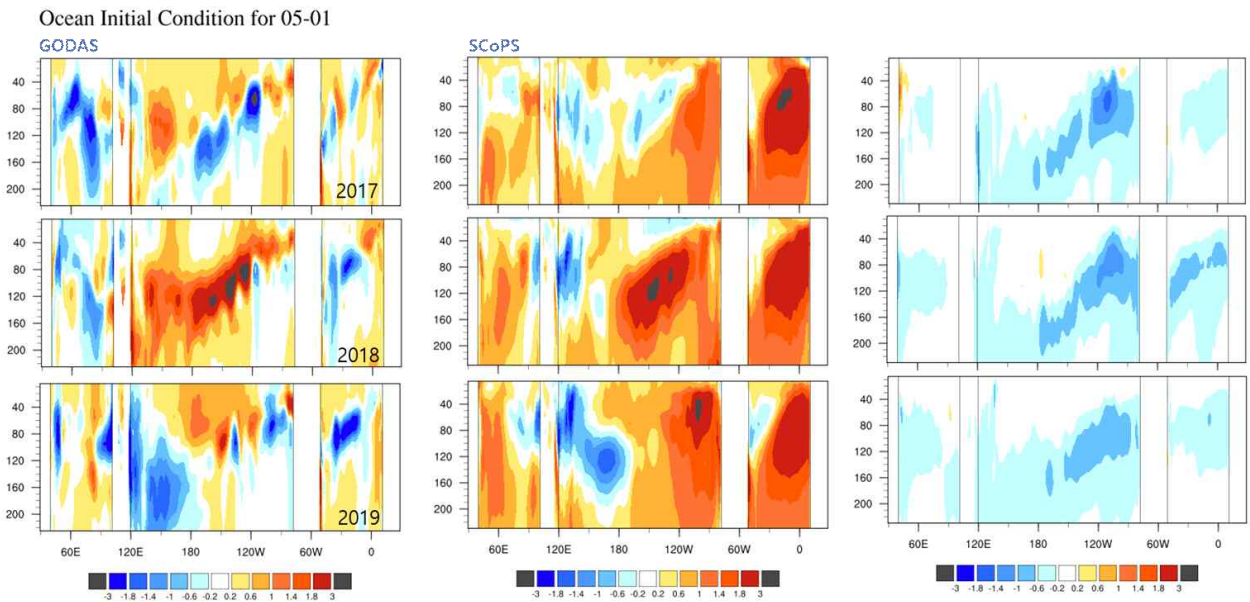


Figure 3.27. Comparison of ocean vertical temperature initial condition on May 1 for the years 2017-2019. (left) GODAS-based temperature anomaly, (middle) OPER-driven temperature anomaly, and (right) difference between OPER and ONCR experiments.

Figure 3.28은 SCoPS의 기존 실험과 해양초기장을 바꾼 ONCR 실험의 연직 해양 온도 및 염도의 차이를 나타낸 그림이다. 표층 온도의 경우, 북대서양 고위도 및 오호츠크 해에서 비교적 뚜렷한 차이를 보이고 있다. 표층 염분 차이를 살펴보면, 북대서양 아열대 고염 영역에서 ONCR의 염도가 높아지고 열대 인도양 및 동태평양에서 염도가 낮아지는 것을 알 수 있다. 중층에서는 두 실험의 수온 차이가 더욱 강하게 나타난다. 적도 태평양 및 대서양을 중심으로 매우 강한 차이가 나타나며 이는 두 실험의 thermocline 구조가 크게 달라졌음을 시사한다. 동태평양은 96m 수심대에서, 중태평양은 190m 수심대에서 가장 큰 차이를 보이고 있다.

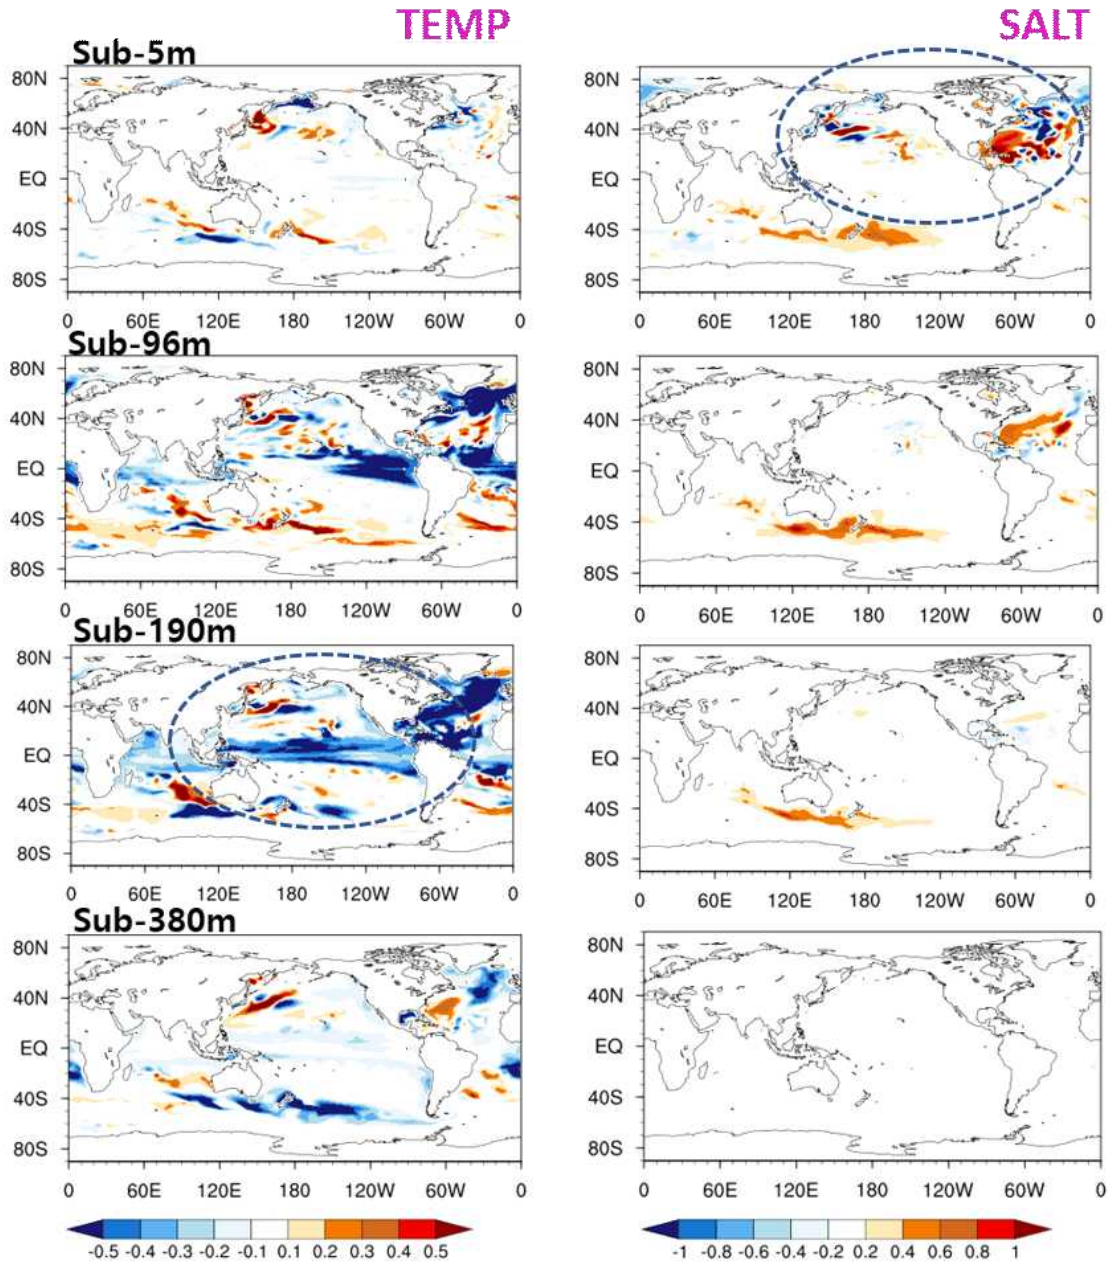


Figure 3.28. Vertical distribution of (left) temperature and (right) salinity differences between OPER and ONCR experiments at four depth levels (5m, 96m, 190m, and 380m).




Figure 3.29. Lead-time evolution (1-100 days) of the OCNR - OPER differences in (top) temperature and (bottom) salinity for eastern Pacific region.

Figure 3.29는 동태평양 영역에서 OCNR과 OPER의 온도 및 염분 차이를 리드타임 (1-100 일)에 따른 변화를 나타낸다. 온도 차이의 경우, 표층(5m)과 아표층(96m, 190m) 모두에서 초기 시간부터 100일까지도 일정한 차이를 보여주고 있다. 반면, 리드타임이 약 60일 전후가 되는 시점부터 표층 수온에서 매우 두드러진 온도 변동이 나타나고 있다. 이는 아표층 온도 구조의 변화가 점진적으로 표층으로 전파되는 지연된 subsurface-to-surface 반응 과정으로 볼 수 있다. 이러한 반응은 ENSO관련 서태평양-동태평양 열수지 전달 과정의 전형적인 시간 스케일과도 일치하고 있어 두 실험의 thermocline 구조의 변화가 가져오는 결과라고 볼 수 있다. 반면, 염분에서는 리드타임 전반에 걸쳐 상대적으로 작은 변화만이 확인된다. 이는 염분 변화가 표층 대기-해양 상호작용의 영향이 약한 동태평양에서 주로 나타나기 때문에 시간에 따라 크게 확대되지 않기 때문으로 보인다. 따라서 염분보다 온도 차이가 두 초기장 변화에 더욱 민감하게 반응하고, 그 영향이 훨씬 명확하게 리드타임에 따라 변화할 수 있음을 알려준다.




Figure 3.30. Lead-time evolution (1-100 days) of the OCNR - OPER differences in (top) near-surface air temperature, and (bottom) 850 hPa specific humidity for the (left) eastern Pacific and (right) East Asia regions. The solid black line represents the ensemble mean and grey lines denote individual ensemble members.

Figure 3.30은 동태평양(EP) 및 동아시아(EA) 영역에서 OCNR과 OPER 실험의 지표기온 및 하층 습도 차이를 리드타임에 따라 나타낸 그림이다. 검은 실선은 앙상블 평균, 회색선은 각 앙상블 멤버를 나타낸다. 동태평양 영역에서는 리드타임 초기 약 7일 이내에 명확한 차이가 나타나기 시작하며, 이는 초기화 단계의 두 실험이 가진 해양의 차이가 예측 초기에 직접적으로 반영된 결과라 할 수 있다. 다만, 두 실험의 대기 변수 및 해수면 온도의 차이가 없기 때문에 직접적인 예측장의 차이는 크지 않다. 이후 리드타임이 증가함에 따라 차이가 점진적으로 변화하는데, 이는 해수면 온도 변화가 대기 하층에 전달되며 나타나는 해양-대기 상호작용의 영향이라 할 수 있다. 반면, 동아시아 영역에서는 두 실험의 차이가 리드타임 전 구간에 걸쳐 전반적으로 작고, 뚜렷한 시간적 변화 패턴도 확인되지 않는다. 이는 동아시아 지역의 대기 변동성이 해양 초기 조건보다 대기 변동성에 더 크게 좌우되며, 초기 해양 상태 영향이 동태평양에 비해 대기변수에 미치는 영향이 상대적으로 제한적임을 의미한다. 또한 동아시아 지역은 원격 상관에 대한 영향이 더 크게 나타나기 때문에 해양 초기화 개선 효과가 영향을 주지 못하는 것으로 판단할 수 있다.

Figure 3.31은 OCNR 실험이 OPER 실험 대비 T2M RMSE의 차이를 OPER 실험의 RMSE로 나누어 그 비율(dRMSE)을 나타낸 그림이다. 음의 값은 기준 실험 대비 오차가 감소한 지역을, 양의 값은 오차가 증가한 지역을 의미한다. 또한 바뀐 5월 초기장을 사용하여 예측한 결과의 1-15일, 16-30일 리드타임에 대해 나타낸 그림이다. 전반적으로 dRMSE의 크기는 전 지역에 대해 낮은 값을 보인다. 특히 1-15일 리드 타임의 결과에서는 열대 태평양 일부 지역과 남미 남동부 등에서 소폭의 차이가 있고 해양 초기 조건의 영향은 거의 없다고 할 수 있다. 계절내 규모인 16-30일 리드 타임의 결과에서는 차이의 크기는 여전히 작지만 공간적 분포가 더 퍼져서

나타난다. 북반구 여름철인 JJA를 나타내는 1-3개월 리드 타임에서는 두 실험의 차이가 거의 나타나지 않는다 (그림에 나타내지 않음). 대부분의 차이는 5% 이내로 나타나기 때문에 T2M에 해양 연직 초기 조건이 미치는 영향은 매우 제한적임을 알 수 있다.

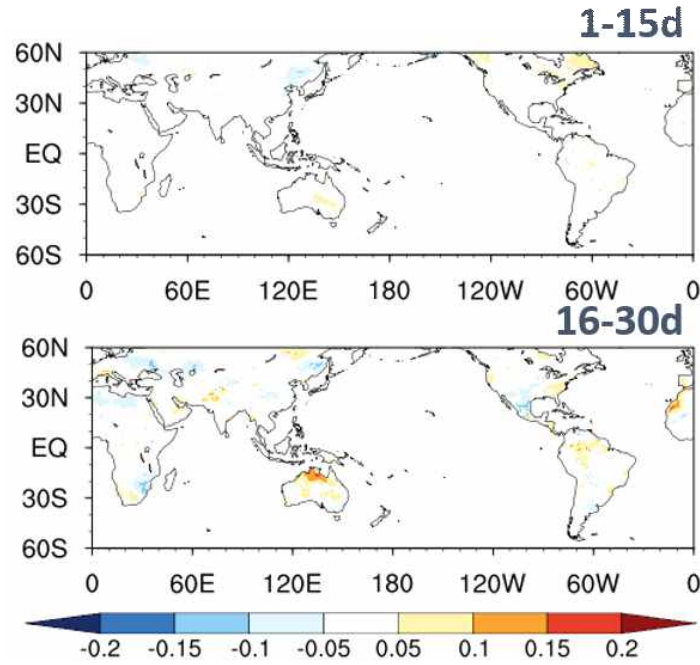


Figure 3.31. Spatial distribution of the change in T2M RMSE difference rate (dRMSE) for the OCNR experiment. Negative values indicate reduced errors relative to the OPER experiment, whereas positive values denote increased errors.

### 3.3.2. 대기 초기장의 영향

Figure 3.32는 2017-2021년 5월의 GODAS 관측과 SCoPS 기존 실험의 해수면 온도 및 해양 연직 초기장 분포와 두 실험간의 차이를 나타낸 그림이다. GODAS에서는 중태평양의 따뜻한 해수면 온도 및 중앙에서 서태평양으로 따뜻한 해수층 동태평양으로 차가운 해수층을 보이고 있다. SCoPS의 기존 실험인 OPER에서는 전반적으로 해수면 온도를 잘 모의하고 있지만 북서태평양 및 대서양 일부에서 관측에 비해 높은 온도를, 동태평양 남미 연안에서는 관측보다 낮은 해수면 온도를 보이고 있다. 반면, 동태평양의 해수층의 분포를 보면 관측 자료에 비해 매우 높은 온도를 모의하고 있으며, 대서양의 해수층 역시 매우 따뜻하게 나타나고 있음을 알 수 있다. ONCR 실험과 기존 실험과의 차이를 살펴보면, 북서태평양을 비롯한 여러 지역에서 해수면온도가 OPER 보다 낮게 나타나며, 동태평양 연안에서 OPER보다 높게 나타나고 있다. 특히 인도양에서 Maritime Continent, 한반도, 오호츠크해 연안까지 이르기까지 온도의 차이가 뚜렷이 나타나고 있다. Subsurface 연직 온도 분포에서도 대기 초기 조건이 바뀐 실험에서 동태평양의 계통적 오차인 온난 오차를 효과적으로 줄여주고 있음을 확인 할 수 있다. 이는 ONCR 실험과 OPER의 차이의 분포와도 흡사하게 나오고 있으며 해양 초기조건이 바뀌지 않았음에도 불구하고 오차가 줄어드는 긍정적이 효과로 볼 수 있다. 이는 SCoPS의 초기화 기법의 특성으로 인해 야기한 것으로 볼 수 있다. SCoPS는 대기-해양 결합 초기화 방법을 사용하고 있으며, 대기 초기 조건을 바꾸고 해양 초기 조건이 그대로이지만 초기 조건이 바뀐 뒤 자료동화를 거쳐 대기-해양 모델 적분을 통해 리스타트 파일을 생산하여 밸런스를 맞추는 과정이 포함되어 있다. 따라서 해양 연직 온도 조건은 동일하지만 해수면 온도가 변화하여 해양 모델이 적분되면서 해양 연직 온도의 변화가 일어나고 이러한 변화가 초기장에 반영이 되어 긍정적 효과를 보인 것으로 분석된다. 즉, 대기 조건 및 해수면 온도의 초기 변화가 태평양 수온 약층의 깊이를 비롯해 해수층의 온도 오차를 효과적으로 줄일 수 있음을 알 수 있다.

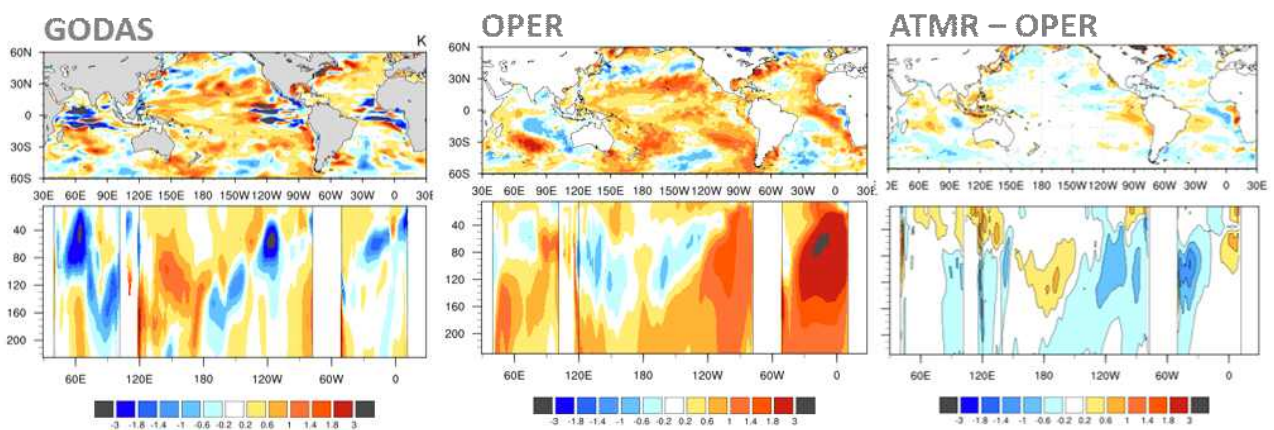


Figure 3.32. Comparison of ocean surface and subsurface temperature initial condition on May 1 for the years 2017-2021. (left) GODAS-based temperature, (middle) OPER-driven temperature, and (right) difference between OPER and ATMR experiments.




Figure 3.33. Time series of the (top) global, (middle) tropics, and (bottom) east Asian for 2017-2021 averaged 2m temperature RMSE values for the OPER(blue) and ATMR(magenta) experiments over a 1-365-day period.

Figure 3.33은 OPER와 ATMR 실험의 전지구, 열대, 동아시아 평균 지표 온도 RMSE 오차의 일별 변화를 5년 평균하여 나타낸 값이다. 두 실험의 일관적인 차이를 확인할 수 있으며, 전지구 평균에서는 약 120-160일 부근에서는 가장 뚜렷한 큰 오차를 보이고 있으며, ATMR이 OPER보다 모든 계절에서 낮은 값을 유지하고 있다. 열대 지역 평균의 경우 두 실험이 모두 유사한 변동을 보이지만, 변동성이 증가하는 여름철, 겨울철 시기에 OPER 실험의 RMSE가 더 증가한 RMSE를 보이고 있다. 동아시아 지역에서도 OPER 실험의 RMSE에 비해 ATMR 실험의 RMSE가 더 낮아지는 것을 확인할 수 있다. 즉, 대기 초기 조건을 ERA5로 바꾸었을 때 대부분의 지역에서 지표 온도의 오차를 줄여 줄 수 있음을 확인할 수 있다. 이러한 결과는 ATMR 실험에서 적용된 대기 관련 변화가 모델의 대규모 및 열대 영역에 영향을 미칠 수 있음을 기대할 수 있다. 다시 정리하면, RMSE의 시계열의 비교는 ATMR 실험이 OPER 대비 전지구 및 열대, 동아시아 지역에서 모두 개선된 오차 구조를 제공하며, 대기 상하부 과정의 상호작용을 보다 효과적으로 재현할 수 있음을 시사한다.

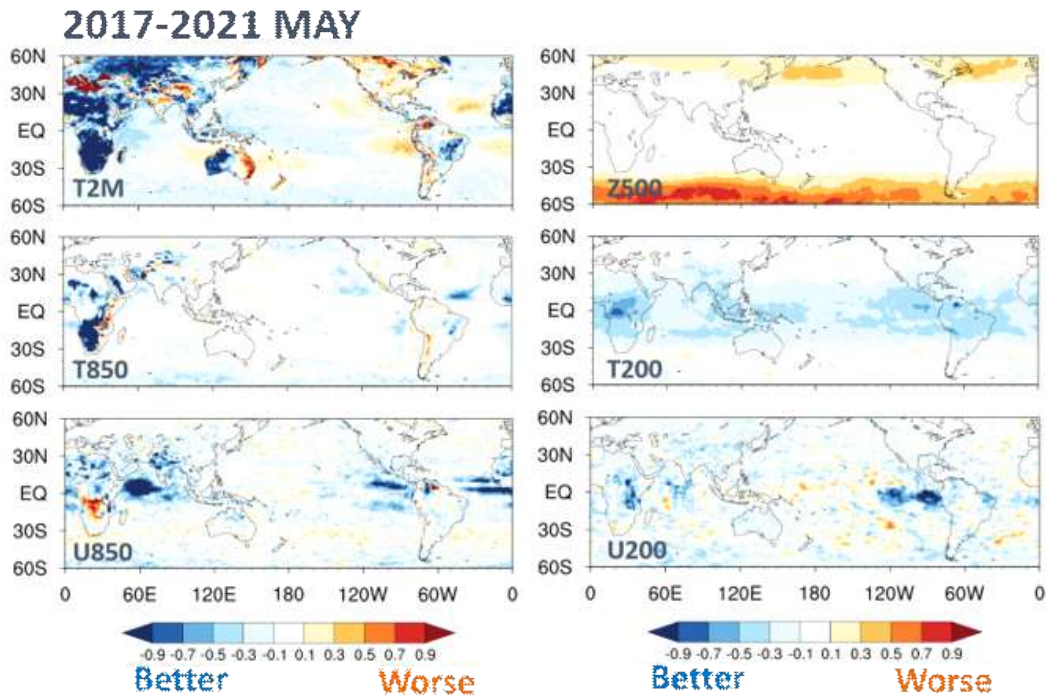


Figure 3.34. Spatial distribution of the RMSE difference rate between the two experiments for six atmospheric variables initial condition for 2017-2021 May. Colors indicate improvement (blue) or degradation (red) in ATMR experiment relative to the OPER experiment.

Figure 3.34는 두 실험 간 여름철 초기장 예측 성능의 차이를 다양한 대기 변수와 연직 레벨에서 비교한 결과이다. 2m 기온과 850hPa 기온의 경우 열대 및 남반구 해양을 중심으로 오차가 뚜렷하게 감소하며, 이는 지표 및 하층 온도장의 초기화가 열적 구조를 재현하는 데 기여할 수 있음을 보여준다. 850hPa 동서 바람에서도 유사한 개선 패턴이 관찰되며, 이는 하층 제트 및 저위도 순환 구조의 재현의 개선을 나타낸다. 또한 대기 상층인 200hPa 기온과 동서 바람의 오차 변화를 살펴보면 저위도 지역으로 중심으로 ATMR 실험의 RMSE가 매우 효과적으로 줄어들고 있음을 알 수 있다. 다만, 500hPa 지위 고도는 중-고위도 지역을 중심으로 오차가 늘어난다. 다른 변수와는 다르게 진단 변수임에도 오차가 늘어나는 이유는 SCoPS의 대기-해양 결합 초기화에 사용되는 대기 변수는 연직 바람, 온도, 습도 ( $u$ ,  $v$ ,  $t$ ,  $q$ )이며, 지위고도( $z$ )는 연직층 모두가 아닌 지표 기압(psf)만 사용되기 때문이다. 마찬가지로 겨울철 초기장 RMSE 오차 비율을 나타낸 Figure 3.35를 살펴보면, 여름철 초기장 오차 차이와 거의 유사한 결과를 보이고 있다. 상층 지위고도를 제외하고 모든 연직 대기 변수에서 RMSE가 효과적으로 줄어드는 특징을 보이고 있다. 다만, 2m 기온의 경우 북미 및 동태평양 남단으로 오차가 늘어나는 특징도 보이고 있다.

2017-2021 NOV

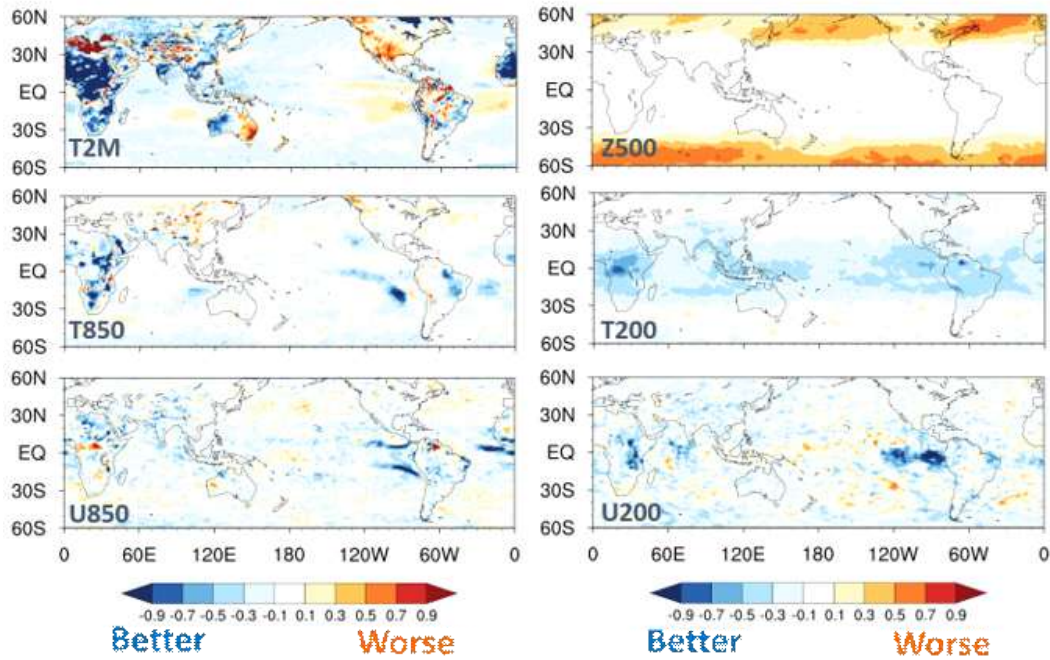


Figure 3.35. Spatial distribution of the RMSE difference rate between the two experiments for six atmospheric variables initial condition for 2017-2021 November. Colors indicate improvement (blue) or degradation (red) in ATMR experiment relative to the OPER experiment.

Figure 3.36은 적도 태평양의 해수면 온도(SST)에 대한 Hovmoller 다이어그램으로 관측, OPER의 오차, OPER와 ATMR 실험의 차이를 나타낸 것이다. 각 패널은 1월부터 12월에 이르는 기간동안 적도 부근의 경도-시간 SST 변화를 보여주고 있다. OPER 실험은 관측에서 나타나는 동-서 SST의 기울기와 계절적 진화 특성을 대체로 잘 모의하고 있지만, 중-동태평양에서 양의 해수면 온도 오차가 과도하게 나타나는 경향이 있다. 이는 OPER 실험에서 ENSO 관련 해수면 온도 진폭이나 동서 비대칭 구조의 일부가 과도하게 표현되었음을 나타내며, 특히 1월에서 12월로 이어지는 모든 기간에서 중태평양의 온난 시그널이 관측보다 지속적으로 크게 나타나고 있다. 반면 EXPR - OPER 차이에서 중, 동태평양을 중심으로 SST 편차가 감소하는 영역이 넓게 분포하며, 이는 EXPR 실험에서 초기 조건이 해양 표층의 열적 구조를 보다 현실적으로 완화시키는 방향으로 작용했음을 보여준다. 특히 Nino3 및 Nino3.4 영역에 해당하는 경도대에서 오차 감소가 뚜렷하여, EXPR 실험이 OPER 대비 ENSO 관련 SST 편차의 과대 모의를 효과적으로 줄이고 있음을 알 수 있다. 즉, EXPR 실험이 계절 전환기 적도 SST 진화와 동서 SST 비대칭을 보다 정확히 재현하며, 결국 예측 초기장의 해양 상태 표현을 개선하는데 기여했음을 의미한다.




Figure 3.36. Hovmöller diagrams of equatorial Pacific sea surface temperature(SST) for (left) observation(OBS), (middle) the OPER - OBS, and (right) the EXPR - OPER difference. The panels show the longitude-time evolution of SST along the equator from January(bottom) to December(top).




Figure 3.37. Evolution of ocean and atmospheric temperature difference between OPER and ATMR experiments as a function of lead time (1-100 days). (top) Subsurface temperature represents at 3m (black), 96 m (purple), and 190 m (cyan). (bottom) Highlighting black line indicates a pronounced SST response for the ensemble mean and gray lines for each individual experiment.

Figure 3.37은 OPER와 ATMR 실험의 리드타임(1-100일)에 따른 해양 및 대기 온도 차이를 나타낸 그림이다. Subsurface의 해수층 온도를 살펴보면, ATMR 실험은 5m 수심에서 초기 리드타임부터 뚜렷한 온도 증가를 보이고 있으며 이는 해수면 온도의 증가 및 그에 따른 표층 혼합층의 반응으로 나타난 결과이다. 그러나 심층으로 갈수록(96m, 190m) SST 변화에 대한 영향은 약화되지만, 해수층의 초기조건이 변하지 않았음에도 기존 실험과 대비하여 뚜렷하고 일관된 차이를 보이고 있음은 주목할 만 하다. 한편, 2m 기온의 경우 리드타임 전 구간에서 상대적으로 작지만 일관된 차이를 보이고 있다. 해양 초기 조건을 바꾸었을 때 약 60일 정도의 해양-대기 반응이 필요했던것과 달리 대기 초기 조건을 바꾸었기 때문에 거의 즉각적인 대기-해양 반응이 일어나고 있어 대기변수 및 해양변수 모두가 바뀌는 결과를 보이고 있다.

Figure 3.38은 리드타임 구간에 따른 예측 성능 변화의 공간 분포를 나타낸다. 붉은색으로 나타나는 지역은 OPER 실험 대비 ATMR 실험의 RMSE가 줄어드는 지역을 나타내며, 푸른색으로 나타나는 지역은 RMSE가 증가하는 지역을 나타내고 있다. 값은 두 실험의 RMSE의 차이를 기존의 OPER 실험 RMSE로 나누어 나타낸 변화 비율을 표현한다. 1-15일 리드타임에서는 일부 지역에서 예측 성능의 개선이 뚜렷하게 나타나고 있으며, 이는 대기 초기장의 불확실성을

줄이는 과정이 단기 예측에 직접적으로 기여하고 있음을 시사한다. 특히 중위도 폭풍대 및 열대 수렴대 부근에서 개선된 신호가 나타나는데, 이는 대기 초기조건이 대규모 순환 패턴의 초기 반응을 안정화시키는 역할을 한다는 점을 보여준다. 한편, 16-30일 리드타임으로 넘어가면 예측성능이 개선된 영역이 여전히 유지되고 있음을 알 수 있다. 이는 대기 초기화 효과가 초기 단기 구간뿐 아니라 subseasonal 예측 구간에서도 안정적이고 일관된 성능 향상을 이끌어내는 데 기여함을 확인할 수 있다.

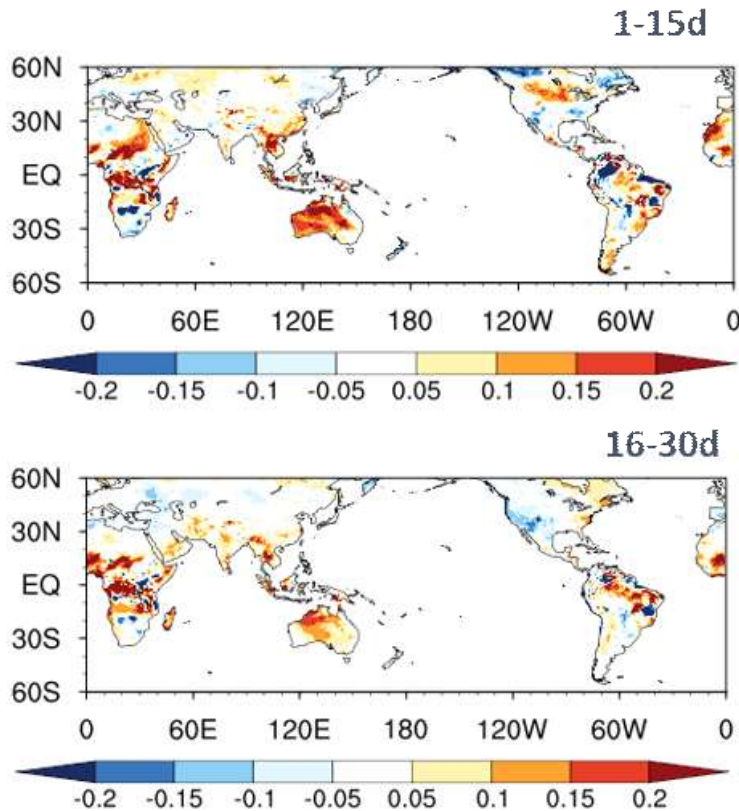


Figure 3.38. Spatial distribution of the change in T2M RMSE difference rate (dRMSE) for the ATMR experiment. Negative values indicate reduced errors relative to the OPER experiment, whereas positive values denote increased errors.

Figure 3.39는 동아시아 지역에서 리드타임 16-30일 동안의 기온 및 동서 바람 연직 프로파일에 대한 예측과 관측의 차이를 나타낸다. 검은색 실선은 OPER, 파란색 실선은 OCNR, 붉은색 실선은 ATMR 실험의 biases를 나타낸다. OPER 실험과 비교해 볼 때 해양 초기장을 바꾼 실험은 연직 온도의 차이가 거의 나타나지 않으며, 동서 바람의 경우 상층에서 약간의 변화가 나타나고 있음을 알 수 있다. 그에 비해 대기 초기 조건을 바꾼 ATMR 실험의 경우 기존 OPER 실험과 달리 연직 온도 오차를 크게 줄여주고 있으며, 이는 대기 초기 조건의 개선이 중위도 지역 제트류 및 상층 열구조 재현에 보다 효과적으로 영향을 줄 수 있음을 시사한다. 즉, 대기 초기조건의 변화는 예측성 향상으로 연결될 수 있으며 특히 subseasonal 예측에서 중요한 역할

을 할 수 있음을 의미한다.




Figure 3.39. Vertical profiles of experiments - observation differences for (left) temperature and (right) zonal wind over the East Asia region at 16-30 day lead time. Black, blue, and red lines represent the OPER, OCNR, ATMR experiment, respectively.

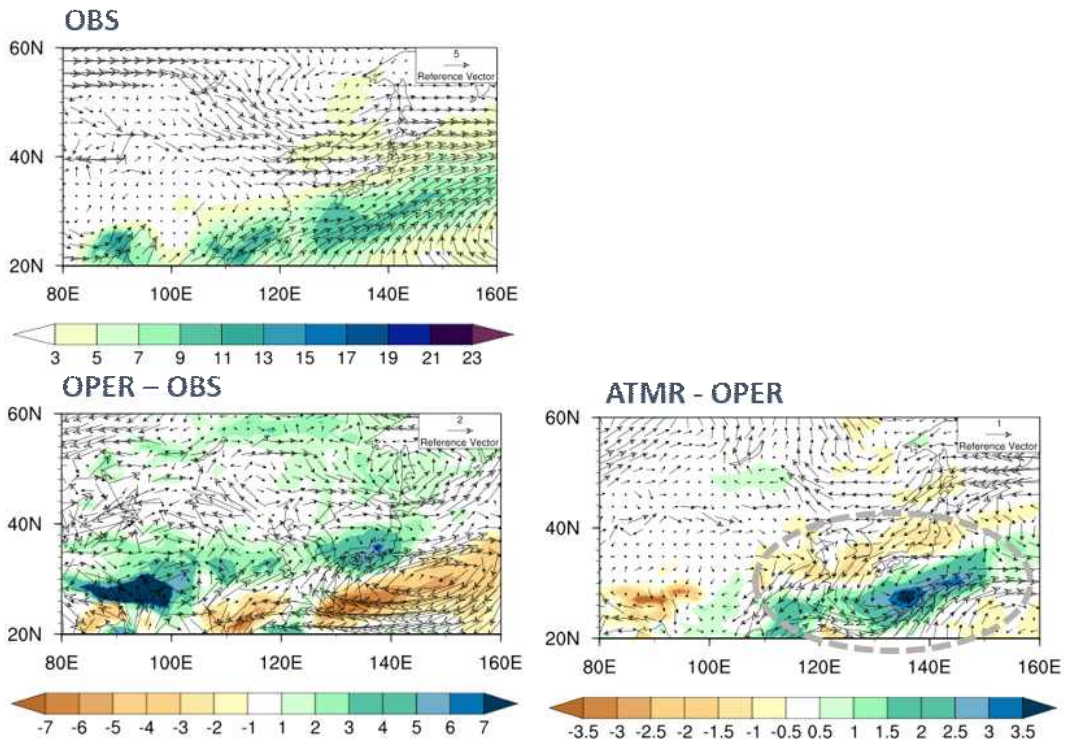


Figure 3.40. Comparison of precipitation distribution and biases over East Asia. (top) Observed mean precipitation with atmospheric circulation(850hPa wind vectors). (bottom-left) Precipitation biases from the OPER experiment. (bottom-right) Differences between the ATMR and OPER experiments.

Figure 3.40은 동아시아 지역의 강수 분포 및 16-30일 리드타임의 예측 오차를 나타낸 그림이다. 관측의 평균 강수 분포와 하층 바람장과 함께 OPER의 오차, ATMR과 OPER 두 실험의 차이를 나타내었다. 먼저 관측에서 확인되는 열대 및 아열대 해양을 따라 발달한 강수대는 OPER 실험에서 일부 지역에서 과대모의 또는 과소모의가 위/아래로 나타난다. 특히 남중국해 및 북서태평양에서의 과대 강수 편차는 수렴대 위치를 정확히 재현하고 있지 못함을 나타낸다. 반면, ATMR 실험의 결과를 보면 이러한 강수 편차를 매우 뚜렷하게 완화시키며, 이는 초기 대기장의 정확도 개선이 저층 바람 수렴 및 수증기 수송 패턴을 보다 적절하게 모의시킬 수 있음을 알 수 있다. 또한 바람장의 변화는 대기 초기화가 몬순 계통 및 서쪽 제트류에도 영향을 미칠 수 있음을 보여준다. 결과적으로 대기 초기조건 개선은 16-30일 리드타임의 subseasonal 영역에서 동아시아 강수에 뚜렷하게 영향을 미칠 수 있음을 확인할 수 있다.

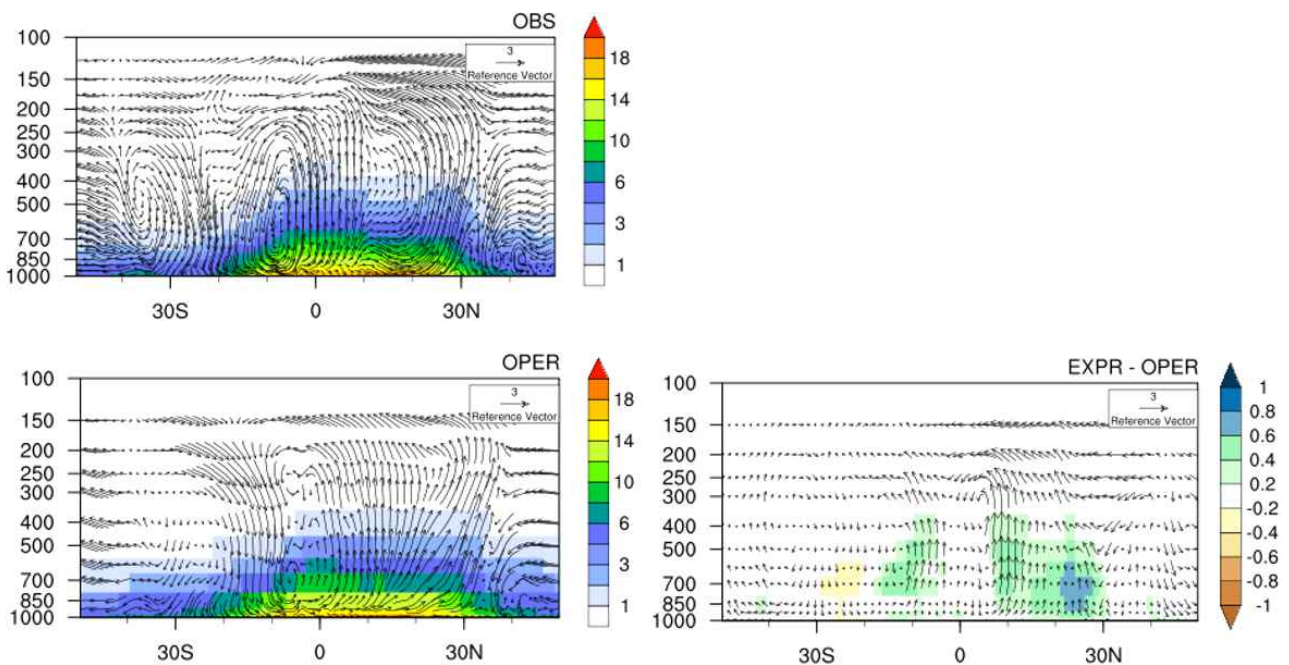


Figure 3.41. Vertical humidity distribution and local Hadley circulation over the western Pacific-East Asia region for (top) Observed humidity (shading) and meridional-vertical circulation (vectors), (bottom-left) OPER experiment, and (bottom-right) difference between ATMR and OPER.

Figure 3.41은 서태평양-동아시아 지역에서의 연직 습도 분포와 로컬 해들리 순환 구조를 관측과 두 실험 간 비교를 통해 분석한 결과이다. 관측에서는 적도 부근의 강한 상승 운동과 아열대 지역의 하강 운동이 뚜렷하게 나타나며, 이는 풍부한 저층 수증기와 결합하여 북상하는 몬순 수렴대의 형태를 형성한다. OPER 실험에서도 전반적인 순환 구조는 모의되고 있으나, 적도 부근의 상승 운동은 다소 약화되어 나타나며 중층 습도 역시 낮게 나타나 대류 활동의 강도가 충분히 재현되지 못하고 있다. 반면, ATMR 실험은 OPER 실험에 비해 중층 상승 운동 강화 및 저층 수증기 공급 증가가 확인되며, 이는 대기 초기조건 개선이 수렴대 위치와 수직 수송 구조를 보다 현실적으로 반영하는데 기여했음을 나타낸다. 이러한 개선은 앞서 보인 동아시아

아 강수 예측의 오차 감소에 영향을 줄 수 있었을 것으로 판단된다.




Figure 3.42. Improvement rates of forecast skill in the ATMR experiment relative to the OPER experiment for 1-15 days, 16-30 days lead time and Global, Tropics, and East Asia regions. Positive values indicate an enhancement in forecast performance, while negative values represent degradation.

Figure 3.42는 OPER 실험 대비 ATMR 실험에서의 예측 성능 향상률(Improvement rate)을 리드타임 구간별(1-15일, 16-30일) 및 영역별(Global, Tropics, East Asia)로 비교한 결과를 나타낸 그림이다. T2M, U850, T850, T500, U200, T200 변수에 대해 계산된 RMSE 변화 비율이 양수일수록 예측 성능이 개선되었음을 의미하며, 음수는 성능 저하를 나타낸다. 1-15일 단기 리드타임에서는 전지구 평균 기준으로 T2M 향상이 나타나며, 열대지역 평균 하층 온도 및 바람장, 상층 온도 등의 향상이 두드러진다. 열대지역에서 특히 상층 온도장의 향상이 크게 증가하는 특징이 나타나며, 이는 Hadley 순환 및 대류 활동의 민감한 초기 조건 의존성을 반영하는 결과로 볼 수 있다. 16-30일 리드타임으로 넘어가면 전지구 및 열대지역 모두 상층 변수에서 성능 향상이 확인된다. 이는 subseasonal 예측 규모에서도 초기장 개선 효과가 대기-해양 상호작용을 통해 계속해서 영향을 미칠 수 있음을 나타낸다. 한편 동아시아 영역의 경우, 짧은 규모에서 오히려 성능 저하를 보였던 반면 계절내규모에서는 대부분의 변수에서 비슷하거나 좋은 결과를 보이고 있다.

대기 초기조건의 오차 감소의 효과가 짧은 규모에서 계절내규모까지 뚜렷한 개선을 보이고 있으며, 이는 열대 지역을 중심으로 더 강하게 나타난다. 이러한 결과들을 바탕으로 계절내 예측에서 초기장, 특히 SST 및 대기 조건의 품질 관리가 특히 중요함을 알 수 있다. 현재 SCoPS는 같은 설정으로 계절예측장도 생산되고 있다. 계절내 규모에서 긍정적인 효과를 보인 만큼 계절 예측에서 초기 조건의 영향이 유지되는지를 더 살펴보고자 하였다. 특히, 계절규모에서 SCoPS는 대서양에서의 계통적 오차가 매우 크게 나타나는 것이 최근 알려졌다. 또한, 오토츠크 해 연안에서의 매우 큰 한랭오차가 매월 계절 예측 결과에서 나타나고 있다. 이는 CFSR 초기 조건에서 잘 알려진 계통적 오차이며 이는 CFS 모델에서 해빙 관련 초기화와 연관되어 해빙이 너무 두껍게 표현되어 생기는 것이다. 초기 조건의 오차는 예측장에서 더욱 심화되어 나타나고 SCoPS의 결과에서도 대서양 및 오토츠크 해 연안에서 매우 차가운 해수를 보이고 있다. 이러한 특성이 초기 조건에 의해 얼마나 달라질 수 있는지 살펴보기 위해 2017-2021년 5월 초기장을 사용하여 북반구 여름철 JJA의 예측장을 생산하고 초기 조건의 영향을 살펴보았다.

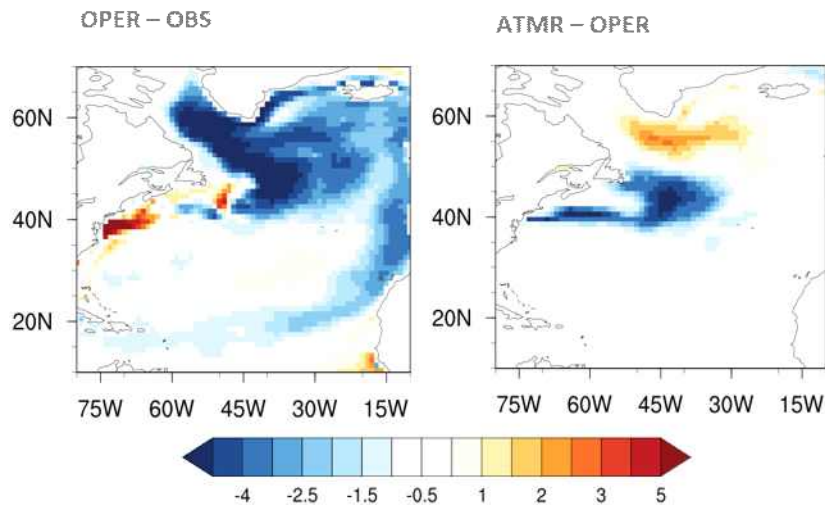


Figure 3.43. Sea surface temperature distribution over the North Atlantic region. (left) Difference between the OPER and observation. (right) Difference between the ATMR and OPER experiments.

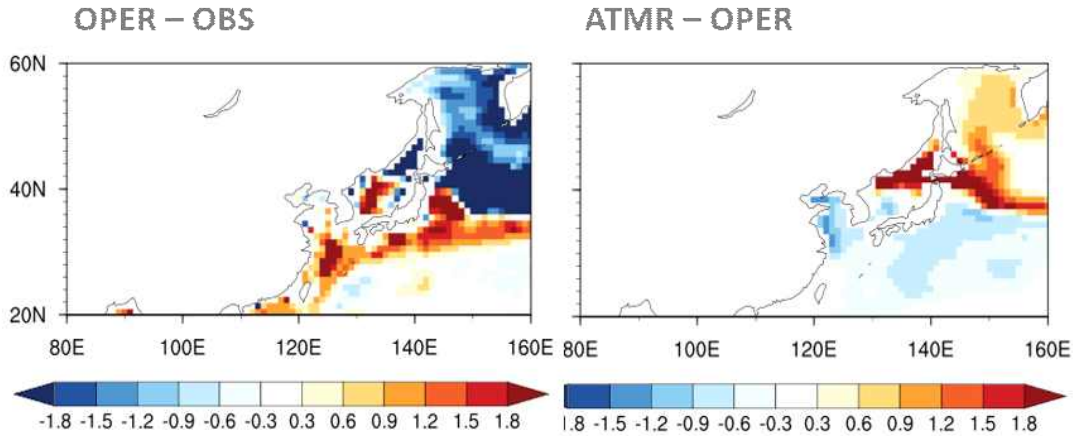


Figure 3.44. Sea surface temperature distribution over the East Asian coastal region. (left) Difference between the OPER and observation. (right) Difference between the ATMR and OPER experiments.

Figure 3.43은 북대서양 지역에서의 해수면 온도(SST) 예측 오차 및 개선 효과를 나타낸 그림이다. 그림에서도 확인할 수 있듯이 OPER는 걸프스트림 경계류 주변에서 뚜렷한 냉각 오차를 나타내고 있다. 반면, ATMR 결과에서는 이와 같은 냉각 오차가 일부 완화되는 경향이 확인되며, 특히 걸프스트림 확장부 인근에서 SST 재현성이 향상된 모습을 확인할 수 있다. 이는 CFS에서 나타나던 초기오차의 감소가 계절예측까지 영향을 효과적으로 주었음을 보여준다. 다만, 일부 지역에서는 SST 오차가 여전히 남아 있거나 오히려 증가하는 영역도 존재하여, 대기 초기화만으로 해결되지 않는 해양 내부 역학의 한계 또한 존재함을 확인할 수 있다.

Figure 3.44는 동아시아 주변 해역에서의 해수면 온도 예측 오차 및 초기화 개선 효과를 비교한 그림이다. OPER 실험은 쿠로시오 확장 영역과 일본 남쪽 해역에서 뚜렷한 양의 오차가 나타나며, 동해 및 일본 북쪽 오후츠크해 연안까지 매우 강한 음의 오차가 존재한다. 반면 ATMR 실험은 이러한 편차가 부분적으로 완화되며, 특히 쿠로시오 경로 주변에서 SST 예측이 크게 개선되는 모습을 보인다. 즉, CFS 초기 조건에서 보이던 계통적 오차가 OPER에도 뚜렷하게 유지되며, 초기 조건의 개선으로 이러한 계통적 오차를 줄일 수 있음을 보여준다. 특히 쿠로시오 관련 해역은 동아시아 지역의 예측 성능과 매우 밀접한 요소이기 때문에 이 지역의 오차 감소는 주목할 만하다고 할 수 있다.

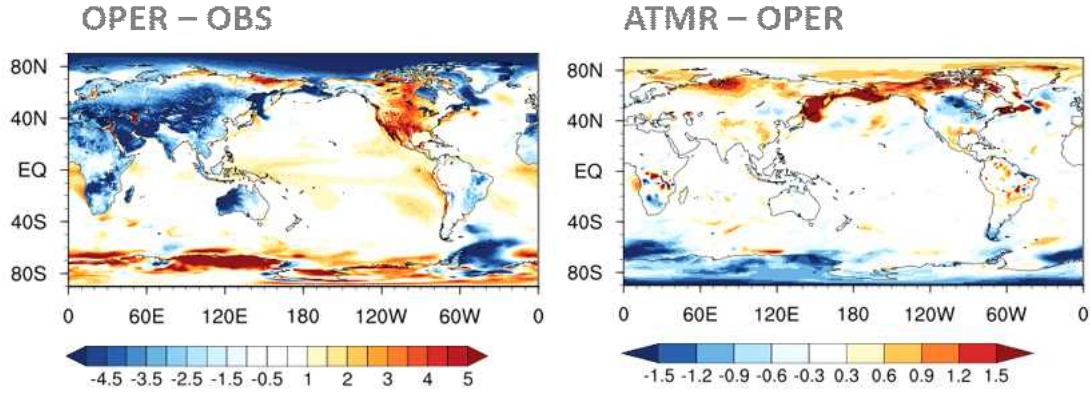


Figure 3.45. 2m temperature difference distribution (left) between the OPER and observation, and (right) between the ATMR and OPER experiments.

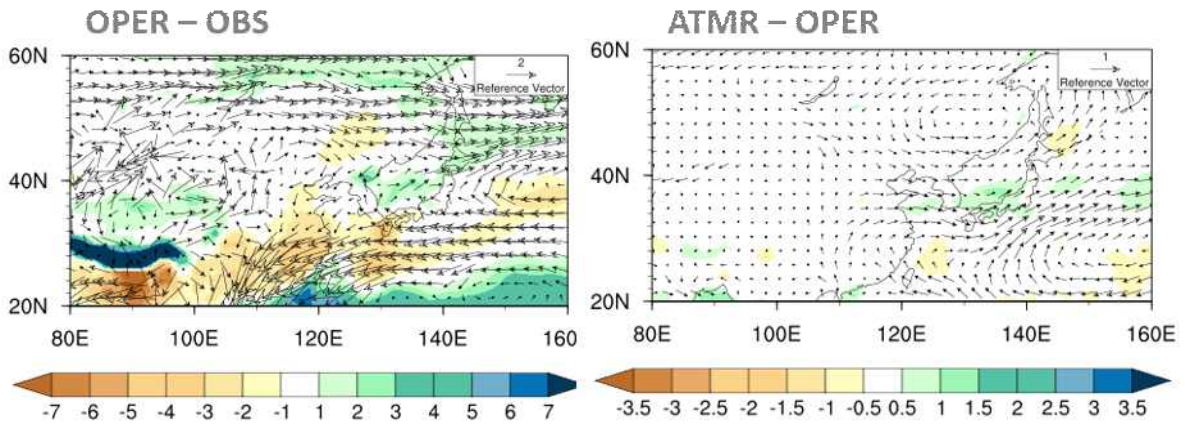


Figure 3.46. Surface precipitation difference distribution (left) between the OPER and observation, and (right) between the ATMR and OPER experiments.

Figure 3.45는 전지구 온도를 관측과 비교하고 실험간의 차이를 나타낸 그림이다. OPER 실험은 북서태평양과 북서대서양을 포함한 중위도 서안경계류 주변에서 강한 편차가 나타나고 있다. 특히 걸프스트림, 쿠로시오와 같은 서안경계류 및 확장부에서의 오차는 해류 위치와 경도 등의 오차로 연결될 것을 예상할 수 있다. 남반구에서는 남극해 주변 모양으로 음의 편차가 두드러지는데, 이는 강한 바람에 의한 혼합과 해빙 등 고위도의 과도한 냉각 표현으로 야기된 것으로 생각된다. 열대 지역에서는 중위도에 비해 상대적으로 작은 편차를 보이지만, 동태평양 및 인도양 일부에서 나타나는 국지적인 오차는 대기-해양 상호작용과 대류 활동 등의 오차로 연결될 수 있다. ATMR 실험은 OPER에서 나타나는 오차를 줄이는 지역이 뚜렷하게 확인된다. 표층 대기의 안정도, 바람 등이 개선되어 과도하게 냉각, 가열되던 해수의 에너지 교환이 보다 관측에 가까운 방향으로 진행되고 있고, 특히 해빙과 연관된 초기조건인 큰 변화는 고위도 지역에서의 온도를 뚜렷하게 개선하고 있다. 다만, 여전히 SCoPS 자체 물리과정으로 야기되는 계통적 오차는 일관되게 유지되고 있다.

Figure 3.46은 동아시아 여름 몬순 영역에서 강수 예측과 하층 순환의 변화를 나타낸 그림

이다. 우선 OPER 실험에서는 중국 남부-한반도-일본 남부로 이어지는 장마 강수대 부근에서 강수의 과소 모의가 뚜렷하며 반면 아열대 강수대에서는 과대모의가 나타난다. 이는 저층 남풍류와 서태평양 아열대 고기압의 가장자리를 따라 형성되는 몬순 수렴대의 위치와 강도가 정확히 모의되지 못함으로 나타난다고 할 수 있다. 또한 북서태평양 몬순 영역에서 남서류가 충분히 강화되지 못하거나 과도하게 발달함에 따라 강수 편차가 띠 모양으로 분포하고 있다. 15-30일 리드타임에서 효과적으로 반응하였던 대기 초기조건은 계절 규모에서는 효과가 약하게 나타나는 것을 알 수 있다. 하층 바람장은 관측과 더 가까운 형태로 바뀌면서 몬순 수렴대의 위치가 조금 더 안정적으로 바뀐다. 다만, 대부분의 강수 오차가 그대로 유지되어 몬순 강수의 세부 구조의 개선을 위해서는 초기 조건의 대체로는 한계가 있음을 시사한다.

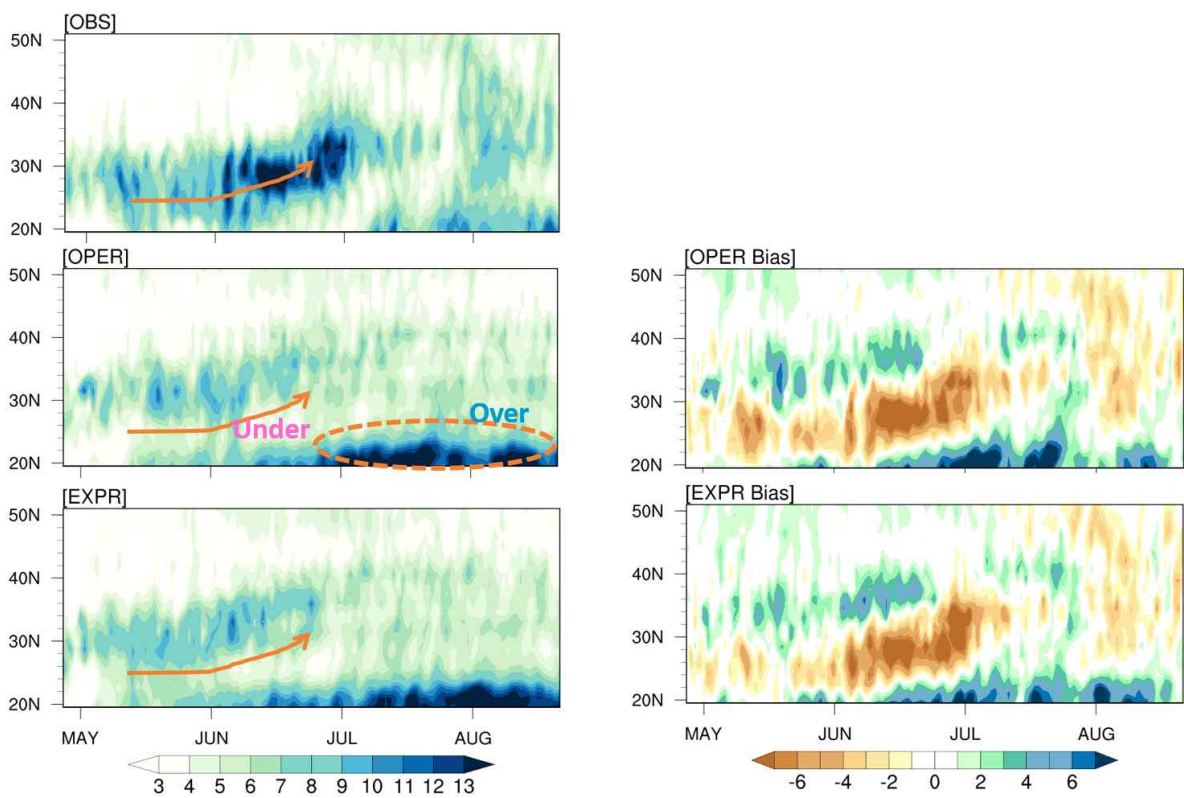


Figure 3.47. Comparison of the (left) seasonal evolution and (right) its biases of East Asian summer monsoon precipitation. Latitude-time sections of precipitation (mm/day) from observation, OPER, and ATMR(EXPR) experiments during May-August.

Figure 3.47은 동아시아 여름몬순 강수의 계절 진행 및 오차를 위도-시간 단면으로 나타낸 그림이다. 관측에서는 5월에 20N 부근에서 시작된 강수대가 시간이 지남에 따라 점진적으로 북상하여, 6월에는 25-30N, 7월에는 30N 부근까지 이동하는 전형적인 장마 전선의 계절 진행을 뚜렷하게 나타내고 있다. 특히 6-7월 사이에 25-35N 범위에서 강한 강수대가 형성되며, 이는 남서류에 의해 공급되는 수증기와 중위도 제트 및 상층 파동과의 상호작용으로 유지되는 대표적인 동아시아 몬순 및 장마 특성이다. 이에 비해 OPER 실험은 5-6월에 걸쳐 20N 근처에서 관측에 비해 강한 강수를 모의하며 이러한 강수는 지속되면서 저위도 강수대가 넓게 확산

되는 반면, 6-7월에 관측에서 뚜렷하게 나타나는 중위도의 집중 강수대는 상대적으로 약하게 모의한다. 즉 강수대의 공간·시간적 이동이 전반적으로 남쪽으로 치우쳐져 있으며 이는 몬순의 강도와 북상 속도, 서태평양 아열대 고기압의 위치를 제대로 모의하고 있지 못함을 알 수 있다. 반면, ATMR 실험은 대기 초기조건의 오차가 줄어들면서 예측장에서도 효과적인 변화를 가져온다. 특히 5월 이후 강수대는 OPER 대비 더 지속적으로 북상하여 저위도에서 중위도까지 이르는 강수의 오차가 다소 줄어들고 있으며, 6-7월에 저위도에서 나타나던 과도한 강수대도 일부 약화되는 것을 알 수 있다. 그러나, 앞서 말했듯이 대부분의 특징적인 오차 패턴은 OPER와 유사하게 유지되고 있기 때문에 몬순 강수의 세부 구조의 개선을 위해서는 초기 조건의 대체로는 한계가 있다.

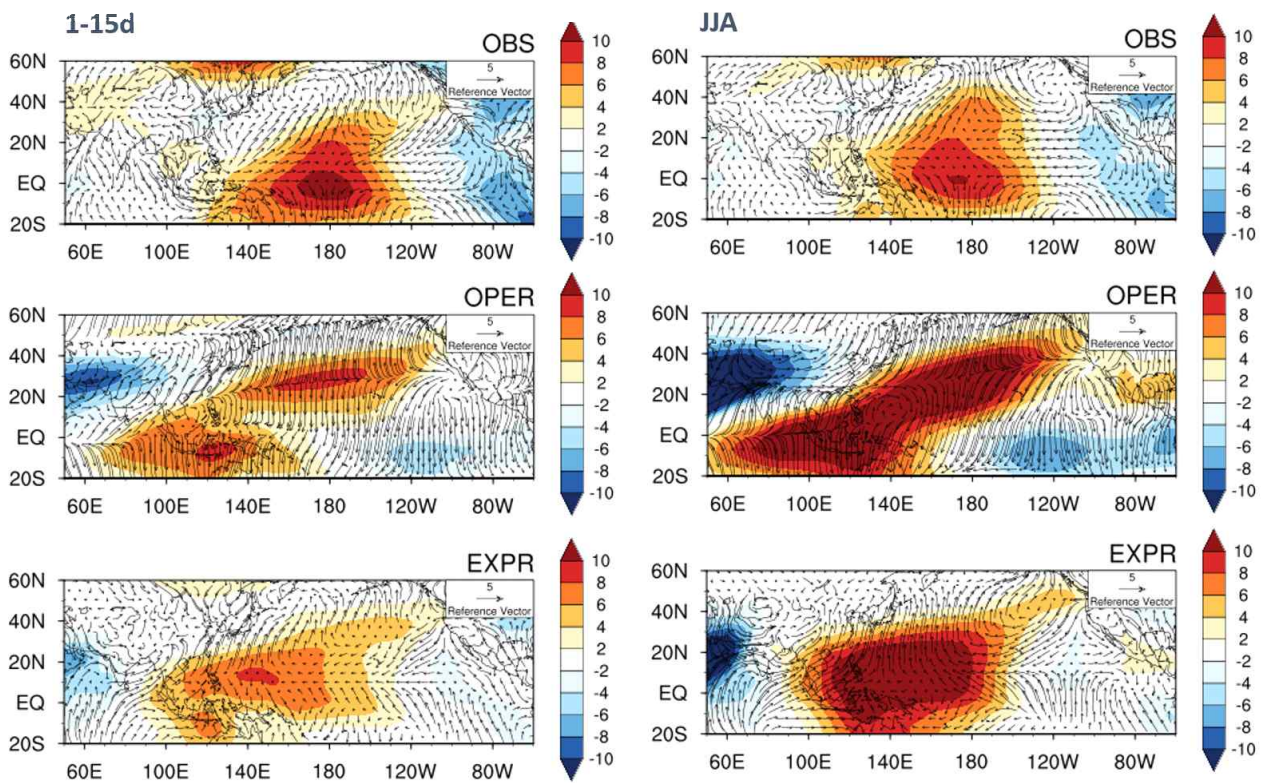


Figure 3.48. Comparison of Walker circulation and upper-level divergence fields for (left) 1-15 day mean and (right) JJA mean.

Figure 3.48은 상층 발산장으로 계산한 위커 순환 및 발산 바람장을 나타낸 그림이다. 관측을 살펴보면 서태평양에서 뚜렷한 저층 수렴과 상층 발산이 나타나며 이는 활발한 대류 활동에 의해 유지되는 전형적인 위커 순환 패턴이다. 이와 동시에, 동태평양에서는 상대적으로 강한 상층 수렴과 저층 발산이 나타나며 열대 태평양 전체에 걸쳐 뚜렷한 동서 방향의 대규모 기압·열 구조 대비가 유지된다. 그에 비해 OPER 실험에서는 위커 순환의 장주기 구조가 관측과 매우 다르게 모의되며, 이러한 구조는 정상적인 서태평양 대류 영역이 과도하게 동쪽으로 이동한 것과 연결되며, ENSO-like warm bias 특성과도 연관될 수 있다. 동시에 서태평양 상층 발산 및 저층 수렴이 약화되어 서태평양 몬순 수렴대와 관련된 대규모 상승이 충분히 재현

되지 못한다. 반면, ATMR(EXPR) 실험은 위커 순환의 동-서 구조가 관측과 보다 가까운 결과를 가져온다. 대류 중심이 서쪽으로 더 집중되어 나타나고 동태평양의 과도한 발산 패턴이 다소 완화된다. 이러한 순환 구조는 서태평양-동아시아 지역의 저층 수렴 및 상층 발산의 연결을 강화하여 강수를 개선시키는 것으로 판단된다. 또한 강수가 뚜렷하게 개선되었던 짧은 리드타임은 물론이고 계절 규모의 리드타임에도 효과적으로 영향을 보이고 있어 추후 동아시아 몬순과 연관된 원격 상관 패턴들을 자세히 조사해 볼 필요가 있겠다.




Figure 3.49. Vertical profiles of experiments - observation temperature differences over the (left) global and (right) East Asia region at JJA lead time. Black, blue, and red lines represent the OPER, OCNR, ATMR experiment, respectively.

Figure 3.49는 JJA 동안의 연직 기온 오차를 전지구 및 동아시아 평균으로 비교한 결과이다. 먼저 OPER 실험은 전구 평균에서 전체 대기층에 걸쳐 약한 한랭오차를 보이고 있으며 특히 지표 근처에서의 오차가 뚜렷하다. OCNR 실험은 위에서도 언급했듯이 거의 차이를 보이지 않고 있으며, ATMR 실험의 경우 오차를 개선하는 것이 뚜렷하게 나타나고 있다. 이는 여름철 대기 상층 발산과 중층 상승 운동이 밀접히 연관된 위커/해들리 순환 및 몬순 활동 개선과도 일관된 결과이며, 특히 동아시아 지역의 하층에서의 오차 개선은 주목할 만 하다. 이는 CFSR에서 특징적으로 나타났던 해빙 관련 오차가 해수면 온도 및 염도 뿐만 아니라 하층 연직 순환에도 영향을 미치고 있음을 설명한다.

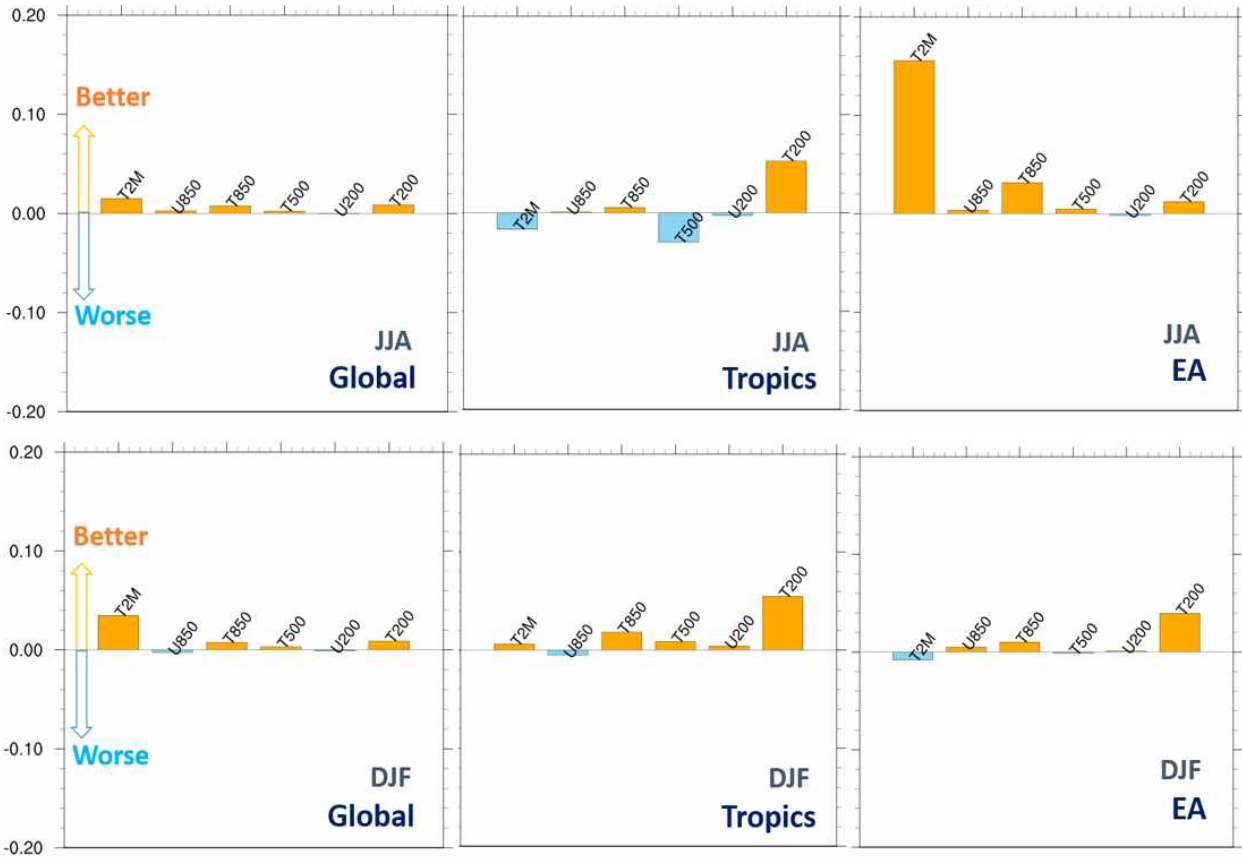


Figure 3.50. Improvement rates of forecast skill in the ATMR experiment relative to the OPER experiment for JJA, DJF lead time and Global, Tropics, and East Asia regions. Positive values indicate an enhancement in forecast performance, while negative values represent degradation.

Figure 3.50은 OPER 실험 대비 ATMR 실험에서의 예측 성능 향상률(Improvement rate)을 리드타임 구간별(JJA, DJF) 및 영역별(Global, Tropics, East Asia)로 비교한 결과를 나타낸 그림이다. T2M, U850, T850, T500, U200, T200 변수에 대해 계산된 RMSE 변화 비율이 양수일수록 예측 성능이 개선되었음을 의미하며, 음수는 성능 저하를 나타낸다. 우선 JJA(여름철)에는 동아시아에서의 개선 효과가 특히 두드러진다. 이는 앞서 말한 해빙 관련 계통적 오차의 제거로 인해 나타난 효과가 계절까지도 지속됨을 나타낸다. 또한, 지표기온, 상층 동서바람, 상층 온도 등에서도 개선 효과를 보이고 있으며, 이는 대기 상층에서의 발산 구조 개선이 장마 전선의 강수 재현성 향상과 연결되는 앞선 결과와 일관적으로 나타난다. 반면 열대 지역에서는 일부 성능 저하가 나타나는데, 이는 대류 활동의 지속적인 모의 실패로 인한 불안정성 및 해양 심층에서 올라오는 해양-대기 반응이 해수면 근처의 온도를 냉각시켜 오히려 오차가 커지는 결과를 가져오는 것으로 판단된다. 더 자세한 역학적 분석은 기후값 적분을 통해 이루어져야 할 것이다. 한편, 겨울철에는 전구 및 열대 영역에서 상층 온도 및 바람의 오차 개선이 보인다. 겨울철은 중위도 제트 및 열대-중위도 파동 상호작용이 강하게 작용하므로, 상층 역학 변수의 초기 개선이 계절 예측에도 영향을 줄 수 있을 것으로 판단된다. 역시 기후값 적분을 통한 원격상관

분석으로 더 자세한 영향을 살펴봐야 할 것이다.

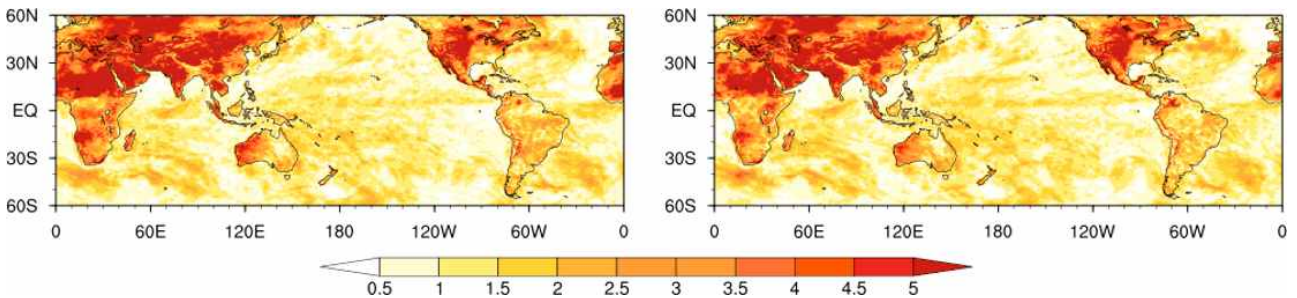


Figure 3.51. Distribution of root-mean-square error(RMSE) of 2m temperature at a 1 day lead time from (left) OPER and (right) ATMR experiments.

특히, Figure 3.51에서 나타낸 1일 리드타임의 RMSE를 살펴보면 이미 초기 시간에 SCoPS의 뚜렷한 온도 오차의 패턴을 확인할 수 있다. 다소 간단한 버킷 방법을 사용하는 지면 과정의 불확실성은 대부분의 지표기온의 오차를 매우 크게 나타내고 있으며, 이러한 특징은 초기 조건의 개선에도 거의 영향을 미치지 못하였다. 또한, SCoPS의 대기-해양 결합초기화 방식은 모델과 초기장의 초기 충격을 완화시키는데 매우 효과적일 수 있으나 불안정한 모델의 오차를 초기 조건에 반영시키는 단점이 있을 수 있다. 본 과제에서 진행된 초기 조건의 개선은 특히 대기 조건을 변경하였을 때 계절내에서 계절까지 여러 연직 순환 및 지표 기온, 강수 등 개선 가능성을 보였으나 조금 더 장기적인 기간을 포함하는 기후값의 생산 및 분석을 통해 실질적인 예측 성능 및 원격 상관의 모의 성능 등의 분석이 동반되어야 할 것이다. 다만, 이러한 개선 역시 본질적인 오차를 감소시키기에는 역부족이므로 추후 SCoPS 모델 내 물리 과정 및 성분 모델들의 보다 현실적인 처방이 필요할 것이다.

## 4. 요약 및 결론

### 4.1. 계절내예측 활용 체계 구축

APCC는 기상청의 1개월 및 3개월 전망을 효과적으로 지원하기 위해 ECMWF S2S 자료를 기반으로 한 다중모델앙상블(MME) 및 딥러닝 기온 확률예측 시스템을 안정적으로 운영해왔다. 특히 2025년에는 자료 수집 및 예측 시스템의 서버 이전과 프로세스 최적화를 통해 운영의 효율성과 유지보수의 편의성을 대폭 강화하였다. 2025년 8월 사례 분석을 통해 확인된 바와 같이, 본 시스템이 제공하는 주별 예측 정보는 단순 월평균 자료만으로는 파악하기 어려운 기상 패턴의 급격한 전환을 조기에 탐지하는 데 핵심적인 역할을 수행하였다. 아울러 동아시아 이상 기후 모니터링 시스템의 병렬화 개선을 통해 기후 감시 체계의 안정성 또한 확보하였다. 그러나 현재 생산하는 결과만으로는 차별화된 계절내예측 정보를 생산하기에 어려움이 있으며 APCC 홈페이지를 통해 제공되는 계절예측 정보를 보완하기에는 무리가 있다. 급변하는 기후 특성들을 고려하고 계절예측 정보의 한계를 극복하기 위해 APCC는 계절내예측 시스템을 구축하여 그 활용 가치를 높여보고자 하였다.

APCC 계절내예측 시스템 구축을 위해 전 세계 SubC/S2S 프로젝트 모델과 APCC 자체 모델의 계절내예측 정보를 체계적으로 수집하였다. 수집된 자료를 바탕으로 기후값과 예측력을 정량적으로 평가하였으며, 다중모델앙상블(Multi-Model Ensemble, MME) 적용 시의 효율성과 성능 향상을 확인하였다. 이는 APCC가 장기간 수행해온 계절예측 MME 운영 경험이 계절내예측 영역에서도 유효함을 보여주는 중요한 결과이다. 또한 모델 간 예측 성능 비교, MME 기여도 분석 등을 수행하여 APCC 계절내예측 체계 구축에 필요한 과학적 근거를 마련하였다. 또한, 제한된 앙상블 멤버 수로 인한 불확실성을 줄이고 예측 정보의 현업 활용성을 극대화하기 위해, 변수별 통계적 특성에 최적화된 확률예측 방법론을 선정하기 위한 연구를 수행하였다. 분석 결과, 기온과 강수량 모두에서 이론적 분포를 가정한 모수화 방법이 비모수적 방법 대비 RPSS 및 ROC 등 정량적 예측 성능에서 우위를 보이거나 동등한 수준을 유지함을 확인하였다. 특히, 모수화 방법은 앙상블 범위를 벗어나는 극한 기후 현상에 대한 외삽 능력이 뛰어나 이상 기후 감시 활용성이 높으며, 샘플링 오차로 인해 발생하는 공간적 노이즈를 획기적으로 감소시켜 예보관에게 물리적으로 타당하고 직관적인 예측장을 제공한다는 점에서 현업적 가치가 높게 평가되었다.

이를 바탕으로 제5차(2023년)와 제6차(2025년) 모델제공기관 회의 및 공식 요청을 통해 자료 제공 협의를 완료한 모델을 포함한 총 10개 기관의 모델자료를 수집하여 APCC 계절내예측 시스템을 구축하였다. 여기에는 APCC 자체 모델(SCoPS) 외에 BOM, ECCO, ECMWF, NCEP 등 주요 기관의 모델이 포함되며, 자료는 기관별 특성에 맞춰 FTP, API 등의 방식을 통해 자동으로 수집된다. 수집된 자료는 자동 다운로드 및 전처리가 수행되며, 전처리 과정에서는 모든 자료가 1도 해상도로 표준화되고, 주평균, 1~4주 평균 등 다양한 형태로 가공되며 모든 파일 형식은 최종적으로 NetCDF로 변환 저장된다. MME 수행 단계에서는 단정예측을 위해 SCM(Simple Composite Method)을, 확률예측을 위해 Gauss 및 Hybrid Gamma 기법을 적용하여 예측 결과를 생산한다. 최종 시스템은 자료 수집부터 전처리, MME 수행, 그래픽 표출까지 모든 과

정을 통합하며, 개별 모델의 예측 시작 요일 차이를 고려하여 월요일 ~ 일요일 기준의 4주간 예측 정보를 생산한다. 이 MME 예측 결과는 2025년 11월 24일부터 매주 월요일에 시험 생산되고 있다. 이를 통해 고품질의 계절내예측 정보 생산을 위한 기술적 기반을 확립하였고, 자동화된 전처리 및 생산 체계는 안정적인 시스템 운영에 기여할 수 있다. 향후 이 시스템은 아태지역의 기후 정보 서비스 역량을 강화하고, 예측 정보를 기반으로 한 재난 방지 및 기후 리스크 관리에 도움을 제공할 수 있을 것으로 기대되며, 지속적인 운영 및 성능 개선을 통해 APCC의 계절내예측 시스템은 아태지역 기후 정보 서비스의 핵심적인 역할을 수행할 것이다.

계절내예측(Subseasonal-to-Seasonal, S2S)은 2주에서 8주 사이의 예측 정보를 제공하는 영역으로, 재해 예방, 농업 관리, 수문·에너지 운영 등 다양한 분야에서 활용 가치가 빠르게 증가하고 있다. 그러나 예측기간의 특성상 초기장 민감도와 외부 강제력 신호가 모두 약해 예측 난이도가 높은 영역이기도 하다. 이러한 가운데, APCC는 기존 월·계절예측 중심의 서비스에서 확장하여 계절내-계절을 아우르는 seamless 예측 서비스 구축을 전략적으로 추진하고 있다. 타 기관과의 차별화를 확보하기 위해, 계절내(week-to-week)-계절(monthly) 정보를 연계한 seamless 콘텐츠를 탐색하고, 즉시 제공 가능한 콘텐츠와 중장기 개발이 필요한 콘텐츠를 선정하였다. 이러한 일련의 연구와 개발 활동은 APCC가 미래 기후서비스에서 요구되는 단기-중기-장기 예측의 연속성을 제공하는 핵심 기관으로 도약하기 위한 중요한 기반을 제공한다. 특히, 본 연구에서 선정한 seamless 콘텐츠들은 APCC의 차별적 경쟁력으로 이어질 것으로 기대되며, 향후 현업 서비스 전환 및 국제 협력 확대에도 크게 기여할 것이다.

## 4.2. SCoPS 운영 및 개선

APCC 계절내예측 시스템의 참여모델로 자료를 제공하기 위해 SCoPS 계절내예측의 실시간 운영을 시작하였다. 필요한 입력 자료인 CFS 분석장과 ARGO 해양관측 자료를 매주 목요일에 crontab을 이용해 지난 일주일 분량(수요일~화요일)을 자동으로 수집하고, 수집된 자료는 SCoPS 모델의 대기/해양 너징 및 EAKF 적용에 필요한 형태로 전처리된다. 계절내예측의 특성을 고려하여 기존의 5일 간격 시간지연 대신 하루의 시간 지연이 적용된 restart 파일을 사용하여 10개의 앙상블 멤버를 구성하였다. 매주 화요일 초기장을 기준으로 60일 예측을 수행하게 되며, 초기장 생산(약 3시간), 예측장 생산(약 10시간), 후처리(약 2시간) 과정을 거쳐 매주 금요일에 자료 생산이 완료된다. 생산된 SCoPS 예측 자료는 다음 주 월요일에 수행되는 MME 예측의 핵심 입력 자료로 활용되는 순환 체계를 구축하였다. SCoPS 모델의 실시간 운영체계 구축은 월 단위였던 예측 주기를 주 단위로 전환하여 고해상도의 선제적 기후 정보를 제공하는 기반을 마련하였다.

SCoPS의 개발 시점이 오래된 점과 다른 참여 모델과의 성능 비교에서의 한계 등을 고려하였을 때 계통적 오차를 줄이는 방안이 필요하다고 판단하였다. 따라서, 본 연구에서는 SCoPS 초기장의 오차를 감소시키고 계절내예측의 오차를 줄여보고자 하였다. 먼저, ERA5-Land 기반 토양 수분 초기화를 도입하고, EAKF 필터를 활용하여 2003-2016년 여름철 hindcast 실험을 수행함으로써 토양 수분 초기화가 Subseasonal-to-seasonal (S2S) 규모 기온 예측에 미치는 영향을 체계적으로 평가하였다. 지면 초기화를 통한 예측 성능 개선을 정량화하고, 초기 조건 개선 → 토양 수분 메모리 → 육지-대기 결합 강도 → 최종 예측 성능으로 이어지는 물리적 메커니즘을 규명하였다.

EAKF 기반 토양 수분 초기화는 5일 이내에 모델 상태를 ERA5-Land 관측에 효과적으로 수렴시켰다. 전지구 평균 RMSE는 초기 0.292 m에서 최종 0.002 m로 감소하여 99.3%의 개선을 확인하였다. 지역별로는 중부 미국(CUS) 지역에서 99.5%, 동남유럽(SEE) 지역에서 99.4%의 RMSE 감소를 보였다. 반면 CTRL 실험은 초기화 기간 동안 거의 변화하지 않아(-0.2%), EAKF 기반 초기화의 효과성이 명확히 입증되었다. 토양 수분 메모리는 e-folding time으로 정량화하였으며, 전지구 평균  $39.1 \pm 15.5$ 일로 나타나 S2S 예측 기간(2주-2개월)과 일치하는 시간 규모를 보였다. 중요한 발견은 LAND와 CTRL 실험 간 메모리 차이가 매우 작다는 점이다(전지구: -0.2일, CUS: +0.9일, SEE: -0.6일). 이는 토양 수분 초기화가 메모리 시간 규모 자체를 변화시키지 않고, 정확한 초기 상태를 제공을 통해 기존 메모리를 최대한 활용하는 방식으로 작동함을 의미한다.

지면-대기 결합 강도의 경우, 16-30일 리드타임에서 전지구 평균 지면 결합 지수( $I_{SM,LH}$ )는 LAND 실험에서 CTRL 대비 21% 감소하였다. 이는 열대 지역에서 초기화로 인한 토양 수분 재분포가 증발산 제한을 완화했기 때문이다. 그러나 CUS 지역에서는 정반대의 결과가 나타났다. 지면 결합 지수는 46% 증가, 대기 결합 지수( $I_{SM,T2m}$ )는 87% 증가하여 토양 수분 초기화가 중위도 전이대에서 지면-대기 결합을 크게 강화함을 보여주었다. 기온 예측 성능은 토양 수분 초기화로 유의미하게 향상되었다. 16-30일 리드타임에서 전지구 평균  $R^2$ 는 CTRL 0.126에서 LAND 0.158로 증가하여  $\Delta R^2 = +0.013$  (10% 개선,  $p < 0.05$ )를 달성하였다. 지역별로는

결합 강도가 높은 지역에서 더 큰 개선을 보였다. 리드타임에 따른 개선 효과는 31-45일에서 전지구 13% 개선, 46-60일에서 1% 개선으로 점차 감소하였다. 그러나 CUS 지역은 46-60일에서도 12% 개선을 유지하여, 토양 수분 메모리가 긴 지역에서 장기 예측 성능 향상이 가능함을 입증하였다. 강수 예측 성능은 모든 리드타임에서 초기화의 영향을 거의 받지 않았다. 이는 S2S 시간 규모에서 강수가 주로 대기 순환과 대규모 해양-대기 상호작용에 의해 결정되며, 지면 조건의 영향은 제한적임을 의미한다.

본 연구는 토양 수분 초기화가 예측 성능에 기여하는 물리적 메커니즘을 다음과 같은 인과 체인으로 정립하였다:

- (1) 초기화 단계: 10-12일 내에 모델 토양 수분을 관측에 수렴시킴 (RMSE 99% 감소)
- (2) 메모리 단계: 초기화된 정보가 약 30-40일간 보존됨 (e-folding time 기준)
- (3) 결합 단계: 주요 hotspot 지역에서 지면-대기 결합 강도 증가 (최대 87-101%)
- (4) 예측성 단계: 결합이 강화된 지역에서 기온 예측 정확도 향상 (최대 15-60%)

이러한 체계적 연결은 토양 수분 초기화가 물리적으로 일관된 메커니즘을 통해 S2S 예측 성능을 개선함을 보여준다. 특히 중위도 전이대(CUS, SEE)에서 효과가 크며, 이는 (1) 초기 조건 개선, (2) 충분한 메모리, (3) 강한 지면-대기 결합의 세 조건이 동시에 충족될 때 최대 효과가 발현됨을 시사한다.

본 연구는 여러 중요한 성과에도 불구하고 몇 가지 한계점을 갖는다. 여름철(JJA)에만 집중하여, 다른 계절에 대한 일반화가 제한적이다. 겨울철에는 눈 덮임과 토양 동결이 토양 수분-대기 결합을 약화시킬 수 있으며, 봄철에는 눈 녹음수가 토양 수분 변동성에 중요하게 작용할 수 있다. 또한, 본 연구는 토양 수분만을 초기화하였으나, 눈 덮임, 식생 상태 등 다른 지면 변수의 동시 초기화가 추가적인 개선을 가져올 수 있다. 따라서, 향후 연구 개발 방향으로서는 전 계절 분석을 위해 우선적으로 겨울철에 대한 초기화 효과 평가 및 계절별 메커니즘 규명을 위해 실험을 추가할 계획이며, 다변수 초기화를 위해 토양 수분 이외에도 snow depth나 snow melting flux와 같은 변수의 통합 초기화의 방향으로 기술 체계를 개선하고자 한다.

또한, 본 연구에서는 SCoPS 계절내예측 시스템을 대상으로 해양 및 대기 초기 조건을 개선하고, 그 영향이 단기(1-15일), 계절내(16-30일), 나아가 계절(1-3개월) 규모 예측 성능에 어떻게 나타나는지를 평가하였다. 특히 해양 연직 초기장 개선 실험 (OCNR)과 대기 초기장 개선 실험 (ATMR)을 기존 실험(OPER)와 비교함으로써 초기장 종류별 기여를 살펴보고자 하였다. 해양 연직 초기화의 효과를 살펴보면, GODAS 기반 연직 구조와의 비교에서 기존 실험은 동태평양 수온약층이 전 연도에 걸쳐 과도하게 깊고 따뜻하게 모의되는 계통적 온난 오차를 보이는 반면, OCNR 실험은 온난 오차를 100-200m 수심대를 중심으로 감소시키고 있다. 이는 리드타임 증가에 따라 해양-대기 상호작용으로 연결되어 대기로 전파될 수 있다. 그러나, 두 실험의 차이가 리드타임 전 구간에 걸쳐 전반적으로 작고, 뚜렷한 시간적 변화 패턴도 확인되지 않는다. 이는 동아시아 지역의 대기 변동성이 해양 초기 조건보다 대기

변동성에 더 크게 좌우되며, 초기 해양 상태 영향이 동태평양에 비해 대기 변수에 미치는 영향이 상대적으로 제한적임을 의미한다. 또한 동아시아 지역은 원격 상관에 대한 영향이 더 크게 나타나기 때문에 해양 초기화 개선 효과가 영향을 주지 못하는 것으로 판단할 수 있다. 반면, 대기 초기자료의 변경으로 인한 영향은 더 빠르고 직접적으로 나타난다. ERA5 기반 대기 초기 조건을 적용한 ATMR 실험에서는 전지구 및 열대, 동아시아 평균 기온 성능이 OPER 대비 전 리드타임 구간에서 일관되게 감소하였고, 상하층 대규모 순환의 초기 상태를 안정화시킬 수 있음을 확인하였다. 특히, 온도 및 바람 개선을 통해 동아시아 여름 몬순과 관련된 하층 습도 및 강수 예측이 유의미하게 개선되며, 이는 워커 및 해들리 순환의 개선과도 연관되었다. 계절내 리드타임뿐만 아니라 계절 규모에서도 고위도 및 서안경계류 주변의 SST 오차를 감소시키는 등 개선 영향을 유지할 수 있음을 확인하였다.

그럼에도 불구하고 일부 한계가 존재한다. 동아시아 지역은 여전히 초기 조건의 영향이 제한적이며, 강수 예측의 계통적 오차는 여전히 유효하다. 또한, 대기-해양 결합초기화에서 비롯되는 모델 자체의 오차가 초기 조건에 반영되면서 뚜렷하고 큰 계통적 오차가 초기 1일부터 일관적으로 유지된다. 즉, 초기 조건의 개선을 통해 계절내-계절에 이르기까지 예측 성능 향상을 기대할 수 있게 되었으나, 기후값 생산 등을 통한 일관된 성능 평가 및 원격 상관 등의 분석으로 더 명확한 가이드라인을 제공할 필요가 있다. 하지만, SCoPS 모델 내 물리 과정 및 성분 모델들의 더 현실적인 처방을 통해 근본적인 오차를 해결해야 할 것이다.

## 사사

이 연구는 APEC기후센터의 지원을 통해 수행되었습니다.

## References

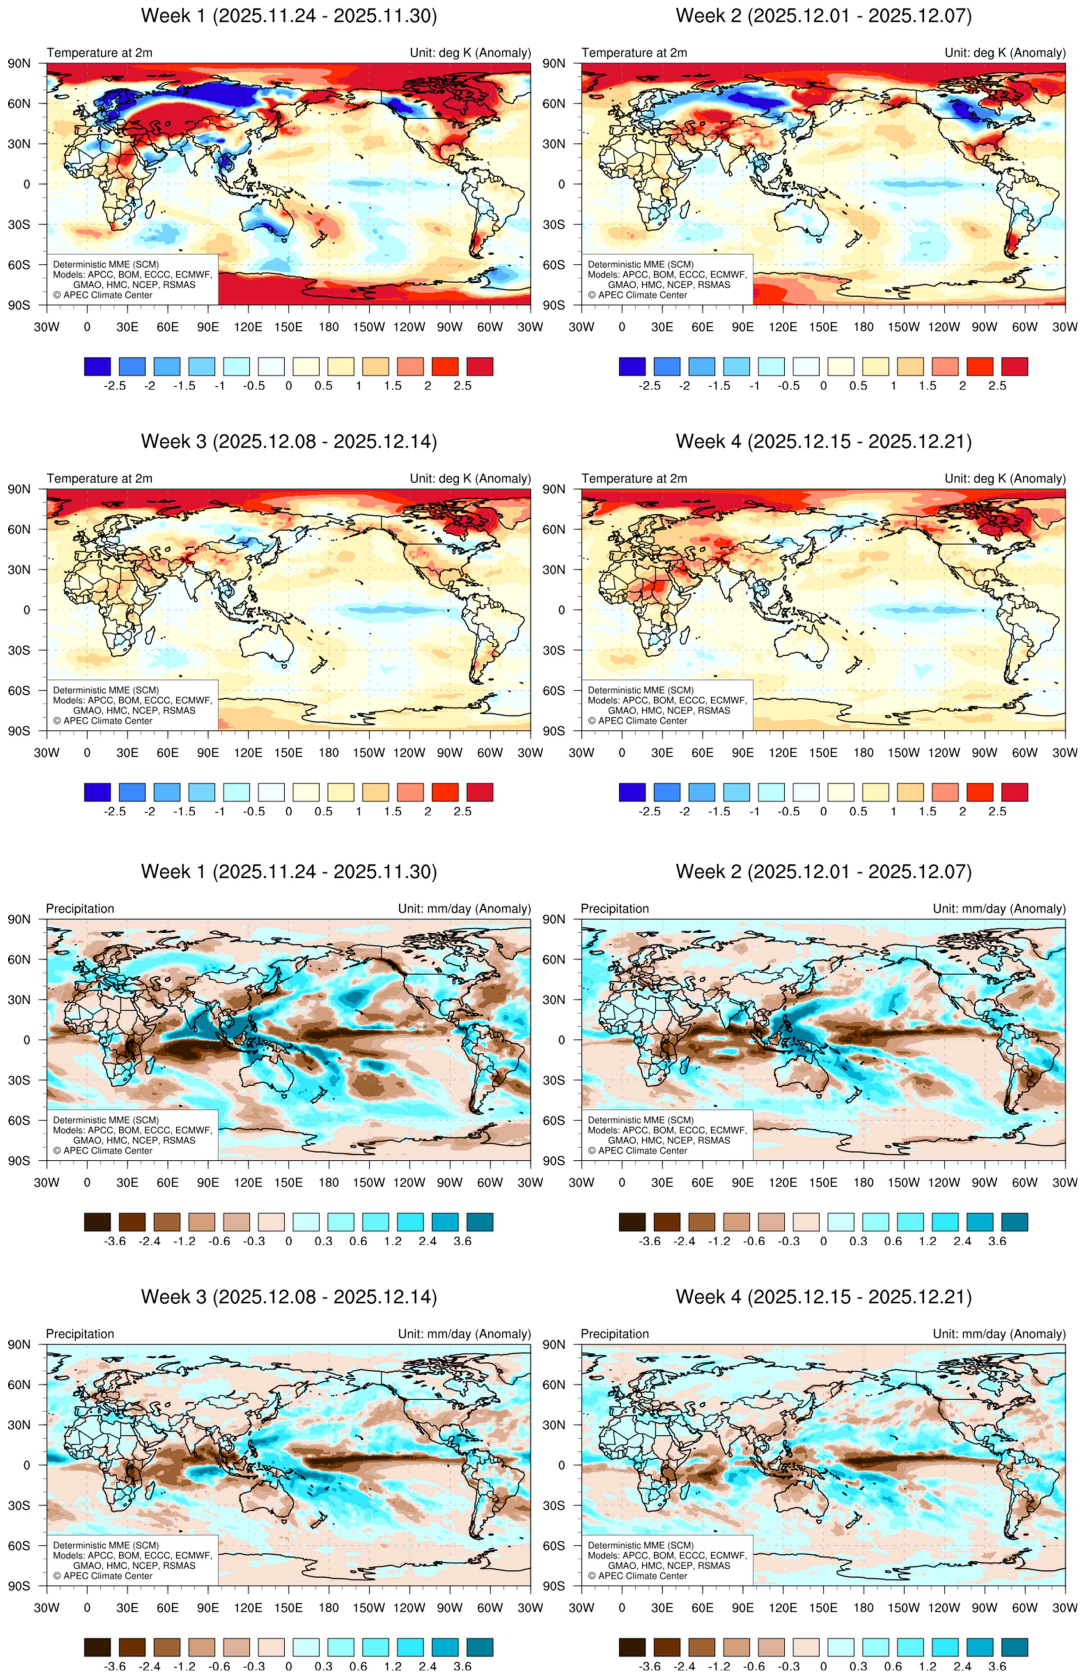
- 서은교, 이명인, 정지훈, 강현석, 원덕진, 2016: 전지구 계절 예측 시스템의 토양수분 초기화 방법 개선. *Atmosphere*, **26(1)**, 35-45.
- 정영윤, 문일주, 장필훈, 2016: 기상청 계절예측시스템(GloSea5)의 해양성층 강화시기 단기 해양예측 정확도 및 대기-해양 접합효과. *Atmosphere*, **26(4)**, 599-615.
- Anderson, J. L., 2001: An ensemble adjustment Kalman filter for data assimilation. *Monthly weather review*, **129(12)**, 2884-2903.
- Ardilouze, C., Batté, L., Déqué, M., van Meijgaard, E., and van den Hurk, B., 2019: Investigating the impact of soil moisture on European summer climate in ensemble numerical experiments. *Climate Dynamics*, **52(7)**, 4011-4026.
- Day, J. J., Vitart, F., Stockdale, T., de Rosnay, P., Ardilouze, C., Peano, D., ... and Andrews, M., 2025: Soil-moisture-atmosphere coupling hotspots and their representation in seasonal forecasts of boreal summer. *Climate Dynamics*, **63(6)**, 275.
- Dirmeyer, P. A., 2011: The terrestrial segment of soil moisture-climate coupling. *Geophysical Research Letters*, **38(16)**.
- Dirmeyer, P. A., Jin, Y., Singh, B., and Yan, X., 2013: Evolving land-atmosphere interactions over North America from CMIP5 simulations. *Journal of Climate*, **26(19)**, 7313-7327.
- Dirmeyer, P. A., and Halder, S., 2016: Sensitivity of numerical weather forecasts to initial soil moisture variations in CFSv2. *Weather and Forecasting*, **31(6)**, 1973-1983.
- Draper, C. S., Reichle, R. H., De Lannoy, G. J. M., and Liu, Q., 2012: Assimilation of passive and active microwave soil moisture retrievals. *Geophysical Research Letters*, **39(4)**.
- Duan, Y., Kumar, S., Maruf, M., Kavoo, T. M., Rangwala, I., Richter, J. H., ... and Raeder, K., 2025: Enhancing sub-seasonal soil moisture forecasts through land initialization. *npj Climate and Atmospheric Science*, **8(1)**, 100.
- Epstein, E. S., 1969: A scoring system for probability forecasts of ranked categories. *J. Appl. Meteor.*, **8**, 985-987.
- Ferro, C. A. T., 2007: Comparing probabilistic forecasting systems with the Brier score. *Wea. Forecasting*, **22**, 1076-1088.
- Hagemann, S., Arpe, K., and Roeckner, E., 2006: Evaluation of the hydrological cycle in the ECHAM5 model. *Journal of climate*, **19(16)**, 3810-3827.
- Ham, S., A-Y. Lim, S. Kang, H. Jeong, Y. Jeong, B. Wang, B. Xiang, S. Wu, and J. X. Fu,

- 2019: Correction to: A newly developed APCC SCoPS and its prediction of East Asia seasonal climate variability. *Clim. Dyn.*, **53**, 3703–3704.
- Ham, S., Y. Jeong, J. H. Yoo, S. Lim, H. Ji, and Y.-K. Hyun, 2024: What is the effect of atmospheric initial condition inconsistency between the hindcasts and real-time forecasts? *Clim. Dyn.*, **62(3)**, 1613–1623
- Hamill, T. M., and J. S. Whitaker, 2006: Probabilistic quantitative precipitation forecasts based on reforecast analogs: Theory and application. *Mon. Wea. Rev.*, **134**, 3209–3229.
- Hersbach, H., and Coauthors, 2020: The ERA5 global reanalysis. *Quart. J. Roy. Meteor. Soc.*, **146**, 1999–2049.
- Hunke, E. C., Lipscomb, W. H., Turner, A. K., Jeffery, N., and Elliott, S., 2010: CICE: the Los Alamos sea ice model documentation and software user's manual version 4.1. Los Alamos National Laboratory, Los Alamos, NM, 1–115.
- Hurk, V. D., B., Doblas-Reyes, F., Balsamo, G., Koster, R. D., Seneviratne, S. I., and Camargo Jr, H., 2012: Soil moisture effects on seasonal temperature and precipitation forecast scores in Europe. *Climate dynamics*, **38(1)**, 349–362.
- Kharin, V. V., and F. W. Zwiers, 2003b: On the ROC score of probability forecasts. *J. Climate*, **16**, 4145–4150.
- Koster, R. D., Mahanama, S. P. P., Yamada, T. J., Balsamo, G., Berg, A. A., Boisserie, M., ... and Wood, E. F., 2010: Contribution of land surface initialization to subseasonal forecast skill: First results from a multi-model experiment. *Geophysical Research Letters*, **37(2)**.
- Koster, R. D., and Coauthors, 2011: The second phase of the global land-atmosphere coupling experiment: soil moisture contributions to subseasonal forecast skill. *Journal of Hydrometeorology*, **12(5)**, 805–822.
- Lin, H., G. Brunet, and J. S. Fontecilla, 2010: Impact of the Madden-Julian Oscillation on the intraseasonal forecast skill of the North Atlantic Oscillation, *Geophysical Research Letters*, **37**, L19803, doi:10.1029GL044315.
- Mariotti, A., Ruti, P. M., and Rixen, M., 2018: Progress in subseasonal to seasonal prediction through a joint weather and climate community effort. *npj Climate and Atmospheric Science*, **1(1)**, 4.
- Mason, I., 1982: A model for assessment of weather forecasts. *Aust. Meteor. Mag.*, **30**, 291–303.
- Massey Jr., F. J., 1951: The Kolmogorov-Smirnov test for goodness of fit. *J. Amer. Stat. Assoc.*, **46**, 68–78.

- Meehl, G. A., and Coauthors, 2021: Initialized Earth System prediction from subseasonal to decadal timescales. *Nat. Rev. Earth Environ.*, **2**, 340–537.
- Min, Y. M., C.-M. Lim, J.-H. Yoo, and Coauthors, 2025: A diachronic assessment of advances in seasonal forecasting: Evolution of the APCC Multi-Model Ensemble prediction system over the last two decades. *Geophys. Res. Lett.*, **52**, e2025GL116416.
- Murphy, A. H., 1971: A note on the ranked probability score. *J. Appl. Meteor.*, **10**, 155–156.
- Robertson, A. W., A. Kumar, M. Peña, and F. Vitart, 2015: Improving and promoting subseasonal to seasonal predictions. *Bull. Amer. Meteor. Soc.*, **96**, ES49–ES53.
- Rodríguez-Fernández, N., De Rosnay, P., Albergel, C., Richaume, P., Aires, F., Prigent, C., and Kerr, Y., 2019: SMOS neural network soil moisture data assimilation in a land surface model and atmospheric impact. *Remote Sensing*, **11(11)**, 1334.
- Roeckner, E., Bäuml, G., Bonaventura, L., Brokopf, R., Esch, M., Giorgetta, M., ... and Tompkins, A., 2003: The atmospheric general circulation model ECHAM 5. PART I: Model description.
- Rosnay, D., P., Drusch, M., Vasiljevic, D., Balsamo, G., Albergel, C., and Isaksen, L., 2013: A simplified extended Kalman filter for the global operational soil moisture analysis at ECMWF. *Quarterly Journal of the Royal Meteorological Society*, **139(674)**, 1199–1213.
- Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., ... and Teuling, A. J., 2010: Investigating soil moisture–climate interactions in a changing climate: *A review*. *Earth-Science Reviews*, **99(3–4)**, 125–161.
- Smith, R. D., Dukowicz, J. K., and Malone, R. C., 1992: Parallel ocean general circulation modeling. *Physica D: Nonlinear Phenomena*, **60(1–4)**, 38–61.
- Vigaud, N., A. W. Robertson, and M. K. Tippett, 2017: Multimodel ensembling of subseasonal precipitation forecasts over North America. *Mon. Wea. Rev.*, **145**, 3913–3928.
- Vitart, F., and Coauthors, 2017: The Subseasonal to Seasonal (S2S) Prediction Project Database. *Bull. Amer. Meteor. Soc.*, **98**, 163–173.
- Vitart, F., and Coauthors, 2025: The WWRP/WCRP S2S project and its achievements. *Bull. Amer. Meteor. Soc.*, **106** (5), E791–E808.
- White, C. J., Carlsen, H., Robertson, A. W., Klein, R. J., Lazo, J. K., Kumar, A., ... and Zebiak, S. E., 2017: Potential applications of subseasonal-to-seasonal (S2S) predictions. *Meteorological Applications*. **24(3)**, 315–325.

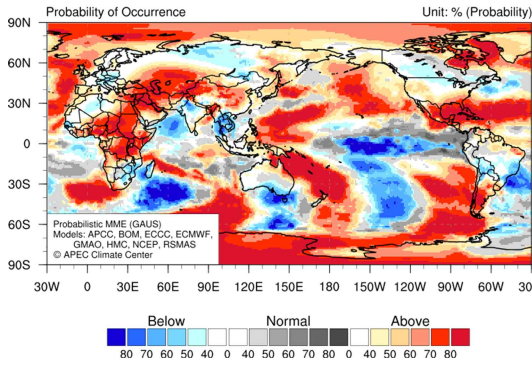
# 부록 A. MME 계절내예측 시험운영 결과(2025.11.24. 이후)

단정예측, 예측기간 : 2025.11.24. ~ 2025.12.21.

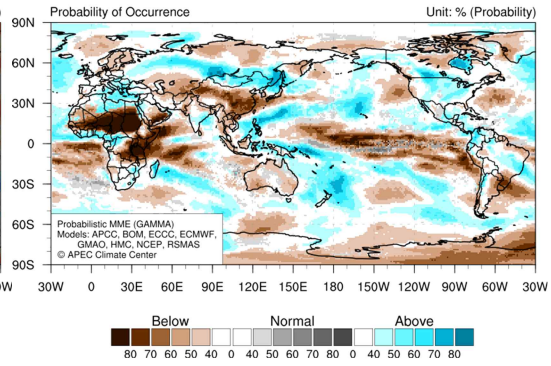


단정예측, 예측기간 : 2025.11.24. ~ 2025.12.21.

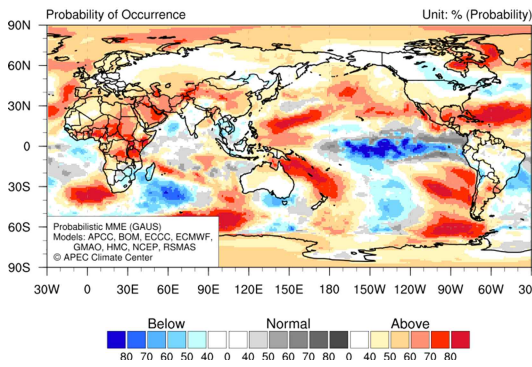
Week 1-4 (2025.11.24 - 2025.12.21)




Week 1-4 (2025.11.24 - 2025.12.21)



Week 3-4 (2025.12.08 - 2025.12.21)

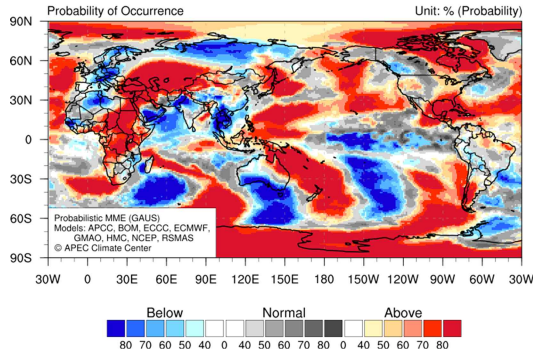


Week 3-4 (2025.12.08 - 2025.12.21)

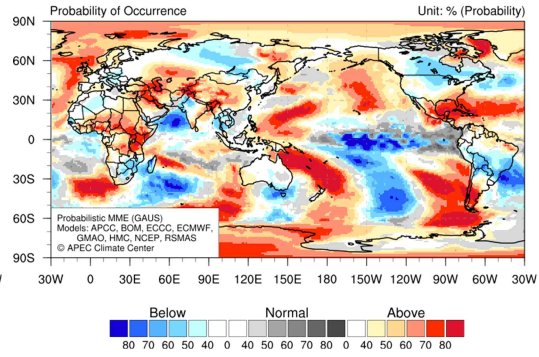


확률예측, 예측기간 : 2025.11.24. ~ 2025.12.21.

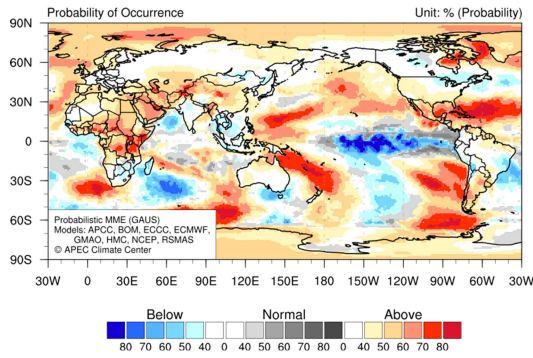
Week 1 (2025.11.24 - 2025.11.30)



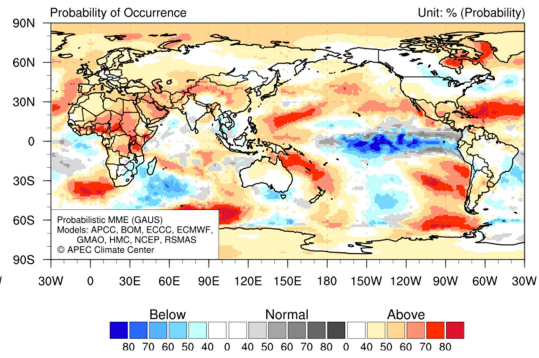
Week 2 (2025.12.01 - 2025.12.07)



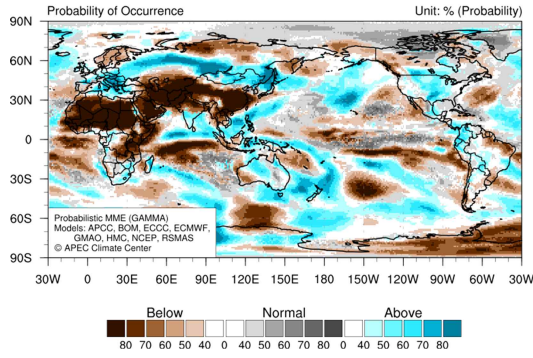
Week 3 (2025.12.08 - 2025.12.14)



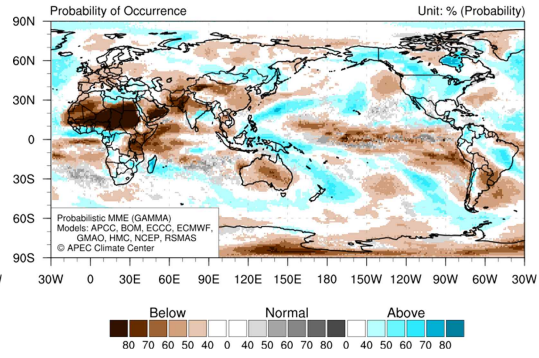
Week 4 (2025.12.15 - 2025.12.21)



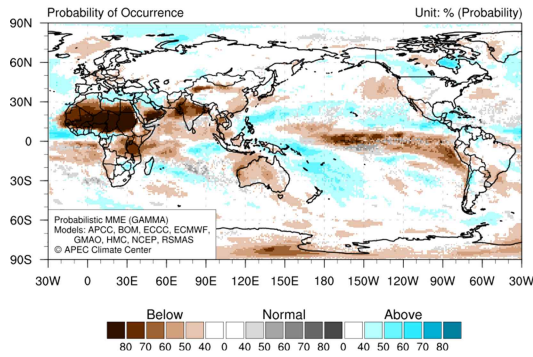
Week 1 (2025.11.24 - 2025.11.30)



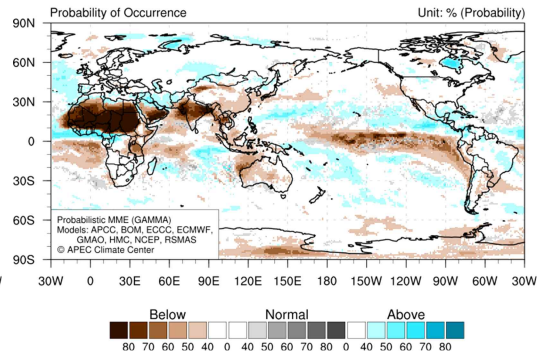
Week 2 (2025.12.01 - 2025.12.07)



Week 3 (2025.12.08 - 2025.12.14)

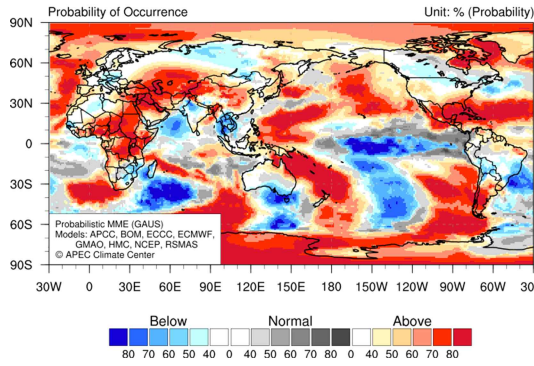


Week 4 (2025.12.15 - 2025.12.21)




확률예측, 예측기간 : 2025.11.24. ~ 2025.12.21.

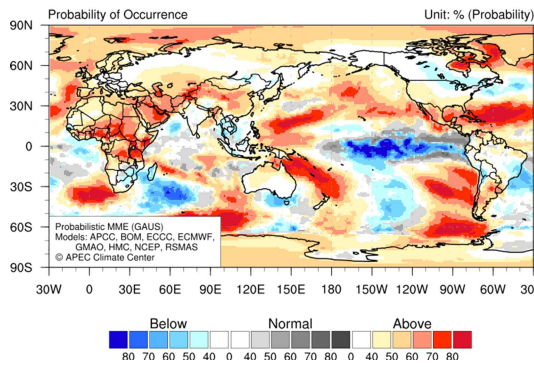
Week 1-4 (2025.11.24 - 2025.12.21)



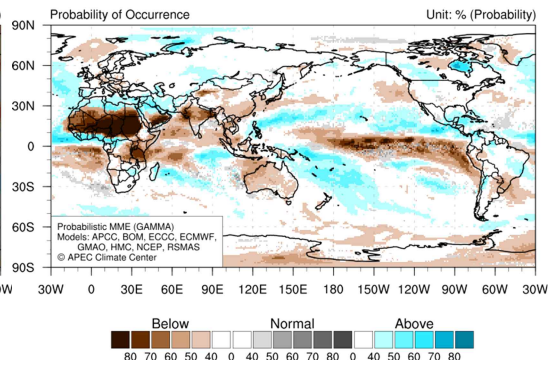
Week 1-4 (2025.11.24 - 2025.12.21)



Week 3-4 (2025.12.08 - 2025.12.21)

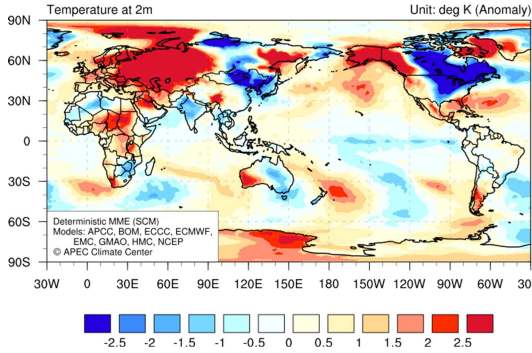


Week 3-4 (2025.12.08 - 2025.12.21)

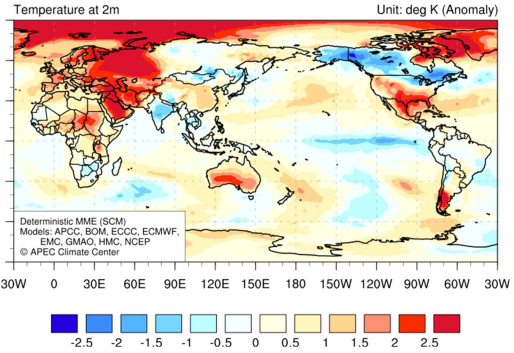


단정예측, 예측기간 : 2025.12.01. ~ 2025.12.28.

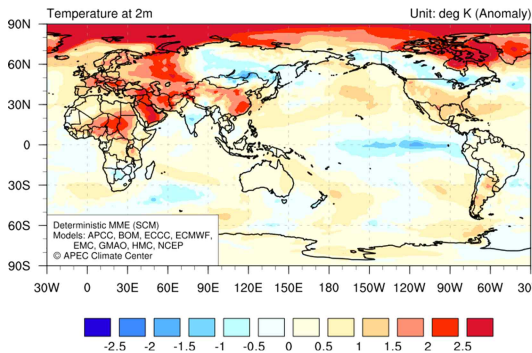
Week 1 (2025.12.01 - 2025.12.07)



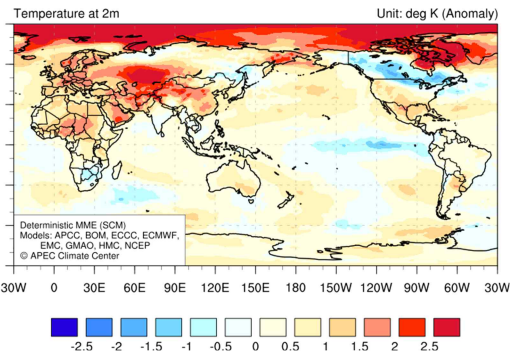
Week 2 (2025.12.08 - 2025.12.14)



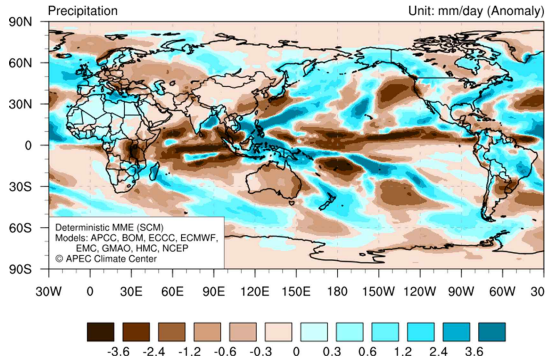
Week 3 (2025.12.15 - 2025.12.21)



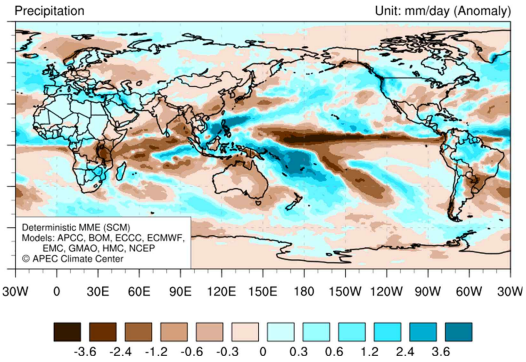
Week 4 (2025.12.22 - 2025.12.28)



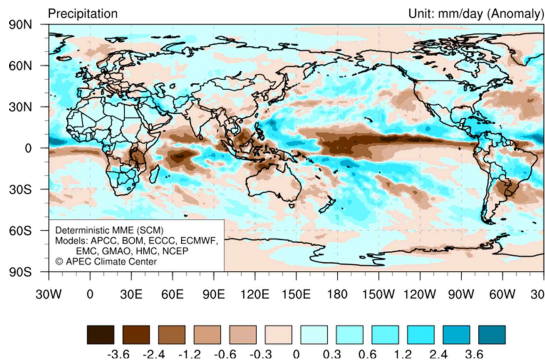
Week 1 (2025.12.01 - 2025.12.07)



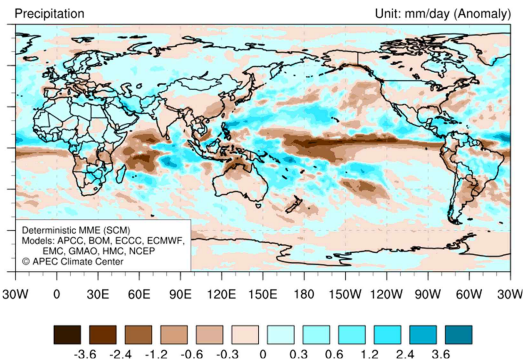
Week 2 (2025.12.08 - 2025.12.14)



Week 3 (2025.12.15 - 2025.12.21)

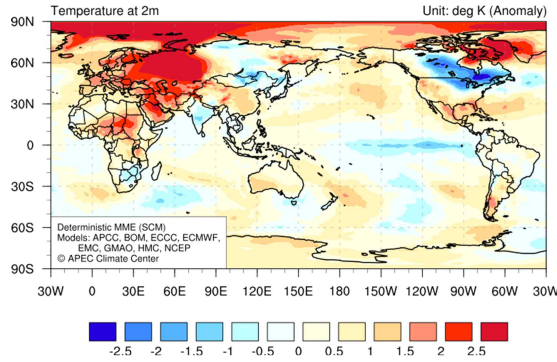


Week 4 (2025.12.22 - 2025.12.28)

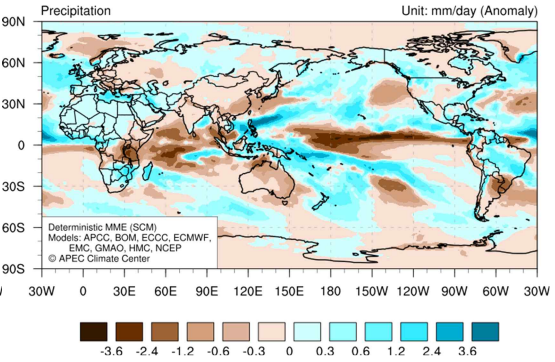


단정예측, 예측기간 : 2025.12.01. ~ 2025.12.28.

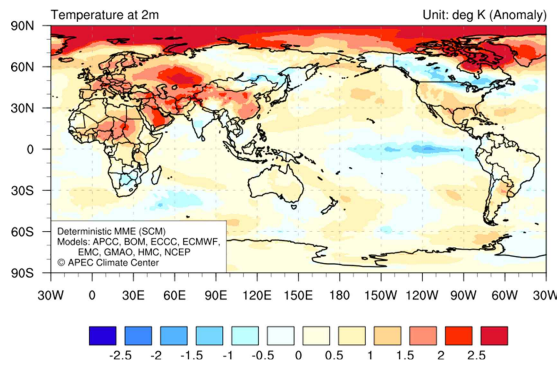
Week 1-4 (2025.12.01 - 2025.12.28)



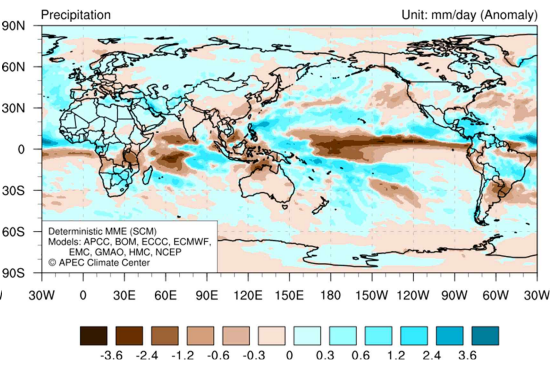
Week 1-4 (2025.12.01 - 2025.12.28)



Week 3-4 (2025.12.15 - 2025.12.28)

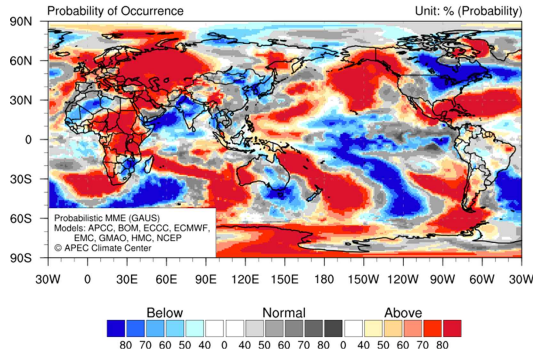


Week 3-4 (2025.12.15 - 2025.12.28)

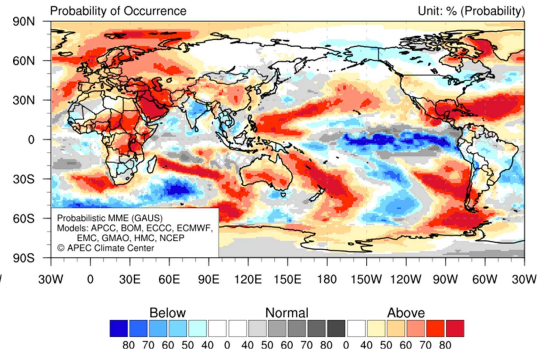


확률예측, 예측기간 : 2025.12.01. ~ 2025.12.28.

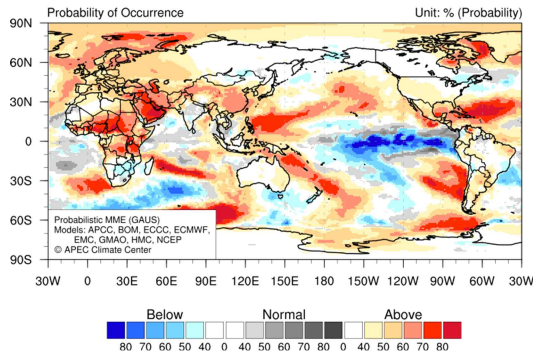
Week 1 (2025.12.01 - 2025.12.07)



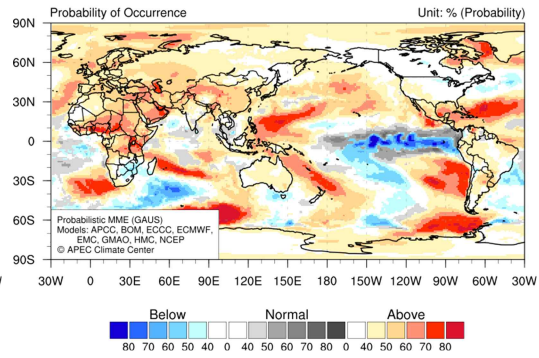
Week 2 (2025.12.08 - 2025.12.14)



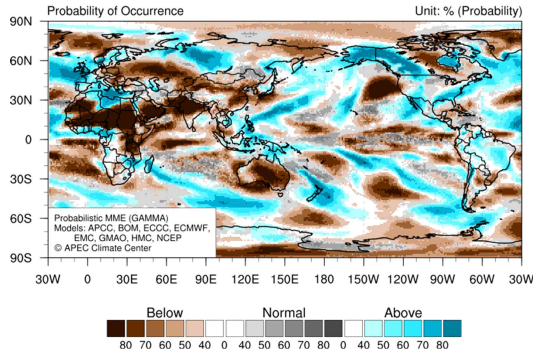
Week 3 (2025.12.15 - 2025.12.21)



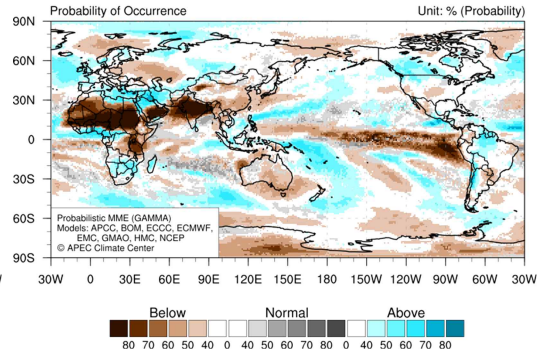
Week 4 (2025.12.22 - 2025.12.28)



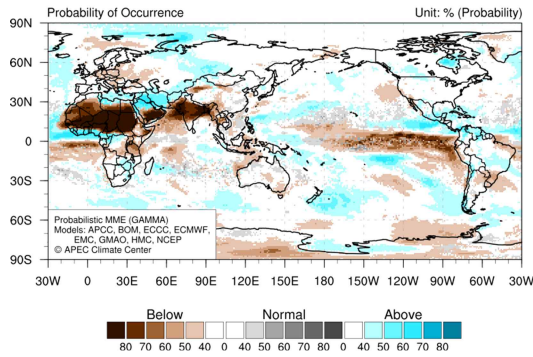
Week 1 (2025.12.01 - 2025.12.07)



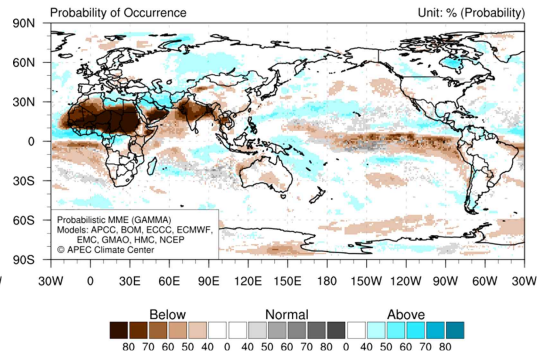
Week 2 (2025.12.08 - 2025.12.14)



Week 3 (2025.12.15 - 2025.12.21)

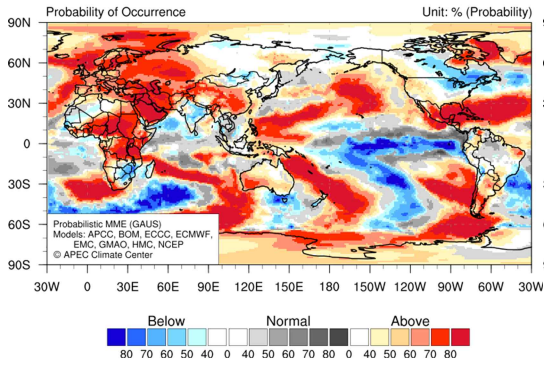


Week 4 (2025.12.22 - 2025.12.28)

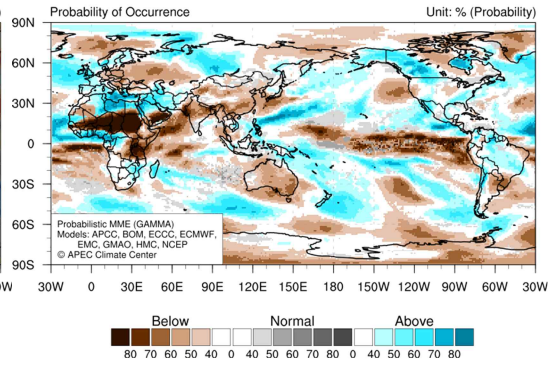


확률예측, 예측기간 : 2025.12.01. ~ 2025.12.28.

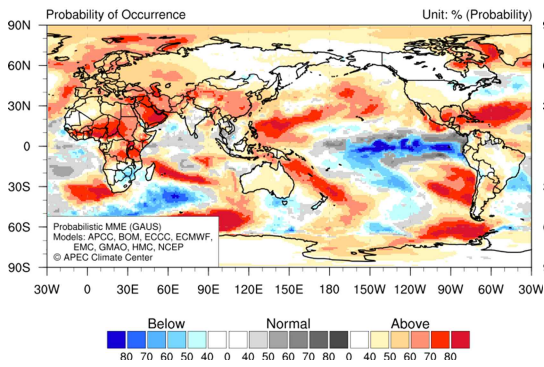
Week 1-4 (2025.12.01 - 2025.12.28)



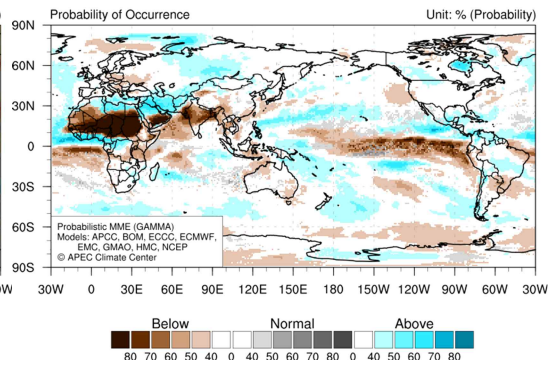
Week 1-4 (2025.12.01 - 2025.12.28)



Week 3-4 (2025.12.15 - 2025.12.28)

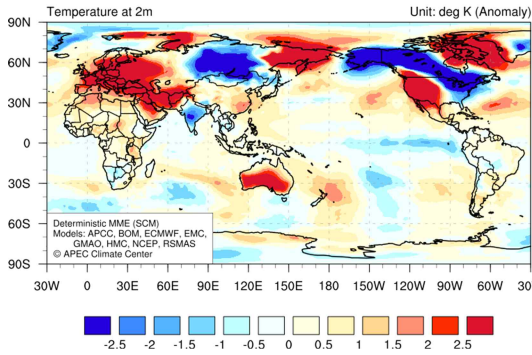


Week 3-4 (2025.12.15 - 2025.12.28)

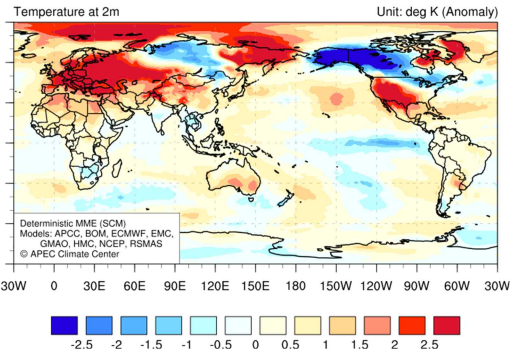


단정예측, 예측기간 : 2025.12.08. ~ 2026.01.04.

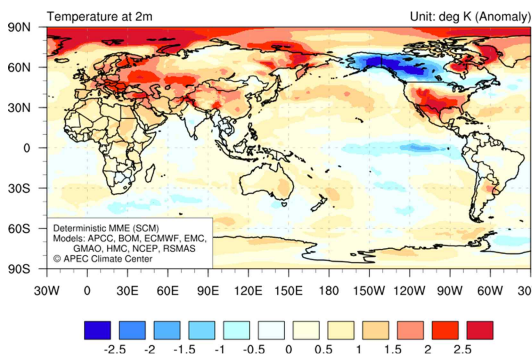
Week 1 (2025.12.08 - 2025.12.14)



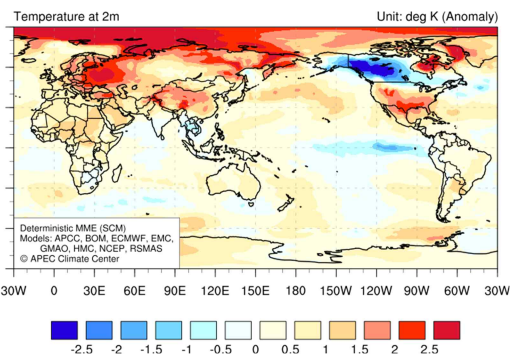
Week 2 (2025.12.15 - 2025.12.21)



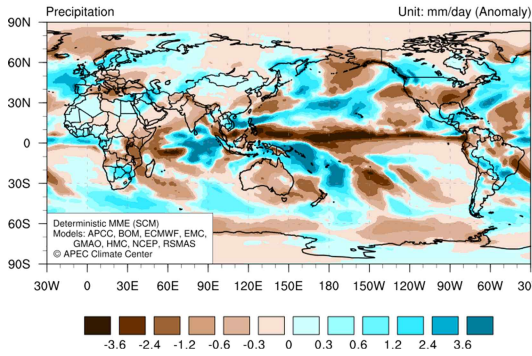
Week 3 (2025.12.22 - 2025.12.28)



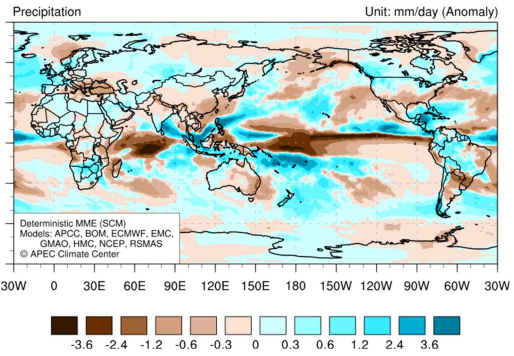
Week 4 (2025.12.29 - 2026.01.04)



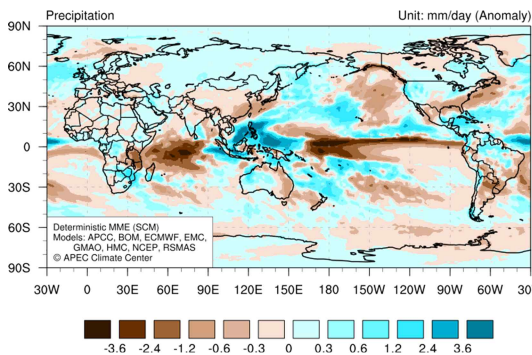
Week 1 (2025.12.08 - 2025.12.14)



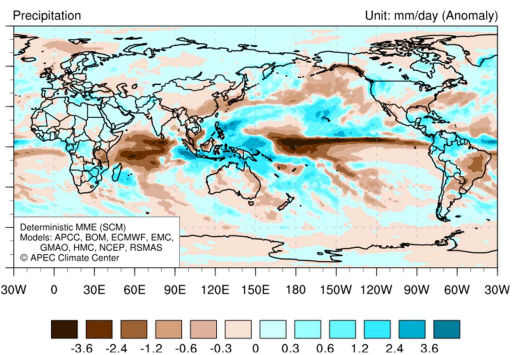
Week 2 (2025.12.15 - 2025.12.21)



Week 3 (2025.12.22 - 2025.12.28)

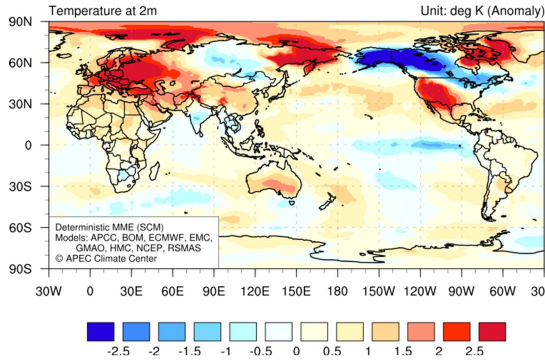


Week 4 (2025.12.29 - 2026.01.04)

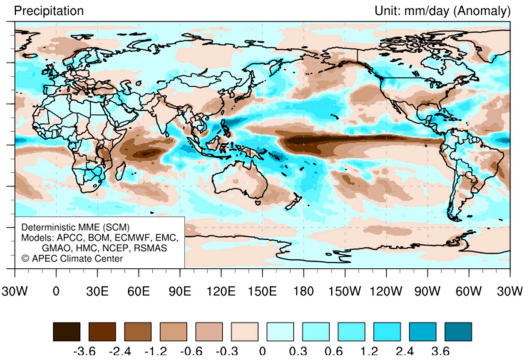


단정예측, 예측기간 : 2025.12.08. ~ 2026.01.04.

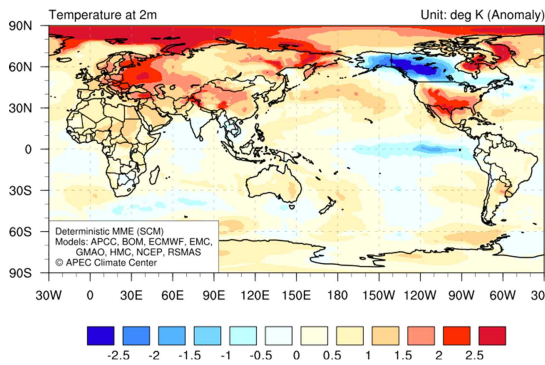
Week 1-4 (2025.12.08 - 2026.01.04)



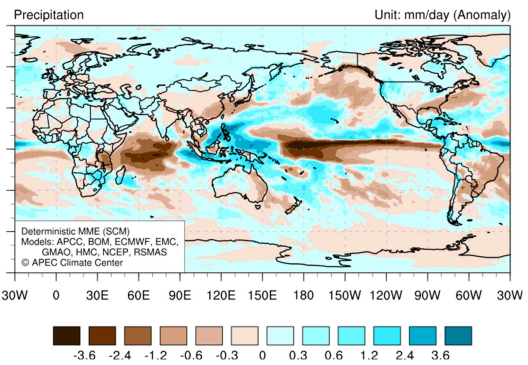
Week 1-4 (2025.12.08 - 2026.01.04)



Week 3-4 (2025.12.22 - 2026.01.04)

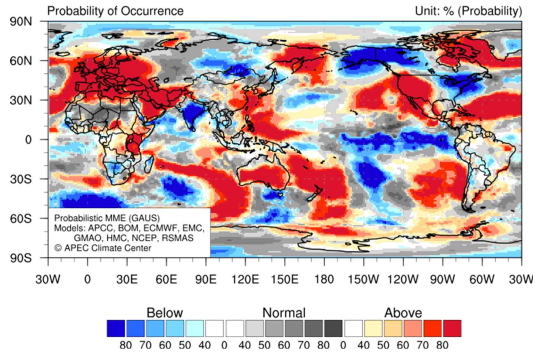


Week 3-4 (2025.12.22 - 2026.01.04)

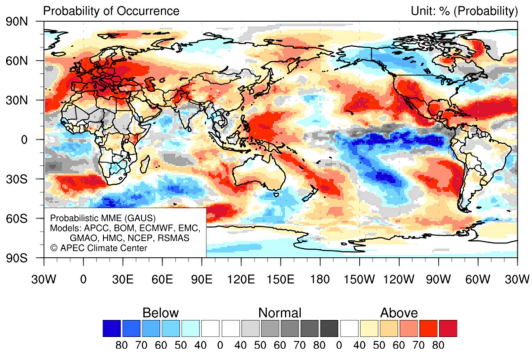


확률예측, 예측기간 : 2025.12.08. ~ 2026.01.04.

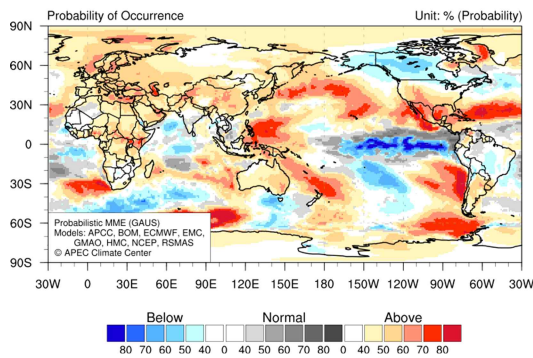
Week 1 (2025.12.08 - 2025.12.14)



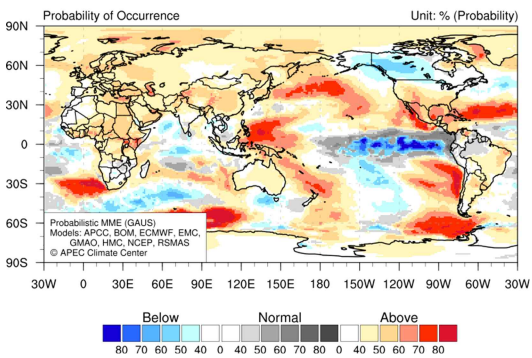
Week 2 (2025.12.15 - 2025.12.21)



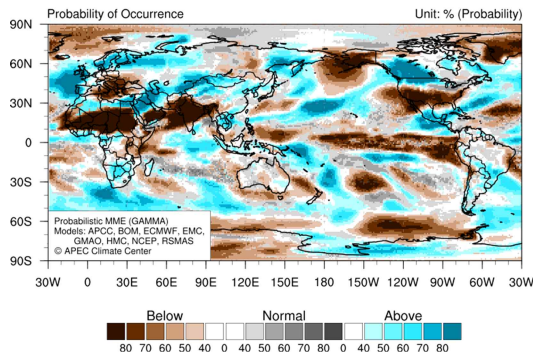
Week 3 (2025.12.22 - 2025.12.28)



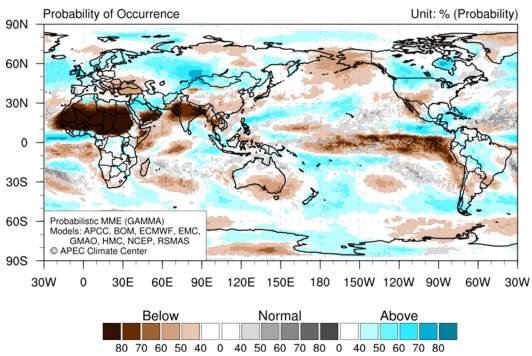
Week 4 (2025.12.29 - 2026.01.04)



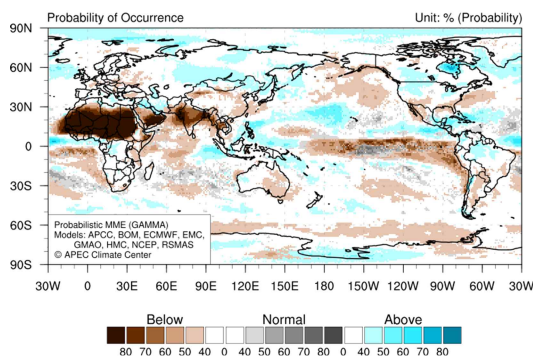
Week 1 (2025.12.08 - 2025.12.14)



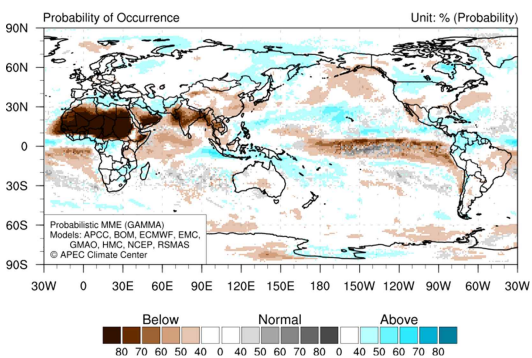
Week 2 (2025.12.15 - 2025.12.21)



Week 3 (2025.12.22 - 2025.12.28)

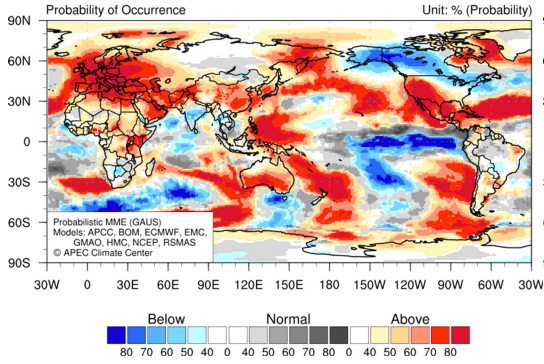


Week 4 (2025.12.29 - 2026.01.04)

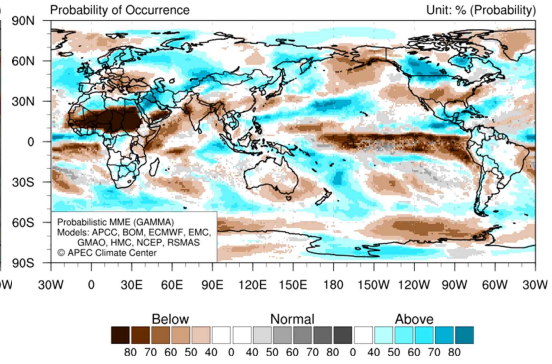


확률예측, 예측기간 : 2025.12.08. ~ 2026.01.04.

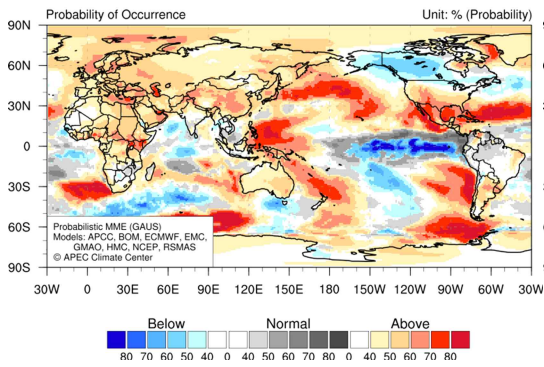
Week 1-4 (2025.12.08 - 2026.01.04)



Week 1-4 (2025.12.08 - 2026.01.04)



Week 3-4 (2025.12.22 - 2026.01.04)



Week 3-4 (2025.12.22 - 2026.01.04)

