

기후예측자료 기반 새로운 콘텐츠 생산을 위한 예측시스템 개발

Development of Prediction System for New Contents based on
APCC MME Seasonal Forecast

민영미, 손수진, 신선희, 이현주, 김가영 기후예측팀

발간사

아·태지역의 이상기후 감시 및 예측의 중추적 역할 수행을 위해 APEC 회원국 합의에 의해 설립된 APEC 기후센터는 2005년 개소 이후 지금까지 기후에 대한 진단 연구 및 예측 기술 개발을 위해 많은 노력을 기울여 왔다. 그 결과, APEC 기후센터는 현재 10개국 16기관의 예측정보를 통합함으로써 전 세계적으로 가장 다양한 계절예측모델의 정보를 활용한 다중모델앙상블 시스템 개발 및 안정적인 현업을 운영하고 있으며, 매월 홈페이지를 통해 신뢰도 높은 기후 예측정보를 제공하고 있다.

하지만 최근 다중모델앙상블을 활용하여 계절예측정보를 생산하는 현업 기관의 수가 점차 늘어나고 있으며, 또한 다중모델앙상블에 참여하는 모델들이 점차 중복되는 현 상황에서 세계 우수 현업 기관들과의 경쟁에서 APEC 기후센터의 우위 확보를 위해 사용자 중심의 새로운 콘텐츠 발굴 및 예측기술 개발이 절실히 필요한 시점이다. 따라서 다양한 계절예측정보 제공을 위해 APEC 기후센터 현업에 적합한 콘텐츠 발굴과 예측기술 개발이 목적인 본 과제는 시기적절하다고 판단되며 최종적으로 APEC 기후센터의 기후서비스 다양화에 기여한다는 점에서 상당히 의미가 크다고 할 수 있다. 또한, 세계 우수현업기관의 현황분석 및 센터 내 선행 연구들에 대한 종합적인 리뷰를 통해 현재 APEC 기후센터의 역량 및 타 기관과의 차별성 등을 고려하여 선정된 예측 콘텐츠에 대한 참여모델 및 다중모델앙상블의 예측력 평가는 향후 예측정보 해석 및 예측기술 개선을 위한 기초자료로 활용될 것으로 기대한다.

마지막으로 본 연구보고서가 발간되기까지 심도 깊은 연구를 수행한 민영미 박사, 신선희 박사, 손수진 박사, 이현주 연구원, 김가영 연구원에게 깊은 감사의 말씀을 드린다. 또한, 평가위원 및 자문위원으로서 아낌없는 조언과 격려를 해 주신 익명의 검토자들과 한양대학교 예상욱 교수 및 포항공과대학교 국종성 교수께 감사의 뜻을 전한다.

2018년 3월
APEC 기후센터
원장 정 홍 상

ABSTRACT

This work was motivated by the need for the development of an integrated system from finding new contents for providing seasonal forecast information to the development of a prediction method, as well as to the operation and construction of a prediction system. Considering the current monthly availability of APCC data, its internal capability and difference from other operational centers, four contents were potentially selected from analysis of the current status of leading centers that provide multi-model ensemble (MME) seasonal forecasts and comprehensive reviews of previous researches. The selected contents are ENSO type (or phase) and strength (or intensity), global drought, East Asia Winter Monsoon (EAWM), and climate extremes. The purpose of the first-year research, which was proposed as a multi-year project, is to evaluate the predictability and the prediction skill of the selected contents and the possibility of developing it into a climate service at the APCC.

We first developed a probabilistic MME prediction system (PMME) for ENSO type and strength forecasts, based on an uncalibrated multi-model ensemble with equal model weights, and a parametric Gaussian fitting method, which is the most appropriate for use in an operational prediction system. Then, we examined the skill of probabilistic forecasts for ENSO type and strength from individual models and from the MME with a large set of retrospective (1982–2010) and real-time forecasts (2013–2016). The results indicate that the developed PMME prediction system is capable of providing more detailed probabilistic forecasts of ENSO type and strength than are typically provided. Furthermore, the possible causes of the

failure and success of the model calibration and combination methods in a real-time basis and many operational issues when developing/improving the prediction system are also discussed.

A MME-based global drought prediction system has been developed as a prototype for the period of 1983–2005 and its prediction skill has been evaluated. The model-simulated precipitation can be calibrated based on the mean bias that performs better than the mean/variance correction. Six-month Standardized Prediction Index (SPI6) prediction shows high skills due to its auto-correlation and robust skills compared to that of persistent run. Categorical forecast skills for the occurrence, intensity, and spatial extent of drought events show that the SPI prediction of bias calibrated MME precipitation has the best performance. The well-designed and well-validated drought prediction system can be further developed for real operational practice.

By analyzing the characteristics of the existing EAWM indices, we present the EAWM index, which is representative of winter temperature fluctuations in East Asia. Using this index, we developed a dynamic – statistical hybrid prediction model and tried to provide reliable winter season prediction information. This hybrid model shows a reasonable skill of 0.6 or higher, which significantly improves the inter-model difference and represents the same EAWM phase for most years. Moreover, it shows consistently significant skill in all individual models, and is maintained with a lead time of four months. Therefore, it is expected that reliable seasonal forecast of EAWM can be produced.

Finally, we examine the skill of probabilistic forecasts for climate extremes during the period 1982–2005, defined by the upper and lower 15th percentile of a climatological distribution, from individual models and the MME in both deterministic and probabilistic sense. Our results reveal several significant issues. Firstly, the superiority of the multi-model concept is more clearly evidenced in a probabilistic

framework. Secondly, a parametric Gaussian fitting method along with a pooling approach is the most appropriate way to estimate forecast probability and to combine predictions of individual models for global climate extremes. Thirdly, the current systems can predict extreme temperatures, but the predictability of extreme precipitations on seasonal scales is still limited. Additionally, sensitivity experiments on different percentiles (10/15/20%) are discussed.

목 차

1. 연구 배경	1
2. 세계 유수현업기관 현황 및 선행 연구 리뷰	4
2.1 국외 현황	4
2.1.1 북미지역 다중모델앙상블(NMME)	4
2.1.2 국제 기후·사회 연구소(IRI)	6
2.1.3 유럽중기예보센터(ECMWF)	9
2.1.4 세계기상기구 장기예보 선도센터(WMO LC-LRF)	11
2.2 센터 내 선행 연구	12
2.3 콘텐츠 발굴	13
3. ENSO 종류/강도 확률예측기술 개발	15
3.1 서론	15
3.2 자료 및 분석 방법	17
3.2.1 관측 및 모델자료	17
3.2.2 분석 방법	20
3.3 APCC 개별모델 및 MME 예측성 평가	25
3.3.1 SST 및 Nino 3.4 지수	25

3.3.2 유수현업기관과의 예측력 비교	29
3.4 다중모델앙상블 확률 예측기술 개발	32
3.4.1 분포도 적합성 검정	32
3.4.2 모수화/비모수화에 따른 예측확률 추정	36
3.4.3 ENSO 확률예측기법의 예측력 평가	40
3.5 확률 다중모델앙상블 예측기술 개선	49
3.5.1 Model Calibration	49
3.5.2 Model Combination	56
3.5.3 실시간 예측(2013-2016) 적용	59
3.5.4 예측력 향상이 나타나지 않은 이유?	62
3.6 요약	71
4. 전구 가뭄 예측기술 개발	75
4.1 서론	75
4.2 가뭄지수의 선정	78
4.3 전구 가뭄 예측시스템 개발 및 과거기후예측 자료 생산	82
4.3.1 전구 가뭄 예측시스템	82
4.3.2 SPI	84
4.3.3 검증 방법	86
4.4 전구 강수 및 가뭄의 특징	87
4.5 전구 육지 지역에 대한 강수 예측 성능	92
4.6 평균 및 분산을 고려한 기후학적 편차 보정	96
4.7 가뭄지수의 일반적인 예측성능	103
4.8 가뭄의 주요 특징과 관련된 예측성능	106
4.8.1 가뭄 발생	107
4.8.2 가뭄 강도	109
4.8.3 가뭄 범위	112

4.9 계절성과 관련된 예측성능	114
4.10 요약	117
5. 동아시아 겨울 몬순 예측기술 개발	120
5.1 서론	120
5.2 자료 및 연구 방법	123
5.2.1 자료	123
5.2.2 EAWM 지수	124
5.2.3 역학-통계 하이브리드 예측 기법 개발	125
5.3 EAWM 예측력 평가	126
5.3.1 EAWM 지수의 특성	126
5.3.2 역학모형에서의 예측력	130
5.3.3 역학-통계 하이브리드 예측	137
5.4 요약	146
6. 극한 기후 예측기술 개발	149
6.1 서론	149
6.2 연구 자료 및 방법	151
6.2.1 관측 및 모델 자료	151
6.2.2 검증방법	153
6.2.3 극한 기후 정의	154
6.3 변동성 분석 및 예측성 평가	154
6.3.1 관측자료 분석	154
6.3.2 APCC 참여모델 및 MME 예측력 평가	158
6.4 MME를 활용한 극한 기후 확률예측기법 개발	162
6.4.1 분포도 적합성 검정	162
6.4.2 모수화/비모수화 기법에 따른 예측력 평가	165

6.4.3 다중모델양상불 기법-----	170
6.4.4 예측력 평가-----	172
6.5 요약-----	179
7. 결론 및 종합 토론-----	182
■ REFERENCES -----	185
■ Glossary -----	201
■ APPENDIX 1. -----	204
■ APPENDIX 2. -----	207
■ APPENDIX 3. -----	208
■ APPENDIX 4. -----	210

LIST OF TABLES

Table 1.1.	Relative Operating Characteristic (ROC) scores for global 3-month mean tercile-based categorical probabilistic forecasts of precipitation from APCC and other operational centers providing seasonal forecasts for the period 2012–2015. For each category, the highest skill result among the all centers is shown in table in bold. -----	3
Table 2.1.	Description of participating models in NMME real-time forecast. ----	5
Table 2.2.	Climate services disseminated by NMME (http://www.cpc.ncep.noaa.gov/products/NMME/). -----	5
Table 2.3.	Climate services disseminated by IRI (http://iri.columbia.edu/our-expertise/climate/forecasts/#GCM_and_SST_Forecast_Model_Outputs) -----	7
Table 2.4.	EUROSIP Climate services disseminated by int/en/ECMWF (https://www.ecmwf.forecasts/charts/seasonal/) -----	10
Table 2.5.	Description of participating models in EUROSIP. -----	10
Table 2.6.	Description of participating models in WMO LC-LRF. -----	11
Table 2.7.	Climate services disseminated by WMO LC-LRF (https://www.wmolc.org). -----	12
Table 2.8.	Summary of researches related to development/improvement of MME techniques, data analyses and application, and predictability for seasonal forecasts. -----	14
Table 3.1.	Description of eight participating models in MME ENSO prediction used in the study. -----	19
Table 3.2.	Definition of historical episode on ENSO type (or state) from different operational centers providing seasonal forecasts. -----	21

Table 3.3. Definition of ENSO type and strength based on 3-month mean Nino 3.4 index anomaly used in the study. -----	22
Table 3.4. Description of model combination experiments with different weights of individual models for probabilistic MME ENSO type and strength forecast used in the study. -----	24
Table 3.5. Temporal correlation coefficients (TCCs) of 3-month mean Nino 3.4 index forecast anomalies from eight individual models and MME for the whole period 1982JFM–2010/11DJF at lead times of 1 (L1) and 4 months (L4). -----	27
Table 3.6. TCCs for hindcasts of the participating models in the IRI/CPC, NMME, and APCC ENSO forecast. -----	31
Table 3.7. P-value of K-S test for the normality of the observed 3-month mean Nino 3.4 index for each target season during the period 1982–2010. ----	34
Table 3.8. Frequency of ENSO type from individual models and observation. The values in parenthesis refer to relative error with respect to the observation (%). -----	50
Table 4.1. Main characteristics of various drought indices. -----	78
Table 4.2. Brief data description of various drought indices. -----	81
Table 4.3. Description of the eight coupled climate models used in this study. ---	83
Table 4.4. Flood/drought conditions categorized according to the SPI value. --	87
Table 4.5. Global mean of basic statistics of accumulated precipitation at 6 months. ----	91
Table 5.1. Description of 9 APCC models used in this study. -----	123
Table 5.2. Description of 13 EAWM indices used in this study. Here, SLP: sea level pressure, U: zonal wind, Φ : geopotential height. Superscript -----	125
Table 5.3. The correlation coefficients between observation and individual models for EAWM, Artic Oscillation (AO), Siberia High (SH), East Asian Trough (EAT), and East Asian Jet Stream (EAJS). Values in Bold and *, ** fonts exceed the confidence levels of 90%, 95% and 99%. -----	137

Table 5.4.	The correlation coefficients of EAWM with Nino3.4, Artic Oscillation (AO), Siberia High (SH), East Asian Trough (EAT), and East Asian Jet Stream (EAJS) in reanalysis and individual forecast models and their MME. Values in Bold and *, ** fonts exceed the confidence levels of 90%, 95% and 99%. -----	137
Table 6.1.	Overview of APCC models used in this study. -----	152
Table 6.2.	Relationship between counts of forecast and event pairs for the dichotomous categorical verification situation as displayed in a 2×2 contingency table. -----	154
Table 6.3.	Temporal correlation coefficient (TCCs) for the probability of occurrence of upper 15% extremes for JJA/DJF temperature and precipitation from individual models and observation for the period 1982–2005. -----	159
Table 6.4.	List of probabilistic multi-model ensemble approaches considered for this study. -----	176

LIST OF FIGURES

- Figure 1.1. Flow chart for the development and improvement of APCC operational monitoring, prediction, and verification systems. ----- 2
- Figure 1.2. Anomaly Pattern Correlation Coefficients (PCCs) of (a) global 3-month mean (seasonal) temperature at 850hPa and (b) precipitation forecast from the APCC MME prediction system in each year (2008–2016) for the hindcast period of 1983–2005. The relative skill difference is calculated as the skill difference between the recent 3-year mean PCCs (2014–2016) and the first 3-year mean PCCs (2008–2011), divided by the recent the first 3-year mean ones, given a variable and season (%). ----- 3
- Figure 2.1. (a) ENSO Plume prediction and (b) ENSO 3-categorical probabilistic MME forecasts issued by IRI and NOAA/CPC. ----- 8
- Figure 2.2. Forecast probability of SPI below selected SPI threshold for Mar. 2017 issued at the end of Feb. 2017. ----- 8
- Figure 2.3. EUPORIAS partnership (<https://www.metoffice.gov.uk/research/collaboration/euporias>). ----- 10
- Figure 3.1. (a) Spatial distribution of SST MME forecast anomaly for 2014DJF and (b) Nino 3.4 index forecast for 2014SONDIF from individual models and MME prediction issued on November 2014 at APCC. ----- 17
- Figure 3.2. Errors of the first-lead 3-month mean Nino 3.4 forecast anomaly from the corresponding observation for the period 1982JFM–2010/11DJF. (a) NCEP based on 1982–2010 climatology and (b) NCEP_2c based on two climatologies (1982–1998, 1999–2010). ----- 20

- Figure 3.3. Schematic diagram for the estimation of forecast probabilities (a) based on empirical ranking method and (b) based on statistical fitting method from a forecast PDF for each category, El Nino, ENSO-Neutral, and La-Nina. -- 23
- Figure 3.4. Schematic diagram showing (a) the combination of forecast probabilities from single-model (M1-Mn) by applying the total probability formula with different model weights (PMME; e.g., equal weighting, proportional to the ensemble size, etc.) and (b) the pooling of the bias-corrected ensembles from each single-model together to produce one large super-ensemble with equal weights (POOL) to estimate categorical probabilities. -- 24
- Figure 3.5. (a) The observed (red) and the first-lead forecast anomalies of 3-month mean Nino 3.4 index from individual models (grey) and MME (blue), and (b) same as (a), except for only MME forecasts at lead times of 1, 2, 3, 4 months. ----- 27
- Figure 3.6. TCCs of 3-month mean Nino 3.4 index forecast anomalies from (a-h) each individual models and (i) MME as a function of target season (3-month mean) and lead time. Black plus indicates that the skill is not statistically significant at 5% significance level using a Student's t-test. ----- 28
- Figure 3.7. TCCs ($\times 100$) of SST forecast anomalies for (a) NMME prediction and (b) APCC MME prediction for each season (1-month lead DJF, JJA, SON, and DJF) during the period 1982-2010. NMME results are extracted from Figure 8 of Becker et al. (2014). ----- 29
- Figure 3.8. Skill improvement of APCC-MME and NMME-MME as compared with the average of the individual models skill (AVG) in terms of TCC (%). ---- 32
- Figure 3.9. Kolmogorov-Smirnov (K-S) Test for the normality of observed SST anomalies for (a) MAM, (b) JJA, (c) SON, (d) DJF for the period 1982-2010. Shaded areas are the regions where the observed PDFs differ from the normal PDFs at the 5% significance level. The box indicates the Nino 3.4 region. -- 33
- Figure 3.10. Distribution of 3-month mean Nino 3.4 index from POAMA for each target season during the period 1982-2010. P-values of K-S test for the normality are displayed. Blue, grey, and red indicate El Nino, ENSO-Neutral, and La Nina condition. ----- 35

- Figure 3.11. Mean and maximum difference in forecast probability for (a) ENSO type (3-category; El Nino, ENSO-Neutral, La Nina) and (b) ENSO strength (7-category, strong/moderate/weak El Nino/La Nina, ENSO-Neutral) using Gaussian fitting method (GAUS) and empirical ranking method (EMP) for each model and target season, during the period 1982–2010. All years, leads, and multi-category are included. ----- 37
- Figure 3.12. Same as Figure 3.11, except for each category of ENSO type and strength. ----- 38
- Figure 3.13. Ranked probability skill score (RPSS) and Heidke Skill Score (HSS) of ENSO (a) type and (b) strength forecasts, averaged over all target seasons and lead times, with different methods (GAUS, EMP) for estimation of forecast probability. Blue (light blue) indicates that the skill difference between GAUS and EMP is significant using a Monte-Carlo (MC) test at 10% (20%) significance level. ----- 39
- Figure 3.14. Aggregated ROC curve over all years, target seasons, and leads of individual models' forecast (open circle) and PMME forecast (closed circle) for ENSO type; (a) El Nino, (b) ENSO-neutral, and (c) La Nina, and for ENSO strength; (d-f) strong/moderate/weak El Nino and (g-i) strong/moderate/weak La Nina. ----- 43
- Figure 3.15. Same as Figure 3.14, except for only PMME ENSO type forecast at lead times of 1, 2, 3, 4 months. ROC scores (area under the ROC curve) for each category and lead time are shown in the plot. ----- 44
- Figure 3.16. Same as Figure 3.15, except for ENSO strength forecast. ----- 44
- Figure 3.17. (a) Observed 3-month mean Nino 3.4 index and its PMME forecast for ENSO type (El Nino, ENSO-Neutral, and La Nina) at lead times of (b) 1 and (c) 4 months. ----- 47
- Figure 3.18. (a) Same as Figure 3.17, except for ENSO strength forecast. ----- 48
- Figure 3.19. Distribution of (a) observed and the first-lead Nino 3.4 forecast anomalies from (b-i) individual models. Variation (Var) and Skewness (Skew) for each distribution are also displayed. Blue, grey and red indicate El Nino, ENSO-Neutral, and La Nina condition. ----- 50

- Figure 3.20. Seasonal frequency of (a) ENSO type and (b-c) ENSO strength forecasts based on 3-month mean Nino 3.4 index with the corresponding observation for the period 1982–2010. ----- 52
- Figure 3.21. Difference in seasonal frequency of ENSO type forecasts with corresponding observation. Histogram, plus-marker and star-marker indicate the frequency from MME, each individual model, and CMCC, respectively. ----- 53
- Figure 3.22. Schematic diagram of M-II method to newly define thresholds by having the same frequency as observations for El Nino, ENSO–Neutral, and La Nina for each model and target season. ----- 54
- Figure 3.23. RPSS difference of probabilistic forecasts for (a) ENSO type and (b) ENSO strength between M-I and M-II as a function of lead time and target season for the period 1982–2010. ----- 55
- Figure 3.24. (a) Averaged model error and (b) forecast skill (HSS) for ENSO type and ENSO strength over the years, seasons, and leads. Model error is calculated by $\frac{|M - O|}{M + O}$, where M and O are forecast probabilities from model and observation and E, N, and L indicate El Nino, ENSO–Neutral, and La Nina. --- 56
- Figure 3.25. RPSS of probabilistic forecast from (a) PMME, (b) POOL, (c) PMME_N, and (d) PMME_SK for ENSO type and (e–g) skill difference with respect to PMME ones as a function of target season and lead time for the period 1982–2010. Averaged RPSS over the seasons and leads are also displayed. ----- 57
- Figure 3.26. Averaged RPSS of probabilistic forecast for (a) ENSO type and (b) ENSO strength over the target seasons and leads for the period 1982–2010. Relative skill difference (RD) is estimated by difference between M-I and M-II, divided by M-I for each target season and lead, and then averaged them. ----- 59
- Figure 3.27. (a) Observed 3-month mean Nino 3.4 index and the first-lead PMME forecast for (b) ENSO type and (c) strength based on M-II method for the period 2013–2016. ----- 61

- Figure 3.28. Scatter diagram of forecast skills of ENSO type and strength using M-I and M-II method in terms of RPSS and HSS for each individual models and MMEs for the period 2013–2016. ----- 62
- Figure 3.29. Averaged RPSS of probabilistic forecast for ENSO type over target seasons and leads from different experiments. All estimations are based on (a) 29 years for hindcast (No), (b) 28 years in a cross-validation mode for hindcast (Cv), and (c) 29 years for real-time forecast (RT). (c) Skill difference between M-II and M-I in No and Cv. ----- 66
- Figure 3.30. Means of 23-year moving averaged Nino 3.4 SST climatology for the period 1982–2010 for each target season (closed circle). Maximum and minimum values (their differences) are also displayed with plus-marker (histogram). ----- 67
- Figure 3.31. The dependence of occurrence probability of (a–c) ENSO type and (d–i) strength for each target season from observation as Nino 3.4 SST climatologies of 23-year moving average for the period 1982–2010. ----- 67
- Figure 3.32. The 29-year mean ratio, R, for 3-month mean SST from individual models. R is the ratio between the model standard errors and differences between the model ensemble means. ----- 70
- Figure 4.1. U.S. Seasonal Drought Outlook of NOAA CPC. ----- 77
- Figure 4.2. Global Integrated Drought Monitoring and Prediction System (GIDMaPS). --- 77
- Figure 4.3. Consistency of inter-drought indices. PDSI, sc-PDSI, SPI, and SPEI are taken from different database. SPEI (Calc) is calculated based on 2m air temperature form National Centers for Environmental Prediction–National Center for Atmospheric Research (NCEP–NCAR) reanalysis products (Kalnay et al. 1996) and Climate Anomaly Monitoring System Outgoing Longwave Radiation Precipitation Index (CAMS OPI; Janowiak and Xie 1999). Both SPI and SPEI (or Calc) represent those estimated from 6-month accumulated data. ----- 81
- Figure 4.4. Defining SPI from accumulated precipitation amount. ----- 86
- Figure 4.5. Interannual variance for the 6-month accumulated precipitation, based on (a) NDJFMA and (b) MJJASO. ----- 88

- Figure 4.6. Frequency of drought occurrences based on SPI6 ending in (a) April and (b) October. Blue line denotes the monsoon area with large precipitation variability exceeding 30 mm/day. ----- 88
- Figure 4.7. Same as Figure 4.5 but for skewness. ----- 89
- Figure 4.8. Moment ratio diagram for accumulated precipitation at 6 months based on (left) observations and (right) MME prediction. Red dots denote the mean of whole samples. ----- 90
- Figure 4.9. (a) Time series of the observed SPI6 (left; shaded) and LEPS of MME-simulated SPI6 (right; blue dashed line) averaged over the globe. The temporal correlation between the two time series is given at the upper right. (b) Same as Figure 4.9a but for global extent. ----- 91
- Figure 4.10. Global distribution of temporal correlation coefficient (TCC) between observations and the MME prediction for (a) January, (b) April, (c) July, and (d) October. Values with absolute magnitudes of 0.526, 0.413, 0.352, and 0.277 represent the 99%, 95%, 90%, and 80% confidence levels, respectively. The area-averaged value over the globe are provided in upper right of each panel. ----- 93
- Figure 4.11. Same as Figure 4.10 but for global terrestrial region. ----- 93
- Figure 4.12. Area-averaged values of TCC between observations and simulations, over the terrestrial region of (a) globe, (b) northern hemisphere, and (c) southern hemisphere, from January to December. Hatched bars in purple and plain bars in sky blue denote the MME and model prediction, respectively. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models. ----- 94
- Figure 4.13. Time-averaged values of pattern correlation coefficient (PCC) between observations and simulations, during the period of 1983–2005 for (a) January, (b) April, (c) July, and (d) October. Hatched bars in purple and plain bars in sky blue denote the MME and model prediction, respectively. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models. The mean values of the MME and model prediction are provided in upper right of each panel. ----- 95

- Figure 4.14. Spatial maps of SPI6 ending in October 1988 over the North American Continent based on (a) observation and raw predictions without any calibration from (b) MMEp, (c) MMEs, (d) APCC, (e) CMCC, (f) CANCM3, (g) CANCM4, (h) NASA, (i) NCEP, (j) PNU, and (k) POAMA. The PCCs between observations and predictions are shown at the upper right of the panels, from (b) to (k). ----- 97
- Figure 4.15. Same as Figure 4.14 but for the bias-corrected predictions with observed climatological mean. ----- 98
- Figure 4.16. Same as Figure 4.14 but for the bias-corrected predictions with observed climatological mean and variance. ----- 99
- Figure 4.17. TCC (x-axis) and PCC (y-axis) skills between observations and various prediction for SPI6 for the domain of (a) globe and (b) North American Continent. TCC skill denotes the area-averaged over the domain and PCC skill denotes the time-averaged for the whole period of 1983–2003. The non-calibrated, mean, mean and variance-calibrated predictions are presented in gray-black, sky blue-purple, orange-red, respectively. The individual models, the MMEp and MMEs denote thin open, thick open, closed circles, respectively. The respective dotted lines denote the spread of the model and MME predictions for each calibration method. ----- 100
- Figure 4.18. (a, c) TCC skill and (b, d) root mean square errors, between observations and the mean-calibrated predictions, of SPI6 for (a, b) MMEp and (c, d) MMEs. ----- 102
- Figure 4.19. Same as Figure 4.18 but for the mean and variance-calibrated predictions. ----- 102
- Figure 4.20. (a) Area-averaged TCC (x-axis) and RMSE (y-axis) of the mean (mean and variance)-calibrated prediction in blue sky-purple (in orange-red) with observations for global SPI6. (b) The difference between mean-calibrated and mean and variance-calibrated TCC and RMSE. Various marks in the legend denote two MME and their member models. High TCC skill and low RMSE is denoted by the rectangle surrounded by red dotted lines in (b). ----- 103

Figure 4.21. (a, b) TCC skills of the mean calibrated predictions from (a) MMEp and (b) MMEs with observations for global SPI6. (c, d) Improvement of TCC skills from (c) MMEp and (d) MMEs, compared to baseline skill of persistent run. Shading denotes the value exceeding the 95% significance level.

----- 104

Figure 4.22. Global mean of skill improvement from the model and MME predictions of SPI6 for (a) the whole period and initiated in (b) November and (c) February. Various marks in the legend denote two MME and their member models.

----- 105

Figure 4.23. (Left) PCC skills of the various predictions for the global SPI6 during the whole period from 1983 to 2005, and the time-averaged value. The numbers from 1 to 11 in the right panel and legend indicate the MME and its member models. The corresponding colors between left and right panels denote the same model prediction

----- 106

Figure 4.24. Verification skills of categorical forecast of (a c, e) MMEp and (b, d, f) MMEs for drought occurrence, based on (a, b) hit rate, (c, d) false alarm, and (e, f) threat score.

----- 108

Figure 4.25. Global mean of various verification skills of categorical forecast of individual models and their MME for drought occurrence. The numbers from 1 to 11 in the figure and legend indicate the MME and its member models.

----- 109

Figure 4.26. Verification skills of categorical forecast for (a c, e, g) severe and (b, d, f, h) extreme drought, based on (a, b) hit rate, (c, d) false alarm, (e, f) threat score, and (g, h) bias.

----- 110

Figure 4.27. Global mean of various verification skills of categorical forecast of individual models and their MME for (a) severe and (b) extreme drought. The numbers from 1 to 11 in the figure and legend indicate the MME and its member models

----- 111

Figure 4.28. (Left) Time series and (right) time-averaged value of various verification skills of categorical spatial forecast of individual models and their MME for drought occurrence over the globe, based on (a) hit rate, (b) false alarm, (c) threat score, and (d) bias. The numbers from 1 to 11 in the upper panel and legend indicate the MME and its member models.

----- 113

- Figure 4.29. Time-averaged value of various verification skills of categorical forecast of individual models and their MME for (a) severe and (b) extreme drought. The numbers from 1 to 11 in the figure and legend indicate the MME and its member models. ----- 114
- Figure 4.30. Area-averaged values of TCC between observations and simulations for SPI6, over the terrestrial region of (a) globe, (b) northern hemisphere, and (c) southern hemisphere, from January to December. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models. ----- 115
- Figure 4.31. Time-averaged values of PCC between observations and simulations for SPI6 ending in (a) June, (b) September, (c) December, and (d) March, during the period of 1983–2005. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models. The mean values of the MME and model prediction are provided in upper right of each panel. ----- 116
- Figure 5.1. Spatial pattern and principal component (PC) of the first and second EOF modes for DJF mean T2m in the entire EAWM domain [0°–60°N, 100°–140°E]. The numbers in parentheses on the top of the panels denote the contribution of the total variances, whereas the numbers on the top-right corners of the lower panels denote the correlation coefficient between the PC of two major EOF modes and DJF-mean T2m averaged over Korea [35°–40°N, 125°–130°E]. ----- 122
- Figure 5.2. Illustration of the regions for defining the existing EAWM index, as listed in Table 5.2. ----- 124
- Figure 5.3. Schematic diagram illustrating the dynamic-statistical hybrid EAWM prediction system. ----- 126
- Figure 5.4. Time series of the DJF-mean T2m averaged over Korea (gray bar) and EAWM indices (color marker) obtained from the reanalysis data (observation) for 1983–2016. Black marked line denotes the simple average over EAWM indices. ----- 128
- Figure 5.5. (Upper) The correlation coefficients between EAWM indices and East Asia temperature modes developed by Wang et al (2010). (Lower) The correlation coefficients between DJF-mean temperature anomaly averaged over Korea

(East Asia) and EAWM indices. The last bar, MEAN represent the simple average over EAWM indices. ----- 129

Figure 5.6. Scatter plots of normalized EAWM index vs DJF-mean T2m anomalies averaged over Korea during the period of hindcast (1983–2010). The abscissa (ordinate) of each dot in each diagram represents the amplitude and sign of the EAWM index (temperature anomalies) for an individual winter season. ----- 130

Figure 5.7. The correlation coefficients between the observed and simulated normalized DJF-mean EAWM indices during the period of 1983–2010. Dashed lines denotes the threshold values for the 95% and 99% significance levels. ----- 132

Figure 5.8. The correlation coefficients between observed and simulated EAWM indices by MME and individual model forecasts with varying forecast lead time. Upper and lower panels represent the EAWM prediction skill calculated by WangC_P and Li_U index, respectively. The dashed lines denote the statistical significance at the 99% and 95% confidence level. ----- 133

Figure 5.9. Time series of the DJF-mean EAWM indices from the observation (gray bar) and the model forecasts with 1 month lead time from MME and individual models. ----- 134

Figure 5.10. Scatter plots of simulated EAWM index from POAMA vs observed DJF-mean T2m anomalies averaged over Korea based on the WangC_P and Li_U indices. ----- 134

Figure 5.11. Spatial distribution of correlation coefficients between the observed and APCC MME hindcast T2m, T850, SLP and Z500 with 1-month lead time over the 28-years period 1983–2010. Black dots indicate correlations above the 95% confidence level. Boxes indicate the region where the variables are used as predictors for the dynamic-statistical forecasts of EAWM. ----- 140

Figure 5.12. Correlations of observed and APCC MME hindcast DJF SLP, T2m, T850 and Z500 with the observed EAWM index. ----- 141

Figure 5.13. Correlations of predicted EAWM indices with 1-month lead time from MME and individual models. Black dots denote the cross-validated correlation coefficients. ----- 142

- Figure 5.14. Time series of the DJF-mean EAWM indices obtained from observation (gray bar), dynamic (blue line), and dynamic-statistical hybrid forecasts (red line) with 1-month lead time. ----- 143
- Figure 5.14. Time series of the DJF-mean EAWM indices obtained from observation (gray bar), dynamic (blue line), and dynamic-statistical hybrid forecasts (red line) with 1-month lead time. ----- 143
- Figure 5.15. Time series of the DJF-mean EAWM indices from the observation (gray bar) and the hybrid model forecasts with 1 month lead time from MME and individual models (colored mark). The red line denotes the DJF-mean T2m averaged over Korea and blue line denots the ONI index. --- 144
- Figure 5.16. Prediction skill of dynamic and hybrid EAWM forecasts with varying forecast lead time and their difference. ----- 145
- Figure 5.17. Scatter plots of forecasted EAWM index vs observed DJF-mean T2m anomalies averaged over Korea based on the WangC_P index. Left and right panels are from the results of POAMA and mean index averaged over individual hybrid indices. ----- 146
- Figure 6.1. Spatial distribution of upper 15% extremes for JJA temperature during the period 1982–2016. ----- 156
- Figure 6.2. Interannual variability of the upper/lower 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) over globe for the period 1982–2016. ----- 156
- Figure 6.3. Recent trend in the occurrence probability of the upper/lower 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) for the period 2006–2016. ----- 157
- Figure 6.4. Interannual variability of the upper 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) during the period 1982–2005 from the individual models (circle) and their simple averaged MME (solid line), with the corresponding observation (dashed line). ----- 159
- Figure 6.5. Symmetric Extremal Dependency Index (SEDI) of upper 15% extremes for JJA/DJF a) temperature and b) precipitation from individual models

and MME. Dashed (solid) line indicates the average of the individual models' SEDI in JJA (DJF) for the period 1982–2005. ----- 161

- Figure 6.6. Spatial distribution of SEDI of the upper 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) from MME prediction for the period 1982–2005. ----- 161
- Figure 6.7. Anderson–Darling (A–D) and Kolmogorov–Smirnov (K–S) Tests for the normality of JJA/DJF (a) temperature and (b) precipitation. Shaded areas (contours) are the regions where the observed PDFs differ from the empirical normal PDFs at the 5% significance level from the AD (KS) tests. ----- 164
- Figure 6.8. Same as Figure 6.7, except for only JJA precipitation from individual models. ----- 164
- Figure 6.9. Probabilistic forecasts of upper 15% extremes for JJA 1998 temperature using empirical ranking method (EMP), as an example. ----- 166
- Figure 6.10. Same as Figure 6.9, except for using Gaussian fitting method (GAUS). --- 167
- Figure 6.11. Difference in probability of upper 15% extremes for a) temperature and b) precipitation from two different methods (EMP and GAUS) to estimate forecast probabilities. ----- 167
- Figure 6.12. ROC score aggregated over globe of probabilistic forecast of upper 15% extremes for a) JJA and b) DJF temperature. ----- 169
- Figure 6.13. Same as Figure 6.12, except for precipitation. ----- 170
- Figure 6.14. ROC curves of MMEp predictions for JJA/DJF temperature (a, c) and precipitation (b, d) based on GAUS method. ----- 175
- Figure 6.15. Same as Figure 6.14, except for Reliability diagrams ----- 176
- Figure 6.16. The aggregated ROC score over globe for different threshold of extreme temperature. Threshold is upper a) 10%, b) 15% and c) 20% from climatological distribution. Dashed line indicates the aggregated ROC score of tercile forecast (above normal). ----- 177
- Figure 6.17. Same as Figure 6.16, except for precipitation. ----- 178

1. 연구 배경

최근 전 세계적으로 기후예측정보의 제공은 계절규모에 국한하지 않고, 계절내에서 수십년에 이르기까지 그 시간규모를 확장하고자 하며, 이와 더불어 사용자 중심의 가치가 부가된 기후예측정보에 대한 수요가 점차 커지고 있다. 지난 10여 년간 APEC(Asia-Pacific Economic Cooperation) 기후센터(APEC Climate Center, APCC)는 현업적인 측면에서 많은 발전을 이뤄왔다(그림 1.1). 특히 연구 및 현업적인 목적으로 다중모델앙상블(Multi-Model Ensemble, MME) 예측기술 개발에 끊임없는 노력을 기울인 결과 현재 다양한 MME 기법을 활용한 결정론적/확률론적 예측정보를 생산하고 있다(Min et al. 2014). 또한 한국 및 미국형 모델에 의존해오던 설립 초기에 비해 현재는 이탈리아, 영국 등 유럽형 모델들이 참여하면서 참여모델의 다양화를 이뤘으며 이는 참여모델 및 앙상블 수의 증가뿐만 아니라 MME 예측력 향상에도 기여하였다(그림 1.2). 예측정보 제공 측면에서 살펴보면, 년 4회에서 12회로 예측빈도가 증가했으며 최근 들어 APEC 회원국의 요구 및 기후정보 활용성 제고를 위해 2013년 9월부터 기후예측시스템을 3개월에서 6개월로 확대 운영하면서 예측력이 높은 대기-해양 접합모델을 활용하여 해수면 온도(Sea Surface Temperature, SST) 및 엘니뇨-남방진동(El Niño-Southern Oscillation, ENSO) 정보를 제공하면서 예측정보 다양화에 노력을 기울였다. 이러한 노력은 기후예측뿐만 아니라, 기후감시 및 검증에서도 찾아볼 수 있다. 그 결과 APCC는 현재 10개국 16개 기관의 예측정보를 통합함으로써 전 세계적으로 가장 다양한 예측모델의 정보를 활용한 MME 예측시스템을 현업으로 운영 중이며, 예측력 또한 세계 유수 현업기관에 비해 다소 우위를 확보하고 있다(표 1.1).

그간 센터에서는 진단 연구 또는 MME 및 극한기후 예측기술 개발이라는 이름으로 상당히 많은 연구가 개별적으로 진행되어 왔으며 그 성과 또한 연구적인 측면에서 인정을 받아왔다. 하지만 이러한 연구가 시험운영(test-bed)을 거쳐 현업으로 안정화되어 기후서비스로 성장(Research-to-Operation, R2O) 하기까지는 제약과 한계가 많았던 것이 사실이다. 이는 실제 현업으로 연결된 연구가 현재까지 단 4건밖에 없는 것을 통해서도 확인할 수 있으며(Kug et al. 2008; Kang et al. 2009; Min et al. 2009; Kim et al. 2017a), 그 결과 현재 홈페이지를 통해 APCC에서 제공하고 있는 예측정보의 종류 또한 상당히 제한적이다. 따라서 본 연구에서는 팀 차원에서 계절예측정보 생산을

위한 콘텐츠 발굴부터 예측기술 개발, 예측시스템 구축 및 운영까지 통합적이고 유기적인 시스템 개발이 절실히 필요함을 느끼며 기존에 개별적으로 진행되어 왔던 연구들을 R2O로 전환하는 업무를 추진하고자 한다. 이는 APCC 기후서비스 다양화를 위한 노력의 일환으로 APCC 미션에도 부합하는 과제라 할 수 있다. 또한 최근 MME를 활용한 계절예측정보를 생산하는 현업기관의 수가 점차 늘어나고 있으며(예, NMME¹⁾, WMO LC-LRFMME²⁾ 등) 또한 MME 참여 모델들이 대부분 중복되는 이 시점에서 세계 우수 현업기관들과의 경쟁에서 APCC의 우위확보를 위해 사용자 중심의 새로운 콘텐츠 발굴 및 예측기술 개발이 절실히 필요하다고 판단된다. 따라서 본 과제의 최종 목표는 다양한 계절예측정보 제공을 위해 APCC 현업에 적합한 콘텐츠 발굴, 예측기술 개발 및 안정적인 시스템 운영(현업화)이다.




Figure 1.1. Flow chart for the development and improvement of APCC operational monitoring, prediction, and verification systems.

1) North American Multi-Model Ensemble

2) World Meteorological Organization Lead Centre for Long-Range Forecast Multi-Model Ensemble




Figure 1.2. Anomaly Pattern Correlation Coefficients (PCCs) of (a) global 3-month mean (seasonal) temperature at 850hPa and (b) precipitation forecast from the APCC MME prediction system in each year (2008–2016) for the hindcast period of 1983–2005. The relative skill difference is calculated as the skill difference between the recent 3-year mean PCCs (2014–2016) and the first 3-year mean PCCs (2008–2011), divided by the recent the first 3-year mean ones, given a variable and season (%).

Table 1.1. Relative Operating Characteristic (ROC) scores for global 3-month mean tercile-based categorical probabilistic forecasts of precipitation from APCC and other operational centers providing seasonal forecasts for the period 2012–2015. For each category, the highest skill result among the all centers is shown in table in bold.

	APCC	WMO LC-LRF	ECMWF ^a	NCEP ^b	UKMO ^c	JMA ^d
Above-Normal	0.58	0.55	0.54	0.54	0.53	0.54
Near-Normal	0.52	0.52	0.54	0.52	0.52	0.52
Below-Normal	0.57	0.54	0.54	0.54	0.52	0.54

^a European Center for Medium-Range Weather Forecast

^b National Centers for Environmental Prediction

^c United Kingdom Met Office

^d Japan Meteorological Administration

2. 세계 우수현업기관 현황 및 선행 연구 리뷰

우선 MME를 활용하여 계절예측정보를 제공하고 있는 세계 우수현업기관의 현황을 파악하고 센터 내 기존에 진행되었던 연구들에 대한 종합적인 리뷰를 통해 타 기관과의 차별성을 고려하여 APCC 현업에 적용 가능한 콘텐츠를 발굴하고자 한다. 단 기관별로 설립 목적 및 성격이 상이한 점을 감안하여 본 연구에서는 계절예측 측면을 중심으로 고려하였다. 하지만 최근 계절 예측정보 뿐만 아니라 그로 인해 발생하는 사회·경제적 영향을 포함한 고부가가치의 정보 제공에 대한 필요성 및 요구가 전 세계적으로 확산되고 있는 점 또한 고려하여 계절예측정보에서 더 나아가 사용자에게 보다 유용한 예측정보 제공에 대한 현황 또한 포함하였다.

2.1 국외 현황

2.1.1 북미지역 다중모델앙상블(NMME)

NOAA(National Oceanic and Atmospheric Administration) CTB(Climate Test-Bed) 연구과제로 시작된 NMME는 북미지역 현업기관에서 개발한 기후모델을 활용한 MME 기후예측시스템을 2001년 시험 운영하면서 hindcast 및 실시간 예측정보를 제공하기 시작했다(Kirtman et al. 2014). 안정적인 현업을 위해 4년 이상의 R2O 과정을 거쳐 2015년 최종적으로 현업화가 되었고, 매월 NOAA CPC(Climate Prediction Center) 현업 스케줄에 맞춰 CPC³⁾와 NCAR⁴⁾(National Center for Atmospheric Research) 자료 서버를 통해 그래픽 및 디지털 형태로 예측정보를 제공하고 있다. 2017년 현재 실시간 예측정보를 제공하고 있는 모델은 7개 모델이며(표 2.1), NMME 홈페이지를 통해 제공되고 있는 예측정보는 표 2.2와 같다. 여기서 주목할 점은 예측정보 중 “experimental” 또는 “preliminary”라는 이름으로 현업 전 R2O 단계에서 최상의 기후정보 서비스를 위한 시간과 노력이 투자되고 있음을 확인할 수 있다.

3) <http://www.cpc.ncep.noaa.gov/products/NMME/about.html>

4) <https://www.earthsystemgrid.org/search.html?Project=NMME>

Table 2.1. Description of participating models in NMME real-time forecast.

Model	Hindcast Period	No. of Ensemble	Lead	Reference
NCEP/CFSv2 ^a	1982–2010	24 (28)	0–9	Saha et al. (2014)
GFDL/CM2.1 ^b	1982–2010	10	0–11	Delworth (2006)
GFDL/CM2.5	1982–present	24	0–11	Vecchi et al. (2014)
NCAR/CCSM ^c	1982–2010	6	0–11	Kirtman and Min (2009)
CMC/CANCM3 ^d	1981–2010	10	0–11	Merryfield et al. (2013)
CMC/CANCM4	1981–2010	10	0–11	Merryfield et al. (2013)
NASA/GEOS5 ^e	1981–2010	11	0–9	Vernieres et al. (2012)

^a Climate Forecast System version 2^b Geophysical Fluid Dynamics Laboratory/Climate Modeling version 2.1^c Community Climate System Model^d Canadian Meteorological Centre/Canadian Coupled Model version 3^e National Aeronautics and Space Administration/Goddard Earth Observing System Model version 5Table 2.2. Climate services disseminated by NMME (<http://www.cpc.ncep.noaa.gov/products/NMME/>).

Contents	Information
Lead Time	7-month (4-season) lead for monthly mean (3-month mean)
Variable	SST, Global T/P, US T/P and Nino 3.4 Plume (*Additional variable: Z500, Global Tmax/Tmin, US Tmax/Tmin/soilm/runoff)
Form	Deterministic (anomaly map) and **probabilistic (probability map) forecast by model, NMME and IMME
Verification	Hindcast: ACC and RPSS map Real-time forecast: comparison with the observed anomaly map

* Preview / ** Preliminary

현재 다양한 분야에서 NMME 자료를 활용하여 많은 연구가 진행되고 있으며⁵⁾, NMME가 준현업으로 예측정보를 제공하기 시작한 초창기에는 개별 모델 및 NMME의 예측력 검증 또는 NMME 예측시스템 개발에 관한 연구가 주로 이루어진 반면, 현재는 태풍, ENSO, 가뭄 등과 같은 좀 더 다양하고 유용한 예측정보 제공을 위해 자료 분석을 통한 예측력 평가(Appendix 1) 및 예측기술 개발(Appendix 2)에 관한 연구가 활발히 진행되고 있다. 또한 현재 홈페이지를 통해 제공되고 있는 대부분의 정보는 월별 또는

5) http://www.nws.noaa.gov/ost/CTB/nmme_pub.htm

3개월 평균장(계절평균)에 국한되어 있지만 참여모델에 대한 일자료(hindcast 및 실시간 예측자료)가 구축되어 있어 전구 및 북미 지역에 대해서는 우선적으로 일 최고/최저 기온, 토양수분, 유출량 등을 제공하고 있다⁶⁾. 최근 계절 내 규모에 대한 NMME 그룹의 연구 또한 활발히 진행 중인 점을 감안하면 다양한 분야에 적용 가능한 고부가가치 예측 정보 제공을 위한 노력을 이미 시작했음을 확인 할 수 있다. 한 예로, NOAA CPC에서는 현재 NMME에서 제공하고 있는 북미지역의 일자료를 활용하여 다양한 정보(CPC 기온/강수전망, NCEP/CFS 장기예측정보, NCEP과 ECMWF의 단기예측정보, U.S. Drought Monitor(USDM)⁷⁾로부터의 가뭄 현재 상태 등)들과 통합하여 최종적으로 북미 지역에 대한 월/계절가뭄 전망을 제공하고 있다⁸⁾(Huang 2016).

2.1.2 국제 기후·사회 연구소(IRI)

IRI(International Research Institute for Climate and Society)는 1997년 이후 대기대순환모델들(ECHAM4.5, CCM3.6, GFDL, COLA)을 활용한 전지구 평균 기온 및 강수에 대한 MME 계절예측정보를 제공해오면서(2001년부터는 매월 예측정보 제공, Net Assessments로 명명) 계절예측정보 제공에 있어서 가장 긴 역사를 가지고 있다. 하지만 현재 대부분의 현업기관에서 예측력이 높은 대기-해양 접합모델로 자체모델을 개선하거나 또는 대기-해양 접합모델로 차세대 모델을 개발하는 노력을 기울이고 있는 현 시점에서 대기대순환모델들만 활용하는데 있어서는 어느 정도 한계점이 있었다. 이러한 한계점을 극복하고자하는 노력을 기울인 결과, 2017년 4월부터 NMME에 참여 하고 있는 대기-해양 접합모델들을 활용하여 MME 예측정보를 제공하고 있다. 계절예측과 관련하여 IRI 홈페이지를 통해 현재 제공되고 있는 예측정보는 Net Assessments, ENSO, 개별모델의 예측정보, 사용자 중심의 기후정보 tool로 크게 나눌 수 있다(표 2.3). Net Assessments는 앞서 설명한 바와 같이 전지구 평균 기온 및 강수에 대해 3개의 카테고리에(평년보다 높음/비슷/낮음)대한 예측 확률을 제공하고 있으며, 예측정보에 대한 검증정보까지 포함하고 있다. 또한, 사용자 편의에 따라 percentiles(예, 상/

6) http://www.cpc.ncep.noaa.gov/products/NMME/model_seasonom_plus.shtml

7) USDM은 1999년 3개의 기관(NOAA CPC, National Drought Mitigation Center, U.S. Department of Agriculture)에 의해 만들어졌으며, 북미 지역에 대한 가뭄 상태를 주별로 모니터링하고 있음. 현재 NIDIS(National Integrated Drought Information System) 홈페이지를 통해 가뭄 모니터링 및 전망자료를 확인할 수 있음(<http://drought.gov>).

8) http://www.cpc.ncep.noaa.gov/products/expert_assessment/sdo_summary.php

하위 20/15/10/5%) 또는 특정 임계값(예, 기온 20℃ 이상)에 대한 확률예측정보를 제공하고 있다.

Table 2.3. Climate services disseminated by IRI (http://iri.columbia.edu/our-expertise/climate/forecasts/#GCM_and_SST_Forecast_Model_Outputs)

Contents	Information
Seasonal Climate Forecasts	- Tercile probabilistic outlooks and verification information for T and P - Flexible seasonal forecast for T and P (e.g., upper/lower percentiles or specific threshold)
ENSO Forecasts	- Probabilistic ENSO forecast for El Nino, Neutral, or La Nina - Plume of ENSO model predictions - ENSO rainfall teleconnection maps
GCM and SST Forecast Model Outputs	- Dynamical climate predictions with different individual models
Tailored Climate Products	- US-Mexico drought prediction maps, international federation of Red Cross and Red Crescent Societies maps, climate and agriculture maps, selection of a point climatology

IRI 예측정보 중 가장 주목할 점은 바로 ENSO 예측정보라고 할 수 있다. 세계 유수현업기관 및 연구기관에서 제공하는 다양한 역학/통계모델의 Nino 3.4 지수를 수집하여 Plume(그림 2.1a) 및 카테고리에 대한 확률값(그림 2.1b)으로 최대 9개월까지의 계절 평균 ENSO 예측정보를 제공하고 있다. 또한 NOAA CPC의 ENSO 예측정보와 통합하여 최종적으로 매월 중순경 CPC/IRI 공동으로 매월 ENSO 예측정보를 제공하고 있다. IRI는 현재 가장 다양한 종류의 ENSO 예측정보를 수집하고 있으며, 특히 MME 정보를 활용하여 엘니뇨/중립/라니냐에 대한 확률예측정보를 제공하고 있는 유일한 기관으로 기후뿐만 아니라 다양한 응용분야에서도 참고자료로 널리 활용 되고 있다.

IRI는 보건, 수자원, 농업 및 재해 관리 부분 전문가와 긴밀히 협력하여 기후정보가 의사 결정 및 정책 수립 등에 활용될 수 있도록 많은 노력을 기울여 왔으며, 그 결과 사용자 중심의 기후정보 tool을 통해 tailored climate products를 제공하고 있다(표 2.3). 특히, 현재 NMME에서 제공하고 있는 전구 월평균 강수예측정보 및 관측으로부터 초기 조건을 활용하여 멕시코 및 북미 지역에 대한 3/6/9/12개월 Standardized Precipitation Index(SPI) 예측정보를 전구가뭍예측 tool을 활용하여 제공하고 있으며), 사용자는 지

역, SPI 기간 및 임계값, 예측 선행시간 선택이 가능하며 선택된 임계값에 대한 SPI 카테고리화에 대한 발생확률을 제공 한다(그림 2.2; Lyon et al. 2012; Quan et al. 2012). 또한 국제 적십자와 협력하여 IRI에서 개발한 Maproom은 인도주의적 의사결정에 활용 되는 기상/기후 예측정보를 제공하고 있으며, 취약성 정보를 포함한 조기행동 유형에 대한 정보도 함께 제공하고 있다는 점에서 기후정보를 활용한 융합연구 관점에서 선두적인 역할을 해오고 있다고 할 수 있다.





Figure 2.1. (a) ENSO Plume prediction and (b) ENSO 3-categorical probabilistic MME forecasts issued by IRI and NOAA/CPC.



Forecast Probability of SPI Being below Selected SPI Threshold for Mar 2017 Issued at the End of Feb 2017

Figure 2.2. Forecast probability of SPI below selected SPI threshold for Mar. 2017 issued at the end of Feb. 2017.

2.1.3 유럽중기예보센터(ECMWF)

ECMWF에서는 System4라고 불리는 해양-대기모델을 이용하여 매달 6개월 예측자료를 생산하여 홈페이지를 통해 공간분포와 열대 폭풍우(tropical storm) 분포, 월별 편차 시계열, Nino Plume을 제공하고 있다¹⁰⁾. 그러나 대부분은 특정 사용자들에게만 제공되고, 일반 사용자에게는 기본 변수(예, 기온, 강수, 해면기압 등)에 대한 공간분포(유럽지역 중심) 만이 공개된다. 예측정보는 앙상블 평균뿐만 아니라 3개 카테고리에 대한 확률예측정보 및 다양한 임계값(예, 중앙값, 상/하위 20%)에 대한 확률예측정보를 제공하여 사용자가 필요에 따라 선택하여 표출 할 수 있다.

ECMWF는 DEMETER(Development of a European Multimodel Ensemble System for seasonal to inTERannual prediction, Palmer et al. 2014)와 ENSEMBLE(ENSEMBLE-based Predictions of Climate Change and their IMPactS, Weisheimer et al. 2009) 2개의 프로젝트로부터 발전되어 온 EUROSIP MME 계절예측시스템을 현업으로 운영하고 있다. EUROSIP 예측정보는 기본적으로 ECMWF 예측정보와 형태가 동일하며(표 2.4), 일반 사용자에게는 제한적으로 제공되고 있다. 초반에는 유럽기관(ECMWF, Met Office, Meteo-France)의 예측자료만을 이용하였으나, 2012년 9월 NCEP이 추가되었고, 최근에는 JMA가 추가되어 참여모델의 폭이 넓어졌다(표 2.5).

유럽에서는 계절예측정보 제공에서 한발 더 나아가 사회·경제적 영향을 포함한 정보를 제공하기 위한 고부가가치 예측정보(즉, 영향예보¹¹⁾)에 대한 중요성을 인식하고 국제적인 협력을 통한 연구/개발에 대한 노력을 기울였다. 그 결과, 2012년 11월부터 유럽연합집행위원회 자금을 지원받아 영국기상청을 중심으로 24개의 파트너 기관(그림 2.3)이 협력하여 EUPORIAS(European Provision Of Regional Impact Assessment on a Seasonal-to-decadal timescale) 공동 프로젝트를 수행하였다. EUPORIAS는 계절예측 정보 제공자와 정책결정자들이 함께 참여하여, 서로간의 긴밀한 협력과 이해를 통해 인터페이스를 개발하고, 궁극적으로 기후변화에 대한 사회적으로 유용성 개선을 목적으로 하였으며, 최종적으로 5개 분야(에너지, 교통, 농업, 보건, 수자원)에 대한 현업 측

10) <https://www.ecmwf.int/en/forecasts>

11) 기상/기후 현상으로 인해 예상되는 사회·경제적 영향 및 취약성을 고려하여 과학적인 자료를 바탕으로 상세한 기상/기후 정보와 함께 전달하는 예보를 뜻함.

면의 프로토타입을 개발하였다(<http://www.euporias.eu/prototypes>). 하지만 현재의 영향예보는 대부분 재해 대응에 초점을 두어 시간규모가 짧은 기상학적 관점에서 생산되고 있으며, 현재 미국 및 영국에서 현업으로 제공하고 있는 영향예보에 대한 자세한 설명은 Appendix 3을 참고하길 바란다.

Table 2.4. EUROSIP Climate services disseminated by ECMWF (<https://www.ecmwf.int/en/forecasts/charts/seasonal/>)

Contents	Information
*Spatial Maps	Spatial maps of model probabilities stratified by terciles (Variable: T, P, SLP, SST, T850 and Z500)
*Nino Plumes	Nino 3, Nino 3.4 and Nino 4
Tropical Storm Forecast	6-month Forecasts of tropical storm frequency and mean location of tropical storm genesis valid (Note that the tropical storm forecasts are created using data from ECMWF and Meteo France systems only.)

* Public Chart

Table 2.5. Description of participating models in EUROSIP.

Model	Forecast Ensemble	Hindcast Ensemble	Hindcast Period
ECMWF	51	15	1981-2010
Met Office	42	12	1996-2009
Meteo-France	51	15	1991-2010
NCEP	52	12	1982-2010
JMA	51	10	1981-2015



Figure 2.3. EUPORIAS partnership (<https://www.metoffice.gov.uk/research/collaboration/euporias>).

2.1.4 세계기상기구 장기예보 선도센터(WMO LC-LRF)

WMO LC-LRF(이하, 선도센터)는 12개 국가의 장기예보 결과를 공유하고 MME 기후 예측시스템을 개발하기 위한 목적으로 설립되었으며, 2005년 GPC(Global Producing Centre) 회의에서 선도센터의 필요성이 제안되었고, 여러 국제회의를 거쳐 2009년부터 한국 기상청과 미국 기상청이 공동 운영해오고 있다. APCC는 선도센터의 연구 개발을 지원하는 역할을 현재 수행하고 있다¹²⁾. 선도센터에서는 매달 3개월 예측자료를 생산하여 홈페이지를 통해 디지털 및 그래픽 형태로 예측자료를 제공하고 있으며 이러한 선도센터의 예측자료는 GPC(표 2.6), RCOF(Regional Climate Outlook Forum) 관련 기관, 각국 기상청 등 특정한 사용자들에게만 제공되고 있다.

Table 2.6. Description of participating models in WMO LC-LRF.

GPC	Forecast Ensemble	Hindcast Ensemble	Hindcast Period
Beijing	24	24	1991-2010
CPTEC	15	10	1979-2010
ECMWF	41	15	1981-2010
Exeter	42	28	1993-2015
Melbourne	33	99	1981-2011
Montreal	20	20	1981-2010
Moscow	20	10	1986-2010
Pretoria	40	10	1982-2009
Seoul	42	12	1991-2010
Tokyo	51	10	1981-2010
Toulouse	41	11	1991-2014
Washington	40	20	1982-2010

초창기에는 결정론적 3개월 MME 및 개별모델 예측자료만이 제공되었고, 2011년에 APCC 확률론적 MME 예측시스템(Min et al. 2009)이 도입되어 현재까지 3개월 확률론적 MME 예측자료와 함께 개별모델의 확률예측자료도 제공되고 있다(Kim et al. 2015). 2014년 결정론적 MME 중 단순평균 기법에 한해 예측시작월과 예측기간(1~6개

12) <https://www.ecmwf.int/sites/default/files/elibrary/2015/14501-wmo-lead-centre-activities-global-sub-seasonal-mme-prediction.pdf>

월)을 사용자가 선택할 수 있도록 하여 편의성을 높였으며, 공간분포로 제공되는 예측자료는 모두 사용자가 원하는 영역을 직접 선택할 수 있다. 현재는 예측자료 뿐만 아니라 MME와 개별모델에 대한 hindcast 검증결과와 실시간 예측검증결과도 홈페이지를 통해 제공되고 있다(표 2.7).

Table 2.7. Climate services disseminated by WMO LC-LRF (<https://www.wmolc.org>).

Contents	Information
Spatial Maps	- 3-month 4 deterministic and tercile-based probabilistic MME - Individual forecast anomaly and tercile-based probabilistic forecast - Consistency map (T, P, SLP, T850, Z500 and SST)
Nino Plumes	Nino 3.4
Time-series	Time-series of monthly mean anomalies for each individual forecast (T, P, SLP, T850, Z500 and SST) AO, PNA, SOI, NOI, WNPMMI, IMI, EAMI, EAWMI, WYI and RM2

2.2 센터 내 선행 연구

그간 센터에서는 연구 및 현업 목적으로 계절예측측면에서 진단/예측력 평가 또는 예측기술 개발과 관련하여 많은 연구들이 수행되어 왔다(표 2.8). 우선, MME 예측기술개발과 관련하여 살펴보면, 여러 가지 통계적 기법을 활용하여 MME 기법개발에 노력을 기울인 결과 순차적 패턴 투영기법을 활용한 결정론적 MME 기법(step-wise pattern projection method, SPM; Kug et al. 2008)과 다중모델앙상블 확률예측기법(probabilistic multi-model ensemble, PMME; Min et al. 2009)은 현재 APCC 현업으로 운영 중이며, 특히 PMME는 앞서 선도센터에서 설명한 바와 같이 2009년부터 세계기상기구 장기예보 표준 확률예측기법으로 선정되어 선도센터 홈페이지를 통해 예측정보를 제공하고 있다. 이 외에도 climate filter(Lee et al. 2011) 및 통계적 상세화 기법을 활용한 다양한 MME 기법들이 개발(예, Kang et al. 2009; Kim 2016; Kryjov 2016) 되어 기존의 단순평균 또는 전구예측정보에 비해 향상된 예측력을 보이긴 했지만 연구적인 측면에서 특정 지역 및 특정 계절에 대한 예측력 평가로만 그쳐 현업으로 발전하지는 못했다.

설립초기에는 MME 자체의 기술 개발에 많은 노력을 기울였으나, 최근 들어서는

APCC MME 예측력 평가(Min et al. 2014; Sohn et al. 2016; Min et al. 2017) 및 MME 기후예측자료를 활용한 가뭄, 태풍, 몬순, 폭염 등 극한 기후에 대한 연구들이 진행되고 있다(예, Lee 2015; Sohn et al. 2016; Kim et al. 2017a). 특히, 동아시아 겨울몬순(East Asia Winter Monsoon, EAWM) 관련 연구들이 많이 있었으며, Sohn et al. (2011)과 Shin (2015)은 APCC 참여모델 및 MME에 대한 EAWM 예측력을 종합적으로 평가함으로써 EAWM 예측에 있어서 현재 기후예측기술의 수준 및 한계점을 분석하였다. 한발 더 나아가 Kim et al. (2017b)은 hindcast 자료를 활용하여 동아시아 겨울철 기온의 변동을 대표할 수 있는 새로운 EAWM 지수를 개발하였으나, 실제 예측까지 적용하지는 못했다. 가뭄의 경우, 최근 Sohn and Tam (2016)은 한반도 겨울철-봄철 기온 및 강수 특징을 고려한 MME 기후예측 자료의 가뭄 재현성을 연구, 향후 가뭄 예측에 대한 가능성을 평가하였다.

2.3 콘텐츠 발굴

지난 10여 년 동안 APCC는 개별모델/MME 예측력 평가 및 예측기술 개발, MME 자료를 활용한 극한기후 예측에 대한 많은 연구적인 성과에도 불구하고 앞서 세계유수현업기관의 계절예측정보 현황을 비교해보면, 현재 APCC 홈페이지를 통해 제공되고 있는 예측정보는 상당히 제한적임을 확인할 수 있다. 따라서, 본 연구에서는 국외 현업기관의 현황분석과 센터 내 선행연구들에 대한 종합적인 리뷰를 통해 현재 **APCC 자료의 가용성** (월 평균 자료), **내부 역량**, **타 기관과의 차별성** 등을 고려하여 아래와 같이 4개의 콘텐츠를 1차적으로 선정하였다. 다년도 과제로 제안된 본 연구의 1차 년도(2017년) 연구 목표는 새로운 콘텐츠 생산을 위한 사전 연구로서 개별모델 및 MME 예측성을 우선 평가하고, APCC 현업에 적합한 콘텐츠를 선정하여 2차 년도에는 예측시스템을 구축하여 안정적인 현업 운영을 목표로 한다. 다음 3-6장에서는 각 콘텐츠에 대한 예측력 평가 및 예측기술 개발 내용을 포함한다.

- (1) ENSO 종류(엘니뇨/중립/라니냐) 및 강도(강/중/약 엘니뇨 및 라니냐)
- (2) 전구적인 관점의 3개월 이상의 장기 가뭄
- (3) 동아시아 겨울몬순 지수
- (4) 상/하위 15% 초과하는 기온 및 강수 극한기후

Table 2.8. Summary of researches related to development/improvement of MME techniques, data analyses and application, and predictability for seasonal forecasts.

Development	Contents	Reference
MME	Deterministic MME method: SPM	Kug et al. (2008)*
	Deterministic MME method: climate filter	Lee et al. (2011)
	Probabilistic MME method: non-calibration	Min et al. (2009)*
Statistical Downscaling	Deterministic method for Korea T and P	Kang et al. (2009)*
	Deterministic method for Korea summer P	Kim (2016)
	Deterministic method for Korea spring T	Kryjov (2016)
	Probabilistic method for Korea T and P	Min et al. (2011)
	Probabilistic method for Asia Summer monsoon P	Sohn et al. (2012b)
Extreme Diagnostic	Drought for Korea	Sohn and Tam (2016)
	Dynamical-statistical prediction method for WNP typhoons	Kim et al. (2017a)*
	Predictability of East Asian winter climate variability	Sohn et al (2011)
	Predictability of the EAWM	Shin (2015)
	Development of a new index of EAWM	Kim et al (2017b)
	Heat wave in Korea	Lee (2015)
Predictability	Assessment of different MME prediction systems	Min et al. (2014)
	Real-time operational MME forecast for 2008–15	Min et al. (2017)
	Different ENSO flavors	Sohn et al. (2016)
	APCC 6-month MME SST prediction	Jeong et al. (2012)

* Operationally implemented at APCC

3. ENSO 종류/강도 확률예측기술 개발

3.1 서론

ENSO는 열대 태평양 대기-해양 상호작용의 대표적인 현상이며, 이와 관련된 열대 열원의 시-공간적인 변동은 전지구적인 기후와 생태계, 더 나아가 많은 국가들의 사회경제활동에까지 영향을 미치는 중요한 기후 요인 중 하나이다(Trenberth et al. 1998; Bradly et al. 1987; Ropelewski and Halpert 1987, 1989). 특히, ENSO의 강도가 강할수록 극한 기상·기후 현상(예, 호우, 가뭄, 태풍 등)의 발생 빈도 및 심각성은 크게 나타난다(Lyon 2004; Lyon and Barnston 2005; Hoell et al. 2016). 즉, 강한 엘니뇨/라니냐에 의해 야기되는 피해는 전지구적으로 엄청난 인명과 재산을 앓아가며, 20세기 최대의 엘니뇨라 불리는 82/83의 경우, 2000여명의 생명과 134억 달러의 재산피해가 발생하기도 하였다. 이와 같이 ENSO 발생에 따른 전지구적인 영향력을 고려했을 때, 엘니뇨/라니냐 발생여부 자체에 대한 예측정보도 중요하지만 강도에 대한 예측정보가 절실히 요구되는 부분이다. 또한, 역학모형을 활용한 계절예측에 있어서 ENSO 변동은 중·장기 계절예측의 중요한 원천으로 알려져 있다(Wang et al. 2009a; Barnston et al. 2010).

이러한 ENSO 현상에 대한 관심 및 예측에 대한 중요성이 점차 커지면서 현재 대부분의 현업기관에서는 적도태평양의 SST 및 ENSO에 대한 지속적인 감시 및 예측정보를 제공하고 있다(예, JMA, IRI, NCEP, KMA¹³⁾, BOM¹⁴⁾, NMME 등). 현재 대부분의 현업기관에서 제공하고 있는 ENSO 예측정보는 Plume 형태의 결정론적(혹은 정량적) 정보가 대부분이다. 하지만 기후시스템 자체의 무질서(chaotic) 및 역학 모델이 가진 불완전성(예, 불완전한 초기조건) 때문에 예측정보는 불확실성(uncertainty)이 존재하며(Curry and Webster 2011; Knutti 2010; Slingo and Palmer 2011), 이를 정량화하는 것은 기후예측에 있어서 아주 중요한 부분이다(Palmer 2000). 예측이 가지는 불확실성에 관한 정보는 사용자들이 합리적인 의사결정을 하는데 도움을 주며, 이는 상당한 경제적 가치를 도출하기도 한다. 따라서 기존의 결정론적 예측정보와 함께 사용자에게

13) Korea Meteorological Administration

14) Australian Government Bureau of Meteorology

유용한 불확실성에 대한 정보를 함께 제공할 수 있는 확률예측기법의 중요성 또한 점차 부각되고 있다.

현재 ENSO 예측에 있어서 유일하게 IRI와 NOAA/CPC에서 공동으로(편의를 위해, IRI/CPC로 명명) ENSO 종류(또는 위상)에 대한 MME 카테고리별 확률예측정보(즉, 엘니뇨/중립/라니냐)를 제공하고 있다. 이는 국제협력을 통해 2002년부터 다양한 현업기관 및 연구기관으로부터 매일 역학모델 및 통계모델에서 예측한 ENSO 예측정보(Nino 3.4 지수 편차 값)를 제공받고 있으며, 현재 전세계적으로 가장 많은 통계 및 역학모델들이 참여하고 있는 ENSO 예측정보이다. 하지만 Barnston et al. (2015) 언급한 바와 같이, 이는 ENSO Plume을 기반으로 한 확률예측이기 때문에 역학모델 및 통계모델들의 평균에 대한 불확실성(inter-model spread) 정보만 제공할 뿐, 개별 역학모델의 불확실성(ensemble spread) 및 통계모델의 표준오차(standard error)등에 대한 정보는 포함하고 있지 않다. 또한 일부기관에서는 자체적으로 정의한 기후값으로 계산한 Nino 3.4 지수 편차값만 제공하고 있기 때문에, 예측정보들 간의 기후값이 동일하지 않다는 한계점이 있다.

APCC 역시 적도 태평양 SST 및 ENSO 변동성에 대한 감시 및 예측기술 개발에 노력을 기울인 결과, 2009년 9월부터 MME를 활용한 SST 및 ENSO 예측시스템을 준현업으로 운영하였다. 최근 APEC 회원국의 요구 및 기후정보 활용성 제고를 위해 2013년 9월부터 기후예측 다중모델앙상블 시스템을 3개월에서 6개월로 확대 운영하여(Min et al. 2017), 향후 6개월에 대한 SST 및 ENSO 예측정보를 홈페이지를 통해 제공하고 있다¹⁵⁾ (그림 3.1). 하지만 APCC에서 제공하는 SST 및 ENSO 예측정보는 모두 결정론적 형태이며, 그 종류 또한 상당히 제한적이다. 따라서 보다 다양하고 유용한 정보(예, 불확실성을 고려한 확률예측정보) 제공을 위한 새로운 콘텐츠 발굴 및 예측기술 개발이 필요한 현 시점에서, ENSO 종류 뿐만 아니라 강도 예측을 위한 MME 확률예측기술 개발은 시기적절하다고 판단된다. 따라서 본 연구에서는 APCC 6개월 계절예측에 사용 중인 전지구 대기-해양 접합모델을 활용하여 APCC 현업에 적합한 ENSO 카테고리별 확률예측기법을 개발하고자 한다. 이는 ENSO 종류(엘니뇨/중립/라니냐)에 따른 발생확률 뿐만 아니라, 현재 그 어느 현업기관에서도 제공하고 있지 않는 ENSO 강도(강/중/약 엘니

15) <http://www.apcc21.org/ser/enso.do?lang=en>

노 및 라니냐)에 따른 확률예측정보도 포함한다.




Figure 3.1. (a) Spatial distribution of SST MME forecast anomaly for 2014DJF and (b) Nino 3.4 index forecast for 2014SONDJF from individual models and MME prediction issued on November 2014 at APCC.

3.2 자료 및 분석 방법

3.2.1 관측 및 모델자료

ENSO 종류 및 강도에 대한 카테고리별 확률예측기법 개발을 위해 본 연구에 사용된 모델은 현재 APCC 6개월 MME 예측에 참여하고 있는 모델(CMCC¹⁶⁾, CANCM3, CANCM4, NASA, NCEP, PNU¹⁷⁾, POAMA¹⁸⁾)과 2017년 하반기부터 현업으로 참여하게 될 APCC 모델인 SCoPS(Seamless Coupled Prediction System)까지 총 8개 대기-해양 접합모델이다(표 3.1). 모델별로 앙상블 수는 서로 상이하며(5-33개), 본 연구에서는 확률예측기법 개발을 위해 각 앙상블 멤버를 모두 활용하였고, 개별모델이 가지는 서로 다른 해상도를 2.5° x 2.5° 동일한 해상도로 내삽하여 분석하였다. 다양한 모

16) The Euro-Mediterranean Center on Climate Change

17) Pusan National University

18) Predictive Ocean Atmosphere Model for Australia

텔을 활용한 MME 연구를 수행할 때 참여모델의 공통기간에 대해서 분석하는 것이 일반적이지만, 본 연구의 특성상 좀 더 다양한 ENSO 경우(특히, 강도에 대한 엘니뇨/라니냐 수)를 포함하기 위해 1982-2010년까지 총 29년에 대한 월별 6개월 예측정보를 활용하였다. 즉, 1982년 1월의 경우 NCEP, POAMA, SCoPS 자료를 제외한 5개 모델을 활용했으며, 2006-2010년에 대해서는 CMCC 모델을 제외한 7개 모델로 MME 예측정보를 생산하였다. 하지만 이런 몇몇의 경우를 제외하고는 대부분 모델들은 29년 분석기간을 포함한다. 또한, 개발된 ENSO 종류 및 강도 확률예측기법을 실시간예측(real-time forecast) 적용을 위해 사용된 자료는 2013-2016년 기간동안 모든 계절에 대해 6개월 예측자료를 포함하고 있는 5개 모델(CANCM3, CANCM4, NASA, NCEP, POAMA)만을 활용하였다. 참고로, 캐나다 기상청은(MSC¹⁹⁾) 기존에 2개의 대기-해양 접합모델의 자료(CANCM3, CANCM4)를 각각 제공하다 2016년부터 2개의 모델의 예측정보를 하나로 통합하여 MSC로 제공하고 있으며, 본 연구에서는 2016년에 대한 CANCM3와 CANCM4 자료는 MSC로 대체하였다.

APCC 참여모델 중 NCEP의 적도지역 SST에서 나타나는 모델의 계통적 오차(systematic error)는 많은 선행연구를 통해 이미 알려져 있으며(예, Saha et al. 2010; Kirtman et al. 2014; Infanti and Kirtman 2016), 이는 NCEP에서 활용하고 있는 자료동화 및 초기화 기법이 1999년을 기점으로 달라지기 때문이다(Xie et al. 2011; Kumar et al. 2012; Barnston and Tippett 2013). NCEP이 모의한 3개월 평균 Nino 3.4 지수를 1982-2010년까지 살펴보면, 1999년을 기준으로 전반기에는 관측에 비해 차갑게 모의하는 경향(cold bias)이, 후반기에는 관측보다 따뜻하게 모의하는 경향(warm bias)이 두드러지게 나타난다(그림 3.2a; NCEP). 이러한 문제를 극복하기 위해 Tippett et al. (2017)과 Barnston et al. (2017)는 1999년을 기준으로 2개의 기후값(1982-1998, 1999-2010; NCEP_2c)을 사용하여 각 기간에 대한 편차를 계산하는 방법을 제안했으며, 동일한 방법을 적용해 본 결과 그림 3.2b에서 나타나는 바와 같이 1999년을 기준으로 나타났던 cold/warm bias가 어느 정도 해결이 되는 것을 확인할 수 있다. 그 결과, 1982-2010년 기간 동안 3개월 평균 Nino 3.4 지수 예측력은 0.83(NCEP) → 0.91(NCEP_2c)로 크게 향상되었다. 따라서 본 연구에서는 2개의 기후값을 활용하여 NCEP의 계통적 오차를 제거한 NCEP_2c 자료를 활용하였으며, 다른

19) Meterological Service of Cadana

모델과의 통일성을 위해 앞으로는 NCEP_2c를 NCEP으로 표기하도록 한다.

예측정보를 검증하기 위해 사용된 관측자료는 미국 해양대기청의 기후진단센터에서 실시간으로 제공되는 최적내삽법을 활용한 해수면온도(Optimum Interpolation SST, OISST; Reynolds et al. 2002)의 월평균 자료이며, 사용된 기간 및 해상도는 모델과 동일한 2.5°격자의 29년 자료(Hindcast 기간)와 2013~2016년(실시간예측 기간) 자료이다. 분석을 위해 모델 및 관측자료는 각각의 기후값에 대한 편차를 이용하였으며, Hindcast 기간의 편차는 예측하고자 하는 해를 제외한 28년의 자료를 활용하여 편차를 계산하였고(leave-one-out cross-validation; Wilks 1995), 실시간 예측에 대해서는 총 29년 자료를 사용하였다. 즉, 모델은 개별모델 자체의 기후값으로 편차를 계산하기 때문에 모델이 가지는 기후값(또는 평균)에 대한 바이어스는 보정된 예측정보이다.

Table 3.1. Description of eight participating models in MME ENSO prediction used in the study.

Model	Organization/ Country	Resolution	Ens. Size (H/F)	Hindcast Period	Reference
CMCC	CMCC/Italy	T63L19	9/9	1982.01–2006.01	Aleesandri et al. (2010)
CANCM3	MSC/Canada	T63L31	10/10 (20 ^a)	1982.01–2010.12	Scinocca et al. (2008)
CANCM4	MSC/Canada	T63L31	10/10 (20 ^a)	1982.01–2010.12	Merryfield et al. (2013)
NASA	NASA/USA	288x181grid L72	11/11	1982.01–2011.12	Molod et al. (2012)
NCEP	NCEP/USA	T62L64	20/20	1982.03–2010.12	Saha et al. (2014)
PNU	PNU/Korea	T41L18	5/5 (3–10 ^b)	1982.01–2014.12	Ahn and Kim (2003)
POAMA	BOM/Australia	T47L17	33/33	1983.01–2011.12	Lim et al. (2012)
SCoPS	APCC/Korea	T159L31	10/10	1982.02–2013.12	Ham et al. (2017)

^a Replaced by MSC with 20-ensemble from 2016

^b Usually 5-ensemble, but sometimes it differs from 3 to 10-ensemble.




Figure 3.2. Errors of the first-lead 3-month mean Nino 3.4 forecast anomaly from the corresponding observation for the period 1982JFM–2010/11DJF. (a) NCEP based on 1982–2010 climatology and (b) NCEP_2c based on two climatologies (1982–1998, 1999–2010).

3.2.2 분석 방법

다중모델앙상블을 활용한 확률예측기법 개발을 위해서는 다음과 같은 사안을 고려해야 한다.

- 각 카테고리를 어떻게 정의할 것인가?
- 각 카테고리에 대한 확률값을 어떻게 추정할 것인가?
- 개별모델의 예측값을 어떻게 합할 것인가?

3.2.2.1 카테고리 정의

현재 세계 유수현업기관마다 ENSO 종류를 정의하는 기준이 상이하며(표 3.2), 이는 과거사례(historical episode)에 대한 기준이다. 하지만 실제 예측에 있어서 몇 개월

이동 평균한 엘니뇨 감시구역 지수가 몇 개월 이상 특정임계값을 초과하는 기간을 포함 하기에는 예측자료가 가진 선행시간의 한계 때문에 연속기간에 대한 기준을 적용하기란 현실적으로 어렵다. 따라서 현재 유일하게 ENSO 종류에 대한 카테고리별 확률예측정보 를 제공하고 있는 IRI/CPC에서도 연속기간(즉, 임계값을 초과하는 경우가 연속 몇 개월 지속될 때)에 대한 기준을 배제하고, 3개월 이동평균 Nino 3.4 지수 편차를 $\pm 0.5^{\circ}\text{C}$ 기준으로 엘니뇨/중립/라니냐로 구별하여 각각의 발생확률을 예측하고 있다.

본 연구에서는 ENSO 종류(3개 카테고리; 엘니뇨/중립/라니냐) 및 강도(7개 카테고리; 강/중/약 엘니뇨 및 라니냐, 중립)를 정의하기 위해 일반적으로 가장 널리 활용되고 있는 엘니뇨 감시구역 3.4 지역의 SST 영역 평균값(5°S - 5°N , 170° - 120°W ; Nino 3.4 지수)을 사용하였다. 즉, 3개월 이동평균 Nino 3.4 지수 편차가 $+0.5^{\circ}\text{C}$ 이상(-0.5°C 이하)인 경우를 엘니뇨(라니냐), 그 사이는 중립으로 정의하였고, 강도에 대해서는 $+1.5^{\circ}\text{C}$ / $+1.0^{\circ}\text{C}$ / $+0.5^{\circ}\text{C}$ (-1.5°C / -1.0°C / -0.5°C) 이상(이하)일 경우를 각각 강/중/약 엘니뇨 (라니냐)로 정의하였다(표 3.3). APCC MME에 참여하는 모델은 매월 향후 6개월의 예측정보를 포함하고 있기 때문에, 3개월 평균 Nino 3.4 지수를 활용하는 경우 선행 시간 4개월까지 표현이 가능하다(즉, 2월 초기자료를 활용하여 3-8월까지 월별 예측정보를 가지고, 3개월 평균 Nino 3.4 지수는 3-5월, 4-6월, 5-7월, 6-8월 계산 가능).

Table 3.2. Definition of historical episode on ENSO type (or state) from different operational centers providing seasonal forecasts.

Organization/ Country	Definition of El Nino/ENSO-Neutral/La Nina
KMA/Korea	6 consecutive overlapping seasons based on a threshold of $\pm 0.4^{\circ}\text{C}$ for 5 month running mean of SST anomalies in the Nino 3.4 region
NCEP/USA	5 consecutive overlapping seasons based on a threshold of $\pm 0.5^{\circ}\text{C}$ for 3 month running mean of SST anomalies in the Nino 3.4 region
JMA/Japan	5 consecutive overlapping seasons based on a threshold of $\pm 0.5^{\circ}\text{C}$ for 5 month running mean of SST anomalies in the Nino 3 region

Table 3.3. Definition of ENSO type and strength based on 3-month mean Nino 3.4 index anomaly used in the study.

ENSO Category	Definition
Strong El Nino	Nino 3.4 index $\geq +1.5^{\circ}$
Moderate El Nino	$+1.0^{\circ} \leq \text{Nino 3.4 index} < +1.5^{\circ}$
Weak El Nino	$+0.5^{\circ} \leq \text{Nino 3.4 index} < +1.0^{\circ}$
ENSO-neutral	$-0.5^{\circ} < \text{Nino 3.4 index} < 0.5^{\circ}$
Weak La Nina	$-1.0^{\circ} < \text{Nino 3.4 index} \leq -0.5^{\circ}$
Moderate La Nina	$-1.5^{\circ} < \text{Nino 3.4 index} \leq -1.0^{\circ}$
Strong La Nina	$-1.5^{\circ} \geq \text{Nino 3.4 index}$

3.2.2.2 예측확률 추정

각 카테고리에 대한 확률값을 추정하는 방법은 크게 비모수화 방법(non-parametric estimate 또는 empirical ranking method)와 모수화 방법(parametric estimate 또는 statistical fitting method)으로 나뉜다. 비모수화 방법에 따르면, 사건 A 에 해당하는 확률($P(A)$)값은 전체 샘플 수(N)에 대한 사건 A 에 해당하는 샘플 수(N_A)의 비율로 계산된다. 즉, 엘니뇨 카테고리에 해당하는 개별모델의 양상블 수를 전체 양상블 수로 나누어 확률값을 얻는 방법이다(그림 3.3a). 모수화 방법은 샘플의 분포가 통계적인 분포를 따른다는 가정 하에(예, 정규 분포, Gamma 분포 등), 통계적인 분포의 확률밀도함수(Probability Density Function, PDF)를 이용하여 각 카테고리에 해당하는 면적을 계산하여 확률값을 얻는 방법이다(그림 3.3b). 본 연구에서는 ENSO 종류/강도 확률예측을 위해 두 가지 방법 모두를 적용하여, 예측확률 추정기법에 따른 예측확률의 차이 및 실제 예측력의 차이를 살펴보고자 한다. 또한, 모수화 기법 적용에 앞서 샘플에 대한 정규분포 적합성 테스트를 위해 Kolmogorov-Smirnov(K-S) 검정을 수행하였다. K-S 검정은 샘플 자료의 누적분포함수(Cumulative Distribution Function, CDF)와 이론적으로 가정한 분포의 CDF와의 최대 편차를 이용해 통계적으로 동일한 분포인지 아닌지를 판별하는 기법이다.




Figure 3.3. Schematic diagram for the estimation of forecast probabilities (a) based on empirical ranking method and (b) based on statistical fitting method from a forecast PDF for each category, El Nino, ENSO-Neutral, and La-Nina.

3.2.2.3 다중모델앙상블

다중모델앙상블은 개별 모델이 가지는 계통적 오차 및 초기조건에 의한 오차를 줄이기 위한 방법으로, 일반적으로 개별모델에 비해 예측력이 높은 것으로 알려져 있다 (Doblas-Reyes et al. 2005; Hagedorn et al. 2005; Min et al. 2009; Wang et al. 2009a; Min et al. 2014). 본 연구에서는 ENSO 종류 및 강도 확률예측을 위해 우선 단순평균 기법을 적용하여 예측력을 살펴보았다. 즉, 개별모델에 대한 예측확률을 먼저 추정하고, 개별모델에서 예측한 확률을 단순평균하는 PMME(probabilistic multi-model ensemble with equal weighting)를 사용하여 ENSO 종류 및 강도에 대한 카테고리별 확률예측기법을 개발하였다(그림 3.4a에서 모델 가중치를 동일하게 정의).

이후 3.5.2장에서는 ENSO 종류 및 강도예측을 위한 MME 확률예측기법 개선을 위해 다양한 가중치를 부여하는 MME 기법들을 적용하여 PMME와 예측력을 비교/평가하였다. 이 때 사용된 방법은 개별모델의 앙상블 수에 대한 가중치를 부여한 기법(PMME_N)과 과거기간동안의 ENSO 재현 능력 따른 가중치를 부여한 기법(PMME_SK)이다. 후자의 경우, 카테고리 예측력평가에서 주로 활용되고 있는 Heidke Skill Score(HSS)²⁰⁾를

20) 3분위(평년보다 높음/비슷/낮음) 확률예측에 있어서 세계적으로 널리 사용되고 있는 검증기법(예, NOAA/CPC, IRI, APCC에서 활용)으로 예보와 관측이 맞은 경우에 대해 점수를 부여하고, 기후학적으로 우연히 맞을 확률을 배제하는 객관적인 평가 방법임

사용하여 과거 재현 능력을 평가하였다. 앞선 3가지 방법(PMME, PMME_N, PMME_SK)은 개별모델이 모의한 예측확률에 특정 가중치를 부여하는 방법이라면, 마지막 방법은 개별모델의 모든 앙상블 멤버를 활용하여 하나의 분포를 만든 다음(즉, 모든 앙상블 수를 포함한 하나의 단일모델) 확률을 추정하는 가장 간단한 다중모델앙상블 확률예측기법으로 이미 많은 선행연구에서 적용한 기법이다(POOL; Barnston et al. 2003; Doblas-Reyes et al. 2005; Wang et al. 2009a).




Figure 3.4. Schematic diagram showing (a) the combination of forecast probabilities from single-model (M1–Mn) by applying the total probability formula with different model weights (PMME; e.g., equal weighting, proportional to the ensemble size, etc.) and (b) the pooling of the bias-corrected ensembles from each single-model together to produce one large super-ensemble with equal weights (POOL) to estimate categorical probabilities.

Table 3.4. Description of model combination experiments with different weights of individual models for probabilistic MME ENSO type and strength forecast used in the study.

Method	Model Weight
PMME	Equal weight
PMME_N	Proportional to the ensemble size
PMME_SK	Proportional to the hindcast skill in a leave-one-out cross-validation mode in terms of Heidke Skill Score
POOL	Equal weight of each ensemble member (pooled all ensemble members of all the models)

3.3 APCC 개별모델 및 MME 예측성 평가

3.3.1 SST 및 Nino 3.4 지수

ENSO 종류 및 강도예측을 위한 MME 확률예측기술 개발에 앞서, 우선 APCC MME 6개월 예측에 참여하고 있는 모델들의 SST 예측력을 전반적으로 살펴보았다. 그림 3.5는 개별모델(CMCC, CANCM3, CANCM4, NASA, NCEP, PNU, POAMA, SCoPS) 및 MME가 모의한 3개월 평균 Nino 3.4 지수 편차를 29년 전체 기간에 대해(즉, 1982년JFM-2010/11DJF) 관측과 함께 나타내었다. 관측을 살펴보면, 82/83 아주 강한 엘니뇨, 97/98 강한 엘니뇨, 88/89 강한 라니냐, 91/92 강한 엘니뇨, 97/98 아주 강한 엘니뇨, 그 이후 2년 연속 강한 라니냐(98-00), 02-03 중간 엘니뇨, 07/08과 10/11 강한 라니냐가 발생하는 변동성을 보이고 있다. APCC MME에 참여하는 8개 개별모델의 경우 관측에서 나타나고 있는 이러한 ENSO 변동성을 대체적으로 잘 모의하는 것으로 보인다(그림 3.5). 그 결과, 선행시간 1개월(L1)에 대한 개별모델이 모의한 3개월 평균 Nino 3.4 지수의 상관도(Temporal Correlation Coefficient, TCC)는 8개 모델 평균 0.92(0.87-0.94 범위)를 보이고 있으며, 이는 관측의 경년변동성을 상당히 잘 모의하고 있음을 의미한다(표 3.5). 특히, POAMA 모델의 예측력은 TCC=0.94로 가장 높게 나타났다. 이러한 예측력은 선행시간이 길어질수록 조금씩 떨어지며, 선행시간 4개월(L4)에는 8개 모델의 평균 예측력은 TCC=0.79(0.74-0.86 범위)로 나타났다.

개별모델을 단순 평균한 MME의 경우, 관측의 3개월 평균 Nino 3.4 지수의 경년변동성을 상당히 잘 모의하며, 선행시간 1개월 관측과의 상관도는 0.96으로 개별모델의 평균보다 높은 예측력을 보였다(그림 3.5b). 또한, 선행시간에 따른 예측력의 감소는 개별모델에 비해 상대적으로 작게 나타나며(Jin et al. 2008; Barnston et al. 2012; Tippett et al. 2017), 선행시간 4개월에도 관측과의 상관도가 0.88로 여전히 높은 값을 보이고 있다(표 3.5). 이는 많은 선행연구에서 밝힌 바와 같이 개별모델에 대한 MME 기술의 예측력 향상을 확인 할 수 있다(Doblas-Reyes et al. 2005; Hagedorn et al. 2005; Min et al. 2009; Wang et al. 2009a; Min et al. 2014).

ENSO 종류에 따른 예측력을 좀 더 살펴보면, 개별모델과 관측 간에 차이를 보이고 있으며, 특히 97/98 강한 엘니뇨에 대해선 대부분의 모델들이 과다 모의하는 경향을

보였다. 또한, 엘니뇨 발달시기에는 개별모델간의 예측 범주(spread)가 크게 나타나면서, MME가 예측한 Nino 3.4 지수는 엘니뇨 소멸시기에 비해 관측과의 편차가 크게 나타났다. 즉, 엘니뇨 발달/중립 시기에 비해 엘니뇨 소멸시기에 예측력이 높게 나타나며(Jin et al. 2008; Zheng et al. 2016), 선행시간이 길어질수록(L1→L4) ENSO 변동은 점점 느리게 그리고 강도는 약하게 모의하는 경향을 보였다(97/98 엘니뇨 제외; 그림 3.5b). 특히, 엘니뇨에서 중립으로 전이되는 시점에서 MME는 지연되는 경향이 크게 나타났다으며, 이는 Tippett et al. (2012)의 연구와 일치하는 결과이다.

다음으로 29년에 대한 개별모델 및 MME의 3개월 평균 Nino 3.4 지수의 계절/선행 시간별 예측력을 살펴보았다(그림 3.6). 선행시간이 증가할수록(L1→L4) 3개월 평균 Nino 3.4 지수 예측력은 점점 떨어지며, ENSO 위상에 따른 예측력의 계절별 차이를 확인 할 수 있다. 즉, 중립 또는 약한 엘니뇨/라니냐가 주로 발생하는 봄/여름철에 비해 ENSO의 최성기인 가을/겨울철이 상대적으로 예측력이 높음을 확인할 수 있다. 또한 대부분의 대기-해양 접합모델에서 나타나고 있는 봄철 예측력의 한계(spring predictability barrier; Jin et al. 2008; Duan and Wei 2013; Larson and Kirtman 2016)를 APCC 참여모델에서도 나타나고 있다. CANCM3, PNU, SCoPS에서 선행시간 3-4개월의 봄/여름철 예측에서 유의수준 5%에서 통계적으로 유의하지 않는 TCC를 보이고 있긴 하지만, 이를 제외하고는 모든 모델이 대부분의 선행시간/계절에서 통계적으로 유의한 높은 예측력을 보이고 있다. MME의 경우, 앞선 분석에서 확인한 바와 같이 선행시간/계절별 모두 개별모델에 비해 향상된 예측력을 보이고 있으며, 특히 개별모델에서도 가장 높은 예측력을 보인 가을/겨울철 MME 예측은 L4에서도 0.9이상의 상당히 높은 예측력을 보임으로써 APCC MME를 활용한 3개월 평균 Nino 3.4 지수 예측은 여러 방면으로 활용 가능할 것으로 판단된다.




Figure 3.5. (a) The observed (red) and the first-lead forecast anomalies of 3-month mean Nino 3.4 index from individual models (grey) and MME (blue), and (b) same as (a), except for only MME forecasts at lead times of 1, 2, 3, 4 months.

Table 3.5. Temporal correlation coefficients (TCCs) of 3-month mean Nino 3.4 index forecast anomalies from eight individual models and MME for the whole period 1982JFM–2010/11DJF at lead times of 1 (L1) and 4 months (L4).

TCC	CMCC	CANCM3	CANCM4	NASA	NCEP	PNU	POAMA	SCoPS	MME
L1	0.94	0.94	0.94	0.92	0.91	0.87	0.94	0.87	0.96
L4	0.83	0.80	0.86	0.81	0.84	0.74	0.80	0.70	0.88




Figure 3.6. TCCs of 3-month mean Nino 3.4 index forecast anomalies from (a-h) each individual models and (i) MME as a function of target season (3-month mean) and lead time. Black plus indicates that the skill is not statistically significant at 5% significance level using a Student's t-test.

3.3.2 유수현업기관과의 예측력 비교

그렇다면 세계 유수현업기관에 비교해서 현재 APCC MME의 SST 및 Nino 3.4 지수 예측력은 어느 정도인가? 현재 MME를 활용하여 ENSO Plume을 제공하고 있는 기관은 IRI/CPC와 NMME가 있으며, 객관적인 비교평가를 위해서 두 기관의 예측력은 이미 출판된 최근 논문을 활용하여 APCC MME 예측력과 비교/평가하였다. 그림 3.7은 동일한 Hindcast 기간(1982-2010년)에 대한 NMME와 APCC가 예측한 1개월 선행시간의 계절별(봄/여름/가을/겨울) SST 예측력을 살펴보았다. NMME 검증결과(그림 3.7a)는 Becker et al. (2014)에서 그대로 발췌하였다. 일반적으로 SST 예측은 북대서양 및 적도 태평양 지역에서 전 계절에 걸쳐 높게 나타나며, 특히 겨울철 Nino 3.4 감시구역의 예측력은 두 기관 모두 $TCC > 0.9$ 으로 상당히 높게 나타났다. 즉, 현재 다양한 계절예측 현업모형을 활용한 MME SST의 예측정보는 다른 기후변수에 비해 신뢰성이 높다고 할 수 있다(Min et al. (2014) 그림 3 참고). 두 기관의 예측력을 지역/계절별로 좀 더 살펴보면, 대체적으로 29년에 대한 두 기관의 SST 예측력 공간분포는 대체적으로 상당히 유사하게 나타나고 있지만, 전반적으로 APCC MME SST 예측력이 NMME에 비해 높은 것을 확인 할 수 있다. 즉, 여름/가을철에는 필리핀해 동쪽 서태평양, 아라비아해, 동인도양-인도네시아 지역에서, 겨울/봄철은 서인도양과 북대서양에서 APCC 예측력이 다소 높게 나타나는 경향을 보였다.




Figure 3.7. TCCs (x100) of SST forecast anomalies for (a) NMME prediction and (b) APCC MME prediction for each season (1-month lead DJF, JJA, SON, and DJF) during the period 1982-2010. NMME results are extracted from Figure 8 of Becker et al. (2014).

다음은 엘니뇨 감시구역인 Nino 3.4 지수에 대한 APCC 예측력을 IRI/CPC, NMME 예측력과 비교/평가 하였다(표 3.6). 여기서, IRI/CPC와 NMME에서 모의한 3개월 평균 Nino 3.4 지수에 대한 개별모델 평균 및 MME의 TCC는 Barnston et al. (2017)에서 발췌하였다. IRI/CPC는 MME 예측력 결과가 없기 때문에, 우선 IRI/CPC, NMME, APCC 참여모델들의 평균 예측력(AVG)을 비교하였다. IRI/CPC는 1981-2010년에 대해 5개의 대기-해양 접합모델(fully coupled model; IRI/CPC-5M²¹⁾)과 2개의 intermediate coupled model²²⁾까지 포함한 총 7개의 모델(IRI/CPC-7M)을 사용하였으며, NMME와 APCC는 1982-2010년에 대해 8개의 대기-해양 접합모델이 참여했다. 개별모델에 대한 IRI/CPC의 평균 예측력을 살펴보면, fully coupled model만 참여한 경우 모든 선행시간에 대해 AVG가 높게 나타났다(IRI/CPC-5M > IRI/CPC-7M). 이는 대기-해양 접합모델들이 일반적으로 대기모형 또는 intermediate coupled model에 비해 예측력이 높다는 Barnston et al. (2012) 연구 결과와 일치한다.

또한 많은 선행연구에서 밝힌 바와 같이, MME 예측력이 개별모델의 AVG보다 모두 높고(MME: APCC > AVG: APCC, MME: NMME > AVG: NMME), 3개월 평균 Nino 3.4 지수에 대한 NMME와 APCC의 MME 예측력은 비슷한 것으로 나타났다. 선행시간 1개월에서는 NMME가 약간 높지만 선행시간이 길어질수록 예측력이 떨어지는 정도는 APCC가 작아서 결과적으로 선행시간 4개월에는 APCC 예측력이 높은 걸 확인할 수 있다. 하지만 두 기관의 TCC 차이는 사실상 통계적으로 유의하지 않기 때문에 예측력 차이는 없는 것으로 보인다. 하지만 여기서 주목할 점은, 개별모델의 평균 예측력(AVG)에 대한 MME 예측력 향상은 APCC에서 크게 나타난다는 점이다(그림 3.8). 특히 선행시간 증가에 따른 예측력 감소는 APCC MME에서 작게 나타남을 표 3.6을 통해 확인한 바와 같이, L4에서 개별모델 평균 예측력에 대한 APCC MME의 예측력 향상은 10%이상으로 크게 나타났다. Yoo and Kang (2005)에 따르면, MME 예측력은 참여모델의 평균 예측력이 높을수록, 그리고 서로 독립적일수록 높아진다. NMME의 경우 8개 대기-해양 접합모델간의 독립성이 떨어지는 반면(즉, 동일 기관의 여러 개 모델이거나 또는 동일모델의 다른 버전의 모델; Barnston et al. (2017) 표 3.1 참고), APCC에 참여하고 있는 8개 대기-해양 접합모델은 서로 독립적임을 알 수 있다(표 3.1). 따라서, APCC에

21) CFSv2, POAMA, IRI_A, IRI_D, Meteo-France

22) KMA-SNU, LDEO

참여하는 모델들의 평균 예측력은 NMME에 비해 상대적으로 낮지만, 모델간 독립성이 크기 때문에 이로 인한 MME 예측력 향상이 크게 나타나면서 결국 NMME와 유사한 예측력을 보인 것으로 판단된다. 이는 지난 십여년 동안 좀 더 다양한 모델을 참여시키기 위한 APCC 노력의 결과라고 볼 수 있다(그림 1.1). 하지만, 개별모델의 평균 예측성과 모델간의 독립성 정도에 따른 MME 예측력 향상에 대한 기여도 분석은 추후 좀 더 객관적인 분석이 필요할 것으로 보인다.

지금까지 분석을 종합해보면, SST 및 Nino 3.4 예측에 있어서 APCC MME 예측은 개별모델에 비해 높고, 선행시간 4개월에서 초차 상당히 높은 예측력을 보이고 있다. 또한, MME를 활용하여 ENSO 예측을 수행하고 있는 세계 유수현업기관(IRI/CPC, NMME)과 예측력 비교결과, APCC MME 예측력이 다소 우위(적어도 유사한 예측력)에 있는 것을 확인 할 수 있다. 즉, 예측력이 보장된 Nino 3.4 지수를 활용하여 현재 APCC 에서 제공하고 있는 예측정보보다 좀 더 다양하고 유용한 예측정보 제공을 위한 본 과제 의 취지 상, ENSO 강도에 대한 확률예측기술 개발은 타 기관과의 차별성 및 예측성 면에서 적절한 컨텐츠라 판단된다. 따라서, 3.4장에서는 ENSO 종류 및 강도 예측을 위한 다중모델앙상블 확률예측기술을 개발하고자 한다.

Table 3.6. TCCs for hindcasts of the participating models in the IRI/CPC, NMME, and APCC ENSO forecast.

TCC: 1981(2)-2010	L1	L2	L3	L4
AVG: IRI/CPC-7M	0.93	0.88	0.83	0.79
AVG: IRI/CPC-5M	0.94	0.89	0.84	0.80
AVG: NMME	0.95	0.91	0.87	0.82
MME: NMME	0.97	0.94	0.91	0.88
AVG: APCC	0.92	0.88	0.84	0.80
MME: APCC	0.96	0.94	0.91	0.89

The IRI/CPC data spans 1982-2010 while the NMME and APCC data is for 1982-2010. Data sets of hindcasts are for 3-month mean Nino 3.4 SST anomaly. MME shows the skill of MME forecasts from the NMME and APCC, in contrast with AVG that shows the average of the skills of the individual IRI/CPC models, NMME, and APCC models.

* IRI and NMME results are from Barnston et al. (2017).




Figure 3.8. Skill improvement of APCC-MME and NMME-MME as compared with the average of the individual models skill (AVG) in terms of TCC (%).

3.4 다중모델앙상블 확률 예측기술 개발

3.4.1 분포도 적합성 검정

3.4장에서는 예측성 높은 APCC MME 참여모델들을 활용하여 ENSO 종류 및 강도 예측기술을 개발하고자 한다. 우선, 개별모델에 대한 예측확률을 추정하기 위해 3.2.2.2에서 설명한 비모수/모수화 기법을 모두 적용하여 예측확률 차이 및 예측력의 차이를 살펴보고자 한다. 모수화 기법은 샘플의 분포를 특정 통계적인 분포로 가정하기 때문에, 실제로 샘플이 얼마나 통계적인 분포를 따르는냐에 따라 결과가 달라질 수 있다. 따라서 모수화 적용에 앞서 샘플의 분포도 검정이 선행되어야 하며, 본 연구에서는 ENSO 종류/강도를 정의하기 위해 활용한 3개월 평균 Nino 3.4 지수에 대한 분포도 검정과 예측확률 추정 기법에 따른 예측력 차이를 분석하였다. 계절예측에 있어서 기온 및 지위고도는 일반적으로 정규분포를 따른다고 알려져 있지만(Tippett et al. 2007; Min et al. 2009), 전구를 대상으로 한 SST에 대한 선행연구는 아직까지 없는 실정이다. 따라서 본 연구에서는 ENSO 종류 및 강도를 정의하는데 활용되는 SST 및 3개월 평균 Nino 3.4 지수에 대한 분포도 적합성 검정을 우선 수행하였다.

그림 3.9는 29년(1982-2010) 관측자료의 SST에 대한 K-S 테스트 결과이다. 그림에서 음영부분은 각 계절평균 SST가 유의수준 5%에서 K-S 검정결과 정규분포를 따르지 않는 지역을 의미한다. 일부 극 지역을 제외하고는 대부분의 지역에서 모든 계절에 대해 SST는 정규분포를 따르는 것으로 나타났다. 엘니뇨 감시구역 3.4의 SST가 정규분포를

따르기 때문에 영역 평균값(5°S - 5°N , 170° - 120°W) 즉, 실제 ENSO 종류/강도를 정의할 때 활용되는 3개월 평균 Nino 3.4 지수 또한 모든 계절에 대해서 유의수준 5%에서 통계적으로 정규분포를 따름을 알 수 있다(표 3.7). 그렇다면 실제 예측에 활용되는 개별 모델의 Nino 3.4 지수는 관측과 동일하게 정규분포를 따르는가? 이를 검정하기 위해, 관측과 동일한 방법으로 개별모델의 3개월 평균 Nino 3.4 지수에 대해 K-S 테스트를 수행하였다. 그 결과, NASA, NCEP, POAMA, SCoPS는 모든 계절에 대해 3개월 평균 Nino 3.4 지수는 통계적으로 정규분포를 따름을 확인할 수 있다(표 3.7). 그림 3.10은 POAMA가 모의한 3개월 평균 Nino 3.4 지수 분포도이며, 계절별로 분포도가 조금씩 상이하긴 하지만, 모든 계절에 대해서 정규분포의 모습을 보이며 K-S 검정 결과 유의수준 5%에서 모두 통계적으로 정규분포를 따름을 알 수 있다. 나머지 모델들 또한 한 계절을 제외하고는(CANCM4 제외) 모델들이 모의한 3개월 평균 Nino 3.4 지수는 정규분포를 따르는 것으로 나타났다. K-S 테스트를 통한 분포도 검정결과, 관측과 개별모델의 3개월 평균 Nino 3.4 지수는 대체적으로 정규분포를 따른다고 할 수 있으며 본 연구에서 ENSO 종류 및 강도에 대한 예측 확률 추정을 위해 모수화 기법 적용 시, 정규분포로 가정할 수 있을 것으로 판단된다.




Figure 3.9. Kolmogorov-Smirnov (K-S) Test for the normality of observed SST anomalies for (a) MAM, (b) JJA, (c) SON, (d) DJF for the period 1982-2010. Shaded areas are the regions where the observed PDFs differ from the normal PDFs at the 5% significance level. The box indicates the Nino 3.4 region.

Table 3.7. P-value of K-S test for the normality of the observed 3-month mean Nino 3.4 index for each target season during the period 1982–2010.

K-S test (p-value)	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ	DJF
OBS	0.89	0.89	0.86	0.91	0.99	0.81	0.96	0.99	0.91	0.88	0.41	0.87
CMCC	0.33	0.13	0.74	0.36	0.86	0.22	0.91	0.15	0.23	0.66	0.03	0.24
CANCM3	0.56	0.12	0.02	0.09	0.13	0.34	0.11	0.01	0.05	0.22	0.33	0.51
CANCM4	0.59	0.05	0.01	0.03	0.57	0.03	0.40	0.01	0.05	0.35	0.11	0.55
NASA	0.46	0.53	0.16	0.17	0.57	0.84	0.70	0.12	0.71	0.84	0.05	0.33
NCEP	0.28	0.07	0.11	0.07	0.19	0.64	0.05	0.18	0.73	0.51	0.32	0.51
PNU	0.85	0.89	0.04	0.17	0.38	0.74	0.95	0.19	0.73	0.48	0.22	0.46
POAMA	0.07	0.14	0.14	0.08	0.26	0.06	0.68	0.08	0.88	0.50	0.10	0.24
SCoPS	0.47	0.38	0.23	0.38	0.74	0.13	0.83	0.19	0.98	0.68	0.27	0.10

* H0: The observed data is normally distributed. If p-value of K-S test is smaller than 0.05, H0 can be rejected at the 5% significance level. Bold represents that the observed and predicted distribution of Nino 3.4 index does not follow the Gaussian PDF for each season.




Figure 3.10. Distribution of 3-month mean Nino 3.4 index from POAMA for each target season during the period 1982–2010. P-values of K-S test for the normality are displayed. Blue, grey, and red indicate El Niño, ENSO-Neutral, and La Niña condition.

3.4.2 모수화/비모수화에 따른 예측확률 추정

K-S 테스트를 통한 분포도 검정결과를 바탕으로, 본 연구에서는 비모수화 방법(Empirical Ranking Method, EMP)과 정규분포를 가정한 모수화 방법(Gaussian Fitting Method, GAUS)에 따른 ENSO 종류 및 강도 예측확률의 차이를 살펴보았다. 그림 3.11은 예측확률 추정기법에 따른 ENSO 종류 및 강도에 대한 카테고리 예측확률의 차이를 모델별, 계절별로 나타낸 것이다. 즉, 총 분석기간(29년), 선행시간(4개월), 카테고리(ENSO 종류: 3개, ENSO 강도: 7개)에 대한 예측확률 차이의 평균 및 최대값을 보여준다. ENSO 종류의 경우(그림 3.11a), 개별모델은 평균 2%-7%, 최대 10%-50% 범위의 예측 확률값 차이를 보이고 있다. ENSO 종류별로 살펴보면(그림 3.12a-c), 엘니뇨/라니냐에 비해 중립일 경우 예측확률 추정기법에 따른 확률차이의 평균 및 최대값 모두 상대적으로 크게 나타났다. GAUS와 EMP에 따른 예측확률 차이의 최대값은 ENSO 강도에서 더 크게 나타나는 경향을 보였다(그림 3.11b). 또한, 엘니뇨와 라니냐의 강도가 점점 약해질수록(strong→weak) 예측확률 추정기법에 따른 확률값의 차이는 점점 커지는 것으로 확인되었다(그림 3.12d-i). 또한 확률예측 추정기법에 따른 예측확률의 차이는 샘플의 수(여기서는 개별 모델의 앙상블 수)에 민감하게 반응하는 것으로 나타났다. 즉, 상대적으로 앙상블 수가 작은 PNU 모델에서 두 기법에 따른 예측확률 차이가 크게 나타났다. 즉, ENSO 종류에 있어서는 최대 30-50%, 강도에 있어서는 40-55% 정도의 예측확률 차이를 보였다. 이는 EMP 방법의 경우, 샘플에 대해서 어떠한 통계적 분포 가정 없이 샘플 자체의 분포를 그대로 사용한다는 점에서 장점이긴 하지만, 샘플의 수가 작을 경우 표본오차가(sampling error)가 증가한다는 단점이 있다. 반면 모수화 방법은 샘플을 통계적인 분포로 가정하여 연속함수(continuous function)를 적분하여 계산하기 때문에, 특히 샘플의 수가 작은 경우 EMP와의 예측확률 차이가 크게 나타난다. 마지막으로 PMME(Probabilistic Multi-Model Ensemble)는 개별모델에 비해 ENSO 종류/강도 모두 예측확률 추정기법에 따른 확률의 차이가 작게 나타나는데, 이는 PMME의 경우 개별모델의 예측확률을 다시 평균하기 때문에 예측확률 차이가 큰 부분들이 상쇄되어 두 기법간의 예측확률 차이는 개별모델에 비해 작게 나타나게 된다.




Figure 3.11. Mean and maximum difference in forecast probability for (a) ENSO type (3-category; El Nino, ENSO-Neutral, La Nina) and (b) ENSO strength (7-category, strong/moderate/weak El Nino/La Nina, ENSO-Neutral) using Gaussian fitting method (GAUS) and empirical ranking method (EMP) for each model and target season, during the period 1982-2010. All years, leads, and multi-category are included.

그렇다면 예측확률 추정기법에 따른 개별모델의 확률 차이가 실제 예측력에 영향을 미치는지 알아보기 위해, 두 가지 기법을 적용하여 예측한 ENSO 종류 및 강도에 대한 예측력을 비교하였다(그림 3.13). 이때 사용된 검증기법은 관측의 발생빈도와 예측 확률과의 오차를 측정하는 RPSS(Ranked Probability Skill Score)²³⁾와 관측의 카테고리를 얼마나 잘 맞췄는지에 대한 정확도를 측정하는 HSS를 사용하였다. 두 검증기법 모두 기준(reference)이 되는 예측력(RPSS: 기후학적 제곱오차, HSS: 기후학적으로 맞힐 확률)에 대한 실제 예측력의 정도를 나타내기 때문에 1에 가까울수록 기준에 비해 예측력이 높고, 0보다 작으면 예측력이 낮음을 의미한다. ENSO 종류에 대해 살펴보면, 대부분의 모델에서 GAUS 방법이 EMP에 비해 RPSS가 높게 나타났다. 특히, NCEP, PNU, POAMA, SCoPS에서 GAUS에 의한 예측력 향상은 통계적으로 유의한 것으로 나타났다. 하지만, HSS 검증기법에서는 그 차이가 RPSS에 비해 크지 않다. 이는 현재 대부분의 대기-해양 접합모델은 엘니뇨/중립/라니냐에 대한 카테고리 예측력(즉, 관측과 동일

23) 관측과 예측과의 확률차이를 측정하는 기법으로 각 카테고리의 확률차이에 대한 누적제곱오차(RPS)를 기후학적 누적제곱오차(RPS_{ref})와 비교한 예측검증 기법

$$RPS = \frac{1}{N_{cat} - 1} \sum_{icat=1}^{n_{cat}} (CDF_{f,icat} - CDF_{o,icat})^2, \quad RPSS = 1 - \frac{RPS}{RPS_{ref}}$$

한 카테고리를 예측하는지에 대한 정확도) 자체가 상당히 높기 때문에(대부분의 모델 $HSS > 0.5$), GAUS에 의한 예측력 향상 정도는 그리 크게 나타나지 않는 것으로 보인다. 그럼에도 불구하고, CANCM3와 SCoPS에서는 EMP에 대한 GAUS의 예측력 향상은 통계적으로 유의한 것으로 나타났다. ENSO 강도에서도 모든 모델에 대해 GAUS가 EMP에 비해 높은 예측력을 보이고 있으며, PNU와 POAMA에서 GAUS의 예측력 향상이 통계적으로 유의하게 나타났다.




Figure 3.12. Same as Figure 3.11, except for each category of ENSO type and strength.




Figure 3.13. Ranked probability skill score (RPSS) and Heidke Skill Score (HSS) of ENSO (a) type and (b) strength forecasts, averaged over all target seasons and lead times, with different methods (GAUS, EMP) for estimation of forecast probability. Blue (light blue) indicates that the skill difference between GAUS and EMP is significant using a Monte-Carlo (MC) test at 10% (20%) significance level.

ENSO 강도예측에 있어서 GAUS에 의한 예측력 향상은 ENSO 종류에 비해 상대적으로 크게 나타나는 것을 알 수 있다(4개의 모델에서 통계적으로 유의한 예측력 향상을 보임). 또한 PMME에서도 EMP에 비해 GAUS 예측력이 높게 나타나고 있으며, 예측력 향상 정도는 개별모델에 비해 작다. 여기서 주목할 점은 두 기법간의 예측확률 차이가 컸던 PNU의 경우(그림 3.11-12), 관측과 예측확률 차이로 예측력을 평가하는 RPSS에서 GAUS의 예측력 향상은 ENSO 종류 및 강도 모두에서 통계적으로 유의하게 나타났다. 즉, 샘플수가 작을 경우 비모수화 방법을 적용하여 예측확률을 추정하게 되면 표본오차가 커지기 때문에, 통계적으로 fitting 하는 모수화 방법이 보다 정확한 예측확률을 추정하고, 결과적으로 예측력도 높아지는 것을 확인할 수 있다. 또한, K-S 분포도 검정 결과 정규분포를 잘 따르는 모델(NASA, NCEP, POAMA, SCoPS)에서 대체적으로 GAUS 예측력 향상이 유의한 것으로 나타났다. 따라서, 본 연구를 바탕으로 특히 양상불수가 작은 모델이거나 모델의 예측자료가 통계적인 분포를 매우 잘 따르는 경우, 이를 활용하여 카테고리에 대한 확률예측을 한다면 비모수화 방법보다는 모수화 방법을 사용할 것을 권장한다.

지금까지의 분석결과를 종합해보면, 대부분의 모델에서 정규분포를 가정한 모수화 방법이 비모수화 방법에 비해 관측과의 예측확률 차이는 작게 나타나고, 예측력은 높게 나타났다. 특히, 앙상블 수가 작은 모델과 모델의 모의한 3개월 평균 Nino 3.4 지수가 정규분포를 잘 따르는 모델에서 GAUS에 의한 예측력 향상이 두드러지게 나타났다. 본 연구의 최종목표는 현업적인 측면에서 가장 적절한 ENSO 확률예측기법 개발이기 때문에, 앞선 분석 결과(GAUS 예측력이 높음) 및 현재 현업으로 제공하고 있는 tercile 확률예측(평년보다 높음/비슷/낮음에 대한 예측확률) 기법²⁴⁾과의 통일성 등을 고려하여 본 연구에서는 ENSO 종류/강도 카테고리 확률예측을 위해 GAUS 방법을 사용하고자 한다.

3.4.3 ENSO 확률예측기법의 예측력 평가

앞선 분석들을 바탕으로 본 연구에서는 ENSO 종류 및 강도에 대한 카테고리 확률예측을 위해 Gaussian fitting 방법을 적용하여 개별모델의 예측확률을 추정하고, 이를 단순평균하는 방법으로 Hindcast 및 실시간 ENSO 예측에 대해 예측력을 평가하였다. 이때 사용된 검증기법은 WMO에서 권고하는 중/장기 확률예측의 표준 검증기법인 ROC²⁵⁾ 곡선을 사용하였다. ROC 곡선은 샘플 수에 민감하게 반응하기 때문에 일정 시간 및 영역을 포함하는 자료에 대해 검증하기를 WMO에서는 권고하고 있다. 따라서 본 연구에서는 29년에 대한 매월 3개월 평균 예측정보를 L4까지 포함하여 시간적으로 종합한(aggregated) ROC 곡선을 계산하였다. ROC 곡선은 Hit Rate(HR)와 False Alarm Rate(FAR)의 상대적인 비율을 나타낸 것으로, 각 카테고리를 얼마나 잘 구별하는지에 대한 능력을 평가 한다(즉, resolution). ROC 곡선이 대각선에 비해 왼쪽-상단으로 갈수록 예측력이 높음을 의미 한다($HR > FAR$).

3.4.3.1 Hindcast(1982-2010)

SST 및 ENSO는 다른 기후변수에 비해(예, 기온 및 강수) 다양한 분야로의 활용을 위해 적어도 몇 개월 전의 예측정보를 필요로 한다. 따라서 본 연구에서는 선행시간 1개

24) 현재 APCC 홈페이지를 통해 제공하고 있는 계절예측은 Gaussian fitting 방법을 적용한 카테고리 확률예측기법임(Min et al. 2009)

25) Reliability Operating Characteristics

월뿐만 아니라 4개월 전에 예측한 3개월 평균정보(즉, 2월에 예측한 여름철 예측정보)까지 예측력을 평가하고자 한다. 그림 3.14는 전체 Hindcast 기간(1982-2010), 계절(JFM-DJF), 그리고 모든 선행시간(L1-L4)까지 포함하여 PMME의 ENSO 종류 및 강도에 대한 예측력 검증 결과이다. PMME의 ROC 곡선은 대각선을 기준으로 가장 좌측-상단에 위치하고 있으며, 이는 PMME가 엘니뇨/중립/라니냐에 대한 각 각의 카테고리를 구별하는 능력이 개별모델에 비해 뛰어남을 의미한다(그림 3.14a-c). 하지만, 개별모델에서 보여주고 있는 예측력 또한 다른 기후변수들에 비해 상당히 높음을 알 수 있다. 즉, 엘니뇨(라니냐)를 예측하는 데 있어 개별모델의 ROC score(ROC 곡선의 아래 면적)은 선행시간 4개월까지의 예측정보를 모두 고려했음에도 불구하고 약 0.81-0.91(0.80-0.93) 정도의 범위를 가지며, 이는 일반적으로 예측성이 높다고 알려져 있는 적도지역의 지표기온 ROC score가 선행시간 1개월에서 0.7-0.8 범위의 값을 가지는 것과 비교해보면(예, Min et al. 2009; Wang et al. 2009a) 개별모델의 예측력 또한 상당히 높음을 알 수 있다. ENSO 중립의 경우는 엘니뇨와 라니냐에 비해 상대적으로 예측력이 낮게 나타나며, 이는 일반적으로 카테고리별 확률예측에서 주로 나타나는 현상이다. 즉, tercile 확률예측에서(3분위 확률예측; 평년보다 높음/비슷/낮음²⁶⁾) 평년과 비슷할 경우는 다른 두 경우에 비해 신호 섭동(signal perturbation)에 대한 민감도가 낮기 때문에 평년과 비슷할 경우에 대한 예측확률은 기후학적으로 발생할 확률(예, 3분위 카테고리 예측의 경우, 0.33)과 유사한 값을 가지게 된다. 그 결과, 많은 선행연구에서 나타난 바와 같이, 평년과 비슷할 경우에 대한 예측력은 다른 두 카테고리에 비해 상대적으로 예측력이 낮다고 알려져 있다(예, van den Dool and Toth 1991; Kharin and Zwiers 2003; Min et al. 2009). 이러한 경향은 ENSO 종류에 대한 카테고리 확률예측에서도 동일하게 나타났다. PMME 결과를 선행시간에 대해 좀 더 살펴보면(그림 3.15), L1에서 엘니뇨/중립/라니냐에 대한 예측률은 각각 0.98/0.91/0.97로 상당히 높음을 알 수 있다. 선행시간이 길어질수록(L1→L4), ROC 곡선은 점차 대각선 쪽으로 가까워지긴 하지만 L4에서도 여전히 엘니뇨/라니냐는 0.9 이상의 높은 ROC score를 보이며, 선행시간에 따른 예측력 감소는 상대적으로 중립에서 크게 나타났다.

ENSO 강도에 대한 예측력을 살펴보면, PMME는 대체적으로 개별모델에 비해 예측력이 높게 나타나고, 특히 강한 엘니뇨/라니냐가 약한 엘니뇨/라니냐에 비해 예측력이 높

26) Above-Normal(AN), Near-Normal(NN), Below-Normal(BN)

음을 알 수 있다. 그 결과, L1에서 강한 엘니뇨와 라니냐는 ROC score ≥ 0.98 이며, L4에서조차 0.89 이상의 값을 보였다(그림 3.16). 즉, ENSO가 강할수록 예측력이 높다는 것을 의미하는데 이는 역학모델의 초기/경계조건으로 사용되는 SST는 천천히 변동하는 기후요소로 강한 ENSO가 발생하기 전 관측의 SST 상태는 이러한 신호가 잠재적으로 포함되어 있기 때문에 예측력이 높게 나타나는 것으로 보인다. 이에 반해 약한 엘니뇨/라니냐의 경우 역학모델을 수행하는 시기의 관측 SST는 대부분 신호가 강하지 않기 때문에 개별 모델간의 예측 spread가 증가하고 그 결과 ENSO가 강할 때보다 SNR(Signal-to-Noise Ratio)²⁷⁾이 작아지면서 예측력은 떨어지는 것으로 보인다. 이는 ENSO 최성기인 가을/겨울철이 중립 또는 약한 ENSO 상태가 자주 발생하는 봄/여름에 비해 예측력이 높다는 기존의 선행연구와 일치하는 결과이다(예, Jin et al. 2008; Barnston et al. 2012; Zheng et al. 2016).

대부분의 경우 PMME가 개별모델에 비해 ROC 곡선이 좌측-상단에 위치하지만, 강한 엘니뇨/라니냐에서는 PMME 보다 높은 예측력을 보이는 모델이 있는 것으로 나타났다(그림 3.14d, g). 그 모델은 각각 강한 엘니뇨에서는 CANCM4, 강한 라니냐에서는 POAMA로 확인 되었다. 이는 강한 엘니뇨/라니냐는 지난 29년에 대해 아주 드물게 발생하는 현상으로 특정 경우에 대해서는(특히, 강도가 강한 경우), PMME에 비해 개별모델이 예측력이 높을 수도 있다. PMME는 개별모델의 예측정보를 다시 평균하기 때문에 강도가 강한 경우와 같은 극한 값에 대해서는 MME를 함으로써 어느 정도 상쇄가 되기 때문이다. 하지만, 강한 엘니뇨에서 최고의 예측력을 보인 CANCM4는 강한 라니냐에 대해서는 8개 모델 중 두 번째로 낮은 예측력을 보였고, 반대로 강한 라니냐에서 최고의 예측력을 보인 POAMA의 경우 강한 엘니뇨에서는 가장 낮은 예측력을 보이며 단일 모델의 예측력은 경우에 따라 편차가 크게 나타나는 것을 알 수 있다. 이에 반해 PMME는 강한 엘니뇨/라니냐에 대해선 최고의 예측력을 보장하지는 못하지만, 최고의 예측력을 보인 한 모델을 제외하고는 모든 모델들에 비해 예측력이 높게 나타났다. 또한 강한 ENSO보다 발생빈도가 훨씬 높은 나머지 카테고리(중/약 엘니뇨와 라니냐)에 대해서는 PMME가 어떤 개별모델보다 높은 예측력을 보였다(그림 3.16e-f, h-i). 즉, MME는 다양한 경우의 예측정보를 고려했을 때 개별모델에 비해 높은 예측력을 보여준다는 점이 바로 MME의 가장 큰 장점으로 알려져 있으며(Doblas-Reyes et al. 2005; Rodrigues

27) 예측 가능한 부분(predictable component)과 예측 불가능한 부분(unpredictable component)에 대한 비율

et al. 2014), 이러한 경향이 ENSO 예측에서도 확인할 수 있다. ENSO 강도 예측 또한 선행시간이 길어질수록 예측력이 점차 떨어지는 경향을 보이며, 이러한 경향은 라니냐에 비해 엘니뇨에서 크게 나타났다. 이는 앞선 ENSO 종류에서도 나타나고 있으며(그림 3.15). 선행시간이 길어질수록 엘니뇨가 라니냐에 비해 예측력이 상대적으로 크게 떨어지는 부분에 대한 자세한 분석은 추후 진행되어야 할 것으로 생각된다.




Figure 3.14. Aggregated ROC curve over all years, target seasons, and leads of individual models' forecast (open circle) and PMME forecast (closed circle) for ENSO type; (a) El Nino, (b) ENSO-neutral, and (c) La Nina, and for ENSO strength; (d-f) strong/moderate/weak El Nino and (g-i) strong/moderate/weak La Nina.




Figure 3.15. Same as Figure 3.14, except for only PMME ENSO type forecast at lead times of 1, 2, 3, 4 months. ROC scores (area under the ROC curve) for each category and lead time are shown in the plot.




Figure 3.16. Same as Figure 3.15, except for ENSO strength forecast.

3.4.3.2 실시간 예측(2013-2016)

본 연구는 ENSO 종류/강도 예측을 위해 개발된 확률예측기법이 최종적으로 APCC 현업시스템으로의 발전 가능성을 평가를 위해, Hindcast에 대한 예측력 평가뿐만 아니라 실제 실시간 예측(real-time forecast)에 대한 예측력 평가도 함께 수행하였다. 서론에서 언급한 바와 같이, APCC는 2013년 9월부터 MME를 활용한 SST 및 ENSO 예측 정보를 제공하기 시작했기 때문에(Min et al. 2017), 지난 4년간(2013-2016)의 예측자료를 활용하여 개발된 ENSO 확률예측기술을 객관적으로 평가하기에는 자료가 충분하지 않을 수도 있다. 하지만, 29년에 대한 Hindcast 예측결과와 더불어 최근 4년(4년 $\times$ 12개월 = 48 자료 활용)에 대한 예측력 평가 또한 본 연구의 특성상 충분히 의미가 있다고 판단된다. 실시간 예측에 활용된 모델은 2013-2016년 기간 동안 모든 계절에 대해 6개월 예측자료를 포함하는 5개 모델(CANCM3, CANCM4, NASA, NCEP, POAMA)을 사용하였다.

우선 OISST 자료를 활용한 3개월 평균 Nino 3.4 지수 편차를 살펴보면(그림 3.17a), 2011/12년 약한 라니냐 이후 2014년 중반까지 중립상태가 2년 이상 지속되다 2014년 가을부터 Nino 3.4 지수 편차가 0.5°C 이상의 값을 보이며 약한 엘니뇨가 시작되었다. 이후 2015년 봄철부터 Nino 3.4 지수는 급격히 증가하다 여름철 이후 강한 엘니뇨 임계값인 1.5°C 이상의 값을 보이다 2015/16 겨울철 Nino 3.4 지수는 2.5°C 이상으로 아주 강한 엘니뇨로 발달하였다. 이후 엘니뇨가 소멸하면서 2016년 가을철 약한 라니냐로 발달하였다가 다시 중립으로 돌아섰다. 보통 강한 엘니뇨 뒤에는 강한 라니냐가 주로 발생하는데 반해(ENSO blog²⁸⁾), 이번 2015/16 강한 엘니뇨는 짧은 주기의 경년 변동성 보다는 온난화 추세와 장주기 변동성이 우세하여 라니냐로 크게 발달하지 못한 것으로 보인다(Kim et al. 2017c). APCC MME에 참여하는 대기-해양 접합모델이 예측한 3개월 평균 Nino 3.4 지수는 관측에서 나타나고 있는 ENSO의 변동성을 대체적으로 잘 모의하는 것으로 나타났다(그림 미 제시). 그 결과, APCC MME가 모의한 3개월 평균 Nino 3.4 지수는 2013JFM-2016/17DJF 기간 동안 관측과 상관도는 선행시간 1개월에 0.97(TCC)의 값을 보였고, 선행시간 4개월에 대해서도 TCC=0.92로 아주 높은 예측

28) <https://www.climate.gov/news-features/blogs/enso/will-la-ni%C3%B1a-follow-el-ni%C3%B1o-what-past-tells-us>

력을 보였다.

그림 3.16b-c는 PMME에 의해 예측된 엘니뇨/중립/라니냐에 대한 각 카테고리의 예측확률을 나타낸 것이다. 엘니뇨 임계값인 0.5°C 이상의 값을 관측에서 보인 2014SON-2016AMJ 기간 동안 PMME는 2015FMA만 제외하고는(PMME는 중립으로 예측함), L1에서 관측과 동일하게 엘니뇨에 대한 카테고리에서 가장 높은 예측 확률값을 보이며, ENSO 종류에 대한 카테고리를 정확히 맞춘 것으로 확인 된다(그림 3.17b). 하지만 2015/16 엘니뇨 이후 아주 짧은 기간 동안 발생했던 약한 라니냐에 대해서 PMME는 L1에서 예측을 못한 것으로 나타났다. 즉, 강한 ENSO가 약한 엘니뇨/라니냐 또는 중립에 비해 예측력이 높게 나타났던 Hindcast 결과처럼 ENSO 위상(종류)에 따른 예측력 차이를 확인 할 수 있다. 또한, 2015/16 엘니뇨를 관측에 비해 빠르게 발달하고, 빠르게 소멸하는 것으로 예측하는 경향을 보였다. L4에서는 L1과 비슷한 경향을 보이긴 하지만, 선행시간이 길어질수록 개별모델간의 예측 spread는 커지면서 엘니뇨/중립/라니냐 간의 예측확률 차이는 L1에 비해 작은 것으로 나타났다.

ENSO 강도예측은 3개의 카테고리(엘니뇨/중립/라니냐) 중 가장 높은 확률을 예측한 카테고리를 우선 선정하고, 그 카테고리가 엘니뇨 또는 라니냐일 경우 강도에 대한(강/중/약) 예측확률을 함께 나타내었다(그림 3.18b-c). 관측에서 3개월 평균 Nino 3.4 지수가 엘니뇨 임계값인 0.5°C 이상의 값을 보인 기간에 대해서 PMME는 모두 엘니뇨의 발생확률을 가장 높게 예측했으며(그림 3.17b-c), 강한 엘니뇨 기간(2015JJA-2016FMA) 동안 L1, L4 모두 PMME는 강한 엘니뇨가 중/약한 엘니뇨에 비해 예측확률이 대부분 90% 이상으로 상당히 높은 것을 확인할 수 있다. 또한, 중간급 엘니뇨가 나타났던 기간에 대해서도(2015AMJ-JJA, 2016FMA-MAM) PMME는 강/약한 엘니뇨 보다 중간급 엘니뇨에 대한 예측확률을 상대적으로 높게 예측하면서 ENSO 강도에 대한 카테고리를 잘 구별하는 것으로 나타났다. 즉, 본 연구에서 개발한 확률예측 기법(Gaussian fitting 방법을 적용하여 개별모델의 예측확률을 추정하고, 이를 단순평균하는 방법)은 ENSO 종류뿐만 아니라 강도에 따른 예측력 또한 높음을 확인 할 수 있다.




Figure 3.17. (a) Observed 3-month mean Nino 3.4 index and its PMME forecast for ENSO type (El Nino, ENSO-Neutral, and La Nina) at lead times of (b) 1 and (c) 4 months.




Figure 3.18. (a) Same as Figure 3.17, except for ENSO strength forecast.

3.5 확률 다중모델앙상블 예측기술 개선

3.5.1 Model Calibration

3.5.1.1 ENSO 발생빈도

앞선 3.4장에서 개발한 ENSO 종류 및 강도 예측을 위한 확률예측기법(PMME)을 개선하기 위한 노력으로 여러 가지 통계적 기법을 적용하여 기존의 방법과 예측력을 비교/평가하였다. 우선 개별모델의 계통적 오차를 살펴보기 위해, 개별모델이 모의한 3개월 평균 Nino 3.4 지수에 대한 분포도 및 ENSO 발생빈도를 관측과 비교하였다. 그림 3.19는 전체 분석기간(1982JFM-2010/11DJF: 29년 $\times$ 12월 = 348 샘플)에 대한 관측 및 선행시간 1개월의 개별모델 3개월 평균 Nino 3.4 지수 분포도 및 통계량을 나타내었다. 관측의 경우, 3개월 평균 Nino 3.4 지수의 분산(평균으로부터 흩어진 정도, variance; Var)은 0.77이며, 왜도(분포가 기울어진 방향과 정도, skewness; Skew)는 0.28로 왼쪽으로 약간 치우쳐진 분포임을 알 수 있다(하지만, 절대값이 크지 않아 비대칭 정도는 상당히 작음). 그 결과, 엘니뇨(27%)에 비해 라니냐(29%) 발생빈도가 조금 크게 나타나며, 발생빈도로 보면 중립이 가장 많이 발생하는 것으로 관측에서는 나타났다(44%, 표 3.8). CANCM3 모델을 제외하고 모든 개별모델의 분산은 관측보다 크게 나타나며(즉, 퍼짐정도가 큼), 그 결과 ENSO 중립의 발생빈도는 관측에 비해 7개 모델 평균 11%(5%-20% 범위) 작게 모의하였다. 반대로 CANCM3의 분산은 관측에 비해 작으며(Var=0.65; 중앙으로 많이 모여 있는 분포), 그 결과 중립은 관측에 비해 20% 과다 모의, 엘니뇨/라니냐는 관측에 비해 각각 18%와 14% 과소 모의하는 경향을 보였다. 대부분의 모델들은 관측과 동일한 양의 왜도를 보였으며, 특히 양의 왜도 절대값이 가장 크게 나타난 CMCC의 경우, 왼쪽으로 치우침 정도가 크게 나타나면서 관측에 비해 라니냐를 48% 과대 모의하는 경향을 보였다.




Figure 3.19. Distribution of (a) observed and the first-lead Nino 3.4 forecast anomalies from (b-i) individual models. Variation (Var) and Skewness (Skew) for each distribution are also displayed. Blue, grey and red indicate El Nino, ENSO-Neutral, and La Nina condition.

Table 3.8. Frequency of ENSO type from individual models and observation. The values in parenthesis refer to relative error with respect to the observation (%).

	OBS	CMCC	CANCM3	CANCM4	NASA	NCEP	PNU	POAMA	SCoPS
El Nino	0.27	0.22 (-18%)	0.22 (-18%)	0.33 (22%)	0.29 (7%)	0.33 (22%)	0.33 (22%)	0.24 (-11%)	0.26 (-3%)
ENSO Neutral	0.44	0.35 (-20%)	0.53 (20%)	0.39 (-11%)	0.38 (-14%)	0.38 (-13%)	0.38 (-14%)	0.42 (-5%)	0.44 (-)
La Nina	0.29	0.43 (48%)	0.25 (-14%)	0.28 (-3%)	0.33 (6%)	0.31 (6%)	0.29 (-)	0.34 (17%)	0.30 (3%)

또한, 모델이 모의한 ENSO 발생빈도는 관측과 유사한지를 살펴보기 위해 모델 및 MME가 모의한 ENSO 종류 및 강도(표 3.3 기준)에 대한 발생빈도를 계절별로 관측과 비교하였다(그림 3.20). 관측의 발생빈도를 살펴보면, 엘니뇨와 라니냐는 계절별 발생빈도가 비슷하며, 알려진 바와 같이 봄에서 겨울로 갈수록 발생빈도가 점차 커지는 것을 알 수 있다. ENSO 중립은 봄-가을까지 40% 이상의 발생빈도를 보이며, 엘니뇨/라니냐에 비해 자주 발생하는 것으로 나타났다. 관측에서 나타나는 계절별 ENSO의 발생빈도를 선행시간 1개월의 MME에서는 대체적으로 잘 모의하는 것으로 보인다. 특히, 엘니뇨와 라니냐는 중립에 비해 관측과의 발생빈도 차이가 작게 나타났다(약 10% 이내). 하지만 개별모델의 경우, 엘니뇨/중립/라니냐에 대한 발생빈도 차이는 MME에 비해 크게 나타나며 중립과 라니냐의 경우는 30% 이상 차이를 보이는 모델/계절도 있는 것으로 나타났다. 또한, CMCC처럼 라니냐에 대해서 일관되게 과대 모의하는 경향이 있다면(그림 3.21, 파란색 표시), 이러한 모델의 계통적 오차를 보정(calibration 또는 correction)하여 예측력을 향상시킬 수 있을 것으로 보인다.

즉, 개별 모델이 모의한 3개월 평균 Nino 3.4 지수의 분포는 관측과 상이하기 때문에 관측과 동일한 임계값으로 모델의 ENSO의 종류 및 강도를 정의하면 그림 3.20-21에서 확인한 바와 같이 모델은 바이어스(또는 에러)를 가지게 되어 결국 예측력을 떨어트리게 된다. 따라서 본 연구에서는 모델의 계통적 오차를 고려하여 모델별/계절별로 ENSO를 정의하는 새로운 방법을 적용해보고자 한다. 이는 관측과 동일한 발생빈도를 가지는 임계값을 모델별/계절별로 새로 정의하고, 그 기준을 바탕으로 예측하고자 하는 해의 ENSO 예측정보를 계산하는 방법이다(그림 3.22). 즉, 관측과 동일한 발생빈도를 가지는 임계값을 모델에서 새로 정의함으로써 앞서 분석 결과에서 나타난 관측과 통계적으로 다른 분포로 인해 나타나는 차이를 어느 정도 보정할 수 있을 것으로 기대된다. 편의를 위해, 관측과 동일한 임계값으로 ENSO를 정의하는 기존의 방법과 모델별로 임계값을 새롭게 정의하는 방법을 각각 M-I, M-II로 명명하겠다. M-II 방법을 Hindcast(1982-2010년) 및 실시간 예측(2013-2016년)에 대해 모두 적용하여 M-I 방법의 예측력과 비교/평가하였다. 여기서 Hindcast 적용 시, 개별모델별로 새로운 ENSO를 정의하기 위해 사용한 관측의 발생빈도는 예측하는 해를 제외한 기간에 대한 정보를 활용함으로써 예측하고자 하는 해의 정보를 완전히 배제하였다(one-year-out cross-validation mode, Wilks 1995). 즉, 1982년 ENSO 예측을 위해 28년(1983-2010)에 대한 관측의 발생빈도 정

보를 이용하여 모델별/계절별로 ENSO에 대한 카테고리 임계값을 새로 정의하였다. 실시간 예측정보에 대해서는 총 29년(1982-2010)에 대한 관측의 발생빈도를 활용하였다.




Figure 3.20. Seasonal frequency of (a) ENSO type and (b-c) ENSO strength forecasts based on 3-month mean Nino 3.4 index with the corresponding observation for the period 1982-2010.




Figure 3.21. Difference in seasonal frequency of ENSO type forecasts with corresponding observation. Histogram, plus-marker and star-marker indicate the frequency from MME, each individual model, and CMCC, respectively.




Figure 3.22. Schematic diagram of M-II method to newly define thresholds by having the same frequency as observations for El Nino, ENSO-Neutral, and La Nina for each model and target season.

3.5.1.2 M-I vs M-II 예측력 평가

ENSO 종류 및 강도 확률예측기법을 개선하기 위해 제안한 M-II 방법의 예측력을 기존의 방법(M-I) 예측력과 비교하였다. 그림 3.23은 1982-2010년 동안 M-I 방법에 대한 M-II 방법의 예측력 향상(즉, 두 기법의 예측력 차이)을 RPSS 차이로 나타낸 것이다. ENSO 종류에 대한 예측력 차이를 살펴보면(그림 3.23a), 대부분의 모델에서 M-II의 예측력이 대체적으로 높게 나타났으며(특히, CMCC, CANCM4, NASA), 선행시간에 상관없이 봄철과 여름철에 M-II에 의한 예측력 향상이 상대적으로 크게 나타났다. 또한, M-II 방법에 의한 예측력 향상은 PMME에 비해 개별모델에서 다소 크게 나타났다. 이러한 M-II의 예측력 향상은 ENSO 강도 예측에서도 동일하게 나타나며, 예측력 향상 정도는 ENSO 종류에 비해 다소 크게 나타났다(그림 3.23b).

앞서 설명한 바와 같이, RPSS는 관측과 예측과의 예측확률차이에 대한 평가이며, 확률예측에서는 이와 더불어 관측과 동일한 카테고리 정확히 맞추는지에 대한 평가도 중요하다. 따라서 RPSS와 더불어 본 연구에서는 HSS를 활용하여 두 기법의 예측력을 계절별/리드별로 비교하였다(그림 미 제시). 그 결과, RPSS에서 나타났던 M-II의 예측력 향상이 동일하게 나타났다. ENSO 종류와 강도에 대한 M-II 방법의 예측력 향상이 특히 봄철과 여름철에 크게 나타난 이유를 분석하기 위해, 각 카테고리에 대한 관측과 모델의 예측확률 에러를 평균제곱오차를 활용하여 살펴보았다(그림 3.24a). 그 결과,

M-II에 의한 예측력 향상이 크게 나타났던 계절(FMA, MAM, JJA)에 관측과 모델의 확률차이가 크게 나타나며, ENSO 종류 및 강도에 대한 일반적인 예측력 또한 FMA, JJA에 낮은 것을 확인 할 수 있다(그림 3.24b). 이는 일반적으로 모델에서 예측력의 한계를 보이는 지역/변수에서 통계적 기법을 활용한 개선기술의 효율성이 상대적으로 크게 나타남을 밝힌 선행연구들과 일치하는 결과이다(Jia et al. 2010; Min 2011).




Figure 3.23. RPSS difference of probabilistic forecasts for (a) ENSO type and (b) ENSO strength between M-I and M-II as a function of lead time and target season for the period 1982-2010.




Figure 3.24. (a) Averaged model error and (b) forecast skill (HSS) for ENSO type and ENSO strength over the years, seasons, and leads. Model error is calculated by $Error = \sqrt{(M_E - O_E)^2 + (M_N - O_N)^2 + (M_L - O_L)^2}$, where M and O are forecast probabilities from model and observation and E , N , and L indicate El Nino, ENSO-Neutral, and La Nina.

3.5.2 Model Combination

개별모델에 대한 다중모델앙상블의 예측력 향상은 이미 많은 선행연구들에 의해서 증명되었고, 최근 들어 MME 예측성 향상을 위해 개별모델의 예측값에 가중치를 부여하는 MME 기술에 관한 연구가 활발히 진행되고 있으며(예, Yun et al. 2003, 2005; Kug et al. 2008; Lee et al. 2011), 특정지역/계절에 대해 단순평균기법보다 향상된 예측력을 보이고 있다. 본 연구에서는 ENSO 종류 및 강도 확률예측기법 개선을 위한 두 번째 방법으로 다양한 MME 기법들을 적용, 단순평균 PMME 결과와 예측력을 비교/평가 하고자 한다. 본 연구에서는 표 3.4에서 설명한 바와 같이, 개별모델의 앙상블 수와 과거자료의 예측력에 따른 가중치를 부여하는 MME_N과 PMME_SK 기법을 적용하였고, 마지막으로 개별모델의 모든 앙상블을 하나의 super-ensemble로 가정하여 예측확률을 계산하는 POOL 방법까지 총 4가지 MME 방법에 대한 예측력을 비교하였다. 여기서 PMM_SK 경우, Hindcast 실험에서 예측하고자 하는 해(예, 1982년)에 대한 개별모델의 가중치는 예측하고자 하는 해를 제외한 나머지 28년(1983-2010년)에 대한 ENSO 예측성(HSS)을 사용하였다.

그림 3.25는 ENSO 종류에 대한 MME 기법들의 RPSS 예측력을 나타낸 것이다. MME 기법들의 예측력 또한 가을철/겨울철에 높게 나타나고, 봄철/여름철 예측력은 다소 떨어지는 경향이 나타났다. 전체 계절과 선행시간을 평균한 RPSS 값은 4개의 MME 모두 0.6이상으로 엘니뇨/중립/라니냐에 대한 예측력은 상당히 높은 것을 확인 할 수 있다. MME 기법들 간의 예측력 차이를 계절별/리드별로 살펴보면(기준이 되는 PMME 예측력에 대한 차이: 그림 3.25e-g), PMME_SK 기법은 PMME에 비해 예측력 향상이 나타나고 있으며(하지만 그 값의 차이는 크지 않음), 다른 두 기법에 대해서는 예측력 향상과 감소가 계절별/리드별 상이하게 나타나고 있어 일관된 결론을 내리기는 힘들어 보인다. MME 기법에 따른 ENSO 강도 예측력 차이 또한 크지 않은 것으로 나타나며, PMME, POOL, PMME_N, PMME_SK의 전체 평균 RPSS는 각각 0.56, 0.55, 0.55, 0.57로 APCC 참여모델들은 ENSO 강도에 따른 엘니뇨/라니냐 또한 잘 재현하고 있는 것으로 나타났다(그림 미 제시). 이러한 경향은 HSS를 통한 검증결과에서도 동일하게 나타났다(그림 미 제시).




Figure 3.25. RPSS of probabilistic forecast from (a) PMME, (b) POOL, (c) PMME_N, and (d) PMME_SK for ENSO type and (e-g) skill difference with respect to PMME ones as a function of target season and lead time for the period 1982–2010. Averaged RPSS over the seasons and leads are also displayed.

PMME 기법을 개선시키기 위해 3.5장에서 제안한 기법들에 대한 예측력을 계절별/리드별 평균해서 종합적으로 살펴보면(그림 3.26), ENSO 종류에 대해서는 M-I에 대한 M-II의 예측력 향상은 SCoPS를 제외한 모든 모델에서 나타나고 있으며, M-II에 의한 예측력 향상이 가장 큰 모델은 CANCM4로 RPSS와 HSS에서 M-I에 비해 각각 20%와 10% 이상의 상대적인 예측력 향상을 보였다. 여기서, RD²⁹⁾는 계절/리드별로 두 방법의 상대적인 예측력 차이를 계산하고 이를 평균한 값이다. M-II 기법을 통한 예측력 향상 정도는 MME에 비해 개별모델에서 두드러지게 나타나며 이는 그림 3.23에서도 확인한 결과이며, MME에서는 기법에 상관없이 예측력 차이가 유의하지 않은 것으로 나타났다. ENSO 강도에 따른 예측에서도 유사한 결과를 보이며, MME에서는 오히려 M-II의 예측력이 떨어지는 경향을 보였다(그림 3.26b).

결과적으로 모델의 바이어스를 보정하는 M-II 기법에 의한 예측력 향상은 MME에 비해 개별모델에서 상대적으로 크게 나타나며, 다양한 가중치에 따른 MME 기법들 간의 ENSO 종류 및 강도에 대한 예측력 차이는 크지 않은 것으로 나타났다. 즉, ENSO 종류 및 강도 예측에 있어서 model combination에 의한 예측력 향상보다 model calibration에 의한 예측력 향상이 큰 것으로 나타났다. 이는 계절평균 예측력 향상을 위해 순차적 패턴 투영기법을 활용하여 개별모델의 계통적 오차를 보정 하고 예측력 높은 모델을 선정하는 기법을 적용하여 기존의 단순평균 MME와 예측력을 비교/평가한 Min (2011) 연구와 일치하는 결과(적도지역 기온의 경우 calibration에 의한 예측력 향상이 combination에 의한 예측력 향상보다 크게 나타남)이다.

29) Relative Skill Difference=((M-II-M-I)/M-I)*100, M-I에 대한 M-II의 상대적인 예측력 향상을 의미함




Figure 3.26. Averaged RPSS of probabilistic forecast for (a) ENSO type and (b) ENSO strength over the target seasons and leads for the period 1982–2010. Relative skill difference (RD) is estimated by difference between M-I and M-II, divided by M-I for each target season and lead, and then averaged them.

3.5.3 실시간 예측(2013-2016) 적용

예측성 향상을 위한 기법개발과 관련된 대부분의 연구들은 Hindcast 자료를 활용한 예측력 평가로만 그치고, 실시간 예측정보에 대한 평가를 함께 수행한 연구는 그리 많지 않다. 하지만 본 연구의 최종목표는 현업적인 측면에서 활용 가능한 ENSO 종류 및 강도에 대한 예측기술 개발이 목적이기 때문에, 현재 APCC에서 활용 가능한 실시간 예측정보의 길이가 짧음에도 불구하고 실시간 예측에 대한 예측력 평가를 실시하였다. 사용된 모델은 3.4.3.2에서 활용한 모델과 동일하다. M-II 방법을 실시간 예측에 적용하기 위해서 29년 총 Hindcast 기간의 자료를 활용하여 모델의 ENSO를 정의하는 기준값을 보정(동일 기간 관측에서 발생한 ENSO 빈도) 하였고, 과거재현 예측력에 가중치를 부여하는 PMME_SK 또한 29년 Hindcast 자료에 대한 예측력을 활용하였기 때문에, 실제 예측하는 해의 정보는 전혀 포함되지 않아 서로 독립적이다.

그림 3.27은 M-II 방법으로 2013-2016년 기간 동안 선행시간 1개월 PMME가 예측한 ENSO 종류 및 강도에 대한 카테고리 확률예측결과이다. 대체적으로 관측에서 나타나는 ENSO 변동성을 잘 모의하는 것으로 보이며, 2015/16년 중/강한 엘니뇨의 발달

시점과 강도는 적절히 재현한 것으로 나타난다. 하지만 M-I에서 나타났던 바와 같이(그림 3.17), 2014년 엘니뇨를 관측에 비해 빠르게 모의하는 경향은 여전히 나타나고 있음을 확인할 수 있다. 앞서 M-I에서 2016년 약한 라니냐 예측을 실패한 것과 같이 M-II에서도 라니냐 대신 중립으로 예상했으며, 그 이후 관측에서는 라니냐로 발달하지 못하고 중립으로 돌아선 반면 M-II는 1개월 선행시간에서 라니냐는 뒤늦게 점점 발달할 것으로 예상하면서 예측이 빗나간 것을 확인할 수 있다. 이러한 경향들은 L4에서 동일하게 나타났다(그림 미 제시).

2013JFM-2016/17DJF까지 확률예측결과에 대한 RPSS와 HSS 예측결과를 M-I과 비교하여 리드별/모델별로 그림 3.28에 나타내었다. M-I과 M-II 예측력 비교에 앞서, 검증기법에 대한 상관도를 살펴보면 두 기법들에는 선형관계가 있음을 확인할 수 있다. 특히, Nino 3.4 지수를 활용한 ENSO 강도 카테고리 예측에 대한 개별모델 및 MME의 예측력은 선형관계가 강하며, 3개의 카테고리인 ENSO 종류를 맞추는 것이 7개 카테고리인 ENSO 강도를 맞추는 것보다 HSS가 다소 높게 나타나면서 대각선 아래 쪽에 위치하는 경향을 보였다. 이는 Tippet et al. (2017)에서 언급한 바와 같이, RPSS는 각 카테고리의 확률 차이에 대한 제곱오차를 전체 카테고리에 대해서 누적하기 때문에 이론적으로 카테고리 수에 따라 RPSS는 민감하지 않다는 결과와 일치한다. 이에 반해, HSS는 카테고리 수가 증가함에 따른 예측력의 감소가 나타남을 확인할 수 있다.

실시간예측 기간 동안의 M-I과 M-II의 예측력을 비교해보면, ENSO 종류/강도 상관 없이 대부분의 모델/리드에서는 M-II 예측력(그림 3.28; + 표시)은 M-I 예측력(그림 3.28; • 표시)에 비해 왼쪽 아래쪽에 위치함을 알 수 있다. 이는 M-II의 예측력이 M-I에 비해 낮다는 것을 의미이며, 예측력 감소의 정도는 개별모델보다 작게 나타나지만 이러한 경향은 MME에서도 동일하게 나타났다. 또한, MME 기법 간의 예측력은 ENSO 종류에 대해서는 PMME 기법이, 강도에 대해서는 PMME와 PMME_SK 기법의 예측력이 상대적으로 높게 나타났다. 즉, Hindcast 자료를 활용한 leave-one-out cross-validation 실험에서 M-II의 예측력 향상이 개별모델에서 두드러진데 반해, 실제 실시간 예측실험에서는 전혀 예측력 향상이 나타나지 않았다. 심지어 예측력이 떨어지는 경향을 보였으며, 과거재현 예측력에 따른 가중치를 부여하는 PMME_SK 기법 또한 Hindcast 및 실시간 모두에서 큰 예측력 향상을 찾아보기는 힘들었다.




Figure 3.27. (a) Observed 3-month mean Nino 3.4 index and the first-lead PMME forecast for (b) ENSO type and (c) strength based on M-II method for the period 2013-2016.




Figure 3.28. Scatter diagram of forecast skills of ENSO type and strength using M-I and M-II method in terms of RPSS and HSS for each individual models and MMEs for the period 2013–2016.

3.5.4 예측력 향상이 나타나지 않은 이유?

이론상으로는 M-II 기법(관측과 동일한 발생빈도로 개별모델의 ENSO 기준을 새롭게 정의하는 방법)과 PMME_SK 기법(과거 ENSO 재현 능력에 따른 모델의 가중치를 부여하는 방법)은 기존의 방법들(M-I, PMME)에 비해 예측력이 높을 것으로 기대된다. 하지만, Hindcast 자료를 활용한 leave-one-out cross-validation 모드 내에서 개별모델에서 나타났던 M-II의 예측력 향상은 실시간 예측에서는 전혀 나타나지 않고 심지어

예측력이 감소하는 모습을 보였다(그림 3.28). 또한, PMM_SK 기법은 Hindcast 실험에서 약간의 예측력 향상을 보이긴 했지만, 대체적으로 다양한 MME 기법들 간의 예측력 차이는 크지 않았으며, 이는 실시간에서도 마찬가지였다. 그렇다면, 이렇게 실시간 예측에서 M-II의 예측력 향상이 나타나지 않은 이유와 다양한 MME 기법들이 ENSO 예측에서 예측력 차이가 나타나지 않는 이유에 대해서 알아보기 위해 몇 가지 분석을 수행하였다.

3.5.4.1 Model Calibration

본 연구에서는 통계모델에서 흔히 나타나는 과적합 문제(overfitting problem)를 극복하기 위해 Hindcast 자료를 활용하여 개별모델의 새로운 ENSO 기준을 정할 때 예측하고자 하는 해의 정보를 배제한 기간에 대한 관측의 발생빈도를 활용하였다. 또한, PMME_SK 기법에서는 동일하게 cross-validation을 적용하여 예측하고자 하는 해를 제외한 나머지 해에 대한 ENSO 종류/강도에 대한 예측력을 바탕으로 개별모델에 대한 가중치를 부여하였다. 즉, 매 단계마다 예측하고자 하는 해의 정보가 포함되지 않도록 독립적인 과정에서 모든 계산을 수행하였다.

그림 3.29a는 총 29년에 대한 정보를 모두 활용하여 1982-2010년에 대한 ENSO 종류에 대한 M-I과 M-II의 예측력 차이를 나타낸 것이다. 즉, 매 해마다 그 해 관측의 정보가 포함된 경우이며, 이를 보통 통계모델을 활용한 선행연구에서는 training period라고 언급한다. 예상가능 하듯이 통계적 기법을 활용한 M-II 기법은 모든 개별모델과 MME에서 일관되게 상당한 예측력 향상을 확인할 수 있다(그림 3.29d). CANCM4와 NASA의 경우 모든 계절과 선행시간을 평균한 RPSS 예측력 향상은 20% 이상으로 크게 나타났고, 나머지 모델에서도 10% 이상의 예측력 향상을 보였다. 이에 반해, 본 연구에서 training 하는 기간과 예측하는 해와의 독립성을 유지하기 위해 cross-validation 내에서 계산을 수행 했을 때는(그림 3.29b) 3.29a에 비해 대부분의 모델에서 M-II의 예측력 향상 정도는 작은 것으로 확인할 수 있으며, 앞서 언급한 바와 같이 SCoPS 모델은 심지어 M-I에 비해서 예측력이 떨어지는 것으로 나타났다. 또한 실시간 예측정보에 대해서는 모든 개별모델과 MME에서 M-II 기법은 기존의 M-I에 비해 예측력이 떨어지는 것으로 나타났다(그림 3.29c). 즉, 그림 3.29를 통해 현업적인 측면에서 통계기법을

개발할 때 training 기간과 예측하는 해의 독립성이 얼마나 중요한지 확인 할 수 있다. 이는 일반적으로 training 기간 동안에 나타났던 예측력 향상이 왜 예측기간에는 두드러지게 나타나지 않는지에 대한 대답이 될 것이며, 또한 본 연구에서처럼 Hindcast 자료를 활용하여 과적합 문제를 극복하기 위해 cross-validation 내에서 개별모델을 보정했다 할지라도 실제예측에 있어서는 예측력이 향상되지 않을 수 있음을 확인하였다.

앞선 분석들을 통해 ENSO 종류 및 강도 예측에서 있어서 M-II의 예측력 향상이 실시간 예측에서 나타나지 않은 이유에 대해서 다음과 같이 설명할 수 있을 것 같다. 첫째, training 자료에 대해서 예측하고자 하는 해의 정보를 철저히 배제했음에도 불구하고(즉, cross-validation 기법 내에서 수행), 1982-2010년 기간에 대해서만 통계적인 관계를 설명하기 때문에 실제 2014-2016년만의 특징적인 현상에 대해서는 설명하지 못하는 경우가 발생하게 된다(예, 최근 ENSO 발생 빈도 및 강도에 대한 변동성이 과거와 다를 경우). 둘째, ENSO 종류 및 강도에 대한 통계적인 발생빈도를 추정하여 실시간 예측에 적용하기에는 29년의 Hindcast 자료 길이 또한 짧은 것으로 판단된다(특히, 강한 엘니뇨와 라니냐의 경우). 셋째, ENSO는 4-5년의 주기를 가지는 특성이 있으며, 본 연구에서는 특히나 ENSO 종류 및 강도에 대한 발생빈도에 초점이 맞춰져 있기 때문에 4년의 실시간 예측기간으로 통계적으로 보정한 기법에 대한 예측력을 종합적으로 판단하기에는 실시간예측자료 길이의 한계 또한 있는 것으로 판단된다. 즉, 짧은 검증기간으로 인해 통계적 기법에 대한 예측력은 민감하게 반응하여 29년 Hindcast 기간에 비해 다소 random한 예측력을 보일 가능성도 있는 것으로 판단된다.

본 연구는 ENSO 종류 및 강도를 최대한 활용하기 위해 29년에 대한 Hindcast 자료를 사용했음에도 불구하고, 자료 길이에 대한 한계로 인해 실시간 예측에 있어서 여러 가지 한계에 봉착했다. 하지만 실제 현업에서 활용 가능한 Hindcast 길이는 참여모델의 공통기간을 기준으로 삼기 때문에 보통 23년 정도이다. M-II 기법의 경우 Hindcast 기간에 대한 관측의 ENSO 종류 및 강도 발생빈도에 따라 개별모델의 ENSO를 정의하는 기준이 달라지기 때문에, 과거자료의 기간에 대한 민감도 실험을 실시하였다. 그림 3.30은 관측의 총 35년 자료(1982-2016)에 대해 23년씩 이동평균하여 계산한 Nino 3.4 지역의 SST 기후값과 최대/최소의 차이값을 나타낸 것이다. 23년씩 이동평균한 SST의 기후값의 차이는 겨울철에 크게 나타나며, 상대적으로 여름에는 작게 나타났다.

즉, 기후값 기간에 대한 계절별 차이가 나타나는 이유는 겨울철이 ENSO 최성기기 때문이다. 즉, 2015/16년과 같은 강한 엘니뇨가 들어가는냐 들어가지 않는냐에 따라 겨울철 SST의 기후값은 영향을 받게 되며, 대부분 중립 또는 약한 엘니뇨/라니냐가 자주 발생하는 봄/여름철의 경우는(그림 3.18) 기후값 기간에 대해 많이 민감하지 않는 것으로 보여진다. 즉, 23년 이동평균에 대한 Nino 3.4 지역의 SST 기후값 차이는 가을/겨울철 0.2℃이상의 차이를 보이며 이는 결국 실제 예측하는 해의 SST 편차값에 영향을 미치는 것이다. 즉, Nino 3.4 지수의 경우 적어도 가을철/겨울철에는 기후값기간에 대해 민감하게 반응하는 것으로 나타났다.

그렇다면 기후값 기간에 따라 ENSO 발생 및 강도의 발생빈도는 민감하게 반응하는지 확인하기 위해, 동일한 방법으로 23년씩 이동한 기후값 기간 동안의 ENSO 발생빈도를 관측에서 살펴보았다(그림 3.31). 그 결과, Hindcast 기간에 대한 엘니뇨와 라니냐의 발생빈도는 약 10-40%의 차이를 보이며, 특히 중립의 경우 봄/여름철에는 평균 50%, 최대 80%까지도 발생빈도 차이가 나는 것을 확인할 수 있다. 강도에 대해서는 특히 중/강한 엘니뇨와 라니냐는 다른 계절에 비해 상대적으로 겨울철에 발생빈도 차이가 크게 나타나며(그림 3.29와 동일한 결과), 기후값기간에 따른 ENSO 발생빈도 민감도는 강한 엘니뇨/라니냐에서 약한 엘니뇨/라니냐로 갈수록 크게 나타났다. 즉, 기후값기간에 대한 예측하는 해의 편차는 크게 영향을 받지 않지만(그림 3.30), 실제 예측하는 해의 ENSO 카테고리를 정의하는 기준이 되는 과거 기후값기간 동안의 ENSO 발생빈도는 상당히 민감하게 반응함을 확인 할 수 있었다(그림 3.31). 따라서, 관측과 동일한 발생빈도로 개별모델을 보정하는 M-II 기법은 기후값 기간에 따라 관측의 발생빈도가 상당히 민감하게 반응하기 Hindcast 기간에 대한 좀 더 심도 깊은 연구가 필요할 것으로 판단된다.




Figure 3.29. Averaged RPSS of probabilistic forecast for ENSO type over target seasons and leads from different experiments. All estimations are based on (a) 29 years for hindcast (No), (b) 28 years in a cross-validation mode for hindcast (Cv), and (c) 29 years for real-time forecast (RT). (c) Skill difference between M-II and M-I in No and Cv.




Figure 3.30. Means of 23-year moving averaged Nino 3.4 SST climatology for the period 1982–2010 for each target season (closed circle). Maximum and minimum values (their differences) are also displayed with plus-marker (histogram).




Figure 3.31. The dependence of occurrence probability of (a–c) ENSO type and (d–i) strength for each target season from observation as Nino 3.4 SST climatologies of 23-year moving average for the period 1982–2010.

3.5.4.2 Model Combination

마지막으로 Nino 3.4 지수를 활용한 ENSO 종류 및 강도에 대한 카테고리 확률예측에 있어서 다양한 가중치를 부여하는 MME 기법들(PPOOL, PMME_N, PMME_SK)이 단순평균기법(PMME)보다 예측력이 크게 향상되지 않는 이유는 무엇인가에 대해 살펴 보았다. 우선, PPOOL 방법은 개별모델의 모든 앙상블 멤버를 하나의 분포로 가정하여 예측확률을 추정하는 가장 간단한 방법으로, 확률예측 MME 연구에서 주로 활용되는 방법이다(예, Barnston et al. 2003; Doblas-Reyes et al. 2005; Wang et al. 2009a). 하지만 Min et al. (2009)에 따르면 현재 대부분의 현업기관에서 활용하는 있는 개별모델들 간의 앙상블 수가 서로 상이하며, 또한 한 모델 내에서도 Hindcast와 실시간예측의 앙상블수가 동일하지 않는 경우에 대해서는 Hindcast 및 실시간 예측의 PDF의 특성이 일치하지 않기 때문에 현업 기관에서는 PPOOL 기법이 적절하지 않다고 언급하였다. 그 결과, 서로 다른 앙상블 수를 가지고 있는 APCC 참여모델들을 활용(표 3.1)한 본 연구에서 또한 PPOOL 방법은 PMME에 비해 예측력이 높지 않은 것으로 나타났다(특히, 실시간 예측에서는 4개의 기법 중 가장 예측력이 낮은 것으로 나타남).

다음은 적도지역 해수면온도 예측력의 원천을 찾기 위해, 3개월 평균 해수면온도에 대한 개별모델 앙상블 평균의 표준오차(standard error, SE)와 개별모델 앙상블 평균의 차이(difference, DF)의 비를 분석하였다.

$$R = \sqrt{\frac{(SE^2)}{(DF^2)}}$$

여기서 $(\quad)$ 는 29년에 대한 평균을 의미하며 SE와 DF는 각각 아래와 같다.

$$SE = \frac{\sqrt{n}}{\sigma}, \quad DF = \sqrt{\frac{\sum_{i=1}^M (\mu_i - \mu_{mm})^2}{M-1}}$$

여기서, n 과 σ 는 개별모델의 총 앙상블 수와 앙상블의 표준편차(즉, 앙상블 spread)를 의미한다. 개별모델 앙상블 평균의 차이는 개별모델 앙상블 평균의 표준편차로 나타내며, M 은 전제 모델의 수, μ_i 와 μ_{mm} 은 i 번째 모델의 앙상블 평균과 전제 모델 앙상블 평균의 평균(즉, MME)를 의미한다.

29년 평균에 대한 개별모델의 R 공간분포를 모델별로 살펴보면(그림 3.32), 앙상블 수가 많은 모델에 비해 앙상블 수가 작은 모델에서 상대적으로 R 이 크게 나타났다. 또한 지역별로 살펴보면 중위도 지역에서 R 이 크게 나타났으며, 이는 모델간 평균에 대한 차이(즉, inter-model spread)보다는 모델내의 앙상블간의 차이(즉, ensemble spread)가 크다는 것을 의미한다. SE가 큰 중위도 지역에서 최적의 모델 가중치는 개별모델의 표준오차제곱에 반비례하는 기법이다(Taylor 1997). 즉, 표준오차를 줄이기 위해 앙상블 수를 많이 하거나 또는 앙상블 수에 따른 가중치를 부여하는 기법이 적절하며, 이는 기온에 비해 상대적으로 R 의 값이 큰 강수에서 앙상블 수에 비례하는 가중치를 부여한 MME 기법이 단순평균 기법보다 예측력이 향상됨을 밝힌 Min et al. (2009) 선행연구와 일치하는 결과이다.

반면, 적도지역(특히, Nino 3.4 지역)은 중위도 지역에 비해 R 이 상당히 작으며 이는 개별모델의 앙상블간의 차이가 상당히 작고, 개별모델의 평균에 대한 차이가 크다는 것을 의미한다. 즉, 적도지역은 모델이 적도 해수면온도의 평균을 예측하는 능력에 따라 예측력이 좌우한다는 것을 의미한다. 이는 최근 Kumar et al. (2016) 연구에서 예측 가능한 부분(predictable component)과 예측하지 못하는 부분(unpredictable component)에 대한 상대적인 비율로 측정한 적도지역의 예측력은 개별모델의 앙상블 spread 보다는 앙상블 평균에 의해 좌우된다는 결론과 일치한다. 또한 ENSO 예측에 있어서 SST PDF의 spread 보정보다 평균에 대한 보정으로 인한 예측력 향상이 크게 나타나는 선행연구와도 일치한다(예, Tippett et al. 2004; Peng and Kumar 2005; Tang et al. 2008; Peng et al. 2011; Kumar and Hu 2014). 즉, 적도지역의 해수면 온도 예측력은 모델의 앙상블 평균을 재현하는 능력에 좌우된다고 할 수 있으며, 평균적인 상태(mean state)에 대해 일반적으로 높은 예측력을 보이는 단순평균기법이 적도지역에 가장 적절한 하다고 판단된다. 하지만, 적도지역에서 일관되게 최고의 예측력을 보이는 모델이 있다면 예측력에 가중치를 부여하는 방법이 이론적으로는 예측력을 향상시킬 수 있는 최적의 방법일 것이다. 하지만 현재 APCC MME에서 활용하고 있는 대기-해양 접합모델을 활용하여 지난 29년 기간 동안 ENSO 종류 및 강도에 대해 안정적인 예측력을 보이는 최고의 모델은 없으며, 계절/리드/년도에 따라 예측력은 민감하게 달라지는 것을 확인 할 수 있었다. 예를 들어, 29년 전체 기간을 평균한 예측력에서는 POAMA가 개별 모델 중 최고의 예측력을 보이지만, 실시간 예측기간 동안의 예측력을 보면

POAMA가 가장 낮은 예측력을 보이고 있다(그림 3.29). 따라서, 최고의 개별모델을 확신할 수 없는 상황에서 적도지역의 ENSO 예측력을 향상시키기 위한 최적의 MME 기법은 개별모델을 단순평균하는 기법이다. 그 결과, Hindcast 및 실시간 예측에서 다양한 모델의 가중치를 부여한 MME 기법은 적도지역 ENSO 예측에 있어서 향상된 예측력을 보이지 않은 것으로 판단된다.




Figure 3.32. The 29-year mean ratio, R , for 3-month mean SST from individual models. R is the ratio between the model standard errors and differences between the model ensemble means.

3.6 요약

ENSO 현상에 대한 관심 및 예측에 대한 중요성이 점차 커지면서 대부분의 현업기관에서는 적도태평양의 SST 및 ENSO에 대한 지속적인 감시 및 예측정보를 제공하고 있다. 하지만 현재 제공하고 있는 대부분의 예측정보는 Plume 형태의 결정론적 예측정보이며, 사용자들에서 좀 더 합리적인 의사결정을 하는데 도움을 주는 불확실성에 대한 정보를 함께 제공할 수 있는 확률예측 정보의 중요성이 점차 부각되고 있다. APCC 또한 지난 2013년 9월부터 SST 및 ENSO 예측정보를 홈페이지를 통해 제공하고 있으며, 이는 모두 결정론적 예측정보이며 그 종류 또한 상당히 제한적이다. 따라서 보다 다양하고 유용한 정보제공을 위한 새로운 콘텐츠 발굴 및 예측기술 개발이 목적인 본 과제에서는 타 기관과의 차별성을 고려하여 ENSO 종류(3개 카테고리; 엘니뇨/중립/라니냐)뿐만 아니라 강도 예측(7개 카테고리; 강/중/약 엘니뇨 및 라니냐, 중립)을 위한 MME 확률예측 기술을 개발하고자 한다.

ENSO 종류 및 강도예측을 위한 MME 확률예측기술 개발에 앞서, 우선 APCC MME 6개월 예측에 참여하고 있는 모델들(CMCC, CANCM3, CANCM4, NASA, NCEP, PNU, POAMA, SCoPS)의 SST 예측력을 전반적으로 살펴보았다. 1982-2010년 기간에 대한 3개월 평균 Nino 3.4 지수에 대한 MME의 예측력(TCC)은 선행시간 1개월(L1)과 4개월(L4)에서 각각 0.96과 0.88로 개별모델에 비해 높은 예측력을 보이며, 특히 선행시간이 길어짐에 따른 예측력 감소는 작은 것으로 나타났다(그림 3.5 및 표 3.5). 또한, APCC의 SST 예측력이 세계 유수현업기관과 비교했을 때 어느 정도의 수준인지 살펴보기 위해 IRI/CPC와 NMME 예측력과 비교/평가하였다. 그 결과, 계절평균 전구 SST의 경우 APCC MME의 예측력이 높은 지역($TCC > 0.6$)이 NMME에 비해 다소 넓게 분포하고, Nino 3.4 지수에 대해서는 NMME와 유사한 예측력을 보였다. 특히, APCC MME의 높은 예측력은 다양한 모델의 참여로 인한 예측력 향상이 많은 부분 기여하는 것으로 나타났다.

ENSO 종류 및 강도예측을 위한 다중모델앙상블 확률예측기술 개발을 위해, 예측확률 추정 기법(비모수 방법; EMP와 모수화 방법)에 따른 확률 차이 및 예측력의 차이를 비교/평가하였다. 우선, Kolmogorov-Smirnov 테스트를 통한 정규분포 적합성 검정(K-S 테스트)을 통해 관측 및 모델의 3개월 평균 Nino 3.4 지수는 정규분포를 따름을 확인하

였고(그림 3.9-10, 표 3.7), 본 연구에서는 정규분포를 가정한 모수화 방법(GAUS)을 사용하였다. ENSO 종류/강도 모두에서 예측확률 추정기법에 따른 개별모델의 확률 차이를 확인할 수 있었고(특히, 앙상블 수가 작은 모델; 그림 3.11-12), 그 결과 앙상블 수가 작거나 개별모델의 분포가 정규분포를 잘 따르는 모델에 대해서는 두 기법에 따른 예측력 차이가 통계적으로 유의한 것으로 나타났다(그림 3.13). 따라서, 앞서 분석을 통한 GAUS의 예측력 향상과 현재 APCC 현업에서 제공하고 있는 tercile 확률예측 기법(Min et al. 2009)과의 통일성 등을 고려하여 ENSO 종류 및 강도 확률예측을 위해 GAUS 기법을 선정하였다.

즉, Gaussian fitting 방법을 통한 개별모델의 예측확률을 추정하고, 개별모델의 예측확률을 단순평균하는 방법(PMME)으로 예측한 ENSO 종류 및 강도 확률예측정보의 APCC 기후서비스로 발전 가능성을 평가하기 위해, Hindcast(1982-2010년) 및 실시간 예측(2013-2016)에 대한 예측력을 종합적으로 검증하였다. 그 결과 ENSO 종류 뿐만(그림 3.15) 아니라 강도 예측에 있어서 PMME는 예측력이 높게 나타났다(그림 3.16). 즉, 강한 엘니뇨와 라니냐에 대해서 L1(L4)에서는 ROC score가 각각 0.99(0.89)과 0.98(0.93)로 상당히 높은 값을 보였다. 실시간 예측에 대해서도 관측에서 나타난 ENSO 변동성을 굉장히 잘 모의한 것으로 나타났다. 특히, 2015/16년 겨울철에 발달한 아주 강한 엘니뇨에 대해서 PMME는 강도에 대한 예측확률 및 발달 시점 등을 잘 재현한 것으로 나타났다(그림 3.17-18).

또한, 개발된 PMME 기법을 개선하기 위한 노력으로 개별모델의 오차를 보정하는 기법(model calibration) 및 모델에 다양한 가중치를 부여하는 기법(model combination)을 적용하여 기존의 방법과 예측력을 비교/평가 하였다. 우선, 본 연구에서 ENSO를 정의하는 데 활용되는 3개월 평균 Nino 3.4 지수의 분포도는 관측과 상이함을 확인하였고(그림 3.19-21), 그 결과 관측과 동일한 임계값으로 ENSO를 정의하는 기존의 방법(M-I) 대신, 관측과 동일한 발생빈도를 가지는 임계값을 모델별/계절별로 새로 정의하여 관측과 모델에서 나타나는 바이어스를 어느 정도 보정할 수 있는 방법(M-II; 그림 3.22)을 제안하였다. 또한, 다양한 MME 기법(PPOOL, PMME_N, PMME_SK; 표 3.4)을 적용하여 Hindcast 및 실시간 예측에 대한 예측력 평가를 수행(HSS, RPSS)하였다. 그 결과, Hindcast 기간에 대해서 M-II는 특히 관측과의 예측확률 차이가 크고, 예측력이 상대적

으로 낮은 계절(봄/여름)에 대해서 예측력 향상이 크게 나타났지만(그림 3.23-24), 실제 예측에서는 M-II의 예측력 향상이 전혀 나타나지 않았다(그림 3.28). 다양한 가중치를 부여한 MME 기법에 따른 예측력 차이 또한 Hindcast 및 실시간 예측 모두에서 유의하지 않은 것으로 나타났다(그림 3.25-26, 그림 3.28).

그렇다면 실시간 예측에서 M-II 기법의 예측력 향상이 나타나지 않은 이유는 무엇인가? 첫째, 과적합 문제(overfitting problem)를 극복하기 위해 예측하고자 하는 해의 정보를 철저히 배제했음에도 불구하고, 과거자료로부터 오는 정보는 과거기간(즉, hindcast 기간)에 대해서만 통계적인 관계를 설명하기 때문에, 실시간 예측 기간에 대한 특징적인 현상에 대해서는 설명하지 못하기 때문이다(즉, 최근 ENSO 발생빈도의 변동성이 과거와 다를 경우). 둘째, Nino 3.4 지수값이 아닌 지수값을 활용한 ENSO 종류 및 강도에 대한 발생빈도 정보를 실시간 예측자료에 활용하기에는 29년이라는 Hindcast 기간이 짧은 것으로 판단된다(특히, 강한 엘니뇨/라니냐 경우). 셋째, 통계기법 자체의 문제가 아닌 짧은 검증기간으로 인해 Hindcast에서 나타나는 안정적인 예측력이 아닌 random한 예측력을 보일 가능성도 있는 것으로 보인다. 특히, ENSO의 특성상 4-5년의 주기를 가지기 때문에 한 번의 주기를 포함하는 4년간의 실시간 예측정보로는 종합적인 예측력 평가에 대한 결론을 내리기는 힘들어 보인다. 또한, 현업적인 측면에서 개발된 예측기술의 경우 실시간 예측에 대한 검증이 얼마나 중요한지를 확인할 수 있었다(그림 3.29). 즉, 일반적으로 활용되는 training period에 대한 검증결과에서 과적합의 문제를 확인하였고, 이를 극복하기 위해 cross-validation 내에서 수행을 하더라도 실시간 예측에서 예측력 향상이 나타나지 않을 수 있음을 또한 확인하였다.

다음으로 model combination 기법들의 예측력 향상을 보이지 않는 이유를 찾기 위해 개별모델 앙상블 평균의 표준오차(standard error, SE)와 개별모델 앙상블 평균의 차이(difference, DF)의 비를 분석한 결과, 적도지역은 $DF > SE$ 크게 나타나며(그림 3.32), 이는 적도지역의 예측력은 개별모델이 해수면온도의 평균을 예측하는 능력에 좌우한다는 것을 의미한다. 이런 경우, 적도지역에서 일관되게 최고의 예측력을 보이는 모델이 있다면 예측력에 가중치를 부여하는 방법이 이론적으로는 예측력을 향상시킬 수 있는 최적의 방법일 것이다. 하지만 실제 현업모델들의 예측력은 계절별/리드별/년도별 민감하게 반응하기 때문에 이러한 상황에서 적도지역의 ENSO 예측력을 향상시키기 위

한 최적의 방법은 평균적인 상태(mean state)에 대해 일반적으로 높은 예측력을 보이는 단순평균기법이 가장 적절하다고 판단된다.

마지막으로, 현업적인 측면에서의 M-II 활용성을 위해 23년 기간에 대한 ENSO 종류 및 강도의 발생확률 민감도 실험을 수행한 결과(23년 이동평균 기후값 실험), Hindcast 기간에 따른 기후값의 차이는 계절별로 다르게 나타나며 특히 가을/겨울철에는 0.2-0.3℃ 정도의 차이를 보이로 이는 예측하는 해의 편차값에도 영향을 미칠수 있는 정도의 차이로 보여진다. 더 나아가, ENSO 종류 및 강도 발생확률에 대해 살펴봤을 때는 중립의 경우 20-80%까지 차이가 나는 것으로 확인되었다. 이는 현재 대부분의 현업기관에서 각기 다른 Hindcast 기간을 정의하고 있으며, 또한 가장 다양한 역학/통계 모델 자료를 활용하여 ENSO 종류에 대한 확률예측정보를 제공하는 IRI/CPC에서 제공받는 자료들은 기관 자체에서 계산한 Nino 3.4 지수의 편차값을 활용하는 경우도 많기 때문에 IRI/CPC에서 제공하는 ENSO Plume의 경우 개별모델간의 예측 spread가 상당히 큰을 확인 할 수 있다. 따라서 본 연구에서 개발된 PMME는 개별모델별로 동일한 기간에 대한 기후값으로 계산된 Nino 3.4 지수를 활용하여 ENSO 종류 및 강도에 대한 예측확률을 제공하기 때문에, 서로 다른 기후값에서 올 수 있는 문제점들에 대해서는 IRI/CPC와 차별성이 있다고 할 수 있다. 이 보다 더 중요한 차별점은 현재 유일하게 ENSO 확률 예측정보를 제공하고 있는 IRI/CPC는 ENSO 강도에 대한 정보는 제공하고 있지 않다는 것이다. 즉, APCC에서 예측한 SST 및 Nino 3.4 지수 예측력은 세계유수 현업기관과 비교 우위(적어도 비슷한 수준)에 있으며, ENSO 강도에 대한 다중모델앙상블 확률예측정보를 제공을 위한 기초적인 연구를 수행하고, 추후 현업시스템개발에 대한 과학적인 자료를 제공할 수 있다는 점에서 본 연구는 상당히 의미가 있다고 볼 수 있다.

4. 전구 가뭄 예측기술 개발

4.1 서론

지금까지 APCC MME 기후예측정보는 주로 기온, 강수, ENSO(해수면온도 포함)에 한정되어 제공되어 왔다. 그러나 최근 계절 예측 정보의 활용성 증대와 계절 규모를 벗어난 예측정보의 필요성이 대두되면서, 새로운 기후예측 콘텐츠 개발이 꾸준히 요구되고 있다(1장 참조). 그 중에 가뭄은 아태지역에서 취약한 수문 관련 이상기후 중 하나이며 장기간 누적된 값을 지표로 하므로, 계절기후 이상의 시간규모에서 전망되어야 하는 기후예측정보 중 하나이다.

센터 내외부의 선행 연구 및 기후예측 서비스 현황을 고려할 때, 대부분의 가뭄예측이 지리적으로 유역 규모 또는 국가 영역에서 진행되고 서비스 되어 왔는데, 그 대표적인 예시가 바로 National Oceanic and Atmospheric Administration(NOAA) Climate Prediction Center(CPC)의 “US Monthly and Seasonal Drought Outlook”이다. NOAA CPC는 그림 4.1과 같은 정보를 <http://www.cpc.ncep.noaa.gov/products/Drought/> 통해 제공하고 있으며, 미국 내 다양한 지역 가뭄 센터³⁰⁾에서 그 자료를 활용 중에 있다. Seasonal Drought Outlook(SDO)를 위해서 사용되는 자료는 CPC 기온/강수 계절전망과 extended-range forecasts(ERFs), 여러 역학 모델의 기후전망(CFSv2, NMME, IRI, IMME, ECMWF), Weather Prediction Center(WPC)의 초-중기 예보와 7일간의 quantitative precipitation forecast(QPF), GFS의 384 시간 동안의 강수 예보, 4개월 동안의 Palmer drought termination and amelioration probabilities, 그 계절의 해당 기후값(climatology)과 초기조건(initial condition)으로, 앞서 언급한 NMME 등 다양한 역학 모형의 계절 전망 자료가 가뭄 전망을 위한 기초자료로 활용되고 있다.

최근 이상기후 및 지구온난화와 더불어 가뭄은 지역규모를 벗어나 전지구적인 문제로 인식³¹⁾되고 있다. 이를 극복하고자 전지구 규모의 기후감시 및 예측자료를 활용한 공동 선제대응이 요구되고 있으며, 그 중 하나로 “전구 가뭄 정보 시스템(Global Drought

30) 예를 들어, Colorado Climate Center(<http://ccc.atmos.colostate.edu/>)

31) <https://www.theguardian.com/global-development-professionals-network/2015/oct/09/why-isnt-there-a-global-body-to-monitor-drought>

Information System, GDIS)”의 필요성이 대두되고 있다(WCRP 2012). 이상적인 가뭄 정보 시스템은 가뭄 탐지부터 준실시간 가뭄 예보와, 중장기 가뭄 전망을 모두 포괄해야 한다. 이를 위해서, 최근 위성기술의 발달과 함께 위성 자료를 기반으로 한 가뭄 탐지 및 준실시간 가뭄 예측 시스템 개발에 대한 연구가 꾸준히 진행되어 왔다. 이 외에도 계절역학모형의 중장기 기후예측자료를 활용한 가뭄 전망이 함께 고려되어야 한다. Hao et al. (2014)은 가뭄 감시와 예측이 결합된 플랫폼인 Global Integrated Drought Monitoring and Prediction System(GIDMaPS; 그림 4.2 참조)을 소개한 바 있으나, 이는 역학모형의 계절기후예측정보의 반영 없이 주로 통계적인 방법에 기반하고 있다. 반면에, Durtra et al. (2014a, b)은 ECMWF System 4 모형을 바탕으로 3, 6, 12개월 Standardized Precipitation Index(SPI; McKee et al. 1993, 1995) 전구 예측을 수행하였으며, Lavaysse et al. (2015)은 ECMWF의 앙상블 시스템을 바탕으로 유럽 지역 가뭄 조기 경보에 대한 연구를 수행한 바 있다. NMME Climate Test Bed(CTB)에서는, MME 자료를 이용하여 실험적으로 전구 가뭄을 예측하고(Kirtman et al. 2013), 그 예측성능을 연구하였다(Yuan and Wood 2013; Mo and Lyon 2015).

APCC는 현재 전구 가뭄 감시 자료만 서비스³²⁾ 중에 있으며, APCC MME 기후예측 자료를 기반으로 하는 새로운 콘텐츠 발굴 및 생산을 고려하여, MME 기후예측자료를 활용한 전지구 가뭄 예측 시스템의 개발 및 현업운영, 예측성 평가가 요구된다. 이에 1차 년도인 2017년에는 “다중모델앙상블을 활용한 전지구 가뭄 예측 시스템 개발 및 예측성 평가”를 목표로 하며, 이를 위해 가뭄 예측에 적합한 가뭄 지수 선정 및 검증 방법을 채택하여 예측 시스템의 성능을 평가하고자 한다. 이는 향후 전구 규모의 계절적 수문관련 이상기후 정보를 제공함으로써, 사전적 대응 및 정책 반영을 위한 기초 체계로의 정보 전달에 기여할 것으로 보인다.

32) <http://www.apcc21.org/ser/global.do?lang=en#grap2>




Figure 4.1. U.S. Seasonal Drought Outlook of NOAA CPC.




Figure 4.2. Global Integrated Drought Monitoring and Prediction System (GIDMaPS).

4.2 가뭄지수의 선정

다중모델앙상블을 활용한 전지구 가뭄 예측 시스템 개발 및 예측성 평가를 위해, 가뭄을 정의하는 표시자(indicator)의 선정이 중요하며, 본 연구에서는 흔히 쓰이는 가뭄 지수를 활용한 방안을 고려 하고자 한다. 가뭄 지수의 선정 기준은 다음 5가지 기준을 가지고 평가하고자 한다.

- ① 사용자에게 친숙한 보편적인 지수인가 ?
- ② 전지구적 측면에서 유용한가?
- ③ 선정에 있어서 당위성이 있는가?
- ④ MME 자료를 바탕으로 변수나 선행시간을 고려할 때 가용할 수 있는가?
- ⑤ 실용적인 측면을 고려 시 예측성이 있는가?

흔히 사용되는 대표적인 가뭄 지수들에 대해서 선행 연구를 먼저 검토하고, 위의 기준에 따라 적합한 가뭄 지수를 선정하고자 한다. 본 연구에서 후보 지수로 고려된 지수들은 보편적으로 사용되는 Palmer Drought Severity Index(PDSI; Palmer 1965), self-calibrated PDSI(sc-PDSI; Wells et al. 2004), SPI, Standardized Precipitation Evapotranspiration Index(SPEI; Vicente-Serrano et al. 2010)의 4가지이며, 각 지수의 특징은 아래 표 4.1에 기술되었다.

Table 4.1. Main characteristics of various drought indices.

Index	Characteristics
PDSI	• landmark • Soil water balance eq. • Wetness (+), dryness (-), based on supply and demand concept • Prior precipitation, moisture supply, runoff, evaporation demand • Strong influence of calibration period, problems in spatial comparability, subjectively in relating drought
sc-PDSI	• Spatially comparable • Fixed temporal scale (between 9 and 12 months), autoregressive
SPI	• Precipitation probabilistic approach
SPEI	• Precipitation and temperature (climatic water balance)

표 4.1에서 나타난 것처럼 해당 가뭄 지수들은 그 입력자료, 계산방법, 정의에 따라 각 가뭄이 나타내는 주요 특징이 다르며, 따라서 그 의미와 용도도 다르다. 가뭄은 그 영향 영역을 고려하여 일반적으로 기상학적(meteorological), 농업적(agricultural), 수문학적(hydrological), 사회학적(sociological) 가뭄으로 나누는데, PDSI는 토양 수분을 고려한 대표적인 수문학적 가뭄지수이며 SPI는 강수만을 고려하여 정의한 기상학적 가뭄이다. 따라서 그 각각의 가뭄지수들의 상세 정보는 다르고 강도나 해석 면에서도 서로 다른 정보를 제공한다. 하지만 일반적으로 같은 정보(예를 들어, 신호나 위상)를 제공하는지 확인하는 것은 지수 선정에 크게 도움이 되므로 이를 위해서 지수들 간의 경향성을 살펴보았다. 즉 한 지수가 가뭄을 나타낼 때, 다른 지수가 여전히 가뭄을 나타내는지 확인하였다. 또한 본 연구는 APCC MME 기후예측자료를 기반으로 전구 가뭄 예측 자료를 생산 및 서비스하는 것을 목표로 하므로, 현업에서 MME의 기후예측자료의 검증자료로 사용하는 관측 자료를 실측(ground truth)으로 보고 이로부터 계산된 가뭄 자료가 다른 가뭄 자료와 일반적으로 같은 정보를 제공하는지 확인하였다.

그림 4.3은 가뭄 지수간의 일관성이나 경향성을 보여주는데, 지수들이 서로 같은 시기에 같은 신호나 위상을 가지는지를 단순하게 확인하기 위해서 지수들 간의 시계열을 가지고 상관도(temporal correlation)를 계산하였다. 각 지수를 계산하기 위한 자료 출처(data source)나 지수를 계산하기 위해 사용된 기간(calibration period)은 서로 다르며, 표 4.2에 요약되었다. 지수간의 상관성 분석은 1983부터 2005년까지의 기간을 이용하여 일관성 혹은 경향성을 확인하였다. 또한 현업에서 이용하는 관측자료(NCEP/NCAR의 기온 및 CAMS OPI)로부터 계산된 가뭄지수들(SPI Calc와 SPEI Calc)과 다른 관측 database에서 가져온 지수들과의 차이점 및 계산된 지수들 간의 관련성도 확인하였다. 그림 4.3에서 양의 값을 가지면 지수들 간 같은 신호나 위상을 가짐을 의미하며, 그 절대 값이 크면 일관성의 정도도 상당히 큼을 나타낸다. PDSI와 SPI는 다른 영역의 가뭄 지수를 나타내지만, 크게는 같은 시기에 유사한 가뭄 정보를 준다(그림 4.3a). 하지만, 새 자료로 계산된 자료인 SPI(Calc)와는 그 일관성이 떨어지고(그림 4.3b), 이는 같은 지수 간인 SPI와 SPI(Calc)에서도 그러한 경향을 볼 수 있다(그림 4.3c). 대부분의 경우에서, 그 강도는 다 다르지만 같은 경향을 나타내고 있음을 알 수 있다(그림 4.3a-h). 하지만 여기에서 주목해서 할 점은 계산된 SPI(Calc)와 SPEI(Calc)의 관련성에서 북반구 내륙 지역은 오히려 반대의 양상으로 dry/wet을 나타냄을 알 수

있다. SPI(Calc)와 SPEI(Calc) 사이의 신호(sign)가 주로 다른 지역은 SPEI를 개발하고 검증한 test-bed(Vicente-Serrano et al. 2010)³³⁾에서 제외되어 있음을 알 수 있다. 또한 이러한 지역은 증발산(evapotranspiration)이 굉장히 작은 지역³⁴⁾으로, 상대적으로 강수의 역할이 증발산에 비해 큰 것으로 추정되어 반대의 경향으로 나타난 것으로 보인다. 또는 관측 증발산이 아닌 기온만으로 증발산을 추정³⁵⁾하는데, 이런 추정치가 다소 상이한 결과를 유도한 것으로 보인다. 같은 맥락으로, SPEI와 같이 water balance를 고려하는 PDSI나 sc-PDSI도 토양 수분 등의 추정 때문에 50도 이상의 고위도에서는 주의를 요한다³⁶⁾. 또한, 하나의 지수에 대해서도(가령, SPI) 관측 자료가 다를 경우, 상이한 결과를 나타냄은 이미 잘 알려져 있다(Sohn et al. 2012a; Mo and Lyon 2015).

MME 기후예측 자료의 가용 변수를 고려하면 SPI와 SPEI를 계산할 수 있는데, SPEI는 증발산 추정과정에서 가정 방법 때문에, 결과에 차이를 보일 수 있다. SPI는 강수 자료만을 사용하므로 상대적인 가정이 작고, 또한 WMO에서 가뭄 감시를 위한 지수로 권고하고 있다³⁷⁾. 따라서 선정기준 대비, 이러한 이유와 조건들을 종합하여 본 연구에서는 가뭄지수로 SPI가 채택되었다. 아울러, 예측 가능한 변수와 예측 선행 시간을 고려하여, 3개월 SPI(SPI3) 및 6개월 SPI(SPI6) 예측을 수행하고 그 예측성을 검증하고자 한다.(본 보고서의 분석 결과는 주로 SPI6에 대해서 나타낸다.) 특히, 3개월 및 6개월은 농업 및 수자원 측면의 가뭄에 영향을 미치는 시간 규모(McKee et al. 1993)로 알려져 있어, 기후자료를 바탕으로 한 응용 연구 분야에서 유용하게 활용 할 수 있다.

33) Vicente-Serrano(2010)은 SPEI를 개발하고, 11 지역(Albuquerque, Tampa, Sao Paulo, Punta Arena, Helsinki, Wien, Valencia, Kimberley, Lahore, Indore, Abashiri)에서 그 품위(performance)를 평가

34) <http://www.ntsg.unt.edu/project/modis/mod16.php>

35) 증발산을 추정하는 여러 방법 중, 여기에서는 Thornthwaite(1948)의 방법을 사용

36) <http://www.cgd.ucar.edu/cas/catalog/climind/pdsi.html>

37) http://www.wmo.int/pages/mediacentre/press_releases/pr_872_en.html




Figure 4.3. Consistency of inter-drought indices. PDSI, sc-PDSI, SPI, and SPEI are taken from different database. SPEI (Calc) is calculated based on 2m air temperature from National Centers for Environmental Prediction–National Center for Atmospheric Research (NCEP–NCAR) reanalysis products (Kalnay et al. 1996) and Climate Anomaly Monitoring System Outgoing Longwave Radiation Precipitation Index (CAMS OPI; Janowiak and Xie 1999). Both SPI and SPEI (or Calc) represent those estimated from 6-month accumulated data.

Table 4.2. Brief data description of various drought indices.

Index	Database	Data Source	Data/Calibration Period
PDSI	https://www.esrl.noaa.gov/psd/data/gridded/data.pdsi.html	Dai dataset (Dai et al. 2004): observed or model monthly surface air temperature (Jones and Moberg, 2003) and precipitation	1870/01 to 2005/12
sc-PDSI	https://www.esrl.noaa.gov/psd/data/gridded/data.pdsi.html	surface air temperature (HadCRUT 4 ³⁸) and precipitation (–1947: Dai et al. (1997), 1948–1978: Chen et al. (2002), 1979–: GPCP v2.2), surface forcing data	Available from 1850–2014, Calibration from 1950–1979
SPEI	http://spei.csic.es/database.html	CRU TS 3.23 dataset	1901–2015
SPI	https://rda.ucar.edu/datasets/ds298.0/	CRU TS 3.21 dataset	1949–2012

38) <http://www.cru.uea.ac.uk/cru/data/temperature>

4.3 전구 가뭄 예측시스템 개발 및 과거기후예측 자료 생산

4.3.1 전구 가뭄 예측시스템

SPI6 예측에 앞서서, APCC MME 계절예측에 참여하고 있는 8개 전구 대기-해양 접합 대순환 모형에서 생산된 월별 강수 예측 자료 평균 및 표준 편차를 강수 관측 자료로 보정하고 3개월 및 6개월 기간에 대해 누적 후 SPI 지수를 계산하였다.

좋은 가뭄 예측 및 경보 시스템을 개발하기 위하여, 가뭄 감시는 중요한 요소이다. APCC의 전구 가뭄 감시 정보 서비스는 $2.5^{\circ} \times 2.5^{\circ}$ 해상도의 월 강수량 자료를 사용하여, 1, 3, 6, 12개월 동안의 SPI의 전구 분포를 제공한다. SPI 계산을 위해서는 Climate Anomaly Monitoring System(CAMS)과 상향장파복사(Outgoing Longwave Radiation, OLR) 강수 지수(Precipitation Index)(OPI)(CAMS OPI; Janowiak and Xie 1999)가 사용되며, 이는 실시간 월별 전구 강수 자료 생산을 위해서 강수게이지로부터의 실측값과 위성 알고리즘으로부터의 추정 값을 합친 강수 분석 자료이다. 또한, CAMS OPI는 실시간으로 월별 자료를 제공하기 때문에 APCC MME 기후예측 자료의 검증을 위해서 사용하고 있다. 따라서 본 연구에서는 월 평균 강수 관측 자료로 CAMS OPI를 사용하였다.

월평균 강수예측 자료는 APCC 월별 6개월 MME 예측에 사용 중인 8개의 전지구 대기-해양 접합 대순환 모형의 과거기후예측으로부터 얻어진다. 표 4.3은 본 연구에 사용된 8개 모형의 목록과 모형 설명을 나타낸다. 본 연구에서 사용된 모든 모형 자료는 공통의 2.5° 위도 $\times$ 2.5° 경도 해상도로 변형되었다. 과거기후예측 및 검증을 위해, 분석 기간은 관측 및 모형의 공통 기간인 1983-2005년을 사용하였다. 모형의 월평균 강수예측 자료는 모형의 평균 및 표준 편차에 대한 계통 오차(systematic bias)를 보정하여, SPI 예측에 사용하였다. 기본적인 평균 편차 보정 방법은 Yoon et al. (2012)과 동일하며, 여기에 표준편차에 대한 편차보정(Sohn et al. 2013)을 추가하였다. 또한, 편차 보정은 모형의 계통 오차를 제거 후, 관측의 평균과 표준편차로 보정 해 주는 방식을 취하였으며, 이 모든 과정은 교차 검증(cross-validation)을 통해 과거기후예측 자료를 재생산하였다. 또한, 월별 강수량의 MME 예측자료를 편차 보정 후 SPI를 예측한 경우(이하, MMEp)와, 보정된 개별 모형 예측자료로 SPI 예측 후 MME를 취한 경우(이하, MMEs)를 비교하였다. 마지막으로, SPI6는 분석기간인 1983-2005년 전체 자료(총 276개 월별 강수 자료 = 23년 $\times$ 12달)로부터 계산되었다.

Table 4.3. Description of the eight coupled climate models used in this study.

Country	Institute	Model	AGCM Resolution	OGCM Resolution	Ensemble Member	Period	Reference
Australia	BoM	POAMA2.4	BAMV3.0d T47L17	ACOM2 0.5–1.5°latx2°lonL25	33	1983–2011	Cottrill et al. 2013
Canada	MSC	CanCM3	AGCM3 T63L31	OGCM4 1.41°lonx0.94°latL40	10	1982–2010	Merryfield et al. 2013
Canada	MSC	CanCM4	AGCM4 T63L31	OGCM4 1.41°lonx0.94°latL40	10	1982–2010	Merryfield et al. 2013
Italy	CMCC	CMCC-SPSv2	ECHAM5.3 T63L19	OPA8.2 ORCA2gridL31	9	1982–2005	Alessandri et al. 2010
Korea	APCC	CCSM3	CAM3 T85L26	POP1.3 Gxv2L40	5	1983–2014	Jeong et al. 2008
Korea	PNU	PNU	CCM3 T42L18	MOM3.0 0.7–2.8latL29	5	1981–2012	Sun and Ahn 2011
USA	NASA	GMAO	GEOS-5 288x181L72	MOM4 720x410L40	11	1982–2011	Ham et al. 2012, 2014
USA	NCEP	CFSv2	GFS T126L64	MOM4 1/3°x1°lonL40	17	1983–2005	Saha et al. 2014

4.3.2 SPI

본 연구에서 가뭄예측을 위해 사용하는 지수인 SPI는 McKee et al. (1993)에 의해 처음으로 제안된 방법으로, 특정기간에 대해서 누적된 강수량을 일단 자료의 분포(distribution)로 변형하는데, 누적 강수량은 보통 Gamma 분포를 가지는 것으로 알려져 있다. 여기에서 얻어진 자료 분포는 다시 동일 확률을 가지는 표준화된 정규 분포로 변형되는 데, 이 값이 바로 SPI 지수이다(그림 4.4 참조). SPI3과 SPI6는 자료 내 전체 분석 기간을 사용하여 계산되었다. SPI 지수 산정을 위한 보다 자세한 방법은 아래와 같다.

4.3.2.1 Gamma 확률분포함수

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta}$$

여기서, α : 형상매개변수(shape parameter)

β : 축척매개변수(scale parameter)

x : 강수량(precipitation amount)

$$\Gamma(\alpha) : \text{Gamma 함수(gamma function)}, \Gamma(\alpha) = \int_0^\infty y^{\alpha-1} e^{-y} dy$$

α 와 β 는 Gamma 확률밀도함수의 계수로서 시간단위에 따라 해당 관측점별로 추정하는데, Thom (1966)의 방법으로 추정한다.

$$\hat{\alpha} = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right)$$

$$\hat{\beta} = \frac{\bar{X}}{\hat{\alpha}}$$

여기서, $A = \ln(\bar{X}) - \frac{\sum \ln(X)}{n}$ n : 강수량 자료의 수

이를 통해 계산된 매개변수를 이용해 대상지점의 시간간격에 대한 강우사상의 누가확률을 계산한다.

4.3.2.2 누가확률 분포함수(Cumulative probability Distribution Function, CDF)

$$G(x) = \int_0^x g(x)dx = \frac{1}{\hat{\beta}^{\hat{\alpha}} \Gamma(\hat{\alpha})} \int_0^x x^{\hat{\alpha}-1} e^{-x/\hat{\beta}} dx$$

$$t = x/\beta \text{ 로 치환, } G(x) = \frac{1}{\Gamma(\hat{\alpha})} \int_0^x t^{\hat{\alpha}-1} e^{-t} dt$$

Gamma 함수는 $x=0$ 에서 정의 되지 않으나 강수분포 0을 나타낼 수 있으므로 누가 함수식을 다음과 같이 혼합 분포형으로 나타낼 수 있다.

$$H(x) = q + (1-q)G(x)$$

여기서, $H(x)$: 누가확률 분포함수

$q = m/n$, q : 무 강우 확률, 강우관측일수(n)에 대한 무 강우일수(m)의 비

추정된 Gamma 함수분포의 매개변수를 이용하여 개개 변량에 대한 누가확률을 산정한 후, 표준정규분포에 적용시켜 표준강수지수를 산정하게 된다.

4.3.2.3 SPI 산정공식

$$Z = SPI = -\left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3}\right), \quad 0 < H(x) \leq 0.5$$

$$\begin{aligned} c_0 &= 2.515517 \\ c_1 &= 0.802853 \\ c_2 &= 0.010328 \end{aligned}$$

$$Z = SPI = +\left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3}\right), \quad 0.5 < H(x) \leq 1.0$$

$$\begin{aligned} d_1 &= 1.432788 \\ d_2 &= 0.189269 \\ d_3 &= 0.001308 \end{aligned}$$

$$t = \sqrt{\ln\left(\frac{1}{(H(x))^2}\right)}, \quad 0 < H(x) \leq 0.5$$

$$t = \sqrt{\ln\left(\frac{1}{(1.0 - H(x))^2}\right)}, \quad 0.5 < H(x) \leq 1.0$$




Figure 4.4. Defining SPI from accumulated precipitation amount.

4.3.3 검증 방법

각 개별 예측 모델 및 두 MME(MMEp와 MMEs)에 대한 SPI 과거기후예측이 1983-2005년을 기준으로, SPI6에 대해서 검증되었다. 어떤 verification measure를 선택하느냐는 검증 결과에 차이를 줄 수 있으므로, 여러 가지 측면에서 포괄적인 검증을 하는 것이 중요하다. 따라서 본 연구에서는 연속된 SPI 값들에 대한 일반적인 예측스킬을 평가하기 위해서 Pearson 상관관계가 이용되었고, 시간적인 변동성(temporal correlation; Barnston 1994)과 공간적인 유사성(spatial correlation)이 함께 고려되었다. Temporal correlation과 아울러 Linear Error in Probability Score(LEPS; Pott et al. 1996)가 함께 고려되었는데, 후자는 실제 자료 공간이 아니라 확률 공간에서의 오차를 평가한다. 또한, 가뭄 사례에 대해서 중점적으로 평가하기 위해서, SPI를 종류와 강도에 대해서 카테고리를 나눈 후(표 4.4 참조), 각각의 이벤트에 대한 예측성을 진단하였다. 검증방법으로는 hit rate, false alarm, threat score 등(Mo and Lyon 2015)을 이용하여, 가뭄 발생, 강도, 범위를 평가하였다.

Table 4.4. Flood/drought conditions categorized according to the SPI value.

SPI values	Category
>2.0	Extremely Wet
1.5 to 1.99	Very Wet
1.0 to 1.49	Moderately Wet
-0.99 to 0.99	Near Normal
-1.0 to -1.49	Moderate Dry
-1.5 to -1.99	Severely Dry
<-2	Extremely Dry

4.4 전구 강수 및 가뭄의 특징

SPI의 변동성은 오로지 강수 변동성에 기초하므로(표 4.1 참조), 전구 강수의 특징을 이해하는 것은 전구 가뭄의 특징을 이해하는 데 있어서 가장 중요한 요소이다. 그림 4.5는 6개월 누적 강수량의 분산(variance) 분포를 보여주는데, 북반구 겨울 또는 여름을 기준으로 반구적으로 상이한 강수 변동성을 보여준다. 북반구 겨울에서는 아프리카 대륙의 남쪽 지역, 동남아시아, 호주, 남미에서 큰 변동성을 보이며, 반대로 북반구 여름에서는 적도 아프리카 지역, 서남아시아, 동남아시아, 동북아시아, 북미 동부지역, 멕시코, 중미, 남미 열대지역에서 큰 강수 변동성을 보인다. 이는 위 지역의 우기 시즌에 해당하는데, 전구적으로 wet summer-dry winter(북반구 기준)으로 요약될 수 있으며, 결국 남아시아, 동아시아, 호주, 북(서) 아프리카, 북/남미 몬순 지역의 변동성을 나타낸다. 따라서 이러한 전구 몬순 시스템(Wang et al. 2012)은 전구적인 물 순환(water cycle)을 결정하는데 중요한 요소임을 알 수 있다.

그림 4.6은 같은 시간규모에서의 관측 SPI로부터 계산된 가뭄의 빈도로, 1983-2005년 전체 기간 동안 SPI6가 -1보다 작은 해(표 4.4 참조)의 수를 나타낸다. 일반적으로 북반구 겨울에는 주로 북반구 내륙에서, 여름에는 아프리카 남쪽 지역, 호주, 남미 전반에서 큰 가뭄 발생 빈도를 보인다. 하지만, 강수변동성이 큰 몬순지역(파란 실선, 6개월 누적 강수량의 분산이 30 mm/day를 초과하는 지역)의 일부에서도 큰 가뭄 발생 빈도를 보인다. 즉, 강수의 wet/dry 이벤트는 서로 비대칭(asymmetric)하게 발생할 수 있다. 이는 강수 자료 자체의 비대칭성 또는 가뭄을 정의할 때 계절적 연속성을 고려하기 때문으로 보인다.

6개월 누적 강수량의 비대칭성을 확인하기 위해서 그림 4.7은 그림 4.5의 동일기간에 대한 전구 왜도(skewness) 분포를 나타낸다. 그림 4.5와 4.6에서 나타난 6개월 누적 강수량의 변동성이나 가뭄 발생 빈도는 반구적 계절성으로 인해 크게 남북이 상이한 분포를 나타냈다. 하지만, 6개월 누적 강수량의 비대칭성은 전구 내륙 모두에서 보이며, 이 기간 동안 누적된 관측 강수의 고유 특성으로 보인다. 남북 지역 간의 차이는 크지 않지만, 계절적인 특성은 있어서 북반구 겨울의 강수자료의 비대칭이 더욱 크다. 두 계절 모두 양의 왜도를 나타내는 데, 이는 가뭄 발생이 용이한 자료 분포를 나타낸다. 특히 아프리카 대륙의 사막 지역이나 기후학적으로 건조한 지역이 양의 왜도가 큼을 알 수 있다. 이는 단순한 강수 정보만으로는 가뭄을 탐지하고 예측하는 데 충분하지 않으며, 이러한 비대칭성을 고려한 가뭄 감시 및 예측시스템이 필요함을 나타낸다.




Figure 4.5. Interannual variance for the 6-month accumulated precipitation, based on (a) NDJFMA and (b) MJJASO.




Figure 4.6. Frequency of drought occurrences based on SPI6 ending in (a) April and (b) October. Blue line denotes the monsoon area with large precipitation variability exceeding 30 mm/day.




Figure 4.7. Same as Figure 4.5 but for skewness.

그림 4.5와 4.6으로부터 전구 강수량자료는 wet/dry 이벤트에 대해서 비대칭(asymmetric)하게 발생하며, 단순한 강수량 예측 정보만으로 가뭄 예측에 적합하지 않음을 알 수 있었고, 이러한 비대칭성을 고려한 가뭄예측이 필요함을 확인하였다. 따라서 관측 및 예측 자료의 기본적인 통계치를 분석하여, 자료 고유의 특성을 비교하는 것이 선행되어야 한다. 표 4.5는 관측 및 모형 자료의 기본적인 통계 특성을 보여준다. 6개월 누적강수량의 전구 평균 관측 자료는 10에 가까운 분산과, 양의 값을 가지는 왜도(0.53)와 첨도(0.17)를 가진다. MME는 관측에 비해 분산은 약간 크게, 왜도와 첨도는 작게 모의하고 있다. 즉, 첨도를 제외한 경향성은 거의 유사하게 모의하고 있다. MME의 경우 관측과 유사한 양의 왜도로 인해, dry event는 잘 모의할 수 있음 나타낸다.

그림 4.8은 관측과 MME 기후예측자료를 기반으로, 6개월 누적 강수량에 대한 왜도와 첨도의 moment ratio 전구 분포를 scatter diagram으로 보여준다. 관측에서는 자료 분포의 흩어짐이 크며, 왜도는 최대 5에 육박하고 첨도는 25에 가까운 값을 가진다. 두 통계치의 비율은 자료의 특성상 2차 항의 곡선을 나타낸다. MME 예측자료도 두 통계치의 비율은 2차 항의 곡선을 나타내지만, 첨도도 훨씬 작고, 왜도도 상대적으로 작아 자료 간 흩어짐이 관측에 비해 작다. 하지만, 관측이나 MME 기후예측 자료에서 자료의 대부분은 두 자료의 평균에 위치해 있고, 두 자료는 대부분의 영역에서 유사한 자료 분포를 가짐을 알 수 있다. 즉 양의 왜도를 가지면서 첨도가 작은 평평한 구조로, 이러한 자료의 비대칭성은 관측과 MME 예측 자료 모두에서 볼 수 있다. 즉 MME 자료의 분포를 고려할 때, dry event는 잘 모의할 수 있지만, wet tail을 예측하는 데는 한계를 가질 수 있음을 암시한다. 결과적으로, MME 예측 자료는 전구 가뭄 예측을 하는데 의미를 가질 수 있음을 나타낸다.

한편, 그림 4.9는 SPI6의 전구 평균 time series를 보여주는데, 명백한 자기 상관에 의한 계절성(Lyon et al. 2012)을 보여준다. 이는 특정기간에 대해서 매월 이동한 누적 강수량을 바탕으로 계산되므로, 이는 이 지수가 가지는 고유의 특성이다. 또한, 이 시계열은 수십년 규모의 경향성(decadal trend)을 보여준다. 다른 선행연구에서는 지역 가뭄 강도는 ENSO와 관련이 있고, 이는 Pacific Decadal Oscillation(PDO)나 Atlantic Multidecadal Oscillation(AMO)에 의해서 변조 될 수 있음(Wang et al. 2014; Hu and Feng 2012)을 밝힌 바 있다. 여기서 주목 할 점은 SPI6의 변동성은 MME(여기에 사용된 자료는 MMEp) SPI³⁹⁾ 예측의 LEPS 변동성과 관련이 있다. 두 시계열은 음의 상관관계를 가지면서, 특히 가뭄(음의 값) 일 때 큰 예측성을 보임을 알 수 있다. 그림 4.9b는 전구에서 가뭄을 차지하는 비율을 나타내는데, SPI 값과 마찬가지로 수십년 규모의 경향성 및 계절성을 가진다. 특히, 전구에서의 가뭄 범위는 전구 평균된 LEPS와 더 큰 상관성을 가지며, 예측성의 대부분은 가뭄에 의해 좌우됨을 다시 한 번 확인할 수 있다. 이는 MME 기후예측자료를 기반으로 한 가뭄예측이 잠재적인 예측성을 가질 수 있으며, 유용한 가뭄 예측 자료로 활용될 수 있음을 시사한다.(실제 예측성은 4.6절 이후부터 고려하기로 한다.)





Figure 4.8. Moment ratio diagram for accumulated precipitation at 6 months based on (left) observations and (right) MME prediction. Red dots denote the mean of whole samples.

39) 4.4절의 MME SPI 예측자료는 MMEp를 의미

Table 4.5. Global mean of basic statistics of accumulated precipitation at 6 months.

	OBS	MME	APCC	CMCC	CANCM3	CANCM4	NASA	NCEP	PNU	POAMA
Variance	9.84	11.55	10.02	10.34	10.17	10.81	10.61	10.3	9.97	11.3
Skewness	0.53	0.41	0.36	0.43	0.39	0.44	0.43	0.36	0.42	0.48
Kurtosis	0.17	-0.09	-0.29	-0.11	-0.27	-0.07	-0.03	-0.25	-0.19	0.04

**Figure 4.9.** (a) Time series of the observed SPI6 (left; shaded) and LEPS of MME-simulated SPI6 (right; blue dashed line) averaged over the globe. The temporal correlation between the two time series is given at the upper right. (b) Same as Figure 4.9a but for global extent.

4.5 전구 육지 지역에 대한 강수 예측 성능

전구 관측 강수의 특징을 이해하고 파악하는 것과는 별도로, 신뢰성 있는 전구 가뭄 예측의 핵심은 월/계절별 강수 예측 스킬을 제대로 평가하고 진단하는 것이다. 그러므로 SPI를 고려하기 전에, 전지구 강수 예측 성능이 먼저 평가되었다. 그림 4.10은 APCC MME 예측시스템의 월 평균 강수량의 예측성을 나타내는데, 일반적으로 월평균 강수 전구 모의 능력에 있어서는, 계절성은 크게 나타나지 않음을 알 수 있다. 대신에, 지역적인 편차가 크게 나타나는데, 적도 지역의 강수 예측성이 크게 나타나며, 이 지역은 역학 모형의 잠재 예측성(potential predictability)이 큰 지역으로도 잘 알려져 있다(Kang et al. 2004). 특히 그 중에서도 열대 태평양의 예측성이 가장 높으며, 이러한 예측성은 ENSO 변동성에 크게 기인하는 하는 것으로 알려져 있다(Sohn, 2016).

하지만, 전구 가뭄 예측에서 가장 중요한 요소는 육지 강수예측 정보이므로, 해양을 제외한 육지(in-land) 지역에서의 강수예측성이 다시 평가 되었다(그림 4.11 참조). 전 지구 예측성(0.15~0.18)과 육지 지역만의 예측성(0.10~0.12)을 비교 할 때, 육지 지역의 예측성이 다소 낮아진 경향이 있으나, 그 차이(0.05~0.06)가 그리 크지 않으며, 이렇다 할 계절성도 발견되지 않는다. 결국 그림 4.10과 4.11의 예측성의 차이는 열대 태평양에서 나타나는 큰 규모의 순환장 패턴을 가진 높은 예측성에서 비롯하는데, 이는 ENSO와 같은 주요 기후 모드에 의해 영향을 받음을 알 수 있다. 반면에 육지에서의 예측성은 큰 규모의 순환 패턴은 보이지 않고, 지역 간(location-to-location) 편차가 다소 커서 모자이크한 양상을 보인다. 이는 육지 강수는 특정 대규모 순환장의 영향을 받을 수도 있지만, 오히려 그 지역의 지역성(locality)에 더 기인하며, 따라서 역학 모형의 재현 능력도 해당 기간이나 지역에 따라 크게 다를 수 있다.

또한, 역학 모형의 강수예측성은 크게 반구적인 차이를 보이는데, 북반구의 예측성은 전지구 예측성과 유사하나 약간 미치지 못하는 수준이지만, 남반구의 경우 상대적으로 높은 예측성을 나타낸다(그림 4.12 참조). 개별 모델 간 차이(inter-model spread)도 상당히 크게 나타나며, 이는 역학모형의 육지 강수 예측성이 서로 크게 상이함을 알 수 있다. 즉, 주요 기후 모드의 영향이 크지 않고 지역성이 더 큰 경우, 모델 간 재현성의 편차가 큼을 말한다. 그럼에도 불구하고, MME는 일반적으로 개별모형의 성능보다 높은 수준의 예측 성능을 보여줌으로써, 향후 가뭄 예측 시스템에서 개별 모형에 비해 유용한 정보로 활용될 수 있음을 시사한다.




Figure 4.10. Global distribution of temporal correlation coefficient (TCC) between observations and the MME prediction for (a) January, (b) April, (c) July, and (d) October. Values with absolute magnitudes of 0.526, 0.413, 0.352, and 0.277 represent the 99%, 95%, 90%, and 80% confidence levels, respectively. The area-averaged value over the globe are provided in upper right of each panel.




Figure 4.11. Same as Figure 4.10 but for global terrestrial region.




Figure 4.12. Area-averaged values of TCC between observations and simulations, over the terrestrial region of (a) globe, (b) northern hemisphere, and (c) southern hemisphere, from January to December. Hatched bars in purple and plain bars in sky blue denote the MME and model prediction, respectively. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models.

그림 4.13은 APCC MME 월평균 강수의 공간적인 유사성에 대한 예측성을 나타낸다. 시간적인 변동성에 대한 재현능력과 마찬가지로, 공간적인 유사성에 있어서도 계절적 변동성은 보이지 않으며, 모델 간 차이가 상당히 큼을 알 수 있는데, 이는 지역(location)별 강수 변동성을 재현하는 능력이 모델 별로 크게 상이하고, 결국 전구 육지에서의 전반적인 강수 분포를 모형이 서로 다르게 모의함을 알 수 있다. 그럼에도 불구하고

고 MME는 일반적으로 개별모형에 비해 높은 스킬을 나타냄으로서, 전구 육지의 강수 분포를 예측하는데 있어서도 높은 예측성을 나타냄을 알 수 있다.




Figure 4.13. Time-averaged values of pattern correlation coefficient (PCC) between observations and simulations, during the period of 1983–2005 for (a) January, (b) April, (c) July, and (d) October. Hatched bars in purple and plain bars in sky blue denote the MME and model prediction, respectively. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models. The mean values of the MME and model prediction are provided in upper right of each panel.

4.6 평균 및 분산을 고려한 기후학적 편차 보정

본 연구에서 개발 중인 전구 가뭄 예측시스템에서는 모형의 월평균 강수예측 자료에 모형의 평균 및 표준 편차에 대한 계통 오차(systematic bias)를 보정하여, SPI 예측에 사용하였다(4.3.1절 참조). 기본적인 보정 방법은 Yoon et al. (2012)과 동일하며, 여기에 표준편차에 대한 편차보정(Sohn et al. 2013)을 추가하여, 평균과 보정한 경우와 평균과 분산을 함께 보정한 경우의 차이에 대해서 분석하였다. 편차 보정 과정은 모형의 계통 오차를 제거 후, 관측의 평균과 표준편차로 보정 해 주는 방식을 취하였으며, 이 모든 과정은 교차 검증(cross-validation)을 통해 과거기후예측 자료를 재생산하였다. 또한, 월별 강수량의 MME 예측자료를 편차 보정 후 SPI를 예측한 경우(이하, MMEp)와, 보정된 개별 모형 예측자료로 SPI 예측 후 MME를 취한 경우(이하, MMEs; Mo and Lyon 2015)를 비교하였다.

북미 지역에서 발생한 1988-89년 가뭄⁴⁰⁾은 역사상 가장 심각한 가뭄 중에 하나로 알려져 있으며, SPI는 이러한 가뭄 사상을 잘 나타내고 있다(그림 4.14 참조). 5-10월의 누적 강수량을 기준으로 할 때, 북서 지역을 제외한 대부분의 미국 지역과 캐나다 중부에서부터 동부 전역까지 가뭄이 관찰되었으며 캐나다 중부 지역은 심각한 가뭄 강도를 나타내었다. 대부분의 역학 모형들은 이러한 가뭄 패턴을 전반적으로 잘 나타내고 있으나(pattern correlation: 0.46~0.70), 전반적으로 지역적인 차이점을 상세하게 묘사하는 것과 해당 강도에 있어서는 서로 다르게 예측하고 있다. 가령, 일부 모형들은 실제로는 발생하지 않은 홍수 사상을 모의하기도 하고(CMCC, PNU), 캐나다 중부의 강한 가뭄(severe drought)을 오히려 과대 모의하기도 한다(CMCC). 일반적으로 MME는 개별 모형의 결과에 비해 향상된 모의 능력을 보여주는데(0.69~0.71), 특히 일부 모형에서 잘못 예측한 홍수 사상은 나타나지 않았다. 또한 가뭄의 강도나 위치에 있어서도 대체로 관측 패턴과 일치하는 하는 것을 알 수 있다. 이러한 두 가지 요소에 의해 MME는 개별 모형에 비해 향상된 예측 결과를 나타내는 것으로 보여 진다. 하지만, MME와 SPI 계산을 언제 하느냐에 따라 매우 근소한 차이를 보여 준다(MMEp와 MMEs).

40) https://en.wikipedia.org/wiki/1988%E2%80%9989_North_American_drought




Figure 4.14. Spatial maps of SPI6 ending in October 1988 over the North American Continent based on (a) observation and raw predictions without any calibration from (b) MMEp, (c) MMEs, (d) APCC, (e) CMCC, (f) CANCM3, (g) CANCM4, (h) NASA, (i) NCEP, (j) PNU, and (k) POAMA. The PCCs between observations and predictions are shown at the upper right of the panels, from (b) to (k).

그림 4.15와 4.16은 동일 기간에 대해서 편차 보정을 수행한 결과를 보여주는데, 편차 보정 이후에 일반적으로 예측성이 향상되었음을 알 수 있다(평균 보정: 0.65~0.77, 평균과 분산 보정: 0.63~0.76). 특히 예측성이 가장 낮았던 POAMA 모형의 경우 그 예측 향상율이 가장 크고, 원래 예측성이 높았던 MME는 그에 미치지 못하는 것 하지만 일반적으로 개선된 것을 알 수 있다. 특히 보정된 개별 모형 예측자료로 SPI 예측 후 MME를 취한 경우(MMEs)가 강수량의 MME 예측자료를 편차 보정 후 SPI를 예측한 경우(MMEp) 보다 좀 더 나은 예측성을 보이는 것을 알 수 있다. 하지만, 강도에 있어서는

편차 보정 후에 extreme한 지역을 좀 더 과대 모의하는 경향이 있는 것으로 보인다. 평균 대 평균과 분산 보정을 하는 경우의 차이를 살펴보면, 1998년 북미 가뭄을 예측하는 데 있어서는 단순히 평균만 보정하는 것이 평균과 분산을 함께 보정하는 것에 약간 더 나은 예측성을 보였다. 즉 가뭄과 같은 extreme한 사상을 예측하는 데 있어서는 분산을 고려하는 것은 크게 영향을 미치지 않는 것으로 보인다. 이는 가뭄을 고려할 때 강수의 분포를 정규분포로 고려하지 않고 한쪽이 기울어진 감마 분포로 가정하기 때문으로 사료된다.




Figure 4.15. Same as Figure 4.14 but for the bias-corrected predictions with observed climatological mean.




Figure 4.16. Same as Figure 4.14 but for the bias-corrected predictions with observed climatological mean and variance.

위의 사례들을 전반적으로 요약하기 위해서, 그림 4.17에서 전지구와 북미대륙에 대해서 temporal correlation의 영역 평균과 spatial correlation의 전체 분석기간 평균을 나타내었다. 두 지역 모두에서, 무보정한 모형 결과들은 굉장히 넓은 분포를 가지면서 보정한 결과들에 비해 낮은 예측성을 보여준다. 이러한 요소들은 보정 후에 크게 개선되어, 보정한 모형 결과들은 예측성능의 차이에 있어서 서로 간에 좁은 분포를 보여준다. 특히 예측성이 낮을수록 개선 비율이 큰 것으로 보인다. 강수 MME를 보정 후 SPI를 계산한 MMEp의 경우, 평균만 보정한 경우가 평균과 분산을 함께 보정한 경우보다 훨씬 좋은 예측성을 보여주었고, 개별 모형을 보정한 후에 SPI를 계산하고 그 평균을 취하는 MMEs의 경우에는 두 방법(즉, 평균만 보정, 평균과 분산을 함께 보정) 간에 유사한 예측

성능을 보이면서, 보정 방법에 덜 영향을 받는 것으로 보인다. 특히 평균만 보정하는 경우에 MMEp와 MMEs가 유사한 예측성능을 보여주는 것을 확인할 수 있는데, 이는 이 방법이 MME와 SPI의 계산 순서에 덜 영향을 주는 안정적인 방법으로 사료된다.




Figure 4.17. TCC (x-axis) and PCC (y-axis) skills between observations and various prediction for SPI6 for the domain of (a) globe and (b) North American continent. TCC skill denotes the area-averaged over the domain and PCC skill denotes the time-averaged for the whole period of 1983–2003. The non-calibrated, mean, mean and variance-calibrated predictions are presented in gray-black, sky blue-purple, orange-red, respectively. The individual models, the MMEp and MMEs denote thin open, thick open, closed circles, respectively. The respective dotted lines denote the spread of the model and MME predictions for each calibration method.

그림 4.18과 4.19는 두 보정기법의 예측성능과 오차를 보여주는데, 평균만 보정했을 경우에 MMEp와 MMEs의 예측 성능은 매우 유사한 것을 알 수 있다(그림 4.17의 결과와 동일). 전반적으로 아주 일부 지역을 제외하고는 전지구적으로 매우 높은 예측성능을 보여주고 있으며, 이러한 예측 능력은 SPI 시계열의 자기상관과 관련이 있다(이 점은 다음 장에서 다시 논의). 북서아프리카 일부지역, 서러시아, 서아시아, 서남아시아, 남미

남쪽 지역에서 상대적으로 낮은 예측 성능을 보여 주고 있으며, 마찬가지로 동일 지역에서 예측오차가 큰 것을 알 수 있다. 이러한 예측 오차는 평균과 분산을 동시에 적용하여 보정하였을 경우 더 커지는 것을 알 수 있으며, 같은 지역의 예측 성능도 낮아지는 것을 확인할 수 있다. 사실 MMEs의 경우, 평균만 보정하였을 경우나 평균과 분산을 함께 보정하는 경우 매우 유사한 정도의 예측 성능과 오차를 보여주는데, SPI처럼 정규화 된 (standardized) 지수를 다루는 경우 분산의 영향을 덜 받는 것으로 보인다. 하지만, 강수의 평균과 분산을 보정할 경우 자료 분포에 영향을 크게 주어, MMEp와 MMEs의 예측성능이나 오차에 다소 차이가 나타나는 것으로 보인다.

그림 4.20은 두 보정기법의 예측성능과 오차를 전구 평균하여 개별 모형 및 MME에 대해서 비교한 그림으로, 종전과 동일하게 MMEs의 경우에는 보정 기법의 영향을 크게 받지 않고, 유사한 예측 성능과 오차를 나타내는 것으로 보인다. 하지만, MMEp의 경우에 그 차이가 다소 크며, 평균만 보정하였을 경우가 평균과 분산을 함께 보정하였을 경우에 비해 좀 더 높은 예측성과 작은 예측 오차를 가지는 것으로 보여 진다. 강수를 정규분포 기준으로 그 분산을 보정(inflation) 하고 그 다음 지수 계산을 하는 방법은 가뭄예측에서는 실효성이 크게 없음을 알 수 있다. 분산을 보정하는 inflation에서는 모델간의 예측성능 차이는 작아진 것을 볼 수 있지만, MMEp에서의 예측성 향상이나 오차 보정은 그리 크지 않은 것을 알 수 있다. 두 편차 보정기법에 따른 예측성능과 오차의 차이를 구해보면, 단순히 평균만 보정한 것이 분산과 함께 보정한 기법보다 높은 예측성과 작은 오차를 보이며, 이는 개별 모형이나 MMEs에서는 그 차이가 미비하나 MMEp에서는 월등히 크다. 따라서 본 연구에서는 향후 전구 MME 가뭄 예측시스템의 개발을 위해 평균만을 이용하여 계통오차를 보정한 방법을 사용할 것이며, 뒤에 나오는 결과들은 이 보정 기법의 결과를 바탕으로 한다.




Figure 4.18. (a, c) TCC skill and (b, d) root mean square errors, between observations and the mean-calibrated predictions, of SPI6 for (a, b) MMEp and (c, d) MMEs.




Figure 4.19. Same as Figure 4.18 but for the mean and variance-calibrated predictions.




Figure 4.20. (a) Area-averaged TCC (x-axis) and RMSE (y-axis) of the mean (mean and variance)-calibrated prediction in blue sky-purple (in orange-red) with observations for global SPI6. (b) The difference between mean-calibrated and mean and variance-calibrated TCC and RMSE. Various marks in the legend denote two MME and their member models. High TCC skill and low RMSE is denoted by the rectangle surrounded by red dotted lines in (b).

4.7 가뭄지수의 일반적인 예측성능

SPI 과거기후예측이 교차검증을 통해 1983-2005년 동안, 각 모형 및 두 MME(MMEp와 MMEs)에 대해서 수행되었으며, 가뭄예측의 일반적인 예측성능을 평가하기 위해서 SPI6의 전체 시계열에 대해서 검증되었다. 그림 4.21은 두 MME에 대한 전체예측기간에 대한 예측성능을 나타내는데, 대부분의 육지지역에서 높은 상관관계를 나타내며(북서 아프리카, 서러시아, 서아시아, 서남 아시아 일부 지역, 남미 대륙의 남쪽 지역을 제외), 이는 통계적으로 5%에서 유의한 값이다(a-b). 이 분석에서 분석기간 동안의 전체 시계열을 바탕으로 상관성을 계산하였기 때문에, SPI 지수의 자기상관적인 특성으로 인해 높은 예측성을 나타낸다.

따라서 예측시스템의 성능을 제대로 파악하기 위해서, persistent run 대비 예측성능의 향상을 분석하였다(그림 4.21 c-d). persistent run은 강수자료의 자기상관성에 기

초하여 설계된 실험으로 본 연구에서는 persistent run의 성능을 역학 모형의 예측시스템의 성능 향상을 평가하기 위한 대비군(baseline skill)으로 사용하였다. 그 두 차이는 결국 성능 향상(skill improvement)을 나타낸다. 아울러 Fisher's Z transformation(Quan et al. 2012)을 사용하여 두 상관관계의 차에 대한 유의 수준을 평가하였으며, 보다 자세한 설명한 Mo and Lyon (2015)에 나타나있다. 일반적인 예측성능과 마찬가지로 5%에서 유의한 수준에서 대부분의 지역에서 persistent run에 비해 성능 향상이 된 것을 알 수 있다. 또한 원래 성능이 낮은 지역(북서 아프리카, 서러시아, 서아시아, 서남 아시아 일부 지역의, 남미 대륙의 남쪽 지역)은 persistent run과 비교했을 때에도 성능향상을 기대하기 어려움을 알 수 있다.




Figure 4.21. (a, b) TCC skills of the mean calibrated predictions from (a) MMEp and (b) MMEs with observations for global SPI6. (c, d) Improvement of TCC skills from (c) MMEp and (d) MMEs, compared to baseline skill of persistent run. Shading denotes the value exceeding the 95% significance level.

그림 4.22는 각 모형 및 두 MME에 대한 가뭄예측시스템의 예측향상도를 나타내는데, 양수일 경우, persistent run 보다 개선됨을 나타낸다. 분석기간 동안의 전체 시계열을 다 고려할 경우, 각 모형 및 MME 예측성능이 크게 향상되었음을 알 수 있다. 개별 모형의 경우도 persistent run에 비해 그 성능이 향상된 것을 확인할 수 있으며, 특히 MME의 경우에는 그 향상 폭이 가장 크며 두 MME 사이의 차이는 그리 크지 않음을 알 수 있다. 11월 초기조건으로 한 DJFMAM 기간 동안의 가뭄 예측의 경우, 모형간 성능의 분포(spread)가 굉장히 크며, 오히려 persistent run에 비해 성능이 떨어지기도 한다. 특히 여기에서는 매해 DJFMAM의 예측결과만 사용하였기 때문에, 자기상관성이 큰 전체시계열을 사용하였을 경우 보다는 자료 독립성이 커지고 자기상관에 의한 영향은 줄어들었다고 할 수 있다. 그럼에도 불구하고 MME 기반 가뭄 예측은 성능향상을 보이고 있다. 2월 초기조건인 경우에도 MME 기반의 가뭄 예측시스템은 안정적인 성능향상을 보여주고 있다.




Figure 4.22. Global mean of skill improvement from the model and MME predictions of SPI6 for (a) the whole period and initiated in (b) November and (c) February. Various marks in the legend denote two MME and their member models.

지금까지는 시간적인 변동성에 대한 가뭄예측시스템의 예측성을 살펴보았다면, 다음은 공간적인 패턴의 재현성에 대한 일반적인 예측성능을 점검해보고자 한다. 그림 4.23은 전구 pattern correlation을 바탕으로 한 예측성능을 보여주는데, 해마다 계절마다 변폭이 큼을 알 수 있다. 그 중 persistent run이 가장 낮은 예측성을 보여주며 최근

십년간에 오히려 그 성능이 감쇠하는 경향을 보여준다. 역학 모형의 경우에는 이러한 경향성(trend)은 없지만, 모형 간 성능 분포(spread)가 굉장히 큰 것을 알 수 있다. 그림에도 불구하고 MME 기반의 가뭄예측시스템은 가장 우수한 성능을 보여주며, MMEp와 MMEs 두 방법의 차이는 크지 않다. 가뭄의 시간적인 변동성을 재현하는 데는 persistent run이 역학 모형에 비해 때로는 더 나을 때도 있지만(그림 4.22 참조), 가뭄의 공간적 분포를 재현하는 데는 그 한계가 큼을 알 수 있다. 즉 역학 모형은 가뭄의 시·공간 변동성이나 분포를 예측하는데 적합하며, 특히 MME는 그 성능이 비교적 안정적이다. 하지만, 이 분석들은 가뭄 이외의 경우를 다 포함하는 SPI 지수의 전체 시계열을 다 고려하여 분석한 결과이므로 다음 장에서는 가뭄이 발생한 경우에 한하여, 이벤트 위주의 분석을 하고자 한다.




Figure 4.23. (Left) PCC skills of the various predictions for the global SPI6 during the whole period from 1983 to 2005, and the time-averaged value. The numbers from 1 to 11 in the right panel and legend indicate the MME and its member models. The corresponding colors between left and right panels denote the same model prediction

4.8 가뭄의 주요 특징과 관련된 예측성능

앞 절에서는 SPI의 일반적인 예측성에 대해서 살펴보았으며, 이번 장부터는 가뭄과 관련된 주요특징들의 예측성능을 검증하고자 한다. 본 연구에서 고려된 가뭄의 주요 특징은 가뭄 이벤트의 발생, 강도, 그리고 공간적 분포에 대해서 검증하였고, 자료의 샘플 수가 적은 관계로 시·종이나 지속기간은 고려되지 않았다. 표 4.4에 나타난 분류처럼

SPI가 -1.0 이하로 떨어질 때 가뭄 이벤트로 정의하고, 이 후에 강도나 분포에 대해서도 검증하였다. 시·종이나 지속기간은 고려되지 않으므로, 이벤트의 연속성은 고려하지 않고 매 달 기준으로 이벤트가 생겼을 때를 한 사례로 보고, contingency table을 구성하고 categorical 자료 분석을 수행하였다.

4.8.1 가뭄 발생

그림 4.24는 두 MME의 가뭄 발생 예측에 대한 hit rate, false alarm, threat score의 전구 분포를 나타낸다. hit rate는 발생한 전체 이벤트 가운데, 모형이 그 이벤트를 예측한 경우를 나타낸다. 따라서 hit rate는 모형이 그 이벤트를 예측하지 못한 경우(missed event)에 민감하며, 모형이 드문 이벤트에 과대 모의하면 hit rate도 과대 추정된다. False alarm은 모형이 예측한 전체 이벤트 가운데 잘못 예측한 경우를 나타내며, 놓친 이벤트를 나타내는 것은 아니다. 이벤트가 드문 경우에 과소 모의 되는 것에 의해 값이 향상 될 수 있다. 따라서 이 두 검증 방법은 항상 함께 사용하고 비교해야 한다. SPI 예측의 일반적인 성능(즉 temporal correlation)에서 예측성능이 높았던 지역(북동 아프리카, 중앙아시아, 동아시아, 북미 중앙지역 등)이 hit rate에서도 높은 것을 알 수 있다. 즉 이 지역에서 역학 모형의 예측성이 일관되게 높음을 알 수 있다. 두 MME 간의 차이는 그리 크지 않으나, 미세하게 MMEp의 성능이(특히 중앙 러시아와 중국 북쪽 지역에서) MMEs의 성능보다 높음을 알 수 있다. hit rate가 높은 지역에서 false alarm이 낮고, 결국 모형이 가뭄을 잘 감지 또는 예측하는 지역에서 틀리게 예보하는 사례도 적음을 알 수 있다. 일반적인 예측성능에서 RMSE가 컸던 지역에서, 모형이 가뭄을 잘못 경고하는 경우(즉 false alarm이 높은 경우)가 많음을 알 수 있다. 따라서 이 두 가지의 경우를 복합적으로 나타내고 있는 threat score에서 동일한 검증 결과를 확인할 수 있다.

그림 4.25는 각 모형과 두 MME의 가뭄 발생 예측에 대한 다양한 검증 결과들의 전구 평균을 나타내는데, PoD(Probability Of Detection), FAR(False Alarm Rate), CSI(Critical Success Index)는 각각 hit rate, false alarm, threat score를 의미한다. persistent run의 경우, 굉장히 낮은 hit rate, 높은 false alarm을 보이면서 결국 예측 결과들 중에서 가장 낮은 threat score를 보인다. 역학 모형의 경우는 그 어떤 모

형이라도 persistent run 보다는 나은 결과를 보이는데, 이런 점들이 결국 전체(일반적인) 예측성 향상에 기여한 것으로 보인다(그림 4.21 참조). 일단 두 MME의 결과는 일반적으로 개별 모형의 결과에 비해 그 성능이 우수하다. 특히 두 MME 중에서는 MMEp가 MMEs의 결과보다 나은 결과를 보이는데, MMEs의 경우 SPI 계산 후 평균을 취하므로 각 모형들이 서로 다르게 예측한 event들이 상쇄 될 수 있음에 기인한 것으로 보인다. 따라서 가뭄을 감지 및 예측하는 데에는 MME 강수 자료를 보정 후에 SPI를 계산하는 방법이 가뭄과 같은 이상기후를 감지하고 예측하는 데 있어서 좀 더 효과적인 방법으로 사료된다.




Figure 4.24. Verification skills of categorical forecast of (a, c, e) MMEp and (b, d, f) MMEs for drought occurrence, based on (a, b) hit rate, (c, d) false alarm, and (e, f) threat score.




Figure 4.25. Global mean of various verification skills of categorical forecast of individual models and their MME for drought occurrence. The numbers from 1 to 11 in the figure and legend indicate the MME and its member models.

4.8.2 가뭄 강도

가뭄의 경우에 발생 뿐 만 아니라 강도에 의해서도 구분 될 수 있는데, SPI가 -1.5이하 일 경우 severe drought로, -2.0 이하일 경우에는 extreme drought로 분류 된다(표 4.4 참조). 두 강한 가뭄의 예측결과에 대해서 분석한 결과가 그림 4.26에 나타난다. 강한 가뭄의 경우에 사례 수가 전체 가뭄의 발생 빈도보다 적기 때문에 전반적인 예측성은 좀 전의 가뭄 발생에 대한 결과(그림 4.24 참조) 보다 예측성이 떨어짐을 알 수 있다. Severe 가뭄의 경우, 아프리카 중앙 지역, 북동아시아, 북미 중앙 지역에서 높은 hit rate와 threat score를 보여준다. 아프리카 일부 지역, 서남아시아, 미국 남쪽 지역 등에서 모형이 강한 이벤트를 잘못 예측하여 높은 false alarm을 볼 수 있는데, 이 지역은 대체로 bias도 큰 것을 알 수 있다. Bias는 관측 발생 빈도에 대한 모형의 예측 빈도를 나타내는데, 결과적으로 best score는 1이며 결과적의 모형의 신뢰도(reliability)를 나타낸다. 즉 관측이 실제로 발생한 수 보다 모형이 그 사례를 잘못 많이 예측하고 있어서 false alarm도 크고, 결국 bias도 1이 넘는 큰 값을 나타내고 있다. extreme drought의 경우에는 그 사례가 훨씬 적기 때문에, severe drought에 비해 예측성이 확실히 떨어지는 것을 알 수 있다. 특히 전체 예측 중에서 hit rate의 비율보다, false alarms의 경우가 높으면서, threat score도 작고 bias도 관측에 비해 과소 또는 과대 모의하는 경우가 많음을 알 수 있다.




Figure 4.26. Verification skills of categorical forecast for (a, c, e, g) severe and (b, d, f, h) extreme drought, based on (a, b) hit rate, (c, d) false alarm, (e, f) threat score, and (g, h) bias.

이러한 특징을 개별 모형들과 두 MME에 대해서 살펴보고자 전구 평균한 값을 그림 4.27에 나타내었다. Severe 가뭄을 감지(detect)하는 능력은 역학 모형의 경우, persistent에 비해 우세하고 대신 오측하는 사례는 역학 모형과 비슷하거나 오히려 작다. 결과적으로 threat score에 있어서 역학 모형이 좀 더 높은 예측 성능을 보여 줄 수 있다. 두 MME 중에서, MMEp는 MMEs 보다 안정적인 성능을 보여주면서, 그 어떤 개별모형에 비해서도 나은 결과를 보여준다. Severe drought를 예측하는 데 있어서는 개별모형과 유사한 수준의 bias를 보여주지만, extreme drought를 예측할 때는 관측과 가장 유사한 빈도를 예측하면서, bias가 거의 1에 가까운 값을 나타낸다. MMEs

는 각 모형의 지수들을 평균함으로 인해 강한 가뭄을 감지하는 능력이 떨어짐을 알 수 있는데, 특히 그 빈도 면에서 과소 모의함으로 인해 모든 검증 결과에 있어서 낮은 값을 나타낸다. Extreme drought에 있어서, 그러한 현상은 좀 더 심해서 persistent run이 잘못 과대 모의하는 비율만큼 MMEs는 과소 모의하고 있다. 그래서 잘못 예측하는 false alarm도 작지만, hit rate이나 threat score도 가장 작은 값을 나타낸다.




Figure 4.27. Global mean of various verification skills of categorical forecast of individual models and their MME for (a) severe and (b) extreme drought. The numbers from 1 to 11 in the figure and legend indicate the MME and its member models

4.8.3 가뭄 범위

지금까지는 가뭄 발생과 강도의 시간적인 변동성에 대해서 contingency table을 구성하고, 그 예측성능을 평가하였다. 하지만 가뭄을 제시간에 감지 및 예측하는 것도 중요하지만 공간적인 분포에 대해서도 검증하는 것이 중요하다. 따라서 본 절에서는 전구 가뭄에 대해서 범위를 어떻게 예측하는지를 공간에 대해서 contingency table 구성하여 그 성능을 평가하였다. 이 경우 매해 값을 얻을 수 있고, 그림 4.28은 그 검증결과들의 시간 변동성과 그 전체 평균을 나타낸다. 검증 지수의 변동성이 크므로, 그 평균값을 기준으로 살펴보면 공간적으로 MMEp는 가장 높은 예측성능을 보여준다. hit rate도 사용된 모형 자료 중에 가장 높은 값을 나타내며, false alarm은 비교적 낮은 경우에 속한다. 따라서 threat score의 경우 가장 높은 값을 나타내며 bias도 가장 1에 가까우면서 가장 안정적인 성능을 보여준다. 근소한 차이로 MMEs는 개별모형에 비해 일반적으로 높은 성능을 보여주지만, 가장 낮은 bias 값을 보여주면서, 여전히 관측에 비해서 과소 모의하는 경향이 있음을 보여준다.

그림 4.29는 severe drought와 extreme drought에 대한 가뭄 범위를 검증한 결과이다. 종전의 결과와 동일하게 가뭄의 강도가 강해질수록 그 범위를 예측하는데 있어서 예측성능은 떨어지지만, 그림에도 불구하고 MMEp는 안정적인 성능을 보여준다. Severe drought와 extreme drought의 공간 분포를 예측하는데 있어서, 높은 감지율(hit rate과 threat score)과 낮은 false alarm, 1에 근접한 bias 보여준다. Extreme drought의 경우 persistent run의 경우 원래 그 실험이 가지고 있는 고유의 특성인 지속성으로 인해 bias가 3에 육박하는 값을 가리킨다. MMEs는 종전의 결과와 동일하게 severe drought와 extreme drought 모두에서 빈도 자체를 과소 모의하는 경향이 있다.

가뭄과 관련된 주요특징들, 즉 가뭄 이벤트의 발생, 강도, 그리고 공간적 분포에 대해서 검증하였고, baseline skill로서 persistent run의 결과와 함께 비교하였다. persistent run의 경우 그 예측성은 역학 모형의 일반적인 예측성에 미치지 못 하였으며, 그 실험의 고유 특성인 지속성으로 인해 extreme drought가 종료된 경우에도 계속인 경우로 예측하여 모형의 빈도가 관측에 비해 과대모의 되어 bias가 1을 크게 상회하는 값을 나타내었다. 역학 모형들은 일반적으로 강도가 강해질수록 이벤트의 감지나 공간 분포를 예측하는데 있어서 예측성이 낮아짐을 보였다. 그 중에서 MMEs는 각 모형의

SPI 값 자체를 평균하는 특성으로 인해서 extreme한 이벤트를 예측하는 빈도가 관측에 비해 작고, 결과적으로 bias가 1보다 훨씬 작은 값을 나타낸다. 이러한 특성으로 인해 false alarm도 작지만, 다른 감지율이나 예측 성능도 낮았다. 모든 결과를 통틀어 가뭄의 특성과 관련된 예측성을 평가할 때, MME 강수예측을 mean bias 보정 후 SPI를 예측하는 경우 가장 높은 예측성을 나타냄을 알 수 있었다.




Figure 4.28. (Left) Time series and (right) time-averaged value of various verification skills of categorical spatial forecast of individual models and their MME for drought occurrence over the globe, based on (a) hit rate, (b) false alarm, (c) threat score, and (d) bias. The numbers from 1 to 11 in the upper panel and legend indicate the MME and its member models.




Figure 4.29. Time-averaged value of various verification skills of categorical forecast of individual models and their MME for (a) severe and (b) extreme drought. The numbers from 1 to 11 in the figure and legend indicate the MME and its member models.

4.9 계절성과 관련된 예측성능

4.5절에서 예측 강수의 월별 예측성능을 살펴보았으며, 그 결과 예측성능에 있어서 계절적 변동성은 보이지 않고, 지역적 차이는 크게 보였다. 월 평균 강수량자료와는 달리 매월 계산되는 SPI6 자료는 6개월 누적 강수량을 바탕으로 함으로 자기상관성 (autocorrelation)이 있다. 따라서 SPI를 기반으로 하는 가뭄예측자료가 계절성과 관련된 예측성능이 있는지 평가하는 것이 중요하다. 그림 4.30은 SPI6의 매월 예측성능을 보여주는데, 가로축에 있는 달은 예측기간 동안의 첫째 달을 가리킨다. 예측성능은 계절적으로 지역적으로 변동하는데, SPI 전체의 예측성을 살펴보면 북반구겨울(NDJFMA)의 예측성능이 북반구여름(MJJASO)보다 크다. 일반적인 강수 예측성능과 마찬가지로 북반구의 평균 예측성은 전구 평균보다는 작고, 남반구의 평균 예측성이 세 지역 가운데 가장 높다. 전구 평균에서는 다소 뚜렷하지 않지만, 북반구나 남반구를 떼어놓고 보면 계절적인 변동성이 명확하게 보이는데, 북반구에서는 북반구 겨울에 남반구에서는 남반구 겨울

에 좀 더 예측성이 높은 것을 알 수 있다. 즉, 건기 시즌의 예측성이 우기 시즌에 비해 상대적으로 높은 것을 알 수 있다.




Figure 4.30. Area-averaged values of TCC between observations and simulations for SPI6, over the terrestrial region of (a) globe, (b) northern hemisphere, and (c) southern hemisphere, from January to December. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models.

그림 4.31은 전구 pattern correlation에 대한 분석기간 1983-2003년 동안의 평균으로 월별 SPI6의 공간적인 유사성의 예측값을 나타낸다. 시간적인 변동성에 대한 예측 성과는 달리 역학 모형의 예측성능이 persistent run에 비해 크게 뛰어나면, 특히 전이

(transition) 계절에 시작하는 예측의 공간 패턴에 대한 예측성이 높음을 알 수 있다. 두 MME 예측성은 일반적으로 개별 모형의 예측성에 비해 뛰어나며, 가뭄 특성에 기준을 준 categorical 검증 결과와 달리 MMEs의 예측성능이 MMEp의 예측성능보다 높다. 이는 SPI의 일반적인 예측성과 일치하는 결과로, 전체 시계열이나 자료를 고려할 땐 MMEs의 예측성능이, 가뭄과 같은 특정 임계치에 대해서는 MMEp의 성능이 좀 더 뛰어남을 알 수 있다. 이는 동시에 가뭄과 같은 특정 임계치가 중요한 예보의 경우에는 어떤 점을 우선적으로 고려하여 예측 시스템을 개발하고 그 예측성을 분석해야 하는지 보여주는 단편적인 예라고 할 수 있다.




Figure 4.31. Time-averaged values of PCC between observations and simulations for SPI6 ending in (a) June, (b) September, (c) December, and (d) March, during the period of 1983–2005. The numbers from 1 to 9 in the upper panel and legend indicate the MME and its member models. The mean values of the MME and model prediction are provided in upper right of each panel.

4.10 요약

가뭄은 전지구적인 문제로 인식되고 있으며, 전지구적 기후감시 및 예측자료를 활용한 공동 선제대응이 요구된다. APCC는 현재 전구 가뭄 감시 자료만 서비스 중에 있으며, APCC MME 기후예측자료를 기반으로 한 새로운 콘텐츠 발굴 및 서비스를 위해 전구 가뭄 예측시스템의 개발 및 예측성 연구가 수행되었다. 이를 위해서는 가뭄을 정의하는 표시자(indicator)의 선정이 중요하며, 본 연구에서는 흔히 쓰이는 가뭄 지수 중 보편성, 유용성, 당위성, 가용성, 예측성 등의 선정 기준을 바탕으로 SPI를 가뭄 예측에 적합한 가뭄 지수로 선정, MME 기후예측 자료의 예측 선행 시간을 고려하여 SPI6의 예측자료를 생산하고 그 예측성을 검증하였다.

선정된 SPI의 변동성은 오로지 강수 변동성에 기초하므로, 전구 강수 및 가뭄의 특징을 함께 이해하는 것이 중요하다. 강수의 변동성은 북반구 겨울/여름을 기준으로 반구적으로 상이하며, 가뭄의 발생 빈도는 일반적으로 강수의 변동성과 반대 양상으로 나타난다. 강수의 변동성이 큰 시기는 주로 그 지역의 우기 시즌에 해당하는데, 이것은 전구 몬순 시스템을 나타낸다. 가뭄의 발생은 전구 몬순과 asymmetric하게 발생하는 지역도 있다. 이를 통해 몬순과는 별도로 가뭄 감시 및 예측시스템이 필요함을 시사한다. 또한, 이것은 강수 자료 자체의 비대칭성 또는 가뭄에서 보여주는 계절적 연속성 때문으로 보인다. 6개월 누적 강수량의 비대칭성은 전구 내륙 모두에서 보이는 데, 이는 강수 자료 자체가 가뭄 발생에 용이한 자료 분포를 가짐을 나타낸다. 특히 MME는 관측과 유사한 양의 왜도를 가지며, 공간적인 자료 분포 상으로는 dry event는 잘 모의하지만 wet tail을 예측하는 데는 한계를 가질 수 있음을 보여주었다. 한편 전구 SPI 시계열은 자기상관에 의한 계절성과 수십년 규모의 경향성을 보여 주었고, 가뭄 일 때 큰 예측성을 보였다. 특히 전구 가뭄 범위의 시계열은 전구 평균된 LEPS와 큰 상관성을 가지면서, MME 기후 예측자료를 기반으로 한 가뭄예측이 잠재적인 예측성을 가질 수 있음을 나타내었다.

전구 강수 변동성을 이해함과 동시에, 신뢰성 있는 전구 가뭄 예측의 핵심은 월/계절별 강수 예측 스킬을 제대로 평가하고 진단하는 것이다. 우선 전구 가뭄 예측시스템에서 가장 중요한 입력 변수인 MME 강수 예측 자료의 예측성이 검증되었다. 전구 강수의 예측성은 열대 태평양 지역에 한정되어 있으며, 이는 ENSO의 변동성과 큰 관련이 있다. 하지만 육지 지역만을 고려할 경우에는 그 예측성은 지역 간 편차가 굉장히 큼을 알 수

있다. 반구적인 차이로 살펴보면, 남반구는 북반구에 비해 예측성이 높으며, 월별 강수의 예측성에서 계절성을 찾아보기는 힘들다. 그럼에도 불구하고 MME는 일반적으로 개별 모형의 성능보다 높은 수준의 예측성능을 가지는데, 이는 향후 가뭄 예측 시스템에서 개별 모형에 비해 유용한 정보로 활용될 수 있음을 시사한다.

APCC MME 계절예측에 참여 중인 8개 전구해양-대기대순환모형의 강수예측자료를 활용 SPI 기반의 전구 가뭄 예측 시스템이 과거기후예측 기간인 1983년 2005년에 대해서 프로토타입으로 개발되었으며, 그 기간에 대한 일반적인 성능 및 가뭄과 관련된 특징, 계절성이 평가되었다. SPI의 예측성능은 지역, 3/6개월 누적기간, 그리고 모형 자료의 보정 방법에 따라서도 서로 다른데, 가뭄 예측을 수행하기에 앞서 월별 강수 예측 자료를 강수 관측 자료를 이용하여 평균/표준편차를 보정하였다. 두 편차 보정기법에 따른 예측 성능과 오차의 차이를 구해보면, 단순히 평균만 보정한 것이 분산과 함께 보정한 기법보다 높은 예측성과 작은 오차를 보이며, 이는 개별 모형이나 MMEs에서는 그 차이가 미비하나 MMEp에서는 월등히 크다.

SPI 전체의 시계열을 이용한 일반적인 예측성을 살펴보면, 전체 시계열의 시간 변동성은 일반적으로 높은 예측성을 나타내는데, 이는 자료 자체의 자기 상관성에 기인한 것이다. Persistent run과 비교해서, 역학 모형은 가뭄의 시·공간적 변동성이나 분포를 예측하는데 적합하며, 특히 MME는 그 성능이 비교적 안정적이다. 가뭄과 관련된 주요특징들, 즉 가뭄 이벤트의 발생, 강도, 그리고 공간적 분포에 대해서 검증하였다. Persistent run의 경우 그 예측성은 역학 모형의 예측성에 미치지 못 하였으며, 그 실험의 고유 특성인 지속성으로 인해 extreme drought가 종료된 경우에도 계속인 경우로 예측하여 모형의 빈도가 관측에 비해 과대모의 되는 경향이 있다. MMEp는 이에 비해 보다 안정적으로 나은 성능을 보여주지만, MMEs는 각 모형의 SPI 값 자체를 평균하는 특성으로 인해서 extreme한 이벤트를 예측하는 빈도가 작아짐을 알 수 있었다. 후자는 NMME CTB에서 사용한 방법으로, MME 기반의 가뭄 예측을 위해 보정 및 앙상블 등의 예측시스템을 개발할 때 좀 더 주의 깊게 설계될 필요가 있음을 시사한다. 결과적으로 가뭄의 특성과 관련된 예측성을 평가할 때, MME 강수예측을 mean bias 보정 후 SPI를 예측하는 경우 가장 높은 예측성을 나타냄을 알 수 있었다. 월별 강수량과 달리 SPI 예측성은 계절성을 보이며, 이는 그 활용성이 더 클 것으로 기대된다.

본 연구는 MME 기후예측 자료의 콘텐츠를 다양화하기 위해 전구 가뭄 예측시스템을 개발하고 서비스하는 것을 목표로 한다. 이를 위해 1983-2005년 기간에 대해 prototype으로 개발된 예측시스템에 대해서 일반적인 예측성능이 평가되었다. MME 기후예측 자료를 바탕으로 적절한 보정을 거쳐 가뭄을 예측할 경우 일반적으로 안정적인 예측 성능을 제공할 것으로 기대된다. 다만, 가뭄 취약 지역에 대한 집중적 연구 및 2006년 이후의 기후예측 자료에 대해서 적용한 예측성 등은 2차 년도로 넘기기로 한다. 또한 서비스의 구체적인 내용에 대해서도 다음 해에 고려하기로 한다. 결과적으로 해당 가뭄 예측자료의 서비스는 수문 관련 이상 기후에 취약한 아태지역에서 크게 기여할 것으로 사료된다.

5. 동아시아 겨울 몬순 예측기술 개발

5.1 서론

APCC 개별모델/MME 계절 예측력은 다른 지역에 비해 동아시아 지역에서 상대적으로 낮으며, 특히 겨울철 기온 예측성의 경년 편차가 매우 큰 특징이 있다. APCC 실시간 계절 예측 자료에서 동아시아 겨울철 기온의 예측 스킬은 동아시아 영역 평균한 온도 아노말리와 뚜렷한 양의 상관을 가지며, 특히 추운 겨울해에 예측성이 매우 낮게 나타난다. 이는 대부분의 역학 모형들이 동아시아 겨울 몬순(East Asian Winter Monsoon, EAWM)에 의한 겨울철 극한 기후 위상을 모의하지 못하기 때문이다(Shin et al. 2015).

동아시아 겨울철 기후는 EAWM의 영향으로 강한 경년 변동성을 가지며, 이는 우리나라를 비롯한 동아시아 영역에서의 겨울철 기온 예측에 큰 영향을 미친다. 동아시아 겨울철 평균 기온은 EAWM 지수와 강한 음의 상관을 가지며, 이러한 상관은 기후 변화와 무관하게 일관적으로 높은 값을 보여준다(Shin et al. 2015). 우리나라 겨울철 기온의 경년 변화를 가장 잘 대표하는 지수가 EAWM 지수임을 제시하는 결과라 할 수 있다. EAWM의 주요 강제력은 육지-해양 비열 차에 의해 발생하는 유효 위치 에너지(available potential energy)이며(Zhang et al. 1997), 시베리아 고기압과 알류산 저기압의 강한 기압 경도와 이와 관련되어 유도되는 대기 순환장(특히 동아시아 연안을 따라 흐르는 북서풍의 강화), 그리고 동아시아 상층 기압골과 상층 제트류의 강화가 주요 대기 특징으로 나타난다. EAWM의 강도는 ENSO(Zhang et al. 1996; Wang et al. 2010)와 열대 인도양 SST(Wang and Chen 2014), MJO와 같은 열대 해양으로부터의 강제력에 의해 제어될 뿐 만 아니라 유라시아 눈면적(Watanabe and Nitta 1999), Barents-Kara 해의 해빙 면적(Mori et al. 2014), Arctic Oscillation(Jeong and Ho 2005), 유럽과 우랄 지역에서의 블라킹과 같은 중-고위도 대륙으로부터의 강제력에도 큰 영향을 받는다. 가을철 유라시아 대륙에서의 눈면적의 증가는 그해 겨울몬순 강도를 강화시키며(Walland and Simmonds 1997; Watanabe and Nitta 1999; Clark and Serreze 2000; Jhun and Lee 2004), 가을철 Artic Sea Ice 또한 동아시아 겨울 몬순의 강도에 중요한 영향을 미친다(Wu et al. 2011; Li and Wu 2012). Ma et al. (2012)은 서태평양 아열대 고기압과 시베리아 고기압의 공동 작용이 중국의 한파 빈도

에 영향을 미친다고 밝혔다. 또한 EAWM은 엘리뇨 해에 약하고 라니냐 해에 강하게 나타나는 경향이 있는데, 북태평양 warming 에 의해 유도되는 필리핀 해양에서의 고기압성 순환과 이와 관련된 남풍 아노말리에 의해 ENSO와 연결된다. 한편 AO 와 NAO 는 EAWM의 수십년 시간 규모에 주로 영향을 미친다(Gong et al. 2001; Jhun and Lee 2004; Wu et al. 2006; Li and Bates 2007).

Wang et al. (2010)은 동아시아 겨울철 기온 변화를 두 가지 주요 기온 모드, 북쪽과 남쪽 모드로 설명 하였는데, 이는 현저히 다른 시·공간 구조와 변동성을 가지고 각각 다른 강제력에 의해 유도됨을 밝혔다. 북쪽 기온 모드는 시베리아 남부와 몽골에서의 과도한 눈덮임이 선행되는 반면, 남쪽 기온 모드는 라니냐 이벤트의 발달과 시베리아 북동쪽 적설량의 감소가 선행된다. 이러한 두 기온 모드의 현저하게 다른 시·공간 구조와 강제력은 주로 동아시아 온도의 경년 변동과 밀접한 관련이 있음을 제시하였다. 북쪽 기온 모드는 시베리아 북동쪽으로부터 발생한 한랭한 기온의 내습과 관련되며 동아시아 북부를 중심으로 추운 겨울이 나타나는 반면, 남쪽 기온 모드는 몽골리아 고기압의 강화와 동아시아 상층 기압골의 강화로 특징지어지고 이는 동아시아 남부를 중심으로 추운 겨울이 발생한다. 우리나라를 포함하는 동아시아는 Wang et al. (2010)이 제안한 독립적인 두 순환 시스템의 영향을 모두 받는 지역에 위치하며, 우리나라 겨울철 평균 기온은 각각의 기온 모드와 -0.68과 -0.70으로 높은 상관을 나타낸다(그림 5.1).

EAWM의 변동성 및 메커니즘을 이해하기 위한 노력의 일환으로 많은 연구자들이 몬순 지수 개발에 힘써왔다(Chen et al. 2000; Jhun and Lee 2004; Wu and Wang 2002; Sun and Li 1997). 많은 연구자들에 의해 동아시아 겨울몬순 지수가 개발되었으며, Wang and Chen (2010)은 기존 18개의 동아시아 겨울몬순 지수들을 크게 4개의 카테고리 - 저층 바람 지수(Chen et al. 2000), 상층 동서 바람 쉬어 지수(Jhun and Lee 2004), 동서 기압 대비 지수(Wu and Wang 2002), 동아시아 상층 기압골 지수(Sun and Li 1997) - 로 분류하여 동아시아 겨울몬순의 변동성을 비교·평가하였다. 그 외에도 온도를 변수로 하는 지수(Wang et al. 2010; Li and Wang 2012)가 있다. Wang and Chen (2014) 은 동아시아 주변의 동서-남북 기압 경도를 함께 고려한 새로운 동아시아 겨울몬순 지수를 제안하였으며, 이는 기존 지수들에 비해 동아시아 겨울 지표 기온, 특히 강추위와 같은 극한 기온을 묘사하는데 효과적임을 보였다. Kim et

al. (2017b)은 APCC의 과거예측자료(hindcast)를 활용하여 동아시아 겨울철 기온의 변동을 대표할 수 있는 새로운 EAWM 지수를 개발하였다. 이러한 EAWM 지수는 특히 현업 기후센터에서 EAWM을 예측하고 모니터링 하는데 유용하게 사용될 수 있다.

본 연구에서는 겨울철 계절 예측성 향상을 위한 방안으로 EAWM 지수를 이용하여 계절 예측 기술을 개발하고자 하였다. 먼저 기존 EAWM 지수들이 나타내는 온도의 특성을 분석 하였으며, 동아시아 겨울철 기온 변동을 대표하는 EAWM 지수를 제시하였다. 이러한 지수들을 통해 APCC 개별 모델과 MME에서의 EAWM 예측성을 평가하고 현재 기후모형의 예측 수준을 제시하였다. 더 나아가 EAWM 예측성 향상을 위해 APCC 예측 시스템에서 활용 가능한 역학-통계 하이브리드 예측 모형을 개발하였으며, 이를 통한 EAWM 계절 예측 정보 생산을 본 과제의 최종 목표로 하였다.




Figure 5.1. Spatial pattern and principal component (PC) of the first and second EOF modes for DJF mean T2m in the entire EAWM domain [0°–60°N, 100°–140°E]. The numbers in parentheses on the top of the panels denote the contribution of the total variances, whereas the numbers on the top-right corners of the lower panels denote the correlation coefficient between the PC of two major EOF modes and DJF-mean T2m averaged over Korea [35°–40°N, 125°–130°E].

5.2 자료 및 연구 방법

5.2.1 자료

사용된 모델은 표 5.1에 표시하였으며, 일정기간(1983-2010년)의 과거예측자료를 가지는 9개의 모델, 2개의 two-tier 모형(APCC, HMC)과 7개의 one-tier 모형(JMA, CANCM3, CANCM4, NASA, NCEP, PNU, POAMA)이 해당된다. 과거예측자료는 11월을 초기 조건으로 예측된 결과로, 1개월 리드 타임을 가지는 3개월(December, January, February) 평균(DJF) 예측 자료이다. EAWM 예측력 평가를 위해 1983/84년부터 2010/11년(28년) 동안의 과거예측자료가 사용되었으며 실시간 예측 특성 분석을 위해 2012/13년부터 2016/17년까지(5년)의 자료가 사용되었다. 사용된 다른 모델과는 달리 JMA 자료는 전처리 과정이 필요하며, 이는 Appendix 4에 제시하였다. 또한 리드 타임에 따른 EAWM의 예측성을 보기위해 6개월 예측 자료가 분석되었으며, 6개월 예측 자료에는 6개의 one-tier 모형(CANCM3, CANCM4, NASA, NCEP, PNU, POAMA)이 사용되었다. 예측력 검증을 위해 ERA-Interim 자료가 사용되었으며, 5개의 대기 변수(SLP, T2m, T850, Z500, U200)가 해당된다. 모형간 예측성 비교 및 검증을 용이하게 하기 위해, 모든 자료는 수평 해상도 $2.5^{\circ} \times 2.5^{\circ}$ 로 내삽하여 사용하였으며, 편의를 위해 본 연구에서는 1993/94 DJF를 93년 겨울로 표기 하였다.

Table 5.1. Description of 9 APCC models used in this study.

Model	Institution	No. of ensemble	Reference
APCC	APEC climate center		Jeong et al. (2008)
HMC	Hydrometeorological Center of Russia	2	Trosnikov et al. (2005)
JMA	Japan Meteorological Agency	5	Takaya et al. (2010)
CANCM3	Meteorological Service of Canada	10	Merryfield et al. (2013)
CANCM4	Meteorological Service of Canada	10	Merryfield et al. (2013)
NASA	National Aeronautics and Space Administration	11	Vernieres et al. (2012)
NCEP	National Centers for Environmental Prediction	20	Saha et al. (2014)
PNU	Pusan National University	10	Sun and Ahn (2011, 2015)
POAMA	Bureau of Meteorology	33	Zhong et al. (2005)

5.2.2 EAWM 지수

기존 EAWM 지수들은 각각 정의에 사용되는 변수에 따라 크게 5가지-저층 바람 지수, 상층 동서바람 쉬어 지수, 기압 대비 지수, 동아시아 상층 기압골 지수, 저층 기온 지수로 분류된다. 기존 개발된 EAWM 지수들 중 APCC 예측 시스템에서 활용 가능한 13개 지수들의 특성이 분석되었다(표 5.2). EAWM 지수에 사용되는 각 변수의 영역을 그림 5.2에 나타내었으며, 선택된 영역들은 시베리아 고기압의 강도, 육지-해양의 열적 대조, 동아시아 상층 기압골의 강도와 같은 EAWM 순환 시스템의 주요 특징을 반영하는 영역이다. 각 지수마다 사용되는 평균 영역과 특징이 다르며, 이는 EAWM 변동성의 특정 부분만을 설명할 수 있다. 사용된 모든 지수들은 뚜렷한 경년 변동성을 나타내며, 각각의 지수마다 강도 차이는 있지만 비슷한 패턴을 나타낸다. 지수 간 상관관계를 살펴본 결과 0.52에서 0.98로, 동일 변수를 사용하는 지수들 간의 상관성이 다소 높게 나타났다.




Figure 5.2. Illustration of the regions for defining the existing EAWM index, as listed in Table 5.2.

Table 5.2. Description of 13 EAWM indices used in this study. Here, SLP: sea level pressure, U: zonal wind, Φ : geopotential height. Superscript * denotes the normalized field.

Index	Defining Variable, Level, and Region	Reference
Chan_P	SLP gradient, (30–55°N,100–120°E)–(30–55°N,150–170°E)	Chan and Li (2009)
Gong_P	SLP, (40–60°N,70–120°E)	Gong et al. (2001)
Guo_P	SLP gradient, (10–60°N,110°E)–(10–60°N,160°E)	Guo (1994)
Shi_P	SLP* gradient, (20–50°N,110°E)–(20–50°N,160°E)	Shi (1996)
WangC_P	SLP* gradient, $\{[(40-60^{\circ}\text{N},70-120^{\circ}\text{E})-(30-50^{\circ}\text{N},140^{\circ}\text{E}-170^{\circ}\text{W})]$ $+[(40-60^{\circ}\text{N},70-120^{\circ}\text{E})-(20^{\circ}\text{S}-10^{\circ}\text{N},110-160^{\circ}\text{E})]\}/2$	Wang and Chen (2014)
Wang_P	SLP* gradient, (40–70°N,110°E)–(40–70°N,160°E)	Wang et al. (2009b)
Wu_P	SLP* gradient, (20–70°N,110°E)–(20–70°N,160°E)	Wu and Wang (2002)
Kim_P	SLP* gradient, (20–40°N,140°E–150°W)–(50–70°N,80–120°E)	Kim et al. (2017b)
Cui_Z	Φ^* , 500hPa, (35–40°N,110–130°E)	Cui and Sun (1999)
Sun_Z	Φ , 500hPa, (30–40°N,125–145°E)	Sun and Li (1997)
Wang_Z	PC1 of Φ^* , 500hPa, (25–50°N,100–180°E)	Wang et al. (2009a)
Li_U	U gradient, 200hPa $\{[(30-35^{\circ}\text{N},90-160^{\circ}\text{E})-(50-60^{\circ}\text{N},70^{\circ}\text{E}-170^{\circ}\text{W})]$ $+[(30-35^{\circ}\text{N},90-160^{\circ}\text{E})-(5^{\circ}\text{S}-10^{\circ}\text{N},90-160^{\circ}\text{E})]\}/2$	Li and Yang (2010)
Wang_T	PC1/PC2 of T, T2m, (0–60°N,100–140°E)	Wang et al. (2010)

5.2.3 역학-통계 하이브리드 예측 기법 개발

EAWM의 계절 예측성 향상을 위한 방안으로 역학-통계 하이브리드 모델이 개발되었다(그림 5.3). 관측된 겨울 몬순 지수와 역학 모형으로부터 예측된 대규모 변수들 간의 물리적 관계를 기반으로 예측인자를 선정하였으며, leave-one-out 교차 유효성 검사 기법을 적용하여 매년 다른 다중 회귀계수를 계산함으로써 역학-통계 하이브리드 모형을 구축하였다(Wilks 2006; Kim et al. 2015). 본 연구에서는 우리나라 기온 변동성을 잘 설명하는 EAWM 지수를 중심으로 개별 모형과 MME에 대한 역학-통계 하이브리드 모형이 구축되었으며, 개별 모형별로 계산된 역학-통계 하이브리드 예측정보의 평균값 또한 함께 비교·검증 되었다.




Figure 5.3. Schematic diagram illustrating the dynamic–statistical hybrid EAWM prediction system.

5.3 EAWM 예측력 평가

5.3.1 EAWM 지수의 특성

EAWM 지수는 EAWM의 변동성 및 메커니즘을 이해하는데 도움을 주며, 특히 현업 기후센터에서 이를 예측하고 모니터링 하는데 유용하게 사용될 수 있다. 먼저 기존 EAWM 지수들이 나타내는 온도 변동 특성을 살펴보고, 동아시아 겨울철 기온 변동을 대표하는 EAWM 지수를 제시하고자 하였다. 그림 5.4는 우리나라 겨울철 평균(DJF) 기온 아노말리와 표 5.2에 제시된 EAWM 지수들의 경년 변화를 나타낸 것으로, EAWM 지수는 우리나라 겨울철 기온과 강한 음의 상관관을 나타낸다(편의를 위해 지수의 음의 값이 강한 EAWM을 나타내도록 (-1)을 곱하여 부호를 조정하였다). 대부분의 지수들은 강한 몬순일 경우 추운 겨울을 나타내고 약한 몬순일 경우 따뜻한 겨울을 나타낸다. 그림에서 검은 실선은 사용된 12개 지수의 평균을 나타낸 것으로, 우리나라 겨울철 기온과 -0.82의 높은 상관관을 보인다. 그러나 모든 지수들이 매해 EAWM의 동일한 부호(phase)를 나타내는 것은 아니다. 이는 일부 지수들이 EAWM 기후 시스템 내의 특정한 지역의 변동만을 반영하기 때문이다. 따라서, 단일 지수들은 EAWM의 변동성을 부분적으로 다르게 모의할 수 있으며, 각 지수가 나타내는 EAWM 강도는 다소 큰 편차를 보인다. 따라

서 우리나라의 겨울철 기온 특성을 잘 반영하는 EAWM 지수의 선택은 본 연구 진행에 있어 매우 중요한 부분이라 하겠다.

EAWM은 적도에서부터 극에까지 아주 큰 자오 범위를 가지기 때문에 어떤 지수를 선택하느냐에 따라 각기 다른 지역적 특성을 제시할 수 있다. 특히 우리나라를 포함하는 동아시아는 독립적인 두 가지 순환 시스템의 영향을 함께 받으며, 각 시스템은 적도 대류나 고위도 대류으로부터 오는 강제력과 각각 다르게 결합되어 있다. 따라서 예측성 평가에 앞서 EAWM 지수의 특성 분석이 먼저 선행되었다. 그림 5.5는 EAWM 지수와 동아시아 기온 모드와의 관계를 나타낸 것이다. 12개의 기존 순환 지수들 중 6개의 지수(Chan_P, Guo_P, Shi_P, Wang_P, Wu_P, Sun_Z)는 기본적으로 남쪽 기온 모드를 설명하는 반면, 다른 6개의 지수(Gong_P, WangC_P, Kim_P, Cui_Z, Wang_Z, Li_U)는 두가지 기온 모드를 모두 설명한다. 두 가지 주요 기온 모드를 모두 설명하는 6개의 지수 중 Kim_P를 제외한 나머지 지수들은 북쪽 기온 모드(EOF1)에 비해 남쪽 기온 모드(EOF2)와 더 강하게 연결되어 있다. 우리나라 겨울철 평균 기온은 각 모드와 -0.68(북쪽)과 -0.7(남쪽)로 비슷한 비율의 높은 상관을 나타내므로, 우리나라에 적합한 EAWM 지수는 두 기온 모드를 모두 설명하는 지수이어야 할 것이다. EAWM 지수와 우리나라 겨울철 평균(DJF) 기온 아노말리와의 상관을 함께 비교해보면, 동아시아 두가지 주요 두 기온 모드를 함께 설명할 수 있는 지수들이 우리나라 기온 변동 또한 잘 모의하고 있음을 확인 할 수 있다.

우리나라 기온 변동 특성을 잘 설명하는 지수로 4개의 지수(WangC_P, Kim_P, Cui_Z, Wang_Z)가 선택되었으며, 몬순 강도에 따른 겨울철 기온 분포의 특성이 분석되었다. 그림 5.6은 EAWM 지수와 우리나라 영역 평균된 DJF 평균 기온 아노말리의 변화 분포를 지수별로 나타낸 것으로, 오른쪽 상단에 기입된 수는 기온과 몬순 지수와의 상관계수를 표기한 것이다. 본 연구에서는 선택된 4개 지수의 평균이 0.5σ 이상인 해를 강몬순해(1983, 1984, 1985, 1995, 1999, 2004, 2005, 2009, 2010)로 정의하였으며, -0.5σ 이하인 해를 약몬순해(1986, 1988, 1989, 1991, 1992, 1997, 1998, 2001, 2006, 2008)로 정의하였다. 강몬순해와 약몬순해의 년도를 각 그림에 빨간색과 파란색으로 기입함으로써 극한 겨울해의 특성을 제시하고자 하였다. 선택된 지수들은 DJF 온도 변화량의 60%가 넘는 많은 부분을 설명하며, 몬순 강도에 따른 온도 변화량의 일반적

인 관계를 잘 모의한다. 지위고도를 변수로 하는 지수들(Wang_Z, Cui_Z)은 전반적으로 온도 변화량을 잘 설명하기는 하나, 강한 EAWM과 관련된 극한 겨울의 온도 특성을 잘 표현하지 못하는 경향이 있다. 반면 해면 기압을 변수로 하는 지수(WangC_P, Kim_P)는 전반적인 온도 변화량 뿐 만 아니라 EAWM과 관련된 극한 겨울해의 온도 특성 또한 잘 모의한다.




Figure 5.4. Time series of the DJF-mean T2m averaged over Korea (gray bar) and EAWMI indices (color marker) obtained from the reanalysis data (observation) for 1983–2016. Black marked line denotes the simple average over EAWMI indices.




Figure 5.5. (Upper) The correlation coefficients between EAWM indices and East Asia temperature modes developed by Wang et al (2010). (Lower) The correlation coefficients between DJF-mean temperature anomaly averaged over Korea (East Asia) and EAWM indices. The last bar, MEAN represent the simple average over EAWM indices.




Figure 5.6. Scatter plots of normalized EAWM index vs DJF-mean T2m anomalies averaged over Korea during the period of hindcast (1983–2010). The abscissa (ordinate) of each dot in each diagram represents the amplitude and sign of the EAWM index (temperature anomalies) for an individual winter season.

5.3.2 역학모형에서의 예측력

본 장에서는 APCC 참여모델 및 MME에서의 EAWM 예측력을 평가함으로써 현재 기후예측 모델의 수준 및 한계점을 제시하고자 하였다. 그림 5.7은 9개의 개별 모형들과 MME가 나타내는 EAWM의 예측성을 나타낸 것으로, EAWM 지수에 따른 기후 모형 예측성의 차이 또한 확인 할 수 있다. EAWM 계절 예측성은 모델 간에 큰 편차를 보이며, 지수에 따른 모델간 예측성 또한 확연한 차이를 나타낸다. POAMA와 NCEP은 대부분의 지수들에서 일관적으로 다른 모형에 비해 높은 예측성을 보이며, MME를 비롯한

나머지 모형에서는 EAWM의 예측성이 유의하지 않게 나타난다. POAMA의 경우 EAWM 예측에 있어 가장 좋은 성능을 보이는데, 특히 WangC_P와 Li_U 지수를 사용하였을 때 28년간의(1983-2010) 상관계수가 0.59 와 0.62로 1개월 예측에 대해 통계적으로 유의한 예측력을 나타낸다. 이 두 지수는 다른 지수와 비교해서 열대 지역에서의 변동성을 직접 변수로 사용하여 계산하는데, 이것이 EAWM 예측성 증가에 부분적으로나마 기여하는 것으로 생각된다. Li_U 지수를 이용한 EAWM 계절 예측성은 다른 지수에 비해 높은 예측성을 보이지만 모형 간 예측성의 편차가 가장 크게 나타나는 특징이 있다. 반면, WangC_P 지수를 이용한 EAWM 예측성은 상대적으로 높은 스킬을 보이면서 모형 간 편차 또한 작다.

상대적으로 유용한 예측력을 보이는 WangC_P 와 Li_U 지수를 이용하여 계산된 EAWM 계절 예측력의 리드별 분포를 살펴보았다. 그림 5.8은 EAWM의 모형 예측력을 리드별로 나타낸 것으로, 예외적으로 POAMA 만이 3 개월의 리드타임까지 유의한 예측력을 보인다. WangC_P 지수에서 POAMA 모형의 EAWM 예측력은 2개월 리드 타임에서 급격히 감소하다 사라지는 반면, Li_U 지수에서 EAWM 예측력은 4개월 리드타임 전체에서 통계적으로 유의한 예측력을 나타내며, 일정 수준의 예측력이 지속적으로 유지됨을 볼 수 있다. 이는 EAWM와 관련된 열대 해양으로 부터의 강제력이 모형에서 매우 잘 모의되기 때문이다(Kang and Lee 2017). 특히 POAMA의 경우 동아시아 주요 온도 모드 중 남쪽 모드에 대한 예측력이 가장 우수하게 나타내는데, 이는 EAWM 계절 예측성에 대한 ENSO의 원격 상관과도 연결된다.

EAWM의 강화는 시베리아 고기압의 강화와 동아시아 저층 남북 바람의 강화, 그리고 동아시아 상층 기압골의 강화와 상층 제트류의 강화로 특징지어진다(Li and Yang 2010; Wang and Chen 2010). EAWM 강도에 따른 대기 순환장의 주요 특성을 살펴본 결과(그림 없음), APCC MME에 참여하는 대부분의 모형들은 북서태평양과 열대에서의 대기 순환장 아노말리 특성은 약하게나마 모의하지만, 아시아 대륙 북동부에서 발생하는 고기압성 아노말리나 강한 지위고도, 아시아 대륙에서의 동풍 편차는 모의하지 못하였다. 그러나 POAMA는 강몬순해의 특징인 시베리아 고기압, 동아시아 남북바람의 편차, 동아시아 기압골, 상층 제트류의 강화를 대체적으로 모의함을 확인하였다.

그림 5.9는 두 지수(Wang_C와 Li_U)를 이용하여 계산된 EAWM 예측값의 경년 변

화를 나타낸 것으로, 개별 모형 및 MME로부터 예측된 EAWM의 강도는 매년 큰 편차를 보이며 EAWM의 부호(phase)를 각기 다르게 모의해 일정한 방향성조차 제공하지 못한다. MME의 경우 TCC 스킬이 0.35로 통계적으로 유의한 수준의 예측값을 보이는 하나, 극값을 가지는 대부분의 해에서 실제 값과 상이한 값을 나타냄을 볼 수 있다. 매년 개별 모형들로부터 계산된 EAWM 예측값의 모형간 범위(model spread)는 거의 모든 해에서 1σ 이상의 큰 편차를 나타낸다. 이로부터 우리는 EAWM의 경년 변화를 예측함에 있어 모형간의 불확실성을 가늠할 수 있다. 개별 모형에서 모의된 EAWM 강도에 따른 합성도 분석을 실시한 결과, 대부분의 모형들은 EAWM 강도와 관련된 대기 순환장의 아노말리를 거의 모의하지 못하지만, POAMA는 주요 대기 순환 변수 모두에 대해 어느 정도 유의한 패턴을 모의하였다. 그러나 EAWM 예측의 경년 변화를 살펴보았을 때 EAWM과 관련된 겨울철 극한 기후(추운 겨울, 따뜻한 겨울)의 위상은 잘 모의하지 못한다. EAWM 강도에 따른 온도 아노말리의 특성을 살펴보기 위해, POAMA로부터 예측된 EAWM의 강도와 우리나라 영역 평균된 DJF 기온과의 관계를 살펴보았다(그림 5.10). 이는 EAWM으로 인한 극한 기후가 제시하는 온도 예측 가능성을 보기 위함이다. POAMA에서 예측된 두 지수는 DJF 평균 온도 변화량의 약 16% 정도밖에 설명하지 못하며, 몬순 강도에 따른 극한 온도 경향 또한 모의하지 못함을 확인할 수 있다.




Figure 5.7. The correlation coefficients between the observed and simulated normalized DJF-mean EAWM indices during the period of 1983–2010. Dashed lines denotes the threshold values for the 95% and 99% significance levels.




Figure 5.8. The correlation coefficients between observed and simulated EAWM indices by MME and individual model forecasts with varying forecast lead time. Upper and lower panels represent the EAWM prediction skill calculated by WangC_P and Li_U index, respectively. The dashed lines denote the statistical significance at the 99% and 95% confidence level.




Figure 5.9. Time series of the DJF-mean EAWM indices from the observation (gray bar) and the model forecasts with 1 month lead time from MME and individual models.




Figure 5.10. Scatter plots of simulated EAWM index from POAMA vs observed DJF-mean T2m anomalies averaged over Korea based on the WangC_P and Li_U indices.

동아시아 겨울몬순 지수와 EAWM과 관련된 주요 기후 지수들의 경년 변동성을 평가하기 위해 관측과 모형으로부터 계산된 지수들을 이용하여 시간 상관계수(TCC)를 계산하였다(표 5.3). 사용된 지수으로써, 동아시아 겨울 몬순 지수로는 WangC_P가 선택되었으며, 시베리아 고기압(SH)은 40° - 60° N, 70° - 120° E에서 영역 평균된 SLP(Gong et al. 2001)로 정의하였고, 동아시아 상층 기압골(EAT)는 30° - 45° N, 125° - 145° E에서 영역 평균된 500hPa 지위고도(Sun and Li 1997), 동아시아 제트(EAJS)는 30° - 35° N, 130° - 160° E에서 영역 평균된 200hPa 동서바람(Yang et al. 2002), 그리고 동아시아 기온은 20° - 50° N, 100° - 145° E에서 영역 평균된 T2m(Boo et al. 2011)으로 정의하였다. 그리고 Li and Wang (2003)의 정의에 따라 35° N와 65° N 사이의 동서 평균된 SLP 아노말리의 정규화된 차이를 이용해 AO 지수를 정의하였는데, 이는 이전 연구(Wu et al. 2009; Jiang and Li 2011)들에서 사용·검증된바 있다. 대부분의 모형들은 EAWM 지수의 경년 변동성을 거의 모의하지 못하는데, 이는 EAWM과 관련된 주요 특징인 시베리아 고기압, 동아시아 상층 기압골, 동아시아 제트류의 경년 변동 변화 특징을 모의하지 못하기 때문이다. 그러나 POAMA 모형은 상관계수 0.54로, 통계적으로 유의한 수준으로 EAWM의 경년 변동성을 모의한다. EAWM 경년 변동성을 모의함에 있어 POAMA 모형의 높은 예측성은 시베리아 고기압을 비롯한 동아시아 상층 기압골 및 제트류의 경년 변화 특징까지도 잘 나타낸다. JMA와 MSC_CANCM4는 동아시아 상층 기압골의 경년 변동성을 유의한 수준에서 모의하지만 EAWM의 예측성은 낮는데, 이는 겨울 몬순 시스템에 영향을 주는 AO, 시베리아 고기압, 동아시아 상층 제트 등을 잘 모의하지 못하기 때문으로 생각된다. 그 외 동아시아 겨울 몬순에 영향을 미치는 SST 강제력으로써 ENSO의 경년 변동성을 살펴본 결과, MME를 포함한 모든 개별 모형들은 상관계수 0.98 이상으로 그 변동성을 매우 잘 모의함을 알 수 있었다(여기서 ENSO 인덱스는 Nino3.4 SST로 정의되었다).

EAWM 지수가 동아시아 겨울 몬순에 영향을 주는 인자와 얼마나 밀접한 관계를 가지는지 살펴보기 위해, EAWM 지수와 다양한 지수들과의 관계를 살펴보았다(표 5.4). 본 연구에서 사용된 EAWM 지수(WangC_P)는 SLP를 변수하는 지수으로써 예상한 바와 같이 시베리아 고기압(SH) 지수와 0.87로 가장 높은 상관관계를 보이며, 동아시아 상층 기압골(EAT) 지수와 동아시아 제트류(EAJS) 지수와도 각각 -0.81 과 0.68로 높은 상관관계를 나타낸다. 이외에도 겨울 몬순과 원격 상관을 가지는 Nino3.4 SST 와 AO 지수

와의 관계를 살펴본 결과, 각각 -0.54과 -0.48로 통계적으로 유의한 음의 상관관계를 나타낸다. EAWM 지수는 SH, EAT, EAJS 등과 0.68 이상의 상관을 보이는데, 이는 EAWM 지수가 몬순 관련 주요 요소들의 경년 변동성과 유의한 관계를 가짐을 의미하며, 상하층 대기에서 일어나는 몬순 현상들과 역학적, 열역학적으로 강하게 연결되어 있음을 의미한다. 모형에서 계산된 EAWM 지수는 SH 지수에 대해서는 관측과 유사한 상관관계를 나타내지만, EAT와 EAJS 지수와는 대체적으로 관측에 비해 다소 낮은 상관관계를 나타낸다. NCEP과 POAMA 모형에서 계산된 EAWM 지수는 관측에서 보이는 SH, EAT, EAJS와의 밀접한 관계를 다른 모형에 비해 대체적으로 잘 모의한다. 이는 다른 모형에 비해 NCEP과 POAMA 모형이 동아시아 겨울 몬순의 연직구조를 더욱 현실적으로 모의하고 있음을 제시하는 결과이다. 원격 상관관계를 살펴보면, NCEP과 POAMA 모형은 관측과 비교해 Nino3.4 SST에 대한 EAWM의 관계를 더 강하게 모의하며, NASA를 제외한 모든 모형들은 EAWM과 AO와의 관계를 거의 모의하지 못한다. MME에서 계산된 EAWM 지수는 SH와 ENSO와의 관계는 대체적으로 모의하지만, 그 외 다른 지수들과의 관계는 대체적으로 모의하지 못한다.

전반적으로 APCC 계절 예측 참여 모델들은 EAWM에 대한 광범위한 예측 기술을 보여 주며, 그 예측성은 여전히 낮은 수준이다. POAMA 모형은 일부 지수들(WangC_P, Li_U)을 사용했을 때 0.6 정도의 상당히 높은 예측 스킬을 보이지만, 겨울철 극한 기후의 위상은 잘 예측하지 못하였다. 또한 몬순 강도에 따른 극한 온도 경향 또한 모의하지 못함을 확인하였다. 그 이유는 아직 명확하게 이해되지는 못했지만, 물리 모수화, 초기화 방법 및 앙상블 멤버 생성과 같은 같은 예측 시스템의 많은 차이점이 모두 예측력의 차이에 기여할 수 있다. 최근 Kang and Lee (2017)는 EAWM 계절 예측성에 대한 ENSO의 원격 상관 역할에 대해 연구하였으며, EAWM과 ENSO 사이의 현실적인 관계를 잘 모의되는 모형에서 EAWM 계절 예측성이 높게 나타남을 밝힌바 있다. 본 연구에서 제시된 EAWM 예측 특성 분석 또한 이와 상응하는 결과를 제시한다.

Table 5.3. The correlation coefficients between observation and individual models for EAWM, Artic Oscillation (AO), Siberia High (SH), East Asian Trough (EAT), and East Asian Jet Stream (EAJS). Values in Bold and *, ** fonts exceed the confidence levels of 90%, 95% and 99%.

	EAWM	AO	SH	EAT	EAJS	T2m
APCC	0.36	-0.16	0.16	-0.18	-0.21	0.22
HMC	0.13	-0.18	0.03	-0.01	-0.32	0.07
JMA	0.10	0.27	0.32	0.34	-0.05	0.60**
CANCM3	0.28	-0.05	0.09	0.17	-0.13	0.33
CANCM4	0.17	0.30	0.08	0.41*	-0.16	0.47*
NASA	-0.20	-0.10	0.09	0.24	-0.20	0.46*
NCEP	0.22	0.12	0.04	0.21	0.23	0.24
PNJ	0.31	-0.19	0.12	0.04	0.00	0.11
POAMA	0.54**	0.12	0.41*	0.46*	0.41*	0.49**
MME	0.40*	0.07	0.44*	-0.18	-0.13	0.53**

Table 5.4. The correlation coefficients of EAWM with Nino3.4, Artic Oscillation (AO), Siberia High (SH), East Asian Trough (EAT), and East Asian Jet Stream (EAJS) in reanalysis and individual forecast models and their MME. Values in Bold and *, ** fonts exceed the confidence levels of 90%, 95% and 99%.

EAWM index	Nino3.4	AO	SH	EAT	EAJS
OBS	-0.54**	-0.48**	0.87**	-0.81**	0.68**
MME	-0.59**	-0.13	0.72**	0.28	-0.14
CANCM3	-0.24	0.11	0.88**	-0.07	0.04
CANCM4	0.15	-0.33	0.85**	-0.39*	0.33
NASA	-0.03	-0.53**	0.75**	-0.58**	0.46*
NCEP	-0.64**	-0.30	0.84**	-0.67**	0.71**
PNJ	-0.57**	-0.13	0.90**	-0.66**	0.55**
POAMA	-0.74**	-0.20	0.96**	-0.62**	0.77**

5.3.3 역학-통계 하이브리드 예측

앞서 APCC 참여모델 및 MME에서의 EAWM 예측력을 평가하고 현재 기후예측 모델의 수준을 제시하였다. 본 장에서는 EAWM 계절 예측력 향상을 위한 방안으로 역학-통계 하이브리드 모형을 구축하였다. 먼저 잠재 예측인자로서 대규모 순환 변수들에 대한 APCC MME 예측 성능을 살펴보았다. 이 때, 잠재 예측 인자는 과거예측기간 동안

(1983-2010년) 제공되고 있는 기본 변수들 중에서 EAWM 주요 특징과 관련된 변수가 선택되었다. EAWM은 시베리아 고기압과 알류산 저기압의 강한 수평 기압 경도와 이로부터 야기되는 저층 대기 순환장(특히 동아시아 연안을 따라 흐르는 북서풍의 강화), 그리고 동아시아 연안을 따라 나타나는 강한 남북 온도 경도, 강한 동아시아 상층 기압골과 일본 남부에 위치한 제트류의 강화로 특징지어진다(Chen et al. 2000; Yang et al. 2002; Jhun and Lee 2004).

그림 5.11 은 SLP, T2m, T850, Z500에 대한 TCC의 공간적 분포를 보여준다. APCC MME는 전반적으로 적도 해양에서 높은 예측 스킬을 보이며 중위도 내륙으로 갈수록 예측 스킬이 낮아지는 특징이 있다. 특히 MME SLP는 인도양에서 서태평양까지의 적도 온난 해수역(warm pool)과 날짜변경선(dateline) 동쪽으로 중부 및 동부 적도 태평양에서 높은 예측 스킬을 나타낸다. 반면 우리나라를 기준으로 시베리아 고기압과 북태평양 고기압 서부에서는 매우 낮은 예측 스킬을 나타낸다. EAWM의 주요 강제력은 육지-해양 비열차에 의해 발생하는 유효 위차 에너지이기 때문에, 우리나라 주변 기압장의 낮은 예측성은 EAWM 예측 스킬을 저하시키는 주요 원인이 될 수 있다(Zhang et al. 1997). MME T2m과 T850은 거의 비슷한 분포의 예측 스킬을 나타낸다. 적도 서태평양에서 상대적으로 낮은 예측 스킬을 나타내는 반면, 적도 태평양의 중부와 동부에서 높은 스킬을 보이고, 이는 EAWM에 영향을 미치는 ENSO의 원격 상관을 모의하는데 유리한 인자임을 알 수 있다(Wang et al. 2000; Kang and Lee 2017). Z500에 대한 예측력은 적도 아열대 지역 전체에서 높게 나타나며 위도에 따라 감소하는 패턴을 보이는데, 북태평양 동부에서 상대적으로 높은 스킬을 나타낸다. 대규모 순환 변수들의 예측 스킬은 리드 타임이 증가함에 따라 다소 감소함을 확인 하였다(그림 없음).

관측과 MME에서 EAWM의 경년 변동성이 주요 변수들과 어떻게 연결되어 있는지 살펴보기 위해, 관측된 EAWM 지수와 대규모 변수들과의 상관 패턴을 관측장과 예측장에 대해 각각 나타내었다(그림 5.12). EAWM 지수와 해면 기압장과의 상관 패턴은 EAWM의 주요 강제력으로 발생하는 강한 육지-해양 기압 경도 패턴과 유사하게 나타난다. EAWM 경년 변동은 시베리아와 유라시아 대륙 고기압과 강한 양의 상관을 나타내며, 아시아 동부를 둘러싼 적도 서태평양과 북태평양 서부에서 강한 음의 상관을 나타낸다. MME SLP는 전반적으로 관측장과 유사한 상관 패턴을 보이지만, 상관 강도는 다소

약하게 나타난다. 특히 우리나라와 일본 동쪽 해양에서의 강한 음의 상관관계가 거의 나타나지 않으며 시베리아 지역에서의 강한 양의 상관관계가 매우 약하게 나타난다. 이에 따라 첫 번째 잠재적 예측인자로서 관측과 유사한 패턴을 보이며 통계적으로 유의한 상관관계를 나타내는 시베리아 남부에서의 영역이 선택되었다.

두 번째 예측인자는 EAWM 지수와 기온과의 관계로부터 검색되었다. 상관 분포에서 볼 수 있듯이 기온 변수와 관련된 EAWM 경년 변동성은 ENSO에 의해 유도되는 패턴으로, 적도 중부와 동부 태평양에서 음의 상관관계를 나타내며 우리나라를 포함하는 아시아 동북부에서 강한 음의 상관관계를 나타낸다. MME 온도는 적도 동태평양에서의 음의 상관관계는 비슷한 강도로 잘 모의하나, 아시아 동북부에서의 강한 음의 상관관계를 전혀 모의하지 못한다. 따라서 NINO3.4 지역에서의 온도 영역이 두 번째 예측 인자로 선정되었다. 이 지역에서의 MME SST 예측 스킬은 몇 개월의 리드 타임을 가지고도 상당히 높게 유지되며, 두 번째 예측인자의 사용은 EAWM과 관련된 ENSO의 영향을 현실적으로 나타내기 때문에 EAWM 예측성에 있어 유리하게 작용할 수 있다.

세 번째 잠재적 예측 인자는 Z500에서 검색되었다. MME 지위고도는 열대지역에서 음의 상관관계가 다소 모의되나, 동아시아와 일본에 걸쳐 나타나는 강한 음의 상관관계는 전혀 모의하지 못한다. 이는 동아시아 상층 기압골의 변동성과 관련된다. 또한 MME에서 북서태평양 동부에 과도한 상관관계가 나타나는 특징이 있다. 관측과 유사하면서 유의한 영역으로 인도양과 중위도에서 잠재 예측인자를 선정하고자 하였으며, 캘리포니아 연안에서 나타나는 유의한 양의 상관관계를 세 번째 예측인자로 선정하였다. 이는 해들리 순환으로 인한 하강기류의 강도에 미치는 ENSO의 영향이 뚜렷한 지역으로써 EAWM과의 물리적 관계는 추후 더 연구될 필요가 있다.

EAWM 변동성과 대규모 환경 변수들 사이에서의 물리적 관계를 기반으로 각 변수에 대해 다른 영역을 가지는 예측 인자들이 선정되었다. APCC MME로부터 생산된 예측인자들의 예측성은 EAWM 경년 변화 모의에 영향을 미치며 hybrid 예측 성능과도 직접 연결된다. 따라서 예측 인자의 영역이 관측과 APCC MME 예측에서 일관적으로 유의한 영역임을 확인하였다. 표 5.3에 제시된 지수들 역시 예측장의 기본 변수로써 제공이 되며, EAWM의 경년 변동성을 부분적으로 설명하기 때문에 잠재 예측인자로 사용될 수 있다. 그러나 다중 회귀식에서 많은 잠재 인자의 사용은 overfitting 문제를 야기시키기

때문에 꼭 높은 예측성을 제공하지는 않는다. 또한 잠재 예측 인자들은 실제로 EAWM과 관련된 대규모 순환 변화를 통해 서로 상호 관련되고 의존적일 수 있다. 따라서 본 연구에서는 포워드 선택 방법을 이용하여 잠재적인 예측 변수로부터 최적의 예측 인자를 선택하였다.

역학-통계 하이브리드 모형 구축을 위해 최종적으로 T2m과 SLP가 예측인자로 선택되었다. Leave-one-out 교차 유효성 검사를 적용하여 예측자(predictor)와 예측(predictant) 간의 다중 회귀 분석을 실시하였으며, 회귀 계수를 목표 연도의 APCC MME 예측에 적용하여 하이브리드 EAWM 예측값을 산출하였다. EAWM 하이브리드 예측은 1983-2010년(28년)의 과거예측자료를 이용해 역학모형과의 EAWM 예측성능을 비교하였으며, 2012-2016년(5년)의 실시간 예측 자료를 이용해 하이브리드 EAWM 계절예측 가능성을 타진해보고자 하였다.




Figure 5.11. Spatial distribution of correlation coefficients between the observed and APCC MME hindcast T2m, T850, SLP and Z500 with 1-month lead time over the 28-years period 1983-2010. Dots indicate correlations above the 95% confidence level. Boxes indicate the region where the variables are used as predictors for the dynamic-statistical forecasts of EAWM.




Figure 5.12. Correlations of observed and APCC MME hindcast DJF SLP, T2m, T850 and Z500 with the observed EAWM index.

그림 5.13은 1983년에서 2010년(28년)의 과거예측기간에 대한 하이브리드 예측 모형의 EAWM 예측성을 모형별로 나타낸 것으로, 역학 모형의 예측성 또한 함께 나타내었다. 개별 막대에 검은 점은 교차 검증을 실시한 상관계수로 HMC를 제외한 모든 모형에서 유의한 예측력을 나타내며, 대부분의 모형에서 역학 모형 보다 우수한 스킬을 보인다. MME_I는 개별 모형으로부터 계산된 EAWM 지수의 평균을 의미하며, 하이브리드를 이용한 MME_I는 MME로부터 계산된 하이브리드 EAWM 지수보다 다소 높은 스킬(0.63)을 나타낸다. 또한 개별 모형의 관점에서 하이브리드 EAWM 예측성은 CANCM4에서 가장 높게 나타난다. 향상된 EAWM의 예측성은 모든 개별 모형에서 일관적으로 유의하게 나타나며, 이는 하이브리드 EAWM 계절 예측 시스템의 잠재 가능성을 제시하는 결과라 하겠다.




Figure 5.13. Correlations of predicted EAWM indices with 1-month lead time from MME and individual models. Black dots denote the cross-validated correlation coefficients.

그림 5.14는 하이브리드 EAWM 예측값의 경년 변화를 나타낸 것으로, 과거예측기간(1983-2010)과 실시간 예측기간(2012-2016) 결과를 함께 표기하였다. 회색 막대는 EAWM지수의 관측을 나타내며, 파란 실선과 빨간 실선은 각각 역학 모형과 하이브리드 모형의 EAWM 지수값을 나타낸다. 과거예측기간 동안 하이브리드 예측은 EAWM 극한 위상들이 잘 나타나게 개선됨으로써 평균 예측 스킬이 향상되지만, 실시간 예측에서는 역학모형에서 모의되는 EAWM의 위상과 거의 같은 양상을 나타내며, 그 강도가 다소 약하게 모의됨으로써 개선된 결과를 나타낸다. 하지만 여전히 실시간 예측에서의 EAWM 지수는 관측과 비교해서 과도하게 약문순으로 모의하는 경향이 있다.

하이브리드 모형에서 예측된 EAWM 지수의 모형 간 편차를 살펴보기 위해, APCC 모든 개별 모형으로부터 예측된 EAWM 지수들의 경년 변화를 제시하였다(그림 5.15). 역학모형에서 보였던 EAWM 예측의 불확실성이 상당히 개선된다. APCC 개별 모형들의 예측값이 나타내는 모형 간 범위는 역학모형에서는 2.8, 하이브리드 모형에서는 1.3으로, 하이브리드 예측은 모형 간 편차를 상당히 개선시키며, 대부분의 해에서 동일한 EAWM의 위상을 모사한다. 이는 하이브리드 예측 모형에서 사용된 예측인자 중 하나가 ENSO의 변동을 나타내며, 이것이 개선된 EAWM 예측력에 상당 부분 기여하기 때문이다.




Figure 5.14. Time series of the DJF-mean EAWM indices obtained from observation (gray bar), dynamic (blue line), and dynamic-statistical hybrid forecasts (red line) with 1-month lead time.

EAWM과 관련된 우리나라 겨울철 온도 아노말리의 특징과 ENSO의 영향력이 예측 스킬과 어떤 관계를 가지는지 살펴보기 위해, 우리나라 겨울철 온도와 ONI 지수를 각각 빨간 실선과 파란 실선으로 표기하였다(그림 5.15). EAWM 강도의 경우 우리나라 온도와 0.78로 높은 상관을 보이며 ONI 지수와 0.55로 유의한 통계적 양의 상관을 나타낸다. Wang et al. (2000)는 엘니뇨의 경우 동아시아 겨울 몬순 강도가 약해지고 양의 온도 편차를 가져오는 반면, 라니냐의 경우 몬순 강도가 약해지고 음의 온도 편차가 유도된다고 하였다. EAWM 강도에 미치는 ENSO의 영향은 우리나라 겨울철 기후 변동에 영향을 주는 남쪽 기온 모드의 주요 특징을 설명하며 특히 라니냐의 경우 뚜렷한 경향을 나타낸다. 하이브리드 모형으로부터 계산된 EAWM 지수와 ENSO와의 상관성이 모든 모형에서 0.8이상으로 높게 나타났다. 이는 관측이 나타내는 -0.54의 상관보다 더 강한

상관을 나타낸다. 하이브리드 예측 결과, EAWM 지수는 ENSO와의 원격 상관관계를 과도하게 모의하는데, 이는 북쪽 기온 모드를 설명하는 대륙으로 부터의 강제력이 모형 내에서 과소 모의되기 때문이다. 하이브리드 예측 지수들의 평균을 구한 지수(MME_I)는 ONI 지수와 0.94의 상관을 가지며, 이는 하이브리드 예측력의 소스가 ENSO임을 제시하는 결과이다.




Figure 5.15. Time series of the DJF-mean EAWM indices from the observation (gray bar) and the hybrid model forecasts with 1 month lead time from MME and individual models (colored mark). The red line denotes the DJF-mean T2m averaged over Korea and blue line denotes the ONI index.

리드타임에 따른 EAWM 예측성을 살펴보기 위해, 6개월 예측에 사용되는 과거예측자료가 분석되었다. 6개월 예측 정보가 제공되는 7개 모형(APCC, CANCM3, CANCM4, NASA, NCEP, PNU, POAMA)에 대해 4개월 예측 선행시간(8월)부터 1개월 예측 선행시간(11월)까지 매 달 예측된 DJF 예측자료가 사용되었고, 이를 각각 LT4, LT3, LT2, LT1로 정의하였다. 예를 들어, LT4는 8월에 생산된 DJF 예측자료를 의미한다.

그림 5. 16은 하이브리드 모형으로부터 예측된 EAWM 지수의 예측성을 리드별로 나타낸 것이다. 하이브리드 모형의 예측성은 긴 리드 타임을 가지고 유지되는데, 이는 예측 인자로 선택된 MME SST의 예측 스킬이 몇 개월의 리드 타임을 가지고도 상당히 높게 유지되기 때문이다. 이로써 EAWM 계절 예측성 있어 ENSO의 원격 상관 관계가 하이브리드 모형 EAWM 예측성 향상에 주요 소스로 작용함을 확인할 수 있다.




Figure 5.16. Prediction skill of dynamic and hybrid EAWM forecasts with varying forecast lead time and their difference.

EAWM과 관련된 온도 아노말리의 경년 변동성이 얼마나 개선되는지를 살펴보기 위해, EAWM의 강도와 우리나라 영역 평균된 DJF 기온과의 관계를 살펴보았다. 역학모형과 하이브리드 모형 중 EAWM 지수의 예측성이 가장 좋은 POAMA와 MME_I를 각각 선택하여 그림 5.17에 나타내었다. POAMA와 MME_I에서 예측된 두 지수 모두 DJF 평균 온도 변화량의 약 20% 이하밖에 설명하지 못한다. POAMA는 몬순 강도에 따른 극한 온도 경향을 거의 모의하지 못하지만, 하이브리드 예측을 통한 EAWM 지수는 강몬순해의 극한 온도 경향을 매우 잘 모의한다. 하이브리드 예측에서 대부분 1988년과 1998년이 강한 몬순으로 예측되는데, 이는 라니냐 해로 ENSO에 대한 과도한 원격 상관으로 기인한 것이다.




Figure 5.17. Scatter plots of forecasted EAWM index vs observed DJF-mean T2m anomalies averaged over Korea based on the WangC_P index. Left and right panels are from the results of POAMA and mean index averaged over individual hybrid indices.

5.4 요약

EAWM의 영향으로 동아시아 겨울철 기후는 강한 경년 변화를 가지며, 우리나라를 비롯한 동아시아 지역의 겨울철 기온 예측에 큰 영향을 미친다. 그러나 APCC의 역학 모형들은 EAWM에 의한 겨울철 극한 기후의 위상을 모의하지 못하기 때문에 추운 겨울에 대한 온도의 예측성은 특히 낮은 실정이다. 따라서 본 연구에서는 APCC 계절예측시스

템에서 활용 가능한 EAWM의 역학-통계 하이브리드 예측 모형을 개발하여 신뢰도 높은 겨울철 계절 예측 정보를 제공하고자 하였다.

먼저 기존 EAWM 지수들이 나타내는 온도 변동 특성을 살펴보고, 동아시아 겨울철 기온 변동을 대표하는 EAWM 지수를 제시하고자 하였다. EAWM은 적도에서부터 극에 까지 아주 큰 자오 범위를 가지기 때문에 어떤 지수를 선택하느냐에 따라 각기 다른 지역적 특성을 제시할 수 있다. EAWM 지수와 동아시아 주요 기온 모드와의 관계를 분석함으로써 두 기온 모드 모두를 설명하는 지수를 선별하였으며, 특히 우리나라 기온의 전반적인 변화량 뿐만 아니라 EAWM과 관련된 극한 겨울해의 온도 특성 또한 잘 모의하는 지수를 제시하였다. 해면 기압을 변수로 하는 지수인 WangC_P(Wang and Chen 2014) 와 Kim_P(Kim et al. 2017b) 지수는 전반적인 온도 변화량 뿐만 아니라 EAWM과 관련된 극한 겨울해의 온도 특성 또한 잘 모의하였다.

각 지수들을 사용하여 APCC 개별 모델과 MME에서의 EAWM 예측성을 평가하고 현 기후 모형의 예측 수준을 제시하였다. EAWM 계절 예측성은 모델 간에 큰 편차를 보이며, 지수에 따른 모델간 예측성 또한 확연한 차이를 보였다. 전반적으로 APCC 계절 예측 참여 모델들은 MME를 비롯하여 EAWM에 대한 광범위한 예측 기술을 보여 주며, 그 예측성은 여전히 낮은 수준이었다. 단 POAMA 모형의 경우 유일하게 모든 지수들에서 유의한 예측 스킬을 보였으며, 일부 지수들(WangC_P, Li_U)을 사용했을 때 0.6 정도의 상당히 높은 예측 스킬을 보였다. 이 두 지수들은 열대 지역에서의 변동성을 직접 변수로 사용하는데, 이것이 EAWM 예측성 증가에 부분적으로나마 기여하는 것으로 생각된다. 하지만, EAWM 예측의 경년 변화를 살펴보았을 때 POAMA는 전체적인 온도 변화량은 상대적으로 잘 모의하지만, 몬순 강도에 따른 겨울철 극한 온도 경향은 잘 예측하지 못하였다.

EAWM 예측성 향상을 위해 APCC 예측 시스템에서 활용 가능한 역학-통계 하이브리드 예측 모형을 개발되었다. 이는 관측된 EAWM의 경년 변화와 대규모 환경 변수들 사이에서의 물리적 관계를 기반으로 구축되었다. 하이브리드 예측은 모형 간 편차를 상당히 개선시키며, 대부분의 해에서 동일한 EAWM의 위상을 나타내었다. 향상된 EAWM의 예측성은 모든 개별 모형에서 일관적으로 유의하게 나타났으며, 4개월의 선행 기간을 가지고도 예측성은 유지되었다. 이는 하이브리드 EAWM 계절 예측 시스템의 잠재 가능

성을 제시하는 결과라 하겠다. 한편, 하이브리드 EAWM 지수는 ENSO와의 원격 상관 관계를 과도하게 모의하는 경향이 있으며, 이는 북쪽 기온 모드를 설명하는 대륙으로부터의 강제력이 모형 내에서 과소 평가되기 때문이다. 하이브리드 예측 지수들의 평균을 구한 지수 MME_I 는 ONI 지수와 매우 높은 상관관계를 가지며, 이는 하이브리드 예측력의 소스가 ENSO로부터 기인한 것임을 제시한다.

6. 극한 기후 예측기술 개발

6.1 서론

최근 급격한 기후변화로 인해 전지구 평균 기온의 상승 뿐 아니라 폭염, 한파, 가뭄, 집중호우 등 극한 기상·기후 현상의 발생빈도가 점차 증가하고 있으며, 이러한 변화는 관측 및 모델링을 통한 많은 선행연구에서 밝혀지고 있다(Janssen et al. 2016; Pepler et al. 2015; Asadieh and Krakauer 2015; Alexander 2016). 특히, 극한 기후는 수자원(Kundzewicz et al. 2014), 농업 및 식량 안보(Lesk et al. 2016; Kang et al. 2009), 에너지(Frank 2005; Bartos et al. 2016), 보건(Hales et al. 2003; Hashim and Hashim 2016) 등에 상당한 영향을 미치며, 이로 인한 재산 및 인명 피해는 사회·경제적으로 파급효과가 크다고 할 수 있다. 이러한 이유로 극한 기상·기후 현상 규명 및 예측 연구에 대한 관심이 점차 증가하고 있으며, 최근 기후변화정부간협의체(Intergovernmental Panel on Climate Change, IPCC)는 극한 현상에 관한 특별 보고서를 통해 극한 기후 연구의 중요성을 언급한 바 있다(IPCC 2012). 또한 전 세계적으로 극한 기상·기후 현상이 더욱 빈번하게 발생함에 따라 이로 인한 기상재해를 사전에 예방하고, 적극적인 대응책 마련을 위한 의사결정 과정에서 정책결정자들과 기후예측자료의 최종 수요자들은 신뢰성 및 실효성 있는 극한 기후 예측정보를 요구하고 있는 실정이다.

극한 기후 예측정보의 중요성이 점차 대두되고 예측정보에 대한 요구가 증가함에도 불구하고, 현재 대부분의 계절예측 연구는 계절평균 기온·강수량에 집중되고 있으며 극한 기후예측에 대한 연구는 Barnston and Mason (2011)과 Becker et al. (2013) 등 몇몇 연구에 국한 되어 있다. Barnston and Mason (2011)은 IRI의 7개 대기모형이 예측한 계절평균 전구 기온 및 강수량의 실시간 예측 자료(1998~2009년)에 대한 예측성 평가를 통해, 기후분포의 상·하위 15% 극한 기후에 대한 IRI MME 확률예측시스템의 현재 수준 및 적도지역에 대한 극한 기후 예측 가능성을 언급하였다. Becker et al. (2013)은 NCEP CFSv1과 CFSv2 모델의 1982~2010년 자료를 이용하여 북미/남미 지역에 대한 월별 극한 기온 및 강수 예측력과 잠재예측력을 결정론적 검증기법을 활용하여 평가하였다. 현재 계절예측규모에서 극한 기후예측정보를 제공하고 있는 현업기관은 유럽중기예보센터(ECMWF)와 국제기후·사회 연구소(IRI)이며, 사용자 편의에 따른 percentiles(예, 상/하위

15%) 또는 특정 임계값(예, 기온 20℃)에 대한 확률 예측정보를 포함한다.

APCC는 아시아·태평양 지역의 이상기후 감시 및 최적의 기후 예측 정보 제공을 통해 경제적 기회의 확대 및 경제적 손실의 경감, 인명과 재산 보호를 위해 노력하고 있다. 특히 아시아·태평양 지역은 전 세계 인구의 60%가 살고 있을 뿐만 아니라 지난해 집중 호우, 폭염 등의 극한 기상·기후 관련 재난으로 약 5000명의 사망자가 발생하였고, 지난 40년간(1971-2010년) 극한 기상·기후 현상은 뚜렷한 증가 추세를 보이고 있다 (Thomas et al. 2013; UN ESCAP⁴¹⁾ 2017). 이에 따라 각 국의 정부 및 정책 결정자는 자연재해 저감 대책수립, 지역 내 농산물 생산량 조절, 수자원 확보 및 관리를 위해 극한 기후 예측정보를 시급하게 요구하고 있다. 현재 APCC에서 제공하는 다중모델 앙상블 기후 예측자료는 세계에서 가장 다양한 기후 예측 모델 정보를 활용 할 뿐만 아니라 세계 유수의 기후 예측기관과 비교해 다소 우위의 기후 예측 정보 예측력을 가지고 있다. 다중 모델 앙상블기법을 이용한 계절 기후예측은 개별 모델이 가지는 계통 오차(systematic error) 및 초기 조건으로 인한 예측 오차를 줄이기 위하여 서로 다른 모델들의 예측 결과를 통계적으로 결합하는 방법으로 계절예측의 예측력을 향상시키는 하나의 방안으로 제시되어 그 우수성은 많은 연구들에서 입증되었다(Wang et al. 2004; Yun et al. 2005; Wang et al. 2008, 2009; Lee et al. 2010). 하지만 현재 APCC에서 홈페이지를 통해 제공하고 있는 기후서비스는 전구 및 지역 규모의 계절평균 기온, 강수, 해수면 온도 등에 대한 예측정보이며, 극한 기후에 대한 예측정보는 제공하고 있지 않다.

즉, 최근 극한 기후현상의 빈번한 발생으로 인한 사회·경제적 피해가 증가하고, 이에 따른 극한 기후 예측의 중요성 및 예측정보에 대한 요구가 증가하지만, 계절예측규모에서 극한 기후 예측성 평가 및 기술 개발에 관한 연구는 현재 전무한 실정이다. 현재 2개의 계절예측 현업기관에서 극한 기후 예측정보를 제공하고 있지만, 기본적인 예측력 평가에 관한 연구조차 많이 이루어지 않은 상황이다. APCC는 현재 다양한 종류의 최신 모델들을 활용한 극한 기후에 대한 MME 확률예측정보를 전구대상으로 장기간에 대해 분석할 수 있다는 점에서 기존의 연구들과 차별성이 있다고 할 수 있다. 이러한 이유로 본 과제에서는 다양한 계절예측정보 제공을 위한 콘텐츠로 ‘극한 기후(상·하위 15%의 기온/강수)’를 선정했고, 종합적인 예측성 평가를 통해 최종 현업시스템으로의 발전 가

41) United Nations Economic and Social Commission for Asia and the Pacific

능성을 살펴보고자 한다.

따라서 본 연구에서는 최근 극한 기후의 발생 빈도 및 발생 특성을 살펴보고, APCC MME 참여모델들의 극한 기후에 대한 예측력을 객관적으로 평가하고자 한다. 이를 통해 극한 기후 예측에 대한 현재 기후시스템의 수준 및 한계점 등을 분석하고, 최종적으로 APCC 현업적인 측면에서 극한 기후예측을 위한 다중모델앙상블 확률예측기술 개발의 가능성을 평가하고자 한다.

6.2 연구 자료 및 방법

6.2.1 관측 및 모델 자료

본 연구에서는 지난 35년(1982-2016)간의 상·하위 극한 기온/강수의 발생 빈도 및 발생 특성을 분석하기 위해서 NCEP-DOE(Department of Energy)에서 제공되는 위·경도 2.5°간격의 재분석 2 자료를 사용하였다(Kanamitsu et al. 2002). 또한, 관측 강수 자료는 CMAP(Climate Prediction Center Merged Analysis of Precipitation) 자료를 사용하였다(Xie and Arkin 1997). 본 연구의 자료 사용 기간은 1982-2016년의 35년간이며, 계절은 여름철(June-July-August, JJA)과 겨울철(December-January- February, DJF)에 대해서 분석을 수행하였으며, 대상 영역은 전구지역(60°S-90°N)으로 선정하였다.

또한 모델에서 모의되는 상·하위 극한 기온/강수의 예측성을 평가하고, 이를 바탕으로 다중모델앙상블 확률예측기술 개발 가능성을 평가하기 위해 APCC 현업 시스템에서 제공하는 계절예측의 과거 자료(hindcast)를 이용하였다. 사용된 모델들은 현재 APCC 3개월 MME 예측에 참여하는 2개의 대기 예측모델(CWB⁴²⁾, IRI)과 7개의 해양-대기 접합 모델(APCC, MSC⁴³⁾, NASA⁴⁴⁾, NCEP, PNU⁴⁵⁾, BOM⁴⁶⁾, CMCC⁴⁷⁾)이며 관련 정보는 표 6.1에 서술되어 있다. 개별 모델에 따라 hindcast 기간이 다르기 때문에 모델 간의 상호 비교를 위해 본 연구에서는 1982년부터 2005년의 공통기간에 대해 분석하였다.

42) Central Weather Bureau

43) Meteorological Service of Canada

44) National Aeronautics and Space Administration

45) Pusan National University

46) Australian Bureau of Meteorology

47) Centro Euro-Mediterraneo sui Cambiamenti Climatici

Table 6.1. Overview of APCC models used in this study.

Organization	Initialization	Ens.Size	SST Specification	Reference
CWB (Chinese Taipei)	Last 10 days (12Z) of previous month from NCEP Reanalysis version2	10	OPGSST 1.1 from CWB	Liou et al. 1997
IRI (USA)	Restart files from long running ECHAM4.5	24	Ensemble forecasts based on Constructed Analogue SST	Barnston et al. 2010
APCC (Republic of Korea)	GODAS ocean initialization	10	Predicted (APCC/CCSM3 SST Nudging)	Jeong et al. 2012
MSC (Canada)	The CMC Global 4D-var analysis	20	Predicted (OGCM4)	Merryfield et al. 2013
NASA (USA)	MERRA reanalysis	9	Predicted (MOM4)	Vintzileos et al. 2003
NCEP (USA)	CFS data assimilation system each day at 00Z, 06Z, 12Z and 18Z	20	Predicted (GFDL MOM4 global ocean model)	Saha et al. 2006
PNU (Republic of Korea)	NCEP/NCAR Reanalysis 2 in AGCM, OISST data in OGCM	5	Predicted	Park et al. 2004
BOM (Australia)	Nudging to the analyses from the Australian Community Climate and Earth System Simulator	30	Predicted (ACOM2 Ocean model based on GFDL Mon2)	Lim et al. 2012
CMCC (Italy)	Operational analysis ECMWF/CIGODAS-CMCC analysis	9	Operational analysis ECMWF	Alessandri et al. 2010

6.2.2 검증방법

개별 모델 및 MME를 이용한 극한 기후 예측이 관측과 얼마나 유사하게 모의하는지 성능을 평가하기 위해 결정론적 방법(또는 카테고리 예측)에서는 SEDI⁴⁸⁾(Ferro and Stephenson 2011)로 검증하였으며, 확률론적 예측의 검증을 위해서는 WMO에서 권고하는 표준 검증 기법인 ROC⁴⁹⁾(Zhu et al. 2002)와 Reliability Diagram(Hsu and Murphy 1986)을 적용하였다(WMO 2002).

SEDI는 아주 드물게 발생하는 기상현상을 검증하기 위해 고안된 것으로, SEDI의 값이 0보다 크면(작으면) 무작위 예측(random forecast)보다 예측력이 우수함(열등함)을 의미한다(Marshall et al. 2014). 즉, 0.1의 SEDI는 무작위 예측 보다 예측력이 약 10% 높음을 의미한다. SEDI 계산식은 아래와 같으며, 각 항에 대한 자세한 설명은 표 6.2를 참고하길 바란다.

$$SEDI = \frac{\log F - \log H - \log(1 - F) + \log(1 - H)}{\log F + \log H + \log(1 - F) + \log(1 - H)} \quad (\text{식 6.1})$$

ROC는 HR(Hit Rate)와 FAR(False Alarm Rate)의 상대적인 비율로 나타낸 것으로 각 카테고리별로 얼마나 잘 구별하는지에 대한 능력을 평가한다. ROC 곡선이 대각선에 비해 좌측 상단으로 갈수록 예측력이 높음을 의미하며(ROC score > 0.5), ROC 곡선이 대각선에 비해 우측 하단으로 내려올수록 예측력이 낮음을 의미한다(ROC score < 0.5). 즉, ROC 곡선이 대각선상에 위치하면 각 예보 확률별로 HR와 FAR가 동일하므로 예측 능력이 없다고 판단한다.

확률예측 검증에서는 예측확률의 정확도뿐만 아니라 신뢰도 또한 검증 되어야 하는 요소 중 하나이다. Reliability Diagram은 각 카테고리별로 예보확률과 실제로 이벤트가 발생한 빈도를 측정하여 신뢰성을 측정하는 척도이다. Reliability Diagram의 가로축은 예측확률 카테고리(0.0~1.0)이며, 세로축은 각 카테고리별 실제 관측된 이벤트의 확률이다. 대각선에 가까울수록 완벽한 예측성에 가깝고, 대각선보다 위쪽에 나타나는 경우에는 과소모의 한 것이고 대각선보다 아래쪽에 나타나는 경우에는 과대모의 한 것이다.

48) Symmetric Extremal Dependency Index

49) Relative Operating Characteristics

Table 6.2. Relationship between counts of forecast and event pairs for the dichotomous categorical verification situation as displayed in a 2×2 contingency table.

		Event observed		
		Yes	No	
Event forecast	Yes	a	b	a+b
	No	c	d	c+d
		a+c	b+d	a+b+c+d
H = $a/(a+c)$, hit rate				
F = $b/(b+d)$, false alarm rate				

6.2.3 극한 기후 정의

전 세계적으로 극한 기후에 관한 연구와 이에 대한 관심이 증가하고 있으나, 극한기후의 정의에 대해서는 사용자의 목적과 지역 등에 따라 달리 사용되고 있으며, 일반적으로 표준화된 정의는 없다. IPCC 3차 보고서에 따르면 ‘특정기간을 벗어나 발생하는 사상들 자체’를 극한 기상/기후로 정의하고 가뭄, 홍수와 폭염 등과 같이 평균적인 기후에서 벗어난 상태의 기후 현상을 의미하고 있다(IPCC 2001). 보통 기후학적인 분포에서는 통계적으로 어떠한 임계 퍼센타일을 초과하여 발생하는 기상/기후 또는 특정 장소에서 통계적 특성 분포에서 거의 발생하지 않는 기상/기후 현상을 극한 기상/기후로 정의한다(Klein et al. 2009; Abatan et al. 2016). 본 연구에서는 기온 및 강수에 대하여 1982-2005년 과거 계절평균 자료의 각 그리드별 기후학적 분포에서 상·하위 15%를 초과하는 것을 극한 기후로 정의하였다.

6.3 변동성 분석 및 예측성 평가

6.3.1 관측자료 분석

6.3.1.1 극한 기후 변동성 분석

이 장에서는 지난 35년(1982-2016)의 관측 자료를 분석하여 기온 및 강수에 대한 극한 기후의 시·공간적인 특징을 살펴보고자 한다. 그림 6.1은 여름철 각 그리드별 기후학적 분포(23년, 1982-2005)에서 상위 15%를 초과하는 극한 기온 발생의 공간적 분포를 나타내고 있다. 전지구 평균 기온은 1880년에서 2012년까지 약 0.85도의 상승을

가져 왔으며, 지구 온난화로 인해 평균적인 기후 요소의 변동 뿐만 아니라 극한 기상/기후 현상이 증가할 것으로 IPCC 제5차 보고서에서 언급한 바와 같이(IPCC 2013), 지구 온난화로 인해 여름철 상위 15% 극한 기온 발생 지역이 뚜렷하게 증가하는 모습을 보이며, 특히 2000년대에 들어서는 극지방에서의 극한 기온의 증가가 뚜렷하게 나타났다. 이러한 특징은 겨울철 상위 15% 극한 기온에서도 동일한 결과를 보였으며, 하위 15% 극한 기온의 감소 또한 여름/겨울철 모두 뚜렷한 모습을 보였다(그림 미 제시).

이를 바탕으로 전지구 면적에 대한 상·하위 15% 극한 기후의 상대적인 비율을 통해 최근 35년 동안의 극한 기후 경년 변동성을 살펴보고자 한다(그림 6.2). 우선 극한 기온에 대한 변동성을 살펴보면, 앞서 그림 6.1과 많은 선행연구에서 분석한 바와 같이(Alexander et al. 2006; Donat et al. 2013) 온난화로 인해 전지구 연평균 기온이 증가하면서 상위(하위) 15% 극한 기온의 발생빈도는 지난 35년 동안 여름·겨울철에 약 750%(82%)와 380%(47%) 각각 증가(감소)하였다. 특히 상위 15% 극한 기온의 증가가 하위 15% 극한 기온의 감소에 비해 변동성이 큰 것으로 나타났다(Kodra and Ganguly 2014). 또한, 상위 15% 극한 기온의 발생빈도는 여름/겨울철 모두 전지구 연평균 기온의 증가 추세보다 큰 것을 확인 할 수 있다(Robeson et al. 2014). 극한 기온의 변동성을 계절별로 좀 더 살펴보면, 상·하위 15% 극한 기온 모두 여름철이 겨울철에 비해 증가/감소의 변동성이 크게 나타났다. 이는 인간활동과 같은 인위적인 배출량에 의한 지구 온난화로 전지구 기온변화 경향이 비대칭적으로 계절별로 다르게 예측한 Cohen (2012)의 연구와 유사하다.

연평균 기온 및 상·하위 15% 극한 기후의 경년 변동성은 ENSO 및 화산활동 등과 관련이 깊은 것을 확인할 수 있다(Ghil and Vautard 1991; Jones 1994). 특히, 연평균 기온 및 상위 15% 극한 기온의 경년변동성은 대체적으로 ENSO 발달/소멸 시기와 비슷한 양상을 보이고 있다(예, 1997/98년, 2015/16년 등). 또한, 하위 15% 극한 기온의 감소 추세에도 불구하고 이례적으로 전지구 면적의 30% 이상에서 저온극한 현상이 발생한 1992년의 경우는 1991년 필리핀 Pinatubo 화산 활동의 영향으로 인한 cooling 효과로 전지구 연평균 기온 하강과 연관되어 있다(McCormick et al. 1995; Robock 2000).

강수의 경우 기온과 달리 그 변동성이 크게 나타나고 있진 않지만 지난 35년 동안

연평균 강수량이 점차 줄어들면서 상(하)위 15% 극한 강수가 감소(증가)하는 경향을 보였다. 특히, 두 계절 모두 하위 15% 극한 강수의 감소가 상위 15% 극한 강수의 증가에 비해 5배 정도로 크게 나타났으며, 상·하위 15% 극한 강수 모두 겨울철의 감소/증가 변동성이 여름철에 비해 크게 나타났다.




Figure 6.1. Spatial distribution of upper 15% extremes for JJA temperature during the period 1982–2016.




Figure 6.2. Interannual variability of the upper/lower 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) over globe for the period 1982–2016.

6.3.1.2 극한 기후 최근 경향 분석

다음은 최근 발생하는 극한 기온 및 강수의 지역적 분포를 살펴보기 위해 각 그리드별 24년(1982-2005년)의 기후학적 분포에 대한 최근 11년(2006-2016) 동안의 상·하위 15% 극한 기후 발생 확률을 계절별로 살펴보았다(그림 6.3). 즉, 붉은(파란) 색은 상·하위 15% 극한 기온의 발생 확률을 나타내며, 45%의 값을 보이고 있는 지역은 최근 11년 동안 5번 정도 극한 기온이 발생했음을 의미한다. 여름/겨울철 모두 상위 15%의 극한 기온 발생 지역이 하위 15%의 극한 기온 발생 지역보다 넓게 분포하며, 특히 여름철 상위 15% 극한 기온의 발생이 최근 들어 상당히 증가하는 것을 다시 한 번 확인할 수 있다(그림 6.2와 동일한 결과). 최근 11년 동안 여름철 상위 15% 극한 기온은 남인도, 흑해 주변 유럽국가, 남미 북쪽지역에서 80% 이상 발생했으며, 카리브해, 캐나다 북동부 그리고 그린란드 등은 겨울철 상위 15% 극한 기온이 주로 발생한 지역과 동일하나 그 면적에 있어서 겨울철에 비해 넓게 분포하며 최근의 증가 추세도 강하게 나타난다. 그러나 하위 15% 극한 기온의 발생 지역은 여름철 칠레 및 아르헨티나 서부지역과 겨울철 남미 남부 일부지역으로 한정되어 나타난다.




Figure 6.3. Recent trend in the occurrence probability of the upper/lower 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) for the period 2006-2016.

강수의 경우 앞서 분석에서 살펴본 바와 같이 기온에 비해 상·하위 15% 극한 강수의 변동성이 작게 나타났으며, 최근 극한 강수의 증가 지역 또한 극한 기온에 비해 지역적인 편차가 크게 나타나는 경향을 보였다. 최근 증가추세가 상대적으로 컸던 하위 15% 극한 강수는 대부분 극지방에서 기인한 것을 알 수 있으며, 이는 최근 온난화로 인해 급격히 줄어들고 있는 북극해빙과 관련이 있는 것으로 보이나 더 자세한 분석은 추후 이루어져야 할 것이다.

6.3.2 APCC 참여모델 및 MME 예측력 평가

APCC 참여모델이 모의한 극한 기후 변동성을 우선으로 검증하여 MME를 활용한 극한 기온/강수 확률예측 기술 개발 가능성을 살펴보고자 하였다. 그림 6.4는 관측과 동일한 방법을 적용하여 APCC 참여 모델과 MME의 상위 15% 극한 기후의 경년변동성을 나타낸 것이다. 먼저 극한 기온의 경우, APCC MME에 참여하는 9개 모델과 MME 모두 전반적으로 관측에서 나타나고 있는 극한 기온의 경년 변동성을 잘 모의하는 것으로 보인다. 즉, 관측에서 상위 15% 극한 기온의 발생빈도가 ENSO의 발달/소멸 시기와 비슷한 양상을 보인 것과 같이 APCC MME와 참여 모델 또한 이러한 변동성을 잘 모의하고 있다. 그 결과, 개별 모델이 모의한 상위 15% 극한 기온 경년 변동성과 관측과의 상관관계수(TCC)는 여름철(겨울철)에 0.52-0.86(0.52-0.88)로 나타났으며, 9개 모델 평균 약 0.72(0.76)를 보이고 있다(표 6.3). MME는 개별 모델에 비해 다소 높은 값의 상관관계수(여름철: 0.82, 겨울철: 0.90)를 보임으로서 관측에서 나타나고 있는 상위 15%의 극한 기온의 경년 변동성을 개별 모델 보다 잘 모의하는 것을 알 수 있다. 즉, 극한 기온의 변동성을 모의함에 있어 MME로 인한 예측력 향상 효과를 기대할 수 있을 것으로 판단된다. 그러나 극한 기온의 발생확률이 상대적으로 낮은 80~90년 중반에는 과소 모의하는 반면 극한 기온의 발생확률이 높은 2000년대의 경우 과대 모의하는 경향을 보였다. 이러한 경향성은 특히 겨울철에 두드러지게 나타났다. 강수의 경우 관측에서 나타난 것과 같이 APCC MME 및 개별모델 모두에서 그 변동성이 크지 않았으며, 개별 모델간의 예측 편차(spread)도 기온에 비해 상대적으로 작게 나타났다. 또한 예측력에 있어서도 기온에 비해 낮은 것으로 나타났다. 이렇게 기온에 비해 상대적으로 낮은 예측력의 개별모델을 이용하여 MME를 수행한 결과, 극한 강수의 여름철(겨울철) 상관관계수는 0.24(0.22)로 낮은 값을 보였다. 즉, 개별모델에 대한 MME 예측력 향상은 개별모델의

평균 예측력이 높을수록, 모델간의 독립성이 클수록 크게 나타나기 때문에(Yoo and Kang 2005), 결정론적 예측에 있어서 상위 15% 극한 강수의 경우 MME를 통한 예측력 향상은 나타나지 않는 것으로 판단된다.




Figure 6.4. Interannual variability of the upper 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) during the period 1982–2005 from the individual models (circle) and their simple averaged MME (solid line), with the corresponding observation (dashed line).

Table 6.3. Temporal correlation coefficient (TCCs) for the probability of occurrence of upper 15% extremes for JJA/DJF temperature and precipitation from individual models and observation for the period 1982–2005.

	Temperature		Precipitation	
	JJA	DJF	JJA	DJF
MME	0.82	0.90	0.24	0.22
CVB	0.54	0.61	0.57	0.20
IRI	0.69	0.76	0.27	0.26
APCC	0.70	0.87	-0.09	0.11
MSC	0.76	0.88	0.17	0.38
NASA	0.86	0.84	-0.12	0.25
NCEP	0.76	0.75	0.31	0.11
PNU	0.66	0.52	0.16	0.12
BOM	0.78	0.87	0.08	0.28
CMCC	0.75	0.77	-0.09	0.35

APCC 참여모델과 MME의 상·하위 15% 극한 기온 및 강수의 예측력을 보다 정량적으로 평가하기 위해 카테고리 예측 정확도 측정 방법 중 아주 드물게 발생하는 기상현상 검증에 위해 고안된 SEDI를 적용하였다(그림 6.5). 상위 15% 극한 기온 예측의 경우 여름철, 겨울철 9개 모델 평균 SEDI는 약 0.41(0.37-0.45 범위)과 0.42(0.36-0.46 범위)로 나타났으며, 겨울철의 극한 기온 예측력이 여름철에 비해 상대적으로 높은 것으로 나타났다. 이는 겨울철 전구 평균 기온의 높은 예측력은 대부분 ENSO 발달과 관련이 있다는 선행 연구(Wang et al. 2009a; Min et al. 2014)와 같이 극한 기온 예측력에서도 동일한 결과를 보였다. 그리고 MME의 여름철, 겨울철 SEDI는 각각 0.45, 0.48로 개별모델에 비해 예측력이 상대적으로 높음을 그림 6.5를 통해 다시 한 번 확인 할 수 있다. 극한 강수 예측의 경우, 9개의 개별모델과 MME 모두 기온에 비해 예측력이 낮긴 하지만, MME는 여름철(겨울철) 0.35(0.37)로 개별모델 평균 0.33(0.34) 보다 예측력이 높게 나타난다. 또한 극한 기온에서 나타난 것과 동일하게 여름철에 비해 겨울철의 극한 강수의 예측력이 향상되나, 극한 기온의 예측력 향상에 비해 그 정도가 작은 것으로 보인다. 개별모델을 좀 더 자세히 살펴보면 여름철(겨울철) 9개의 개별 모델은 무작위 예측 보다 약 31-37%(32-38%) 높은 예측력을 보이며, 상위 15%의 극한 강수에 대한 예측력은 극한 기온의 예측력에 비해 9개 개별 모델간의 예측력 차이가 그리 크지 않는 것으로 나타났다. 개별모델 중 BOM의 SEDI는 여름철(겨울철)에 0.37(0.38)으로 9개의 개별 모델 중 가장 높은 예측력을 보였으며, MME와 유사할 정도의 높은 예측력을 보였다.

MME 예측에서의 여름·겨울철의 극한 기온 및 강수의 SEDI 공간적 분포를 통해 지역적인 예측력 특성을 살펴보면(그림 6.6), 여름철 상위 15% 극한 기온은 태평양, 대서양 지역을 포함한 대부분 해양과 그 인근 지역에서 높은 예측력을 보이며, 북 아시아 지역, 북아메리카 등 고위도의 내륙지역에서는 낮은 예측력을 보인다. 겨울철 상위 15% 극한 기온은 여름철과 전체적으로 예측력이 높은 지역이 비슷하게 분포하나 그 면적에서 여름철에 비해 넓게 분포하는 것으로 나타났다. 특히, 인도, 북 아프리카 그리고 중국 내륙 등 육지의 많은 지역에서도 무작위 예측보다 약 20%의 예측력이 높은 것으로 나타난다. 그 결과, 겨울철 극한 기온의 예측 능력이 여름철에 비해 높다는 것을 다시 한 번 확인할 수 있다. 반면, 극한 강수의 경우는 예측력은 대부분 서태평양, 대서양 및 적도 지역의 해양에서 나타나고 있다. 즉, 상위 15%의 극한 기온 및 강수 예측력의 공간적 분포는 Min et al. (2014)의 선행연구에 언급된 계절 평균의 기온 및 강수량 예측력 분포와 유사한 것으로 보인다.




Figure 6.5. Symmetric Extremal Dependency Index (SEDI) of upper 15% extremes for JJA/DJF a) temperature and b) precipitation from individual models and MME. Dashed (solid) line indicates the average of the individual models' SEDI in JJA (DJF) for the period 1982–2005.




Figure 6.6. Spatial distribution of SEDI of the upper 15% extremes for JJA/DJF temperature (a, c) and precipitation (b, d) from MME prediction for the period 1982–2005.

6.4 MME를 활용한 극한 기후 확률예측기법 개발

6.4.1 분포도 적합성 검정

3.2.2장에서 설명한 바와 같이, 예측확률을 추정하는 방법은 크게 비모수화 방법과 모수화 방법으로 나눌 수 있으며, 비모수화 방법은 과거자료(hindcast)에서 각 변수의 기준 값(예, 상/하위 15%)을 산정하고, 예측하고자 하는 해의 앙상블 멤버 중 기준값을 초과하는 앙상블 수를 전체 앙상블 수로 나누어 확률값을 계산한다(그림 3.3a 참고). 모수화 방법은 과거자료가 통계적인 분포를 따른다는 가정 하에, 통계적 분포의 확률밀도 함수(PDF)를 이용하여 기준값을 결정하고, 예측하고자 하는 해의 PDF에서 기준값을 초과하는 면적으로 계산한다(그림 3.3b 참고). 따라서, 모수화 방법은 실제 사용하는 자료(sample) 분포를 특정 통계적인 분포로 가정하기 때문에, 샘플이 얼마나 통계적인 분포를 따르는가에 따라 결과가 달라질 수 있다. 따라서 모수화 방법 적용에 앞서 샘플의 분포도 검정이 선행되어야 한다. 계절예측에 사용되고 있는 월평균 기온, 지위고도 등의 변수는 일반적으로 정규분포를 따른다고 알려져 있으며, 강수량의 경우 여전히 논란의 여지가 있다. 하지만 Min et al. (2009)에 따르면, 관측 및 모델이 모의한 계절평균 기온 및 강수는 대부분의 지역에서 정규분포를 따르며, 특히 강수에 대해선 정규분포와 Gamma 분포에 따른 예측확률 차이 및 예측력의 차이가 유의하지 않기 때문에 강수 또한 정규분포를 활용한 모수화기법이 전구를 대상으로 할 경우 현업적인 측면에서는 가장 적절함을 밝혔다. 하지만 Min et al. (2009)에서 분석했던 모델과 현재 APCC MME의 참여 모델로써 본 연구에서 극한기후예측을 위해 활용하고 있는 모델은 서로 상이하기 때문에, 동일한 방법을 적용하여 새로운(최신의) 모델 자료에 대한 분포도 검정을 다시 수행하였다.

극한 기온 및 강수의 확률예측기술 개발에 앞서, 각 변수의 분포가 정규 분포를 따르는지 검증하기 위해 K-S 검정(Kolmogorov 1933; Smirnov 1984)과 A-D(Anderson and Darling 1954) 검정을 수행하였다(그림 6.7). K-S 검정은 샘플 자료의 누적분포함수(Cumulative Distribution Function, CDF)와 이론적으로 가정한 분포의 CDF와의 최대 편차가 특정 임계값(유의 수준에 따라 달라짐)을 초과할 경우 샘플과 이론적 확률분포는 통계적으로 다른 분포임을 의미한다. 그러나 통계적 분포 검정에 널리 사용되는 K-S 검정은 이론적 가설분포를 어떤 분포로 설정했는가에 따라 변하지 않으며, 샘플 크기에

의존하지 않는 장점을 가지는 반면, 분포도의 꼬리부분보다는 관찰치가 많은 분포의 중앙 근처에서의 차이에 민감하다는 단점을 가지고 있다. A-D 검정은 샘플이 특정 이론분포와 동일한지를 판별하기 위한 통계적인 검정기법으로 꼬리부분에 가중치를 부여함으로써 K-S 검정의 단점을 보완한 방법이다. 따라서 본 연구에서는 두 가지 검정기법을 모두 활용하여 분포도 테스트를 수행하였다.

그림 6.7은 24년(1982-2005년) 관측자료의 여름/겨울철 기온 및 강수에 대한 K-S 및 A-D 검정의 정규분포 적합도 결과이다. 그림에서 파란실선(회색음영) 부분은 각 계절 평균 기온 및 강수가 유의수준 5%에서 K-S(A-D) 검정 결과 정규분포를 따르지 않는 지역을 의미한다. 두 개의 통계적 검정기법을 비교해보면, A-D 검정 결과 통계적으로 유의하지 않은 지역의 범위가 넓게 나타나는데, 이는 꼬리부분에 민감한 A-D 검정이 K-S보다 좀 더 엄격한 기준을 따르기 때문이다. 예상 할 수 있듯이, 계절평균 기온은 두 계절 모두 대부분의 지역에서 통계적으로 정규 분포를 따르는 것으로 나타났고, 강수 또한 일부지역을 제외하고는 대부분의 지역에서 정규분포를 따르는 것으로 두 검정결과 모두 동일하게 나타났다. 단, 강수에서 K-S 및 A-D 검정 결과 정규 분포를 따르지 않는 지역은 아프리카 남쪽과 북쪽 지역, 오스트리아, 적도 동태평양 지역으로 이 지역들은 대부분 사막 이거나 연평균 강수량이 다른 지역에 비해 상당히 적은 지역이다(Min et al. 2009). 즉, 전구를 대상으로 한 관측의 계절평균 기온 및 강수 분포는 대부분의 지역에서 통계적으로 정규분포를 따름을 확인 할 수 있다.

그렇다면 과연 실제 예측에 활용되는 개별모델의 계절평균 기온 및 강수는 관측과 동일하게 정규분포를 따를 것인가를 확인하기 위해 관측과 동일한 방법을 개별모델에 대해 적용하였다. K-S 및 A-D 검정 결과, 개별 모델에서 예측한 기온 자료는 관측과 동일하게 대부분의 지역에서 통계적으로 정규분포를 따르는 것으로 나타났다(그림 미 제시). 여름철 강수의 경우(그림 6.8), 개별 모델별로 약간의 지역적인 차이는 존재하나, 관측과 동일하게 아프리카 및 적도 동태평양 일부 지역을 제외한 대부분의 지역에서 유의 수준 5% 내에서 정규분포를 따르는 것을 확인 할 수 있다(그림 6.8; 겨울철도 동일한 결과, 그림 미 제시). 즉, 관측과 모델에 대해 통계적 검정을 수행한 결과, 계절평균 기온 및 강수 모두 정규분포를 따르는 것으로 나타났으며, 특히 강수에서 정규분포를 따르지 않는 극히 일부지역은 강수량이 상당히 작은 지역으로 극한 강수에 대한 관심도(또는 중요

도)가 상대적으로 낮고, 또한 최근 극한 강수의 증가/감소 지역과도 일치하지 않는다는 점(그림 6.3) 등을 종합적으로 판단해보면, 본 연구에서 극한기후 확률예측을 위한 모수화 기법 적용 시, 계절평균 기온 및 강수의 분포를 정규분포로 가정할 수 있을 것으로 판단된다.




Figure 6.7. Anderson-Darling (A-D) and Kolmogorov-Smirnov (K-S) Tests for the normality of JJA/DJF (a) temperature and (b) precipitation. Shaded areas (contours) are the regions where the observed PDFs differ from the empirical normal PDFs at the 5% significance level from the AD (KS) tests.




Figure 6.8. Same as Figure 6.7, except for only JJA precipitation from individual models.

6.4.2 모수화/비모수화 기법에 따른 예측력 평가

6.4.2.1 예측확률 차이에 대한 분석

분포도 검정 결과를 바탕으로, 본 연구에서는 비모수화 방법(Empirical Ranking Method; 이후, EMP 명명)과 Gaussian fitting 방법을 활용한 모수화 방법(이후, GAUS 명명)에 따른 극한 기후 예측확률의 차이를 살펴보았다. 그림 6.9-10은 EMP와 GAUS 방법에 따른 개별 모델 및 MME가 예측한 상위 15% 극한 기온에 대한 확률 예측의 한 예이다. 1998년 여름철을 선정한 이유는 1997/98 겨울철에 발달한 강한 엘니뇨로 인해 1998년 전지구 연평균 기온이 상승하고, 이로 인해 특히 여름철 상위 15% 극한 기온의 발생지역이 급격하게 증가했기 때문이다(그림 6.2). 관측에서 나타난 극한 기온의 지역적 발생분포를 개별 모델과 MME는 대체로 잘 모의하는 것으로 나타났다(MME 예측결과는 6.4.3에서 따로 자세히 설명하겠음). 즉, 1997/98년 겨울철 발달한 강한 엘니뇨의 영향으로 인도양, 북서태평양 및 인도차이나와 말레이 반도를 포함하는 동남아시아, 캐나다 북부, 중미, 서시베리아에서 관측된 상위 15%의 극한 기온 발생 지역에 대해 대부분의 모델들은 극한 기온 발생 확률을 70% 이상 예측하면서 1998년 여름철 관측에서 나타난 극한 기온 발생 지역을 잘 모의 하는 것으로 판단된다. 개별모델에 대해 좀 더 살펴보면, IRI 모델은 1997/98 여름철 극한 기온예측에 있어서 타 모델에 비해 인도양과 대서양 지역에서 높은 극한 기온 발생 확률을 예측한 반면, PNU 모델은 관측과 비교 했을 때 특히 인도양지역에서 극한 기온의 발생을 예측하는데 한계가 있음을 보여준다.

예측확률 추정방법(GAUS와 EMP)에 따른 극한 기후 예측확률의 차이를 살펴보면(그림 6.9와 6.10 비교), 두 방법론 간에 큰 차이를 보이고 있진 않지만 대체로 GAUS가 EMP에 비해 상위 15%의 극한 기온 발생 확률이 좀 더 넓은 지역까지 분포하며, 그 확률 값에 있어서도 높게 예측하였다. 이러한 특징은 여름철 상위 15% 극한 강수에서도 동일한 결과를 보였다(그림 미 제시). 다음은 두 가지 예측확률 추정 기법에 따른 계절별 예측확률 차이를 전체 분석기간에 대해 살펴보았다(그림 6.11). 각 포인트는 연도별(1982-2005년)/계절별(매월 3개월 평균값; JFM-DJF) 예측확률 차이의 전구 평균 및 최대값을 의미한다. 극한 기온의 경우, GAUS와 EMP에 따른 예측확률 차이의 평균은 강수에 비해 넓게 분포하고 있으며, 예측확률 차이의 최대값은 강수에서 크게 나타났다.

또한, 확률 추정 기법에 따른 예측확률의 차이는 개별 모델의 앙상블 수에 영향을 받는 것으로 보인다. 즉, 상대적으로 앙상블 수가 작은 PNU와 CMCC에서 두 기법에 따른 예측확률 차이가 크게 나타났다. EMP 방법은 샘플의 분포를 그대로 사용한다는 점에서 장점일 수는 있지만, 샘플의 수가 적을 경우 표본오차(sampling error)가 증가한다는 단점이 있다. 이에 반해 GAUS는 샘플 분포로부터의 매개변수(예, 평균, 분산 등)를 이용하여 통계적인 정규분포 PDF를 활용하여 예측확률을 추정하기 때문에 샘플의 수가 적을 경우 EMP에 나타나는 표본오차가 보완된다는 장점이 있다. 따라서 상대적으로 앙상블 수가 작은 모델에서 두 기법에 따른 예측확률의 차이는 크게 나타나게 된다.




Figure 6.9. Probabilistic forecasts of upper 15% extremes for JJA 1998 temperature using empirical ranking method (EMP), as an example.




Figure 6.10. Same as Figure 6.9, except for using Gaussian fitting method (GAUS).




Figure 6.11. Difference in probability of upper 15% extremes for a) temperature and b) precipitation from two different methods (EMP and GAUS) to estimate forecast probabilities.

6.4.2.2 예측력 차이에 대한 분석

극한 기후 확률추정 방법에 따라 예측확률의 차이가 발생하며, 특히 앙상블 수가 작은 모델에서 예측확률의 차이가 큼을 앞선 분석들을 통해 확인할 수 있었다. 그렇다면 이러한 확률추정 방법에 따른 극한 기후의 예측확률 차이가 실제 예측력에도 영향을 미치는지 살펴보기 위해 과거자료에 대한 예측력을 ROC score를 활용하여 비교/평가하였다(그림 6.12-13). ROC score는 ROC 곡선 아래의 면적을 의미하며, ROC score ≥ 0.5 이면 예측력이 있으며, 1에 가까울수록 예측력은 높음을 의미한다. 두 가지 확률추정 기법에 따른 전지구 평균 극한 기온에 대한 개별 모델의 예측력 차이는 여름/겨울철 모두 크지는 않지만, 거의 모든 모델에서 정규분포를 활용한 GAUS가 EMP에 비해 예측력이 높게 나타나는 경향을 보였다. GAUS에 의한 극한 기온의 예측력 향상(Relative Skill Difference⁵⁰⁾)은 여름/겨울철 9개 모델 평균 각각 0.8%와 1.0%로 나타났으며, 강수에서도 두 계절 모두 동일하게 GAUS에 의한 예측력 향상이 나타났다. 그리고 GAUS에 의한 예측력 향상은 강수에 비해 기온에서 다소 크게 나타났다. 이는 계절평균 기온이 강수에 비해 정규분포를 잘 따르기 때문으로 보이며, 보다 정확한 원인 분석은 추후 수행되어야 할 것이다.

EMP와 GAUS 기법을 3분위 카테고리에 대한 계절평균 기온에 적용하여 확률 예측(tercile 확률예측⁵¹⁾)에 대한 예측력을 비교/평가한 선행연구가 있으며(Tippett et al. 2007), GAUS 기법이 EMP에 비해 평균제곱근편차(RMSE⁵²⁾)가 작고, RPSS⁵³⁾ 예측력은 높다고 밝혔다. 하지만 Tippett et al. (2007)에서 밝힌 RPSS 예측력 향상(GAUS-EMP)은 지역적으로 편차가 크긴 하지만, 전구 육지에 대한 RPSS 예측력 향상의 평균값은 0.023으로 상당히 작음을 알 수 있다. 즉, 보다 정확한 예측 확률을 추정하고 그로인해 예측력이 높은 방법을 선정하기 위해 본 연구에서는 예측확률 추정 기법을 비교했으며, 이것은 개별모델의 개선 또는 예측기술 개발 등과 같은 통계적으로 유의한 정도의 예측력 차이를 기대하기는 사실상 힘들다고 볼 수 있다. 따라서 두 기법간의 실제 예측력 차이는 크지 않지만, 그럼에도 불구하고 대부분의 모델에서 GAUS 기법이 EMP에 비해

50) $RSD = ((GAUS-EMP)/EMP)*100$

51) 평년보다 높음/비슷/낮음에 대한 예측확률

52) Root Mean Square Error

53) Ranked Probability Skill Score

예측력이 높게 나타나는 일관된 결론을 보여준다는 것은 현재 극한 기후를 대상으로 한 확률예측기법개발에 관한 연구가 전무한 상황에서 상당한 의미가 있다고 보여진다. 따라서 앞서 분석한 결과들을 종합해보면, 상위 15% 극한 기온 및 강수에 대한 예측확률 추정 시 정규 분포를 활용한 모수화 방법이 적절하다고 판단된다.




Figure 6.12. ROC score aggregated over globe of probabilistic forecast of upper 15% extremes for a) JJA and b) DJF temperature.




Figure 6.13. Same as Figure 6.12, except for precipitation.

6.4.3 다중모델앙상블 기법

개별모델에 대한 MME 예측력 향상은 이미 많은 선행 연구에서 밝힌 바 있으며(Peng et al. 2002; Palmer et al. 2004), 본 연구에서는 극한 기후 확률예측기법 개발을 위해 다중모델앙상블 방법을 적용하였다. 최근 MME 연구들을 살펴보면, 다양한 통계적 기법을 활용하여 개별모델 예측력에 가중치를 부여하는 기법(calibrated MME)들에 대한 연구가 활발히 진행 중이며, 특정지역/계절에 대해서 개별모델의 예측력을 단순평균하는 MME(uncalibrated MME)에 비해 높은 예측력을 보이고 있다(Luo et al. 2007; Casanova and Ahrens 2009; Fraley et al. 2010; Rodrigues et al. 2014). 하지만, calibrated MME 기법 개발에 관한 대부분의 연구는 과거예측 기간에 대한 예측력 평가이며, 실시간 예측 적용 시 여러 가지 문제(예, overfitting 문제, 짧은 과거예측 기간에

의한 불완전한 통계적 연관성, 최근에 달라진 기후요소들 간의 연관성 등)들로 인해 과거 예측에서 나타났던 만큼의 예측력 향상은 보이지 않는 경우가 많다(Kug et al. 2008; Kharin and Zwiers 2002). 최근 Min et al. (2014)은 과거(1983-2005년) 및 실시간(2013-2015년) 예측 기간에 대해 다양한 MME 기법들의 예측력을 종합적으로 비교/평가했으며, 그 결과 전구를 대상으로 하는 현업적인 측면의 계절평균 기온 및 강수량 예측을 위해서는 단순평균 MME 기법이 가장 적절하다고 언급하였다. 따라서 본 연구에서는 확률예측에 있어서 가장 널리 활용되고 있는 2개의 uncalibrated MME 기법을 우선적으로 극한기후에 적용하여 예측력을 비교하고자 한다. 하지만, 극한 기후는 계절평균 기온 및 강수와 다른 결과를 초래할 수도 있기 때문에 극한 기후에 대한 다양한 MME 기법의 예측력 비교/평가 연구 또한 추후 수행되어야 할 것으로 보인다.

극한 기후 확률예측을 위해 본 연구에서 사용된 방법은 개별모델의 예측확률을 먼저 추정하고, 이를 단순평균하는 방법(이후, MME_i로 명명; 그림 3.4a 참고)과, 개별모델의 모든 앙상블 멤버로 이루어진 하나의 단일모델 분포도를 활용하여 예측확률을 추정하는 방법(이후, MME_p로 명명; 그림 3.4b 참고)을 적용하였다. MME_i는 현재 APCC, WMO LC-LRF, NMME, IRI 및 ECMWF에서 3분위 확률예측을 위해 사용하고 있는 MME 기법이다. 개별모델에서 분석했던 방법과 동일한 방법을 MME 기법들에 대해 적용하였다. 우선, 예측확률 추정기법에 따른 MME 예측확률의 차이를 살펴보면(그림 6.9-10), 1998년 여름철 상위 15% 기온예측에 있어서 대체로 GAUS가 EMP에 비해 극한 기온 발생지역을 좀 더 넓게, 확률값은 높게 예측하는 경향이 나타났다. 이러한 경향은 개별모델에서도 동일하게 나타나는 특징이다. 예측확률 추정기법에 따른 전체분석 기간에 대한 MME 예측확률 차이는 일반적으로 개별모델에 비해 작으며, MME_i가 MME_p에 비해 그 차이는 작게 나타났다(그림 6.11).

다음으로 GAUS와 EMP 기법에 따른 MME 예측력 차이를 살펴보면(그림 6.12-13), 개별모델에서 나타난 것과 같이 MME에서도 극한 기온 및 강수 모두 GAUS가 EMP에 비해 예측력이 높게 나타났다. 하지만, MME에서 GAUS에 의한 예측력 향상(RSD)은 개별모델과는 달리 기온에 비해 강수에서 크게 나타났다. 또한, 극한기후 확률 예측에 있어서 MME 예측력은 모든 변수와 계절에 대해서 개별모델의 평균 예측력 뿐만 아니라 개별모델 중 가장 좋은 예측력을 보인 BOM에 비해서도 높은 예측력을 보였다. 이는

앞서 제시한 극한 기온 및 강수에 대한 카테고리(결정론적) 예측결과의 SEDI 검증과 비교했을 때(그림 6.5), 개별모델에 대한 MME 예측력 향상은 확률론적 예측에서 더욱 더 효과적임을 확인 할 수 있다. 특히, 이러한 특징은 극한 강수에서 두드러지게 나타났다. 즉, MME를 활용한 극한 기온 및 강수의 확률 예측은 개별모델에 비해 예측력이 높으며, 결정론적 예측에 비해서도 좋은 예측 정보를 제공할 수 있음을 확인 할 수 있다(Doblas-Reyes et al. 2005; Hagedorn et al. 2005; Alessandri et al. 2011; Yang et al. 2016).

마지막으로, 다중모델앙상블 방법론에 따른 예측력을 살펴보면, 전반적으로 MMEp가 MMEi에 비해 예측력이 높음을 알 수 있다. 이는 극한 기후의 특성상, 평균에 가까운 정보보다 평균적인 분포에서 벗어난 사건에 대한 정보를 중요시하기 때문에 개별모델의 극한예측정보를 다시 평균하는 MMEi는 개별모델의 극한 정보가 상쇄되는 효과가 있다. 이에 반해 MMEp는 개별모델의 모든 앙상블 멤버를 활용하기 때문에 MMEi에 비해 개별모델의 극한에 대한 정보가 상대적으로 많이 반영되어 극한 기후예측에 좀 더 적합한 방법이라 판단된다.

6.4.4 예측력 평가

지금까지 분석 결과들을 종합해보면, 전구 규모의 상위 15% 극한 기온 및 강수 확률예측을 위해 개별모델의 모든 앙상블 멤버를 활용하여 하나의 super-ensemble 분포를 만들고(MMEp), 모수화(GAUS)방법을 적용하여 극한 기후에 대한 예측확률을 추정하는 방법이 가장 예측성이 높게 나타났다. 이에 본 연구에서는 GAUS와 MMEp 방법을 적용한 극한기후 확률예측기법(PMME-E: Probabilistic Multi-Model Ensemble for Extreme)을 개발하여 과거예측 기간에 대한 객관적인 예측력 평가를 통해 APCC 현업적인 측면에서 극한기후 확률예측정보가 기후서비스로의 발전 가능성이 있는지 판단하고자 한다. 이때 사용된 검증기법은 ROC 곡선과 Reliability Diagram(RD)으로 WMO에서 권고하는 중·장기 확률예측의 표준 검증기법이다(WMO 2002). 그림 6.14는 24년(1982-2005)에 대한 여름/겨울철 상위 15% 극한 기온 및 강수 예측력을 ROC 곡선으로 나타낸 것이다. PMME-E의 ROC 곡선은 대각선을 기준으로 가장 좌측 상단에 위치하고 있으며, 이는 PMME-E가 개별 모델에 비해 예측력이 높음을 의미한다($HR > FAR$).

계절별로 살펴보면, PMME-E는 극한 기온 및 강수 모두 여름에 비해 겨울철 예측력이 다소 높게 나타났다. 강수의 경우, 개별모델과 PMME-E 모두 기온에 비해 ROC 곡선이 대각선에 가깝게 위치하면서 극한 기온에 비해 예측력이 낮지만, 무작위 예측에 비해서는 여전히 예측력은 있음을 알 수 있다.

ROC 곡선은 HR과 FAR의 상대적 비율을 나타낸 것으로 극한 기후를 얼마나 잘 구별하는지에 대한 능력을 평가한다(즉, resolution). 극한 기후에 대한 카테고리를 잘 맞추는 것도 중요하지만, 극한 기후 발생빈도에 대한 정확도(즉, reliability) 또한 확률예측 검증에 있어서 중요한 부분이다. 이를 위해, 여름/겨울철의 상위 15% 극한 기온 및 강수에 대한 RD를 그림 6.15에 나타내었다. 모든 모델은 극한 기온/강수 발생빈도를 과대모의하는 경향을 보였으며, BOM을 제외한 대부분의 모델은 극한 기온 및 강수 예측에 있어서 여름/겨울철 모두 신뢰도면에서 예측력이 없는 것으로 나타났다. 이에 반해, PMME-E의 RD는 모든 변수와 계절에서 대각선과 상당히 가까우며, 이는 관측에서 나타난 발생빈도와 유사한 예측확률을 제공함으로써 예측력이 높다는 것을 의미한다. NCEP의 경우, 극한 기온/강수 발생빈도에 대한 신뢰도(RD)가 BOM 다음으로 높은 편에 속하나, ROC 곡선을 살펴보면 다른 모델에 비해 극한기후 카테고리를 구별하는 능력이 낮은 그룹에 속한다. 즉, 어떤 검증기법을 활용하느냐에 따라 예측력 평가는 달라질 수 있으며, 확률예측 검증에 있어서는 ROC 곡선과 RD를 함께 분석하여 종합적인 결론을 내릴 필요가 있다. 이러한 이유로 WMO에서도 두 방법을 함께 사용하기를 권고하고 있다(WMO 2002). 두 가지 검증기법에 대한 예측력 평가를 종합해보면, PMME-E는 상위 15% 극한 기온 및 강수 예측에 있어서 개별모델에 비해 높은 예측력을 보이고 있음을 확인할 수 있다.

그렇다면, 현재 APCC에서 홈페이지를 통해 제공하고 있는 3분위 확률예측의 예측력과 비교해서 PMME-E의 예측력은 어느 수준인지에 대한 평가도 필요하다. PMME-E가 개별모델에 비해 높은 예측력을 보인다 할지라도, 극한 기후에 대한 예측력 자체가 상당히 낮다면 기후서비스로 발전하기는 힘들기 때문이다. 현재 세계유수 현업기관에서 제공하고 있는 3분위 확률 예측에 대한 예측확률 정보와의 예측력 비교하기 위해 APCC에서 현업으로 사용하고 있는 3분위 확률예측기법(Min et al. 2009)을 적용한 예측정보 중 평년보다 높음(above-normal)에 대한 예측력과 함께 비교하였다. 또한, 본 연구에서

극한 기후 정의를 위해 사용한 상위 15% 기준에 대한 타당성 또한 부족하다. 따라서 마지막으로, 극한의 기준(상위 10, 15, 20%)과 다중모델앙상블 확률 기법에 대한 예측력 민감도 테스트를 수행하였다. 극한의 기준별 다중모델앙상블 확률 예측 기법에 대한 실험을 각각 MMEi_G, MMEi_E, MMEp_G, MMEp_E로 명명하였다(표 6.4).

그림 6.16-17를 통해 다음과 같이 몇 가지 중요한 결론을 내릴 수 있다. 첫째, 극한 기온 및 강수 확률예측에 있어서 극한의 기준에 상관없이 GAUS가 EMP보다 예측력이 높고, MMEp가 MMEi보다 예측력이 높게 나타났다. 그 결과, 모든 기준에서 동일하게 MMEp_G의 예측력이 가장 높으며, 이러한 경향은 모든 계절에 일관되게 나타났다. 둘째, 가장 높은 예측력을 보인 MMEp_G와 기준이 되는 기법(MMEi_E)과의 예측력 차이를 통해(즉, D-A), 기준이 커질수록 D-A는 줄어드는 것을 알 수 있다. 이는, 극한의 정도가 클수록(즉, 20%→10%) GAUS와 MMEp에 의한 예측력 향상이 크다는 것을 의미한다. 셋째, 예측확률 추정기법에 의한 예측력 향상(C-A, D-B)이 MME 기법에 의한 예측력 향상(B-A, D-C)보다 대체적으로 크게 나타났다. 강수 역시 기온에서 나타났던 예측력 향상에 대한 특징이 동일하게 보이지만, 그 정도는 상당히 작은 것으로 나타났다. 마지막으로 3분위 확률예측의 예측력과 비교해보면, 상위 10% 극한 기온 확률 예측력(MMEp_G)은 3분위 확률예측의 예측력에 비해 낮은 예측력을 보였으며, 상위 15%와 20%에 대해서는 3분위 예측력에 비해 다소 높은 예측력을 보였다. 하지만 강수의 경우는 15% 정도까지도 3분위 예측력에 미치는 못하는 것으로 나타났으며, 20% 정도에서는 유사한 예측력을 보였다.

본 연구는 APCC 현업적인 측면에서 극한 기후예측을 통해 기후서비스로의 발전 가능성을 평가하기 위한 것으로 일반적으로 사용되는 “극한 기후의 정의”와 “극한 기후에 대한 예측력”이 확보 되어야한다. 즉, 극한의 기준을 10%로 하게 되면 일반적으로 사용되는 ‘드물게 발생하는 기상/기후 현상’이라는 극한기후의 정의에는 부합하나, 예측력을 담보 하지 못하며, 극한의 기준을 20%로 설정하게 되면 극한 기후 예측력은 확보할 수 있으나, 일반적으로 사용되는 극한의 정의에 맞지 않을 것으로 보인다. 그 결과 본 연구에서 극한 기온 예측 기술 개발을 위해서는 상·하위 15%의 극한 기준이 전구를 대상으로 하는 현업적인 측면에서 타당할 것으로 판단되지만 강수의 경우 다양하고 가장 최신의 모델들을 활용한 MME에서조차 예측력은 여전히 한계가 있는 것으로 보인다.




Figure 6.14. ROC curves of MMEp predictions for JJA/DJF temperature (a, c) and precipitation (b, d) based on GAUS method.




Figure 6.15. Same as Figure 6.14, except for Reliability diagrams

Table 6.4. List of probabilistic multi-model ensemble approaches considered for this study.

Experiment	Description
MMEi_E	Probabilistic multi-model ensemble with average of individual models, with an empirical ranking method for estimation of forecast probability
MMEi_G	Probabilistic multi-model ensemble with average of individual models, with an Gaussian fitting method for estimation of forecast probability
MMEp_E	Probabilistic multi-model ensemble forecast based on an empirical ranking method by pooling together the individual models
MMEp_G	Probabilistic multi-model ensemble forecast based on a Gaussian fitting method by pooling together the individual models




Figure 6.16. The aggregated ROC score over globe for different threshold of extreme temperature. Threshold is upper a) 10%, b) 15% and c) 20% from climatological distribution. Dashed line indicates the aggregated ROC score of tercile forecast (above normal).




Figure 6.17. Same as Figure 6.16, except for precipitation.

6.5 요약

본 연구에서는 APCC 홈페이지를 통해 제공되는 예측정보 다양화를 위한 예측 콘텐츠로 ENSO 종류 및 강도, 전구규모의 가뭄, 겨울철 몬순 등과 더불어 “극한 기후”를 선정했으며, APCC의 현업적인 측면을 고려하여 극한기후에 대한 다중모델앙상블 확률예측 현업시스템으로의 발전 가능성을 평가하였다. 우선 관측에서 나타나는 최근 극한 기후의 발생 빈도 및 발생 특성을 분석하고, APCC MME에 참여하는 9개 모델(CWB, IRI, APCC, MSC, NASA, NCEP, PNU, BOM, CMCC)을 활용하여 극한 기후의 변동성 및 예측력을 비교/평가하였다. 또한 극한 기후 예측을 위해 다중모델앙상블 확률예측 기법을 비교/평가 하였다. 본 연구에서는 기후학적 분포에 대한 상위 15% 기온 및 강수를 극한 기후로 정의하고, 참여모델의 공통기간인 1982-2005년에 대한 여름철/겨울철 극한기후를 분석하였으며 관측은 최근까지 자료를 모두 활용하였다.

극한 기후 예측을 위한 개별모델과 MME의 예측력 평가에 앞서, 지난 35년(1982-2016)의 관측 자료를 분석하여 극한 기온 및 강수에 대한 극한 기후의 시·공간적인 특징을 살펴보았다. 그 결과, 지구 온난화로 인한 전지구 연평균 기온의 증가와 함께 여름/겨울철 상(하)위 15% 극한기온 증가(감소) 추세가 뚜렷하며, 극한 강수의 변동성은 크지는 않으나 상(하)위 15% 극한 강수의 감소(증가) 경향을 보였다. 특히 최근 11년(2006-2016)동안의 상위 15% 극한 기온 발생 지역은 크게 증가하였다. 또한 APCC MME 참여 모델 및 MME의 극한 기온 및 강수의 변동성과 예측력 평가를 통해 극한 기후 예측기술 개발 가능성을 살펴보기 위해, SEDI를 적용한 결정론적(또는 카테고리) 예측력 검증을 수행하였다. 개별모델이 모의한 상위 15% 극한 기온 경년 변동성과 관측과의 상관계수는 여름(겨울)철에 0.52-0.86(0.52-0.88)로 나타났으며, MME는 이보다 다소 높은 0.82(0.90)의 상관계수를 보임으로서 개별모델과 MME 모두 관측에서 나타난 상위 15%의 극한 기온의 경년 변동성을 잘 모의하는 것으로 나타났다. 상위 15%의 극한 기온에 대한 SEDI 예측력은 여름철(겨울철)에 0.37-0.45(0.36-0.46)로 나타났으며, MME는 0.35(0.37)로 개별모델에 비해 예측력이 높음을 알 수 있다. 반면 강수의 경우, 관측과 MME의 극한 강수 변동성에 대한 상관계수가 여름(겨울)철 0.24(0.22)로 여전히 낮은 값을 보이며, MME 예측력은 참여하는 개별모델의 평균 예측력의 비례하기 때문에 극한 강수의 경우 MME를 통한 예측력 향상은 나타나지 않았다.

다음으로는 MME를 활용한 극한기후 확률예측 기법 개발을 위해 예측확률 추정 방법에 따른 APCC 참여모델의 예측확률을 비교하고, 예측력 평가를 수행하였다. 일반적으로 예측확률을 추정하는 방법은 크게 비모수화 방법(EMP)과 모수화 방법으로 나눌 수 있으며, 본 연구에서는 모수화 방법 적용에 앞서 각 변수가 정규 분포를 따르는 지에 대한 K-S와 A-D 통계적 검정이 선행되었다. 그 결과 관측 및 개별모델의 계절평균 기온 및 강수 분포 모두 정규 분포로 가정할 수 있을 것으로 판단되어 극한기후 확률예측을 위한 모수화 기법에 정규 분포를 적용하였다(GAUS). 예측확률 추정방법(GAUS와 EMP)에 따른 극한 기후 예측확률의 차이를 살펴보면 대체로 GAUS가 EMP에 비해 상위 15%의 극한 기온 발생 확률이 좀 더 넓은 지역까지 분포하며, 그 확률값에 있어서도 높게 예측하였다. 이러한 예측 확률의 차는 ROC score를 이용한 예측력 평가에서 유의수준 내의 차이가 발생하지는 않지만 대부분의 모델에서 GAUS 기법이 EMP에 비해 예측력이 높게 나타났다. 예측 확률 추정 방법론 뿐만 아니라 다중모델 앙상블 방법론에 대한 예측력을 살펴보면, 개별모델의 모든 앙상블 멤버로 이루어진 하나의 단일모델 분포도를 활용하여 예측확률을 추정하는 방법인 MMEp가 개별모델의 예측확률을 먼저 추정하고, 이를 단순 평균하는 방법인 MMEi에 비해 예측력이 높게 평가 되었으며, MME 방법론에 무관하게 MME 예측력은 모든 계절과 변수에 대해 개별 모델 보다 극한 기후 예측에 효과적인 것으로 판단된다.

마지막으로, 앞선 분석 결과를 바탕으로, GAUS와 MMEp 방법을 적용한 극한기후 확률예측기법(PMME-E; Probabilistic Multi-Model Ensemble for Extreme)을 개발하여 과거예측 기간에 대한 객관적인 예측력 평가를 통해 전구를 대상으로 하는 APCC 현업적인 측면에서 극한기후 확률예측 정보가 기후서비스로 발전할 수 있는지 평가하였다. WMO에서 권고하고 있는 ROC 곡선과 Reliability diagram을 이용하여 평가한 결과, PMME-E는 상위 15% 극한 기온 및 강수 예측에 있어서 개별모델에 비해 Resolution과 Reliability 측면에서 높은 예측력을 보이고 있음을 확인했다. 그리고 극한의 기준(상위 10, 15, 20%)과 다중모델앙상블 확률 기법에 대한 예측력 민감도 테스트를 수행한 결과, 몇 가지 결론을 도출할 수 있었다. 첫째, 모든 기준에서 동일하게 MMEp-G의 예측력이 가장 높았으며, 둘째, 극한의 기준이 클수록 GAUS와 MMEp에 의한 예측력 향상이 크며, 셋째, 예측확률 추정기법에 의한 예측력 향상이 MME 기법에 의한 예측력 향상보다 크다는 것이다. APCC의 3분위 확률 예측 정보 중 평년보다 높은

과 예측력을 비교할 때, 극한 기온 예측 기술 개발을 위해서는 상·하위 15%의 극한 기준이 전구를 대상으로 하는 현업적인 측면에서 타당할 것으로 판단되지만 강수의 경우 다양하고 가장 최신의 모델들을 활용한 MME에서조차 예측력 한계를 드러냈다.

본 연구는 극한 기후 예측 정보에 대한 중요성과 요구의 증가에도 불구하고 극한 기후 예측에 대한 연구가 전무한 실정에서 APCC MME에 참여하는 최신의 계절 예측 모델을 활용하여 극한 기후의 예측력 평가와 예측 기술 개발을 통해 다양한 계절 예측 정보 제공을 위한 기초 연구로서의 충분한 가치를 가진다. 향후 본 연구를 통해 개발된 극한기후 확률예측기법을 실제 APCC 현업에 적용하여 극한예측 정보를 제공하기 위해서는 앞으로 좀 더 종합적이고 상세한 예측력 검증이 필요할 것으로 보인다. 또한 개별모델의 바이어스 보정과 다양한 통계적 기법을 활용하여 개별모델 예측력에 가중치를 부여하는 다중 모델앙상블 기법에 대한 예측력 비교·평가를 통한 예측력 향상을 위한 연구가 추가적으로 수행되어 신뢰성 있는 극한 기후 예측 정보를 제공을 위해 노력해야 할 것으로 판단된다.

7. 결론 및 종합 토론

2005년 개소 이후, APCC는 다중모델앙상블(MME) 기법 개발 및 참여모델의 다양화를 위한 끊임없는 노력을 기울인 결과 현재 10개국 16개 기관으로부터 계절예측정보를 제공받고 있으며, 다양한 종류의 MME 기법(SCM⁵⁴), MRG⁵⁵), SSE⁵⁶), SPM⁵⁷), PMM E⁵⁸)을 활용한 전구 규모의 계절예측정보를 매월 홈페이지를 통해 제공하고 있다. 하지만 최근 MME를 활용한 계절예측정보를 제공하는 현업기관의 수가 점차 늘어나고 있으며(예, NMME, WMO LC, ECMWF 등), 또한 MME에 참여하는 모델들이 대부분 중복되는 현 상황에서 세계 유수현업기관과의 경쟁에서 APCC의 우위확보를 위해 사용자 중심의 새로운 콘텐츠 발굴 및 예측기술 개발에 대한 필요성이 점차 대두되기 시작했다. 즉, 팀 차원에서 보다 다양하고 유용한 계절예측정보 제공을 위해 콘텐츠 발굴부터 예측기술 개발, 예측시스템의 구축 및 운영까지 통합적이고 유기적인 시스템 개발의 필요성에 의해 다년도로 시작된 과제이다. 1차 년도(2017년) 과제 목표는 APCC 현업에 적용 가능한 콘텐츠를 발굴하고, 예측기술 개발 및 종합적인 예측력 평가를 통해 선정된 콘텐츠가 기후 서비스로의 발전 가능성이 있는지를 판단하는 것이다. 우선, 콘텐츠 선정을 위해 세계 현업기관의 현황분석 및 센터 내 선행연구들에 대한 종합적인 리뷰를 통해 현재 APCC 자료의 가용성, 내부 역량, 타 기관과의 차별성 등을 고려하여 “ENSO 종류/강도”, “전구 규모의 가뭄”, “동아시아겨울몬순”, “상/하위 15% 극한 기후”를 우선 선정하고, 각 콘텐츠에 대한 APCC 참여모델 및 MME의 예측력 평가, 예측기술 개발에 대한 기초연구를 수행하였다.

본 과제를 통해 개발된 ENSO 종류/강도 예측을 위한 다중모델앙상블 확률예측기법을 Hindcast(1982-2010) 및 실시간 예측(2013-2016) 기간에 대한 예측력 평가를 수행한 결과, ENSO 종류뿐만 아니라 강도에 대해서도 상당히 높은 예측력을 보이며 APCC 기후서비스로 발전 가능성이 충분한 것으로 판단된다. 또한, 1) APCC MME의 SST 및 Nino 3.4 지수는 세계 유수현업기관의 비해 다소 우위(적어도 비슷한 정도의

54) Simple Composite Method

55) Multiple Regression Method

56) Synthetic Superensemble Method

57) Step-wise Pattern Projection Method

58) Probabilistic Multi-Model Ensemble

예측력)의 예측력을 보장하며, 2) 현재 그 어느 현업기관에서도 제공하고 있지 않는 ENSO 강도에 대한 확률예측정보를 포함하며, 3) 현재 유일하게 ENSO 종류에 대한 확률예측정보를 제공하고 있는 IRI/CPC 자료에서 나타나는 몇 가지 한계점들(예, 모델별 기후값이 상이함, 개별 모델의 앙상블 spread를 고려하지 못함 등)로부터 APCC는 자유롭다는 점에서 본 과제에서 개발된 예측기법은 여러 가지 면에서 상당한 장점이 있다고 판단된다. 따라서 ENSO 종류 및 강도 예측을 위한 다중모델앙상블 확률예측기법은 2차 년도에는 현업화 작업을 수행할 계획이다. 즉, 현재 APCC 현업시스템(AFS)⁵⁹⁾과의 통일성을 고려하여 ENSO 종류 및 강도 확률예측시스템을 개발, Test-bed 운영을 통한 안정화 과정을 거쳐 최종적으로 홈페이지를 통한 예측정보 제공(현업화)이 가능한 콘텐츠로 판단된다.

가뭄의 경우, 현재 CAMS OPI를 이용하여 SPI 기반의 전구 가뭄 감시 자료를 APCC 홈페이지를 통해 서비스하고 있으며, 가뭄 감시시스템에 대한 다년간의 경험을 바탕으로 감시로만 그쳤던 가뭄정보에 대한 범위를 좀 더 확장하여 예측정보까지 포함하기 위해 APCC MME 자료를 활용한 가뭄예측시스템 개발연구가 추진되었다. 또한, 가뭄은 장기간 지속되는 현상에 대해 전지구적인 관점에서 대응해야 할 문제로 인식이 되고 있다. 하지만 현재 전구 규모의 장기 가뭄에 대한 예측정보를 제공하는 현업기관은 없다는 점에서 ENSO 강도와 마찬가지로 타기관과의 차별성 면에서는 충분한 가치가 있다고 판단된다(단, 예측성 및 활용성 등에 대한 부분도 고려하여 종합적으로 판단해야 함). 하지만 현재 전구를 대상으로 하는 장기 가뭄을 정의하는 지수에 대한 표준 지침조차 없는 사항이라 당해 연도에는 가뭄지수 선정, 예측시스템 개발 및 일반적인 예측성에 대한 기초연구가 수행되었고, 차 년도에는 가뭄 취약 지역에 대한 집중적 연구 및 실시간 예측 자료에 대한 객관적인 평가를 통해 현업시스템으로 발전 가능성을 판단하고 3차 년도에 최종적으로 현업화를 할 계획이다.

APCC MME 계절예측정보는 아·태지역을 대상으로 하고 있긴 하지만, 한국 기상청 또한 APCC 계절예측정보를 활용하는 중요한 수요자이다. 따라서 공간적인 규모를 한반도 및 동아시아 지역으로 조금 더 집중하여 APCC 예측정보의 활용성 증대 및 사용자 중심의 새로운 예측정보 제공 면에서 겨울철 동아시아 겨울몬순 콘텐츠가 선정되었다.

59) Automated Forecast System

개별모델에서 나타나는 예측력의 한계를 극복하기 위해, 본 과제에서는 역학-통계 하이브리드 예측모형을 개발하여 예측력 평가를 수행한 결과 대부분의 개별모델에서 예측력 향상이 일관되게 나타나며, 특히 4개월의 선행시간에서도 안정적인 예측력이 유지됨을 확인하였다. 이는 본 과제를 통해 개발된 역학-통계 하이브리드 예측모형의 실제 예측에 대한 잠재 가능성을 확인할 수 있는 결과라고 할 수 있다. 따라서 2차 년도에는 현업화 작업을 거쳐 매년 겨울철 기상청 장기예보 토의 시 APCC MME 예측정보와 더불어 EAWM 강도예측에 대한 추가적인 정보를 제공할 수 있을 것으로 판단된다.

마지막으로 상위 15% 극한 기후예측은 앞선 콘텐츠들에 비해 상대적으로 타 기관과의 차별성이 현재로서는 낮지만, 이미 다른 현업기관에서 예측정보를 제공하고 있음에도 불구하고(예, IRI, ECMWF 등) 계절예측자료를 활용한 극한 기후예측에 있어서 예측력 평가에 대한 선행연구 조차 전무한 실정이다. 따라서, 장기적인 관점에서 추후 계절내 자료를 활용한 극한기후 예측기술 개발로의 확장 가능성을 보고 마지막 콘텐츠로 선정되었으며, 우선 현재 APCC 자료의 가용성을 고려하여 계절평균 예측자료를 활용한 15% 극한기후에 대한 예측력 평가 및 확률예측 기법 개발에 관한 연구부터 수행하였다. 이를 통해 현재 계절예측시스템의 극한 기후 예측에 대한 현재 수준 및 한계점 등을 파악하여 이는 연구적인 측면에서 극한기후 예측에 있어서 중요한 과학적인 결과물을 도출할 수 있었다는 점에서 중요한 의미가 있다고 할 수 있다. 또한 올해 축적된 경험/과학적인 지식들을 바탕으로 2018년에는 새롭게 제안된 “15-60일 아태지역 극한기후 진단 및 예측기술 개발”과제의 세부 연구로 전환될 계획이다.

본 과제는 철저하게 현업적인 측면에서 현재 APCC 가진 자료 및 역량 등을 바탕으로 4개의 콘텐츠가 선정되었고 2017년 연구를 통해 ENSO 종류/강도 확률예측기법 및 EAWM 통계-역학 하이브리드 기법은 2018년 각각 현업으로 전환될 예정이며, 전구 규모의 장기가뭄예측은 2018년도 좀 더 심도 깊은 연구를 통해 2019년 현업화를 목적으로 한다. 마지막으로 극한 기후는 기본적인 예측력 평가에 대한 기초연구 없이 시작한 다른 현업기관과는 달리 천천히 하지만 기초부터 다시 시작했으며, 내년에는 계절내 극한기후로 범위를 확장하고자 한다.

REFERENCES

- Abatan, A. A., B. J. Abiodun, K. A. Lawal, and W. J. Gutowski, 2016: Trends in extreme temperature over Nigeria from percentile-based threshold indices. *Int. J. Climatol.*, **36**, 2527–2540, doi:<https://doi.org/10.1002/joc.4510>.
- Ahn, J. B., and H. J. Kim, 2013: Improvement of one-month lead predictability of the wintertime AO using a realistically varying solar constant for a CGCM. *Meteorol. Appl.*, **21**, 415–418. doi:10.1002/met.1372
- Alessandri, A., A. Borrelli, A. Navarra, A. Arribas, M. Déqué, P. Rogel, and A. Weisheimer, 2011: Evaluation of probabilistic quality and value of the ENSEMBLES multimodel seasonal forecasts: Comparison with DEMETER. *Mon. Wea. Rev.*, **139**, 581–607, doi:<https://doi.org/10.1175/2010MWR3417.1>.
- Alessandri, A., A. Borrelli, S. Masina, A. Cherchi, S. Gualdi, A. Navarra, P. Di Pietro, and A. F. Carril, 2010: The INGV-CMCC seasonal prediction system: Improved ocean initial conditions. *Mon. Wea. Rev.*, **138**, 2930–2952.
- Alexander, L. V., and Coauthors, 2006: Global observed changes in daily climate extremes of temperature and precipitation. *J. Geophys. Res.*, **111**, D05109, doi:10.1029/2005JD006290.
- Alexander, L.V., 2016: Global observed long-term changes in temperature and precipitation extremes: A review of progress and limitations in IPCC assessments and beyond. *Wea. Climate Extremes*, **11**, 4–16, doi:10.1016/j.wace.2015.10.007.
- Anderson, T.W., and D.A. Darling, 1954: A Test of Goodness-of-Fit. *J. Amer. Stat. Assoc.*, **49**, 765–769. doi:10.2307/2281537.
- Asadieh, B. and N.Y. Krakauer, 2015: Global trends in extreme precipitation: climate models versus observations. *Hydrol. Earth Syst. Sci.*, **19**, 877–891, doi:10.5194/hess-19-877-2015.
- Barnston, A. G., M. K. Tippett, M. L. L'Heureux, S. Li, and D. G. DeWitt, 2012a: Skill of real-time seasonal ENSO model predictions during 2002–11: Is our capability increasing? *Bull. Amer. Meteor. Soc.*, **93**, 631–651.
- Barnston, A. G., 1994: Linear statistical short-term climate predictive skill in the Northern Hemisphere. *J. Climate*, **7**, 1513–1564.
- Barnston, A. G., and S. J. Mason, 2011: Evaluation of IRI's seasonal climate forecasts for the extreme 15% tails. *Wea. Forecasting*, **26**, 545–554, doi:10.1175/WAF-D-10-05009.1.

- Barnston, A. G., M. K. Tippett, H. M. van den Dool, and D. A. Unger, 2015: Toward an improved multimodel ENSO prediction. *J. Appl. Meteor. Climatol.*, **54**, 1579-1595, doi:https://doi.org/10.1175/JAMC-D-14-0188.1.
- Barnston, A. G., M. K. Tippett, M. Ranganathan, and M. L. L'Heureux, 2017: Deterministic skill of ENSO predictions from the North American Multimodel Ensemble. *Climate Dyn.*, doi:https://doi.org/10.1007/s00382-017-3603-3.
- Barnston, A. G., S. Li, S. J. Mason, D. G. DeWitt, L. Goddard, and X. Gong, 2010: Verification of the first 11 years of IRI's seasonal climate forecasts. *J. Appl. Meteor. Climatol.*, **49**, 493-520. doi:10.1175//1520-0493(2003)131<1509:SAIVOT>2.0.CO;2.
- Barnston, A. G., S. J. Mason, L. Goddard, D. G. DeWitt, and S. E. Zebiak, 2003: Multimodel ensembling in seasonal climate forecasting at IRI. *Bull. Amer. Meteor. Soc.*, **84**, 1783-1796.
- Bartos, M., M. Chester, N. Johnson, B. B. Gorman, D. Eisenberg, I. Lingkov and M. Bates, 2016: Impacts of rising air temperatures on electric transmission ampacity and peak electricity load in the United States. *Environ. Res. Lett.*, **11**, 11.
- Becker, E. J., H. M. van den Dool, and M. Pena, 2013: Short-term climate extremes: Predictions on skill and predictability. *J. Climate*, **26**, 512-531, doi:https://doi.org/10.1175/JCLI-D-12-00177.1.
- Becker, E., H. van den Dool, and Q. Zhang, 2014: Predictability and forecast skill in NMME. *J. Climate*, **27**, 5891-5906, doi:https://doi.org/10.1175/JCLI-D-13-00597.1.
- Boo, K.-O., G. Martin, A. Sellar, C. Senior, and Y.-H. Byun, 2011: Evaluating the East Asian monsoon simulation in climate models. *J. Geophys. Res.*, **116**, D01109, doi:10.1029/2010JD014737.
- Bradley, R. S., H. F. Diaz, G. N. Kiladis, and J. K. Eischeid, 1987: ENSO signal in continental temperature and precipitation records. *Nature*, **327**, 497-501.
- Casanova, S., and B. Ahrens, 2009: On the weighting of multimodel ensembles in seasonal and short-range weather forecasting. *Mon. Wea. Rev.*, **137**, 3811-3822.
- Chan, J., and C. Li, 2004: The East Asia winter monsoon. *East Asian Monsoon*, C.-P. Chang, Ed., World Scientific, 54-106.
- Chen, M., P. Xie, J. E. Janowiak, and P. A. Arkin, 2002: Global land precipitation: A 50-yr monthly analysis based on gauge observations. *J. Hydrometeorol.*, **3**, 249-266.
- Chen, W., H. Graf, and R. H. Huang, 2000: The interannual variability of East Asian winter monsoon and its relation to the summer monsoon. *Adv. Atmos. Sci.*, **17**, 48-60.

- Clark, M. P., and M. C. Serreze, 2000: Effects of variations in East Asian snow cover on modulating atmospheric circulation over the North Pacific Ocean. *J. Climate*, **13**, 3700–3710.
- Cohen, J. L., J. C. Furtado, M. A. Barlow, V. A. Alexeev, and J. E. Cherry, 2012: Asymmetric seasonal temperature trends. *Geophys. Res. Lett.*, **39**, L04705, doi:10.1029/2011GL050582.
- Cottrill, A., and Coauthors, 2013: Seasonal forecasting in the Pacific using the coupled model POAMA-2. *Wea. Forecasting*, **28**, 668–680.
- Cui, X., and Z. Sun, 1999: East Asian winter monsoon index and its variation analysis. *J. Nanjing Inst. Meteor.*, **22**, 321–325.
- Curry, J. A., and P. J. Webster, 2011: Climate science and the uncertainty monster. *Bull. Amer. Meteor. Soc.*, 92, 1667–1682, doi:10.1175/2011BAMS3139.1.
- Dai, A., I. Fung, and A. D. Del Genio, 1997: Surface observed global land precipitation variations during 1900–1988. *J. Climate*, **10**, 2943–2962.
- Dai, A., K. E. Trenberth, K. E. Trenberth, and T. T. Qian, 2004: A global dataset of Palmer Drought Severity Index for 1870–2002: Relationship with soil moisture and effects of surface warming. *J. Hydrometeor.*, **5**, 1117–1130.
- Delworth, T. L., and Coauthors, 2006: GFDL’s CM2 global coupled climate models. Part I: Formulation and simulation characteristics. *J. Climate*, **19**, 643–674.
- Delworth, T. L., and Coauthors, 2006: GFDL’s CM2 global coupled climate models. Part I: Formulation and simulation characteristics. *J. Climate*, **19**, 643–674, doi:https://doi.org/10.1175/JCLI3629.1.
- Doblas-Reyes F. J., R. Hagedorn and T.N. Palmer 2005: The rationale behind multi-model ensembles in seasonal forecasting—II. Calibration and combination. *Tellus*, **57A**, 234–252.
- Donat, M. G., and Coauthors, 2013: Updated analysis of temperature and precipitation extreme indices since the beginning of the twentieth century: The HadEX2 dataset. *J. Geophys. Res.*, **118**, 2098–2118, doi:10.1002/jgrd.50150.
- Duan, W. S., and C. Wei, 2013: The spring predictability barrier for El Niño events and its possible mechanism results from a fully coupled model. *Int. J. Climatol.*, **33**(5), 1280–1292.
- Dutra, E., and Coauthors, 2014b: Global meteorological drought – Part 2: Seasonal forecasts. *Hydrol. Earth Syst. Sci.*, **18**, 2669–2678, doi:https://doi.org/10.5194/hess-18-2669-2014.

- Dutra, E., F. Wetterhall, F. Di Giuseppe, G. Naumann, P. Barbosa, J. Vogt, W. Pozzi, and F. Pappenberger, 2014a: Global meteorological drought—Part 1: Probabilistic monitoring. *Hydrol. Earth Syst. Sci. Discuss.*, **11**, 889–917, doi:<https://doi.org/10.5194/hessd-11-889-2014>.
- Ferro, C. A. T., and D. B. Stephenson, 2011: Extremal dependence indices: Improved verification measures for deterministic forecasts of rare binary events. *Wea. Forecasting*, **26**, 699–713, doi:<https://doi.org/10.1175/WAF-D-10-05030.1>.
- Fraley, C., A. E. Raftery, and T. Gneiting, 2010: Calibrating multimodel forecast ensembles with exchangeable and missing members using Bayesian model averaging. *Mon. Wea. Rev.*, **138**, 190–202.
- Frank, T., 2005: Climate Change Impacts on Building Heating and Cooling Energy Demand in Switzerland. *Energy Build.*, **37**, 1175–1185.
- Ghil, M., and R. Vautard, 1991: Interdecadal oscillations and the warming trend in global temperature time series. *Nature*, **350**, 324–327.
- Gong, D.-Y., S.-W. Wang, and J.-H. Zhu, 2001: East Asian winter monsoon and Arctic oscillation. *Geophys. Res. Lett.*, **28**, 2073–2076.
- Guo, Q. Y., 1994: Relationship between the variations of East Asian winter monsoon and temperature anomalies in China(in Chinese). *Quart. J. Appl. Meteor.*, **5**, 218–225.
- Hagedorn, R., F. J. Doblas-Reyes, and T. N. Palmer, 2005: The rationale behind the success of multimodel ensembles in seasonal forecasting. I. Basic concept. *Tellus*, **57A**, 219–233.
- Hales, S., S. J. Edwards, R. S. Kovats, 2003: Impacts on health of climate extremes. Geneva: World Health Organization.
- Ham, Y.-G., S. Schubert, and Y. Chang, 2012: Optimal initial perturbations for ensemble prediction of the Madden-Julian oscillation during boreal winter. *J. Climate*, **25**, 4932–4945, doi:<https://doi.org/10.1175/JCLI-D-11-00344.1>.
- Ham, Y.-G., S. Schubert, Y. Vikhliav, and M. J. Suárez, 2014: An assessment of the ENSO forecast skill of GEOS-5 system. *Climate Dyn.*, **43**, 2415, doi: <https://doi.org/10.1007/s00382-014-2063-2>.
- Ham, S., A.-Y. Lim, and S. Kang, 2017: Seamless Coupled Prediction System(SCoPS) assessment of East Asia climate variability on the APCC model retrospective seasonal prediction(1982–2013). *Geosci. Model Dev.*(submitted).
- Hao, Z., A. AghaKouchak, N. Nakhjiri, and A. Farahmand, 2014: Global integrated drought monitoring and prediction system. *Sci. Data*, **1**, doi:<https://doi.org/10.1038/sdata.2014.1>.

- Hashim, J. H., and Z. Hashim, 2016: Climate change, extreme weather events, and human health implications in the asia pacific region. *Asia-Pac. J. Public Health*, **28**, 2, 8S–14S.
- Hoell, A., M. Hoerling, J. Eischeid, K. Wolter, R. Dole, J. Perlwitz, T. Xu, and L. Cheng, 2016: Does El Nino intensity matter for California precipitation? *Geophys. Res. Lett.*, **43**, 819–825.
- Hsu, W., and A. H. Murphy, 1986: The attributes diagram. A geometrical framework for assessing the quality of probabilistic forecasts. *Int. J. Forecasting*, **2**, 285–293.
- Hu, Q., and S. Feng, 2012: AMO– and ENSO–driven summertime circulation and precipitation variations in North America. *J. Climate*, **25**, 6477–6495.
- Huang J., M. Svoboda, A. Wood, S. Schubert, C. Peters–Lidard, E. Wood, and R. Pulwarth, 2016: NOAA Drough Task Force 2016: Research to Advance National Drought Monitoring and Prediction Capabilities. doi:10.7289/V5V122S3.
- IPCC, 2001: Climate Change 2001: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Third Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press: Cambridge, New York.
- IPCC, 2012: Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. A Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change [Field, C.B., V. Barros, T.F. Stocker, D. Qin, D.J. Dokken, K.L. Ebi, M.D. Mastrandrea, K.J. Mach, G.–K. Plattner, S.K. Allen, M. Tignor, and P.M. Midgley(eds.)]. *Cambridge University Press, Cambridge, UK, and New York, NY, USA*, **582pp**.
- IPCC, 2013: Summary for Policy Makers(SPM) Climate Change, The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, T. F. Stocker et al. al. ((Eds.), Cambridge University Press, Cambridge and New York, 1–30.
- Janowiak, J. E., and P. Xie, 1999: CAMS–OPI: A global satellite–rain gauge merged product for real–time precipitation monitoring applications. *J. Climate*, **12**, 3335–3342.
- Janssen, E., R. L. Sriver, D. J. Wuebbles, and K. E. Kunkel, 2016: Seasonal and regional variations in extreme precipitation event frequency using CMIP5. *Geophys. Res. Lett.*, **43**, 5385–5393, doi:<https://doi.org/10.1002/2016GL069151>.
- Jeong, H. I., and Coauthors, 2008: Experimental 6–month hindcast and forecast simulations using CCSM3, APCC Tech. Rep. 2008.
- Jeong, H.–I., and Coauthors, 2012: Assessment of the APCC couple MME suite in predicting the distinctive climate impacts of two flavors of ENSO during boreal winter. *Climate*

- Dyn.*, **39**, 475-493, doi:<https://doi.org/10.1007/s00382-012-1359-3>.
- Jeong, J. H., and C.H. Ho, 2005: Changes in occurrence of cold surges over east Asia in association with Arctic Oscillation. *Geophys. Res. Lett.*, **32**, L14704, doi:10.1029/2005GL023024.
- Jhun, J. G., and E. J. Lee, 2004: A new East Asian winter monsoon index and associated characteristics of the winter monsoon. *J. Climate*, **17**, 711-726.
- Jia, X., H. Lin, and J. Derome, 2010: Improving seasonal forecast skill of North American surface air temperature in fall using a postprocessing method. *Mon. Wea. Rev.*, **138**, 1843-1857.
- Jiang, X., and Y. Li, 2011: Spatio-temporal variability of winter temperature and precipitation in southwestern China and possible causes, *J. Geogr. Sci.*, **21**, 250-262.
- Jin, E. K., and Coauthors, 2008: Current status of ENSO prediction skill in coupled ocean-atmosphere models. *Climate Dyn.*, **31**, 647-664.
- Jones, P. D., 1994: Recent warming in global temperature series. *Geophys. Res. Lett.*, **21**, 1149-1152.
- Jones, P. D., and A. Moberg, 2003: Hemispheric and large-scale surface air temperature variations: An extensive revision and an update to 2001. *J. Climate*, **16**, 206-223.
- Kalnay, E., and Coauthors, 1996: The NCEP/NCAR 40-Year Reanalysis Project. *Bull. Amer. Meteor. Soc.*, **77**, 437-471.
- Kanamitsu, M., W. Ebisuzaki, J. Woollen, S-H. Yang, J. J. Hnilo, M. Fiorino, and G. L. Potter, 2002: NCEP-DOE AMIP-II Reanalysis(R-2). *Bull. Amer. Meteor. Soc.*, **83**, 1631-1643.
- Kang Y., S. Khan, X. Ma, 2009: Climate change impacts on crop yield, crop water productivity and food security-a review. *Prog. Nat. Sci.*, **19**, 1665-1674.
- Kang, D. and M. I. Lee, 2017: ENSO influence on the dynamical seasonal prediction of the East Asian Winter Monsoon, *Clim. Dyn.*, doi:10.1007/s00382-017-3574-4.
- Kang, H. W., C. K. Park, S. N. Hameed, and K. Ashok, 2009: Statistical downscaling of precipitation in Korea using multimodel output variables as predictors. *Mon. Wea. Rev.*, **137**, 1928-1938.
- Kang, I. S., J. Y. Lee, and C. K. Park, 2004: Potential predictability of summer mean precipitation in a dynamical seasonal prediction system with systematic error correction. *J. Climate*, **17**, 834-844.
- Kharin, V. V., and F. W. Zwiers, 2002: Climate predictions with multimodel ensembles. *J. Climate*, **15**, 793-799.

- Kharin, V. V., and F. W. Zwiers, 2003: Improved seasonal probability forecasts. *J. Climate*, **16**, 1684-1701.
- Kim, G. Y., J. B. Ahn, V. N. Kryjov, S. J. Sohn, W. T. Yun, et al., 2015a: Global and regional skill of the seasonal predictions by WMO Lead Centre for Long-Range Forecast Multi-Model Ensemble. *Int. J. Climatol.*, **36**, 1657-1675.
- Kim, H.-M., E. K. Chang, and M. Zhang, 2015b: Statistical-dynamical seasonal forecast for tropical cyclones affecting New York State. *Wea. Forecasting*, **30**, 295-307, doi:https://doi.org/10.1175/WAF-D-14-00089.1.
- Kim, O.-Y., H.-M. Kim, M.-I. Lee, and Y.-M. Min, 2017a: Dynamical-statistical seasonal prediction for western North Pacific typhoons based on APCC multi-models. *Climate Dyn.*, **48**, 71-88, doi:https://doi.org/10.1007/s00382-016-3063-1.
- Kim, S. T., S. J. Sohn, J. S. Kug, 2017b: Winter temperatures over the Korean Peninsula and East Asia: development of a new index and its application to seasonal forecast. *Clim. Dyn.*, doi:10.1007/s00382-016-3402-2.
- Kim, W. M., S. R., Yeo, and K. Y. Kim., 2017c: Why did not a strong and long-lasting La Niña follow the 2015-2016 super El Niño?, *J. Climate and Atmos. Sci.*(submitted).
- Kim, Y. J., 2016: Development of a physical-empirical seasonal forecast model for the northeastern Asian summer monsoon using APCC-MME. APCC Res. Rep. 2016-14.
- Kirtman, B. P., and Coauthors, 2014: The North American Multimodel Ensemble: Phase-1 seasonal to interannual prediction; phase-2 toward developing intra-seasonal prediction. *Bull. Amer. Meteor. Soc.*, **95**, 585-601, doi:https://doi.org/10.1175/BAMS-D-12-00050.1.
- Kirtman, B. P., and D. Min, 2009: Multimodel ensemble ENSO prediction with CCSM and CFS. *Mon. Wea. Rev.*, **137**, 2908-2930.
- Klein Tank, A. M. G., F. W. Zwiers, and X. Zhang, 2009: Guidelines on analysis of extremes in a changing climate in support of informed decisions for adaptation. *Climate data and monitoring WCDMP-No. 72, WMO-TD No. 1500*, 56pp.
- Knutti, R., 2010: The end of model democracy? *Climatic Change*, **102**, 395-404.
- Kodra, E., and A. R. Ganguly, 2014: Asymmetry of projected increases in extreme temperature distributions. *Sci. Rep.*, **4**, 5884, doi:10.1038/srep05884.
- Kolmogorov, A., 1933: Sulla determinazione empirica di una legge di distribuzione. *G. Ist. Ital. Attuari.*, **4**, 83-91.
- Kryjov, V. N., 2016: Development of physical-empirical models for seasonal prediction of

- south Korea spring temperature. APCC Res. Rep. 2016-13.
- Kug, J.-S., J.-Y. Lee, I.-S. Kang, B. Wang, and C. K. Park, 2008: Optimal multimodel ensemble method in seasonal climate prediction. *Asia-Pac. J. Atmos. Sci.*, **44**, 233-247.
- Kumar, A., and Z.-Z. Hu, 2014: How variable is the uncertainty in ENSO sea surface temperature prediction? *J. Climate*, **27**, 2779-2788, doi:<https://doi.org/10.1175/JCLI-D-13-00576.1>.
- Kumar, A., Z.-Z. Hu, B. Jha, and P. Peng, 2017: Estimating ENSO predictability based on multi-model hindcasts. *Climate Dyn.*, **48**, 39-51, doi:<https://doi.org/10.1007/s00382-016-3060-4>.
- Kundzewicz, Z. W. and Coauthors, 2014: Flood risk and climate change: Global and regional perspectives. *Hydrol. Sci. J.*, **59**, 1-28, doi:10.1080/02626667.2013.857411.
- Larson, S. M., and B. P. Kirtman, 2017: Drivers of coupled model ENSO error growth dynamics and the spring predictability barrier. *Climate Dyn.*, **48**, 3631-3644, doi:<https://doi.org/10.1007/s00382-016-3290-5>.
- Lavaysse, C., J. Vogt, and F. Pappenberger, 2015: Early warning of drought in Europe using the monthly ensemble system from ECMWF. *Hydrol Earth Syst Sci.*, **19**, 3273-3286. doi: 10.5194/hess-19-3273-2015.
- Lee, J.-Y., and Coauthors, 2010: How are seasonal prediction skills related to models' performance on mean state and annual cycle? *Climate Dyn.*, **35**, 267-283. doi:10.1007/s00382-010-0857-4.
- Lee, W. S., 2015: Assessing the probability of occurrence of heat waves in Korea using a multi-model ensemble. APCC Res. Rep. 2015-10.
- Lesk C., P. Rowhani and N. Ramankutty, 2016: Influence of extreme weather disasters on global crop production. *Nature*, **529**, 84-87.
- Li, F., and H. Wang, 2012: Predictability of the East Asian winter monsoon interannual variability as indicated by the DEMETER CGCMS. *Adv. Atmos. Sci.*, **29**, 441-454.
- Li, J., and J. X. L. Wang, 2003: A modified zonal index and its physical sense. *Geophys. Res. Lett.*, **30**, 1632. doi:10.1029/2003GL017441.
- Li, J., and Z. Wu, 2012: Importance of autumn Arctic sea ice to northern winter snowfall. *Proc. Natl. Acad. Sci. USA*, **109**, E1898, doi:<https://doi.org/10.1073/pnas.1205075109>.
- Li, S., and G. Bates, 2007: Influence of the Atlantic multidecadal oscillation on the winter climate of East China. *Adv. Atmos. Sci.*, **24**, 126-135.

- Li, Y., and S. Yang, 2010: A dynamical index for the East Asian winter monsoon. *J. Climate*, **23**, 4255–4262..
- Lim, E. P., H. H. Hendon, S. Langford and O. Alves, 2012: Improvements in POAMA2 for the prediction of major climate drivers and south eastern Australian rainfall. *CAWCR Tech. Rep.*, **No. 051**, <http://www.cawcr.gov.au/publications/technicalreports.php>.
- Liou, C-S., and Coauthors, 1997: The second-generation global forecast system at the Central Weather Bureau in Taiwan. *Wea. Forecasting*, **12**, 653–663. doi:10.1175/1520-0434-12.3.653.
- Luo, L., E. F. Wood, and M. Pan, 2007: Bayesian merging of multiple climate model forecasts for seasonal hydrological predictions. *J. Geophys. Res.*, **112**, D10102, doi:10.1029/2006JD007655.
- Lyon, B., 2004: The strength of El Niño and the spatial extent of tropical drought. *Geophys. Res. Lett.*, **31**, L21204. doi:10.1029/2004GL020901.
- Lyon, B., and A. G. Barnston, 2005: ENSO and the spatial extent of interannual precipitation extremes in tropical land areas. *J. Climate*, **18**, 5095–5107.
- Lyon, B., M. A. Bell, M. Tippett, M. P. Hoerling, A. Kumar, X. Quan, and H. Wang, 2012: Baseline probabilities for the seasonal prediction of meteorological drought. *J. Appl. Meteor. Climatol.*, **51**, 1222–1237.
- Ma, T., Z. Wu, and Z. Jiang, 2012: How does cold wave frequency in China respond to a warming climate? *Climate Dyn.*, **39**, 2487–2496, doi:<https://doi.org/10.1007/s00382-012-1354-8>.
- Marshall, A., D. Hudson, M. Wheeler, O. Alves, H. Hendon, M. Pook, and J. Risbey, 2014: Intra-seasonal drivers of extreme heat over Australia in observations and POAMA-2. *Climate Dyn.*, **43**, 1915–1937, doi:<https://doi.org/10.1007/s00382-013-2016-1>.
- McCormick, M. P., L. W. Thomason, and C. H. Trepte, 1995: Atmospheric effects of the Mt Pinatubo eruption. *Nature*, **373**, 399–404.
- McKee, T. B., N. J. Doesken, and J. Kleist, 1993: The relationship of drought frequency and duration to time scales. Preprints, Eighth Conf. on Applied Climatology, Anaheim, CA, *Amer. Meteor. Soc.*, 179–184.
- McKee, T. B., N. J. Doesken, and J. Kleist, 1995: Drought monitoring with multiple time scales. Preprints, Ninth Conf. on Applied Climatology, Dallas, TX, *Amer. Meteor. Soc.*, 233–236.
- Merryfield, W. J., W.-S. Lee, W. Wang, M. Chen, and A. Kumar, 2013: Multi-system seasonal predictions of Arctic sea ice. *Geophys. Res. Lett.*, **40**, 1551–1556,

doi:<https://doi.org/10.1002/grl.50317>.

- Merryfield, W. J., and Coauthors, 2013: The Canadian seasonal to interannual prediction system. Part I: Models and initialization. *Mon. Wea. Rev.*, **141**, 2910–2945. doi:10.1175/MWR-D-12-00216.1.
- Min, Y. M., 2011: Improvement of the APCC Probabilistic Multi-Model Ensemble Prediction by Model Calibration and Combination. APCC Tech. Rep. 2012–11.
- Min, Y. M., V. N. Kryjov, and C. K. Park, 2009: A probabilistic multimodel ensemble approach to seasonal prediction, *Wea. Forecasting*, **24**, 812–828, doi:10.1175/2008WAF2222140.1.
- Min, Y. M., V. N. Kryjov, and J. H. Oh, 2011: Probabilistic interpretation of regression-based downscaled seasonal ensemble predictions with the estimation of uncertainty. *J. Geophys. Res.*, **D08101**, doi:10.1029/2010JD015284.
- Min, Y. M., V. N. Kryjov, S. M. Oh, and H.-J. Lee, 2017: Skill of real-time operational forecasts with the APCC multi-model ensemble prediction system during the period 2008–2015. *Clim. Dyn.*, doi:10.1007/s00382-017-3576-2.
- Min, Y.-M., V. N. Kryjov, and S. M. Oh, 2014: Assessment of APCC multimodel ensemble prediction in seasonal climate forecasting: Retrospective(1983–2003) and real-time for ecasts(2008–2013). *J. Geophys. Res. Atmos.*, **119**, 12 132–12 150, doi:<https://doi.org/10.1002/2014JD022230>.
- Mo, K. C., and B. Lyon, 2015: Global meteorological drought prediction using the North American Multi-Model Ensemble. *J. Hydrometeor.*, **16**, 1409–1424, doi:<https://doi.org/10.1175/JHM-D-14-0192.1>.
- Molod, A. et al., 2012: The GEOS-5 atmospheric general circulation model: mean climate and development from MERRA to Fortuna. Technical Report Series on Global Modeling and Data Assimilation, 28. <http://gmao.gsfc.nasa.gov/pubs/docs/tm28.pdf>.
- Mori, M., M. Watanabe, H. Shiogama, J. Inoue, and M. Kimoto, 2014: Robust Arctic sea-ice influence on the frequent Eurasian cold winters in past decades. *Nat. Geosci.*, **7**, 869–873, doi:<https://doi.org/10.1038/ngeo2277>.
- Palmer, T. N., 2000: Predicting uncertainty in forecasts of weather and climate. *Rep. Prog. Phys.*, **63**, 71–116.
- Palmer, T., and Coauthors, 2004: Development of a European Multimodel Ensemble System for Seasonal to Interannual Prediction(DEMETER). *Bull. Amer. Meteor. Soc.*, **85**, 853–872.
- Palmer, W. C., 1965: Meteorological drought. Office of Climatology Research Paper 45, U.S. Weather Bureau, 58 pp.

- Park, H.-S., and J.-B. Ahn, 2004: Development of a new CGCM and ENSO Hindcast Experiment using the CGCM. *Asia-Pacific J Atmos Sci.*, **40**, 135–146.
- Peng, P., and A. Kumar, 2005: A large ensemble analysis of the influence of tropical SSTs on seasonal atmospheric variability. *J. Climate*, **18**, 1068–1085, doi:<https://doi.org/10.1175/JCLI-3314.1>.
- Peng, P., A. Kumar, and W. Wang, 2011: An analysis of seasonal predictability in coupled model forecasts. *Climate Dyn.*, **36**, 637–648, doi:<https://doi.org/10.1007/s00382-009-0711-8>.
- Peng, P., A. Kumar, H. van den Dool, and A. G. Barnston, 2002: An analysis of multimodel ensemble predictions for seasonal climate anomalies. *J. Geophys. Res.*, **107**, 4710, doi:[10.1029/2002JD002712](https://doi.org/10.1029/2002JD002712).
- Pepler, A. S., L. B. Díaz, C. Prodhomme, F. J. Doblas-Reyes, and A. Kumar, 2015: The ability of a multi-model seasonal forecasting ensemble to forecast the frequency of warm, cold and wet extremes. *Wea. Climate Extremes*, **9**, 68–77, doi:<https://doi.org/10.1016/j.wace.2015.06.005>.
- Potts, J. M., C. K. Folland, I. T. Jolliffe, and D. Sexton, 1996: Revised “LEPS” scores for assessing climate model simulations and long-range forecasts. *J. Climate*, **9**, 34–53.
- Quan, X. W., M. P. Hoerling, B. Lyon, A. Kumar, M. Bell, M. Tippet, and H. Wang, 2012: Prospects for dynamical prediction of meteorological drought. *J. Appl. Meteor. Climatol.*, **51**, 1238–1252.
- Reynolds, R. W., N. A. Rayner, T. M. Smith, D. C. Stokes, and W. Wang, 2002: An improved in situ and satellite SST analysis. *J. Climate*, **15**, 1609–1625.
- Robeson, S. M., C. J. Willmott, and P. D. Jones, 2014: Trends in hemispheric warm and cold anomalies. *Geophys. Res. Lett.*, **41**, 9065–9071, doi:<https://doi.org/10.1002/2014GL062323>.
- Robock, A., 2000: Volcanic eruptions and climate. *Rev. Geophys.*, **38**, 191–219.
- Rodrigues, L. R. L., F. J. Doblas-Reyes, C. A. S. Coelho, 2014: Multi-model calibration and combination of tropical seasonal sea surface temperature forecasts. *Climate Dyn.*, **42**, 597–616, doi:[10.1007/s00382-013-1779-8](https://doi.org/10.1007/s00382-013-1779-8).
- Ropelewski, C. F., and M. S. Halpert, 1989: Precipitation patterns associated with the high index phase of the Southern Oscillation. *J. Climate*, **2**, 268–284.
- Saha, S., and Coauthors, 2014: The NCEP Climate Forecast System version 2. *J. Climate*, **27**, 2185–2208, doi:<https://doi.org/10.1175/JCLI-D-12-00823.1>.

- Saha, S., and Coauthors, 2006: The NCEP Climate Forecast System. *J. Climate*, **19**, 3483–3517.
- Scinocca, J. F., N. A. Mcfarlane, M. Lazare, J. Li, and D. Plummer, 2008: The CCCma third generation AGCM and its extension into the middle atmosphere. *Atmos. Chem. Phys.*, **8**, 7055–7074. doi:10.5194/acp-8-7055-2008.
- Shi, N., 1996: Features of the East Asian winter monsoon intensity on multiple time scale in recent 40 years and their relation to climate. *Quart. J. Appl. Meteor.*, **7**, 175–182..
- Shin, S. H., 2015: Predictability of the East Asian Winter Monsoon by APCC Multi-Model Ensemble Forecast System. APCC Res. Rep. 2015–09.
- Slingo, J., and T. Palmer, 2011: Uncertainty in weather and climate prediction. *Philos. Trans. Roy. Soc. London*, A369, 4751–4767, doi:10.1098/rsta.2011.0161.
- Smirnov, N., 1948: Table for estimating the goodness of fit of empirical distributions. *Ann. Math. Stat.*, **19**, 279–281, doi:10.1214/aoms/1177730256.
- Sohn, S. J., 2016: Diagnostics of the multi-model ensemble seasonal forecast of the APEC Climate Center: Forecast skill and predictability of ENSO and its response. APCC Res. Rep. 2016–11.
- Sohn, S.-J., C.-Y. Tam, and C.-K. Park, 2011: Leading modes of East Asian winter climate variability and their predictability: An assessment of the APCC multi-model ensemble. *J. Meteor. Soc. Japan*, **89**, 455–474.
- Sohn, S. J., C. Y. Tam, and H. I. Jeong, 2016: How do the strength and type of ENSO affect SST predictability in coupled models. *Sci. Rep.*, **6**, 33790, doi:10.1038/srep33790.
- Sohn, S.-J., C.-Y. Tam, and J.-B. Ahn, 2013: Development of a multimodel-based seasonal prediction system for extreme droughts and floods: A case study for South Korea. *Int. J. Climatol.*, **33**, 793–805, doi:https://doi.org/10.1002/joc.3464.
- Sohn, S., C. Tam, A. Karumuri, and J. Ahn, 2012a: Quantifying the reliability of precipitation datasets for monitoring large-scale East Asian precipitation variations. *Int. J. Climatol.*, **32**, 1520–1526, doi:https://doi.org/10.1002/joc.2380.
- Sohn, S.-J., Y.-M. Min, J.-Y. Lee, C.-Y. Tam, I.-S. Kang, B. Wang, J.-B. Ahn, and T. Yamagata, 2012b: Assessment of the long-lead probabilistic prediction for the Asian summer monsoon precipitation(1983–2011) based on the APCC multimodel system and a statistical model. *J. Geophys. Res.*, **117**, D04102, doi:10.1029/2011JD016308.
- Sun, B. M., and C. Y. Li, 1997: Relationship between the disturbances of East Asian trough and tropical convective activities in boreal winter(in Chinese). *Chin. Sci. Bull.*, **42**, 500–504.

- Sun, J. Q., and B. J. Ahn, 2011: A GCM-based forecasting model for the landfall of tropical cyclones in China. *Adv. Atmos. Sci.*, **28**, 1049–1055, doi:10.1007/s00376-011-0122-8.
- Sun, J., and J. B. Ahn, 2014: Dynamical seasonal predictability of the Arctic Oscillation using a CGCM. *Int. J. Climatol.*, **35**, 1342–1353, doi: <https://doi.org/10.1002/joc.4060>.
- Takaya, Y., T. Yasuda, T. Ose, and T. Nakaegawa, 2010: Predictability of the mean location of typhoon formation in a seasonal prediction experiment with a coupled general circulation model. *J. Meteor. Soc. Japan*, **88**, 799–812.
- Tang, Y., H. Lin, and A. M. Moore, 2008: Measuring the potential predictability of ensemble climate predictions. *J. Geophys. Res.*, **113**, D04108. doi:10.1029/2007JD008804.
- Taylor, J. R., 1997: *An Introduction to Error Analysis: The Study of Uncertainties in Physical Measurements*. 2nd ed. University Science Books, 327 pp.
- Thom, H. C. S., 1966: Same methods of climatological analyses. World Meteorological Organization, Geneva, 53p(WMO, 199; TP, 103; Technical note. 81)
- Thomas, V., J. R. G. Albert and R. T. Perez, 2013: Climate-related disasters in Asia and the Pacific. *ADB Economics Working Paper Series*, **No. 358**, <http://www.adb.org/publications/climate-related-disasters-asia-and-pacific>.
- Thorntwaite, C. W., 1948: an approach toward a rational classification of climate. *Geogr. Rev.*, **38**, 55–94.
- Tippett, M. K., R. Kleeman, and Y. Tang, 2004: Measuring the potential utility of seasonal climate predictions. *Geophys. Res. Lett.*, **31**, L22201, doi:10.1029/2004GL021575.
- Tippett, M. K., A. G. Barnston, and A. W. Robertson, 2007: Estimation of seasonal precipitation tercile-based categorical probabilities from ensembles. *J. Climate*, **20**, 2210–2228.
- Tippett, M. K., A. G. Barnston, and S. Li, 2012: Performance of recent multimodel ENSO forecasts. *J. Appl. Meteor. Climatol.*, **51**, 637–654, doi:<https://doi.org/10.1175/JAMC-D-11-093.1>.
- Tippett, M. K., M. Ranganathan, M. L'Heureux, A. G. Barnston, and T. Delsole, 2017: Assessing probabilistic predictions of ENSO phase and intensity from the North American Multimodel Ensemble. *Climate Dyn.*, doi:10.1007/s00382-017-37210-y.
- Trenberth, K. E., G. W. Branstator, D. Karoly, A. Kumar, N-C. Lau, and C. Ropelewski, 1998: Progress during TOGA in understanding and modeling global teleconnections associated with tropical sea surface temperatures. *J. Geophys. Res.*, **103**, 14291–14324.

- Trosnikov I. V., Kaznacheeva V. D., Kiktev D. B., Tolstikh M.A., 2005: Assessment of potential predictability of meteorological variables in dynamical seasonal modeling of atmospheric circulation on the basis of semi-Lagrangian model SL-AV, *Russian Meteor. Hydrol.*, **12**, 5-17
- UN ESCAP, 2017: Asia-Pacific Disaster Report 2017: Disaster Resilience for Sustainable Development.
- Van den Dool, H. M., and Z. Toth, 1991: Why do forecasts for “near normal” often fail? *Wea. Forecasting*, **6**, 76-85.
- Vecchi, G., and Coauthors, 2014: On the seasonal forecasting of regional tropical cyclone activity. *J. Climate*, **27**, 7994-8016, doi:<https://doi.org/10.1175/JCLI-D-14-00158.1>.
- Vernieres, G., C. Keppenne, M. M. Rienecker, J. Jacob, and R. Kovach, 2012: The GEOS-iODAS: Description and evaluation. NASA/TM-2012-104606/Vol. 30, 61 pp. [Available online at <http://gmao.gsfc.nasa.gov/pubs/docs/Vernieres589.pdf>.]
- Vernieres, G., C. L. Keppenne, M. M. Rienecker, J. P. Jacob and R. N. Kovach, 2012: The GEOS-ODAS description and evaluation. NASA Tech. Rep. Series on Global Modeling and Data Assimilation 30, NASA/TM-2012-104606.
- Vicente-Serrano, S. M., S. Beguería, and J. I. López-Moreno, 2010: A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *J. Climate*, **23**, 1696-1718.
- Vintzileos, A., M. M. Rienecker, M. J. Suarez, S. K. Miller, P. J. Pegion, and J. T. Bacmeister, 2003: Simulation of the El Niño-Interannual Prediction Project coupled general circulation model. *CLIVER Exchanges*, **Vol. 8**, No. 4, International CLIVAR Project Office, Southampton, United Kingdom, 25-27.
- Walland, D. J., and I. Simmonds, 1997: Modeled atmospheric response to changes in Northern Hemisphere snow cover. *Climate Dyn.*, **13**, 25-34.
- Wang, L., and W. Chen, 2014: An intensity index for the East Asian winter monsoon. *J. Climate*, **27**, 2361-2374, doi:<https://doi.org/10.1175/JCLI-D-13-00086.1>.
- Wang, B., and Coauthors, 2008: How accurately do coupled climate models predict the leading modes of Asian-Australian monsoon interannual variability? *Climate Dyn.*, **30**, 605-619.. doi:10.1007/s00382-007-0310-5.
- Wang, B., and Coauthors, 2009a: Advance and prospectus of seasonal prediction: Assessment of the APCC/CLIPAS 14-model ensemble retrospective seasonal prediction(1980-2004). *Climate Dyn.*, **33**, 93-117. doi:10.1007/s00382-008-0460-0.
- Wang, B., I-S. Kang, and J-Y. Lee, 2004: Ensemble simulations of Asian-Australian Monsoon

- variability by 11 AGCMs. *J. Climate*, **17**, 803–818.
- Wang, B., J. Liu, H.-J. Kim, P. J. Webster, and S.-Y. Yim, 2012: Recent change of the global monsoon precipitation(1979–2008). *Climate Dyn.*, **39**, 1123–1135, doi:10.1007/s00382-011-1266-z.
- Wang, B., R. Wu, and X. Fu, 2000: Pacific–East Asian teleconnection: How does ENSO affect East Asian climate? *J. Climate*, **13**, 1517–1536.
- Wang, S., J. Huang, Y. He, and Y. Guan, 2014: Combined effects of the Pacific decadal oscillation and El Niño–Southern Oscillation on global land dry-wet changes. *Sci. Rep.*, **4**, 6651, doi:https://doi.org/10.1038/srep06651.
- Watanabe, M., and T. Nitta, 1999: Decadal change in the atmospheric circulation and associated surface climate variations in the Northern Hemispheric winter. *J. Climate*, **12**, 494–510.
- WCRP, 2012: WCRP Global Drought Information System(GDIS) Workshop. Final Rep, 17pp [Available online at http://eprints.soton.ac.uk/342410/GDIS_Report_final.pdf]
- Weisheimer, A., and Coauthors, 2009: ENSEMBLES: A new multi-model ensemble for seasonal-to-annual predictions—Skill and progress beyond DEMETER in forecasting tropical Pacific SSTs. *Geophys. Res. Lett.*, **36**, L21711. doi:10.1029/2009GL040896.
- Wells, N., S. Goddard, and M. J. Hayes, 2004: A self-calibrating Palmer drought severity index. *J. Climate*, **17**, 2335–2351.
- Wilks, D. S., 1995: *Statistical Methods in the Atmospheric Sciences: An Introduction*, Academic Press.
- Wilks, D. S., 2006: *Statistical Methods in the Atmospheric Sciences*. 2d ed. Academic Press, 627 pp.
- WMO, 2002: Standardised verification system(SVS) for long-range forecasts(LRF). New attachment II-9 to the manual on the GDPS, **Vol 1**. WMO 485, Geneva.
- Wu, B.-Y., and J. Wang, 2002: Winter Arctic Oscillation, Siberian High and East Asian winter monsoon. *Geophys. Res. Lett.*, **29**, 1897. doi:10.1029/2002GL015373.
- Wu, B.-Y., R. Zhang, and R. D’Arrigo, 2006: Distinct modes of the East Asian winter monsoon. *Mon. Wea. Rev.*, **134**, 2165–2179.
- Wu, Z., J. Li, B. Wang, and X. Liu, 2009: Can the Southern Hemisphere annular mode affect Chinese winter monsoon? *J. Geophys. Res.*, **114**, D11107.
- Wu, Z., J. Li, Z. Jiang, and J. He, 2011: Predictable climate dynamics of abnormal East Asian winter monsoon: Once-in-a-century snowstorms in 2007/2008 winter. *Climate Dyn.*,

- 37, 1661-1669, doi:<https://doi.org/10.1007/s00382-010-0938-4>.
- Xie, P., and P. A. Arkin, 1997: Global precipitation: A 17-year monthly analysis based on gauge observations, satellite estimates, and numerical model outputs. *Bull. Amer. Meteor. Soc.*, **78**, 2539-2558.
- Yang, D., X.-Q. Yang, Q. Xie, Y. Zhang, X. Ren, and Y. Tang, 2016: Probabilistic versus deterministic skill in predicting the western North Pacific-East Asian summer monsoon variability with multimodel ensembles., *J. Geophys. Res. Atmos.*, **121**, 1079-1103, doi:10.1002/2015JD023781.
- Yang, S., K-M. Lau, and K-M. Kim, 2002: Variations of the east Asian jet stream and Asian-Pacific-American winter climate anomalies. *J. Climate*, **15**, 306-325.
- Yoo, J. H., and I-S. Kang, 2005: Theoretical examination of a multi-model composite for seasonal prediction. *Geophys. Res. Lett.*, **32**, L18707. doi:10.1029/2005GL023513.
- Yoon, J. H., K. Mo, and E. F. Wood, 2012: Dynamic-model-based seasonal prediction of meteorological drought over the contiguous United States. *J. Hydrometeor.*, **13**, 463-481.
- Yuan, X., and E. F. Wood, 2013: Multimodel seasonal forecasting of global drought onset. *Geophys. Res. Lett.*, **40**, 4900-4905, doi:<https://doi.org/10.1002/grl.50949>.
- Yun, W. T., L. Stefanova, and T. N. Krishnamurti, 2003: Improvement of the multimodel superensemble technique for seasonal forecasts. *J. Climate*, **16**, 3834-3840.
- Yun, W. T., L. Stefanova, A. K. Mitra, T. S. V. Vijaya Kumar, W. Dewar, and T. N. Krishnamurti, 2005: A multi-model superensemble algorithm for seasonal climate prediction using DEMETER forecasts. *Tellus*, **57A**, 280-289.
- Zhang, R., A. Sumi, and M. Kimoto, 1996: Impact of El Niño on the East Asian monsoon: A diagnostic study of the '86/87 and '91/92 events. *J. Meteor. Soc. Japan*, **74**, 49-62.
- Zhang, Y., K. R. Sperber, and J. S. Boyle, 1997a: Climatology and interannual variation of the East Asian winter monsoon: Results from the 1979-95 NCEP-NCAR Reanalysis. *Mon. Wea. Rev.*, **125**, 2605-2619.
- Zhong, A., H. H. Hendon, and O. Alves, 2005: Indian Ocean variability and its association with ENSO in a global coupled model. *J. Climate*, **18**, 3634-3649.
- Zhu, Y. J., Z. Toth, R. Wobus, D. Richardson, and K. Mylne, 2002: The economic value of ensemble-based weather forecasts. *Bull. Amer. Meteor. Soc.*, **83**, 73-83.

Glossary

A-D Test	Anderson-Darling Test
AMO	Atlantic Multidecadal Oscillation
AN	Above-Normal
AO	Arctic Oscillation
APCC	Asia-Pacific Economic Cooperation Climate Center
APEC	Asia-Pacific Economic Cooperation
BN	Below-Normal
BOM	Australian Government Bureau of Meteorology
CanCM3	Canadian Coupled Model versions 3
CanCM4	Canadian Coupled Model versions 4
CCSM	Community Climate System Model
CDC	Climate Diagnostic Center
CDF	Cumulative Distribution Function
CFDL/CM	Geophysical Fluid Dynamics Laboratory/Climate Modeling
CFS	Climate Forecast System
CMAP	Climate Prediction Center Merged Analysis of Precipitation
CMC	Canadian Meteorological Centre
CMCC	Centro Euro-Mediterraneo sui Cambiamenti Climatici
COLA	Center for Ocean-Land-Atmosphere Studies
CSI	Critical Success Index
CTB	Climate Test-Bed
CWB	Central Weather Bureau
DEMETER	Development of a European Multimodel Ensemble System for seasonal to inTERannual prediction
DF	Difference
EAJS	East Asian Jet Stream
EAT	East Asian Trough
EAWM	East Asia Winter Monsoon
ECMWF	European Center for Medium-Range Weather Forecast
EMP	Empirical Ranking Method
ENSO	El Niño-Southern Oscillation
ERFs	Extended Long-Range Forecasts
EUPORIAS	EUropean Provision Of Regional Impact Assessment on a Seasonal-to-decadal timescale

FAR	False Alarm Rate
GAUS	Parametric Gaussian fitting method
GDIS	Global drought information system
GEOS5	Goddard Earth Observing System Model version 5
GIDMaPS	Global Integrated Drought Monitoring and Prediction System
GPC	Global Producing Centre
HR	Hit Rate
HSS	Heidke Skill Score
IMME	International Multi-Model Ensemble
IPCC	Intergovernmental Panel on Climate Change
IRI	International Research Institute for Climate and Society
JMA	Japan Meteorological Administration
KMA	Korea Meteorological Administration
K-S Test	Kolmogorov-Smirnov Test
LEPS	Linear error in probability score
MC	Monte-Carlo
MME	Multi-Model Ensemble
MRG	Multiple Regression Method
MSC	Meteorological Service of Cadana
NASA	National Aeronautics and Space Administration
NCAR	National Center for Atmospheric Research
NCEP	National Centers for Environmental Prediction
NIDIS	National Integrated Drought Information System
NMME	North-America Multi-Model Ensemble
NN	Near-Normal
NOAA	National Oceanic and Atmospheric Administration
OISST	Optimum Interpolation SST
PCC	Pattern Correlation Coefficient
PDF	Probability Density Function
POD	Probability Of Detection
PDSI	Palmer Drought Severity Index
PMME	Probabilistic Multi-Model Ensemble
PNU	Pusan National University
POAMA	Predictive Ocean Atmosphere Model for Australia
PoD	Predictive Ocean Atmosphere Model for Australia
QPF	Quantitative Precipitation Forecast

R2O	Research-to-Operation
RCOF	Regional Climate Outlook Forum
RD	Reliability Diagram
RMSE	Root Mean Square Error
ROC	Relative Operating Characteristics
RPSS	Ranked Probability Skill Score
RSD	Relative Skill Difference
SCM	Simple Composite Method
SCoPS	Seamless Coupled Prediction System
SDO	Seasonal Drought Outlook
SE	Standard Error
SEDI	Symmetric Extremal Dependency Index
SH	Siberia High
SNR	Signal-to-noise ratio
SPEI	Standardized Precipitation Evapotranspiration Index
SPI	Standardized Precipitation Index
SPM	Step-wise Pattern projection Method
SSE	Synthetic Super Ensemble Method
SST	Sea Surface Temperature
TCC	Temporal Correlation Coefficient
UKMO	United Kingdom Met Office
UN ESCAP	United Nations Economic and Social Commission for Asia and the Pacific
USDM	United State Drought Monitor
WMO	World Meteorological Organization
WMO LC-LRFMME	WMO Lead Centre for Long-Range Forecast MME
WPC	Weather Prediction Center

APPENDIX 1. 최근 3년간(2013-15년) NMME 자료 분석을 통한 예측력 평가 및 사례분석

2013	Bastola S et al. 2013: Seasonal Hydrological Forecasts for Watersheds over the Southeastern United States for the Boreal Summer and Fall Seasons. <i>Earth Interact</i>, 17, 1-22. doi: http://dx.doi.org/10.1175/2013EI000519.1 Yuan X and EF Wood 2013: Multimodel seasonal forecasting of global drought onset, <i>Geophys Res Lett</i>, 40, 4900-4905. doi:http://dx.doi.org/10.1002/grl.50949
2014	Becker E et al. 2014: Predictability and forecast skill in NMME. <i>J Climate</i>, 27, 5891-5906. doi: http://dx.doi.org/10.1175/JCLI-D-13-00597.1 Cornuelle B et al. 2014: Issues and challenges with using ensemble-based prediction to probe the weather-climate interface. <i>Bull Amer Meteor Soc</i>, 95, ES213-ES215. doi: http://dx.doi.org/10.1175/BAMS-D-13-00235.1 Infanti JM and BP Kirtman, 2014: Southeastern U.S. rainfall prediction in the North American Multi-Model Ensemble. <i>J Hydrometeor</i>, 15, 529-550. doi: http://dx.doi.org/10.1175/JHM-D-13-072.1 Kumar A et al. 2014: Is there a relationship between potential and actual skill? <i>Mon Wea Rev</i>, 142, 2220-2227. doi:http://dx.doi.org/10.1175/MWR-D-13-00287.1 Larson SM and BP Kirtman, 2014: The Pacific meridional mode as an ENSO precursor and predictor in the North American multimodel ensemble. <i>J Climate</i>, 27, 7018-7032. doi: http://dx.doi.org/10.1175/JCLI-D-14-00055.1 Li H and V Misra, 2014: Global seasonal climate predictability in a two tiered forecast system. part II: boreal winter and spring seasons. <i>Climate Dyn</i>, 42, 1449-1468. doi:http://dx.doi.org/10.1007/s00382-013-1813-x Lopez H and BP Kirtman, 2014: WWBs, ENSO predictability, the spring barrier and extreme events. <i>J Geophys Res</i>, 119, 10,114-10,138. doi:http://dx.doi.org/10.1002/2014JD021908 Misra V and HL 2014: The seasonal climate predictability of the Atlantic Warm Pool and its teleconnections, <i>Geophys Res Lett</i>, 41, 661-666, doi:http://dx.doi.org/10.1002/2013GL058740. Misra V et al. 2014: Global seasonal climate predictability in a two tiered forecast system: part I: boreal summer and fall seasons. <i>Climate Dyn</i>, 42, 1425-1448. doi:http://dx.doi.org/10.1007/s00382-013-1812-y. Mo KC and DP Lettenmaier, 2014: Hydrologic prediction over the Conterminous United States using the National Multi-Model Mensemble. <i>J Hydrometeor</i>, 15, 1457-1472. doi: http://dx.doi.org/10.1175/JHM-D-13-0197.1 Rodrigues LRL et al. 2014: Seasonal forecast quality of the West African monsoon rainfall regimes by multiple forecast systems. <i>J Geophys Res</i>, 119,7908-7930. doi:http://dx.doi.org/10.1002/2013JD021316

2014	Su J et al. 2014: Abrupt termination of the 2012 Pacific warming and its implication on ENSO prediction. <i>Geophys Res Lett</i>, 41, 9058-9064. doi:http://dx.doi.org/10.1002/2014GL062380 Thober S et al. 2014: Stochastic temporal disaggregation of monthly precipitation for regional gridded data sets. <i>Water Resour Res</i>, 50, 8714-8735. doi:http://dx.doi.org/10.1002/2014WR015930 Tian D et al. 2014: Statistical downscaling multimodel forecasts for seasonal precipitation and surface temperature over the southeastern United States. <i>J Climate</i>, 27, 8384-8411. doi: http://dx.doi.org/10.1175/JCLI-D-13-00481.1 Wang H et al. 2014: On the role of SST forcing in the 2011 and 2012 extreme U.S. heat and drought: A study in contrasts. <i>J Hydrometeor</i>, 15, 1255-1273. doi: http://dx.doi.org/10.1175/JHM-D-13-069.1 Wang H 2014: Evaluation of monthly precipitation forecasting skill of the National Multi-model Ensemble in the summer season. <i>Hydrological Processes</i>, 28, 4472-4486. doi: http://dx.doi.org/10.1002/hyp.9957
2015	Capotondi A et al. 2015: Understanding ENSO diversity. <i>Bull Amer Meteor Soc</i>, 96, 921-938. doi: http://dx.doi.org/10.1175/BAMS-D-13-00117.1 Ham YG and JS Kug 2015: Improvement of ENSO simulation based on intermodel diversity. <i>J Climate</i>, 28, 998-1015. doi:http://dx.doi.org/10.1175/JCLI-D-14-00376.1 Johnna M et al. 2015: North American rainfall and temperature prediction response to the diversity of ENSO. <i>Clim Dyn</i>. doi:http://dx.doi.org/10.1007/s00382-015-2749-0 Kim HM et al. 2015: Statistical-dynamical seasonal forecast for tropical cyclones affecting New York State. <i>Wea Forecasting</i>, 30, 295-307. doi:http://dx.doi.org/10.1175/WAF-D-14-00089.1 Kirtman B 2015: Current status of ENSO prediction and predictability. <i>US CLIVAR VARIATIONS</i>, 13, 10-15. http://www.usclivar.org/sites/default/files/documents/2015/Variations2015Winter_0.pdf#page=10 Sarah ML and Kirtman BP 2015: Revisiting ENSO coupled instability theory and SST error growth in a fully coupled model. <i>J Climate</i>, 28, 4724-4742. doi: http://dx.doi.org/10.1175/JCLI-D-14-00731.1 Liu S et al. 2015: A hybrid approach to improving the skills of seasonal climate outlook at the regional scale. <i>Clim Dyn</i>, 1-12. doi: http://dx.doi.org/10.1007/s00382-015-2594-1 Feng M. et al. 2015: Evaluating the skill of NMME seasonal precipitation ensemble predictions for 17 hydroclimatic regions in continental China. <i>Int J Climatol</i>. doi: http://dx.doi.org/10.1002/joc.4333 Feng M. et al. 2015: Seasonal drought predictability and forecast skill over China, <i>J Geophys Res Atmos</i>. 120, doi:http://dx.doi.org/10.1002/2015JD023185 Kingtse CM and B Lyon 2015: Global meteorological drought prediction using the North American Multi-Model Ensemble. <i>J Hydrometeor.</i>, 16, 1409-1424. doi: http://dx.doi.o

2015	rg/10.1175/JHM-D-14-0192.1
	Robertson AW et al. 2015: Improving and promoting subseasonal to seasonal prediction. Bull Amer Meteor Soc, 96, ES49-ES53. doi: http://dx.doi.org/10.1175/BAMS-D-14-00139.1
	Joshua K et al. 2015: A framework for diagnosing seasonal prediction through canonical event analysis. Mon Wea Rev, 143, 2404-2418. doi: http://dx.doi.org/10.1175/MWR-D-14-00190.1
	Seager R et al. 2015: Causes of the 2011-14 California drought. J Climate, 28, 6997-7024. doi: http://dx.doi.org/10.1175/JCLI-D-14-00860.1
	Shukla S et al. 2015: Temperature impacts on the water year 2014 drought in California. Geophys Res Lett, 42, 4384-4393. doi: http://dx.doi.org/10.1002/2015GL063666
	Sikder MS et al. 2015: Are General Circulation Models Ready for Operational Streamflow Forecasting for Water Management in Ganges and Brahmaputra River basins? J Hydrometeorol, doi: http://dx.doi.org/10.1175/JHM-D-14-0099.1
	Thiaw WM and VB Kumar 2015: NOAA's African desk: twenty years of developing capacity in weather and climate forecasting in Africa. Bull Amer Meteor Soc, 96, 737-753. doi: http://dx.doi.org/10.1175/BAMS-D-13-00274.1
	Thober S et al. 2015: Seasonal soil moisture drought prediction over Europe using the North American Multi-Model Ensemble (NMME). J Hydrometeorol, doi: http://dx.doi.org/10.1175/JHM-D-15-0053.1
	Wood EF et al. 2015: Prospects for advancing drought understanding, monitoring, and prediction. J Hydrometeorol., 16, 1636-1657. doi: http://dx.doi.org/10.1175/JHM-D-14-0164.1
	Yuan X et al. 2015: Seasonal forecasting of global hydrologic extremes: system development and evaluation over GEWEX basins. Bull Amer Meteor Soc, doi: http://dx.doi.org/10.1175/BAMS-D-14-00003.1

APPENDIX 2. 최근 3년간(2013~15년) NMME 예측력 향상을 위한 모델 및 기술 개발 연구

2013	Merryfield WJ et al. 2013: Multi-system seasonal predictions of Arctic sea ice, <i>Geophys Res Lett</i> , 40, 1551-1556. doi:http://dx.doi.org/10.1002/grl.50317
2014	DelSole T et al. 2014: Skill improvement from increased ensemble size and model diversity. <i>Geophys Res Lett</i>, 41 (20), 7331-7342. doi:http://dx.doi.org/10.1002/2014GL060133 DelSole T et al. 2014: Comparing forecast skill. <i>Mon. Wea. Rev.</i>, 142, 4658-4678. doi: http://dx.doi.org/10.1175/MWR-D-14-00045.1 Saha S et al. 2014: The NCEP Climate Forecast System Version 2. <i>J Climate</i>, 27, 2185-2208. doi: http://dx.doi.org/10.1175/JCLI-D-12-00823.1 Vecchi GA et al. 2014: On the Seasonal Forecasting of Regional Tropical Cyclone Activity. <i>J Climate</i>, 27, 7994-8016. doi:http://dx.doi.org/10.1175/JCLI-D-14-00158.1
2015	Barnston AG et al. 2015: Toward an improved multimodel ENSO prediction. <i>J Appl Meteor Climatol</i>, 54, 1579-1595. doi: http://dx.doi.org/10.1175/JAMC-D-14-0188.1 DelSole T et al. 2015: Forecast comparison based on random walks. <i>Mon Wea Rev</i>, doi: http://dx.doi.org/10.1175/MWR-D-15-0218.1 Jia L et al. 2015: Improved seasonal prediction of temperature and precipitation over land in a high-resolution GFDL climate model. <i>J Climate</i>, 28, 2044-2062. doi: http://dx.doi.org/10.1175/JCLI-D-14-00112.1 Murakami H et al. 2015: Simulation and prediction of category 4 and 5 hurricanes in the high-resolution GFDL HiFLOR coupled climate model. <i>J Climate</i>, doi: http://dx.doi.org/10.1175/JCLI-D-15-0216.1 Rajesh R et al. 2015: A dynamical climate model-driven hydrologic prediction system for the Fraser River, Canada. <i>J Hydrometeorol</i>, 16, 1273-1292. doi: http://dx.doi.org/10.1175/JHM-D-14-0167.1 Yuan X et al. 2015: A review on climate-model-based seasonal hydrologic forecasting: physical understanding and system development. <i>WIREs Water</i>, 2, 523-536. doi: http://dx.doi.org/10.1002/wat2.1088

APPENDIX 3. 영향예보에 대한 현황

영향예보(impact forecast)는 기상 현상으로 인해 예상되는 사회 경제적 영향을 위험 및 취약성을 고려하여 상세한 기상 정보와 함께 전달하는 예보를 뜻한다. 동일한 날씨 또는 위험 기상이 일어나는 지역에 따라 위험 및 재해의 정도가 서로 다를 수 있기 때문에 이를 고려한 영향 위험 기상에 대한 정보 및 영향을 전달하는 것이 영향예보이다. 따라서 현재의 영향예보는 재해 대응에 초점을 두어 시간규모가 짧은 기상학적 관점에서 생산되고 있다.

2011년부터 영국기상청에서는 위험가능성 도표(그림 A3.1)를 기반으로, 5가지 기상 현상(비, 바람, 눈, 결빙, 안개)에 대해 발생 가능성과 영향의 정도에 따라 최대 5일 전부터 특보를 발표하고 있다. 향후에는 기상재해와 재해 취약성 및 노출을 고려할 수 있는 재해영향 모델을 개발하여 영향예보에 활용하고자, 재해영향모델 중 하나인 VOT(Vehicle OverTurning) 모델을 개발하여 강풍으로 인해 차량이 뒤집혀 발생할 수 있는 영향(교통사고, 도로혼잡 등)을 시범적으로 예측하고 있다. 또한 침수와 산사태에 관한 재해모델을 개발하고 있다. 미국기상청은 2013년 Weather Ready Nation 로드맵을 통해 영향기반 의사결정 지원 서비스(Impact-based Decision Support Services)를 제공할 것을 선언하고, 사용자에게 해석과 상담 서비스 제공을 추진하고 일부 지방 기상청을 중심으로 홈페이지나 SNS를 통한 영향예보를 서비스하거나 4~7일 후의 겨울폭풍 영향예보를 시범적으로 제공 하고 있다(그림 A3.2). 한국기상청 또한 2020년 영향예보를 본격적으로 수행하겠다는 비전을 수립하고 이를 위한 추진전략 및 세부과제를 구성하여 연구개발을 진행 중이다(기상청 2016⁶⁰⁾)

60) 기상청, 2016: 영향예보의 현황 및 응용. 기상기술정책지, 23, 1-71.

Likelihood	High				
	Med				
	Low				
	Very low				
		Very low	Low	Med	High
Impact					

Figure A3.1. 영국기상청의 위험가능성 도표 (impact matrix).




Figure A3.2. 미국기상청의 겨울폭풍 영향 예보 예시.

APPENDIX 4. JMA forecast 자료 처리 방법

APCC MME에 사용되는 JMA 예측자료는 Tokyo Climate Center(TCC)의 홈페이지⁶¹⁾를 통해서 다운받고 있으며(특정 사용들에게만 공개됨), forecast, forecast anomaly, hindcast 자료로 구성되어 있다. 이 중 forecast 자료에 한해서는 모델의 원시 자료(f_{raw})에서 계통적 오차(systematic error, ϵ)가 제거되어 있기 때문에 APCC에서 수집하여 전처리한 JMA의 forecast 자료에도 역시 오차가 보정 되어있다(f_{calib}). 이 때 연구자(또는 사용자)가 APCC를 통해 제공되는 JMA의 forecast 자료를 이용하여 forecast anomaly를 계산할 때 오차가 중복해서 제거될 수 있음을 유의해야 한다. 이러한 중복을 피하기 위해서 JMA 모델의 원시 forecast를 구할 필요가 있다.

2015년 6월부터 현재까지 JMA에서 사용하고 있는 계절예측모델인 JMA/MRI-CPS2는 그림 A4.1과 같이 forecast 자료 생산일로부터 제일 가까운 과거 4개의 initial date에서 각 13개씩, 총 51개의 앙상블 멤버(가장 오래된 initial date에서는 12개 앙상블 멤버)를 생산하고, 이 forecast 자료는 initial date별로 오차 보정이 되어있다. 따라서 initial date 별 계통적 오차 자료를 구할 있다면 오차 보정된 forecast(f_{raw})에 initial date에 해당하는 계통적 오차(ϵ)를 더해줌으로써 원시 forecast 자료(f_{raw})를 구할 수 있다(Eq. A3.1).

$$f_{raw} = f_{calib} + \epsilon \quad (A4.1)$$

다행히도 JMA에서는 예측의 initial date 별 계통적 오차 자료를 제공해주고 있다⁶²⁾. JMA 예측자료에 사용되는 initial date는 Table A4.1에 정리하였다. 실제로 매 월 3개월 예측자료를 만들 시점에 사용한 initial date는 JMA에서 제공해주는 GRIB2 자료의 메타데이터 레코드에서 확인할 수 있다. GRIB2 자료에 wgrib2 명령어를 입력해보면 Table A4.2와 같은 레코드가 153개(앙상블 수(51개)×예측시간(3개월)) 나오는데, 예를 들어 이 중 'd=2017092800'가 initial date인 2017년 9월 28일을 의미한다. 이러한 방법으로 initial date를 확인해보면 예측에 사용된 9월 28일, 10월 3일, 10월 8일, 10월 13일임을 알 수 있다. 여기에서 9월 28일에 생산한 앙상블 멤버 13개에 대해서는

61) <http://ds.data.jma.go.jp/tcc/tcc/index.html>

62) http://ds.data.jma.go.jp/tcc/gpv/model/CPS2/CPS2_syserr.html

9월 28일의 계통적 오차 자료를 더하면 원시 forecast 자료를 생산할 수 있다. 이 과정을 각 앙상블 멤버에 대해 거친 후 51개의 원시 forecast 앙상블 멤버를 평균하면 원시 forecast 앙상블 평균 자료가 된다. 참고로, forecast 자료 중 오차 보정이 적용되는 11개의 변수들을 Table A4.3에 나타내었고, 이 변수들에 대해서는 오차 자료를 제공해 준다.

이렇게 만든 원시 forecast 자료로부터 계산된 1983-2005년의 hindcast에 대한 anomaly(f_{raw})의 공간장을 살펴보면 오차 보정된 forecast를 이용한 anomaly(f_{calib})에서 보이는 극단적인 값들이 잘 수정된다(그림 A4.2-A4.6). 특히 2m 기온의 경우에 수정된 효과가 두드러지게 나타나는데, 수정 전 anomaly의 공간장(그림 A4.2(a))에서는 유럽, 러시아, 북미, 북극 등 북반구 중위도에서부터 북극까지 아우르는 극도로 차가운 온도와 남극 대륙의 극도로 따뜻한 온도가 계통적 오차(그림 A4.2(c))가 더해짐으로써 많이 완화되었을 뿐만 아니라, 아프리카 북부, 중동, 중앙아시아 및 3대양에 보이던 따뜻한 온도 역시 수정 후 anomaly(f_{raw})에서는 나타나지 않는다(그림 A4.2(b)).




Figure A4.1. Schematic diagram of ensemble configurations of operational suite (source: http://ds.data.jma.go.jp/tcc/tcc/products/model/outline/cps2_description.html).

Table A4.1. Initial date of TCC forecast data.

Month	Date
January	01,06,11,16,21,26,31
February	05,10,15,20,25
March	02,07,12,17,22,27
April	01,06,11,16,21,26
May	01,06,11,16,21,26,31
June	05,10,15,20,25,30
July	05,10,15,20,25,30
August	04,09,14,19,24,29
September	03,08,13,18,23,28
October	03,08,13,18,23,28
November	02,07,12,17,22,27
December	02,07,12,17,22,27

Table A4.2. How to find the initial date from the 3-month forecast data file using wgrib2 command.

```
> wgrib2 h2_Ptt_mb.201710
.
.
.
4.1:2471028:d=2017092800:var discipline=0 master_table=4 parmcat=0 parm=0:2 m above
ground:34 day- (34 day+720 hour ave@6 hour fcst,missing=0:ENS=low-res ctl
.
.
.
```

Table A4.3. 11 calibrated variables by subtracting systematic error from direct model output.

Variable	Vertical Level
Geopotential height	850hPa, 500hPa, 300hPa, 200hPa, 100hPa
Sea level pressure	Surface
Temperature	2m, 850hPa, 500hPa, 200hPa
Sea Surface Temperature	Surface




Figure A4.2. (a) Anomaly derived from calibrated forecast, (b) anomaly derived from raw forecast and (c) systematic error of 2m temperature for DJF 2016/17.




Figure A4.3. (a) Anomaly derived from calibrated forecast, (b) anomaly derived from raw forecast and (c) systematic error of sea level pressure for DJF 2016/17.




Figure A4.4. (a) Anomaly derived from calibrated forecast, (b) anomaly derived from raw forecast and (c) systematic error of 850 hPa temperature for DJF 2016/17.




Figure A4.5. (a) Anomaly derived from calibrated forecast, (b) anomaly derived from raw forecast and (c) systematic error of 500 hPa GPH for DJF 2016/17.




Figure A4.6. (a) Anomaly derived from calibrated forecast, (b) anomaly derived from raw forecast and (c) systematic error of sea surface temperature for DJF 2016/17.

【연구자】

민영미 선임연구원

손수진 선임연구원

신선희 선임연구원

이현주 연구원

김가영 연구원

연구보고서 2017-08

기후예측자료 기반 새로운 콘텐츠 생산을 위한 예측시스템 개발

I S B N 979-11-5698-198-5

발 행 2018년 3월

발 행 인 정 홍 상

발 행 처 APEC기후센터
부산시 해운대구 센텀7로 12

제작·인쇄 경성문화사

이 보고서는 APEC기후센터 홈페이지(<http://www.apcc21.org/>)에서 이용하실 수 있습니다.
또한 보고서에 실린 내용은 출처를 명시하면 자유롭게 인용할 수 있습니다. 단, 무단 전재 및
복제를 금합니다.