

이상기후 장기예보 콘텐츠 개발

**Developing Service Contents for Long-term
Extreme Climate Forecasts**

김선태, 김대하, 김옥연, 명복순, 이은정, 이진영, 전종안

기후사업본부 기후분석과

2020.12.

APEC기후센터

평문 초록

지구 온난화와 기후 변동성에 의해 전 지구 평균 기온 최고치가 2010년 이후로 여러 차례 경신되고 있는 가운데 인류 건강 및 생태계 지속성에 가장 민감한 영향을 미치는 기상재해인 폭서기에 대한 사전대응이 더욱 중요해지고 있습니다. 사전 대응을 위한 노력의 일환으로 이상 기후현상을 상시 감시하고 이에 대한 원인을 분석하여, 미리 이상기후현상을 예측하고 이에 대한 피해를 줄이는 대책을 마련하는 게 효과적입니다.

이상기후 감시를 위해서 준 실시간으로 이상기후 감시 정보 제공을 위해서 운영되고 있는 동아시아 이상기후 감시 정보 웹 서비스 개선을 위해서 콘텐츠를 확대하고 전달력 강화 및 이해도를 높이고자 그래픽 품질 개선이 이루어졌습니다. 폭염 같은 이상 기후 발생 전망에서 감시 인자들의 활용성을 높이기 위해서 감시 인자 검증 시스템을 구축하였으며, 아울러 새로운 감시 인자의 확대를 도모하였습니다. 2020년 여름철 한반도 이상 기후 발생에 대한 원인 분석을 수행하고 이해가 쉬운 모식도를 제시하였습니다. 예측 정보 확대를 위해서 과거 유사해 추출 방법과 기계학습 방법을 이용하여 통계 모델들을 구축하였으며 전국 및 지역별 폭서기 이상 기후 3개월 확률전망정보를 생산하였습니다. 그리고 기상청 현업모델의 예측 정보의 신뢰도 및 활용성을 높이기 위해서 예측 오류들을 보정하는 방법 등과 같은 방안들을 제시하였습니다.

개선된 준 실시간 이상기후 정보 제공 서비스에서 추가된 통합맵 들을 통해 여러 가지 이상기후 정보들을 한눈에 볼 수 있게 되었으며, 개발된 이상기후 발생 감시 인자 검증 시스템을 통해서 이상 기후 전망에서 감시 인자들의 활용성을 한층 높일 수 있을 것으로 판단 됩니다. 이 연구를 통해서 작성된 2020년 기록적인 이상 기온과 강수 발생에 대한 감시, 원인, 예측 사후 분석이 통합되어 있는 원인 분석서는 감시 인자 설정 및 예측 모델의 예측 오류를 확인하고, 개선에 도움을 줄 수 있을 것으로 보입니다. 개발된 통계기반 모델들이 신뢰성있는 예측 정보 제공이 가능하다는 것과 기상청 현업 모델들의 예측 결과들의 활용성을 높이고자 이 연구에서 제시된 방안들이 효과가 있음을 확인했습니다. 이들 결과들의 이상 기후 장기 전망에 대한 현업활용을 통해서 예측정보 확대와 개선에 기여할 수 있을 것으로 기대 됩니다.

Executive Summary

In this project, a series of studies are performed on providing monitoring and attribution information of extreme events which are understandable to possible users and on developing 1-3 month forecast contents for expansion of forecast information. Main results are summarized as follows:

Monitoring contents over East Asian extreme climate are added in near real-time web service system built last year. Also, visualization techniques are improved. In the improved monthly monitoring map, not only spatial distribution but also ranking information for comparison with past 40 years is provided. Besides, average of every 10 days over the East Asian and Korean region are added below spatial pattern. Monthly precipitation and drought indices of similar categories are combined into one map such as ‘Combined precipitation map’ and ‘Combined drought map’. For the easier understanding, additional ‘Analysis guide’ is provided at the bottom of the monitoring information website.

After analyzing characteristics of various predictors of monthly mean temperature (Ts) and heat wave days (HWD) in summer, including accuracies of the predictors depending on decades, we also developed a detail-process verification system of the predictors and applied to the case of summer months in 2020. The detail-process verification system, first, calculates correlations (1981-2010) between a predictor and key three atmospheric variables (i.e., geopotential heights at upper- and lower-levels and vertical motion at mid-level) at each grid point in the East Asia and the subtropical western Pacific region and, second, computes pattern correlation coefficients between the previously calculated predictor-key variable correlations and the anomalies of the key variable in the target month in order to test their similarity. Application of this system to summer months in 2020 finds that the detail processes of the April eastern Indian Ocean SST index (July Ts/HWD predictor) and the February north Australia SST index (August Ts/HWD predictor) were similar to the anomaly patterns in July and August, 2020, respectively. In reality, their projections on Ts/HWD (i.e., below-normal Ts and HWD in July and above-normal Ts and HWD in August) found to be correct. In addition, the detail-process verification system is found to increase Accuracy of predictors, compared to Accuracy when the detail processes are not considered. Meanwhile, a new predictor, spring Polar/Eurasia(POL) teleconnection index, is also proposed, showing strong correlations with Ts and with HWD in July and August after 1990’s; When the February-April mean POL index is high, SSTs in the Philippine Sea are high in spring with suppressed convections and in summer stimulate convection in the Philippine Sea, causing anti-cyclonic circulations in East Asia, and then high Ts/HWD in South Korea.

We assessed the applicability of land conditions as monitoring indicators for the

heatwaves over the Republic of Korea. First, the regional heatwaves over the Republic of Korea were defined using the observed daily maximum temperatures at the 45 Automated Synoptic Observation System (ASOS) stations for the period of 1979–2019. The Self-organizing map (SOM) technique was then applied to the clustering analysis of the regional heatwaves to find the regional heatwaves more influenced by land conditions rather than the oceanic influences. The ERA-5 T2m dataset (20–50° N and 110–150° E) corresponding to the regional heatwave dates were classified into the 3 groups using the SOM technique. Node 3 was selected for the further investigation of the influences of the land conditions on the regional heatwaves using a composite analysis. The results showed that the negative soil moisture anomalies in the region between 40–60° N and 0–30° E were statistically significant at the 10% of significance level. A further study is suggested on the investigation of the soil moisture anomalies in the region as a monitoring indicator for the regional heatwaves over the Republic of Korea.

This study explores a possible dynamical mechanism for climate variation over the Korean Peninsula during summer in 2020. During spring season after the peak of 2020/21 El Niño event, there is an anomalous warming in the north Indian Ocean by an atmospheric bridge effect, leading to the development of anomalous anticyclonic circulation (AACC) over the North Western Subtropical Pacific (NWSP) throughout summer season. The AACC over the NWSP transports the warm and wet air from the tropics to the Korean Peninsula, resulting in greater-than-normal June and August extremely warm days. The warm and wet airs from the tropics forms the well-established front together with the cold airs which are transported into Korea by the AACC around the northeastern part of China (NEC) in July, leading to record-breaking increase in the amount of precipitation. The AACC over the NEC is linked to the teleconnection pattern of the negative North Atlantic Oscillation, which is forced possibly by the North tropical Atlantic Ocean warming due to the Walker Circulation eastward shift during El Niño development. It is also found that the joint effect of climate modes in Pacific, Indian and Atlantic Oceans on the Korean summer climates can be modulated by the phases of Atlantic Multidecadal Oscillation.

In this study, for 3-month long-range forecasts of extreme climate events in South Korea, two statistical models are developed. Firstly, We used a method for stochastic heatwave forecasts based on chosen neighbor years. The k nearest neighbor years were selected from lagged correlation analyses between the atmospheric geopotential height fields and heat wave days. The heatwave days in forecasted months were quantified as the number of days with daily maximum temperatures higher than their 90 percentile, and their correlations to the precedented geopotential heights were globally investigated. The neighbor years for forecasted months were chosen by geopotential height differences in the earlier four months at all the locations with statistically significant correlations. The proposed method was tested with the reanalysis geopotential height and synoptic temperature observations in Korea, and showed acceptable performance in reproducing the observed heatwave durations.

Then, the daily maximum temperature observations were used to assess heatwave risks using the Markov-chain-based weather generator. In a probabilistic manner, the weather generator enabled users to visualize spatial and temporal variations of heatwave risks, possibly being an operational tool for heatwave risk assessment.

Secondly, we developed a non-parametric Bayesian machine learning model using a Gaussian Process. Probabilistic forecast information of climate extremes was produced and visualized for South Korea as well as ten sub-regions within South Korea. Four different ways of obtaining input data were compared: predictors with their areas and times of interest are determined following the long-range forecast guidance (GD), areas of predictors are from the guidance but their times of interest are determined by the correlations between the predictors and climate extreme indices (GD_MOD), areas of predictors are determined by clustering the correlation coefficients between the predictors and climate extreme indices (CL), and principal components of CL are derived as predictors (CL_PC). Also, various probabilistic forecast results have been integrated based on the Bayesian Model Averaging (BMA). Models regarding clustering (CL and CL_PC) as well as the BMA produced better results overall. We adopted the method of Jupp et al.(2012) and visualized ternary probabilistic forecast results using a ternary diagram and Hue-Saturation-Value (HSV) color scheme.

In this study, we also proposed methods for best utilizing forecast information from a Korea Meteorological Administration (KMA) operational model that has systematic bias and low skill scores for predicting extreme climate events. The GloSea5 forecast system operated by the (KMA) was selected for this study and the probabilistic forecasts for the extreme temperature in the 9 divisions (Gyeonggi: GG, Gyeongnam: GN, Gyeongbuk: GB, Yeongdong: YD, Yeongseo: YS, Jeonnam: JN, Jeonbuk: JB, Chungnam: CN, and Chungbuk: GB) of the Republic of Korea were then assessed by AUC (Area Under the Curve) for each division and the whole country. These results were compared with those of the ECMWF system. The top and bottom 15% tails were determined for the extreme thresholds. Subsequently, this may enable GloSea5 to provide the 5 categorical probabilistic forecasts (i.e., Extremely Low, Below Normal, Near Normal, Above Normal, and Extremely High) for Tavg. Similar to the Tavg forecasts, the 2 categorical probabilistic forecasts for Tmax and Tmin based on the median values were found to be provided. We applied this proposed categorical probabilistic forecasts to summer in 2020. The categorical probabilistic forecasts for Tavg, Tmax, and Tmin in June were accurately provided, while those in July were not. This result recommends a further study on the improvement of the GloSea5 forecast system.

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

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

국문 요약

본 과제에서는 우리나라 이상기후 장기 전망 정보 개선을 위해서 수요자가 이해하기 쉬운 혹서기 감시 정보 및 원인 분석서 생산, 예측 정보 확대를 위한 1-3개월 예측 콘텐츠 개발을 목표로 하여 연구가 수행되었다.

2019년부터 준 실시간 동아시아 이상기후 감시 정보 웹 서비스 자동화 시스템을 구축하여 운영하며, 다양한 피드백을 통해 이상기후 감시 정보의 콘텐츠를 확대하고 그래픽 품질 개선을 통해 전달력 강화 및 이해도를 높이고자 하였다. 주별 정보를 없애고 월별 1회 웹서비스 실시로 더욱 효율적인 자동화 시스템으로 개선하였다. 개선된 월별 감시 정보에는 동아시아 지역에 대한 공간 분포도와 함께 1981년부터 현재까지의 순위 정보를 부가 정보로 추가하였다. 기존 서비스 중이었던 주별 감시 정보를 대신하여 동아시아/한반도 지역에 대한 순별 변화 양상을 월별 감시 정보의 부가 정보로 통합하여 제공하였다. 그리고 많은 이상기후 감시 정보로 인해 해석이 어려워, 비슷한 카테고리에 속해 있는 감시 정보들을 통합하여 이상강수 통합맵과 가뭄 통합맵을 추가로 생산하였다. 이러한 이상기후 감시 정보들을 이상고온과 저온, 습윤과 건조로 통합하여 한 눈에 볼 수 있도록 동아시아 이상기후 통합맵으로 추가 생산하였다. 개선된 각 감시 정보에 대한 해석과 이해도를 높이기 위해 해석가이드를 웹 페이지에서 함께 서비스하였다.

또한 본 연구에서는 이상 기후 전망에서 활용되는 혹서 감시인자 정보 개선 및 확대를 위해서 예측성의 변동성을 포함한 기존의 혹서기 기온에 대한 감시 인자의 특성을 분석하고 감시 인자 상세 역학과정 검증 시스템을 개발하여 2020년 여름철에 적용하였다. 개발된 상세 역학과정 검증 시스템은 동아시아 및 아열대 서태평양 지역에 대하여 1) 감시인자와 세계의 주요 대기변수(i.e., 상/하층 지위고도, 중층 수직운동)의 격자별 과거 상관관계(1981-2010)를 계산한 후 2) 예측 월의 주요 대기변수 편차장과의 유사성을 패턴 상관관계로 계산하여 감시인자가 대기에 미치는 영향이 해당 월에 구현되고 있는지를 파악하는 시스템이다. 이 시스템을 2020년 여름철에 적용한 결과, 상세 기작이 유사하게 나타난 인자는 4월 동인도양 해수면온도 인자로서 7월 평균 이하의 기온 및 폭염일수를 전망하였고, 2월의 호주 북부 해수면온도 인자는 8월 평균 이상의 기온 및 폭염일수를 전망하였으며 관측결과와 일치하였다. 이러한 상세 역학과정 검증 시스템은 역학과정을 고려하지 않을 경우에 비해 감시인자의 예측성을 높이는 것으로 확인되어 향후 예측에 활용될 수 있을 것으로 보인다. 한편 기존의 감시 인자 뿐 아니라 1990년대 이후로 한반도 여름철 혹서와 관련성이 높은 봄철 Polar/Eurasia(POL) 원격상관 패턴이 한반도 7-8월 폭염에 미치는 역학을 분석하여 새로운 예측인자로 제시하였다; 2-4월 평균 POL 지수가 높을 때, 봄철에 대류가 억제된 필리핀해의 SST를 증가시킨 후 여름철에 활발한 대류를 유도하여 동아시아에 하강기류 및 고기압을 발달시켜 한반도에 고온과 폭염을 유발하는 것으로 분석되었다.

대기와 해양에서의 감시 인자 확대 뿐만 아니라 지면조건을 한반도 폭염에 대한 새로운 감시인자로 활용 가능성에 대해 검토하였다. 먼저, 한반도의 45개 표준관측지점 자료로부터 1979년부터 2019년까지 기간에 대해 지역폭염 발생일을 산정하였다. 이렇게 산정한 지역폭염일

에 해당하는 각 날짜의 ERA-5 T2m 자료(20-50° N과 110-150° E)에 대해 자기조직화지도(Self-organizing Map) 기법으로부터 3개 군집으로 분류하였다. 3개 군집 중 1번 노드는 대기순환의 합성장으로부터 P-J 패턴과 유사한 형태가 나타났으며, 3번 노드는 대륙으로부터 파동 전파 형태와 유사하게 나타났다. 3번 노드의 선행시간에 대한 토양수분 합성장으로부터, 폭염 발생 30일과 60일 전 유라시아(40-60° N과 0-30° E) 지역 토양 수분 부족(유의확률 90%에서 유의)이 나타났다. 이러한 현상은 올해 6월 폭염에 대해서도 선행시간 30일과 60일에 동일한 지역에 비슷한 패턴이 나타났다. 이 연구의 결과로부터 4월과 5월의 해당지역(40-60° N과 0-30° E) 토양수분 부족을 감시인자 활용 가능성이 있을 것으로 판단되나 후속연구가 필요하다.

위에서 언급한 감시 인자들과 관련된 주요 기작들을 기반으로 하여 2020년 여름철 한반도 기후 변동의 원인이 분석되었다. 2019/20 엘니뇨 발달 이후 2020년 봄철에 쇠퇴하는 동안 대기 bridge 기작에 의해서 북인도양의 해수면 온도가 상승하였으며, 이것이 강제력이 되어 북서태평양 고기압 편차가 발달하였다. 북서태평양 고기압 편차는 한반도에 고온 다습한 공기를 유입하여 6월과 8월 동안 한반도 기온 상승을 7월에는 한반도 북동쪽에서 발달한 고기압성 순환 편차에 의하여 유입된 찬공기와 만나 한반도에 이상 강수를 유발 하였다. 한반도 북동쪽에서 발달한 고기압성 순환 편차는 여름철 음의 NAO (North Atlantic Oscillation) 관련 원격상관과 관련이 있는 것으로 분석 되었는데, 여름철 NAO 발생은 엘니뇨 발달 이후 대기 bridge 기작에 의한 봄철 북 열대 대서양 해수면 온도 상승과 관련이 있었다. 더욱이 이와 같은 격년 변동 시간 규모에서 태평양-인도양-대서양 결합 관계가 더 시간 주기를 가진 AMO (Atlantic Multidecadal Oscillation) 같은 기후 모드가 조절 할 수 있다는 것이 발견되었다. 이는 상대적으로 짧은 격년 변동의 시간 규모를 가진 기후 인자와 여름철 한반도 기후와의 관계가 장 주기 기후 모드의 위상에 따라 달라 질 수 있다는 것을 시사한다. 그러므로 장주기 기후 전망에서 예측 기후 인자들의 최선의 활용을 위해서 장주기 기후 모드의 위상을 고려하는 격년 변동 모드와 한반도 기후 관계에 대한 포괄적인 분석이 필요하다.

그리고 본 연구에서 이상기후 예측 정보 개선 및 확대를 위해서 두 개의 통계적 기반 모델들을 구축하였다. 첫 번째로 자료기반 폭염위험 평가를 위해 본 연구에서는 간단한 상관분석을 통한 유사해 추출 방법을 제시하였다. 선행 4개월동안의 지위고도장과 예측월의 폭염지속시간 사이의 상관분석을 통해 한국 폭염일수와 유의한 상관을 갖는 모든 지역을 찾았고 그 지역의 지위고도 차이를 위해 예측해와 유사한 6개의 과거 해를 찾을 수 있는 방법을 제시하였다. 1981년-2019까지 기간 재분석자료와 기온관측자료를 이용해 이 방법을 교차검증하였고 현업에 사용할 수 있을 정도의 예측력을 확인하였다. 또한 유사해 기온관측자료를 Markov chain 무작위 발생기법의 입력하여 한국 기상관측 주요지점에 대해 폭염위험의 시공간적 변동성을 가시화 하였다.

두번째로 이상기후 3개월 장기예보 콘텐츠를 개발하고 이를 효과적으로 나타낼 수 있는 방식을 제시하고자 비모수 베이지안 모델인 가우시안 프로세스의 기계학습을 이용하여 전국 및 지역별 혹서기 이상기후지수 3개월 확률전망정보를 생산하였다. 이를 위해 장기예보 가이던스의 예측인자와 선행감시시점을 이용한 모델, 장기예보 가이던스의 예측인자와 선행감시시점을 이상기후지수와의 상관관계를 이용하여 선정한 모델, 군집분석을 통해 도출한 예측인자들

이용한 모델, 군집분석 도출 예측인자의 주성분을 이용한 모델을 각각 구축하여 확률전망정보를 생산하였다. 또한 베이지안 모델 평균 기법을 이용하여 다양한 전망정보를 통합하였고 특히 군집분석을 통한 모델들과 결합 모델의 이상기후지수 예측 성능이 우수함을 확인하였다. 이상기후 전망정보 표현방식으로 Jupp et al. (2012)의 방법을 적용하여 삼분위 다이어그램과 Hue-Saturation-Value (HSV) 색상 모델을 이용하여 삼분위 확률예측정보를 지역별로 시작적으로 전달하였다.

또한 이상기후 전망 정보 개선/확대를 위해서 통계 기반 모델들을 구축한 것 뿐만 아니라 기존 기상청 현업모델의 예측 결과들을 이상기후 전망에서 활용하기 위해서 개선 방안을 제시 하였다. 먼저 우리나라를 9개 권역별(경기(GG), 경남(GN), 경북(GB), 영동(YD), 영서(YS), 전남(JN), 전북(JB), 충남(CN), 충북(CB))로 나누어, 우리나라의 여름철 극한기온 확률예측성을 평가하였다. 기상청 현업 모델인 GloSea5에 대해 AUC (Area Under the Curve)를 기준으로 극한기후 예측성을 평가하였으며, ECMWF의 극한기후 예측성과 비교하였다. 두 모델의 9개 권역별 및 우리나라 전체에 대한 AUC는 서로 비슷한 수준으로 나타났다. 두 모델의 극한기후최적 기준값은 AUC를 기반으로 Tavg 경우, 상·하위 15%가 적절하였으며, 3분위 전망의 예측성과 유사한 수준에서 5분위 예보가 가능할 것으로 나타났다. 이와 유사한 방법으로 Tmax와 Tmin의 경우, 기준값을 중앙값으로 하는 2분위 예보가 적절한 것으로 나타났다. 2020년 6월, 7월, 8월 예보에 위의 새로운 기준값을 적용하여 예보를 한 결과, 6월은 Tavg, Tmax, Tmin 모두 관측치와 유사하게 전망하였으나, 7월의 경우, 관측보다 GloSea5가 높게 전망하였다. 이 연구의 결과로부터 GloSea5의 예측성 향상을 위한 추가 연구가 필요할 것으로 판단하였다.

그리고 기상청 현업모델 편차보정을 통하여 최고·최저기온 1개월 확률예보 방안을 제시하였다. 기상청 현업모델에는 예측 아노말리와 예측값 자체의 계통적 오차 특징이 다르게 나타난다. 이는 우리가 아노말리 값으로 예측을 하는 경우, 틀린 예측정보를 생산하는 요인이 될 수 있다. 따라서 이 연구에서는 기상청 현업모델의 일정한 편차(bias)의 보정을 통해 예보하는 방안을 마련하고자 하였다. 이 연구에서는 기후예측모델의 편의값과 편의기후값 사이의 통계산출식 개발을 통해 편차를 보정할 수 있는 방안을 개발하고, 실제예측자료를 활용하여 예측성을 검증하였다. 실제 본 연구에서 제시한 편차보정방법을 활용했을 때, 평균적으로 편차(bias)와 제곱근오차(rmse)가 감소하였는데, 특히 최고기온에서 보정효과가 가장 크게 나타났다. 또한 적중률(accuracy)에 대해 검증한 결과에서도, 최고기온(7.7%↑)과 평균기온(1.1%↑)은 개선되었다. 하지만, 최저기온(18.5%↑)의 경우 적중률이 하락하여 이에 대한 추가 연구가 필요하다.

목차

평문 초록	i
Executive Summary	ii
국문 요약	vi
목차	ix
표 차례	xiv
그림 차례	xvi
1. 서론	1
2. 방법 및 자료	5
가. 이상기후 감시 및 분석 콘텐츠	5
(1) 이상기후 감시 정보 콘텐츠 확대 및 가시화 개선	5
(가) 이상기후 감시 정보 콘텐츠 확대	5
① 월별 감시 정보의 부가 정보 추가 생산	5
(나) 이상기후 감시 정보 콘텐츠 통합	6
① 월별 및 주별 감시 정보의 통합	6
② 개별 감시 정보를 통합하여 통합맵 생산	9
(다) 이상기후 감시 정보 콘텐츠 가시화 기법 개선	13
① 이상기후 감시 정보 콘텐츠 가시화 기법 개선	13
(라) 기후소통 TF를 통한 전지구 이상기후 모니터링	15
① 전지구 이상기후 관련 일일 모니터링	15
(2) 이상기후 원인 분석 방법 개선	15
(가) 관측 자료	15
(나) 주성분 분석을 활용한 원인 분석 방법 개선	15
(3) 자기조직화지도(Self-organizing Map) 기법활용 혹서기 이상기후 분석체계 구축	15
(가) 자료수집 및 구축	15

(나) 지역폭염(Regional Heatwave)	16
(다) 지면조건의 한반도 폭염에 대한 예측인자 활용성 평가	18
① 자기조직화지도(Self-organizing Map) 기법 활용 한반도 폭염 패턴분류	18
② SOM 패턴별 대기순환장 및 토양수분과 지연 및 동시상관성 분석	19
나. 이상기후 장기 전망 콘텐츠	19
(1) 유사성 기반 추계학적 폭염예측	19
(가) 상관분석을 이용한 유사해 추출	21
(나) Markov-chain weather bootstrapper	24
(2) 기계학습모델을 이용한 혹서기 이상기후 3개월 확률전망정보 생산	27
(가) 혹서기 이상기후 발생과 주요 기후인자의 통계적 상관성	27
① 전국 및 지역별 혹서기 이상기후지수 통계 분석	28
② 혹서기 이상기후 발생과 주요 기후인자의 상관성 분석	29
③ 혹서기 이상기후 발생과 지역별 기후 및 공간정보의 상관성 분석	31
(나) 가우시안 프로세스를 이용한 전국 및 지역별 혹서기 이상기후지수 3개월 전망정보 생산	32
① 확률전망정보 생산을 위한 관측기반 기후인자 입력자료 구축	32
② 기계학습모델 검토 및 선정	33
③ 전국 및 지역별 혹서기 이상기후지수 3개월 확률전망정보 생산	35
(다) 혹서기 이상기후지수 3개월 확률전망정보 표현방식 개발	37
① BMA (Bayesian Model Averaging)을 이용한 전망정보 결합	38
② 삼분위 다이어그램을 이용한 이상기후 확률전망정보 표현	38
(3) 3개월 기온 장기예보 개선안	40
(가) 자료수집	40
(나) 극한기후 확률예측추정기법	40
(4) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안 제시	43
(가) 국내외 유관기관 계절내 장기예보 현황	43
① 미국 NOAA-NCEP CPC(Climatic Prediction Center)	43
② 호주 기상청(Bureau of Meteorology, BoM)	45
③ 일본 도쿄 기후센터(Tocky climate Center, TCC) 및 일본 기상청(Japan Meteorological	

Agency, JMA)	46
④ 영국 기상청(U.K. Met Office)	48
(나) 기상청 현업모델(GloSea5) 운영 현황 및 편차보정 방법	49
① 현업 운영 현황	49
② 통계적 훈련자료 및 관측자료	50
③ 편차정의 및 편차보정 방법	50
④ 기상청 현업모델 편차분석	51
3. 결과	54
가. 이상기후 감시 및 분석 콘텐츠	54
(1) 이상기후 감시 정보 콘텐츠 확대 및 가시화 개선	54
(가) 이상기후 감시 정보 콘텐츠 확대 생산	54
① 월별 한반도 감시 정보 부가 정보 추가 생산 및 가시화	54
(나) 이상기후 감시 정보 콘텐츠 통합맵 생산	56
① 최대 강우 사상과 재현기간의 통합맵 생산 및 가시화	56
② 가뭄 지수 통합맵 생산 및 가시화	58
③ 동아시아 통합맵 생산 및 가시화	59
(다) 월별 이상기후 감시 정보 표출 자동화 구축 및 개선	59
① 월별 이상기후 감시 정보 생산 자동화 구축 및 개선	60
② 월별 이상기후 감시 정보 표출 자동화 구축 및 개선	60
(라) 이상기후 감시 정보 해석 가이드 생산 및 제공	60
① 이상기후 감시 정보 해석가이드 생산 및 제공	60
(마) 기후소통 TF를 통한 전지구 이상기후 모니터링 자료 제공	61
① 전지구 이상기후 일일 모니터링 자료 수집 및 제공	61
(2) 혹서 감시인자 정보 개선 및 확대	61
(가) 2020년 감시인자 현황	62
① 감시인자 개별 통계 분석	62
② 감시정보의 통합	66
(나) 감시인자 상세 역학 과정 검증 시스템 개발 및 활용	68
① 상세 역학 과정 검증 시스템 개발	68

② 상세 역학 과정 검증 시스템 적용	74
③ 상세 역학 과정 검증 시스템의 활용 방안 제안	75
(다) 새로운 감시인자 발굴	78
① Polar/Eurasia 원격 상관 패턴	78
(3) 자기조직화지도(Self-organizing Map) 기법 활용 흑서기 이상기후 분석체계 구축	86
(가) 지역폭염(Regional Heatwave) 특성	86
(나) 지면조건의 한반도 폭염에 대한 예측인자 활용성 평가	87
① 자기조직화지도(Self-organizing Map, SOM) 기법 활용 한반도 폭염 패턴분류	87
② SOM 패턴별 대기순환장 및 토양수분과 지연 및 동시상관성 분석	94
(4) 2020년 흑서기 원인 분석서	96
(가) 2020년 흑서기 이상 기후 현황	96
① 6월	97
② 7월	104
② 8월	110
(나) 2020년 흑서기 이상 기후 발생 원인 분석	114
① 열대 태평양과 인도양의 상호 작용	117
② 열대 태평양 대서양의 상호 작용	120
③ 대서양 장주기 변동의 조절	124
나. 이상기후 장기 전망 콘텐츠	132
(1) 유사성 기반 추계학적 폭염예측	132
(가) 상관분석을 이용한 유사해 추출	133
(나) Markov-chain 기반 폭염확률 예측	142
(2) 기계학습모델을 이용한 흑서기 이상기후 3개월 확률전망정보 생산	150
(가) 흑서기 이상기후 발생과 주요 기후인자의 통계적 상관성	151
① 전국 및 지역별 흑서기 이상기후지수 통계 분석	151
② 흑서기 이상기후 발생과 주요 기후인자의 상관성 분석	154
③ 흑서기 이상기후 발생과 지역별 기후 및 공간정보의 상관성 분석	159
(나) 가우시안 프로세스를 이용한 전국 및 지역별 흑서기 이상기후지수 3개월 전망정보 생산	160

① 전국 혹서기 이상기후지수 3개월 확률전망정보 생산	160
② 지역별 혹서기 이상기후지수 3개월 확률전망정보 생산	164
(다) 혹서기 이상기후지수 3개월 확률전망정보 표현방식 개발	171
① BMA (Bayesian Model Averaging)을 이용한 전망정보 결합	171
② 삼분위 다이어그램을 이용한 이상기후 확률전망정보 표현	174
(3) 3개월 기온 장기예보 개선안	176
(가) 극한기후 확률예측추정기법	176
(나) 극한기후 확률예측추정기법 적용 및 검증	178
(4) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안 제시	182
(가) 최고·최저기온 편차보정 결과 및 검증	182
① 앙상블 구성을 위한 민감도 비교 결과	182
② 정량적 검증: BIAS 및 RMSE 비교	184
③ 정량적 검증: Categorical 예측 정확도(Accuracy) 비교	189
④ 기후값 변경에 따른 편차보정 영향 분석 및 예측성 검증	192
⑤ 3분위 확률예보 검증	196
(나) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안	198
① 평균기온에 대한 1개월 장기예보 현업활용	198
② 우리나라 1개월 기온 장기예보 서비스 개선(안)	199
③ 최고·최저기온에 대한 2분위 확률예보 방안	200
4. 요약 및 결론	202
References	208
부록 A. 기후 이슈 선제 기후 자료 기상청 지원	215
부록 B. 운영매뉴얼: 동아시아 이상기후 감시 시스템 (개선)	234
부록 C. 2020 혹서기 이상기후 원인 분석서	243
부록 D. 2020 7월과 8월 특정년도 대비 확률예보	246

표 차례

Table	page
1. Meteorological and soil moisture datasets used in this study.	16
2. Station IDs in each division.	40
3. Anomalies of monthly (June~August) mean temperature (°C) and heat wave days in 2020.	68
4. Pattern correlation coefficient (PCC_HGT200) in June over East Asia between HGT200 anomalies in 2020 and the 39-year correlation coefficients (HGT200 in June and predictor).	75
5. Pattern correlation coefficient (PCC_HGT200) in July over East Asia between HGT200 anomalies in 2020 and the 39-year correlation coefficients (HGT200 in July and predictor).	75
6. Pattern correlation coefficient (PCC_HGT200) in August over East Asia between HGT200 anomalies in 2020 and the 39-year correlation coefficients (HGT200 in August and predictor).	75
7. Composite years of negative and positive POL_FMA years ($\pm 0.75 \sigma$) from 1991 to 2019.	83
8. Characteristics of the monthly regional heatwaves for the period of 1979-2019.	87
9. SOM patterns for the regional heatwaves for the period of 1979-2019.	88
10. Regional heatwaves in the year 2020.	94
11. Statistical features of monthly mean temperature (Tm), maximum temperature (Tx), minimum temperature (Tn), heat wave days, and tropical nights from June to August, 2020.	100
12. Lists of El Niño and La Niña events classified by Atlantic Multidecadal Oscillation (AMO) phases.	115
13. Correlation maps between August heat days with $T_{max} > T_{90}$ in Korea and 500hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April, (e) May, and (f) June for 1981-2019.	137
14. As in Table 13, but the heat-day record in the prediction year was not used for the correlation analyses by the LOOCV concept.	138
15. Sea Surface Temperature predictors of the long-range forecast guidance III (2018).	154

16. Snow cover predictors of the long-range forecast guidance III (2018).	155
17. Precipitation predictors of the long-range forecast guidance III (2018).	156
18. 850hPa Geopotential height predictors of the long-range forecast guidance III (2018). ...	157
19. 500hPa geopotential height predictors of the long-range forecast guidance III (2018). ...	158
20. Observed percentiles in each division.	181
21. The number of cases in each category of confusion matrix for maximum temperature.	189
22. The number of cases in each category of confusion matrix for minimum temperature. ..	189
23. The number of cases in each category of confusion matrix for mean temperature.	190
24. The number of cases in each category for maximum temperature.	193
25. The number of cases in each category for minimum temperature.	193
26. The number of cases in each category for mean temperature.	193

그림 차례

Figure	page
1. Monthly average of (a) daily maximum temperature, (b) daily minimum temperature and (c) monthly total precipitation over South Korea.	6
2. Schedules on the HPC and WEB before improvement extreme climate monitoring system.	7
3. Schedules on the HPC and WEB after improvement extreme climate monitoring system.	8
4. Average of (a) extreme hot days, (b) extreme cold days and (c) rainfall amount where RP(return period) is greater than 20 years during first, middle and last ten days of a month over East Asia and South Korea.	9
5. Monthly extreme climate monitoring map (a), (b) before and (c) after improvement visualization technique for (a) magnitude of the largest P event, (b) return period of the largest P event, (c) integrated map both magnitude and return period of the largest P event.	11
6. Monthly drought monitoring map (a), (b), (c) before and (d) after improvement visualization technique for (a) 1-month SPI, (b) 1-month SDEI, and (c) weekly SMI, and (d) integrated map of drought indices.	12
7. (a) Before and (d) after improvement visualization technique for (a) global and (b) East Asian extreme climate map.	13
8. Monthly extreme climate monitoring map (a), (b) before and (c), (d) after improvement visualization technique for (a), (c) daily maximum temperature above 90th percentile and (b), (d) daily minimum temperature below 10th percentile.	14
9. Conceptual diagram for regional heatwave in study area. (a) station location map and the first two steps for the regional heatwave identification (b) the last step for the regional heat wave identification.	17
10. Architecture of a self-organizing map network.	19
11. Two-step framework for heat wave forecasts	21
12. Evolution of the number of days with $T_{max} > T_{90}$ in South Korea from 1981 to 2019	22
13. Distribution of Pearson correlation coefficient (Pearson r) between June heat days in Korea and June geopotential height (GPH) anomalies for 1994–2015. The GPH data are from the NCEP Reanalysis I.	23
14. Transformation of T_{max} time series to the binary occurrence series of 1 for $T_{max} > T_{90}$	

and 0 for otherwise.	26
15. A probable change in P10 and P00 when assuming that hot years are selected for neighbor years.	27
16. Eight input variables are selected out of 17 using a dendrogram for August TXm (LT=3).	33
17. Optimizing Kernel parameters for June TMm (LT=1): the length parameter of 7.78, noise parameter of 0.17, and vertical variation parameter of 1.26 are selected here minimizing the negative Log Marginal Likelihood.	35
18. Probabilistic forecast results for June 2020 (LT=1).	36
19. Credible interval of TXge33 for August.	37
20. Analyzing correlations between predictors and climate extreme indices.	37
21. Determining HSV (Hue-Saturation-Value) color scheme' s Hue and Saturation (Jupp et al., 2012).	39
22. Visualization examples using the ternary diagram by Jupp et al.(2012).	39
23. Procedures of the determination of climate extreme thresholds.	42
24. Procedure of calculating probabilistic forecasts compared to temperature in a selected year.	43
25. One month(30-day average) outlook for temperature(left) and precipitation(right) from NOAA CPC.	44
26. Week 3-4 outlook for temperature(left) and precipitation(right) from NOAA CPC.	44
27. GFS-based MJO ensemble forecast provided by NOAA CPC.	45
28. Climate outlooks for maximum(left) and minimum(right) temperature likelihood of the upcoming weeks, months and seasons being warmer or cooler than usual.	46
29. One-month prediction maps over Tropics and Asia regions for the first week.	47
30. One-month and three-month forecast are issued at 14:30 JST every Thursday and at 14:00 JST around the 25th of each month respectively.	48
31. The two-week temperature forecast from JMA.	48
32. Probability of Months 2-4 tercile categories(left), outer quintile categories(middle), and above median (right) 2m temperature forecast.	49
33. Illustration for date-distance weighted average using GloSea5 subseasonal hindcast.	50
34. Diagram for bias and bias climatology definition.	51

35. Korea domain averaged RMSE and MABE from GloSea5 hindcast for the period of 1~60 forecast days.	52
36. Week 3-4 averaged bias in each month for maximum and minimum temperature (estimated from GloSea5 hindcasts); (left) maximum temperature, (right) minimum temperature.	53
37. Weekly forecast errors in GloSea5 hindcasts for each lead time; (a) maximum temperature, (b) minimum temperature, and (c) mean temperature.	53
38. Monthly extreme climate monitoring map after improvement visualization technique for daily maximum temperature above 90th percentile during 2020.	55
39. Monthly extreme climate monitoring map after improvement visualization technique for daily minimum temperature below 10th percentile during 2020.	56
40. Monthly extreme climate monitoring map after improvement visualization technique for return period of the largest P event and monthly total precipitation during 2020.	57
41. Monthly drought monitoring map after improvement visualization technique for 3 drought indices during 2020.	58
42. East Asia extreme climate monitoring map after improvement visualization technique during 2020.	59
43. Analysis guide for climate extreme maps.	61
44. APCC supports for providing climate information	61
45. 39-year (1981-2019) correlation map between HWD in July and SSTs in April, b) scatter plot of HWD in July (y-axis) and SST_IO (x-axis), c) SST anomalies in April, 2020, d) 21-year sliding correlations of HWD in July and SST_IO from 1973-1993 to 1999-2019, e) time series of the SST_IO value from April to July in 2020, and f) time series of HWD in Jul (bar with the right y-axis) and SST_IO (cross with solid line with the left y-axis).	63
46. a) 39-year (1981-2019) correlation map between HWD in July and SSTs in April, b) scatter plot of HWD in July (y-axis) and SST_WP (x-axis), c) SST anomalies in April, 2020, d) 21-year sliding correlations of HWD in July and SST_WP from 1973-1993 to 1999-2019, e) time series of the SST_WP value from April to July in 2020, and f) time series of HWD in Jul (bar with the right y-axis) and SST_WP (cross with solid line with the left y-axis).	64
47. ACC (solid line) and HSS (dashed line) of a) average temperature and b) HWD in July for moving 21-year periods from 1973-1993 to 1999-2019 using the SST_WP index.	65
48. ACC (solid line) and HSS (dashed line) of a) average temperature and b) HWD in July for moving 21-year periods from 1973-1993 to 1999-2019 using the SST_IO index.	66

49. Summary of heat wave predictor, its ACC and decadal change (% numbers in parentheses), its projection of HWD in 2020 (color of thermometer; AN for red and BN for blue).	67
50. Map version of the summary of heat wave predictors and their predictions in 2020.	68
51. 39-year (1981-2019) correlations of SST_IO with monthly SSTs in a) April, b) May, c) June, and d) July.	69
52. 39-year (1981-2019) correlations of SST_IO with monthly HGT200, HGT850, winds at 850 hPa, and OLR in a-c) April, d-f) May, g-i) June, and j-l) July.	70
53. Anomalies of HGT200, HGT850, and OMG500 in 2020 overlaid onto the 39-year (1981-2019) correlations of SST_IO with monthly HGT200, HGT850, and OMG500, respectively, in a-c) April, d-f) May, g-i) June, and j-l) July.	71
54. 39-year (1981-2019) correlations of SST_WP with monthly SSTs in a) April, b) May, c) June, and d) July.	72
55. 39-year (1981-2019) correlations of SST_WP with monthly HGT200, HGT850, winds at 850 hPa, and OLR in a-c) April, d-f) May, g-i) June, and j-l) July. Black solid lines indicate statistically significant correlations at the 95% level.	73
56. Anomalies of HGT200, HGT850, and OMG500 in 2020 (contours) overlaid onto the 39-year (1981-2019) correlations (dots) between SST_WP and monthly HGT200, HGT850, and OMG500, respectively, in a-c) April, d-f) May, g-i) June, and j-l) July.	74
57. ACC of SST_WP (orange bar) and SST_IO (blue bar) without considering PCC (ACC_noPCC; first column) and with considering PCC (ACC_PCC; from second to 6th column).	77
58. Total number of cases of SST_WP (orange bar) and SST_IO (blue bar) without considering PCC (N_total; first column) and with considering PCC (N_PCC_total; from second to 6th column).	77
59. Geopotential height (500 hPa) spatial pattern of Polar/Eurasia teleconnection pattern in January.	78
60. 29-year (1991-2019) correlations between 3-month running averages of POL from October-December to June-August and July-August average temperature (Ts_JA, red line) and b) HWD (HWD_JA, black line) in South Korea.	79
61. a) Time series of Ts_JA (black) and POL_FMA (red) and b) 21-year sliding correlations of POL_FMA with Ts_JA (red) and with HWD_JA (orange).	80
62. 39-year (1981-2019) correlations of POL_FMA with HGT200, HGT850, SST with winds at 850 hPa, and OMG500 in a-d) February-April, e-h) April-June, and i-l) July-August.	81

63. North-South cross section of 39-year (1981-2019) regressed winds (arrows) and vertical motions (contours) onto POL_FMA in a) February-April, b) March-May, and c) June-August at 130E.	82
64. Standardized values of the key variables (3-month running averages from January-March to June-August) in the a) negative and b) positive POL_FMA composite years.	84
65. ACC of a) average temperature and b) HWD during July and August for moving 21-year periods from 1973-1993 to 1999-2019 using the POL_FMA index. Horizontal solid line indicates ACC for 47 years (1973-2019), which is also displayed by the number in the title.	85
66. Schematic diagram of the impacts of POL_FMA on July-August mean temperature in South Korea.	86
67. Trend of the regional heatwaves for the period of 1979-2019.	87
68. Monthly regional heatwaves classified into the SOM patterns for 1979-2019.	89
69. Durations of the regional heatwaves for 1979-2019. (a) three classifications and (b) two classifications.	89
70. Trends of occurrences of the monthly regional heatwaves (a) and SOM patterns (b) for the period of 1979-2019.	90
71. Trends of durations of the monthly regional heatwaves (a) and SOM patterns (b) for the period of 1979-2019.	91
72. Composite fields of 500-hPa GPH (shading) and 850-hPa wind vector (arrow) for Node 1 (a), Node 2 (b), and Node 3(c).	92
73. Composite fields of soil moisture for Node 1 (a), Node 2 (b), and Node 3(c).	93
74. Lagged composite fields of 500-hPa GPH (shading) and 850-hPa wind vector	95
75. Lagged composite fields of soil moisture for 1979-2019 (Node 3) (a)-(d) and for 2020 (June) (e)-(h). (a) and (e) 0-day lagged, (b) and (f) 15-day lagged, (c) and (g) 30-day lagged, and (a) and (e) 60-day lagged fields.	96
76. Spatial patterns of monthly-mean (Left) total precipitation and (Right) surface air temperature anomalies over the East Asian region from June to August, 2020.	97
77. (a) Monthly mean daily maximum temperature (Tx) anomaly, (b) Percentile of monthly mean Tx, and the number of days with (c) Tx and (d) minimum temperature (Tn) greater than 90 percentile value of Tx and Tn, respectively.	99
78. (left and middle panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of June 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during	

1981-2020.	100
79. Spatial pattern of correlation coefficients between JUN sea surface temperature and expansion coefficients from the first SVD mode based on the analysis of June 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020.	101
80. Spatial patterns of (upper panel) SST, and (lower) 500-hPa geopotential height (shades) and horizontal wind (vectors) anomalies in June, 2020.	102
81. Spatial patterns of 1000-hPa air temperature (shades) and wind (black vectors) anomalies in June, 2020 and their climatology (contours for air temperatures and gray-colored vectors for 1000-hPa winds).	103
82. Heat budget analysis at 1000 hPa in June, 2020	104
83. (a) Monthly mean daily minimum temperature (Tn) anomaly, (b) Percentile of monthly mean Tn, and the number of days with (c) monthly mean daily maximum temperature (Tx) and (d) Tn greater than 10 percentile value of Tx and Tn, respectively.	105
84. (left and middle panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of July 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely cold days over South Korea during 1981-2020.	106
85. Spatial patterns of 500-hPa geopotential height (shades) and horizontal wind (vectors) anomalies in July, 2020.	107
86. Spatial pattern of correlation coefficients between JUN sea surface temperature and expansion coefficients from the first SVD mode based on the analysis of July 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020.	107
87. Spatial patterns of SST anomalies in July, 2020.	108
88. Spatial patterns of July precipitation (shading) and normalized tropospheric (850-250 hPa mean) temperature (contours) anomalies in 2020.	109
89. (left panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of July 200-hPa geopotential height over the region of (30° -60° N, 30° -180° E) and total precipitation over East Asia (China, Korea and Japan) during 1981-2020.	109
90. (a) Monthly mean daily minimum temperature (Tn) anomaly, (b) Percentile of monthly mean Tn, and the number of days with (c) maximum temperature (Tx) and (d) Tn greater than 90 percentile value of Tx and Tn, respectively.	111

91. (left and middle panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of August 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020.	112
92. Spatial patterns of 500-hPa geopotential height (shades) and horizontal wind (vectors) anomalies in August, 2020.	113
93. Spatial pattern of correlation coefficients between August sea surface temperature and expansion coefficients from the second SVD mode based on the analysis of August 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020.	113
94. Spatial patterns of SST anomalies in August, 2020.	114
95. Longitude-time section for composite sea surface temperature anomalies along the equator (5° S-5° N) from (upper panel) El Niño and (lower) La Niña onset to their decays (from March in El Niño or La Niña developing years to August in their decaying years). ..	116
96. Schematic diagram describing how interactions of climate modes over the Pacific, Indian and Atlantic Oceans affect temperature and precipitation over South Korea during 2020 summer.	117
97. Time-latitude section for sea surface temperature (shading), latent heat flux (white-colored contours) and 1000-hPa wind (vectors) anomalies and the climatological zonal winds (black contours) zonally averaged in the tropical IO (40° -100° E) from January to August in 2020.	118
98. Time-latitude section of regression upon ND(0)J(1) Niño3.4 SST: SST (shaded; ° C) and surface wind velocity (vectors) zonally averaged in the tropical IO (40° -100° E).	119
99. June-July-August anomalies of (a) SST (shading), surface wind velocity (vectors), (b) precipitation (shading) and normalized tropospheric (850-250 hPa mean) temperature regressed against Niño 3.4 SST index in th preceding NDJ for 1978-2010.	120
100. Change in NAO index from January to July in 2020.	121
101. Spatial patterns of simultaneous correlation coefficients between NAO index and 500-hPa geopotential height in July	121
102. Longitude-time section for (upper panels) sea surface temperature (shading), latent heat flux (white-colored contours) and 1000-hPa wind (vectors) anomalies and the climatological zonal winds (black contours) and for 500-hPa pressure velocity (shading) and diabatic heating (contours) anomalies averaged meridionally in 10° -20° N from January to July in 2020.	123

103. Schematic diagram describing how interactions of climate modes over the Pacific, Indian and Atlantic Oceans affect temperature and precipitation over South Korea in July, 2020.	124
104. Time series of (upper panel) AMO, (middle) normalized north Atlantic SST, NAO, North Indian SST, tropical North Western Pacific SLP and Niño 3.4 SST indices, and (lower) expansion coefficients from the SVD analysis of July South Korean extremely cold days and east Asian total precipitation.	125
105. Scatter plots of MAM(1) North Indian SST index and D(0)JF(1) Niño 3.4 SST index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña.	126
106. Scatter plots of MAM(1) North Tropical Atlantic SST index and D(0)JF(1) Niño 3.4 SST index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña.	127
107. Scatter plots of MAM(1) Tropical North Western Pacific SLP index (TNW) and MAM(1) North Indian SST index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña.	128
108. Scatter plots of MAM(1) Tropical North Atlantic SST index (TAO) and JJ(1) NAO index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña.	129
109. The temporal evolution of the aggregated (left panels) monthly total precipitation and (right) surface air temperature anomalies after a peak season of El Niño events in a positive AMO phase	131
110. The temporal evolution of the aggregated (left panels) monthly total precipitation and (right) surface air temperature anomalies after a peak season of La Niña events in a negative AMO phase	132
111. Correlation maps between June heat days with $T_{max} > T_{90}$ in Korea and 500hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April for 1981-2019.	133
112. Correlation maps between July heat days with $T_{max} > T_{90}$ in Korea and 500hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April, and (e) May for 1981-2019.	135
113. Correlation maps between August heat days with $T_{max} > T_{90}$ in Korea and 500hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April, (e) May, and (f) June for 1981-2019.	136

114. (a, c, and e) Comparisons between observed mean Tmax and weighted averages of neighbor-year Tmax for June, July, and August, and (b, d, and f) between observed heat days and averages of neighbor-year heat days predicted in May, respectively.	140
115. Comparisons between observed mean Tmax and weighted averages of neighbor-year Tmax for July and August (a and c) and between observed heat days and averages of neighbor-year heat days (b and d) predicted in June, respectively.	141
116. Comparisons between (a) observed mean Tmax and weighted averages of neighbor-year Tmax and between (b) observed heat days and averages of neighbor-year heat days (b and d) for August predicted in July, respectively.	141
117. Interannual changes of (a) P01 and (b) P11 in Korea for 1974-2019.	142
118. (a) The range of Tmax for June predicted in May, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, the spatial distributions of (c) mean Tmax and (d) 100-year-return-period mean Tmax , respectively.	144
119. (a) The range of Tmax for July predicted in May, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, (c) histogram of consecutive days with Tmax>T90, (d) mean Tmax and (e) 100-year-return-period mean Tmax, respectively. ...	146
120. (a) The range of Tmax for August predicted in May, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, (c) histogram of consecutive days with Tmax>T90, (d) mean Tmax and (e) 100-year-return-period mean Tmax, respectively. ...	147
121. (a) The range of Tmax for July predicted in June, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, (c) histogram of consecutive days with Tmax>T90, (d) mean Tmax and (e) 100-year-return-period mean Tmax, respectively. ...	148
122. (a) The range of Tmax for August predicted in June, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, (c) histogram of consecutive days with Tmax>T90, (d) mean Tmax and (e) 100-year-return-period mean Tmax, respectively. ...	149
123. (a) The range of Tmax for August predicted in July, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, (c) histogram of consecutive days with Tmax>T90, (d) mean Tmax and (e) 100-year-return-period mean Tmax, respectively. ...	150
124. Box-plots for South Korea and subregions.	151
125. Time-series graphs for South Korea and subregions.	152
126. Histograms for South Korea and subregions.	153
127. QQ-plots for South Korea and subregions.	153
128. Correlation map between June TMm anomaly and January SST anomaly.	155
129. Correlation map between August TMm anomaly and April snow cover anomaly.	156

130. Correlation map between August TMm anomaly and February precipitation anomaly.	157
131. Correlation map between July TXm anomaly and 850hPa geopotential height anomaly.	158
132. Correlation map between July TNm anomaly and March 500hPa geopotential height anomaly.	159
133. Heidke Skill Score (HSS).	160
134. Total Accuracy.	161
135. Mean Square Skill Score (MSSS).	161
136. Area Under the ROC Curve.	162
137. Comparisons of cross year validation forecast results during 1980–2020.	163
138. Comparisons of probabilistic forecast outputs between GD (upper) and CL (lower) in 2020.	164
139. Heidke Skill Scores of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).	165
140. Mean Squared Skill Scores of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).	166
141. Area Under the ROC Curve of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).	167
142. Total Accuracy of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).	168
143. Correlation coefficients between expected values of probabilistic forecasts and observations of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).	169
144. Mean Absolute Error between expected values of probabilistic forecasts and observations of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).	170
145. Comparisons of cross year validation forecast results between BMA and various models during 1980–2020.	171
146. Heidke Skill Score (HSS).	172
147. Total Accuracy.	172
148. Mean Square Skill Score (MSSS).	173
149. Area Under the ROC Curve.	173
150. Examples where BMA outperforms various individual models.	174

151. Ternary probabilistic forecast maps (left) and observed temperature anomaly maps (right) for June, July, and August 2020.	175
152. Probabilistic forecast results for Daegu-Gyeongbuk (upper) and Busan-Gyeongnam (lower) for June TXM in 2020.	176
153. Climate extreme thresholds for GloSea5.	177
154. Climate extreme thresholds for ECMWF.	178
155. One month lead time forecast for June 2020. (a) Tavg, (b) Tmax, and (c) Tmin	179
156. One month lead time forecast for July 2020. (a) Tavg, (b) Tmax, and (c) Tmin.	179
157. One month lead time forecast for August 2020. (a) Tavg, (b) Tmax, and (c) Tmin.	179
158. Probabilistic forecasts for June 2020 compared to last year ((a), (d), and (g)), the year 2018 ((b), (e), and (h)) and the year 2016 ((c), (f), and (i)).	180
159. Validation of the probabilistic forecasts for June 2020 ((a)-(c)) and July 2020 ((d)-(f)). (a) and (d) for Tavg, (b) and (e) for Tmax, and (c) and (f) for Tmin.	182
160. GloSea5 hindcast bias for each lead time, which is with respect to width of time window: orange line for $\pm 15\text{day}(=30\text{day})$, blue line for -7day , and purple line for no window.	183
161. GloSea5 hindcast bias for week3, which is with respect to the number of training years. The years used are from the 2010 to the previous 5, 10, 15, 20, 26 years.	184
162. Scatterplot and box-plot for GloSea5 bias for lead-time week3, estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	185
163. GloSea5 bias for each lead-time(wk3~wk6), estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	186
164 Scatterplot and histogram for GloSea5 rmse for lead-time week3, estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	187
165 GloSea5 rmse for each lead-time(wk3~wk6), estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	188
166. Accuracy for confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	191
167. Accuracy for each category(AN: above normal, NN: near normal, BN: below normal) in confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	192
168. Normal range ratio(shading) and normal difference(solid line) for weekly (top) maximum, (middle) minimum, and (bottom) mean temperature (4-week running mean).	194

169. Accuracy for confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	195
170. Accuracy in each category for confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).	196
171. Week 3 tercile-based probabilistic forecast of (top) maximum, (middle) minimum, and (bottom) mean temperature, forecasted at Aug 3, 2020.	197
172. ROC curve and score for week3 tercile-based forecasts: (left) raw forecast and (right) bias-corrected forecast.	198
173. A document from KMA/CPD for operational use of APCC bias correction method for the purpose of 1-month forecast(공문서: 기후예측과-2746(2020. 11. 25.).	199
174. (top) Released from KMA at May 21, 2020 for 1-month forecast and (bottom) an example of tercile-based probabilistic forecast of maximum and minimum temperature. ·	200
175. An example of two-category forecasts of heatwave and tropical night from the GloSea5 bias-corrected maximum and minimum temperature.	201
176. An example of two-category forecasts of (left) maximum and (right) minimum temperature for each week(forecast date: Jul. 16, 2018).	202
D1. Density plots grouped by months using GloSea5 (2020 ver.)	246
D2. Probabilistic forecasts for July 2020 compared to last year ((a), (d), and (g)), the year 2018 ((b), (e), and (h)) and the year 2016 ((c), (f), and (i)).	247
D3. Probabilistic forecasts for August 2020 compared to last year ((a), (d), and (g)), the year 2018 ((b), (e), and (h)) and the year 2016 ((c), (f), and (i)).	248

1. 서론

APCC 기후분석과는 2018년 기상청의 제안으로 아태지역의 이상기후 감시 및 원인 분석 과제를 수행하고 있으며 이러한 이상기후 정보들을 기후 정보 사용자에게 효과적으로 전달하기 위해 노력하고 있다. 여러 가지 이상기후 변수들 중 지구 온난화와 기후 변동성에 의해 전 지구 평균 기온 최고치가 2010년 이후로 여러 차례 경신되고 있는 가운데 인류 건강 및 생태계 지속성에 가장 민감한 영향을 미치는 기상재해인 폭서기에 대한 사전대응이 더욱 중요해지고 있다 (Vanos et al., 2015; Lissner et al., 2012; McMichael et al., 2006; Semenze et al., 1996). 특히 세계 기상 기구(WMO)에 따르면 최근 5년은 역사상 가장 더웠던 기간이었으며, 특히 2018년에는 한반도 전국 평균 폭서기 일수가 역대 1위를 기록하며 수많은 인명 피해 및 사회적, 경제적 피해가 속출 하였으며, 2019년 여름 유럽에는 전례 없던 기록적인 폭서기로 인해 수많은 사망자가 발생하였다. 이러한 과학적, 사회-경제적 중요성 때문에 2018년 하반기 APCC/기상청/기상과학원 간 실무 협력 회의에서 폭서기 장기 전망 서비스에 대한 APCC의 기여를 요청하였다.

장기적이고 넓은 범위에 걸쳐 일어나는 폭서기의 피해는 자연 재해에 준하는 수준이며 의료 서비스망 등 사회인프라의 사전준비 없이 대응하기 어렵기 때문에 1개월 이상의 장기 전망이 필수적이다. 높은 사회경제적 필요성에도 불구하고 여전히 이상기후 장기 전망 정보의 예측성 한계와 더불어, 현재 장기에보는 주/월별 평균 기온 전망만 전달하고 있어서, 이상기후(폭서기) 대응 활용에는 한계가 있으며, 더욱이 1-3개월 이상기후 전망 서비스 콘텐츠가 부족한 상황이다. 이상기후 감시/분석/전망 기술의 향상과 더불어 세계적으로 관심이 증대되고 있는 정보 서비스 측면에서 이러한 정보들의 통합 및 전달 방법에 대한 연구 역시 필요하다. 즉 기후정보 제공자의 입장이 아닌, 사용자를 고려한 기후정보를 발굴함과 동시에 사용자의 편의 및 이해를 증대시킬 수 있는 효과적인 전달 체계에 대한 연구가 필요하다.

그러므로 본 연구과제의 목적은 이상기후 장기 전망 정보 개선을 위한 폭서기 감시 정보 생산 및 시의 적절한 원인 분석 정보 제공, 1-3개월 장기 예측 콘텐츠를 개발 하는데 있으며 세부 목적은 다음과 같다.

1) 이상기후 감시 정보 콘텐츠 확대 및 개선

APEC 기후센터에서는 동아시아 지역에 대한 준 실시간 이상기후 감시 정보 웹 서비스 자동화 시스템을 구축한 바 있다. 하지만 이상기후 감시 스케일과 감시 정보가 너무 다양하고, 여러 감시 지수를 함께 고려하여 해석하는 데에는 큰 어려움이 있었다. 이러한 이상기후 감시 정보를 더욱 더 잘 활용하기 위해서는 가시성 좋은 이상기후 감시 정보가 필요하며, 각 감시 정보의 공간 분포뿐만 아니라 다양한 정보를 함께 줌으로써 더욱 이상기후에 대한 이해도를 높일 필요가 있다. 또한 같은 카테고리에 대한 지수들은 중복적인 정보로 느껴지므로, 이를 각 카테고리별로 통합하여 제공할 필요가 있다. 더불어, 더욱 쉽게 이상기후 감시 정보를 해석 할 수 있도록 각 감시 정보에 대한 자세한 설명도 함께 제공하여야 한다.

2) 혹서 감시인자 정보 개선 및 확대

기존의 연구에서 다양한 혹서 감시 인자가 제시된 반면 과거에 예측성이 높았던 감시 인자가 급변하는 기후변동으로 인하여 최근 들어 예측성이 감소하는 경우가 있을 수 있으므로 예측성의 변동성을 살펴봄과 함께 최근 기후격변기 이후 중요도가 높아진 새로운 감시 인자의 발굴 또한 필요하다. 본 연구에서는 예측성 변동성을 포함한 기존의 혹서기 기온에 대한 감시 인자의 특성을 분석하였다. 또한 1990년대 이후로 한반도 여름철 온도와 관련성이 높은 이른 봄철 Polar/Eurasia 원격상관 패턴이 여름철 한반도 폭염에 미치는 역할을 분석하여 새로운 예측인자로 제시하였다. 한편 다양한 혹서 감시 인자의 선정과 감시가 실질적으로 예측성 향상에 기여하기 위해서는 감시 인자와 한반도 혹서와의 연관성 및 감시 인자가 한반도 혹서에 영향을 미치는 상세적인 기작에 대한 이해뿐 아니라 그 상세 기작이 예측 시점에 잘 작동하고 있는지에 대한 모니터링이 필요하다. 즉, 단순히 감시 인자의 편차에 따른 예측 월의 온도 또는 혹서일수의 편차(평균 이상 또는 평균 이하)를 전망하는 것이 아니라 감시 인자가 대기와 해양에 미치는 영향을 함께 모니터링 할 경우 감시 인자 모니터링을 통한 예측성이 증가할 수 있다. 본 연구에서는 감시 인자 상세 역학과정 검증 시스템을 개발하여 해당 해에 잘 구현된 또는 구현되지 못한 감시 인자를 구별하는 시스템을 개발하였다. 또한 이 시스템을 2020년 7월의 경우에 적용하였으며 향후 예측에 활용하는 방안도 제시하였다.

3) 자기조직화지도(Self-organizing Map) 기법 활용 혹서기 이상기후 분석체계 구축

부족한 토양수분에 의해 증발산에 사용되지 못한 잉여 에너지가 발생하고, 이로 인해 공기를 더 데우게 되어, 폭염이 일어날 위험이 커질 수 있게 된다. 광역규모 대기순환이나 해수면온도(SST)는 폭염에 큰 영향을 주는 것으로 알려져 있으나, 토양수분과 같은 지면조건은 폭염을 지속시키는데 중요한 역할을 한다(Fisher et al., 2007; Lee et al., 2016; Zampieri et al., 2009). 폭염의 특성 분석을 위해 군집분류기법이 널리 이용되어 왔다(Yoon et al., 2018; Yoon et al., 2020). Yoon et al. (2020)은 KNN 군집분류기법을 이용하여 한반도 폭염특성을 분석한 바 있다. 백승윤 등(2018)은 자기조직화지도(Self-organizing map, SOM) 기법을 활용하여 서울에 발생한 폭염의 사례 분석을 실시하였으며, 임원일과 서경환(2018)은 한반도의 여름철 극한기온의 특성을 분석하는 연구에 자기조직화지도 기법을 사용한 바 있다. 따라서 이 연구의 목적은 자기조직화지도 기법을 활용하여 한반도에 발생하는 폭염 특성을 분석하고 지면조건과의 상관성을 조사하는 데 있다.

4) 2020년 혹서기 원인 분석서 작성

지구 온난화 아래 기록적인 이상 기후가 빈번히 발생하고 있으며, 대중들은 이상 기후 발생 원인에 대한 정보도 관심이 높아졌다. 그러므로 시의적절한 원인 분석이 수행 되어야 하고, 대중들이 이해가 쉬운 언어로 정보가 제공 되어야 한다. 본 연구에서 시의 적절한 이상 기후 원인 분석을 위한 통계적 분석 방법을 제안하였으며, 혹서기 이상 기후 전문적인 용어가 배제된 채 가능한 쉬운 언어 및 관련된 역학에 대한 이해를 돕기 위해 모식도를 활용하여 2020년 한반도 혹서기 원인 분석서 제공 방안을 제시하고자 한다. 아울러 2020년 여름철 7월 이상 저온/강수 발생에 대한 원인 분석에서 격년 변동 모드의 한반도 기후 영향이 장 주기 기후 변동 모드가 조절 할 수 있다는 결과를 제시하여, decade 별로 한반도 기후 예측 인자의 활용 방안

을 제안하고자 한다.

4) 유사성 기반 혹서기 이상기후 3개월 확률 예측 정보 생산

기존의 한국 폭염예측을 위한 통계 모형은 일최고기온의 발생에 간단히 독립성을 가정하고 극치이론을 적용하는 경우가 많지만 (e.g., 이강진과 권민호, 2019), 대기의 시공간적 변화는 큰 자기상관성을 보이기 때문에 독립성 가정은 폭염의 지속성에 평가를 할 수 없는 단점이 있다 (White and Tawn, 2016). 특히 수문분야에서는 강우의 시간적 지속성을 보존하는 추계학 모형이 오래전부터 개발되어 왔는데 (e.g., Kaz, 1977; Foufoula-Georgiou and Gergakakos, 1991; Woolhiser, 1992; Lettenmaier, 1995; Katz and Parlange, 1995; Wilks and Wilby, 1999), 이는 강수 현상의 시간의존성이 작지 않기 때문에 일강수의 지속을 통계모형에 고려해야함을 의미한다. 이와 마찬가지로 지속되는 하강기류 현상과 함께 나타나는 폭염도 상당히 지속할 수 있기 때문에 기온자료의 자기상관성을 고려할 수 있는 통계모형은 사실 필수적이다 (White and Tawn, 2017). 본 연구의 추계학적 폭염예측 모형은 선행대기운동과 예측월의 폭염일수와의 상관성을 기반으로 한 유사해를 먼저 선정하고 유사해의 관측기록을 간단한 Markov chain 모형에 적용해 폭염위험을 시공간적으로 예측한다.

3) 기계학습모형을 이용한 혹서기 이상기후 3개월 확률 예측 정보 생산

이상기후의 빈번한 발생과 그 빈도의 증가에도 불구하고 현재의 장기에보는 주별, 월별 평균 기온 전망만을 제공하고 있어 1개월/3개월 이상기후 전망에 관한 정보 전달은 매우 미흡한 상황이다. 또한 장기 전망 정보를 통합하고 전달하는 방안에 대한 다양한 연구가 아직 이루어지지 못하였다. 본 연구에서는 이상기후 3개월 장기에보 콘텐츠를 개발하고 이를 효과적으로 나타낼 수 있는 표현방식을 제시하고자 한다. 이를 위해 베이지안 추론 기반 모델인 가우시안 프로세스의 기계학습을 통해 이상기후지수의 확률예측정보를 전국 뿐 아니라 북한을 제외한 10개 지역에 대해 생산하고, 베이지안 모델 평균 기법을 통해 여러 전망정보를 통합하며, 삼분 위 다이어그램을 이용하여 확률전망정보를 시각적으로 전달하는 표현방안을 제시할 것이다.

4) 기상청 현업 모델 활용 3개월 이상 기온 장기에보 개선안 제시

최근 폭염과 같은 기온과 관련한 이상기후 현상이 자주 발생하는 등 북반구 여름철 극한 기온의 분포에 대한 관심이 커지고 있다. Barnston and Mason (2011)은 International Research Institute for Climate and Society (IRI)의 실시간 계절 확률예측에 강수와 기온에 대해 상·하위 15퍼센타일을 극한값의 기준으로 하는 극한기온과 극한강수 확률예보의 예측성을 평가한 바 있다. Barnston and Mason (2011)은 해당 연구에서 기온이 강수보다 예측성이 높다고 보고하였다. Becker et al. (2013)은 계절예측 시간 규모에서 극한 기온과 극한 강수의 현재 예측성과 잠재 예측력을 평가한 바 있다. 이 연구에서는 극한기온을 반영하는 장기에보전망정보 개선에 대한 기상청 수요를 반영하고, 이상기후와 관련하여 극한기온 확률예보 추정기법을 개발하고 그 예측성을 평가하여 3개월 기온 장기에보의 개선안을 마련하고자 한다.

5) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안 제시

지난 몇 년간의 장기에보를 위한 기후예측모델의 예측자료는 warm 아노말리가 지속적으로

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

2. 방법 및 자료

가. 이상기후 감시 및 분석 콘텐츠

(1) 이상기후 감시 정보 콘텐츠 확대 및 가시화 개선

(가) 이상기후 감시 정보 콘텐츠 확대

① 월별 감시 정보의 부가 정보 추가 생산

NCEP/NCAR의 전지구 재분석자료 중 일 최고 및 최저 기온자료와 CPC의 전지구 일 강수 자료 등을 이용하여 과거 기간(1981-2010년)에 대한 월별 90백분위 값과 10백분위 값을 계산하였고, 이를 이상기후 감시 기준으로 선정하여 매월/매주 발생하는 이상기후 발생일 수(days)와 강도 지수를 생산하였다. 기온 자료의 공간 해상도는 T62 가우시안 그리드로 경도 192개 × 위도 92개의 그리드를 가지고 있다. 그리고 CPC 일 강수자료의 공간 해상도는 0.5도 × 0.5도로 기온보다 더욱 고해상도이고, 해양과 극지역 마스크가 되어있는 육지 자료다. 이상기후 감시 정보 기준 선정을 위한 백분위값 계산을 위해 윤년(2월 29일)자료는 모두 제외되었다.

2019년부터 APEC 기후센터에서는 이상기후 감시 정보 계산을 통해 준 실시간 이상기후 감시 정보를 주기적으로 생산하고, 전지구 및 동아시아 지역에 대해 표출하는 서비스 체계를 구축하여 이상기후 감시 정보 웹 서비스를 실시하고 있다. 웹 사이트를 통해 표출되는 감시 정보는 월별 6개, 주별 4개 총 10개다. 총 10개의 지수는 모두 동아시아 지역에 대한 각 지수의 월별/주별 감시 정보의 공간 분포로 표출하여 제공하고 있으며, 이러한 공간 분포도를 통해 각 감시 기간 동안 어느 지역에서 이상기후가 빈번하게 나타났는지 각 지수별로 비교하여 확인할 수 있다. 하지만, 각 월에 대한 이상기후 감시 정보는 현재의 상황만을 반영하여 표출하고 있어 과거 값과의 비교가 힘들 뿐만 아니라, 월별 및 주별 총 10개의 감시 정보를 전체적으로 함께 이해하는 데에 큰 어려움이 있었다.

웹 서비스 중이던 이상기후 감시 정보에 부가 정보를 추가적으로 생산하여 더욱 이상기후 감시 정보에 대한 이해도를 높이고자 했다. 월별 이상기후 감시 정보와 함께 제공되는 부가 정보로 한반도 지역에 대한 과거 기간 대비 현재의 순위를 추가 생산하였다. 2019년에 개발한 감시 정보 웹서비스 시스템에서는 현재 감시 기간에 대한 이상기후 극한 기준에 따라 선정된 감시 정보만 표출하기 때문에, 평균적으로 과거 자료 대비 현재가 어느 정도 수준인 지 파악하기가 어렵다. 이에 대한 부가 정보를 함께 제공하기 위해 과거기간을 포함한 순위 정보를 추가적으로 생산하여, 과거 자료 대비 현재 감시 중인 감시 정보의 월 대푯값이 어느 정도에 위치해 있는지 한 눈에 함께 파악함으로써 이상기후 감시 정보에 대한 이해도를 더욱 높일 수 있다. 월별 감시 정보의 순위 정보는 일 최고기온의 월 평균, 일 최저기온의 월 평균, 월 누적 강수량으로 각 변수의 과거기간 자료(1981년~2019년) 값(회색) 대비 현재 자료(2020년) 값을 컬러(최고 기온은 빨간색, 최저 기온은 파란색, 강수는 초록색)로 표현하였다. 월별 감시 정보의 순위 정보는 일 최고기온의 월 평균, 일 최저기온의 월 평균, 월 누적 강수량 각 변수의 과거기간 자료(1981년~2019년) 값(회색) 대비 현재 자료(2020년) 값을 컬러로 표현하였다(Figure 1). 이

상기후 감시 기준을 선정을 위해 백분위값 계산에 이용한 base period는 1981-2010년이지만, 부가 정보로 함께 제공하는 월평균/월누적 값의 순위 정보에는 1981-2020년 자료가 이용 되었다.




Figure 1. Monthly average of (a) daily maximum temperature, (b) daily minimum temperature and (c) monthly total precipitation over South Korea. (grey: 1981-2019, color: present(2020))

(나) 이상기후 감시 정보 콘텐츠 통합

① 월별 및 주별 감시 정보의 통합

2019년 과제에서 구축한 이상기후 감시 정보 표출 자동화 시스템에서 HPC와 Web에서 주기적으로 실행되는 스케줄은 Figure 2와 같이 주별/월별 자료를 각각 생산하고 서비스를 실시함으로써 평균적으로 월 1회와 주 4회 자동 실행되도록 구축하였다.

월별 자료는 매월 1일부터 말일까지로 계산하기 때문에 감시 정보를 해석하는 데에 큰 어려움이 없었지만, 주별 정보 같은 경우는 감시 정보를 생산하는 월요일 기준으로 2주전 토요일~1주전 금요일 자료를 통합하여 생산하기 때문에, 매년 날짜가 바뀐다는 단점이 있었다. 또한 날짜 기준이 아닌 요일 기준으로 계산을 하게 되므로, 어떠한 주간 같은 경우는 두 달에 걸쳐서 존재하기도 하여, 날짜를 기준으로 계산하는 월별 자료와의 해석에 있어서 혼란이 발생하였다. 감시 정보 생산 및 표출 자동화 시스템을 구축하는 데 있어서 1개월 내 5~6회 정도 생산 및 웹 서비스 운영까지는 적절치 않다고 판단되어, 더욱 간소화하기 위해 개선을 실시하였다.



Figure 2. Schedules on the HPC and WEB before improvement extreme climate monitoring system.

요일 기준으로 감시 정보를 계산하는 주별 감시 정보 생산 및 표출 체계를 없애고, 매 월 날짜를 기준으로 순별 감시 정보를 생산하여 월별 감시 정보의 보조 자료로 이용하였다. 이렇게 날짜 기준인 월별, 요일 기준인 주별 감시 정보를 모두 날짜를 기준으로 계산하여, 순별 감시 정보를 월별 감시 정보의 부가 정보로 활용하여 함께 해석에 활용할 수 있도록 통합하였다. 개선된 이상기후 감시 정보 표출 자동화 시스템 스케줄은 Figure 3과 같이 통합된 자동화 일정에서 함께 월별 자료를 생산하고 표출하여 더욱 효율적인 운영이 가능하다.



Figure 3. Schedules on the HPC and WEB after improvement extreme climate monitoring system.

월별 및 주별 감시정보를 월별 감시 정보로 함께 통합함으로써, 자료 생산 주기가 월 1회로 감소하여, 더욱 효율적으로 감시정보를 제공할 수 있다. Figure 4에서는 월별 자료의 부가정보로 추가되는 동아시아 및 한반도의 순별 자료를 볼 수 있는데, 이상 고온과 이상 저온의 경우, 주별 자료와 월별 자료를 통합하면서, 이상기후 발생일수에 대한 순별 자료를 생산하였으며, 최대 강수 사상의 경우 재현기간이 20년 이상인 강수 사상에 대한 강수량만 추출하여 순별 자료를 생산하였다. 주별 감시정보의 공간분포 대신 관심지역인 동아시아와 한반도 지역에 대한 지역 평균 이상기후 발생일수를 순별로 부가정보로 제공함으로써, 한 달 중 어느 기간에 이상기후 발생이 더욱 빈번하게 발생했는지 간단히 파악할 수 있다.

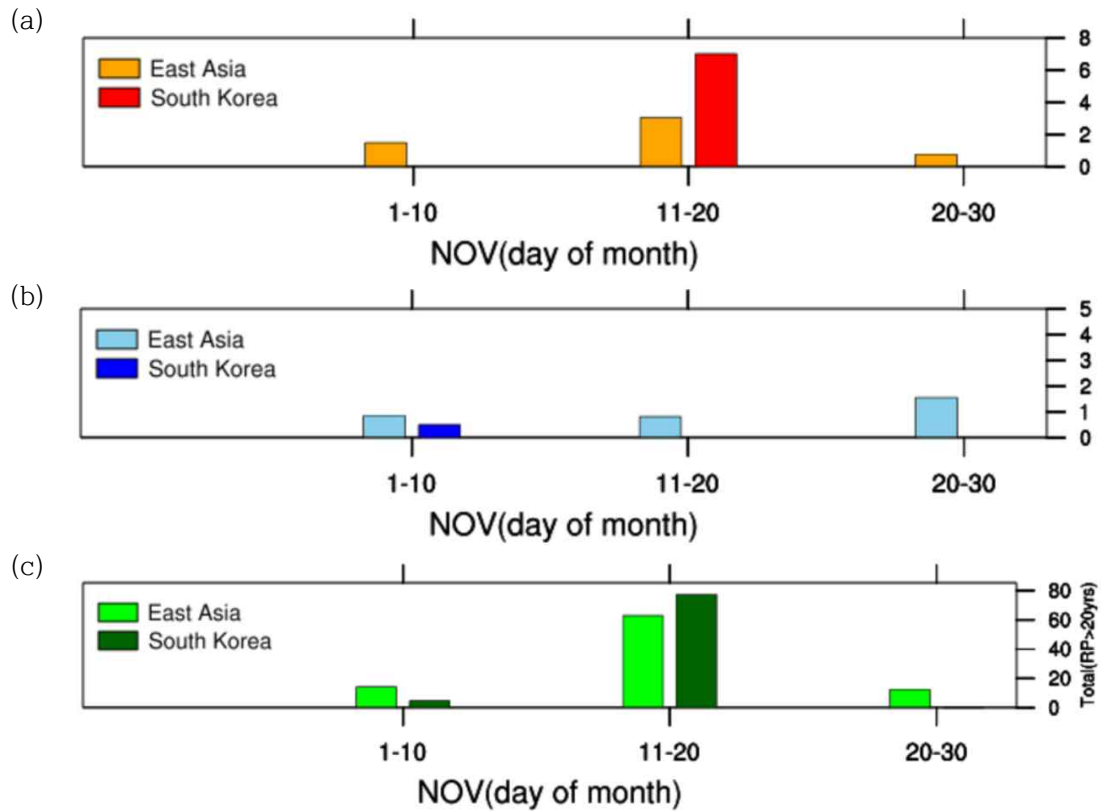


Figure 4. Average of (a) extreme hot days, (b) extreme cold days and (c) rainfall amount where RP(return period) is greater than 20 years during first, middle and last ten days of a month over East Asia and South Korea.

② 개별 감시 정보를 통합하여 통합맵 생산

기존 이상기후 감시 정보 웹서비스는 초기 생산 자료 구축 당시, 더 다양한 감시 정보를 생산하고 웹 서비스로 제공하기 위해 월별 기온 2개, 강수 2개, 가뭄 2개 그리고 주별 기온 2개, 강수 1개, 가뭄 1개로 총 10개의 감시 정보를 생산하고 표출하였다. 하지만, 너무 많은 감시 정보로 인해 여러 정보를 함께 해석하는 데에 큰 어려움이 있었다. 또한 서로 다른 지수임에도 중복 지수로 인식될 뿐만 아니라, 각 변수에 대해 어떤 지수들을 함께 감시하고 해석할지에 대한 논의도 많았기 때문에, 연관성 있는 지수들을 통합하여 통합맵을 생산하여 함께 감시 정보를 한 눈에 볼 수 있도록 개선하였다 .

개선된 웹서비스에서 제공하는 통합맵은 총 3가지이다. 첫 번째는 이상강수 통합맵 (Figure 5), 두 번째는 가뭄 통합맵 (Figure 6), 세 번째는 동아시아 이상기후 통합맵(Figure 7)이다 .

첫 번째, 이상강수 통합맵(Figure 5)은 기존에 웹서비스 되었던 ‘월별 최대 강수 사상’감시 정보와 ‘월별 최대 강수 사상의 재현기간’ 감시 정보를 하나로 통합하여 나타낸 것으로 동아시아 및 한반도에서 발생한 이상강수의 발생 특징을 감시정보로 나타내었다. 또한 순위 정보는 월 누적 강수량을 과거 기간 대비 현재 값으로 나타내었다.

매월 생산되는 최대 강우 사상과 최대 강우 사상의 재현기간, 두 개의 월별 감시정보를 하나의 통합맵으로 나타내었다. 하나의 감시 정보로 통합하면서 동아시아 지역에 대해 최대 강우 사상의 재현 기간을 공간 분포로 나타내었다. 또한 더욱 용이한 해석을 위해 함께 제공하는 부가 정보는 동아시아 및 한반도 지역에 대해 재현 기간이 20년 이상인 지역의 순별 누적 강수량과 과거 기간 대비 현재의 월 누적 강수량 랭크 정보이다.

매월 2개로 생산했던 감시 정보를 하나로 통합할 뿐만 아니라 부가 정보로 월 누적 강수량의 과거 대비 현재 순위 까지 함께 추가함으로써, 통합된 이상강수 통합맵을 통해 어느 지역에서 재현기간이 긴 이상강수가 발생하였는지, 한반도의 누적 강수량은 과거 대비 어떠한 수준인지, 그리고 동아시아와 한반도 지역에서의 순별 강수량 변화는 어땠는지 한 눈에 살펴볼 수 있다.

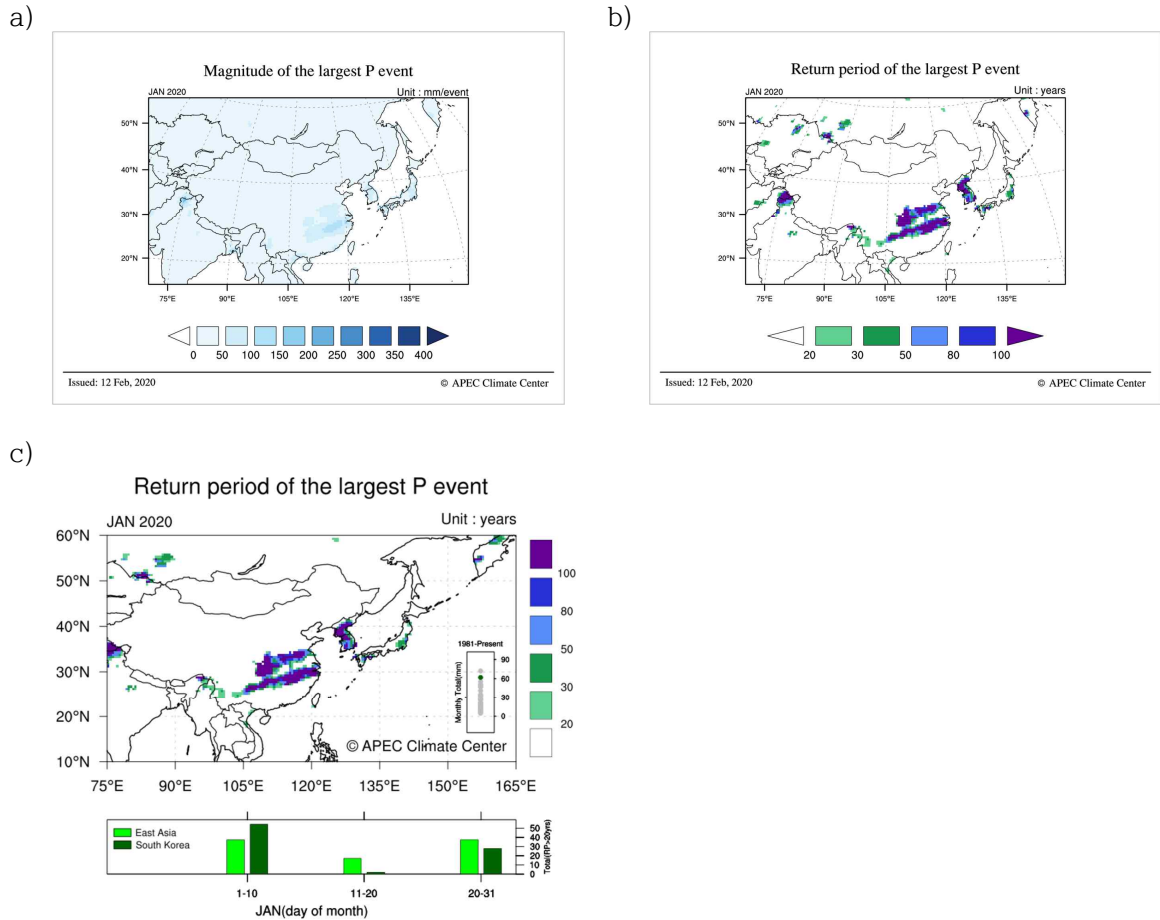


Figure 5. Monthly extreme climate monitoring map (a), (b) before and (c) after improvement visualization technique for (a) magnitude of the largest P event, (b) return period of the largest P event, (c) integrated map both magnitude and return period of the largest P event.

두 번째, 가뭄 통합맵은 ‘월별 표준 강수 지수 (SPI)’, ‘월별 표준 증발량 부족 지수 (SEDI)’, ‘주별 토양 수분 지수 (SMI)’ 등 세 가지 가뭄 지수를 하나로 통합한 감시정보이다. Figure 6은 통합 전 각 가뭄지수와 통합 된 가뭄 통합 맵을 나타낸 것이다. 세 가지 가뭄 지수를 통합하기 위하여, 주별로 생산되던 SMI를 월별 감시 정보로 추가 생산하였으며, 통합맵에서는 이 세 가지 가뭄 지수 중 가장 높은 값을 표출한다. 가뭄 통합맵에서 이용되는 가뭄 지수들은 1개월 단위의 지수이기 때문에, 함께 표출하는 보조 자료는 순별 자료가 아닌 각 가뭄 지수 별로 동아시아 및 한반도에 대한 현황을 나타낸다.

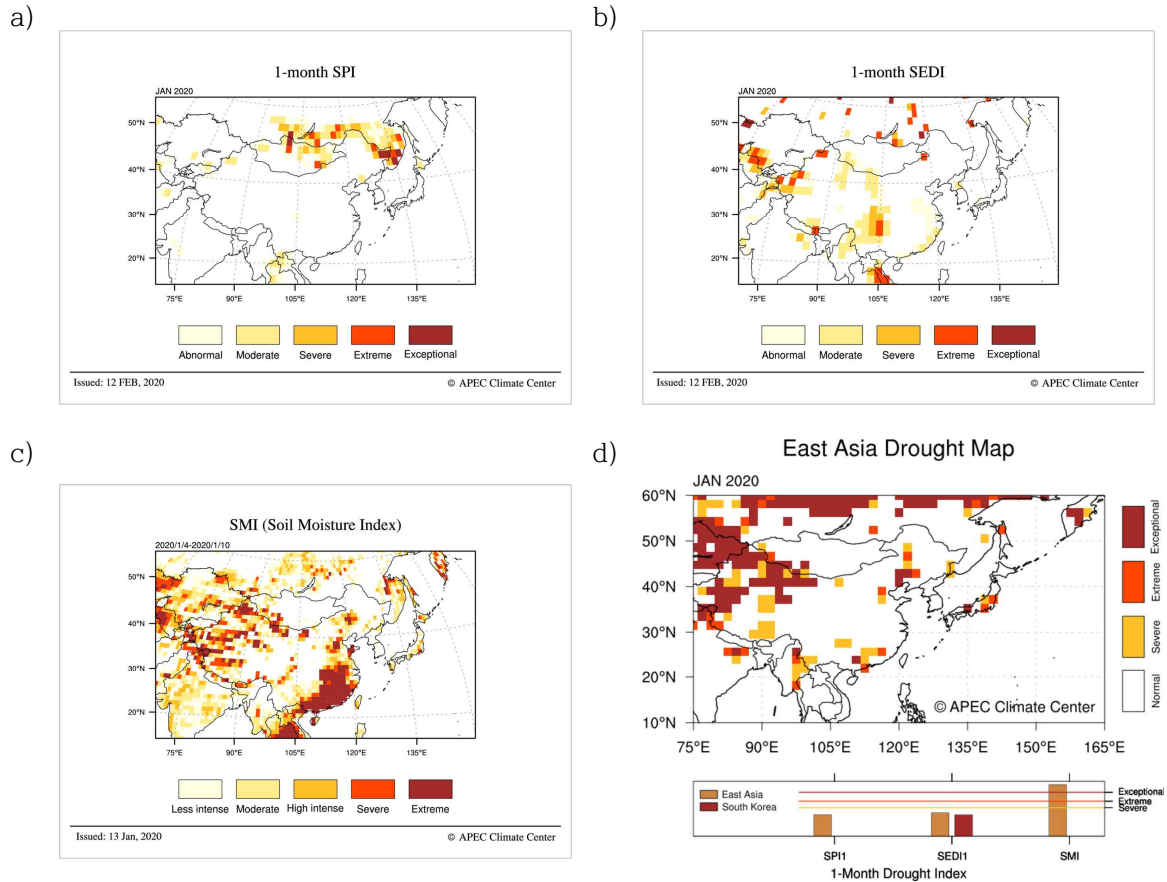
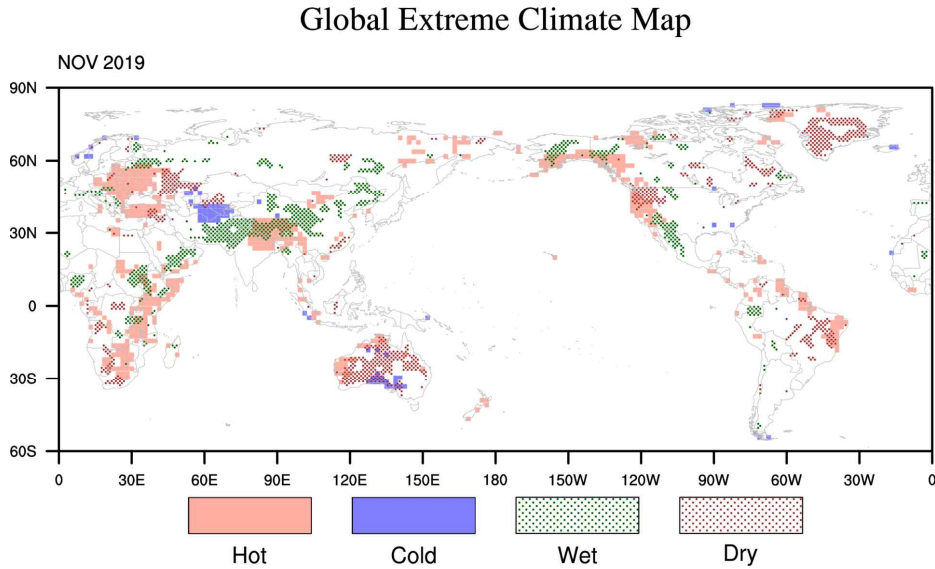


Figure 6. Monthly drought monitoring map (a), (b), (c) before and (d) after improvement visualization technique for (a) 1-month SPI, (b) 1-month SEDI, and (c) weekly SMI, and (d) integrated map of drought indices.

세 번째는 2019년 과제에서 개발되었던 전지구 이상기후 통합맵을 동아시아 지역에 대해 초점을 맞추어 생산하였으며, 가시화 기법도 개선하여 한 눈에 동아시아 지역에서 복합적으로 발생하는 이상기후 감시정보를 볼 수 있는 통합맵이다. Figure 7에서 Hot(이상고온 발생일수가 10일 이상), Cold(이상저온 발생일수가 10일 이상), Wet(SPI 지수가 1.3 이상), Dry(SPI 지수가 -1.3 이상)을 나타내고, 각각 이상 고온, 이상 저온, 이상 강수, 이상 가뭄을 의미한다. 온도와 강수는 겹쳐지는 지역도 나타남을 알 수 있다. 전지구에서 산발적으로 나타나 동아시아 및 한반도 지역에 대해서는 복합적인 이상기후 감시 정보의 현황 파악이 힘들어 동아시아 지역에 대한 도메인으로 집중하였고, 가시화 기법도 함께 개선하여 더욱 한반도와 동아시아에 대한 이상기후 감시 정보를 한 눈에 잘 알아 볼 수 있도록 개선하였다.

a)



c)

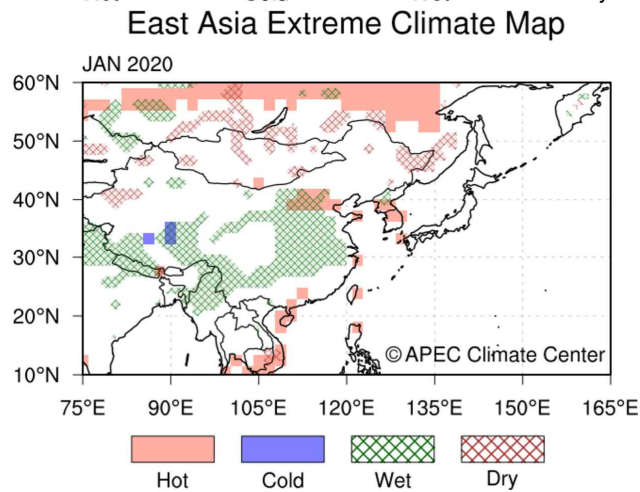


Figure 7. (a) Before and (d) after improvement visualization technique for (a) global and (b) East Asian extreme climate map.

(다) 이상기후 감시 정보 콘텐츠 가시화 기법 개선

① 이상기후 감시 정보 콘텐츠 가시화 기법 개선

기존 감시 정보 콘텐츠의 경우 전체 그림 크기에 비해 여백이 차지하는 공간이 매우 넓어 살펴보고자 하는 도메인 내 공간 분포도를 보기가 힘든 단점이 있었다. 또한 감시 정보 별 제목 글씨체가 깔끔하지 못하고, 전체적으로 감시 정보가 눈에 띄지 않는 배치로 가시성 또한 좋지 않았다. 모든 감시 정보에 대한 일괄적인 통일감을 주며 더욱 가시성 있는 감시 정보를 만들기 위해 전체적인 틀을 바꾸도록 가시화 기법을 개선하였다. 여백은 줄이고 도메인은 키우며 공간 분포도와 글씨체를 더욱 단순화 하면서도 크게 변경하여 더욱 가시성을 높일 수 있도록 개선하였으며, 앞에서 추가 생산 된 보조 자료를 한 그림에 함께 넣음으로써 이상기후 감시 정보에 대한 해석을 더욱 쉽게 할 수 있도록 하였다.

월별 동아시아 및 한반도 지역에 대한 이상고온, 이상저온 감시 정보의 콘텐츠 확대 생산

에 따라 부가 정보를 함께 표출하는 방식으로 바뀌게 되었다. 또한 기존 감시 정보의 경우 전체 그림 크기에 비해 여백이 크고 동아시아 도메인 영역이 작았기 때문에 동아시아 지역에 대해 더욱 공간 분포도를 크게 볼 수 있도록 크기를 늘리고, 한 눈에 감시 정보가 더욱 잘 들어올 수 있도록 글씨체와 여백, 범례, 부가 정보의 위치 등을 모두 고려하여 가시화 기법을 개선하였다. 이상 고온 및 이상 저온의 공간 분포 색상은 그대로 유지하였으며, 전체적으로 통일감을 주기 위해 다른 감시 정보와도 모두 배치를 동일하게 구성하였다.

Figure 8는 부가 정보 추가 및 가시화 기법 전·후의 비교를 보여준다. 가시화 기법 개선 전에는 이상 고온 및 이상 저온 발생일수의 공간 분포도만 보고 해석을 해야 했으나, 가시화 기법 개선 후에는 과거 값 분포도 대비 현재 위치가 어떠한지 순위 분포도를 통해 알 수 있으며, 순별로 비교하여 같은 1개월 내 기간이라도 언제 더욱 이상기후 발생일수가 빈번했는지 함께 살펴볼 수 있다.

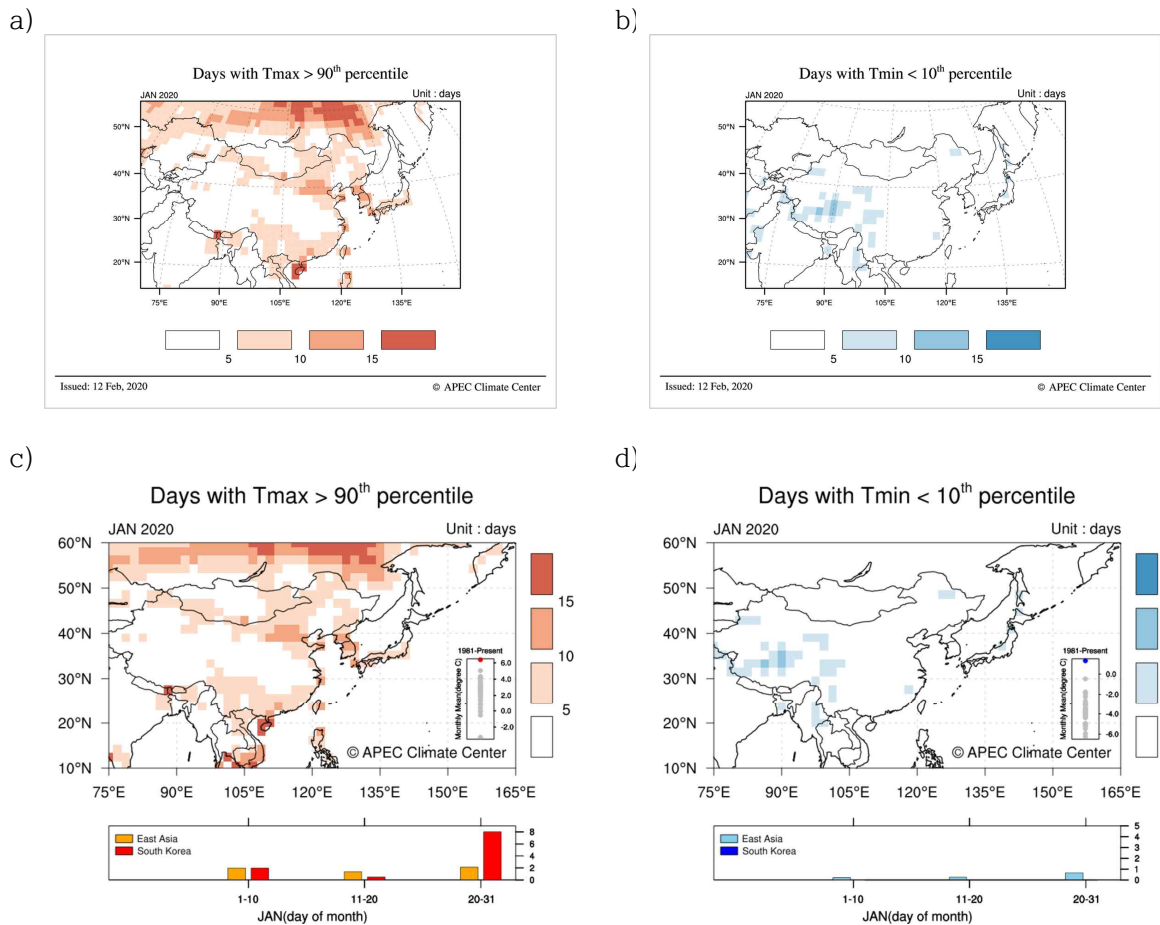


Figure 8. Monthly extreme climate monitoring map (a), (b) before and (c), (d) after improvement visualization technique for (a), (c) daily maximum temperature above 90th percentile and (b), (d) daily minimum temperature below 10th percentile.

(라) 기후소통 TF를 통한 전지구 이상기후 모니터링

① 전지구 이상기후 관련 일일 모니터링

기후소통 TF에서는 매주 월, 수, 금요일마다 전지구 지역에서 발생하는 이상기후 현상 및 재난 재해 피해 등을 모니터링하고, 수집한 일일 모니터링 자료를 기상청과 함께 취합하고 있다.

(2) 이상기후 원인 분석 방법 개선

(가) 관측 자료

관측 해수면 온도 (sea surface temperature, SST) 분석을 위해서 Extended Reconstructed Sea Surface Temperature version 5 (ERSST v5; Huang et al. 2017) 월 자료가 사용되었다. ERSST v5는 $0.5^{\circ} \times 0.5^{\circ}$ 의 수평 해상도를 가지며, 자료 기간은 1854년부터 현재까지 이다. 그리고 대기 순환 분석을 위해서 National Centers for Environmental Prediction-National Center for Atmospheric Research (NCEP-NCAR) 재분석장 I (Kalnay et al. 1996)으로 부터의 기온, 지위고도, 바람 자료가 사용되었다. 이 연구에서는 1981년 이후의 관측 자료들을 중심으로 분석하였으며, 1981년에서 2010년을 평년 기간으로 하여, 1981년에서 현재까지의 기온, 강수, 지위고도, SST, 바람장의 편차가 정의되었다.

태평양의 주요 SST 변동 모드인 ENSO는 Niño3.4 ($170^{\circ}\text{W} - 120^{\circ}\text{W}$, $5^{\circ}\text{S} - 5^{\circ}\text{N}$) 지역에서 평균된 SST 편차로 정의하였다.

(나) 주성분 분석을 활용한 원인 분석 방법 개선

본 연구에서는 한반도 혹서기 이상 기후 발생과 이와 관련된 대기 변동의 공분산을 고려할 수 있도록 SVD (Singular Value Decomposition) 방법을 활용하여, 그 동안 단일 이상 기후 변수에 대한 경험적 직교 함수(Empirical Orthogonal Function) 방법을 사용하던 통계적 원인 분석 방법을 개선하였다.

한반도 이상 기후 지수와 상층 대기 순환 변수 즉 200mb 남북방향 바람장 혹은 지위고도장 변수에 대한 SVD를 적용할 때 상층 대기 순환 변수의 영역을 정하는 데 있어서, 최대한 모드간 분리가 명확한 영역을 정했다. 그 영역은 ($50^{\circ}\text{E}-180^{\circ}\text{E}$, $20^{\circ}\text{N}-50^{\circ}\text{N}$)이다. 이 영역으로 하였을 때 최대 3개 모드까지 통계적으로 유의한 분리가 가능하였다. SVD 모드들의 분포를 해당하는 관측 분포에 투영하여 Expansion Coefficient (EC)를 얻었으며, 이를 통해 모드 강도 변화의 시계열로 활용하게 하였다.

(3) 자기조직화지도(Self-organizing Map) 기법활용 혹서기 이상기후 분석체계 구축

(가) 자료수집 및 구축

이 연구에서는 Table 1에 요약한 자료를 사용하여, 한반도의 여름철 폭염 특성을 분석하고 토양수분 등 지면상태와의 상관성을 분석하였다. 한반도의 폭염을 정의하기 위해 사용한 45개 표준관측지점의 위치는 Figure 9에 도시하였다. ERA-5의 500GPH, 850hPa wind, T2m은 6 hourly 자료를 내려받기 하여 일별자료로 변환하였으며, 토양수분자료는 3 hourly 자료를 내려받기하여 일별자료로 변환하였다. 공간해상도는 ERA-5자료 모두 0.25°×0.25°으로 수집하였으나, 계산시간이나 하드웨어 성능을 고려하여 분석별로 각각 알맞게 보간하여 사용하였다. 예를 들어, ERA-5 T2m의 경우, 군집분류에 사용하였는데, 1°×1°로 보간하여 사용하였다. 이 연구에서 사용한 자료의 기간은 모두 1979년부터 2019년까지이다.

Table 1. Meteorological and soil moisture datasets used in this study.

Data	Source
ASOS	https://data.kma.go.kr/data/grnd/selectAsosRltmList.do?pgmNo=36
ERA-5 500GPH	
ERA-5 850hPa wind	https://www.ecmwf.int/en/forecasts/datasets/reanalysis-datasets/era5
ERA-5 T2m	
ERA-5 soil moisture	

(나) 지역폭염(Regional Heatwave)

한반도의 지역폭염(regional heatwave)을 Figure 1과 같은 방법으로 산정하였다. 지역폭염은 총 3단계에 걸쳐 구할 수 있는데, 먼저, 기상청의 폭염 정의에 따라 특정한 날에 일최고기온이 33°C이상인 관측지점을 선택한다. 이렇게 선택한 관측지점을 “hot station”으로 정의한다(Figure 1의 ①에서 적색으로 표시된 관측지점). 이렇게 선정된 hot station별 반경 80 km 이내의 모든 관측지점 수와 hot station의 수의 비(α)를 구한다. 보통 α 의 값은 0.3-0.6의 범위(Ren et al., 2012; Stefanon et al., 2012; Wang et al., 2017)를 가지는데, 이 연구에서는 권역별 폭염을 나타낼수 있는 크기를 시행착오법(trial and error)으로 선택하였다. 시행착오법에 의해 적어도 권역의 크기 정도를 나타내는 α 값은 0.6이었다. 이 값은 Yoon et al. (2020)이 한반도 지역폭염을 분류하는데 사용한 값과 동일하다. 지역적 동일한 hot station만을 선택하기 위해, α 가 0.6보다 작은 hot station은 모두 지우게 되는데, 이 방법으로 공간적으로 분리된 hot station은 모두 지워지게 된다(Figure 9의 ②). 마지막으로 연속한 다음 날 hot station에 대해 ①과 ②를 반복한 후, 서로 중첩된 hot station의 개수(Figure 1의 ③의 파란색 색칠부분)가 이전 날 hot station의 30%이상이면 동일한 지역폭염으로 정의한다(Figure 9의 ③). 이러한 방법을 통하여, 한반도 45개 표준관측지점의 1979-2019까지 여름철(6월, 7월, 8월) 지역폭염을 산정하고, 그 특성을 분석하였다. 보다 상세한 방법은 Yoon et al. (2020)과 Stefanon et al. (2012)에 설명되어 있다.

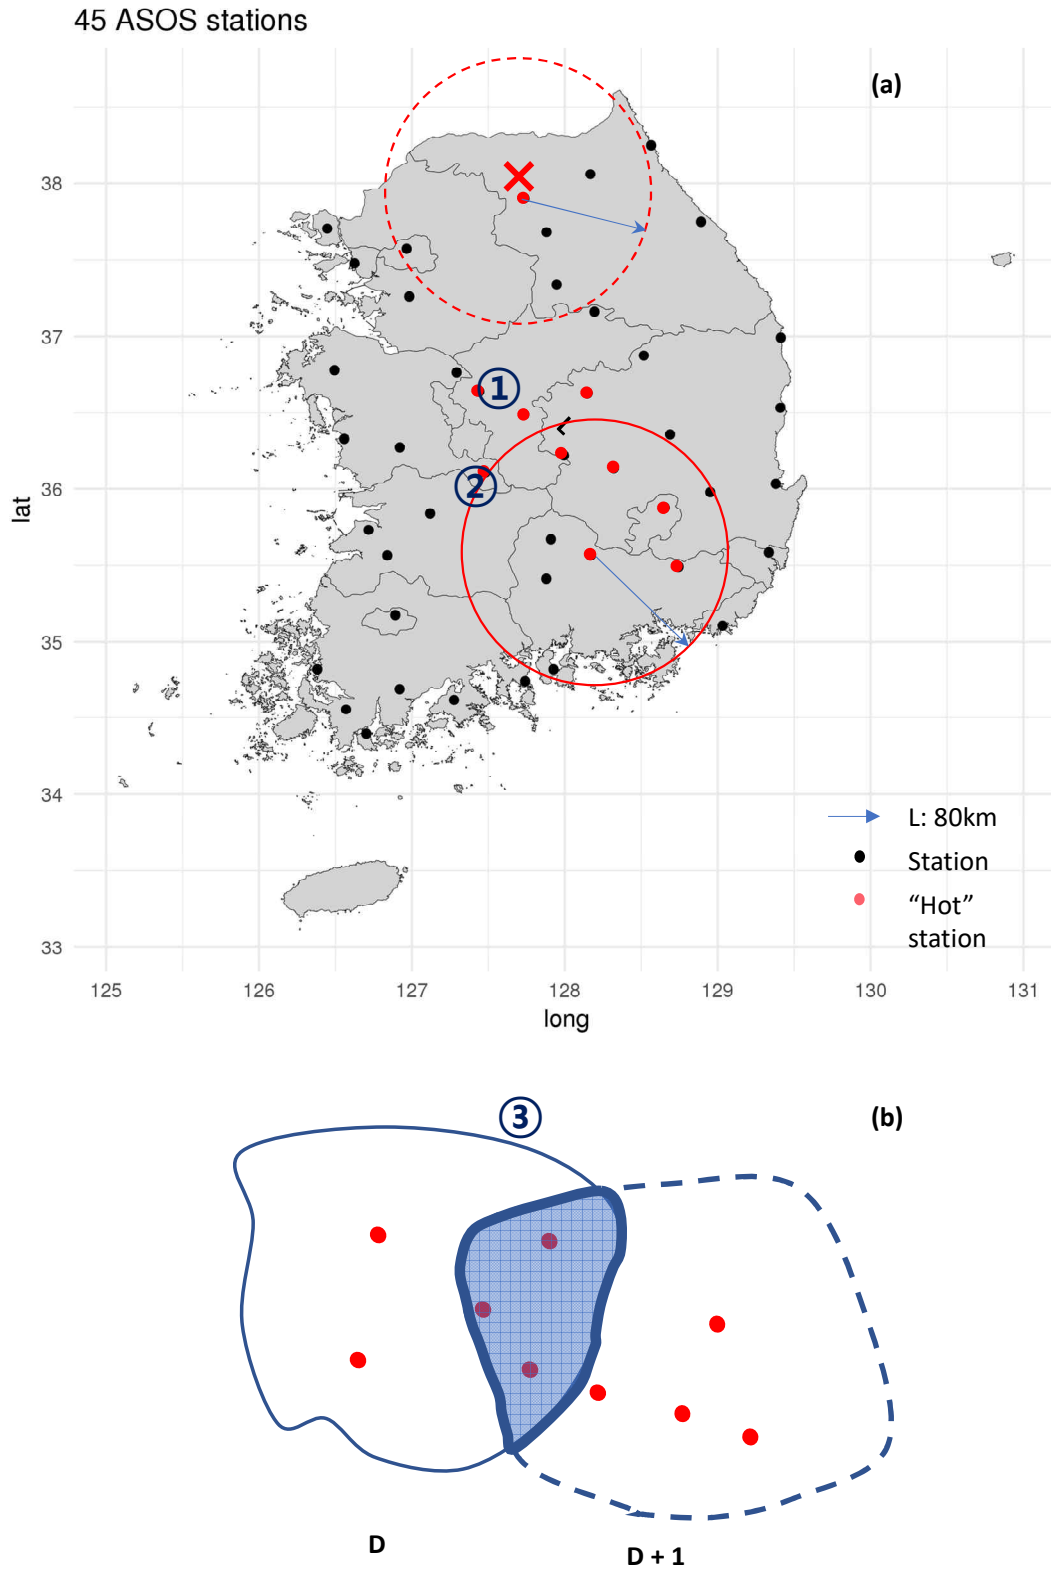


Figure 9. Conceptual diagram for regional heatwave in study area. (a) station location map and the first two steps for the regional heatwave identification (b) the last step for the regional heat wave identification.

(다) 지면조건의 한반도 폭염에 대한 예측인자 활용성 평가

① 자기조직화지도(Self-organizing Map) 기법 활용 한반도 폭염 패턴분류

자기조직화지도(Self-organizing Map, SOM)은 인공신경망(artificial neural network)의 일종으로 비지도 학습(unsupervised learning)에 의한 군집분류기법(clustering method)이다. Figure 10과 같이 보통 입력층(input vector)와 출력층(feature map)으로 구성되어 있으며, 두 개의 층은 전결합(fully connected)되어 있다. SOM은 크게 훈련과정(training processes)과 매핑과정(mapping process)으로 나눌 수 있으며, 무작위적인 순서로 신경망에 입력된 입력 패턴은 가장 유사한 연결강도를 갖는 출력 뉴런을 유클리드 거리(Euclidean distance)에 의해 결정하게 된다. 이때 결정된 가장 유사한 연결강도를 갖는 출력 뉴런을 승자노드(winning node)라 한다. 이러한 SOM기법은 한반도 기온과 강수 특성을 분류하는데 사용되어 왔다. 예를 들면, 임원일과 서경환(2018)은 우리나라 여름철 극한온도 특성을 SOM기법을 통하여 분류한 바 있고, 추정은과 하경자(2011)는 SOM기법을 이용하여 동아시아몬순 계절 내 진동 구분한 바 있다.

이 연구에서는 지역폭염 특성 분석을 위해 ERA-5 T2m 6 hourly 자료를 일자료로 변환 후 $1^{\circ} \times 1^{\circ}$ 로 보간하였다. 그런 다음, 20-50°N과 110-150°E 영역에 대해 45개 표준관측지점으로 추출한 한반도의 지역폭염일에 해당하는 날짜를 선별하였다. 최종적으로 이렇게 선별한 T2m 자료를 입력벡터로 사용하여 SOM 기법을 통하여 총 3개 노드(이하, SOM 패턴)로 군집분류를 실시하였다. SOM 기법은 kohonen R-package (Wehrens and Buydens, 2007; Wehrens and Krusselbrink, 2018)를 사용하였다. 또한, ERA-5 500GPH과 ERA-5 850hPa 바람장의 한반도 지역폭염일에 대한 각 SOM 패턴별 합성장을 구하여 한반도 지역폭염일에 대하여 그 특성을 분석하였다. 토양 수분에 대해서도 ERA-5 500GPH과 ERA-5 850hPa 바람장의 합성장과 유사한 방법으로 합성장을 구하여, 그 특성을 분석하였다.

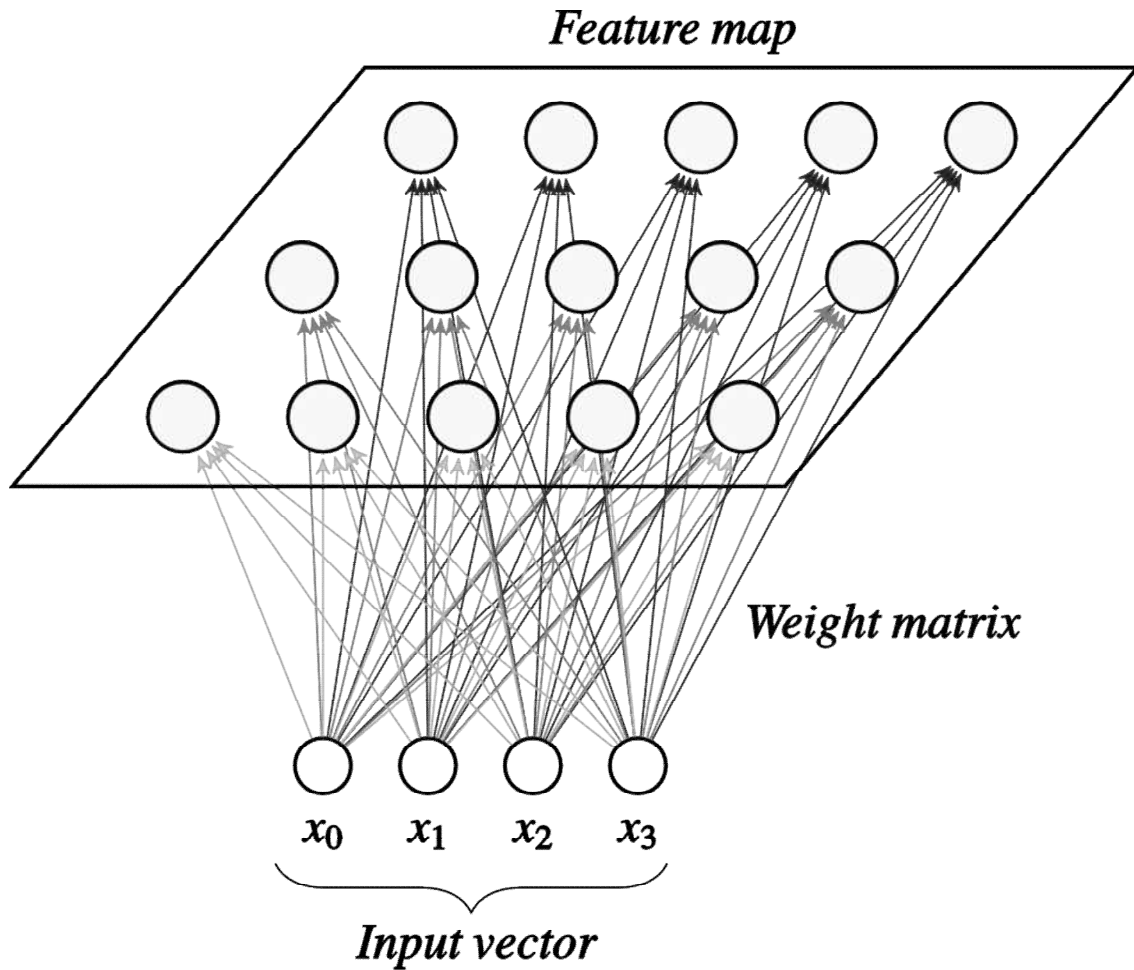


Figure 10. Architecture of a self-organizing map network. (Adapted from <http://gorayni.github.io/blog/2014/10/08/som.html>).

② SOM 패턴별 대기순환장 및 토양수분과 지연 및 동시상관성 분석

각 SOM 패턴별 합성장을 통하여, 한반도 지역폭염이 해양의 영향보다 지면조건과 상관성이 커보이는 SOM 패턴을 선정하였다. 1979년에서 2019년 기간에 대해, 이 SOM 패턴에 대한 ERA-5 500GPH과 ERA-5 850hPa 바람장과 토양수분의 동시 및 지연상관(말하자면, 0일, 15일, 30일, 60일 선행시간) 분석을 실시하였다. 지면조건과 상관성이 큰 SOM 패턴으로 분류된 한반도의 각 지역폭염일에 대하여, 500GPH, 850hPa 바람장, 토양수분의 0일, 15일, 30일, 60일 선행시간의 합성장을 각각 구하여 분석을 실시하였다. 또한, 2020년 여름철(6월, 7월, 8월)에 발생한 지역폭염을 구하고, 위와 유사한 방법으로 ERA-5 500GPH과 ERA-5 850hPa 바람장과 토양수분의 각각 합성장을 구하여, 특정 지면조건이 감시인자로 활용 가능성이 있는지 판단 하였다.

나. 이상기후 장기 전망 콘텐츠

(1) 유사성 기반 추계학적 폭염예측

폭염의 일반적 정의는 생물이 생존하기 어려운 수준 이상으로 기온이 폭증하는 현상이지만 단기적인 고온현상이 생물계에 큰 영향을 미치는 경우는 드물기 때문에 반복특성이나 지속 특성을 고려하여 위험을 평가해야 한다 (White and Tawn, 2017). 하루 이틀 정도 발생했다 금방 사라지는 극한 고온보다는 상대적으로 낮지만 지속하는 넓은 범위에 나타나는 고온현상이 생물 생존에 훨씬 큰 영향을 미친다. 따라서 폭염 위험은 일정기간동안 특정 기준 이상의 온도가 발생한 일수나 (e.g., Balwin et al., 2019; Winter and Tawn, 2017) 공간적 범위로 주로 평가된다 (e.g., Yoon et al., 2020). 한국 기상청은 공식적으로 일최고기온(T_{max})이 33°C 이상으로 지속되는 경우로 정의하고 있다. 본 연구에서는 기온의 시공간적 변동성을 고려하기 위해 33°C 의 절대기준이 아닌 세계기상기구의 T_{max} 90 percentile(T_{90}) 값으로 폭염기준을 설정하였고 1개월 동안 기준을 넘어서는 일수를 기준으로 폭염위험 평가와 유사해 분석을 수행하였다. 따라서 본 절에서 제시하는 예측기법은 폭염의 강도변화보다는 지속성에 초점을 두고 있다.

본 절의 유사성 기반 추계학적 폭염 예측기법은 편미분 방정식에 의한 역학적 예측이 아닌 관측 기록에 완전히 의존하는 방법이다. 따라서 관측되지 않은 기록적인 폭염을 예측하는 방법으로는 사용되기 보다는 폭염현상의 경험적으로 변동성 안에서 폭염 위험을 평가하는 방법이라 할 수 있다. 확률적 폭염예측은 두 단계로 이루어지는데 (Figure 11), 첫 번째 단계는 예측 월의 폭염일수와 선행 월의 대기지위고도(Geopotential height; GPH)와의 상관성을 바탕으로 유사해(Neighbor years)를 추출하는 것이다. 한 지역에서 발생한 폭염, 폭우, 한파, 가뭄과 같은 이상기후 현상의 경년변동성을 선행 HGT나 해수면온도의 경년변동성과 연결해 설명하는 것은 기상학에서 예측인자 개발이나 원인분석을 위해 흔히 사용된다(기상청, 2018). 두 번째 단계는 해당 지역 유사해의 T_{max} 자료를 추계학적 Weather generator에 입력하여 반복적 샘플링을 통해 폭염 위험을 확률적으로 정량화하는 것이다. 이 단계에서 사용되는 weather generator의 종류에 따라 위험평가의 다 지점 확장이 가능하다. 추출된 유사 해의 T_{max} 시계열만을 사용하기 때문에 조건부 weather generation이라고 할 수 있으며 추계학적으로 발생된 T_{max} 자료는 T_{max} 의 시공간적 변동한계를 설정할 수 있게 한다. 자료기반 예측기법이기에 충분한 길이의 T_{max} 관측자료(통상 30년 이상)가 가용할 때에만 제시된 방법이 사용 가능하다.

1. Identifying Neighbor Years

2. Quantifying Heatwave Risk

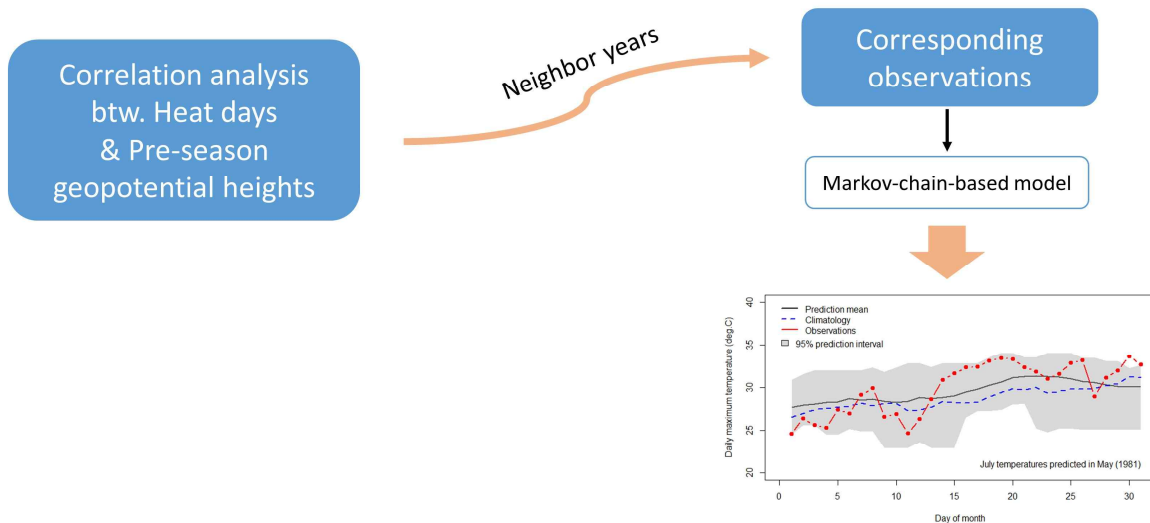


Figure 11. Two-step framework for heat wave forecasts (Selection of neighbor years via correlation analysis → Application of weather bootstrapping method)

(가) 상관분석을 이용한 유사해 추출

상관분석을 위해 먼저 폭염예측 대상지역인 한국의 1981년부터 2019년까지의 평균 폭염일수를 먼저 산정하였다. 기상청 45개 종관관측지점 T_{max} 자료(<https://data.kma.go.kr/cmmn/main.do>)를 사용하여 공간평균 T_{max} 를 계산한 후 1981-2010 기간에 대해 1월 1일부터 12월 31일 각 일별 T_{90} 값을 5일 moving window를 적용해 산정하였다. 종관관측소 자료가 결측인 경우 Inverse distance weighting 방법으로 공간보간 후 평균값을 취하였다. 1981-2019년 기간 동안의 월별 폭염일수는 T_{max} 값이 T_{90} 보다 높은 일수의 합으로 정의하였고 이 정의에 의한 폭염일수 시계열은 Figure 12와 같다. 1994년 여름에 발생했던 기록적인 폭염을 제외하면 2010년 이전의 폭염일수는 통상 5일이 넘지 않는 경우가 대부분이고 10일 이상인 경우는 매우 드문 것을 확인할 수 있다. T_{90} 을 넘는 T_{max} 값은 1/10의 확률로 발생하기 때문에 평균적으로는 1개월 동안의 이런 경우가 3일 정도 발생하는 것으로 볼 수 있고 따라서 10일 이상이면 매우 이례적인 경우이다. 하지만 2010년 이후 특히 2015년 이후에는 T_{max} 가 T_{90} 을 점점 많아지고 있는 것을 어렵지 않게 확인할 수 있는데 이는 Baseline 기간(1981-2010년) 이후 한국의 평균기온에 뚜렷한 상승 추세가 있음을 의미한다. 평균기온의 상승은 당연히 극치사상(extreme events) 발생확률을 높이게 되고 이에 따라 2020년 이후의 폭염일수는 점점 증가할 것으로 보인다. Im et al.(2019)는 2018년 한국의 T_{max} 기록이 Gaussian 분포의 일반적 범위를 넘어서는 것으로 확인하였고 이 사실이 전지구 평균 3°C 상승 시나리오의 기대치와 같은 정도로 평가하였다. 다시 말하면 2018년의 이례적 이상고온은 시간이 지나면 이상치가 아닌 평균값이 될 것이라는 전망으로 이상고온에 의한 가중된 피해가 현재 예상되는 상황이다.




Figure 12. Evolution of the number of days with $T_{max} > T_{90}$ in South Korea from 1981 to 2019

Figure 12의 폭염일수 자료를 각 월별로 다시 추출해 선행월 GPH 편차시계열과의 상관분석에 사용될 수 있다. 예를 들어, Figure 13은 1994-2015년 기간의 6월 500hPa GPH 편차와 동일기간 6월 폭염일수와의 Pearson 상관계수(Pearson r)를 나타내는데 이를 이용해 6월 폭염일수와 대기순환장을 물리적으로 연결해 설명이 가능하다. 기상청(2018)에서는 이와 동일한 상관도를 이용해 6월 평균기온이 북서태평양 지역의 저기압성 편차와 오호츠크해 부근의 저기압성 편차가 강할 때 높아지는 것을 확인하였고, 이를 열대 서태평양에서 발생하는 높은 해수면 온도에 대한 대기반응으로 설명하였다. 이 분석은 일반적으로 오호츠크해 고기압이 발달할 때 우리나라 여름철 기온이 하강한다는 Tachibana et al. (2004)의 분석과 일치한다. 동일한 상관도에서 6월 폭염일수가 북극 칙치해 부근의 고기압성 편차와 관계있는 것도 확인할 수 있다.

하지만 폭염일수를 예측하기 위해서는 Figure 13과 같은 동시상관이 아닌 선행 GPH와의 지연상관이 필요한데 (예를 들어, 6월 폭염일수와 3월의 GPH 편차 사이의 상관도), 이는 기후인자 감시를 수행하는 기관의 분석 운영률과 직접적인 영향을 받는다. 예를 들어 미해양대기청의 NCEP(National Centers for Environmental Prediction) Reanalysis 1 재분석 자료는 이듬월 초에 배포되는데 이 때문에 6월 폭염일수를 5월에 생산하기 위해서는 4월 이전의 GPH 자료만이 상관분석에 사용될 수 있다. 5월과 6월 GPH와의 상관성은 계절기후예측(seasonal climate forecasts)를 제외하면 가용하지 않다. 따라서 상관성 기반 유사해 추출을 위한 재분석자료는 정확도보다는 배포 지체시간을 기준으로 선택되는 것이 더 좋을 수 있다.

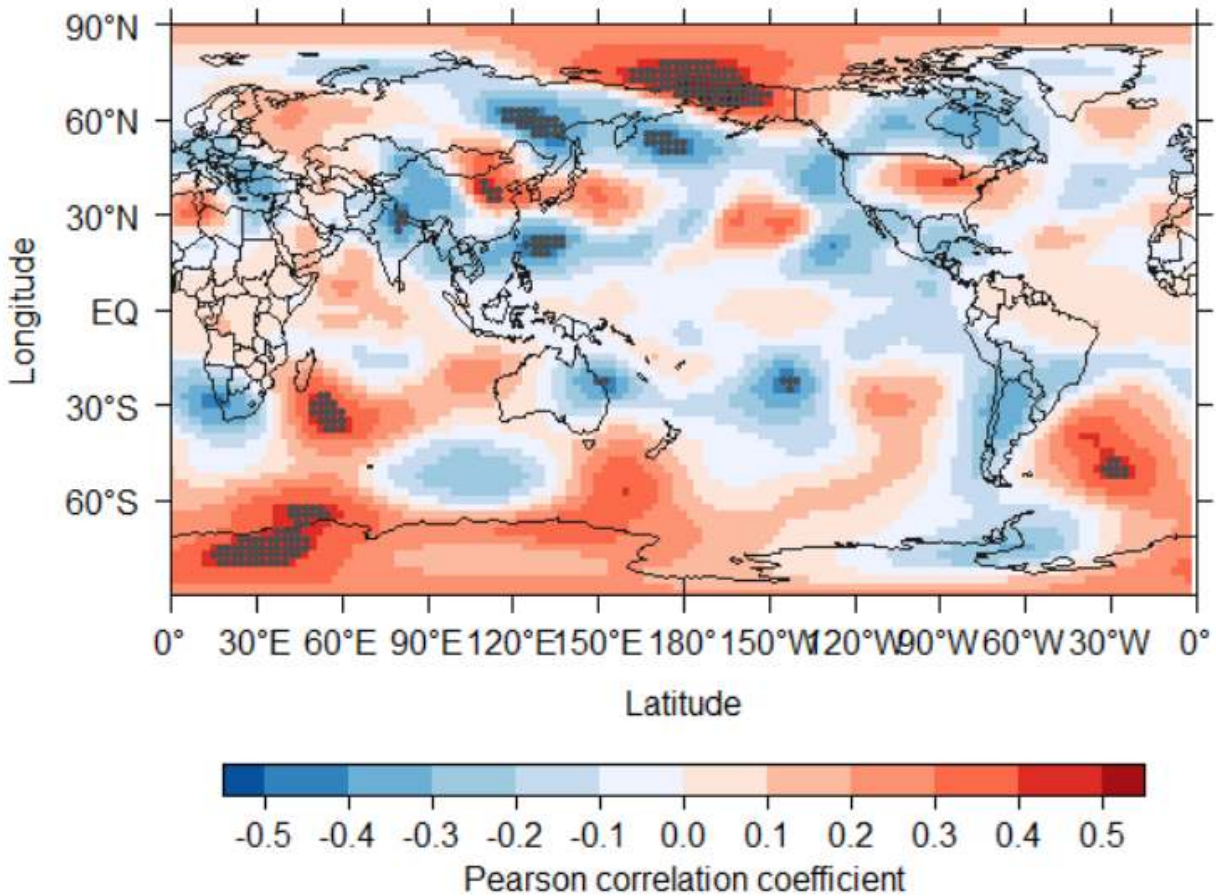


Figure 13. Distribution of Pearson correlation coefficient (Pearson r) between June heat days in Korea and June geopotential height (GPH) anomalies for 1994-2015. The GPH data are from the NCEP Reanalysis I.

물론 한국에서 발생하는 이상고온 현상에 영향을 주는 다른 선행인자를 상관분석에 사용할 수 있으나 본 연구에서는 GPH 편차의 시간공적 변화에 예측인자의 영향이 모두 반영되어 있는 것으로 가정하였다. 예를 들어 여름철 기온에 영향을 주는 장마철 강수량은 장마 시작 전 북대서양, 북태평양, 베링해의 해수면 온도 변화와 밀접한 관계가 있지만(기상청, 2018), 관측 GPH 편차에 이런 예측인자의 영향들이 모두 반영되어 있는 것으로 보았다. 따라서 본 연구에서는 선행 월의 GPH와 예측 대상 월의 폭염일수 사이의 상관만을 고려하였고 예측 수행 월 이전 4개월의 둘 사이의 상관성을 모두 이용하였다.

유사해는 선행상관분석에서 5% 유의수준의 상관성이 나오는 모든 지역의 GPH차이를 이용해 선정되었다. 예를 들어 2020년 6월에 발생할 폭염일수를 예측한다면 유의한 상관성이 나타나는 지역의 2020년 1월부터 4월까지의 GPH와 1981-2019년 기간 각해의 1월부터 4월까지의 GPH의 차이로 Euclidean 거리를 측정해 가장 짧은 해부터 가장 긴 해 순서로 정렬한 후 상위 6개 해를 2020년의 유사해로 결정하였다. Euclidean 거리는 유의한 Pearson r 값의 절대치를 가중치로 이용하였다. 따라서 유사해와 예측해 사이의 Euclidean distance는 다음과 같이 나타낼 수 있다.

$$d = \sqrt{\sum |r| [GPH(y_1) - GPH(y_2)]^2} \quad [1]$$

여기서, d 는 예측해 y_1 과 예측해 y_2 사이의 Euclidean distance (unitless), 유의수준 5% 상관관계가 나타난 한 지점의 GPH편차와 해당월의 폭염일수 사이에 나타난 Pearson r 값이다. 앞서 설명한대로 유의한 상관관계가 나타난 모든 지역의 500hPa GPH 차이를 고려해 두 해 사이의 Euclidean distance를 계산하였고 유의한 상관관계가 나타나지 않은 지역은 계산에서 제외되었다. 상관분석에는 재분석 자료 중 가장 업데이트가 빠른 NCEP R1 자료가 사용되었다 (<https://psl.noaa.gov/data/gridded/data.ncep.reanalysis.html>).

(나) Markov-chain weather bootstrapper

GPH 편차 거리를 이용해 유사해가 선정되면 유사해에 관측된 T_{max} 시계열을 무작위적으로 뒤섞는 weather bootstrap기법으로 예상되는 T_{max} 범위를 쉽게 구할 수 있다. 하지만 $T_{max} > T_{90}$ 발생이 시간적으로 독립적임을 가정하는 weather generator 이나 통계적 방법을 사용할 경우 총 폭염일수는 예측은 가능하나 폭염의 연속성을 판단할 수 있는 정보는 생산이 불가능하다. 앞서 설명한 대로 생물의 생존은 특정온도 이상의 폭염이 얼마나 지속되는가에 큰 영향을 받기 때문에 (Donaldson et al., 2003), 시간지속성을 고려한 weather bootstrapper가 필수적이다. Winter and Tawn (2017, 2016)은 $T_{max} > T_{90}$ 상태가 계속 이어질지 아니면 바로 종료될지에 따라 폭염의 영향은 달라지고 이 시간의존성이 고려되지 않은 폭염위험 평가는 실용적이지 않을 수 있음을 강조하였다. 따라서 본 연구에서는 폭염 발생의 되풀이 특성을 전이확률(transition probability) 개념으로 간단히 모형화 하는 Markov-chain weather bootstrapper를 이용해 폭염 위험을 평가하였다.

Markov Chain을 이용해 폭염을 연구한 대표적인 연구로 Winter and Tawn (2016)를 들 수 있다. 이 방법은 T_{max} 가 기준온도보다 높은 날을 1 그렇지 않은 날을 0으로 하는 Binary series에서 Markov chain의 전이확률(Transition probability)을 추정하고, 연속된 두 날의 T_{max} 결합확률 밀도함수를 이용해 T_{max} 의 확률적 범위를 구한다. 전통적인 Frequentist의 통계해석 기법으로 볼 수 있고 Markov chain으로 폭염발생의 시간적 독립성을 가정하는 기존 연구들(e.g., Ledford and Tawn, 1996)을 보완하는 방법이라 할 수 있다. 하지만 공간상관성을 고려하지 않는 point-scale 분석 방법으로 폭염 발생의 공간적 규모를 평가하지 못하는 단점도 함께 가지고 있는 방법이다. 이를 보완하기 위해 본 연구에서는 Markov chain을 이용하면서 지점 간 상관성을 함께 고려할 수 있는 Appipattanavis et al. (2008)의 semi-parametric weather generator를 T_{max} 예측에 사용하였다.

Appipattanavis et al. (2008)의 weather generator는 원래 강수시계열을 발생하는 기법으로 개발되었지만 T_{max} 시계열도 기준온도(T_{90})를 이용하면 Binary 시계열로 변환이 가능하기 때문에 온도 시계열에도 적용이 가능할 것으로 판단하였다. 간헐성(Intermittency)이 있는 강수 시계열과 연속적인 기온 시계열은 추계학적으로 다른 자료 특성을 갖지만 온도 시계열에도 특정 문턱값(Threshold)를 적용하면 간헐성을 갖게 되어 전이확률 개념을 적용할 수 있게 된다. Markov chain을 강수가 아닌 온도시계열에 적용하는 것은 물리적으로 의미를 갖는데 상승기류 발생에

의한 강수현상이 시간적 지속성이 있듯이 하강기류에 의한 폭염현상도 시간적 지속성이 있는 것으로 보는 것이다.

Appipattanavis et al. (2008)의 weather generator는 강수발생 시계열은 Markov chain 프로세스를 따르는 것으로 가정하고 강수량은 자료에서 k-nearest-neighbor(KNN) 방법으로 직접 추출해 생산하는 방법이다. 강수발생 시계열은 전이확률을 모수(parameter)로 이용하고 크기 발생은 이론적 확률밀도함수를 사용하지 않고 자료에서 직접 추출하는 비모수적(non-parametric) 방법을 사용하기 때문에 Semi-parametric weather generator로 분류된다. 수문학분야에서 비모수적 자료 발생기법은 경험적 분포에서 바로 추출하는 가장 간단한 방법부터(e.g., Semenov and Porter, 1995), data annealing (Bárdossy, 1998), 신경망 기법(Trigo and Palutikof, 1999), kernel density estimator (Rajagopalan et al., 1997) 등 오래전부터 많은 방법이 제안되어 왔다. Weather bootstrappers는 Young (1994)의 가장 간단한 방법에서 Lall and Sharma (1996)의 k-NN bootstrapper, 이후 다지점 발생기법(Yates et al., 2003)으로 연결되었는데 Appipattanavis et al. (2008)는 Lall and Sharma (1996), Rajagopalan and Lall (1999), and Buishand and Brandsma (2001)로 이어진 전통적인 방법을 더 개선한 모형이다.

먼저, 폭염이나 강수의 일단위 발생(occurrence)은 앞서 설명한대로 전이확률에 기반을 두는 간단한 1차 Markov chain을 시계열을 이용한다(Figure 14). 전이확률은 시간이 t_1 에서 t_2 로 변할 때 폭염이나 강수가 발생하거나 멈출 조건부 확률이다. 즉,

$$f(x_i|x_{i-1}, S_i, S_{i-1}) \quad [2]$$

여기서, S_i 와 S_{i-1} 는 강수나 폭염의 발생 state인데 본 연구에서는 1개의 Threshold T_{90} 을 사용하기 때문에 2개의 state, 0 아니면 1을 의미한다. 따라서 2-state 1차 Markov chain의 전이확률은 전날에 폭염이 발생하지 않았을 때 폭염이 발생하지 않을 확률 ($0 \rightarrow 0$; P00), 전날에 폭염이 발생하지 않았을 때 폭염이 발생할 확률 ($0 \rightarrow 1$; P01), 전날에 폭염이 발생했을 때 폭염이 발생하지 않을 확률 ($1 \rightarrow 0$; P10), 전날이 폭염이 발생했을 때 폭염이 발생할 확률($1 \rightarrow 1$; P11) 개의 조건부 확률로 구성된다. 폭염이 발생할 확률과 발생하지 않을 확률의 합은 1이기 때문에 $P00+P01=1$, $P10+P11=1$ 은 항상 만족되어야 한다. Appipattanavis et al. (2008)에서는 강수 발생 시계열을 dry, wet, extremely wet 3개의 state로 나눈 3-state Markov chain을 사용하였지만 T_{max} 는 하루 최고 기온을 의미하고 T_{90} 은 그 중 90 percentile을 의미하기 때문에 extreme heat의 기준을 적용하고 있는 것으로 판단하고 2-state 모형으로 더 간략화 하였다. 3 state 모형을 T_{max} 시계열에 적용할 경우 폭염의 정의가 단계적으로 변할뿐아니라 세계기상기구의 폭염 기준과의 일관성도 모호해 지는 단점을 가지게 되어 오히려 분석에 좋지 않을 것으로 판단하였다.

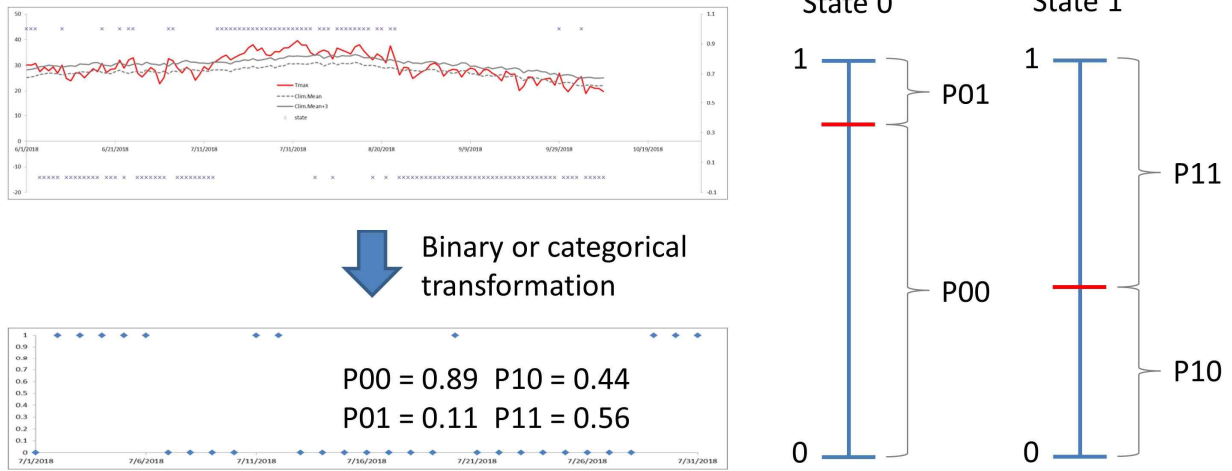


Figure 14. Transformation of Tmax time series to the binary occurrence series of 1 for Tmax > T90 and 0 for otherwise. If 3 states are used for the transformation, the state series should become categorical such as 0, 1, and 2 with transition probabilities being 3×3.

P00, P01, P10, P11 값에 0과 1사이에서 발생시킨 무작위수를 반복적으로 적용하면 원하는 길이만큼의 Binary state 시계열이 생성된다. Binary 시계열이기 때문에 폭염 발생유무와 지속성만을 알 수 있는 정보이고 폭염 강도 정보를 위해서는 추가적으로 Binary 폭염 발생시계열과 관련된 Tmax를 추출해야 한다. Appipattanavis et al. (2008)은 3-state Markov chain으로 발생시킨 강수 발생 시계열과 관련된 강수량 샘플링을 위해 k-NN 방법을 사용하였고 본 연구에서도 동일한 방법으로 Tmax를 샘플링 하였다. 특정일에 대한 폭염발생 시계열이 0→1 전환된 경우라면 그 날을 중심으로 하는 15일 window 안에서 0→1으로 전환된 모든 Tmax 쌍을 샘플링한 후 첫날의 Tmax나 함께 관측된 다른 기상관측치들을 Euclidean distance를 구해 짧은 순에서 긴 순으로 정렬한 후 다음의 Kernel 값을 구한다.

$$K[j(i)] = \frac{1/j}{\sum_{j=1}^k 1/j} \quad [3]$$

여기서, j는 Euclidean distance로 얻어진 순위를 의미한다. Kernel 함수 값은 추출확률을 의미하고 Euclidean distance가 가장 짧은 샘플이 가장 큰 발생확률을 가지는 것을 의미한다. 경험적으로 n개의 샘플을 추출하였다면 \sqrt{n} 에 해당하는 순위까지만 고려하여 K값을 구하고 다시 한 번 0과 1 사이의 무작위수를 발생시켜 고려된 샘플중 하나를 골라낸다. 예를 들어 30년 자료가 있다면 7일 윈도우를 사용할 때 추출할 수 있는 샘플이 7×30=210개가 있고 이중 0→1전환이 1/4정도라면 50개가 추출되는데 50개를 모두 사용할 경우 Kernel 함수의 의미가 사라지기 때문에 그 중 거리가 가까운 7개 중 하나를 선택하는 것이다. Lall and Sharma (1996)는 이 kNN방법이 간단해 보이지만 통계치 재생산에 상당한 성능으로 이미 평가하였고 다른 연구에서도 유사한 결과가 나타났다 (Rajagopalan and Lall, 1999; Yates et al., 2003).

그러나 본 연구에서는 유사해를 선택할 때 먼저 39개 해중 \sqrt{n} 의 기준으로 6개를 선택하

기 때문에 K값을 정렬할 때 \sqrt{n} 을 한 번 더 적용하지는 않았다. 유사해 선택으로 인해 이미 T_{max} 샘플이 상당히 많이 줄어들었기 때문에 여기서 한번 더 \sqrt{n} 기준을 적용하게 되면 샘플링된 T_{max} 의 변동성이 줄어드는 문제가 발생한다. 유사해의 T_{max} 변동성을 보존하기 위한 의도적 생략이라 할 수 있다. kNN 방법으로 샘플링되는 T_{max} 모두 어떤 관측시점의 기록이기 때문에 같은 시점에 같은 지점에서 관측된 다른 변량을 함께 샘플링하면 다변량 발생이 되고 같은 시점에 관측된 지점 들의 T_{max} 를 함께 샘플링하면 다지점 발생이 된다. 발생에 사용된 T_{max} 값은 종관관측지점의 평균치이고 샘플링된 시점에 관측된 모든 지점자료를 함께 추출하면 T_{max} 의 공간상관이 자동적으로 재생산되면서 지점별 T_{max} 값이 생성된다.

본 연구에서 사용된 Markov chain 기반 T_{max} 샘플링은 가장 간단한 형태의 추계학적 기법이라 할 수 있고 완전히 자료기반이기 때문에 관측되지 않은 T_{max} 의 변동성을 확인하는 것은 불가능하다. 하지만 T_{max} 샘플링 이전에 수행하는 상관분석 기반 유사해 선정과정에서 T_{max} 의 평균값은 유사해들의 조합에 따라 크게 변할 수 있다. 다시 말하면 유사해 조합에 의한 폭염위험 평가기법이라 할 수 있다. 만약 선정된 유사해의 T_{max} 가 관측기간 평균보다 높다면 Figure 15에 나타낸 것처럼 P10보다 P11의 확률이 높아지게 되고 높은 T_{max} 관측들이 kNN 방법에 의해 추출되게 된다.

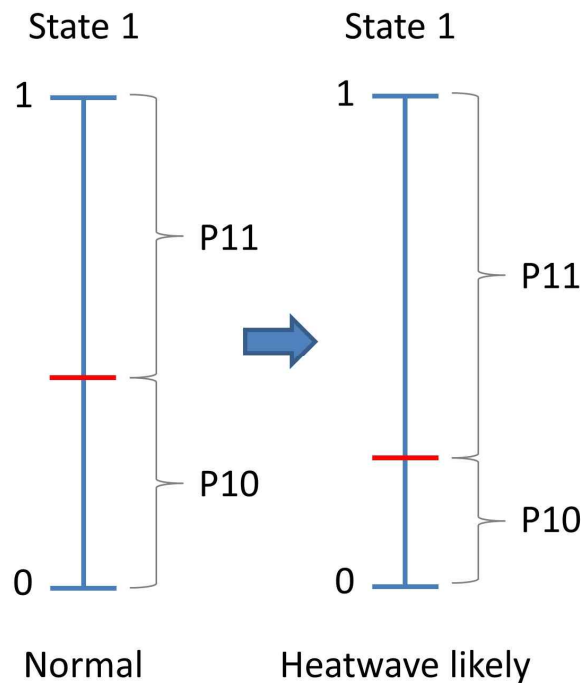


Figure 15. A probable change in P10 and P00 when assuming that hot years are selected for neighbor years.

(2) 기계학습모델을 이용한 흑서기 이상기후 3개월 확률전망정보 생산

(가) 흑서기 이상기후 발생과 주요 기후인자의 통계적 상관성

① 전국 및 지역별 혹서기 이상기후지수 통계 분석

이상기후지수 산정 및 통계 분석을 위해 우리나라 중관기상관측(ASOS) 47개(전국 45개와 제주도 2개) 지점 일별 최고, 평균 및 최저 기온자료를 1973년 1월 1일 이후의 기간에 대해 수집하였다.

혹서기 이상기후는 아래와 같이 세계기상기구(WMO)의 ET-SCI (Expert Team on Sector-specific Climate Indices) 지수와 우리나라 기준을 고려한 지수를 검토하여 선정하였다.

- SU (Summer days): Number of days when TX (Daily Maximum Temperature) > 25°C
- TR (Tropical nights): Number of days when TN (Daily Minimum Temperature) > 20°C
- TXx (Max TX): Warmest daily TX
- WSDI (Warm spell duration indicator): Annual number of days contributing to events where 6 or more consecutive days experience TX > 90th percentile
- WSDI3 (User-defined WSDI): 6일 이상의 기준으로 도출된 이상기후의 빈도가 낮아 3일 이상의 기준을 사용하여 비교 평가
- TXge30 (TX of at least 30°C): Number of day when TX \geq 30°C
- TXge35 (Tx of at least 35°C): Number of days when TX \geq 35°C
- TXdTNd (User-defined consecutive number of hot days and nights): Annual count of d consecutive days where both TX > 95th percentile and TN > 95th percentile, where $10 \geq d \geq 2$ (d = 3의 기준을 이용하여 산정)
- TNx (Max TN): Warmest daily TN
- TMm (Mean TM): Mean daily mean temperature; TM: Daily Mean Temperature
- TXm (Mean TX): Mean daily maximum temperature
- TNm (Mean TN): Mean daily minimum temperature
- TX90p (Amount of hot days): Percentage of days when TX > 90th percentile
- TN90p (Amount of warm nights): Percentage of days when TN > 90th percentile
- HWN (Heatwave number, EHF(Excess Heat Factor)/Tx90/Tn90): EHF, Tx90, Tn90을 각각 이용
- HWF (Heatwave frequency, EHF/Tx90/Tn90)
- HWD (Heatwave duration, EHF/Tx90/Tn90)

- HWM (Heatwave magnitude, EHF/Tx90/Tn90)
- HWA (Heatwave amplitude, EHF/Tx90/Tn90)
- TXge33 (TX of at least 33C, Mon/Ann, days): Number of day when TX \geq 33C, 우리나라 기준을 이용

이 중 폭염지수인 HWN, HWF, HWD, HWM, HWA 산정 시 사용되는 기준으로는 EHF (Excess Heat Factor), TX90p, TN90p가 있는데 EHF 계산 시에는 기준 기간(1981~2010년의 30년 기간 사용)의 모든 날(1.1.~12.31.)의 일간 자료를 이용하나, TX90p, TN90p의 경우에는 15일 윈도우를 이용한다(기준기간 30년 x 15일). 이 5가지 지수를 제외한 백분위 역치를 이용하는 이상기후지수들은 5일 윈도우 이용한다(기준기간 30년 x 5일). 온도의 백분위 기반 지수를 사용하는 경우 이상기후지수 시계열을 산정하는데 해당 연도가 기준 기간에 속하는 경우 샘플링 오차로 인해 기준 기간의 시작과 끝 부분에 비연속적인 구간이 발생하며, 이로 인해 거짓 추세 등이 나타날 수 있다. 따라서 Zhang et al. (2005)이 제안한대로 부트스트랩(Bootstrapping) 기법을 이용한 샘플링을 적용하여 인위적인 불연속성을 제거할 수 있도록 프로그램 코드를 작성하였다.

전국(제주도, 북한제외) 및 각 지역(제주도 및 북한제외 9개 지역)에 대해 ASOS 지점 이용 티센망을 각각 구축하여 지점별 면적 가중치를 산정하였다. 제주도 분석을 위해 1973년부터 자료가 가용한 2개 지점을 추가하고(제주 184, 서귀포189), 제주도 지역에 대한 티센망 구축하여 지점별 면적 가중치를 산정하였다. 각 지역에 대해 티센망을 이용하여 지역평균 일별 최고, 최저 및 평균온도 시계열 자료를 구축하고 이상기후지수를 산정하는 경우와, 지점별로 이상기후지수를 산정하고 티센망을 이용하여 지역평균 이상기후지수를 산정하는 경우를 비교 검토하였다.

② 혹서기 이상기후 발생과 주요 기후인자의 상관성 분석

혹서기 이상기후 발생과 주요 기후인자의 상관성 분석을 위해 전국 혹서기 이상기후 발생에 영향을 주는 기후인자에 대한 문헌조사를 실시하였다. 특히 우리나라 과거 기온 및 강수량의 극값 사례(임슬희, 2018; 임슬희, 2019)와 장기예보 가이드스 III(2018)를 중심으로 우리나라 혹서기 고온에 영향을 주는 기후인자와 기작을 검토하여 다음과 같은 예측인자 자료를 수집하였다. 다음과 같은 예측인자 자료를 1979년 이후의 기간에 대해 수집하였으며 기준기간(1981-2010) 평균을 이용하여 편차의 시계열을 산정하였다.

- 장파복사 (NOAA NCEP CPC GLOBAL monthly olr), 자료 출처: IRI Climate Data Library (<https://iridl.ldeo.columbia.edu/>)
- 해수면온도(ERSST v5), 자료 출처: NOAA Physical Sciences Laboratory (<https://psl.noaa.gov/>)
- 강수(GPCP), 자료 출처: NOAA Physical Sciences Laboratory (<https://psl.noaa.gov/>)

- 눈덮임(NCEI): 주별 자료를 수집하여 월별 자료로 변환, 자료 출처: NOAA National Centers for Environmental Information (<https://www.ncei.noaa.gov/>)
- 850hPa 지위고도(NCEP1 재분석 자료), 자료 출처: NOAA Physical Sciences Laboratory (<https://psl.noaa.gov/>)
- 500hPa 지위고도(NCEP1 재분석 자료), 자료 출처: NOAA Physical Sciences Laboratory (<https://psl.noaa.gov/>)
- 해빙(NSIDC): Concentration 고려한 자료, 자료 출처: NOAA National Snow & ice Data Center (<https://nsidc.org/>)

NOAA에서 제공하는 대기해양 예측인자와 이상기후지수와의 상관성도 분석하였다. 사용된 대기해양인자는 아래와 같다(자료 출처: <https://esrl.noaa.gov/psd/data/climateindices/list/>).

- NAO (North Atlantic Oscillation)
- EA (East Atlantic Pattern)
- WP (West Pacific Pattern)
- EP/NP (East Pacific / North Pacific Pattern)
- PNA (Pacific North American Index)
- EA/WR (East Atlantic / West Russia Pattern)
- SCA (Scandinavia Pattern)
- TNH (Tropical / Northern Hemisphere Pattern)
- POL (Polar / Eurasia pattern)
- PT (Pacific Transition Pattern)
- PDO (Pacific Decadal Oscillation)
- QBO (Quasi-Biennial Oscillation)
- SOI (Southern Oscillation Index)
- AO (Arctic Oscillation)
- Niño 1+2 (Extreme Eastern Tropical Pacific SST)
- Niño 4 (Central Tropical Pacific SST)
- Niño 3.4 (East Central Tropical Pacific SST)

- ONI (Oceanic Niño Index)
- Niño 3 (Eastern Tropical Pacific SST)
- TNI (Trans-Niño Index)
- WHWP (Western Hemisphere warm pool)
- TNA (Tropical Northern Atlantic Index)
- TSA (Tropical Southern Atlantic Index)
- AMO (Atlantic Multi-decadal Oscillation)
- AMM (Atlantic Meridional Mode)
- NTA (North Tropical Atlantic Index)
- CAR (Caribbean SST Index)

장기예보 가이드선의 예측인자와 NOAA의 대기해양 예측인자 모두 선행시점을 전년도 12월부터 목표시점 - (예측의 LT + 1)개월까지로 설정하였으며 상관성 분석은 1980-2020의 41년의 기간에 대해 수행하였다.

③ 흑서기 이상기후 발생과 지역별 기후 및 공간정보의 상관성 분석

원격 예측인자의 우리나라 흑서기 이상기후 발생에 대한 영향은 전국적으로 비슷할 수 있으나, 지역별 이상기후 발생은 이러한 원격 예측인자의 영향과 여러 다양한 국지적인 공간적 요인과의 상호작용으로 다르게 나타날 수 있다. 고정되어 있는 위도, 경도의 위치요인과 고도, 경사, 향의 지형요인, 강수 및 온도의 기후 값, 그리고 시간적으로 변화하면서 기온과 상호작용하는 토양수분과 식생의 상태를 이용하여 지역별 이상기후 발생의 차이가 이러한 요인들로 설명될 수 있는지 다중회귀분석과 이상기후 지수와의 상관성 분석을 통해 검토하였다. 이를 위해 지역별 기후 및 공간정보를 아래와 같이 수집하고 전처리하였다.

- 위치요인: 위도, 경도는 각 지역에 대해 0.05 x 0.05 해상도 그리드로 생산하여 UTM Zone 52N 좌표계로 reproject하여 zonal average함
- 지형요인: 고도는 GTOPO30 자료로 수집하였으며(자료 출처: USGS (<https://www.usgs.gov/>)) 이로부터 경사(slope), 향(aspect)를 QGIS 소프트웨어를 이용하여 산정하고, 고도, 경사, 향에 대해 0.05 x 0.05 해상도 그리드로 resample하여 지역별로 zonal average함
- 기후값: 강수 및 온도 기후 값은 47개 ASOS 지점에서 10개 지역별, 또는 전국에 대해 평균한 값을 이용하여 월별로 산정

- 최근 토양수분: 2015년 4월~2020년 2월에 대해 SMAP L4 monthly geophysical data rootzone (1m vertical average) soil moisture의 3-hourly 자료를 earthdata에서 수집하여 월별로 전환하고 0.05 x 0.05 해상도 그리드로 resample, UTM 52N 좌표계로 reproject하여 zonal average함
- 과거 토양수분: 1948년 1월~2014년 12월 GLDAS Noah Soil Moisture 자료 V2.0 수집하고 2000년 1월~2019년 12월까지 V2.1 자료 수집하였으며 'SoilMoi0_10cm_inst', 'SoilMoi10_40cm_inst', 'SoilMoi40_100cm_inst'를 이용하여 1m까지의 rootzone soil moisture 구함. 나중에 최근 자료를 SMAP 이용하여 사용할 수 있도록 linear scaling 방법으로 GLDAS 자료를 bias correction하고 resample, reproject, zonal average함
- 최근 식생지수: MODIS Terra 위성의 MOD13C2 자료를 2000년 2월~2020년 2월까지 earthdata에서 수집하였으며 resample, reproject, zonal average함
- 과거 식생지수: 과거 자료는 NASA에서 연구 목적으로 1981년~2014년까지 제공하는 VIP30 자료를 수집. 토양수분과 마찬가지로 linear scaling 이용하여 VIP30 자료를 bias correction하고 resample, reproject, zonal average함

월별, 지수별 입력 자료를 구축하고 다중회귀분석을 수행하였다. 전국 평균 또는 각 지역의 지수 편차와 토양수분, 식생지수, 강수 및 온도(TXm을 보는 경우 최고온도, TNm을 보는 경우 최저온도, TMm을 보는 경우 평균온도 사용) 기후 값, 위도, 경도, 고도, 경사, 향의 경우 각 지역의 편차와 전국 편차의 차를 입력 변수로 이용하였다. 전국 및 지역에 대해 목표변수는 해당 지역의 지수 편차, 입력 변수는 전국의 경우는 전국 평균한 지수의 편차, 토양수분 편차의 차(지역 편차 - 전국 편차), 식생지수 편차의 차(지역 편차 - 전국 편차)와 함께 강수 및 온도의 기후 값의 편차의 차, 위도, 경도, 고도, 경사, 향의 편차의 차, 그리고 지역의 경우는 전국 평균한 지수의 편차, 토양수분 편차의 차(지역 편차-전국 편차), 식생지수 편차의 차(지역 편차 - 전국 편차)로 설정하였다.

(나) 가우시안 프로세스를 이용한 전국 및 지역별 흑서기 이상기후지수 3개월 전망정보 생산

① 확률전망정보 생산을 위한 관측기반 기후인자 입력자료 구축

장기예보 가이드스에서 제시한 변수와 지역을 기반으로 도출한 예측인자와 NOAA에서 제공하는 대기해양 인자를 기반으로 도출한 예측인자를 통합하여 지역별, 이상기후지수별, 월별, 선행시간별 흑서기 이상기후지수 전망 모델을 위한 입력 자료를 구축하였다. 선정된 변수를 모두 사용하는 경우와 다중공선성 큰 입력변수를 제거하고 활용하는 경우 각각 테스트하였다. 다중공선성 제거는 이상기후지수별, 월별, 선행기간별로 선정된 입력변수를 군집분석을 통해 (Hierarchical Clustering Methods 중 Ward's method 사용) 그룹으로 묶고 사용되는 모든 변수의 Variance Inflation Factor가 5.0 이하가 되도록 Dendrogram에서 그룹간의 비유사성을 나타내는 거리의 역치를 0부터 0.1씩 증가시키며 VIF 큰 입력변수를 제거하였다(Figure 16). 처리시간을 단축하고자 예측인자의 변수별로 인자 선별을 1차로 수행하고, 감소한 인자들을 모아 전체적으

로 2차 선별을 수행하였다.

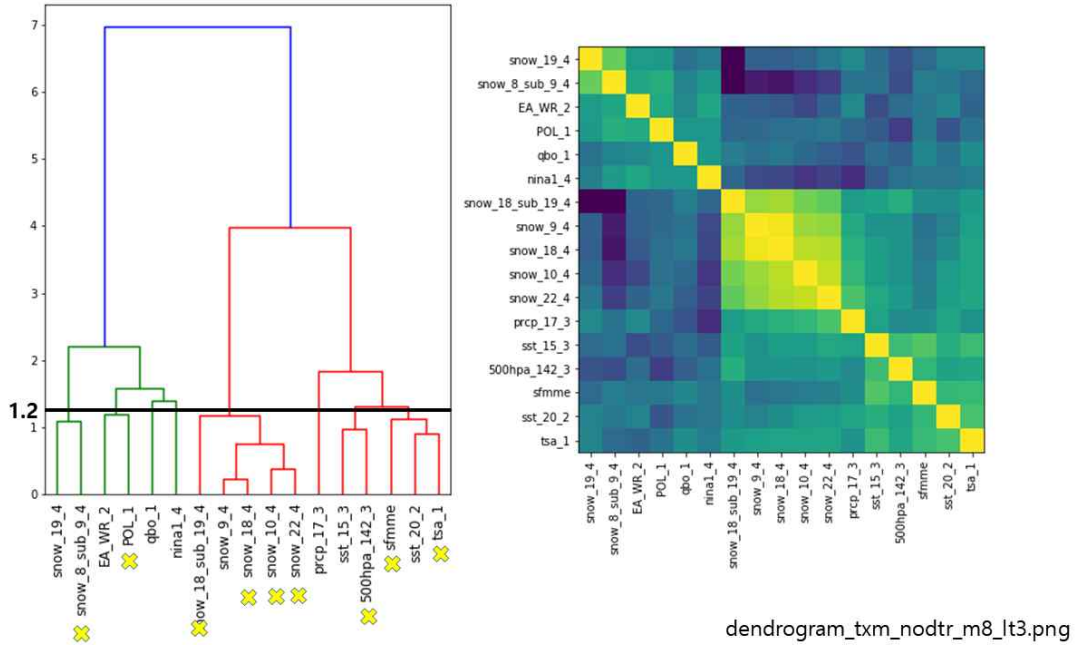


Figure 16. Eight input variables are selected out of 17 using a dendrogram for August TXm (LT=3).

② 기계학습모델 검토 및 선정

베이지안 방법론은 구하고자 하는 종속변수 y 에 적합하다고 여겨지는 함수 $f(x)$ 의 모수(예를 들어, 1차 선형함수를 고려하는 경우 계수 θ_1, θ_2)에 대한 확률분포를 찾아내고자 하는데, GP는 비모수적 베이지안 방법으로서, 종속변수 y 에 적합한(즉, 관측자료와 일관된) 모든 가능한 함수 $f(x)$ 에 대한 확률분포를 찾고자 한다. 가우시안 프로세스(Gaussian Process, GP)는 (실수 값을 가지는 N 개의 한정된 입력변수가 있을 때) 임의의 위치 x_1, \dots, x_n 에서의 확률변수(random variable) $f(x_1), \dots, f(x_n)$ 의 가우스 결합확률분포인 $p(f(x_1), \dots, f(x_n))$ 로 정의되는 확률과정(random process, stochastic process)이다.

GP 사전분포(prior)는 다음과 같은 다변수 정규분포로,

$$p(f|X) = N(f|\mu, K) \tag{4}$$

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

m 은 평균함수이며(보통 $m(x_n) = 0$ 으로 설정하거나 훈련자료의 평균 값으로 설정) k 는 양의 정부호(positive definite) 공분산(또는 kernel) 함수로, GP의 모양이 K 에 의해 결정된다. 확률변수 $f(x_1), f(x_2)$ 두 개의 결합확률분포를 생각하면 kernel k 에 의해 (x_{1i}, x_{2i}) 와 (x_{1j}, x_{2j}) 가 가

까우면, 이 위치에서의 $p(f(x1i), f(x2i)), p(f(x1j), f(x2j))$ 도 가깝다.

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

$$\begin{pmatrix} y \\ f_* \end{pmatrix} \sim N\left(0, \begin{pmatrix} K_y & K_* \\ K_*^T & K_{**} \end{pmatrix}\right) \quad [5]$$

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

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

$$p(f_*|X_*, X, y) = \int p(f_*|X_*, f)p(f|X, y)df = N(f_*|\mu_*, \Sigma_*), \quad [6]$$

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

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

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

- Vertical variation parameter σ_f : 함수의 vertical variation을 제어하는데, σ_f 가 커지면 훈련자료의 범위 밖으로 더 넓은 신뢰 구간을 가지게 됨
- Length parameter l : 함수의 매끄러운 정도(smoothness)를 제어하는데, l 이 커지면 더 매끄럽게 훈련자료에 대해 거칠게 예측을 하며 l 이 작으면 좀 더 구불구불하게 훈련자료 사이에 넓은 신뢰 구간을 가지도록 됨
- White kernel의 Noise parameter σ_y : 별도로 alpha를 설정하거나 RBF kernel에 white noise kernel을 더하여 훈련자료의 global noise 수준을 설정할 수 있음. σ_y 가 커지면 noise가 많은 자료에 과적합을 피하며 coarse한 예측을 할 수 있음. Tikhonov regularization (L2 regularization)와 같이 작용함.

우도함수는 주어진 입력자료와 kernel parameters로부터 관측 y 를 얻을 확률이므로 LML(log marginal likelihood)를 최대화하는 값으로 선정한다. 시각적으로 살펴보기 위해 $\sigma_f=1$ 인 경우 l 과 σ_y 의 변화에 따른 -LML의 변화를 살펴보면 다음 <Figure 17>와 같다.

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

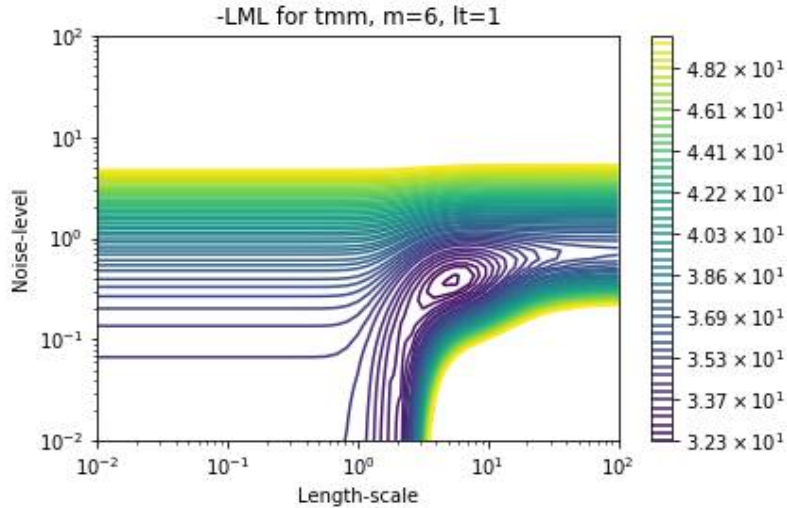


Figure 17. Optimizing Kernel parameters for June TMM (LT=1): the length parameter of 7.78, noise parameter of 0.17, and vertical variation parameter of 1.26 are selected here minimizing the negative Log Marginal Likelihood.

③ 전국 및 지역별 흑서기 이상기후지수 3개월 확률전망정보 생산

다음과 같이 입력변수의 구성을 다양화하여 확률전망정보의 예측성능을 6월 LT1, 7월 LT2, 8월 LT3 예측에 대하여 비교하였다.

- 장기예보 가이드ন্스의 예측인자와 선행감시시점을 이용한 모델(GD);
- 장기예보 가이드ন্스의 예측인자와 선행감시시점을 이상기후지수와의 상관관계를 이용하여 선정한 모델(GD_MOD);
- 군집분석을 통해 도출한 예측인자를 이용한 모델(CL);
- 군집분석 도출 예측인자의 주성분을 이용한 모델(CL_PC)

이 중 군집분석을 통해 예측인자를 도출하는 방법은 장기예보 가이드ন্스에서 활용한 해빙을 제외한 모든 변수(해수면온도, 강수, 장파복사, 500hPa 및 850hPa 지위고도, 눈덮임)에 대하여 각 격자에 대해 해당 변수와 이상기후지수(TXm, TMM, TNm)의 1980-2020 기간에 대한 상관관계를 구하고 이를 군집화하였다. 이 경우 검증에 사용된 해를 제외하지 않고 모두 이용하였으므로, 실시간 예측의 경우 성능이 떨어질 수 있으나 큰 차이가 없을 것으로 가정하였다.

아래와 같이 인자별로 감시지역을 일부 제한하고(여러 단계를 거친 영향은 불확실성이 크므로) 작은 규모의 산발적인 지역이 선정되지 않도록 군집의 개수를 5개로 설정하였다. 도출된 군집 중 1980-2020의 41년 기간 중 validation year를 제외한 기간에 대해 각 군집의 예측인자와 이상기후지수와의 상관관계가 95% 신뢰도로 유의미한 군집만을 선정하여 모델에 활용하였다.

- 해수면온도: 남대서양 제외(0~90S, 240~360E), 서인도양 제외(30N~90S, 0~60E), 유라시아

제외(90~30N, 0~120E), 고위도 지역 제외(90~70N, 40~90S)

- 눈덮임: 북반구 중위도만 고려(60~30N, 0~180E)
- 강수와 장파복사: 30N~40S, 60~210E 지역만 고려
- 지위고도: 고위도를 제외한 북반구(70~0N)만 고려
- 작은 면적의 감시지역(2.5 x 2.5 격자로 15개 이하) 제외

적은 샘플 수(cross year validation이므로 40개의 샘플)에 비하여 인자를 선별하지 않는 경우 훨씬 많은 수의 입력 변수가 존재하는 단점을 극복하기 위해 주성분분석(Principal Component Analysis; PCA)을 이용하여 테스트는 군집분석으로 도출된 예측인자들로부터 전체 인자(feature)의 variance의 95%를 설명하는 개수의 주성분(PC)을 도출, 활용하였다.

모델의 예측결과는 정규분포를 따르므로 주어진 평균과 표준편차를 이용하여 확률밀도함수와 누적밀도함수 산정이 가능하다. 따라서 3분위(above normal, near normal, below normal)의 각 구간과 평년(1981-2010년), 90-퍼센타일, 전년도, 최근 5년의 평균, 2016년, 2018년에 대한 2분위의 각 구간에 대해 발생 확률을 제시할 수 있도록 시각화하였다(Figure 18). 또한 3분위, 2분위 각 구간에 대한 확률 제시 뿐 아니라 베이지안 신용도에 따른 예측구간을 제공할 수 있도록 표출 방안을 개선하였다(Figure 19).

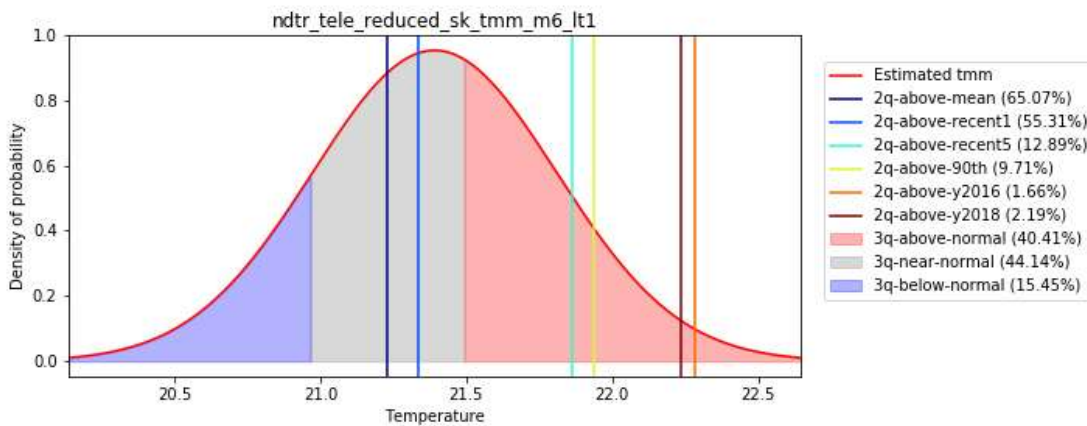


Figure 18. Probabilistic forecast results for June 2020 (LT=1).

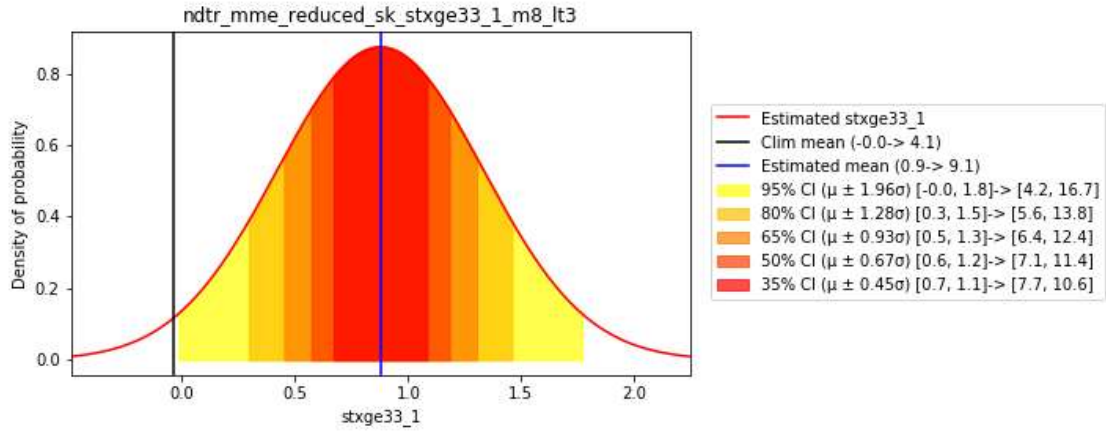


Figure 19. Credible interval of TXge33 for August.

예측인자의 중요도 평가를 위해 모델의 훈련 동안에 각 입력변수에 대해 permutation importance를 산정하는데 이는 각각의 입력변수에 대해 해당 변수의 값을 치환하여 훈련된 모델에 적용했을 때 평균제곱오차의 증가를 측정하여 드러난 변수의 중요도로 설명할 수 있다. 다중공선성을 제거하지 않은 경우에는 입력변수간의 상관관계가 높을 수 있으므로 중요도가 낮게 나타났다고 해서 중요도가 낮은 입력변수라고 할 수는 없으나 중요도가 높게 나타난 경우에는 실제로 중요한 변수임을 알 수 있다. 예측 원인 및 사후분석을 위해 중요도가 높은 입력변수에 대해 단순선형회귀를 통해 예측인자와 이상기후지수와의 상관관계를 분석할 수 있다 (Figure 20).

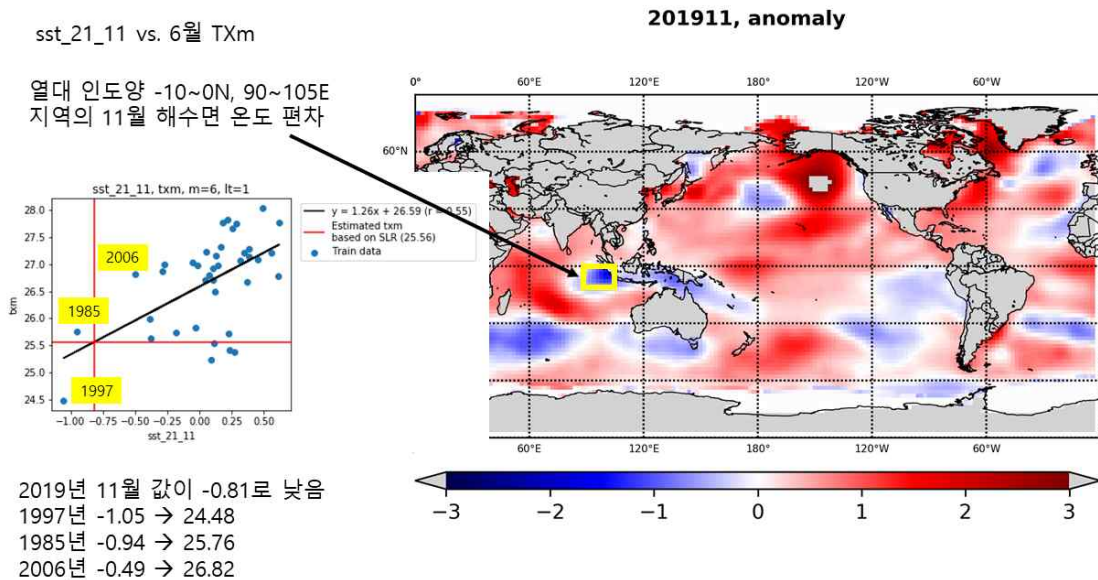


Figure 20. Analyzing correlations between predictors and climate extreme indices.

(다) 흑서기 이상기후지수 3개월 확률전망정보 표현방식 개발

① BMA (Bayesian Model Averaging)을 이용한 전망정보 결합

Raftery et al. (2005)의 방법에 따라 BMA를 적용하였다. $k=1, \dots, K$ 개의 모델이 있을 때 이들의 결합 PDF는 개별모델 PDF의 예측밀도(predictive density)의 가중 평균과 같다.

$$f(y|y_k, k=1, \dots, K) = \sum_{k=1}^K w_k f_k(y|y_k) \quad [9]$$

이때, y 는 관측값, y_k 는 모델 k 의 예측값, w_k 는 모델 k 의 가중치이며 가중치의 총 합은 1이 되어야 한다. 개별모델이 정규분포를 따른다고 할 때 앞서 말한 가중치와 각 개별모델 정규분포의 분산은 Expectation-Maximization(EM) 알고리즘을 이용하여 구할 수 있다. 다만 Raftery et al. (2005)에서는 단정론적 예측의 양상불을 결합하는 것이 목적이므로 BMA 분포의 분산도 추정하나, 본 연구의 경우 여러 확률예측 정보를 결합하는 것이 목적이며 이미 개별모델은 정규분포로 분산이 존재한다. 따라서 각 모델의 가중치만을 EM 알고리즘을 이용하여 구하여 결합하였다.

EM 알고리즘은 Expectation 단계와 Maximization 단계를 iteration하는 방법으로 Expectation 단계에서는 Latent variable인 z 를 산정한다.

$$z_{kt}^j = \frac{w_k^{j-1} f_k(y_t | f_{kt}, \sigma_k^{2,j-1})}{\sum_{k=1}^K w_k^{j-1} f_k(y_t | f_{kt}, \sigma_k^{2,j-1})} \quad [10]$$

이때, j 는 j 번째 iteration, $t=1, \dots, T$ 는 훈련자료, f_{kt} 는 k 번째 개별모델의 t 번째 훈련자료에서의 PDF의 확률밀도, σ_k 는 k 번째 개별모델의 표준편차이다.

Maximization 단계에서는 가중치 w 를 산정하며 로그우도함수 L 의 변화가 아주 작은 수 ($1e-8$)보다 작아지면 iteration을 멈춘다.

$$w_k^j = \frac{1}{T} \sum_{t=1}^T z_{kt}^j \quad [11]$$

$$L(w_1, \dots, w_k, \sigma_k^2) = \sum_{t=1}^T \log \sum_{k=1}^K w_k f_k(y_t | y_{kt}, \sigma_k^2) \quad [12]$$

② 삼분위 다이어그램을 이용한 이상기후 확률전망정보 표현

Jupp et al. (2012)의 방법대로 HSV (Hue-Saturation-Value) 색상 모델을 이용하여 삼분위 다이어그램을 만들어 확률전망을 표현하였다. HSV (Hue-Saturation-Value) 색상 모델의 Hue는 삼

각형에서 Above Normal을 나타내는 지점인 OA와 Climatology를 연결하는 지점인 Q를 이은 선과, 삼분위 예측 지점을 나타내는 P와의 각도를 이용하여 결정한다. Saturation은 Q와 P 사이의 cross entropy를 산정하여 여기에서 information gain을 산정하여 결정하며 Value는 1로 고정하여 삼분위 다이어그램을 완성시킬 수 있다(Figures 21, 22).

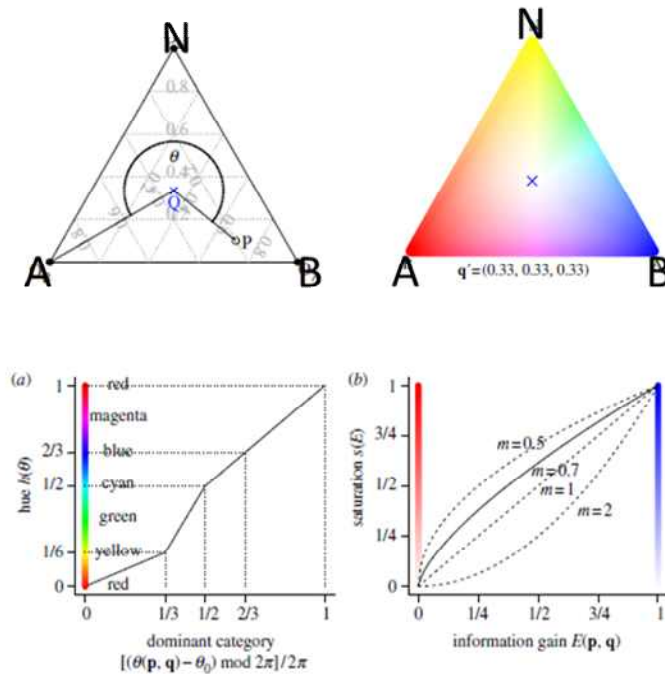


Figure 21. Determining HSV (Hue-Saturation-Value) color scheme's Hue and Saturation (Jupp et al., 2012).

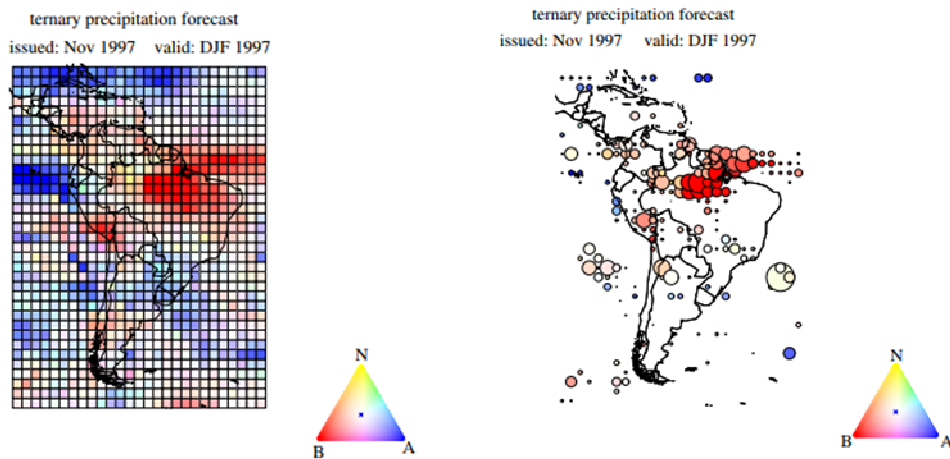


Figure 22. Visualization examples using the ternary diagram by Jupp et al.(2012).

(3) 3개월 기온 장기예보 개선안

(가) 자료수집

한반도 여름철 극한기온 확률예측성 평가를 위해 45개 표준관측지점 월최고기온, 월평균기온, 월최저기온을 1979년 부터 2019년 까지 수집하였으며, 각각의 9개 권역(Table 2)별 평균값 및 전체 평균값을 9개 권역별 및 한반도의 월최고기온, 월평균기온, 월최저기온 값으로 산정하였다. 권역별 한반도의 폭염을 정의하기 위해 사용한 45개 표준지점은 Table 2와 같다. 9개 권역은 경기(GG), 경남(GN), 경북(GB), 영동(YD), 영서(YS), 전남(JN), 전북(JB), 충남(CN), 충북(CB)이며, 영서에 2개 표준관측지점으로 가장 적은 관측지점수를 보였으며, 경북이 10개 관측지점으로 가장 많은 관측지점수를 보유하고 있는 것으로 나타났다.

한반도 여름철 극한기온 확률예측성 평가를 위해 국립기상과학원으로부터 5월, 6월, 7월에 예측한, 6월, 7월, 8월의 GloSea5의 예측자료와 hindcast 자료를 제공받았다. 또한, GloSea5의 한반도 여름철 극한기온 확률예측성을 비교하기 위해, 위의 월별 ECMWF 예측자료를 WMO 선도센터(WMO Lead Centre for Long-Range Forecast Multi-Model Ensemble, <https://www.wmolc.org/>)로부터 내려받기하여 사용하였다. hindcast기간은 GloSea5와 ECMWF가 각각 1991-2010, 1993-2016으로 상이하여, 중첩되는 기간(즉, 1993-2010)을 hindcast 기간으로 정하였다.

Table 2. Station IDs in each division.

Divisions	Station IDs
GG	108, 112, 119, 201
GN	152, 159, 284, 285, 288, 295
GB	130, 135, 138, 143, 272, 278, 279, 281
YD	90, 105, 211
YS	101, 212
JN	156, 165, 168, 170, 160, 261, 262
JB	146, 243, 245, 289,
CN	129, 235, 236, 238
CB	114, 131, 221, 226, 232

(나) 극한기후 확률예측추정기법

현재 기상청은 월평균기온의 기후평년값을 기준으로 평년값보다 높을 확률(Above Normal), 평년과 비슷할 확률(Near Normal), 평년보다 낮을 확률(Below Normal)로 3분위 예보를

발표하고 있다. 극한기온에 대해 확률예측을 위해, 3분위에 양극한(Extremely High: EH, Extremely Low: EL)을 하나씩 추가하여 5분위 예보 예측성 평가를 하였다. 양극한의 기준값을 정하기 위해, 10 퍼센타일, 15 퍼센타일, 20 퍼센타일과 80 퍼센타일, 85 퍼센타일, 90 퍼센타일 값에 대해 GloSea5와 ECMWF모형 예측의 AUC(Area under the Curve) 값을 비교하였다. 새로운 양극한의 기준값을 결정하는 방법은 Figure 23에 도시하였다. 먼저 10/15/20, 80/85/90 퍼센타일에 해당하는 GloSea5와 ECMWF모형 hindcast의 기온(Tavg, Tmax, Tmin) 누적분포함수(Cumulative Distribution Function, CDF, Figure 23에서 적색곡선)에서 각각의 기온값(예를 들어, Figure 23a의 T₃나 T₄)을 읽는다. 그 다음, 각 모형 예측 앙상블을 활용한 누적분포함수(Figure 23b의 녹색곡선)에서 각 온도에 대한 퍼센타일값을 읽어주면 된다. 이렇게 구한 예측확률을 관측과 비교하여 AUC값을 산정하고 최적의 극한 기준값을 선정하였다.

이와 유사한 방법으로 특정년도의 기온과 비교하여 높거나 낮을 확률값을 산정할 수 있는데, Figure 24에 해당 방법을 나타내었다. 먼저, 관측 hindcast CDF에서 특정년도의 기온값(T_{year})에 해당하는 퍼센타일값($F(T_{year})$)을 산정하고, 이를 활용하여 모형의 hindcast CDF에서 이 퍼센타일에 해당하는 기온값(\hat{T}_{year})을 읽는다(Figure 24의 ①). 그 다음, 이 기온값에 해당하는 퍼센타일 값($\hat{F}(\hat{T}_{year})$)을 모형의 예측 앙상블 CDF에서 산정한다(Figure 24의 ②). 이 때, 특정년도의 기온보다 높을 확률값은 $1-\hat{F}(\hat{T}_{year})$ 이며, 특정년도의 기온보다 낮을 확률값은 $\hat{F}(\hat{T}_{year})$ 가 된다. 이 방법으로 2020년 6월, 7월, 8월의 Tavg, Tmax, Tmin에 적용하였다. 이 연구에서는 이전년도와 최근 폭염이 심했던 두 해(2016년, 2018년)의 온도(Tavg, Tmax, Tmin)와 비교하여 높거나 낮을 확률예보를 하였다.

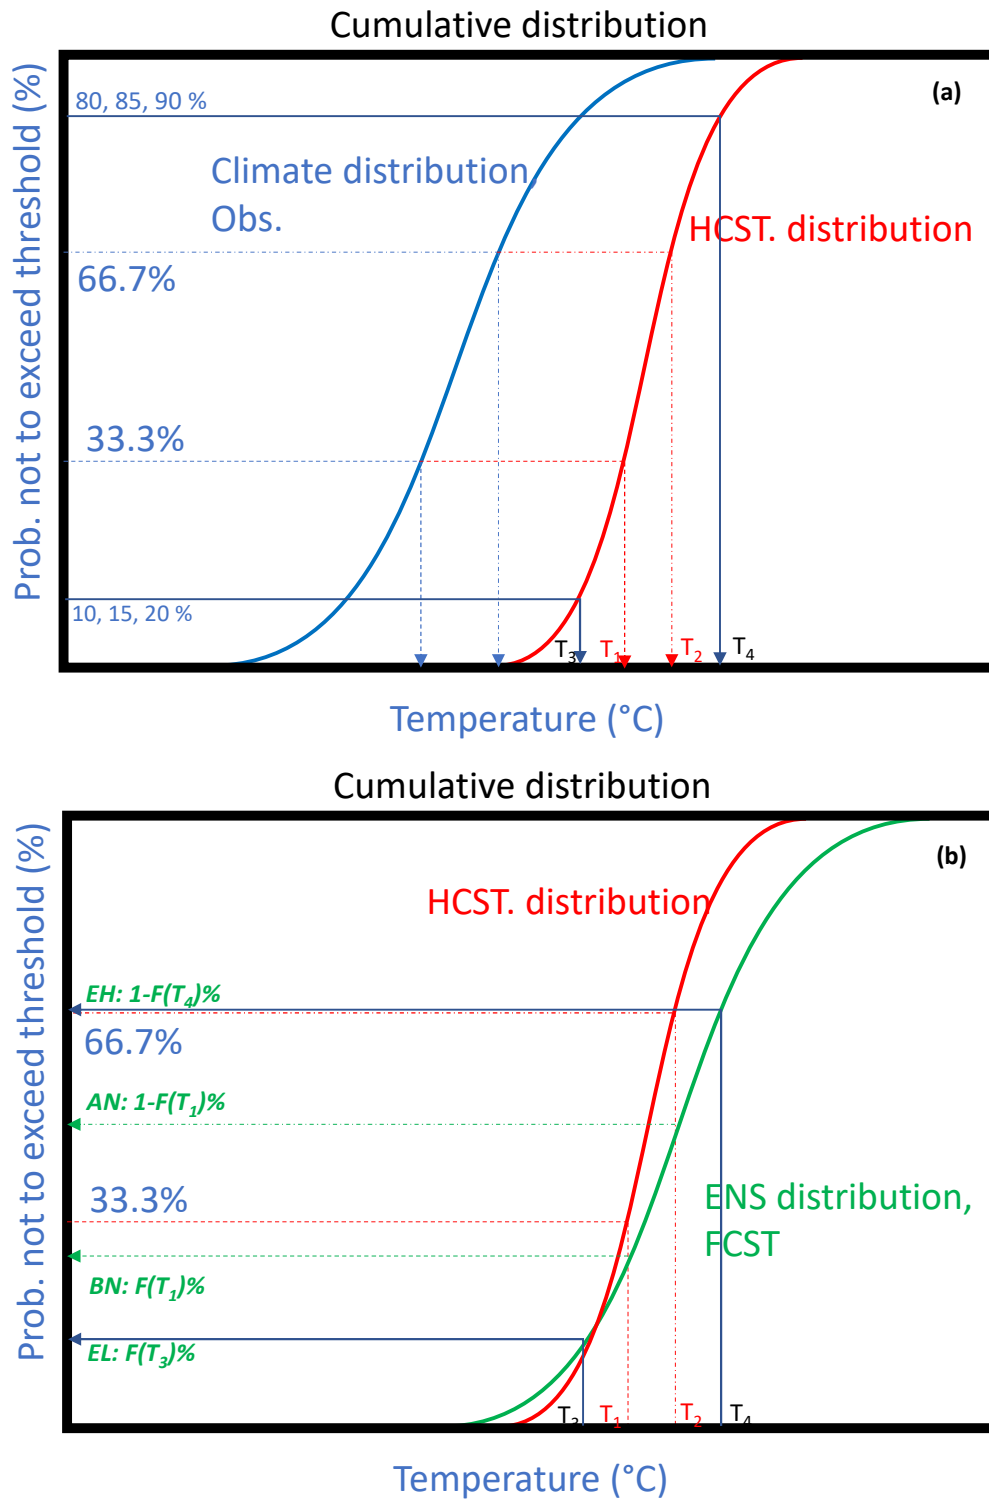


Figure 23. Procedures of the determination of climate extreme thresholds. CDF of the observed, hindcast, and forecast ((a) the observed and hindcast and (b) the hind and forecast CDF).

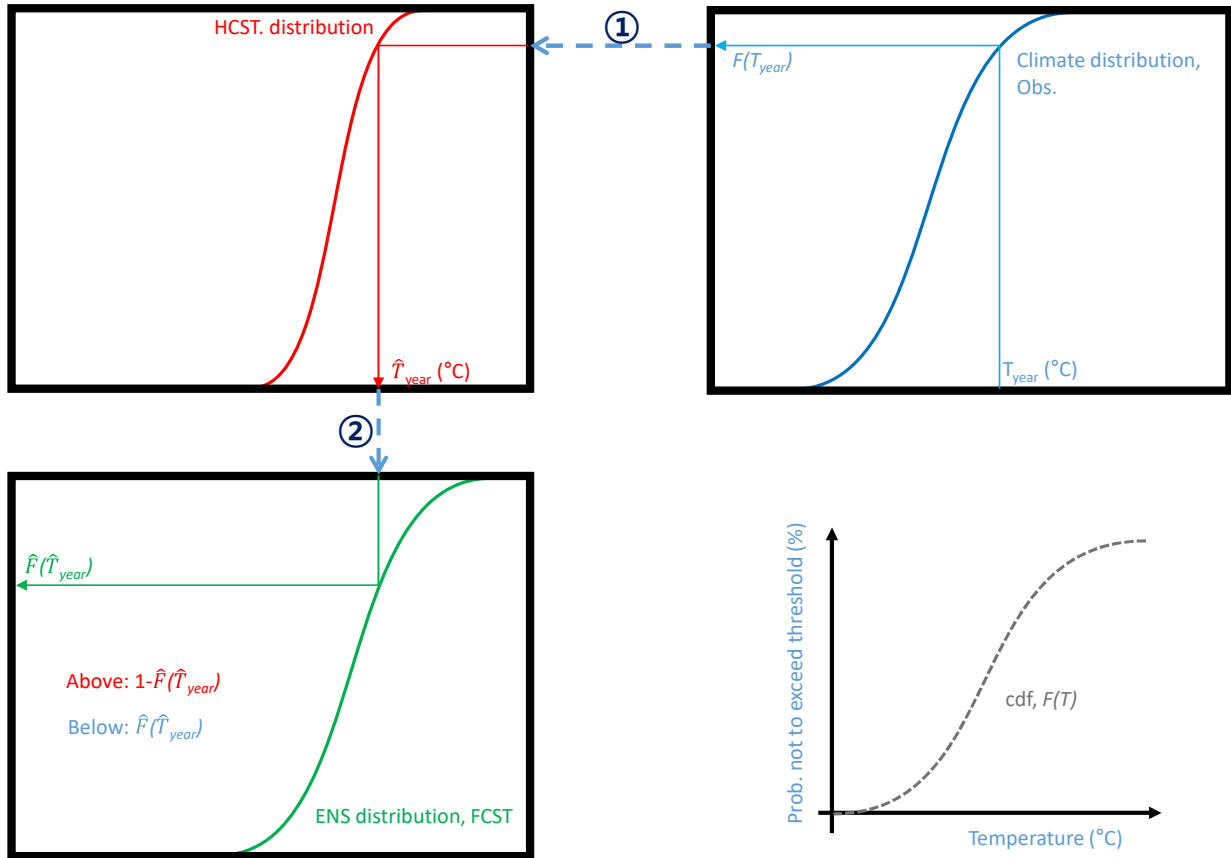


Figure 24. Procedure of calculating probabilistic forecasts compared to temperature in a selected year (last year, 2016, and 2018 for this study).

(4) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안 제시

(가) 국내의 유관기관 계절내 장기예보 현황

① 미국 NOAA-NCEP CPC(Climatic Prediction Center)

미국 기상청(NWS; National Weather Service)의 공식예보 체계는 0~48시간, 3~7일, 6~10일, 8~14일, 그리고 월별(monthly)예보, 계절(seasonal)예보로 이루어져 있으며, NCEP 산하 기후 예측센터(CPC)는 6~10일, 8~14일, 월별 예보, 계절예보를 생산하고 있다. 특히, 1개월(30일) 계절내 예보를 위해서 미국 전역의 월평균 기온과 강수에 대한 예보를 생산(Figure 25; <https://cpc.ncep.noaa.gov/products/predictions/30day/>)하고 있는데, 기온과 강수에 대한 3분위 확률(Above, A; Near-Normal, N; Below, B) 예보 자료를 제공한다. 기온과 강수에 대해 색깔로 구분하는데, 기온이 평년보다 높을 것으로 예상되는 경우 적색, 낮을 것으로 예상되는 경우 청색으로 구분하고, 강수량이 평년보다 많을 경우로 예상되는 경우 녹색, 적을 것으로 예상되는 경우 갈색으로 표시하여 제공한다.

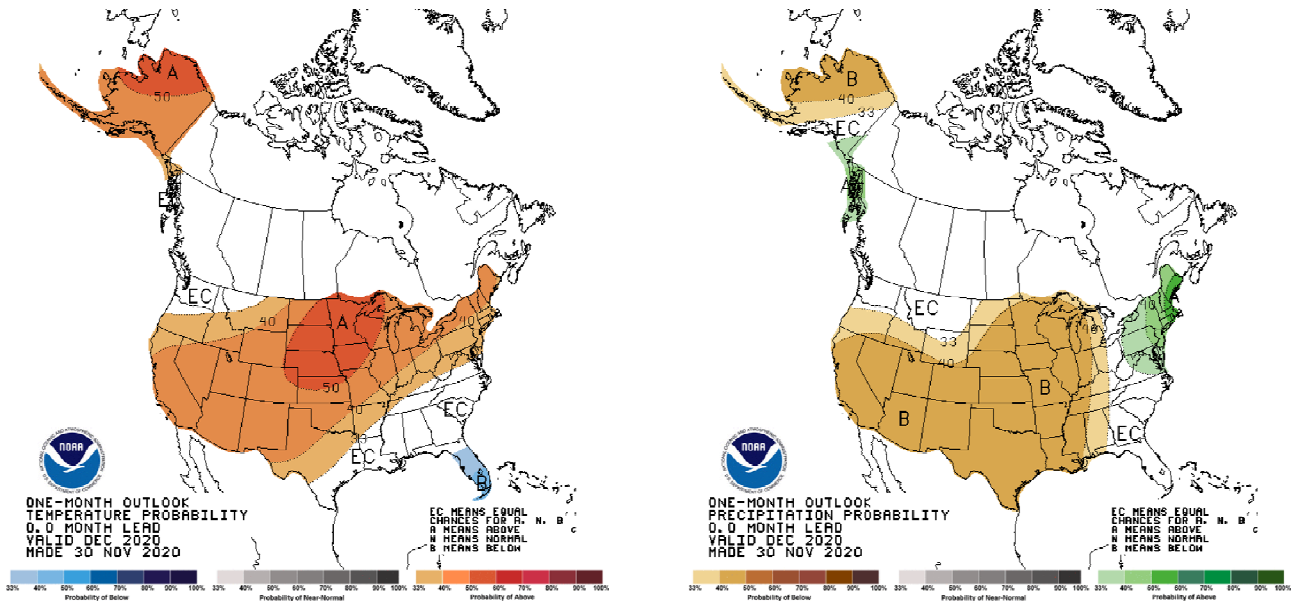


Figure 25. One month(30-day average) outlook for temperature(left) and precipitation(right) from NOAA CPC.

미국 CPC에서는 1개월 예보와 더불어, 3-4주 선행한 기온과 강수(시범제공)에 대해서도 예측자료를 제공한다(Figure 26). 3-4주 예보에 대해서는 2분위 예보를 하고 있는데, above와 below의 확률이 50% 일 때 equal-chance 로 예보한다. 특히, 기후예측에서 3-4주 예보는 예측성이 가장 낮은 기간으로, 3-4주를 포함한 계절내 예측 정확도를 높이기 위한 많은 연구가 이루어지고 있다.

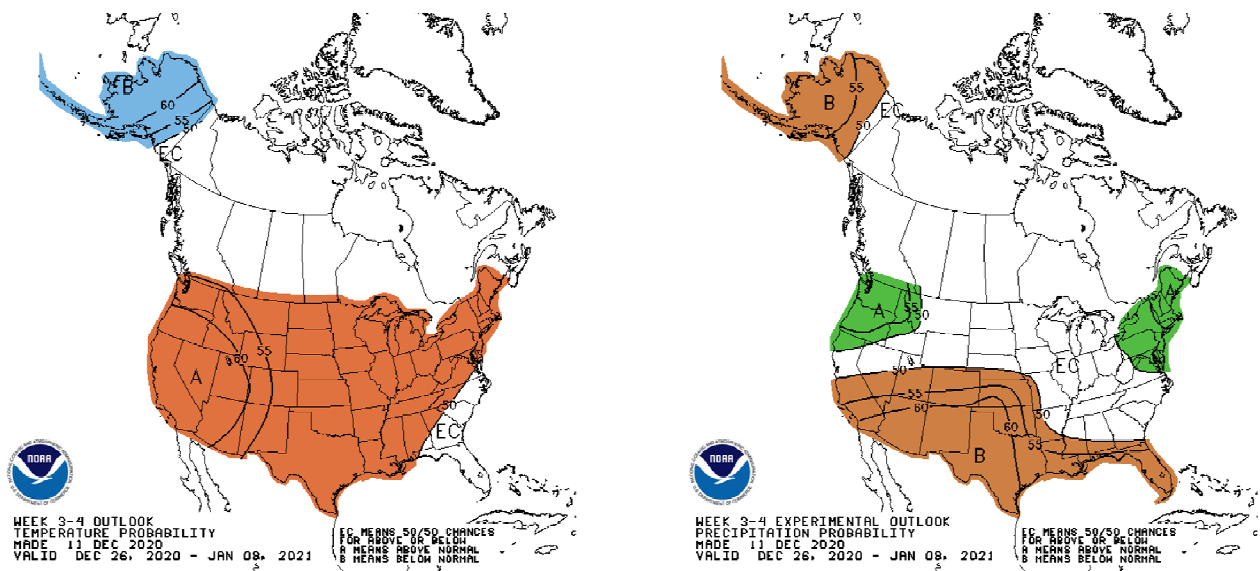


Figure 26. Week 3-4 outlook for temperature(left) and precipitation(right) from NOAA CPC.

계절내 예측의 경우, 계절내진동(MJO; Madden-Julian Oscillation)의 활동 및 예측이 중요하

다. 따라서 CPC에서는 이와 관련한 예측정보도 제공하고 있다(Figure 27; <https://cpc.ncep.noaa.gov/products/precip/CWlink/MJO/foregfs.shtml>). MJO는 지구 장파 복사량(Outgoing Longwave Radiation; OLR)과 800hPa, 200hPa 열대바람을 사용하여 계산한 RMM(Real-time Multivariate MJO) 지수(Wheeler and Hendon, 2004)를 통해 정의된 MJO 지수를 기반으로 예측에 사용한다. CPC에서는 앙상블 GFS 모델결과에서 예측된 RMM 지수 기반으로 +14일까지의 MJO 예측정보를 제공하고 있다. MJO에 따른 열대대류 활동의 변화의 변화는 세계 여러 곳의 기후와 밀접한 연관이 있어, 이와 관련한 많은 연구가 진행되어 왔다. 특히, 열대대류 활동과 관련된 육지 강수에 영향을 미칠 뿐 아니라, 아시아, 호주 및 아프리카 몬순에도 영향을 미친다. 또한, 열대 저기압 활동이나 중규모 대류시스템과도 영향이 있으며, ENSO의 변동성에도 영향을 미치는 것으로 알려져 있다(Camargo et al. 2009, Chand and Walsh, 2010, Hall et al., 2001, Wheeler et al., 2009, Taraphdar et al. 2018, Li et al. 2017).

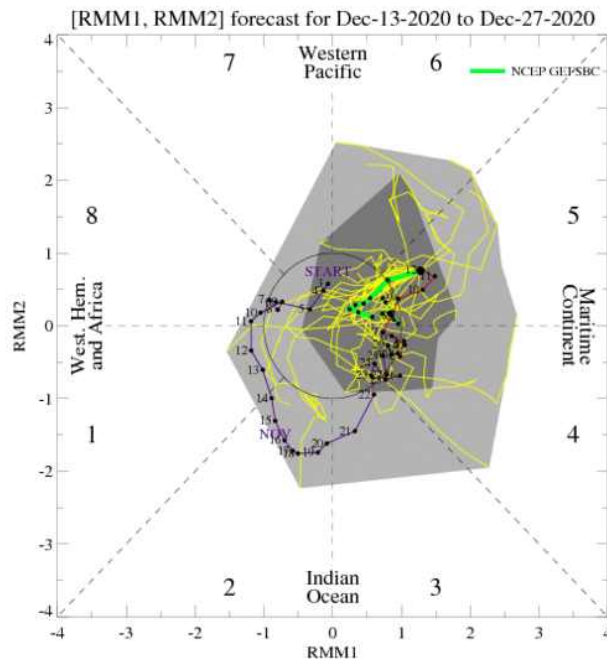


Figure 27. GFS-based MJO ensemble forecast provided by NOAA CPC.

② 호주 기상청(Bureau of Meteorology, BoM)

호주 기상청은 ~36시간(단기), ~4일(중기)예보와 함께, 최고·최저기온, 강수량에 대해 주별(1주 및 2주 평균), 월별(1개월 평균), 계절별(3개월 평균) 동안의 2분위 확률 예보를 제공하고 있다.(Figure 28). 최고·최저기온의 2분위 확률예보를 위해서는 과거 30년간의 중앙값(median)을 넘어설 확률에 대한 예측 정보를 제공하고, 강수량에 대해서는 특정 강수량 이상일 확률(예, 최소 10mm, 50mm, 100mm등)일 확률과 함께 과거 30년간의 강수량 중앙값을 넘어설 확률이 75%, 50%, 25%일때의 확률정보 등을 제공한다. 주별 예보는 1주일에 두 번, 월별, 계절별 예보의 경우 주별로 예보자료를 제공한다(www.bom.gov.au/climate/outlooks). 예보 자료를 생산하

기 위해서 영국기상청 UKMO 모델을 기반으로 자체개발한 ACCESS-S 모델을 사용하고 있다. 기후 관련 정보로는 호주 지역 기후에 가장 중요한 역할을 하는 태평양과 인도양의 해수면 온도를 포함한 엘니뇨/라니냐, 열대 모니터링으로 MJO, 열대 저기압을 제공하는 한편, Southern Annular Mode(SAM), 인도양의 다이폴 지수(Indian Ocean Dipole; IOD) 지수 등을 예측하고 있다.

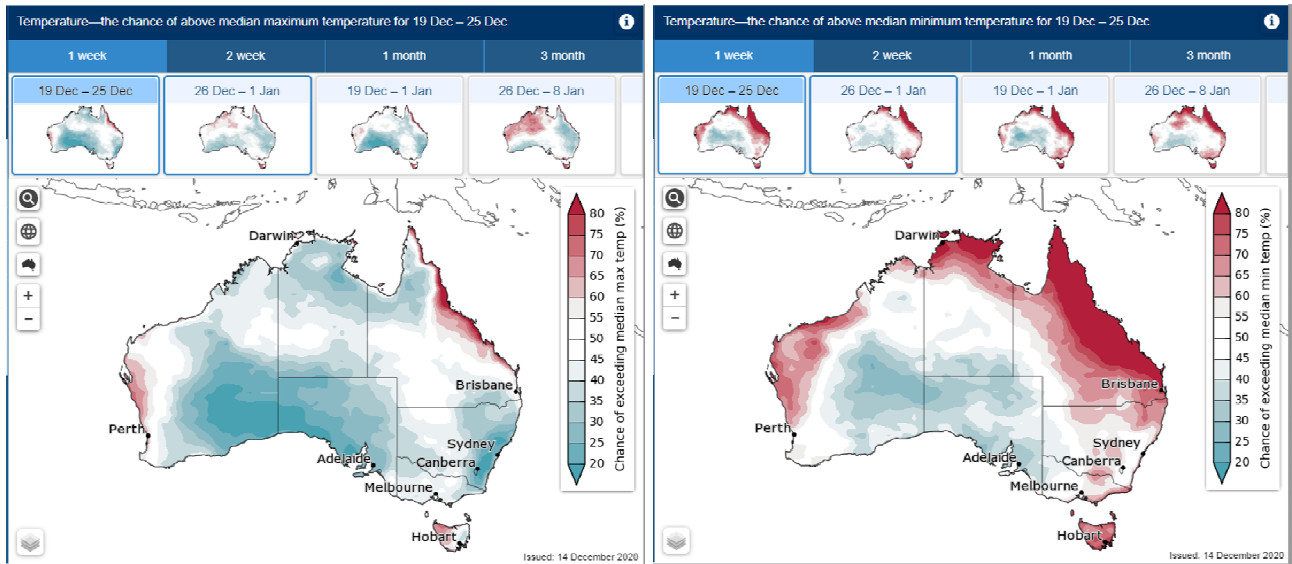


Figure 28. Climate outlooks for maximum(left) and minimum(right) temperature likelihood of the upcoming weeks, months and seasons being warmer or cooler than usual.

③ 일본 도쿄 기후센터(Tocky climate Center, TCC) 및 일본 기상청(Japan Meteorological Agency, JMA)

일본 기후센터에서는 최고·최저기온에 대한 예보는 별도로 제공하지 않으나, 기온 및 강수, 대기 순환장 변수들에 대해 선행시간 1주(3~6일 평균), 2주(10~16일 평균), 3-4주(17~30일 평균), 1개월(3~30일 평균)장에 대한 예보를 제공하고 있다(<http://ds.data.jma.go.jp/tcc/tcc/>). 대기 순환장 변수로는 북반구에 대해서 500hPa 지위고도, 850hPa 온도, 해면기압(SLP)등을 제공하고, 북위 60도~남위 60도 및 아시아 지역에 대해서는 stream function, velocity potential, 강수, 지표기온 등을 제공하고 있다(Figure 29). 이러한 1개월 예측자료를 생산하기 위해서 전구 앙상블 예측 시스템(ESP)을 기반으로 하고 있는데, 대기모델(AGCM)은 JMA-GSM을 기반으로 하며, 18일 이전까지는 TL479, 18일 이후에는 TL319 모델을 사용한다.

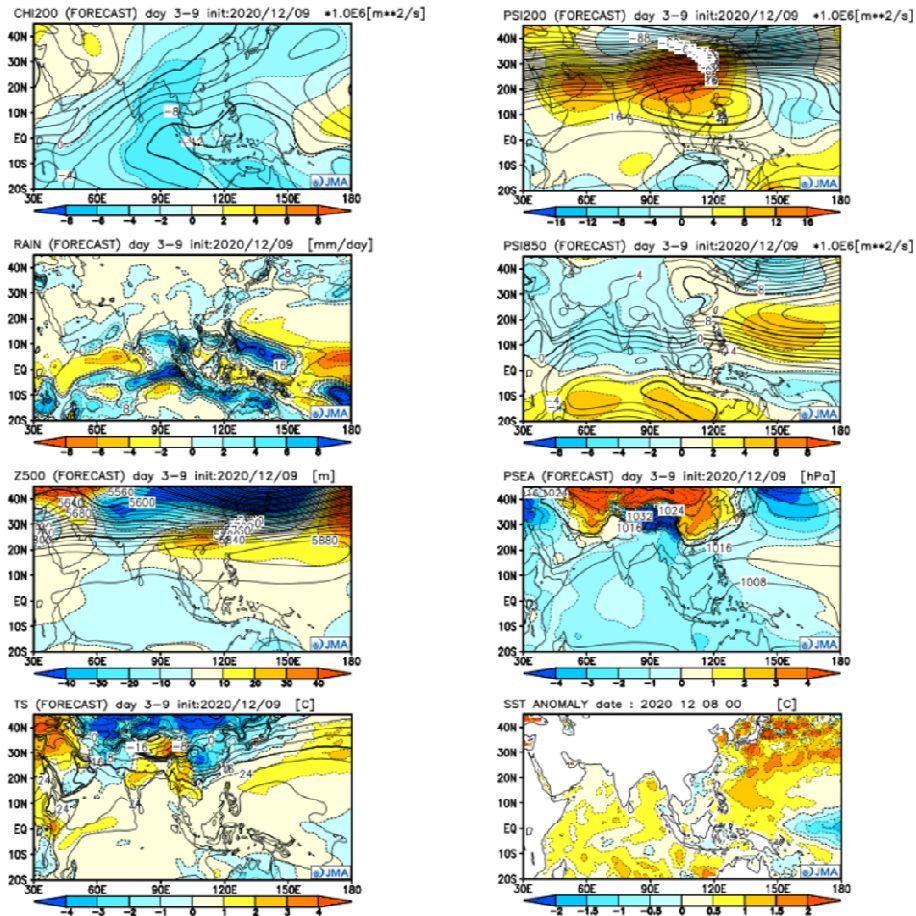


Figure 29. One-month prediction maps over Tropics and Asia regions for the first week. Shaded patterns show anomalies with respect to the each total field.

일본 기상청(Japan Meteorological Agency; JMA)에서도 일본지역 평균기온, 강수량에 대해 일 단위, 1~2주 단위의 계절내 전망을 제공하고 있으며, 이와 더불어 1개월 전망, 3개월 전망, 이상기후 조기경보를 제공하고 있다. 특히, 1개월 및 3개월 기온, 강수, 일조량, 강설량 전망에 대해 3분위 확률예보를 제공하고 있으며, 각 지역별 확률도 제공하고 있다(Figure 30; <http://www.jma.go.jp/en/longfcst/>). 기온에 대해서는 평년보다 낮거나 비슷하거나, 높을 것으로 예상되는 확률값을 제공하고 있으며, 3분위 중 확률이 40% 이상인 범주를 강조해서 나타낸다. 또한, 선행시간 8일의 2주(5일 평균) 평균 기온(<http://www.data.jma.go.jp/gmd/cpd/twoweek/en/>)에 대해서는 Figure 31과 같이 예측정보를 제공하고 있는데, 기후값의 33%를 기준으로 5개의 카테고리 대해 매우 높음, 높음, 평년 비슷, 낮은, 매우 낮음의 각 카테고리에 대해 확률정보를 제공하고 있다. 특히, 매우 높음과 매우 낮음의 경우 기후값의 10%에 해당하는 값에 대한 확률정보를 나타낸다.

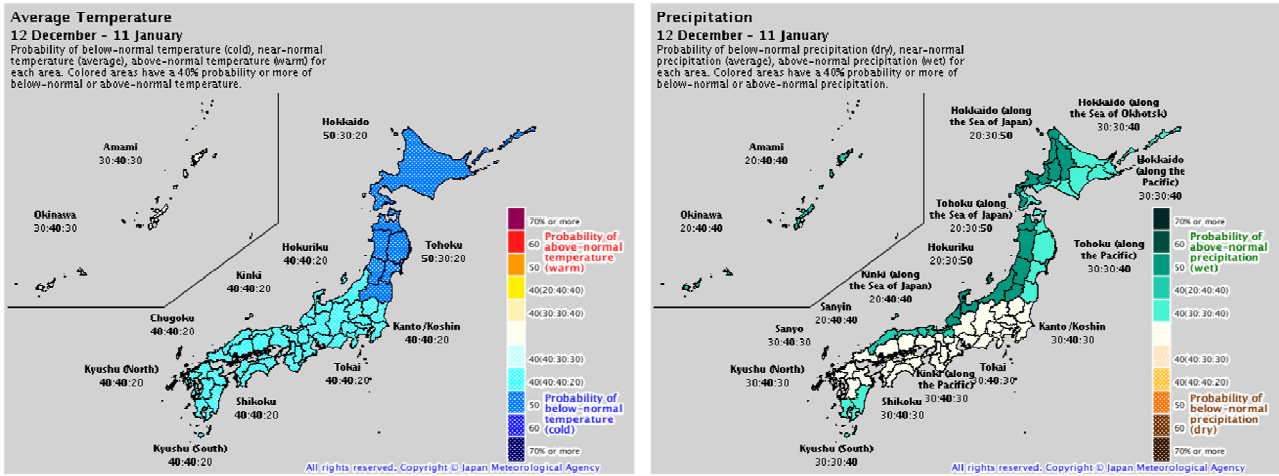


Figure 30. One-month and three-month forecast are issued at 14:30 JST every Thursday and at 14:00 JST around the 25th of each month respectively. Warm- and cold-season outlooks are issued in February and September respectively in concurrence with three-month forecasts.

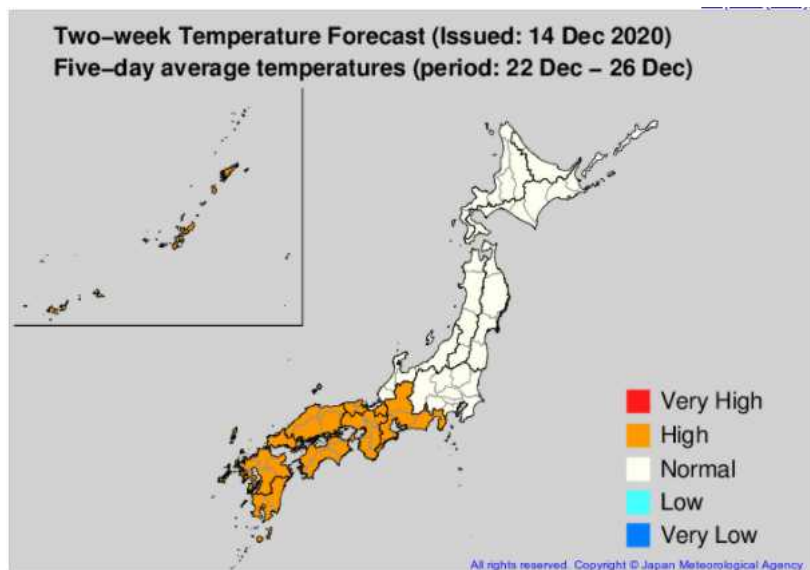


Figure 31. The two-week temperature forecast from JMA. This shows categorized five-day average temperatures from eight days ahead, with red and blue indicating values expected to be very high and very low, respectively, at probabilities of 30% or more. Orange and light blue indicate values expected to be high and low, respectively.

④ 영국 기상청(U.K. Met Office)

영국 기상청에서는 ~5일의 단기예보, 6~15일의 중기예보, 10~30일의 장기예보를 제공하고 있다. 단기예보의 경우, Met Office Global and Regional Ensemble Prediction System(MOGREPS)을 사용하고, 중기 이상의 예보는 Global Sasonal forecast system version

5(GloSea5)을 사용하여 생산한다. 6~15일 예측에는 폭우, 강풍, 고온 및 저온과 같은 이상기상 현상에 대한 위험평가를 포함하고 있고, 이때 영국 기상청 모델뿐 아니라 유럽중기기상예보센터(ECMWF)의 모델 결과 등도 함께 고려한다. 또한, 2~4개월, 3~5개월, 4~6개월의 기간에 대해 2m 기온, 500hPa 지위고도, 850hPa 기온, 전 세계 강수량, 기압, 해수면 온도 예측 결과 등도 함께 제공한다. Figure 32는 2020년 12월 발표된 전지구 2~4개월 2미터 온도에 대한 3분위, 5분위, 2분위 확률예보 결과로써, 이외에도 열대, 아시아, 북미, 남미 및 유럽 등 각 지역별 3분위 확률, 5분위 확률, 2분위 확률(중앙값 이상)에 대한 예보 결과도 함께 제공하고 있다 (<http://metoffice.gov.uk/research/climate/seasonal-to-decadal/gpc-outlooks/glob-seas-prob/>).

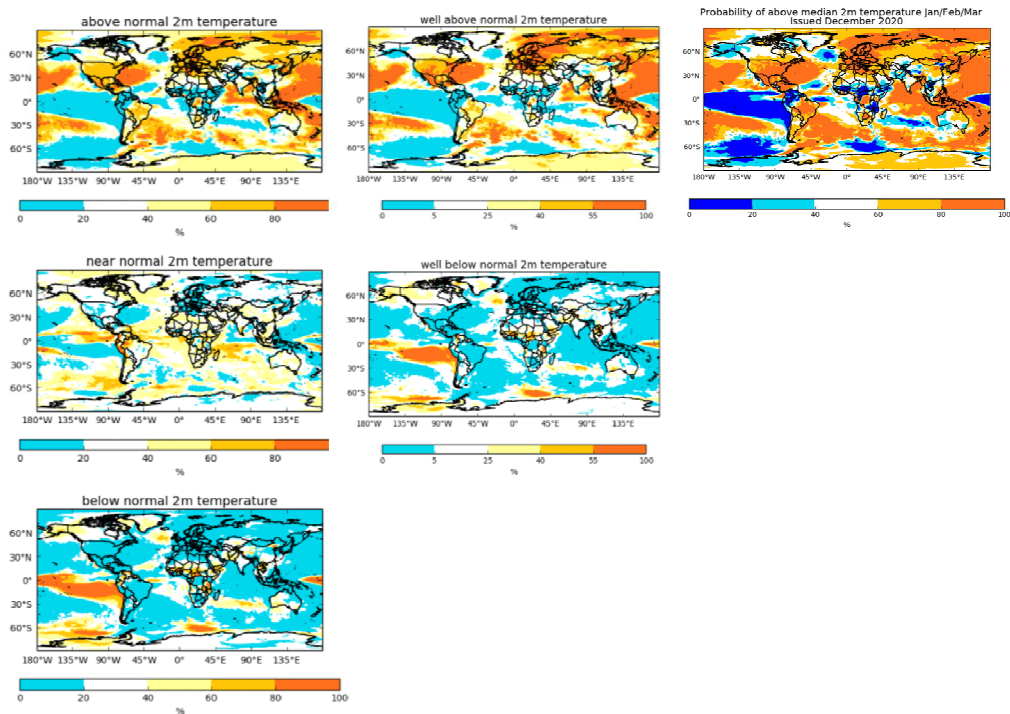


Figure 32. Probability of Months 2-4 tercile categories(left), outer quintile categories(middle), and above median (right) 2m temperature forecast.

(나) 기상청 현업모델(GloSea5) 운영 현황 및 편차보정 방법

① 현업 운영 현황

기상청 현업모델(GloSea5)의 과거재현자료(hindcast)의 경우, 매일 생성되는 예측장(forecast)과 달리 특정일(1, 9, 17, 25일/매월)을 hindcast 적분 시작일로 정의하여 초기화한다. 예측장에 준하는 매일의 hindcast 결과가 필요하기 때문에, 예측장 날짜를 기준으로 전후의 가까운 hindcast 초기 날짜 2개를 찾고, 해당되는 기후장의 자료를 날짜 거리에 따른 가중평균을 하여 예측장의 날짜에 준하는 hindcast를 생산한다(Ham et al. 2017; Figure 33). 영국 UKMO에서도 유사한 방법으로 기후값을 계산하여, 예측값에 대한 편차 보정을 하고 있으므로, 위 방법(날짜 거리에 따른 가중평균)에 따라 예측장의 편차를 보정할 수 있을 것이다(Arribas et al. 2011;

MacLachlan et al. 2015).




Figure 33. Illustration for date-distance weighted average using GloSea5 subseasonal hindcast.

② 통계적 훈련자료 및 관측자료

본 연구에서 사용한 통계적 훈련자료는 GloSea5의 과거재현자료(hindcast)로써 기간은 1991년부터 2010년까지의 20년 자료이다. 단, 2020년 8월부터 과거재현자료의 기간이 1991년부터 2016년까지, 26년으로 연장 생산됨으로써 이를 함께 반영하였다. 모델 예측자료에 대한 실제 검증자료로써 ASOS 45개 지점의 관측자료를 사용하였으며, 관측 기후값 산정을 위해 1981년부터 2010년까지의 30년 기준을 사용하였다. 또한, 2021년부터 예정된 기후값 변경(1991~2020)도 함께 고려하였다. 최종예측 변수는 최저, 최고, 평균기온이며, 실제 예측기간(2017년 1월~2020년 9월) 동안 주별 생산한 한반도 전체 영역 평균 예측자료를 편차보정하여 45개 관측자료 전체평균과의 정확도를 비교하였다.

③ 편차정의 및 편차보정 방법

기상청 현업모델 최고·최저기온에 대한 편차를 다음과 같이 정의하였다. 매주 월요일(00KST기준) 총 21개 멤버(최근 7일×3개/hindcast)에 대해 time-lag 앙상블을 구성하여 앙상블 평균(ensemble mean forecast)과 관측값(ASOS)의 차이를 weekly 평균한 값을 편차(bias)로 정의하였다. 또한, 1991~2010년까지 20년 동안의 주별 예측자료에 대한 bias 평균치를 bias climatology로 정의하였다(Figure 34; Gusan et al. 2019). 대개의 계절내 예측에서는 예측일 기준으로 앞뒤 31일 기간을 sampling window로 하여 bias correction sampling수를 확보할 수 있는데, 본 연구에서는 기상청 기후예측과 현업을 위한 자료 가용성을 고려하여 예측 타겟 시점기준 -15일의 time-window(초기화 3개)를 고려하였으며, 이는 bias climatology에 거의 영향을 주지 않았다(추후 설명).

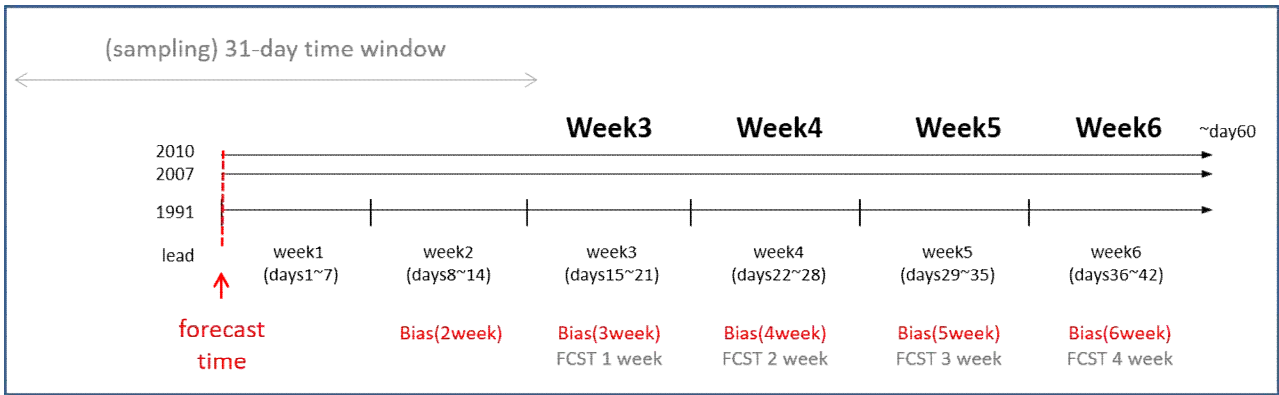


Figure 34. Diagram for bias and bias climatology definition.

④ 기상청 현업모델 편차분석

기상청 현업모델의 과거재현자료를 사용하여 한반도 지역의 lead-time에 따른 최고·최저기온 오차경향(RMSE; Root mean squared error 및 MABE; Mean absolute error)을 분석하였다. Figure 35는 최고, 최저, 평균기온에 대한 오차경향을 나타내는데, 전반적으로 오차는 최고>최저>평균기온 순으로 크게 나타난다. 그림에서 나타나는 바와 같이, 예측 오차는 예보 10일까지 급격히 증가하고, 예측 3주 후 오차가 수렴하는 것으로 나타난다(녹색 점선; saturation point). 특히, 예보 60일 대비 11일(예보 2주 중간시점) MABE 값의 비율로 saturation rate를 추정했을 때, 최고기온의 경우 92.8%, 최저기온은 93.2%, 평균기온은 80.5%로 최고·최저기온이 평균기온보다 빨리 saturation 되는 것으로 나타났다.

또한 MABE 대비 RMSE의 비율로 각 변수별 RMSE에 대한 error variance의 영향을 비교해 봤을 때, 최고기온은 6.7%, 최저기온 10.3%, 평균기온은 10.5%로 나타났다. 이는 한반도 영역이 매우 작은 만큼 variance가 작고 error가 거의 균일하게 분포함을 나타낸다. 참고로 기상청 현업모델의 북반구(동아시아) 지역에 대한 RMSE에 대한 error variance의 영향은 각각 최고기온은 54%(38%), 최저기온은 53%(38%), 평균기온은 53%(37%)로 나타났다. 지역을 불문하고 변수별 차이는 크지 않은 것으로 나타났다.

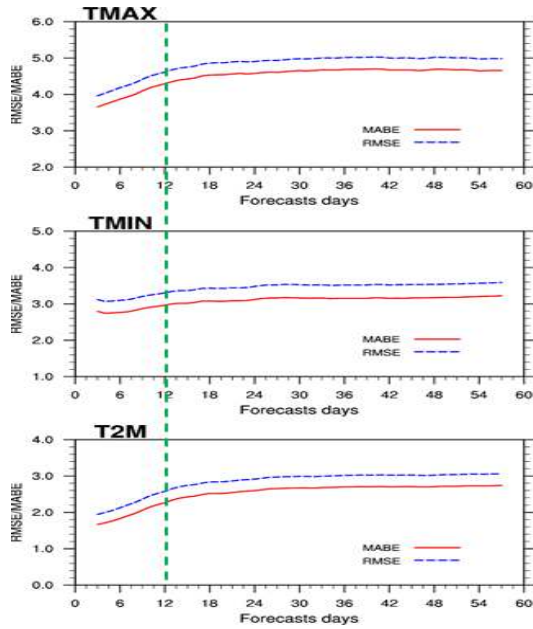


Figure 35. Korea domain averaged RMSE and MABE from GloSea5 hindcast for the period of 1~60 forecast days.

Figure 36 은 계절에 따른 예측 3~4주의 mean error(bias)를 나타내는데, 최고·최저기온 모두 bias의 계절 변동성보다 연변동성이 크게 나타나며, 계절 변동성이 작기 때문에 계절에 따른 systematic bias correction이 가능하다. 최고기온은 cold bias가 크게, 최저기온은 warm bias가 크게 나타나며, 특히 최고기온에 대한 bias가 최저기온에 대한 그것보다 크게 나타났으며, 이는 평균기온의 cold bias에도 영향을 주었다. 또한, 여름철보다 겨울철 cold/warm bias가 더 크게 나타났다(Figure 37). 다음 3장 (나)절에서는 기상청 현업모델의 이러한 편차를 보정하여 1개월 최고·최저기온 예보를 개선할 수 있는 방안과 그 결과에 대해 논의하고자 한다.

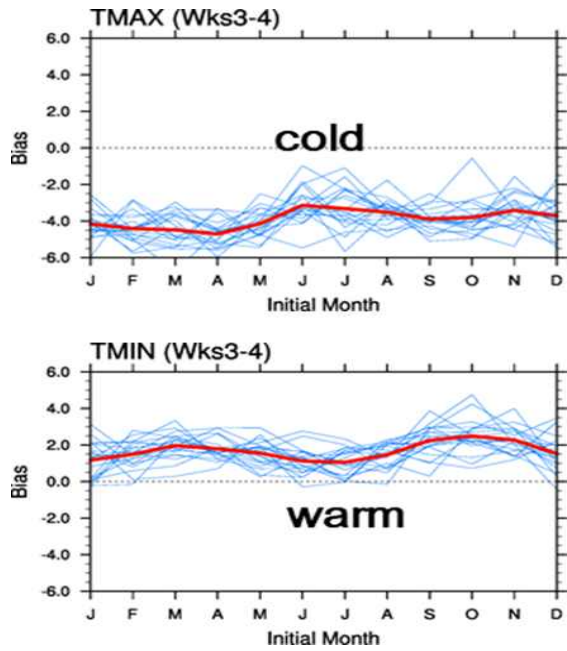


Figure 36. Week 3-4 averaged bias in each month for maximum and minimum temperature (estimated from GloSea5 hindcasts); (left) maximum temperature, (right) minimum temperature.

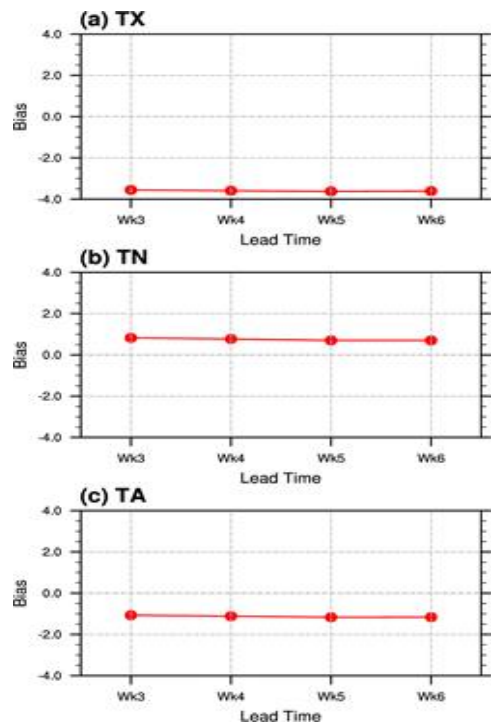


Figure 37. Weekly forecast errors in GloSea5 hindcasts for each lead time; (a) maximum temperature, (b) minimum temperature, and (c) mean temperature.

3. 결과

가. 이상기후 감시 및 분석 콘텐츠

(1) 이상기후 감시 정보 콘텐츠 확대 및 가시화 개선

(가) 이상기후 감시 정보 콘텐츠 확대 생산

① 월별 한반도 감시 정보 부가 정보 추가 생산 및 가시화

Figure 38과 39는 2020년 1월부터 12월까지의 이상 고온, 이상 저온의 감시 정보를 나타낸다. 2020년 매월의 이상 기후 발생현황을 함께 살펴보면, 한반도 지역의 이상 고온은 1~3월에 강하게 나타났으며, 일 최고기온의 월 평균 또한 매우 상위권에 랭크되어 있는 것을 볼 수 있다. 이상 저온의 경우에는 동아시아 지역에서는 티벳 고원 지역 위주로 이상 저온 발생일수가 많았던 것을 알 수 있고, 한반도 지역은 7월 중순과 하순에 이상 저온 발생일수가 빈번하게 나타났을 뿐만 아니라, 월 평균 값 또한 가장 하위에 위치함을 알 수 있다.

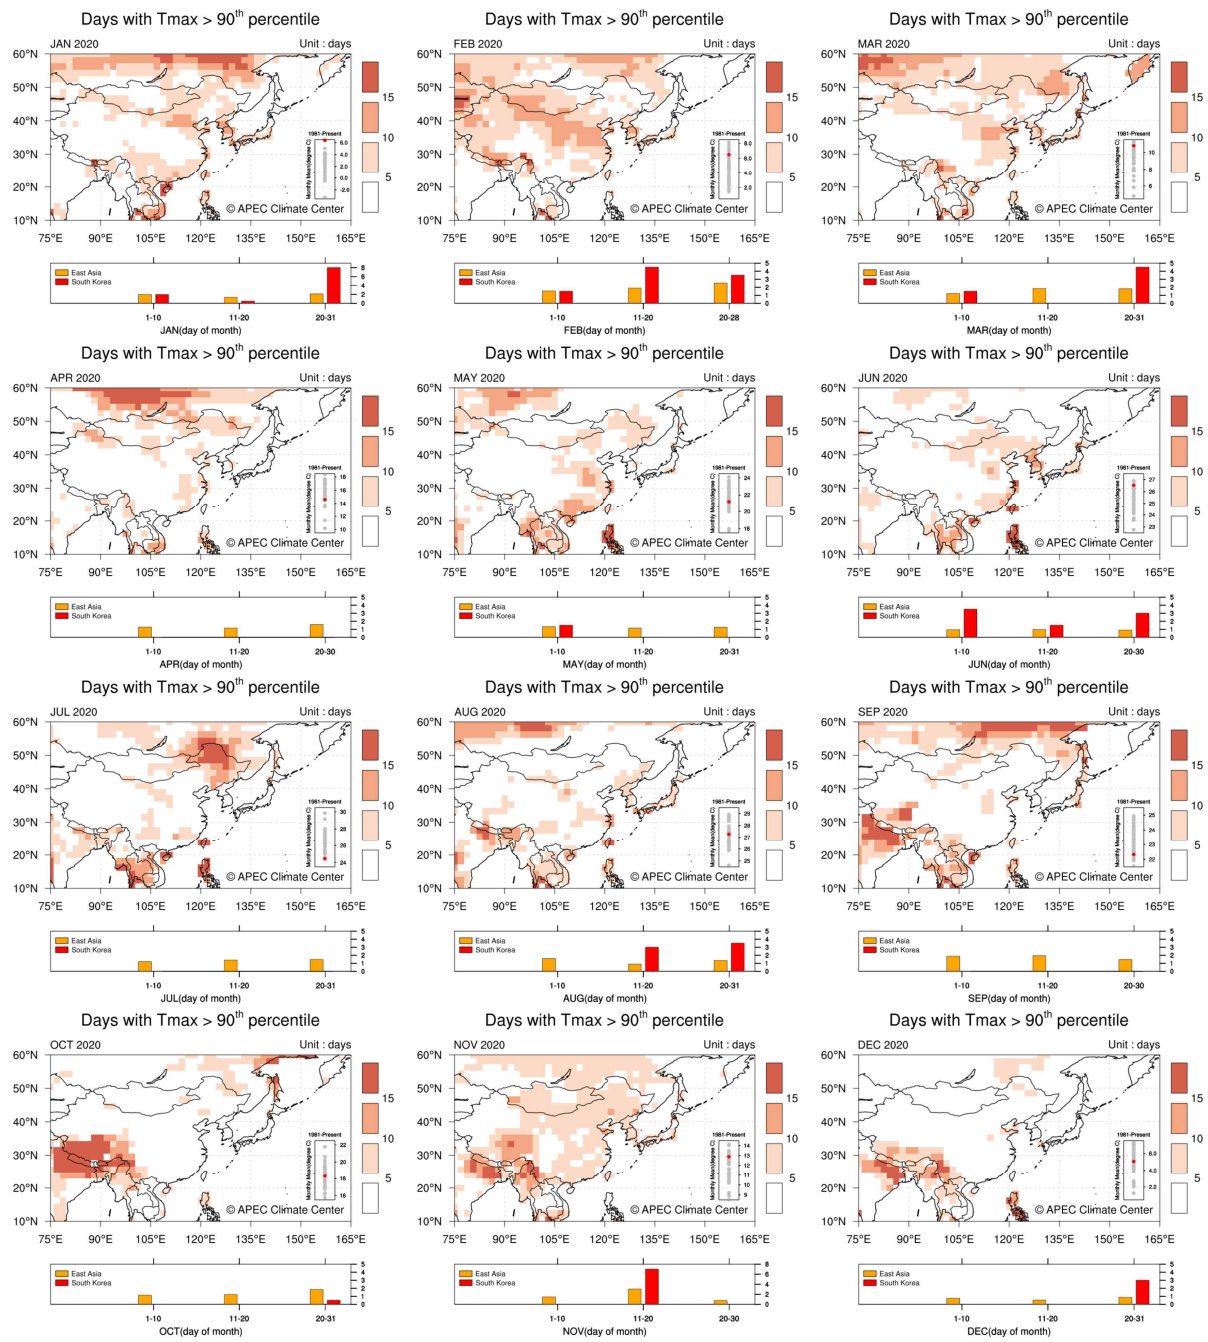


Figure 38. Monthly extreme climate monitoring map after improvement visualization technique for daily maximum temperature above 90th percentile during 2020.

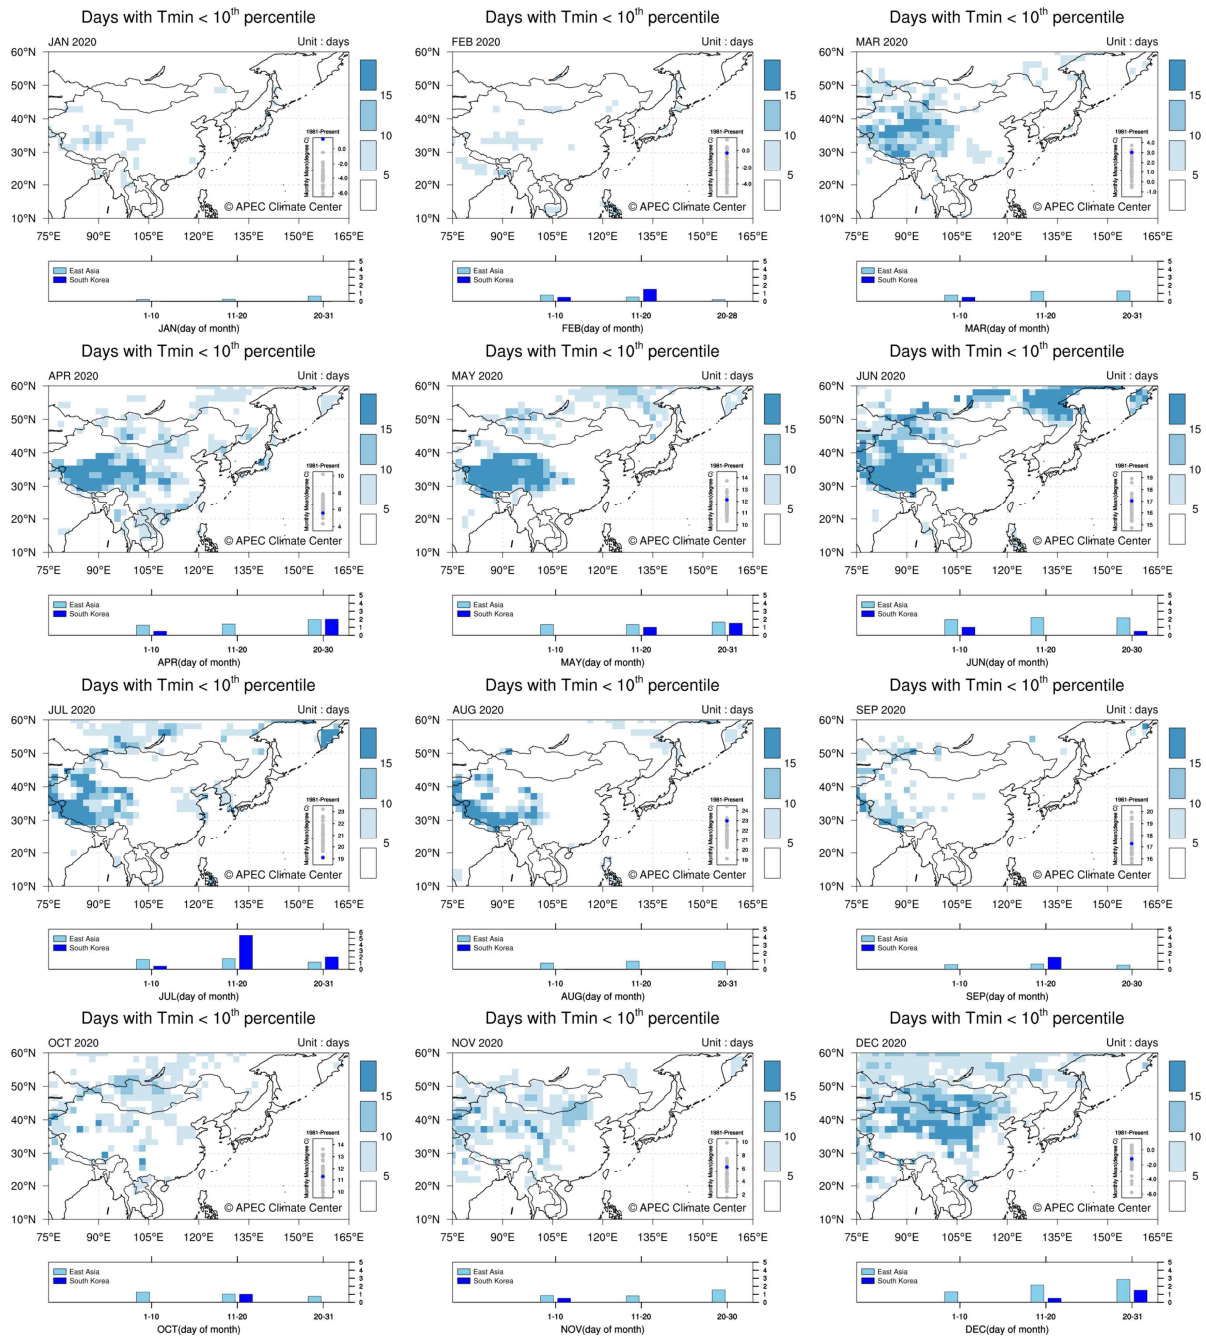


Figure 39. Monthly extreme climate monitoring map after improvement visualization technique for daily minimum temperature below 10th percentile during 2020.

(나) 이상기후 감시 정보 콘텐츠 통합맵 생산

① 최대 강우 사상과 재현기간의 통합맵 생산 및 가시화

Figure 40은 2020년 1월부터 12월까지의 최대 강우 사상 및 재현기간을 나타내고 있다. 공간 분포도는 재현기간을 기준으로 하여, 재현 기간이 20년 이상인 지역부터 재현기간이 길수록 진한 색으로 나타내고 있다. 월별 감시 정보에 추가 된 부가정보는 한반도 지역의 과거 대비 월 누적 강수량의 순위로 1월의 경우 한반도에서 재현기간이 긴 이상 강수가 발생하였을

뿐만 아니라, 월 누적 강수량도 상위에 랭크되어 있다. 그리고 1월 상순과 하순 모두 한반도에
 는 재현기간 20년 이상의 강수일수가 많았던 것으로 보인다. 2020년 여름철 중요 이슈 중 하나
 였던 중국 지역의 기나긴 폭우 또한 6, 7, 8, 9월까지 중국 지역 곳곳에서 재현기간이 긴 이
 상 강수가 발생하였다. 또한 6월 말부터 한반도의 강수량도 늘어났고, 7월 하순과 8월 상순까
 지도 한반도에서 이상 강수 발생이 빈번하게 나타났다.

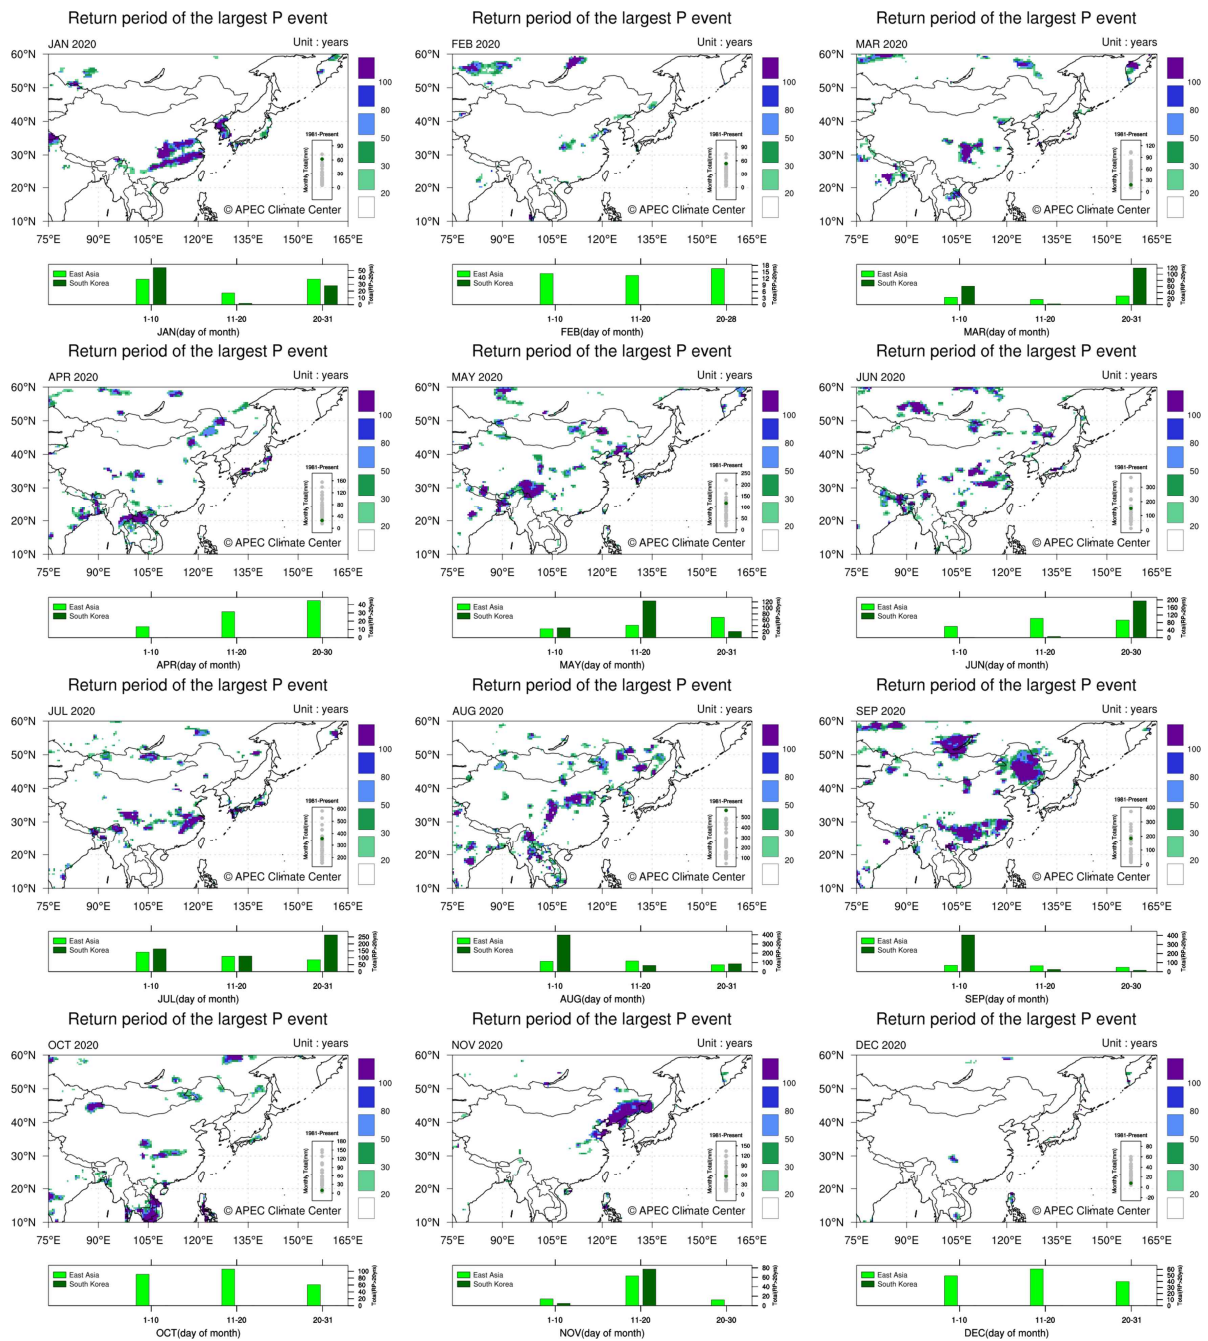


Figure 40. Monthly extreme climate monitoring map after improvement visualization technique for return period of the largest P event and monthly total precipitation during 2020.

② 가뭄 지수 통합맵 생산 및 가시화

Figure 41은 3개의 가뭄 지수를 통합하여 나타낸 가뭄 통합맵으로, 월별 공간 분포도와 함께 제공되는 부가 정보는 순별 정보가 아닌 각 지수의 동아시아 및 한반도에서의 현황이다. 각 가뭄 지수 별로 동아시아 및 한반도 지역에서의 가뭄 상태를 파악할 수 있다.

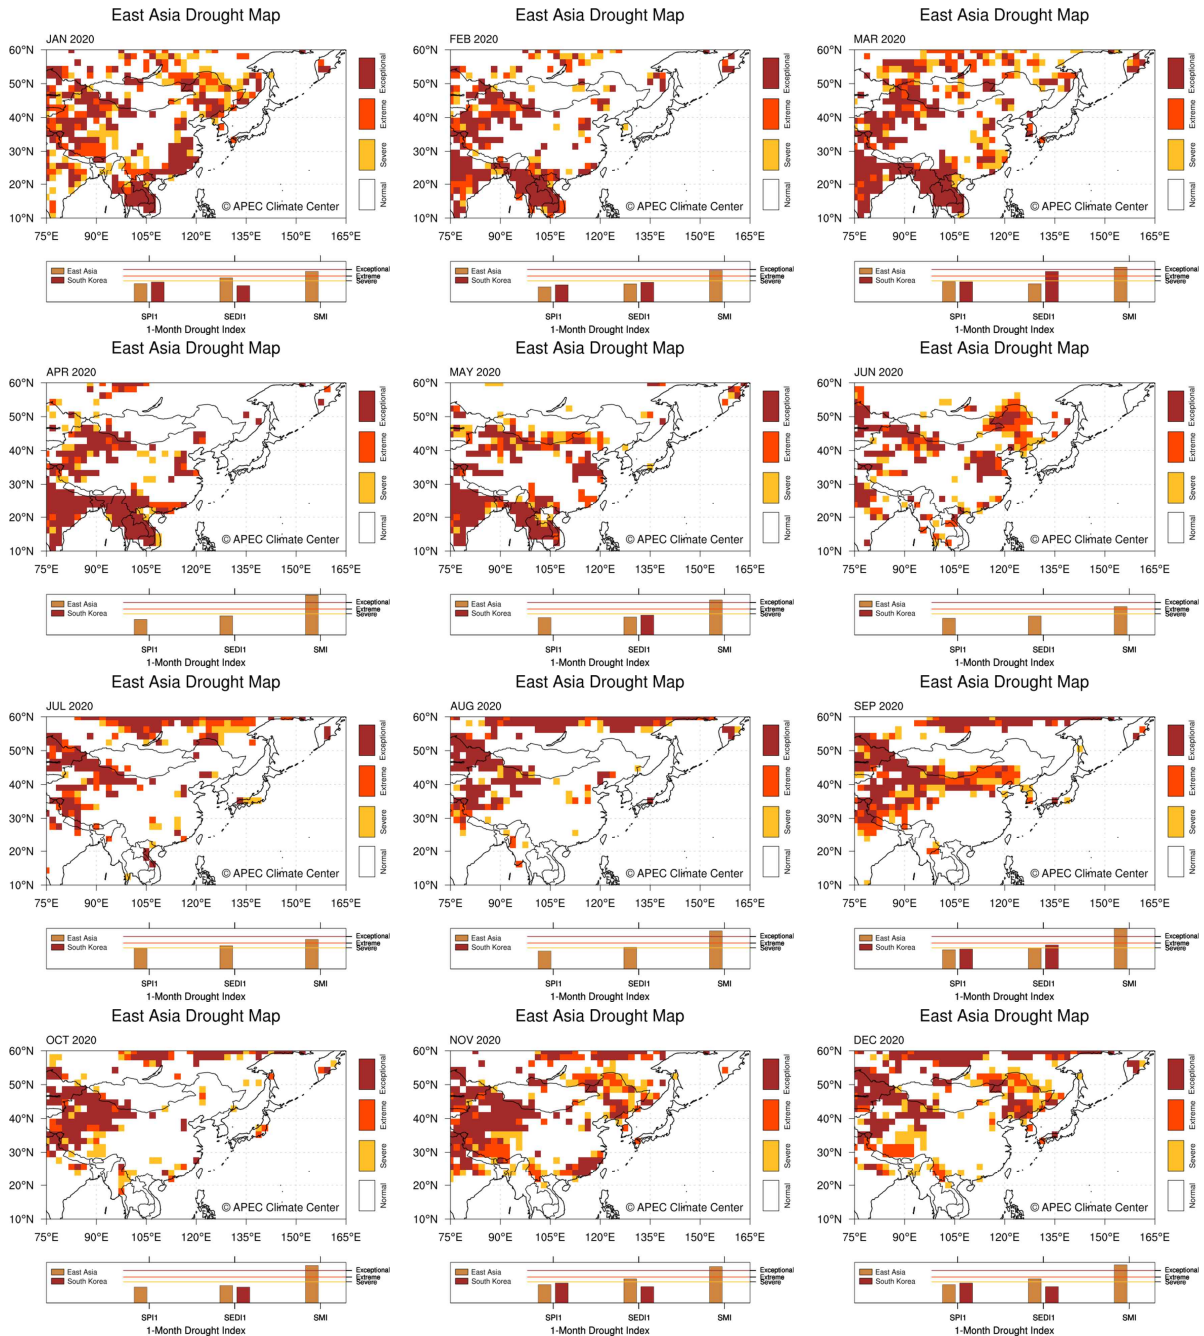


Figure 41. Monthly drought monitoring map after improvement visualization technique for 3 drought indices during 2020.

③ 동아시아 통합맵 생산 및 가시화

Figure 42는 동아시아 및 한반도에 대해 더욱 초점을 맞춘 동아시아 이상기후 통합맵으로 3월부터 6월까지 티벳 고원 인근에서 이상 저온이 많이 발생한 것을 알 수 있고 6월부터 9월까지 중국 남부 및 북부 지역에서 습윤했음을 한 눈에 파악할 수 있다.

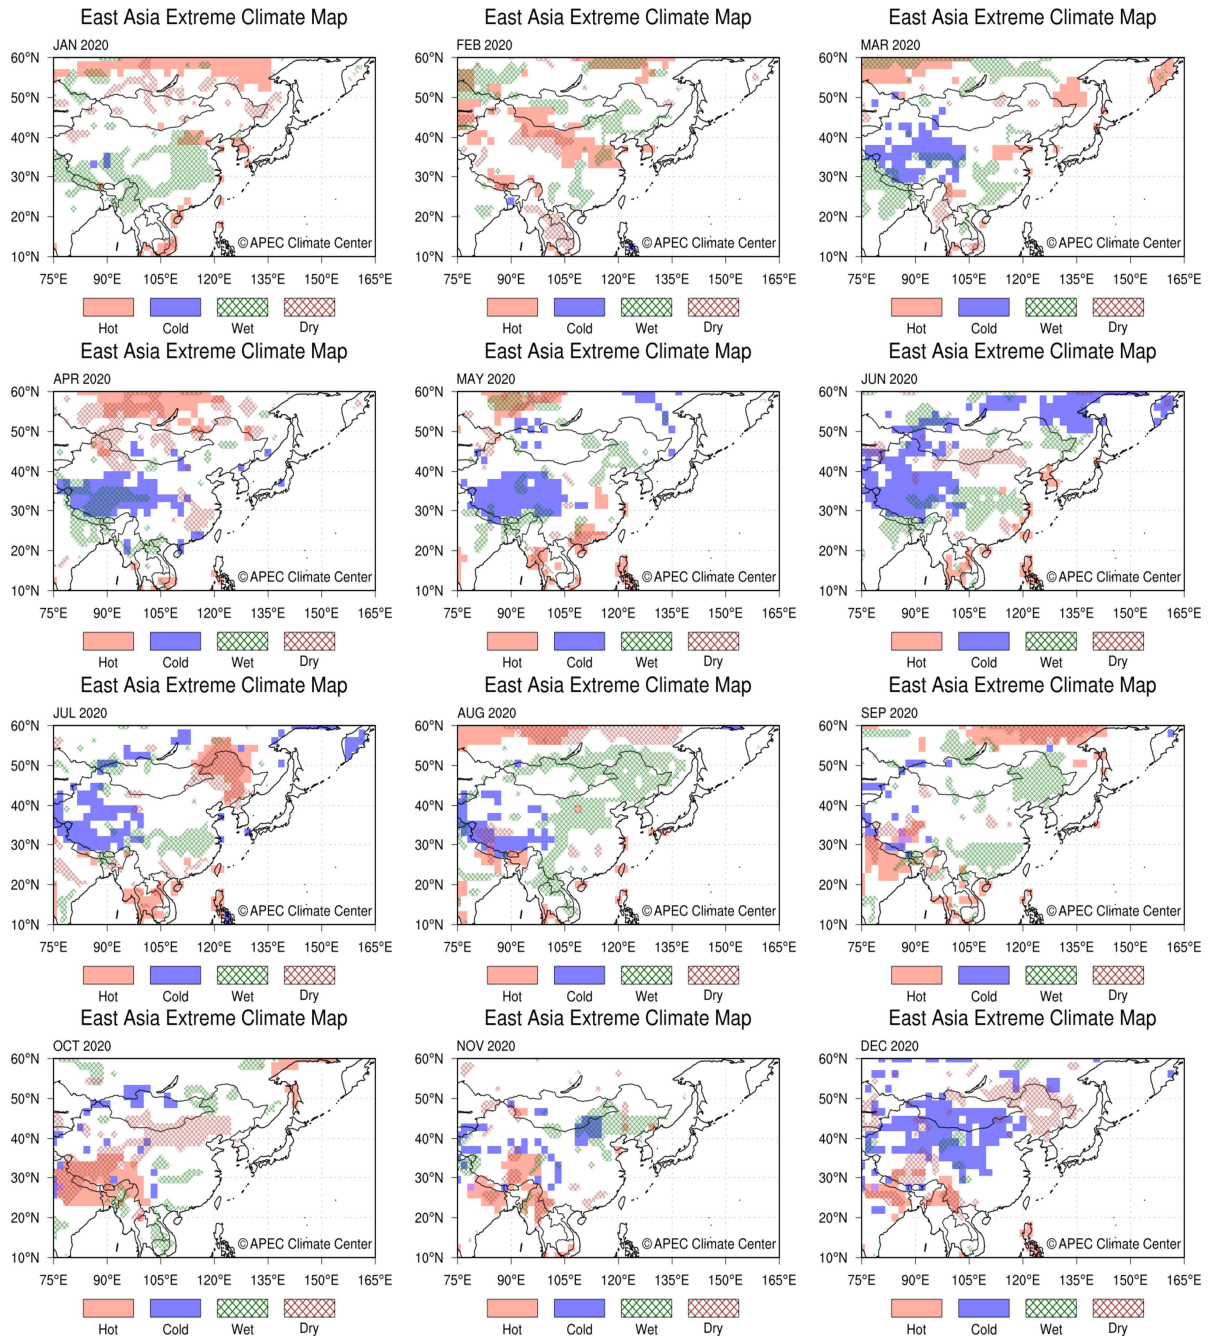


Figure 42. East Asia extreme climate monitoring map after improvement visualization technique during 2020.

(다) 월별 이상기후 감시 정보 표출 자동화 구축 및 개선

① 월별 이상기후 감시 정보 생산 자동화 구축 및 개선

기존에 구축된 이상기후 감시 정보 생산 자동화 구축 시스템에서는 이상 고온 발생일수, 이상 저온 발생일수, 이상강수 발생일수 등을 계산할 수 있었다. 그리고 SMI 같은 경우, 주별 감시 정보지만 자동으로 돌아갈 수 있도록 시스템을 구축 하였다. 하지만 이상기후 감시 정보를 모두 월별 감시 정보로 통합하여야 하므로, 매주 생산되었던 SMI 결과를 이용하여 매일 SMI로 통합할 수 있도록 계산 코드를 개선하였다.

또한 월별 감시 정보 중 최대 강수 사상 및 재현기간 계산, SPI, SEDI 등은 R 스크립트 코드로 작성되어 매일 수동으로 감시 정보를 생산하여야 했으나, 월별 이상기후 감시 정보 시스템을 모두 통합하고 자동화를 위해 C shell 기반 shell 스크립트를 통해 매일 자동으로 감시 정보가 생산 되도록 개선하였다.

② 월별 이상기후 감시 정보 표출 자동화 구축 및 개선

기존 웹 서비스 중인 이상기후 감시 정보 자동화 시스템에서는 월별 6개의 정보와 주별 4개의 감시 정보가 표출 되도록 구축해 두었다. 하지만 개별 감시 정보 표출이 아닌, 통합맵의 종류가 많아지면서 여러 가지 변수의 계산을 다 끝낸 후에 통합맵으로 표출하기 위해 자동화 구축 및 개선하였다.

(라) 이상기후 감시 정보 해석 가이드 생산 및 제공

① 이상기후 감시 정보 해석가이드 생산 및 제공

기존 이상기후 감시 정보 웹서비스에는 월별 및 주별 감시정보만을 제공하고 있었으나, 각 감시 정보 별 사용하는 변수에 대한 설명과 더불어 이상기후 기준 선정 방법 등에 대해 더욱 자세히 설명되어 있는 이상기후 감시 정보 해석 가이드를 생산하여 제공한다. 기존 웹서비스에서는 이상기후 감시 정보와 관련 용어 설명이 각각 분리되어 적혀있었으나, 워낙 감시되는 정보가 다양하고 많은 데다 각 변수별로 이상기후 기준 선정 방법이 다르기 때문에 이를 설명해 주는 해석가이드를 함께 감시 정보를 더욱 상세하게 제공함으로써 이상기후 감시 정보에 대한 이해력을 더욱 높이고자 한다. Figure 43은 5개의 이상기후 감시 정보에 대한 해석가이드를 나타내고 있다.

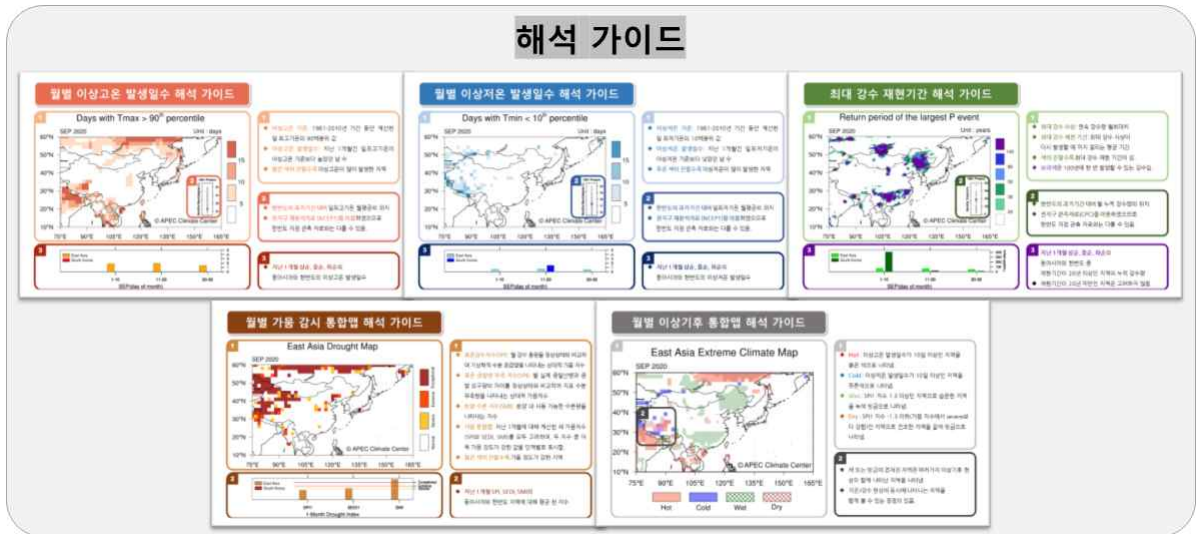


Figure 43. Analysis guide for climate extreme maps.

(마) 기후소통 TF를 통한 전지구 이상기후 모니터링 자료 제공

① 전지구 이상기후 일일 모니터링 자료 수집 및 제공

2020년도 총 98회 전세계 이상 기후 모니터링 정보를 제공하였으며, 그 중에 주요 이슈들 즉 1월 호주 산불, 6월 동시베리아 기록적인 고온, 6월 중국 남부지역 폭우 등에 관한 원인 분석 정보 또한 제공하였다 (Figure 44; 부록 A 참조)




Figure 44. APCC supports for providing climate information

(2) 흑서 감시인자 정보 개선 및 확대

(가) 2020년 감시인자 현황

① 감시인자 개별 통계 분석

기존의 흑서 감시 인자(기상청 기후예측과, 2018; Lim and Seo 2019) 중 2020년에 $\pm 0.5 \cdot \sigma$ (1981-2010 기간에 대한 표준편차)의 기준을 초과하는 인자에 대해 다음과 같은 통계분석 및 2020년 편차 분석을 수행하였다. 예를 들어 7월의 흑서일수(HWD)는 동인도양에서 음의 상관관계를 보이고 있다(Figure 45a). 기존 7월 기온 감시 인자인 4월의 동인도양 SST(SST_IO) 인덱스는 Figure 45a의 검은색 박스 지역($90 \sim 105^{\circ}\text{E}/10 \sim 0^{\circ}\text{S}$)의 평균 SST 값으로써 흑서일수(HWD)와 음의 상관관계($r = -0.19$, 1973-2019)를 지닌다(Figure 45a-b). 최근 5년(2015-2019)의 경우(Figure 45b, 붉은 십자 표시)를 포함한 21년 이동 상관관계를 보면 전 기간에 대해 음의 상관성이 잘 유지 되었다. 올해 2020년 4월에는 $0.5 \cdot \sigma$ 값을 상회하는 양의 값을 보였기 때문에(Figure 45c and 45e) 7월 흑서 일수가 평년보다 적을 것으로 예상되었는데 실제 0.2일(-2.8일의 편차)의 적은 흑서일수(Figure 45b, 붉은 별표시)를 기록하였다.

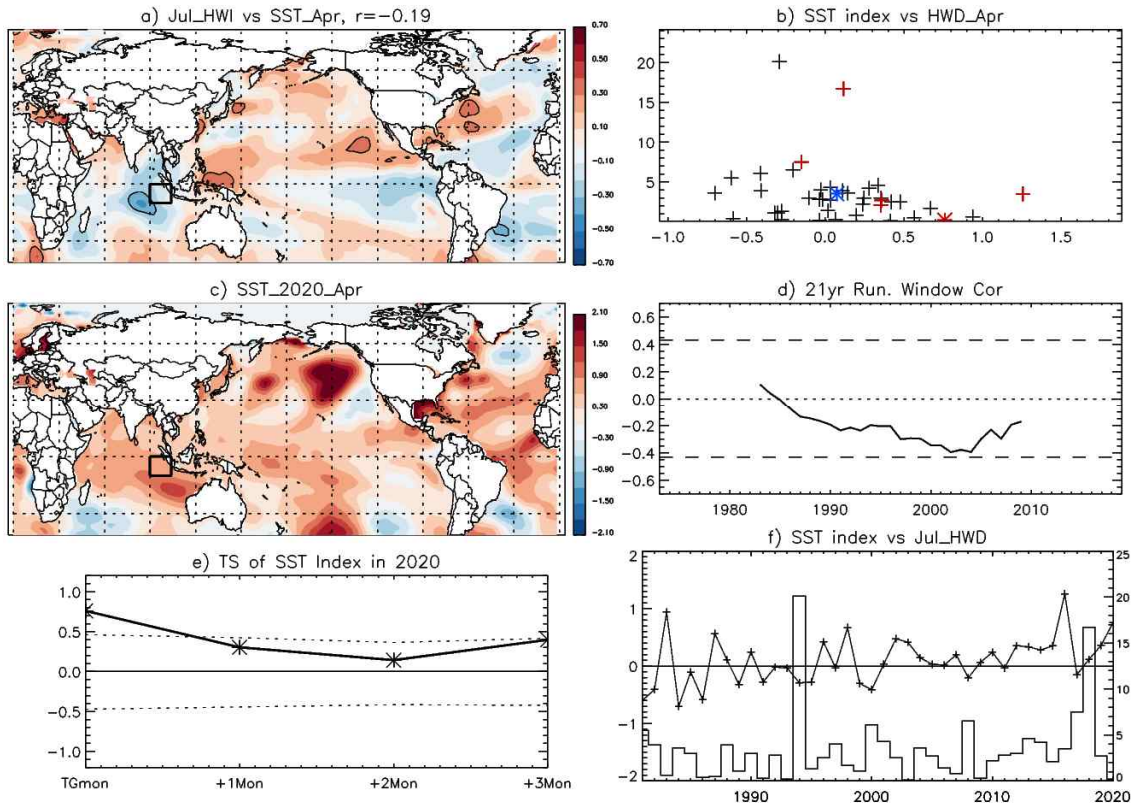


Figure 45. 39-year (1981-2019) correlation map between HWD in July and SSTs in April, b) scatter plot of HWD in July (y-axis) and SST_IO (x-axis), c) SST anomalies in April, 2020, d) 21-year sliding correlations of HWD in July and SST_IO from 1973-1993 to 1999-2019, e) time series of the SST_IO value from April to July in 2020, and f) time series of HWD in Jul (bar with the right y-axis) and SST_IO (cross with solid line with the left y-axis). The box in a) and c) indicates the region of the SST_IO index. Red crosses in b) indicate the recent five year (2015-2019) cases while blue star does 39-year average value. Long-dashed lines in d) show statistical significance at the 95% level. Short-dashed lines in e) show $\pm 0.5\sigma$ levels.

7월의 흑서일수(HWD)는 4월 열대 서태평양 필리핀해 부근에서 양의 상관관계를 보이고 있다(Figure 46a). 기존 7월 기온 감시 인자인 4월의 필리핀해 SST(SST_WP) 인덱스는 Figure 46a의 검은색 박스 지역(120~140°E/0~20°N)의 평균 SST 편차 값으로써 흑서일수와 양의 상관관계($r=0.27$, 1973-2019)를 보이는데(Figure 46a-b) 최근 5년의 경우(Figure 46b, 붉은 십자 표시)를 포함한 21년 이동 상관관계를 보면 최근 관련성이 약간 감소하였다. 올해 2020년 4월에는 0.5σ 값을 상회하는 양의 값을 보였기 때문에(Figure 46c and e) 7월 흑서 일수가 평년보다 많을 것으로 예상되었으나 실제 0.2일(-2.8일의 편차)의 적은 흑서 일수(Figure 46b, 붉은 별표시)를 기록하였다.

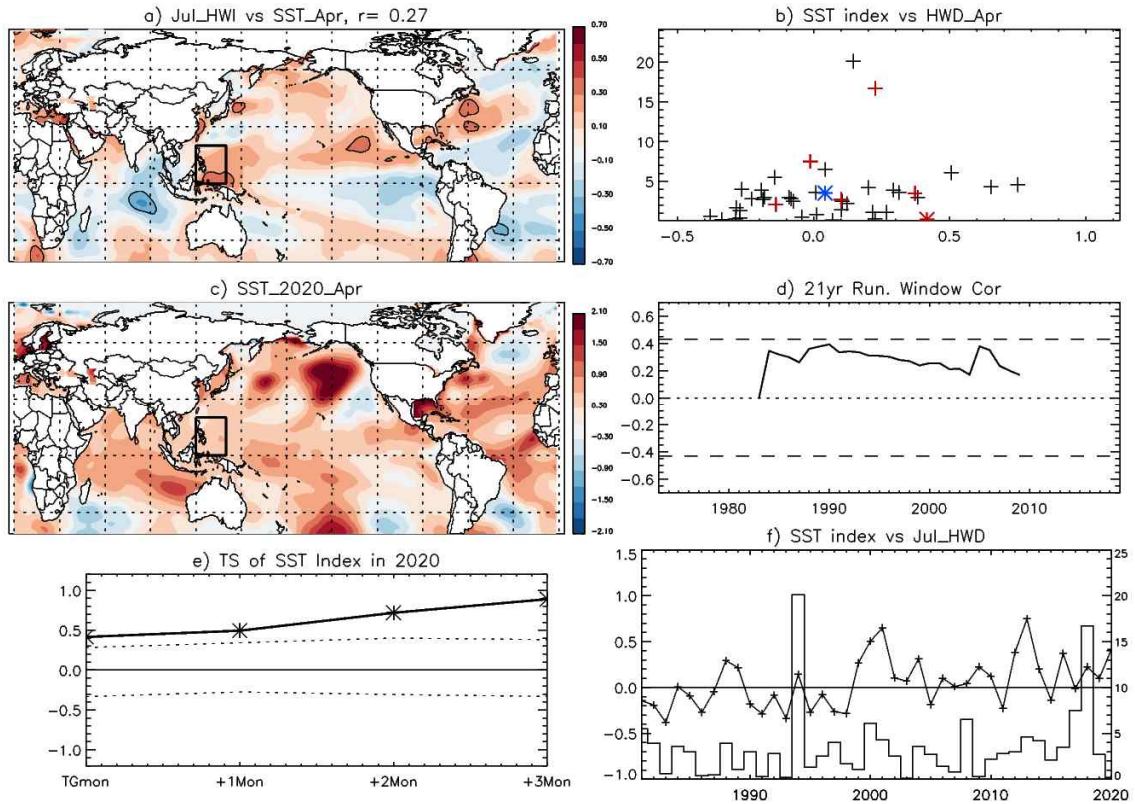


Figure 46. a) 39-year (1981-2019) correlation map between HWD in July and SSTs in April, b) scatter plot of HWD in July (y-axis) and SST_WP (x-axis), c) SST anomalies in April, 2020, d) 21-year sliding correlations of HWD in July and SST_WP from 1973-1993 to 1999-2019, e) time series of the SST_WP value from April to July in 2020, and f) time series of HWD in Jul (bar with the right y-axis) and SST_WP (cross with solid line with the left y-axis). The box in a) and c) indicates the region of the SST_WP index. Red crosses in b) indicates the recent five year (2015-2019) cases while blue star does 39-year average value. Long-dashed lines in d) show statistical significance at the 95% level. Short-dashed lines in e) show $\pm 0.5\sigma$ levels.

각각의 감시 인자에 대한 3분위 예측성을 테스트하였다. 감시 인자와 7월의 평균온도, 혹은 일수에 대하여 각 변수가 정규분포를 따른다고 가정한 후 $\pm 0.43 * \sigma$ 의 기준값에 대해 Above-Normal(AN), Below-Normal(BN), Near-Normal(NN)의 3분위로 구분하였다.

Accuracy(ACC)는 전체기간(1973-2019년)의 경우(T=47)에 대하여 AN, BN, 또는 NN을 적중한 경우의 수를 nAN, nBN, nNN이라 했을 경우

$$ACC = \frac{(nAN + nBN + nNN) \times 100}{T} \quad [13]$$

로 계산하였다.

Heidke Skill Score(HSS)는 NOAA Climate Prediction Center의 정의를 따라

$$HSS = \frac{(nAN+nBN - T/3) \times 100}{T \times 2/3} \quad [14]$$

로 계산하였다.

이와 함께 예측성의 장기 변화 추세를 보기 위하여 21년 이동기간에 대하여 ACC와 HSS를 각각 계산하고 최근 다섯 번의 21년 경우(1995-2015, 1996-2016, 1997-2017, 1998-2018, 1999-2019)와 초반 다섯 번의 21년 경우(1973-1993, 1974-1994, 1975-1995, 1976-1996, 1977-1997)에 대한 ACC 평균의 차이를 계산하였다.

SST_IO의 경우(Figure 47)에는 7월 평균온도와 혹서일수에 대해 47년 기간 동안 44.7%와 42.6%의 ACC를, 9.8%와 -8.4%의 HSS를 각각 보였다. 추세의 측면에서 평균기온 예측성은 증가하고 있지만(+8.6%) 폭염일수 예측성은 최근 들어 감소하는 경향(-40.0%)이 있다.




Figure 47. ACC (solid line) and HSS (dashed line) of a) average temperature and b) HWD in July for moving 21-year periods from 1973-1993 to 1999-2019 using the SST_WP index. Horizontal solid (dashed) line indicates ACC (HSS) for 47 years (1973-2019), which is also displayed in the first (second) number in the title.

SST_WP의 경우(Figure 48)에는 7월 평균온도와 혹서일수에 대해 47년 기간 동안 25.5%와 36.2%의 ACC를, -14.2%와 -10.5%의 HSS를 각각 보였다. 추세의 측면에서는 큰 변화 경향을 보이지는 않다.




Figure 48. ACC (solid line) and HSS (dashed line) of a) average temperature and b) HWD in July for moving 21-year periods from 1973-1993 to 1999-2019 using the SST_IO index. Horizontal solid (dashed) line indicates ACC (HSS) for 47 years (1973-2019), which is also displayed in the first (second) number in the title.

② 감시정보의 통합

위에서 기술한 바와 같이 6, 7, 8월의 기존 혹서 감시 인자에 대하여 통계분석을 수행한 후 결과를 정리하여 Figure 49-50으로 나타내었다. Figure 49에는 2020년 편차값이 0.5σ 이상인 인자들은 붉은색 글씨로, -0.5σ 이하인 인자들은 파란색 글씨로, 그 사이에 해당하는 인자들은 회색 글씨로 각각 표시하였고, 기준값 이상 또는 이하의 인자들이 전망하는 온도/혹서일수의 편차를 온도계의 색깔(붉은색: AN, 파란색: BN)로 표시하였다. 또한 괄호안에 47년 ACC

를 나타냄과 동시에 21년 이동 기간에 대한 ACC의 변화, 즉 최근 5개의 21년 경우의 ACC 평균과 처음 5개의 21년 경우 ACC 평균의 차이가 $\pm 10\%$ 보다 큰 경우 그 차이 역시 표시하였다. 즉 양(음)의 값은 ACC가 최근에 증가(감소)했음을 의미한다. 한편 감시 인자와 그 전망을 한눈에 알아볼 수 있도록 Figure 50과 같이 지도 위에 나타낸 정보 역시 생산하였다.

6월 기온 감시 인자는 3월의 중국 눈덮임을 제외한 세가지 인자(4월 필리핀해 SST, 5월 북태평양 SST, 1월 열대 서태평양 SST)가 모두 AN을 전망하였고 7월은 4월 동인도양 SST를 제외한 세가지 인자(4월 필리핀해 SST, 5월 북태평양 SST, 4월 북미 지위고도 차이)가 AN을 전망하였다. 8월 기온 감시 인자는 네가지 인자(4월 필리핀해 SST, 5월 북태평양 SST, 2월 호주 북쪽 SST, 4월 동인도양 SST)가 모두 AN을 전망하였다. 4월 동인도양 SST의 경우 7-8월 평균온도와 음의 상관관계를 갖는 인자로 알려져 있지만 7월과 8월을 구별하여 분석한 결과 7월 평균기온과는 음의 상관관계, 8월 평균기온과는 양의 상관관계를 보였다. 그 이유는 4월의 동인도양 SST 편차가 높을 때 열대 서태평양에 발달하는 고기압성 흐름(Xie et al. 2009)이 7월에는 한반도 남쪽에 위치함으로써 한반도에 수증기 유입을 증가시켜 강수 증가를 유발하여 기온을 감소시키지만(즉 음의 상관관계) 8월에는 고기압성 흐름이 한반도까지 확장하여 한반도 기온을 증가시키게 된다(즉 양의 상관관계). 이러한 역학과정을 고려하여 4월 동인도양 SST 인자를 7월과 8월에 구분하여 적용하였다.












6월 기온	7월 기온	8월 기온
4월 필리핀해 SST(45,+10%) 	4월 필리핀해 SST(43,-40%) 	4월 필리핀해 SST(36,-7%) 
5월 북태평양 SST(43,+17%) 	5월 북태평양 SST(38,-13%) 	5월 북태평양 SST(40,-26%) 
1월 열대서태평양 SST(51,-7%) 	4월 북미 지위고도 차이(40,-16%) 	2월 호주북쪽 SST(51,-3%) 
3월 북중국 눈덮임(45,-3%) 	4월 동인도양 SST(36,+3%) 	4월 동인도양 SST(53,+2%) 
4월 호주부근 강수차이	3월 유럽 지위고도 차이	4월 동-서아시아 눈덮임 차이
	4월 동인도~필리핀 삼극 SST	3월 호주북쪽 강수편차
	3월 베링해 SST	4월 만주 눈덮임
	4월 만주 눈덮임	4월 북대서양 SST
	4월 북대서양 SST	

Figure 49. Summary of heat wave predictor, its ACC and decadal change (% numbers in parentheses), its projection of HWD in 2020 (color of thermometer; AN for red and BN for blue). Heat wave predictors in grey color are predictors with the value less than $\pm 0.5\sigma$. For more details, refer to the description in the main manuscript.

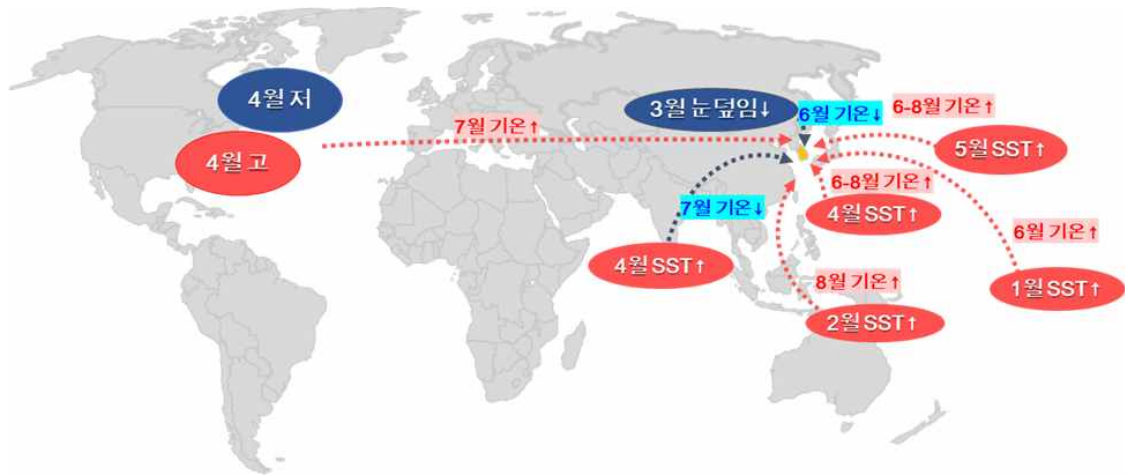


Figure 50. Map version of the summary of heat wave predictors and their predictions in 2020. For more details, refer to the description in the main manuscript.

(나) 감시인자 상세 역학 과정 검증 시스템 개발 및 활용

2020년 관측 결과 6월은 AN, 7월은 BN, 8월은 AN의 평균기온 및 혹서일수를 기록(Table 3)하였다. Figures 49와 50에서 보였듯이 대부분의 기온 감시 인자들이 평년 이상(AN)의 기온 및 혹서일수를 전망하였기에 7월의 전망정보의 불확실성이 크게 대두되었다. 7월의 감시 인자 기반 기온전망의 문제점을 살펴보기 위하여 감시 인자 상세 역학과정을 분석하고 검증 시스템을 아래와 같이 개발하여 2020년 여름에 적용하였다. 이에 더해 상세 역학 과정 검증 시스템을 차후 예측에 활용하는 방안을 모색하여 제안하였다.

Table 3. Anomalies of monthly (June~August) mean temperature (Tm, °C) and heat wave days (HWD) 2020.

	June	July	August
Tm	1.6	-2.5	1.5
HWD	3.4	-2.8	2.9

① 상세 역학 과정 검증 시스템 개발

감시 인자가 한반도 폭염에 미치는 영향을 살펴보기 위하여 SST, 상층(200 hPa) 지위고도(HGT_200), 하층(850 hPa) 지위고도(HGT_85), 중층(500 hPa) 수직운동(OMG_500)과 감시 인자의 상관관계를 월별로 계산하였다. 상관관계는 1981년부터 2019년, 39년에 기반하였다. SST와의 상관관계 결과(Figure 51)에 따르면 SST_IO는 4월 열대 중동 태평양과 양의 상관관계, 인도양과 양의 상관관계를 갖는데 이른 여름철(5~6월)에 인도양과의 상관관계는 유지되는 반면 열대 중동 태평양 SST와의 상관관계가 상당히 약화되는 것을 확인할 수 있다. 이러한 패턴은 겨울철 엘니뇨 현상이 쇠퇴하며 인도양 SST 상승이 봄, 여름철까지 이어지는 Indian Capacitor

Effect(Xie et al. 2009)와 유사하다.

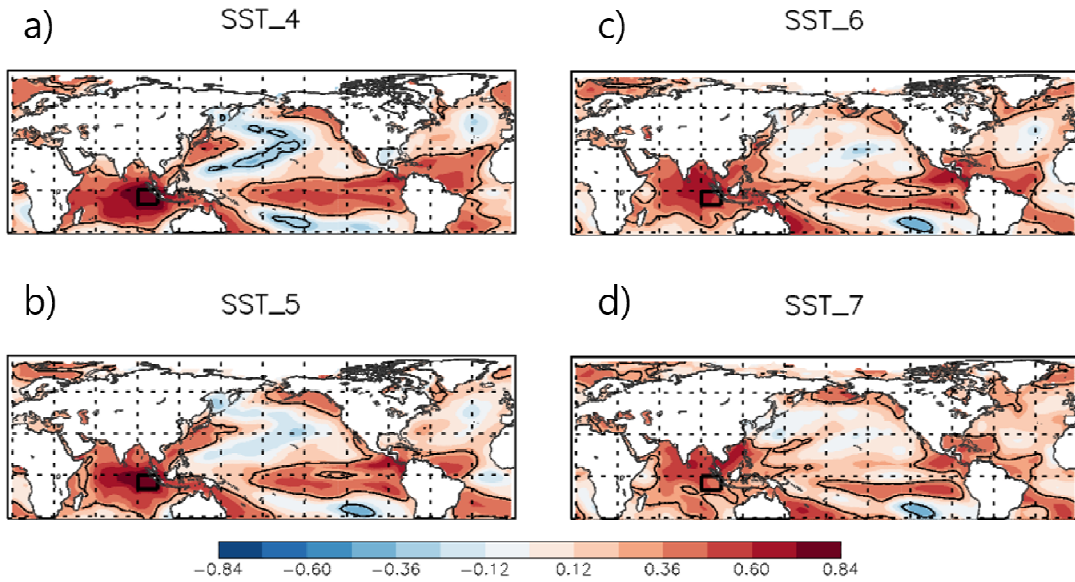


Figure 51. 39-year (1981-2019) correlations of SST_IO with monthly SSTs in a) April, b) May, c) June, and d) July. Black solid lines indicate statistically significant correlations at the 95% level.

대기 변수와의 상관성에서도 Indian Capacitor Effect와 유사한 결과가 나타난다. SST_IO는 4월~7월까지 열대 서태평양 상하층에 지속되는 고기압성 흐름과 연관되어 있다(Figure 52). 특히 필리핀 해 주변의 대류가 억제되는 현상이 4월에서 7월까지 지속되는데(Figure 52c f, i) 5월에는 한반도/일본 남부 바로 남쪽의 해상에 발달한 대류대(고기압 가장자리를 따른 고온다습한 공기의 수렴)가 7월에는 한반도까지 북진하는 형태를 볼 수 있다. 그로인한 한반도 강수 증가와 함께 필리핀해 북쪽의 고기압성 흐름과 대류 억제에 대한 보상작용으로 한반도와 일본 북쪽에 저기압성 흐름을 유발(Xie et al. 2009)함으로써 7월에 한반도 저온 현상이 나타나게 된다.

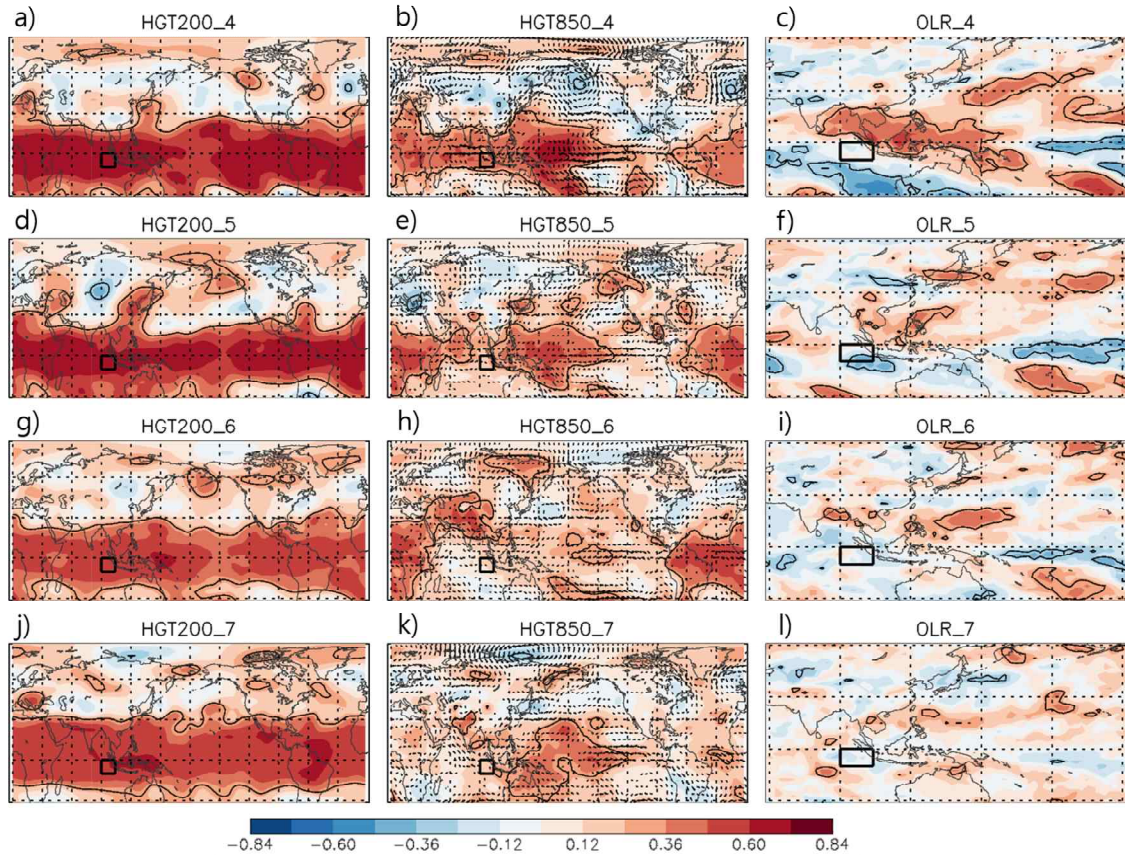


Figure 52. 39-year (1981-2019) correlations of SST_IO with monthly HGT200, HGT850, winds at 850 hPa, and OLR in a-c) April, d-f) May, g-i) June, and j-l) July. Black solid lines indicate statistically significant correlations at the 95% level.

한편 이러한 상세 기작들이 예측하고자 하는 해에 실질적으로 나타났는지를 확인해 보는 과정은 사후 분석에도 중요할 뿐 아니라 향후 예측성 향상에 도움이 될 수 있다. 감시 인자와 기온(혹은 혹서일수)에 대하여 3분위 기준으로 적중했다고 하더라도 상세한 역학기작 역시 뒷받침 되지 않을 경우 우연에 의해 적중한 경우일 수 있기 때문이다. 이를 위해 본 연구에서는 감시 인자 상관관계 패턴이 예측하고자 하는 월의 해당 변수 편차장과 공간적으로 얼마나 유사한지를 확인하기 위해 한반도 주변지역에 대해 감시 인자-대기변수 상관관계와 전망하고자 하는 해의 대기변수 편차 간 공간 패턴 상관관계 지수(pattern correlation coefficient, PCC)를 구하였다.

예를 들어 7월 혹서 감시 인자인 SST_IO와 상층 지위고도장의 경우, SST_IO와 7월의 HGT200의 과거 39년 상관관계 지수(격자별)와 금년 7월의 HGT200 편차(격자별)에 대하여 한반도 주변지역(90E~165E/10N~50N, Figure 53에서 한반도를 포함한 사각형 지역) 527개(=31×17)의 격자점에 대해 PCC를 구하였다. 관심 대기변수는 HGT200, HGT850, OMG500으로써 하나의 감시 인자에 대해 HGT200, HGT850, OMG500에 대한 세 개의 PCC 값이 월별로 산출된다. Figure 53은 2020년 각 월의 편차 값(HGT200, HGT850, OMG500에 대해 각각)을 컨투어로 표시한 위에 SST_IO에 대한 과거기간 유의미한 상관관계를 갖는 격자를 점으로 표시하고 한반도 주변지역에 대한 PCC값을 괄호 안에 표시하였다.

SST_IO의 경우 4월에는 세 변수 모두 음의 PCC를 보이지만 5월부터 7월까지 5월 HGT200 경우를 제외한 모든 경우에 0.17~0.44의 양의 PCC를 보인다. 특히 OMG500의 경우 5월, 6월, 7월에 대해 0.44, 0.28, 0.39의 높은 PCC 값을 보이는데 SST_IO와 관련된 필리핀해 주변의 대류 억제와 한반도 바로 남쪽의 대류 활발의 특성이 금년 5월부터 7월까지 지속적으로 나타났음을 의미한다. 즉, SST_IO와 관련된 기작이 올해 활발히 나타나며 SST_IO가 7월의 낮은 기온편차 및 폭서일수에 영향을 미친 것으로 추측할 수 있다.

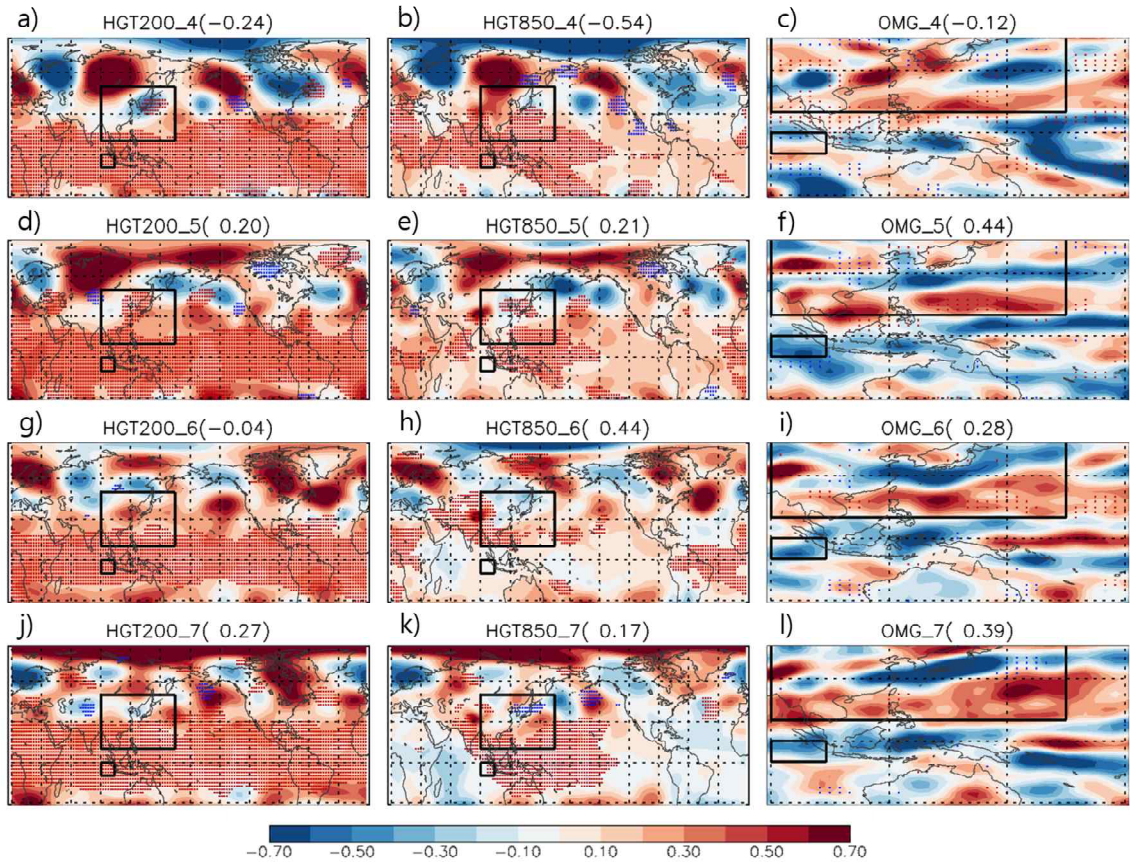


Figure 53. Anomalies of HGT200, HGT850, and OMG500 in 2020 overlaid onto the 39-year (1981-2019) correlations of SST_IO with monthly HGT200, HGT850, and OMG500, respectively, in a-c) April, d-f) May, g-i) June, and j-l) July. Red and blue dots indicate statistically positive and negative significant correlations at the 95% level, respectively. Numbers in parentheses are the pattern correlation coefficients between the anomalies in 2020 and the 39-year correlation coefficients of each variable (i.e., HGT200, HGT850, and OMG500) in the black solid box including Korean Peninsula.

한편 SST_WP의 경우는 4월 열대 서태평양에서 북태평양 SST와 양의 상관관계를 열대 중태평양 SST와는 음의 상관관계를 갖는데(Figure 54) 이러한 라니냐 유사 상관관계 패턴은 6월 까지 유지된다. 대기에서는(Figure 55) 인도차이나 반도를 포함한 남아시아와 필리핀 해에서 저기압성 흐름(Figure 55b, e, h, k)과 대류 강화(Figure 55c, f, i, l)가 4월부터 7월까지 지속적으로

관찰된다. 특히 대류와 관련하여 4월에는 남중국해와 필리핀해 남쪽에서 강한 상관관계가 나타나는 반면 7월에는 남중국해와 필리핀해 북쪽에서 강한 상관관계가 나타나는 등 대류지역이 북진하는 형태를 보인다. 이러한 대류 발달의 보상 기작으로 북쪽인 한반도와 동아시아에는 하강기류(Figure 55i, j)와 고기압성 흐름(Figure 55g, j)이 발달하며 한반도에 고온과 폭염을 야기한다(e.g., Lim and Seo 2019).

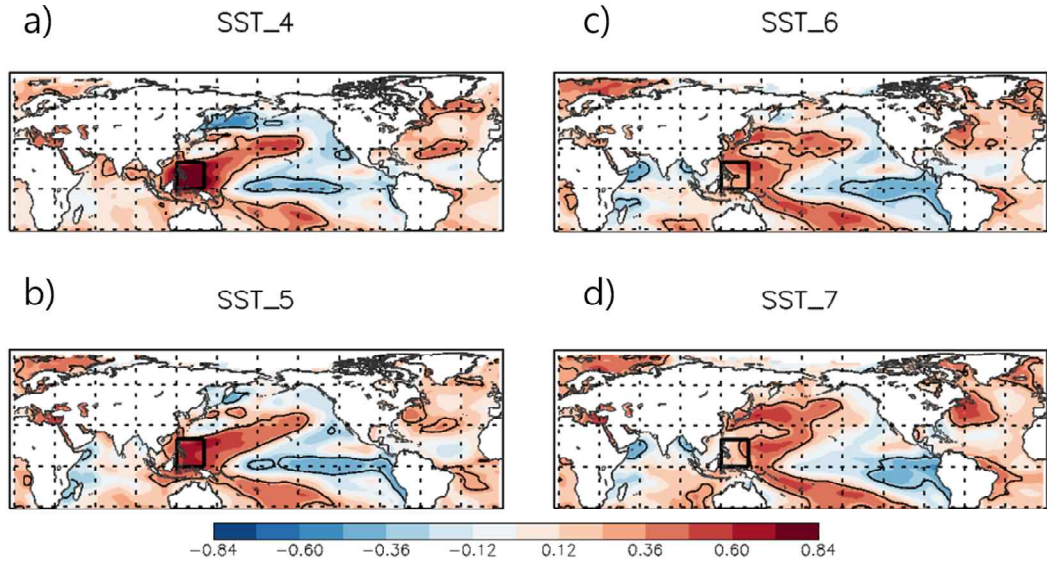


Figure 54. 39-year (1981-2019) correlations of SST_WP with monthly SSTs in a) April, b) May, c) June, and d) July. Black solid lines indicate statistically significant correlations at the 95% level.

상세 기작을 확인하는 PCC의 경우(Figure 56) 4월에는 세 변수 모두 양의 PCC를 보이지만 5월부터 7월까지 대부분의 값이 0에 가깝거나 음의 값을 보인다. 특히 HGT850의 경우 5월, 6월, 7월에 대해 각각 -0.26, -0.21, -0.16의 음의 PCC 값을 보이는데 이는 SST_WP와 관련된 필리핀해 주변의 대류 강화와 한반도 고기압성 흐름의 특성이 올해 나타나지 않았음을 의미한다. 즉, 금년 2020년에 4월에 SST_WP값이 평년보다 높았지만 한반도에 폭염을 유발하는 그와 관련된 기작이 올해 나타나지 않았음을 의미하며 실제로 관측된 2020년 7월의 낮은 기온편차 및 흑서일수가 이러한 주장과 일치한다.

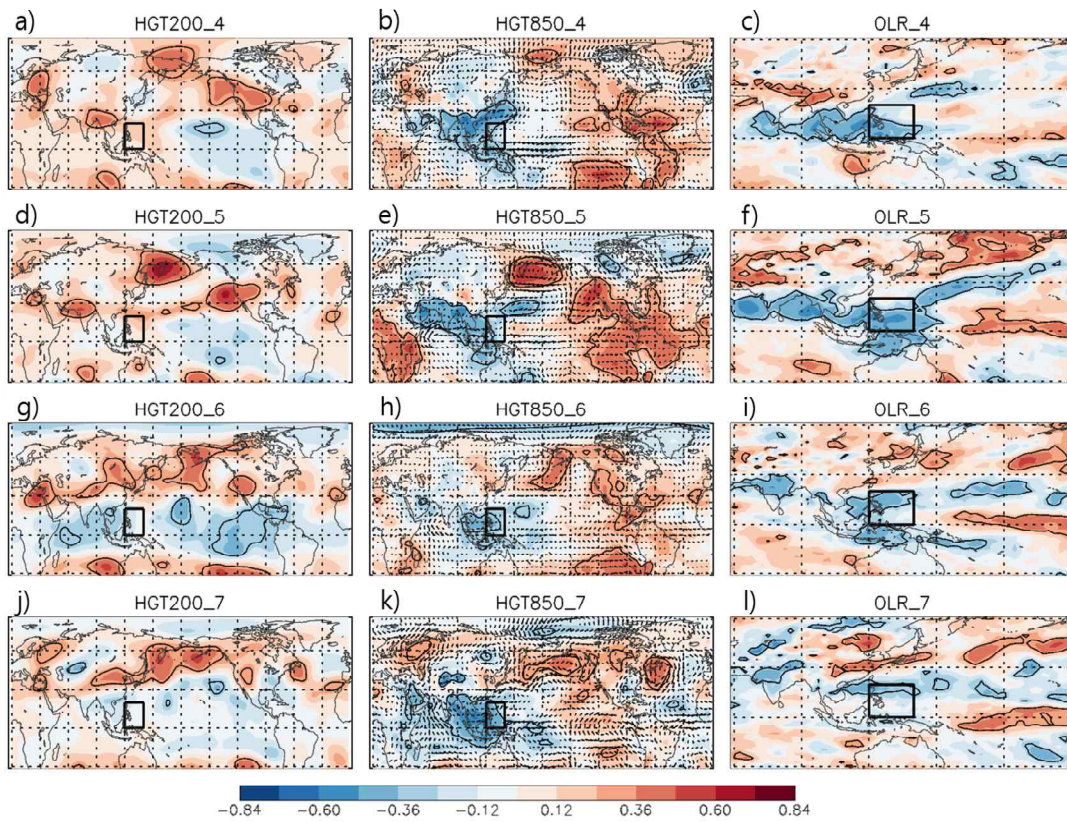


Figure 55. 39-year (1981–2019) correlations of SST_WP with monthly HGT200, HGT850, winds at 850 hPa, and OLR in a–c) April, d–f) May, g–i) June, and j–l) July. Black solid lines indicate statistically significant correlations at the 95% level.

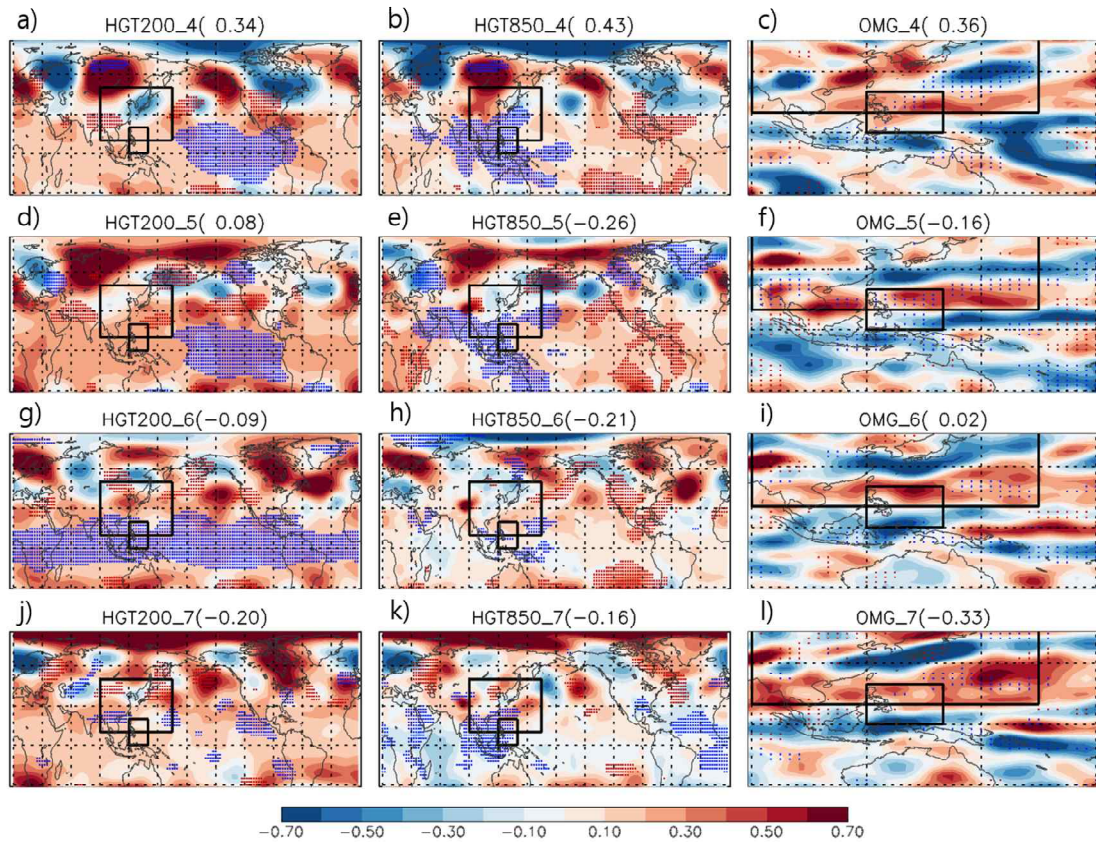


Figure 56. Anomalies of HGT200, HGT850, and OMG500 in 2020 (contours) overlaid onto the 39-year (1981-2019) correlations (dots) between SST_WP and monthly HGT200, HGT850, and OMG500, respectively, in a-c) April, d-f) May, g-i) June, and j-l) July. Red and blue dots indicate statistically positive and negative significant correlations at the 95% level, respectively. Numbers in parentheses are the pattern correlation coefficients between the anomalies in 2020 and the 39-year correlation coefficients of each variable (i.e., HGT200, HGT850, and OMG500) in the black solid box including Korean Peninsula.

② 상세 역학 과정 검증 시스템 적용

6월, 7월, 8월 폭서에 대한 감시 인자들의 동시상관(즉 Lag 0) PCC를 Table 4, 5, 6에 각각 표시하였다. 6월의 경우 대부분의 값들이 음의 상관관계 또는 0에 가까운 PCC 값을 보이고 있다. 7월의 경우 4월 동인도양 SST(i.e., SST_IO) 인자의 PCC는 모두 양의 값으로 HGT200과 OMG500의 경우 0.25보다 높은 값을 보였다. 8월의 경우 2월 호주 북쪽 SST 인자의 PCC는 모두 양의 값으로 세 변수 모두 0.25보다 높은 값을 보였다. 이러한 결과는 이 두 변수의 경우 상세 역학 기작과 올해의 편차장이 상당히 유사하였음을 의미한다. 이 인자들은 2020년 7월에 평년 이하(BN), 8월에 평년 이상(AN)의 기온 및 폭서일수를 각각 전망(Figure 49)했고 관측 또한 일치한 것으로 보아(Table 2) 4월 동인도양 SST 인자가 7월 저온 및 평년 이하 폭서일수에, 2월 호주북쪽 SST 인자가 8월의 고온 및 평년 이상 폭서일수에 기여한 것으로 추측된다. 특히 7월의 경우 평년 이상(AN)의 기온 및 폭서 일수를 전망했던 감시 인자들(4월 필리핀해 SST, 5월 북태평양 SST, 4월 북미 지위고도 차이)의 PCC는 대부분 음의 값을 보였는데 이는 이러한 감시 인자에 기반한 기온 전망은 2020년에 적중할 가능성이 낮음을 의미하며 관측 또한 이와

일치하는 결과가 나타났다. 이러한 결과들은 감시 인자 상세 역학 과정 검증 시스템을 이용하여 예측하고자 하는 해에 상세 기작들이 실질적으로 발현 되었는지를 확인 할 수 있으며 향후 예측성 향상에 도 기여할 수 있음을 의미한다.

Table 4. Pattern correlation coefficient (PCC_HGT200) in June over East Asia between HGT200 anomalies in 2020 and the 39-year correlation coefficients (HGT200 in June and predictor). PCC_HGT850 is the same for HGT850 but HGT200, and PCC_OMG500 is the same for OMG500 but HGT200. PCC values greater than 0.25 are in bolds.

감시 인자	PCC_HGT200	PCC_HGT850	PCC_OMG500
4월 필리핀해 SST	-0.09	-0.21	0.02
5월 북태평양 SST	0.00	0.17	0.01
1월 열대서태평양 SST	-0.41	0.22	0.02

Table 5. Pattern correlation coefficient (PCC_HGT200) in July over East Asia between HGT200 anomalies in 2020 and the 39-year correlation coefficients (HGT200 in July and predictor). PCC_HGT850 is the same for HGT850 but HGT200, and PCC_OMG500 is the same for OMG500 but HGT200. PCC values greater than 0.25 are in bolds.

감시 인자	PCC_HGT200	PCC_HGT850	PCC_OMG500
4월 필리핀해 SST	-0.20	-0.16	-0.33
5월 북태평양 SST	-0.18	-0.22	-0.39
4월 북미지위고도 차이	0.07	0.18	-0.13
4월 동인도양 SST	0.27	0.17	0.39

Table 6. Pattern correlation coefficient (PCC_HGT200) in August over East Asia between HGT200 anomalies in 2020 and the 39-year correlation coefficients (HGT200 in August and predictor). PCC_HGT850 is the same for HGT850 but HGT200, and PCC_OMG500 is the same for OMG500 but HGT200. PCC values greater than 0.25 are in bolds.

감시 인자	PCC_HGT200	PCC_HGT850	PCC_OMG500
4월 필리핀해 SST	0.02	-0.45	-0.08
5월 북태평양 SST	-0.13	-0.67	-0.18
2월 호주북쪽 SST	0.43	0.44	0.29
4월 동인도양 SST	-0.14	0.12	0.04

③ 상세 역학 과정 검증 시스템의 활용 방안 제안

상기 섹션에서는 감시 인자의 상세 역학 과정 검증 시스템을 개발하여 2020년 여름철 사후 분석을 수행하였다. 이 섹션에서는 상세 역학 과정 검증 시스템을 예측에 활용하는 방안을 제안하기 위하여 과거 39년에 대하여 Lead 2개월 시점에서 PCC를 고려 안할 경우와 PCC를 고려할 경우 감시 인자의 ACC의 변화를 살펴보았다. PCC를 고려 안할 경우의 ACC(=ACC_noPCC)는 3분위 기준(정규분포를 가정하고 $\pm 0.43\sigma$)시 감시 인자가 AN 또는 BN에 해당하는 경우의 수(=Ntotal)에 대하여 혹서 일수가 적중한 경우의 수(=N_correct)의 비율로써 다음과 같이 표시하였다. 감시 인자가 NN인 경우는 관심대상이 아니기 때문에 고려하지 않았다.

$$ACC_noPCC = \frac{N_correct \times 100}{Ntotal} \quad [15]$$

PCC를 고려한 경우의 ACC(=ACC_PCC)는 감시 인자가 AN 또는 BN에 해당하는 동시에 세 개의 PCC 값(i.e., PCC_HGT200, PCC_HGT850, PCC_OMG500) 중 두 개 이상이 PCC의 기준 값(=Threshold_PCC, 0.1~0.3) 이상인 경우의 수(=N_PCCtotal)에 대하여 혹서 일수가 적중한 경우의 수 (=N_PCC_correct)의 비율로써 다음과 같이 표시하였다.

$$ACC_PCC = \frac{N_PCC_correct \times 100}{N_PCCtotal} \quad [16]$$

7월의 두 감시 인자(4월 필리핀해 SST와 4월 동인도양 SST)에 대해 PCC를 고려하지 않은 경우와 PCC를 고려한 경우의 ACC 값을 Figure 57에 나타내었다. PCC 고려시 기준값인 Threshold_PCC를 0.1부터 0.3까지 0.05의 차이를 두고 다양하게 시도하였다.

그 결과 PCC를 고려 안 할 경우 ACC가 40% 이하였지만 PCC를 고려할 경우 40~75%의 ACC를 보이며 ACC가 증가하는 경향이 두 경우에 공통적으로 나타났다. 특히 4월 동인도양 SST의 경우 PCC 비 고려시 28%의 ACC를 보였지만 0.3의 기준으로 PCC를 고려할 경우 75%로 급격히 증가하였다. 이는 PCC를 고려할 경우 감시 인자의 예측력이 증가하며 경우에 따라 급격한 예측력 상승이 가능함을 시사한다. 이 부분에서 한가지 고려해야 할 사항은 PCC를 고려 할수록, 그리고 기준값이 높아질수록 해당하는 경우의 수가 줄어든다는 것이다; Figure 58에 보였듯이 PCC를 고려하지 않을 경우에 총 39개의 경우 중 33~34의 경우가 이에 해당하지만 0.1 기준의 PCC를 고려할 경우, 그 수가 1/2(14~16개)정도로 줄어들며 0.3 기준의 PCC의 경우 1/8(4개)의 경우로 줄어든다. 이 결과는 PCC를 고려하고 그 기준값을 높일수록 감시인자의 예측력은 증가하나 그에 해당하는 경우의 수는 상대적으로 감소하므로 예측의 유용성에 있어서는 불리할 수 있음을 의미한다. 따라서 향후 적절한 PCC 기준 값을 선정하여 예측력 상승과 유용성을 적절히 고려한다면 상세 기작 검증 시스템을 이용하여 감시 인자의 예측력을 꺾을 수 있을 것으로 기대된다.

Sensitivity of Accuracy to PCC
(Lead 2 mon: May)



Figure 57. ACC of SST_WP (orange bar) and SST_IO (blue bar) without considering PCC (ACC_noPCC; first column) and with considering PCC (ACC_PCC; from second to 6th column). When considering PCC, values of PCC (Threshold_PCC) vary from 0.1 to 0.3. Among HGT200, HGT850, and OMG500, if PCCs are greater than Treshold_PCC for more than two variables, it is considered to be a hit.

Number of Cases
(Lead 2 mon: May)



Figure 58. Total number of cases of SST_WP (orange bar) and SST_IO (blue bar) without considering PCC (N_total; first column) and with considering PCC (N_PCC_total; from second to 6th column). When considering PCC, values of PCC (Threshold_PCC) vary from 0.1 to 0.3. Among HGT200, HGT850, and OMG500, if PCCs are greater than Treshold_PCC for more than two variables, it is considered to be a hit.

(다) 새로운 감시인자 발굴

① Polar/Eurasia 원격 상관 패턴

Polar/Eurasia 원격상관 패턴(POL)은 북미대륙, 동아시아 및 북서태평양, 남아시아 등 북반구의 넓은 지역의 변동성과 연관되어 있다(Figure 59). 겨울철과 봄철에는 특히 동시베리아해, 북중국/오호츠크해, 북서 아열대 태평양 간 지위고도장의 상대적인 패턴 으로 양(음)의 패턴은 동시베리아해에 저기압성(고기압성) 흐름, 한반도 북쪽에 고기압성(저기압성) 흐름, 북서태평양에 저기압성(고기압성) 흐름의 형태를 보인다.




Figure 59. Geopotential height (500 hPa) spatial pattern of Polar/Eurasia teleconnection pattern in January (from <http://www.cpc.ncep.noaa.gov/data/telecod/poleur.shtml>).

POL과 한반도 혹서현상과의 연관성을 살펴보기 위해 POL 지수의 3개월 평균값(이전해 10월-12월부터 6-8월까지)과 한반도 7-8월 평균 온도(Ts_{JA}) 및 혹서일수(HWD_{JA})와의 상관관계(29년 기간, 1991-2019)를 Figure 60에 도시하였다. 그 결과 겨울철과 봄철에 대부분 유의미한 음의 상관관계를 보이는 가운데 특히 2-4월 평균(POL_{FMA})은 7-8월 평균 온도와 -0.71 , 혹서일수와는 -0.57 의 높은 상관관계를 보였다.




Figure 60. 29-year (1991-2019) correlations between 3-month running averages of POL from October-December to June-August and July-August average temperature (Ts_JA, red line) and b) HWD (HWD_JA, black line) in South Korea.

POL_FMA*(-1.0)와 Ts_JA의 시계열(Figure 61a)을 살펴보면 1980년대 중반부터 두 지수의 관련성이 높아진 가운데 2010년 이후 관련성이 매우 높은 것으로 보인다. 특히 기록적 폭염이 발생했던 2013년, 2016년, 2018년엔 POL_FMA의 값 또한 매우 낮았으며 상대적으로 서늘했던 2015, 2019, 2020년에는 POL_FMA의 값이 양의 값을 보였다. 21년 이동 상관관계 그래프에서도 최근 들어 특히 폭염일수와 상관관계가 매우 증가했음을 확인 할수 있다(Figure 61b).




Figure 61. a) Time series of Ts_JA (black) and POL_FMA (red) and b) 21-year sliding correlations of POL_FMA with Ts_JA (red) and with HWD_JA (orange). For convenience, the POL_FMA index is multiplied by (-1.0).

POL_FMA가 한반도 7-8월 온도에 미치는 기작을 분석하기 위하여 HGT200, HGT850, wind 850, SST, OMG500과의 상관관계를 계산하여 Figure 62에 나타내었다. 동시상관관계를 의미하는 2-4월(February-April, FMA) 기간 상층대기(200 hPa)에서는(Figure 62a) 동시베리아해, 한반도 북쪽, 일본 동남쪽 태평양 일대에 양-음-양의 상관관계 패턴이 나타나며 이는 음의 POL패턴과 일치한다. 상층 양의 상관관계는 인도부근과 남중국해 필리핀 주변지역에도 나타난다. 한편 하층(850 hPa)에서는(Figure 62b) 중위도 및 고위도 지역에서는 상층과 유사한 패턴이 나타나는 반면 인도 부근과 필리핀해 주변에서는 음의 상관관계를 보이며 경압대기의 패턴을 보여준다.

이러한 저층대기 기압패턴(인도/남중국해/필리핀해 저기압성 흐름과 일본 남쪽 해상 고기압성 흐름)으로 인해 열대 서태평양에는 동풍편차가, 열대 인도양에는 서풍편차가 발생하며 필리핀해에 남동풍 편차가 우세함에 따라 필리핀 해의 SST가 증가하게 된다(Figure 62c). 또한 필리핀 해에는 상층대기의 고기압성 흐름과 함께 하강기류가 우세함에 따라 대류가 억제되어(Figure 18d) 하향단파복사가 증가하고(그림 없음) 그로 인해 SST 증가에 기여하는 것으로 보인다. 이러한 패턴은 4-6월(April-June, AMJ)에도 유지 또는 강화되어 필리핀해의 SST가 지속적으로 증가하게 된다(Figure 62f, g).

7-8월에는 고온의 필리핀해와 동인도양 지역에서 대류가 활발해짐에 따라(Figure 62i) 북편으로 Rossby wave 전파에 의해 한반도를 포함한 동아시아 지역에 상층 고기압성 흐름이 발달하게 됨에 따라(Figure 62i) 한반도에 고온이 발생하게 된다.

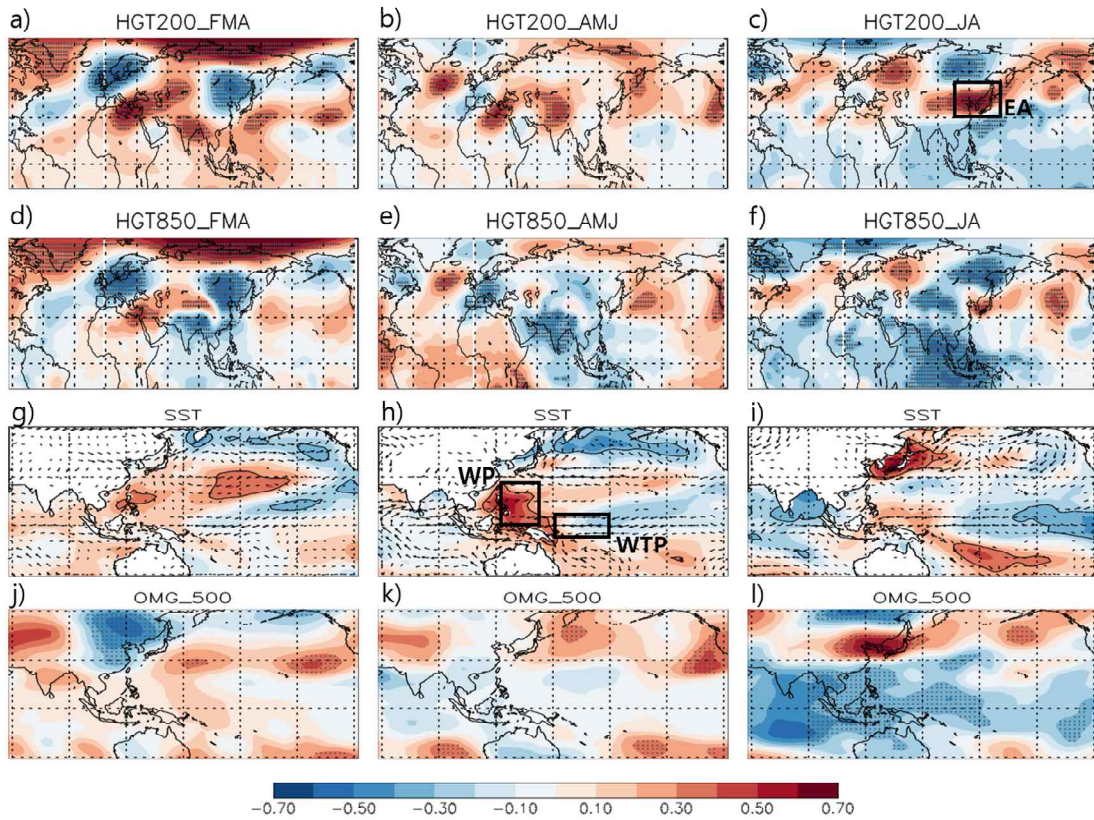


Figure 62. 39-year (1981-2019) correlations of POL_FMA with HGT200, HGT850, SST with winds at 850 hPa, and OMG500 in a-d) February-April, e-h) April-June, and i-l) July-August. Black dots in a-f and j-l and black solid lines in g-i indicate statistically significant correlations at the 95% level. For convenience, the POL_FMA index is multiplied by (-1.0). Black boxes indicate the specific regions for key variables in Figure 64.

남-북 단면 바람장과 POL_FMA*(-1.0)의 상관관계(Figure 63)에서도 필리핀해의 대류억제가 봄철까지 지속(Figure 63a, b)되다가 여름철이 되어 대류가 활발해 지고 북쪽인 한반도에 하강 기류가 강화되는 모습(Figure 63c)이 관찰된다.

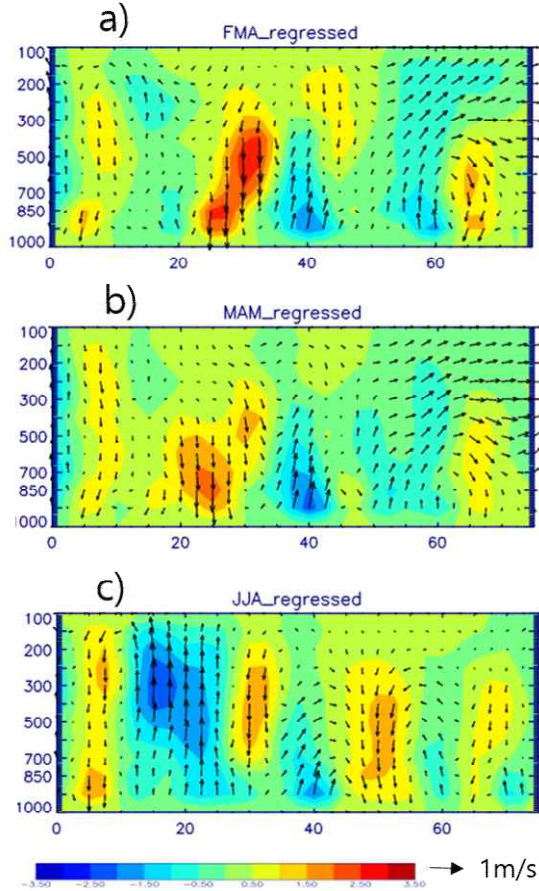


Figure 63. North-South cross section of 39-year (1981-2019) regressed winds (arrows) and vertical motions (contours) onto POL_FMA in a) February-April, b) March-May, and c) June-August at 130E. For convenience, POL_FMA values are multiplied by (-1.0).

이러한 기작을 확인하기 위해 양과 음의 POL_FMA해의 합성장을 구성하여 주요 변수에 대한 1월부터 3개월 연속(sliding) 평균 시계열을 살펴보았다. 합성해는 1991-2019년 기간 동안 POL_FMA값이 $+0.75\sigma$ 이상 및 -0.75σ 이하의 해를 양의 해(PosPOL_FMA), 음의 해(NegPOL_FMA)로 각각 지정(Table 7)하여 분석하였다. 주요 변수로는 Figure 62에 표시한 한반도 고층 고기압(H200_EA), 열대 서태평양 동풍(U_WTP), 필리핀해 SST(SST_WP), 필리핀해 하향단파복사(DSWR_WP), 필리핀해 상향장파복사(OLR_WP)를 포함한다. Figure 64a에 따르면 negPOL_FMA 해에 SST_WP가 겨울철부터 증가하여 봄철(MAM)에 최고조에 이른 후 점차 감소하는 모습을 보이는데 겨울~봄철 기간동안 열대 서태평양에는 동풍편차(U_WTP)가 지속 또는 강화되는 동시에 하향단파복사(DSWR_WP) 역시 양의 값을 보이는 등 SST_WP의 증가에 기여한 것으로 보인다. 이 기간에 OLR_WP는 양의 값을 보이는데 이는 필리핀해에서 대류가 억제됨을 의미한다. 반면 여름철이 되면서 OLR_WP이 음의 값으로 전환되며 대류가 활발해지고 한반도 고층 대기에 고기압성 흐름이 급격히 발달하는 형태를 보인다. 양의 합성해(Figure 64b)

에는 이와는 반대의 패턴이 나타남을 확인할 수 있다. Table 7에 표시된 합성해의 3분위 7-8월 평균온도를 살펴보면 NegPOL_FMA 해에 2004년을 제외한 경우에 AN 온도를 보였으며 PosPOL_FMA 해에는 BN 또는 NN의 온도 경향을 보이고 있다. 이러한 합성장 분석 결과는 POL_FMA이 서태평양의 해수면 온도와 대류활동을 조절함으로써 한반도 여름 온도와 폭서를 유발한다는 상기 기사를 다시 한 번 확인시켜준다.

Table 7. Composite years of negative and positive POL_FMA years ($\pm 0.75 \sigma$) from 1991 to 2019. Red, black, and blue colors indicate above-normal, near-normal, and below-normal July-August mean temperatures, respectively.

합성해	Composite years between 1991
NegPOL_FMA(음의 해)	2000, 2004, 2010, 2013, 2016, 2018
PosPOL_FMA(양의 해)	1991, 1993, 1996, 2003, 2015, 2019

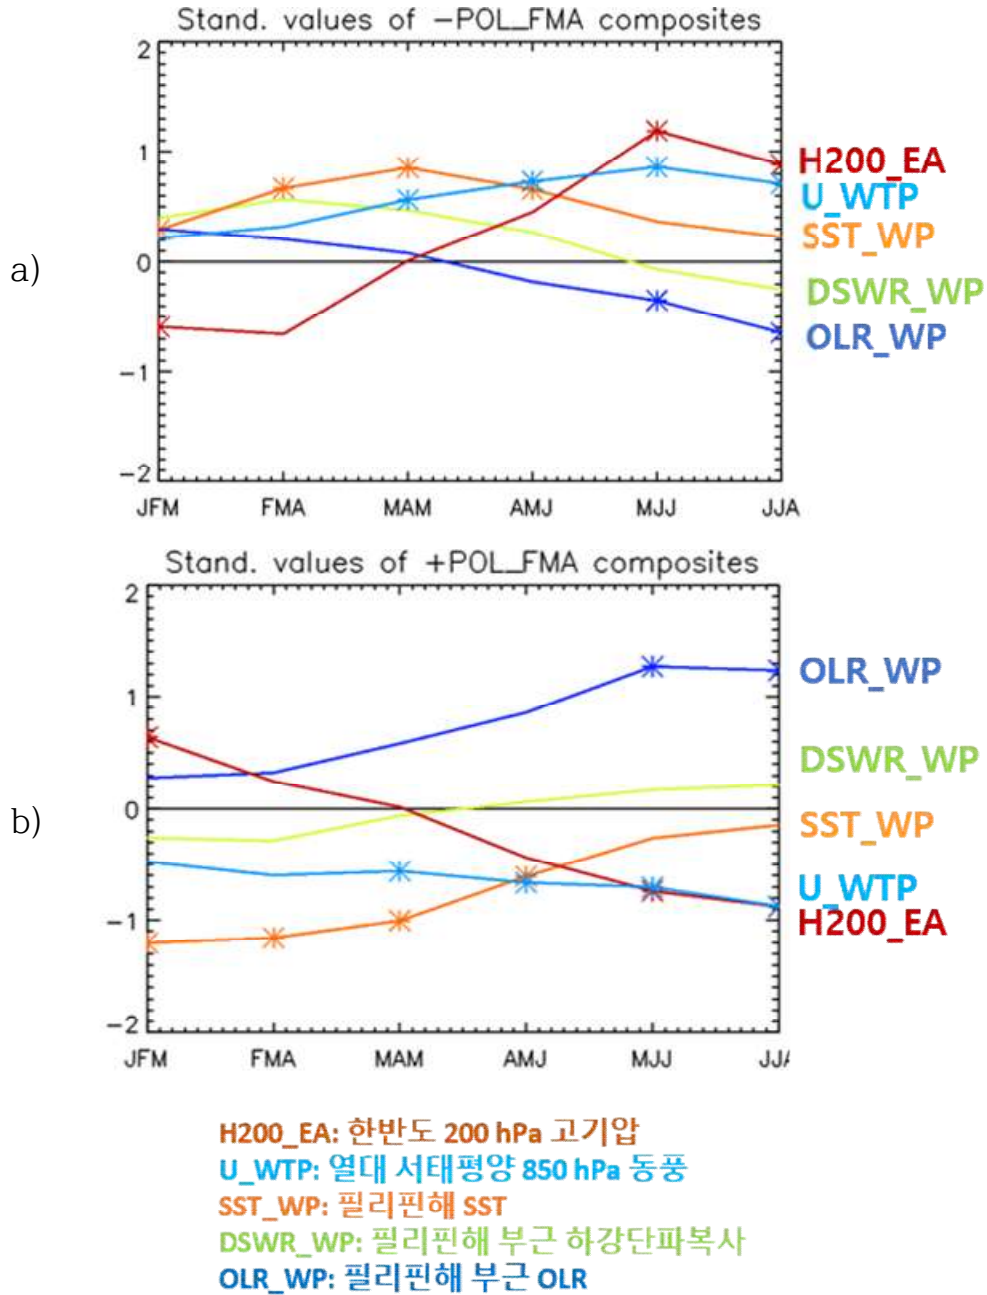


Figure 64. Standardized values of the key variables (3-month running averages from January-March to June-August) in the a) negative and b) positive POL_FMA composite years. The regions (EA, WP, WTP) of the key variables are shown in Figure 62.

흑서일수에 대한 POL_FMA의 예측성을 테스트 해보았다. 1973~2019의 47년에 대해 7월과 8월 흑서일을 3분위로 각각 나눈 후 ACC를 구한 결과 7월에 대해서는 53.2%, 8월에 대해서는 44.7%의 ACC를 보였다. ACC의 decadal 변화를 살펴보기 위하여 1973년부터 2019년까지 21년 이동 기간(예, 1973-1993, 1974-1994,,,1999-2019)에 대하여 ACC를 각각 구하여 Figure 65에 도

시하였다. 7월의 경우는 50~70%의 ACC를 보이면서 최근 들어 약간 감소하는 경향을 보이고 8월의 경우는 40~60%의 ACC를 보이지만 최근 들어 약간 증가하는 경향을 보이고 있다.




Figure 65. ACC of a) average temperature and b) HWD during July and August for moving 21-year periods from 1973-1993 to 1999-2019 using the POL_FMA index. Horizontal solid line indicates ACC for 47 years (1973-2019), which is also displayed by the number in the title.

위에서 분석한 POL_FMA이 7-8월 한반도 온도와 흑서에 미치는 영향에 대한 기작을 Figure 66의 모식도에 정리하였다.

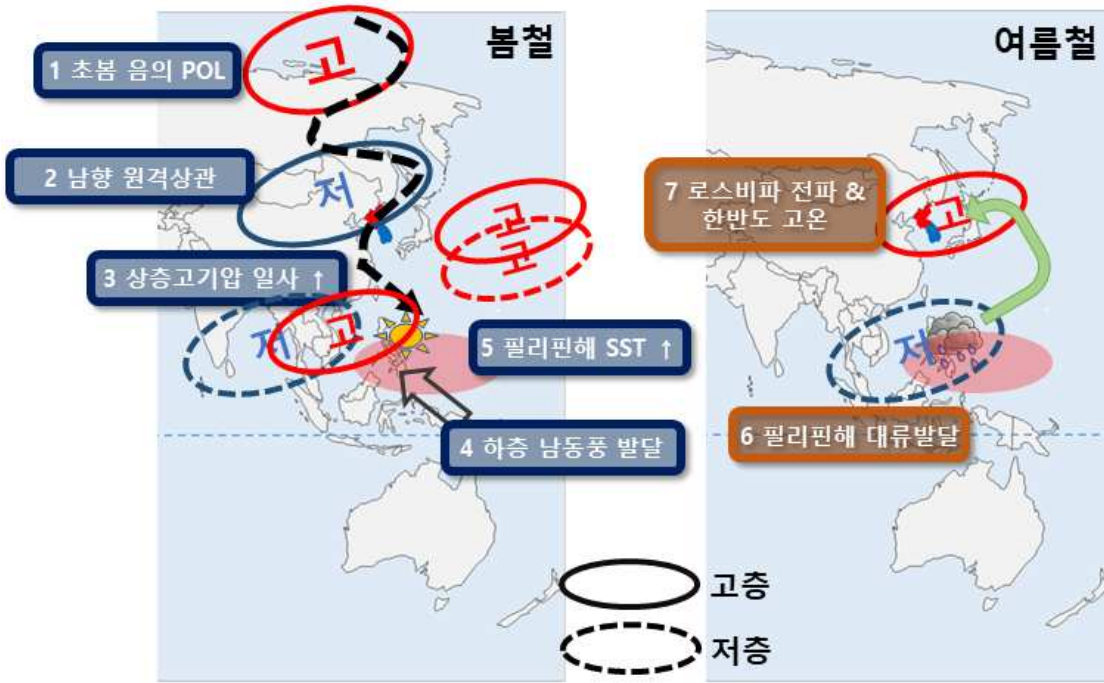


Figure 66. Schematic diagram of the impacts of POL_FMA on July-August mean temperature in South Korea.

(3) 자기조직화지도(Self-organizing Map) 기법활용 흑서기 이상기후 분석체계 구축

(가) 지역폭염(Regional Heatwave) 특성

한반도에서 1979년부터 2019년까지 발생한 지역폭염을 Table 8에 요약하여 제시하였다. 해당 기간동안 총 172회 지역폭염이 발생한 것으로 나타났으며, 7월이 83회로 가장 많았고, 6월은 19회로 가장 적게 발생하였다. 폭염지속일(Heatwave duration, HWD)이 36일로 가장 긴 지역폭염은 2018.7.12.부터 2018.8.16.까지 지속된 폭염이었고, 그 뒤를 이어 1994.7.3.에서 1994.7.31.까지 29일동안 지속된 지역폭염이 발생하였다. 폭염기간을 기준으로 보면, 6월이 평균

2.42 폭염지속일로 가장 작았고, 7월이 5.52 폭염지속일로 가장 긴 것으로 나타났다. 같은 기간 동안 연간 폭염발생일수의 추세를 살펴보면(Figure 67) 매년 0.037회의 매우 약하게 증가하는 추세이고, 유의확률은 약 90%에서 유의하였다.

Table 8. Characteristics of the monthly regional heatwaves for the period of 1979-2019.

Month	Occurrence	Mean (day)	Standard deviation (day)
6	19	2.42	0.69
7	83	5.52	5.83
8	70	4.19	3.31
Sum	172	-	-




Figure 67. Trend of the regional heatwaves for the period of 1979-2019.

(나) 지면조건의 한반도 폭염에 대한 예측인자 활용성 평가

① 자기조직화지도(Self-organizing Map, SOM) 기법 활용 한반도 폭염 패턴분류

총 3개 SOM 패턴(노드)으로 1979년부터 2019년까지 172회의 지역폭염을 자기조직화지도 기법을 활용하여 군집분류하였으며, Table 9에 요약하여 제시하였다. 분류된 각 군집들이 통계적으로 서로 구별되는 지 검정하는 기법으로 false discovery rate test (FDR test)를 실시하였으며, 분류된 3개 노드 모두 유의수준 0.05에서 유의한 것으로 나타났다. 군집분류 결과, 1번 노드에 63개가 분류되었고, 2번 노드에 88개로 가장 많은 지역폭염이 분류되었으며, 3번 노드에

21개로 가장 적게 분류되었다. 그러나, SOM 패턴별 지역폭염일수는 1번 노드에서 584일로 가장 많았고, 2번 노드가 464일로 분류되었으며, 3번 노드는 49일로 가장 적게 분류되었다. 이는 폭염지속일이 긴 지역폭염이 주로 1번 노드에 분류되었고, 폭염지속일이 짧은 지역폭염일은 주로 3번 노드에 분류되었음을 의미한다.

Table 9. SOM patterns for the regional heatwaves for the period of 1979-2019.

Node	Number of occurrences	Number of days
1	63	584
2	88	464
3	21	49
Sum	172	797

SOM 패턴별 6월, 7월, 8월에 발생한 지역폭염의 수를 비교해 보면(Figure 68), 6월에 발생한 지역폭염은 대부분 3번 노드에 분류되었으며, 7월에 발생한 지역폭염은 2번 노드에 대부분 분류되었다. 한편, 1번노드에는 8월에 발생한 폭염의 약 70%가 1번 노드에 분류되었으며, 나머지 모두는 2번 노드에 분류되었다. 7월에 발생한 지역폭염은 1번 노드와 3번 노드에도 작은 부분이지만, 분류가 되어, 3개 SOM 패턴 모두 7월에 발생할 수 있는 것으로 나타났다. 이와는 다르게 6월에 발생하는 폭염은 극소수지만 2번 노드에도 발생할 수 있지만, 1번 노드에는 발생하지 않았으며, 8월에 발생하는 폭염은 3번 노드에는 발생하지 않는 것으로 나타났다.

폭염지속일을 기준으로 3개 기간(short: ≤ 3 일, mid: $4\text{일} < \text{HWD} \leq 7$ 일, long: ≥ 8 일)으로 나누거나(Figure 69a), 2개 기간(short: ≤ 4 일, long: ≥ 5 일)으로(Figure 69b) 각각 나누어, SOM 패턴별로 도시하였다. Figure 69에서 보여주는 것과 같이, 3개 기간으로 나누었을 때, 3번 노드에는 폭염지속일이 short과 mid만 포함되어 있고 1번 노드와 2번 노드에는 short, mid, long 모두 포함되는 것으로 나타났다. 한편, 2개 기간으로 나누었을 때는, 3번 노드에는 폭염지속일이 short한 것만 포함되었고, long한 폭염은 1번 노드와 2번 노드에 비교적 비슷하게 포함되어 있다. 이러한 결과를 Table 3과 함께 종합하여 살펴보면, 6월에 발생하는 지역폭염은 대부분 폭염지속일이 짧은 폭염임을 알 수 있다.




Figure 68. Monthly regional heatwaves classified into the SOM patterns for 1979-2019.

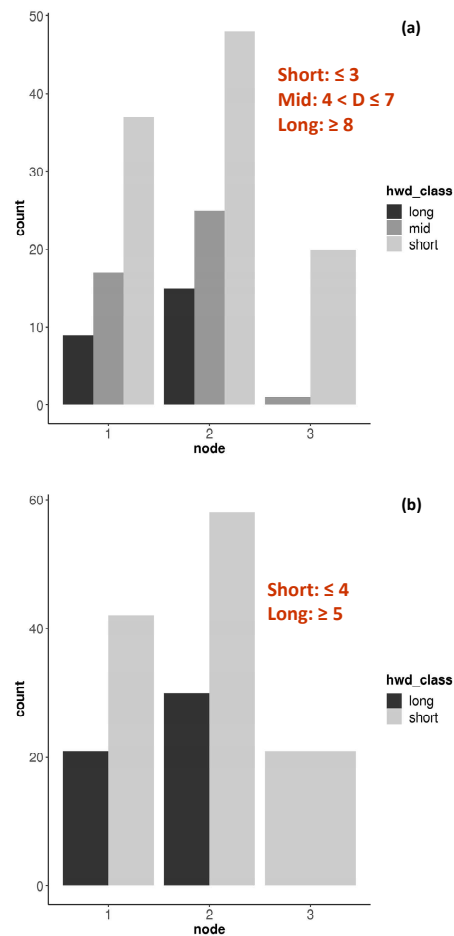


Figure 69. Durations of the regional heatwaves for 1979-2019. (a) three classifications and (b) two classifications.

SOM 패턴별 지역폭염발생 경향성을 분석하였으며, 분석 결과는 Figures 70과 71에 도시하였다. Figure 70a는 월별 지역폭염 발생횟수를 년도별 경향성을 나타내었고, Figure 70b는 각 SOM 패턴의 발생횟수를 년도별 경향성을 나타낸 그림이다. 이와 유사하게, 월별 지역폭염지속일에 대해 년도별 경향성은 Figure 71a에 표시 하였고, Figure 71b는 SOM 패턴별 지역폭염지속일에 대해 년도별 경향성을 나타내었다. 발생횟수와 폭염지속일 모두 3번 노드와 6월의 지역폭염은 뚜렷한 경향성을 보이지 않은 반면, 7월의 지역폭염 발생횟수와 폭염지속일은 모두 증가하는 경향을 보였다. 다만, 통계적 유의성을 보이지 않은 발생횟수와는 다르게 폭염지속일의 경우, 7월과 2번 노드는 유의확률 90%로 증가하는 경향성이 유의한 것으로 나타났다. 통계적으로 유의하지는 않으나, 1번 노드의 경우, 발생횟수와 폭염지속일에서 모두 감소하는 경향이 나타났다.

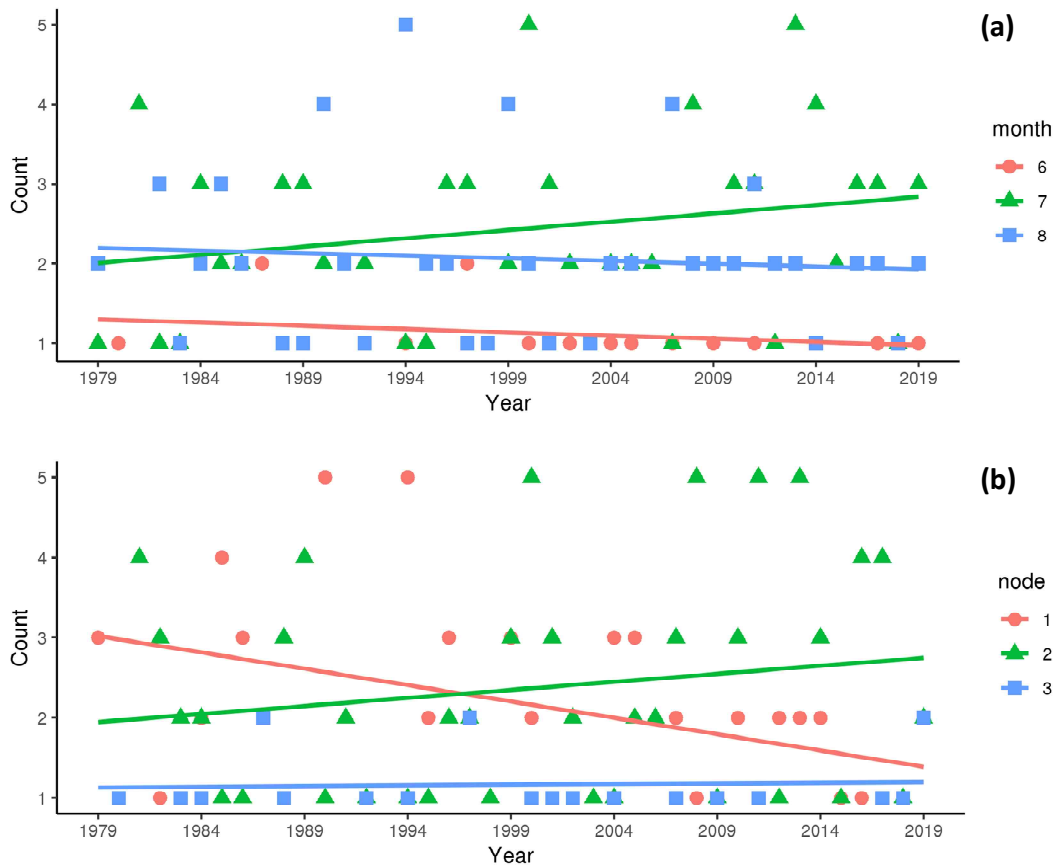


Figure 70. Trends of occurrences of the monthly regional heatwaves (a) and SOM patterns (b) for the period of 1979–2019.




Figure 71. Trends of durations of the monthly regional heatwaves (a) and SOM patterns (b) for the period of 1979-2019.

SOM 패턴별 대기순환장의 특성을 분석하기 위해 SOM 패턴별 아노말리를 구한다음, 각 지역폭염일에 해당하는 날의 500GPH와 850hPa 바람장의 합성장을 분석하였다. Figure 72a는 1번 노드의 합성장을 보여주고, Figure 72b는 2번 노드의 합성장을 도시하였으며, 3번 노드의 합성장은 Figure 72c에 도시하였다. Figure 72a의 500GPH 아노말리 합성장에서는 한반도 상공에 고기압을 중심으로 남서쪽과 북서쪽에 저기압성 순환이 자리잡은 전형적인 Pacific-Japan (P-J) 패턴과 매우 유사한 형태를 보여주고 있다. P-J 패턴은 한반도의 폭염에 영향을 주는 열대성 강제력(tropical forcing)의 한 형태로서 알려져 있다(Lee and Lee, 2016; Nitta 1987). 3번 노드에서는 대륙에서부터 파동의 전파 형태와 유사한 패턴이 보였다. 이 연구의 목적이 지면조건인 한반도 폭염에 대한 영향이나 상관성을 파악하여 새로운 감시 및 예측인자로써의 활용성을 검토하는 것이므로, 해양성의 영향이 큰 SOM 패턴(Figure 72a and b)은 제외하고 대륙의 영향이 큰 3번 노드의 폭염에 대해 토양수분을 추가적으로 분석하기로 하였다.

대륙의 영향이 더 큰 것으로 나타나 보이는(Figure 72c) SOM 패턴에 대해, 지면조건과 한반도의 폭염과의 상관성을 분석하기 위해 3번 노드에 대해 토양수분 아노말리 합성장을 구하였다. Figure 73a에서 보여주듯이, 1번 노드의 토양수분 아노말리 합성장에서는 양쯔강 유역에서 토양수분 음의 아노말리가 나타났으며, 2번 노드(Figure 73b)는 티벳고원을 제외한 중국 전역과 한반도에서 토양수분 음의 아노말리를 보였다. 한편, 3번 노드는 한반도를 포함하여 만

주와 중국의 북동지역에서 강한 음의 아노말리가 나타났다(Figure 73c). 참고로, 분석에 사용한 토양수분 자료에 따라, 나타나는 패턴은 유사했으나, 강도가 다소 상이하였는데, 이 보고서에는 분석결과를 포함하지 않았지만, ESA CCI SM v04.5보다 ERA-5 토양수분자료를 활용하여 분석했을 때, 위의 패턴이 더 뚜렷하게 나타났다.

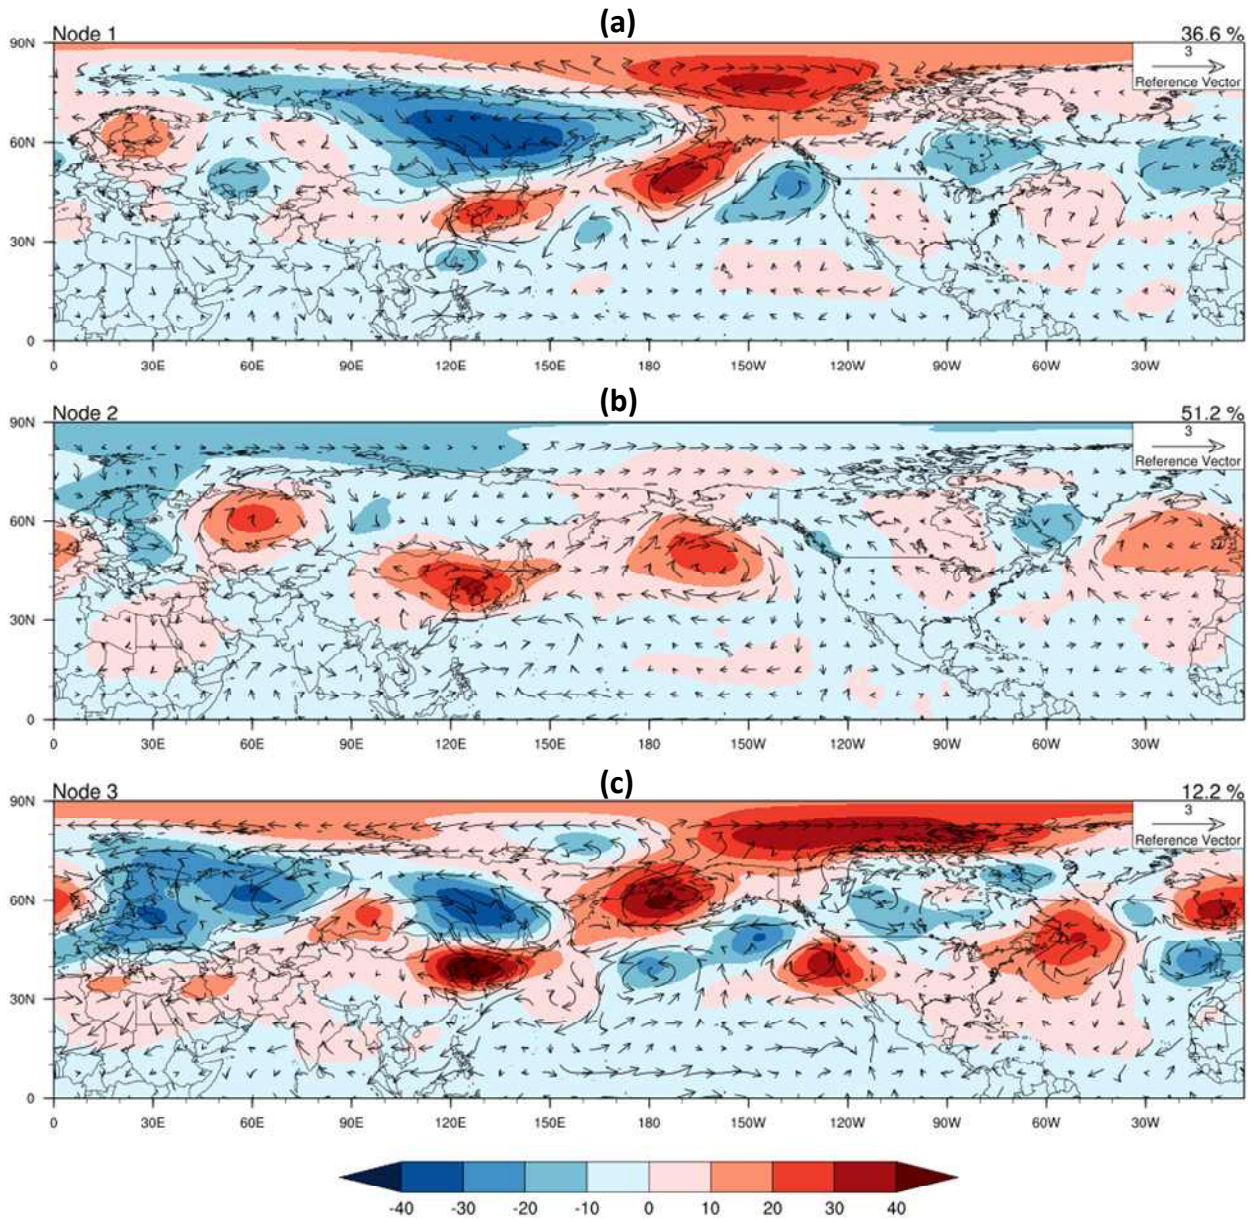


Figure 72. Composite fields of 500-hPa GPH (shading) and 850-hPa wind vector (arrow) for Node 1 (a), Node 2 (b), and Node 3(c).

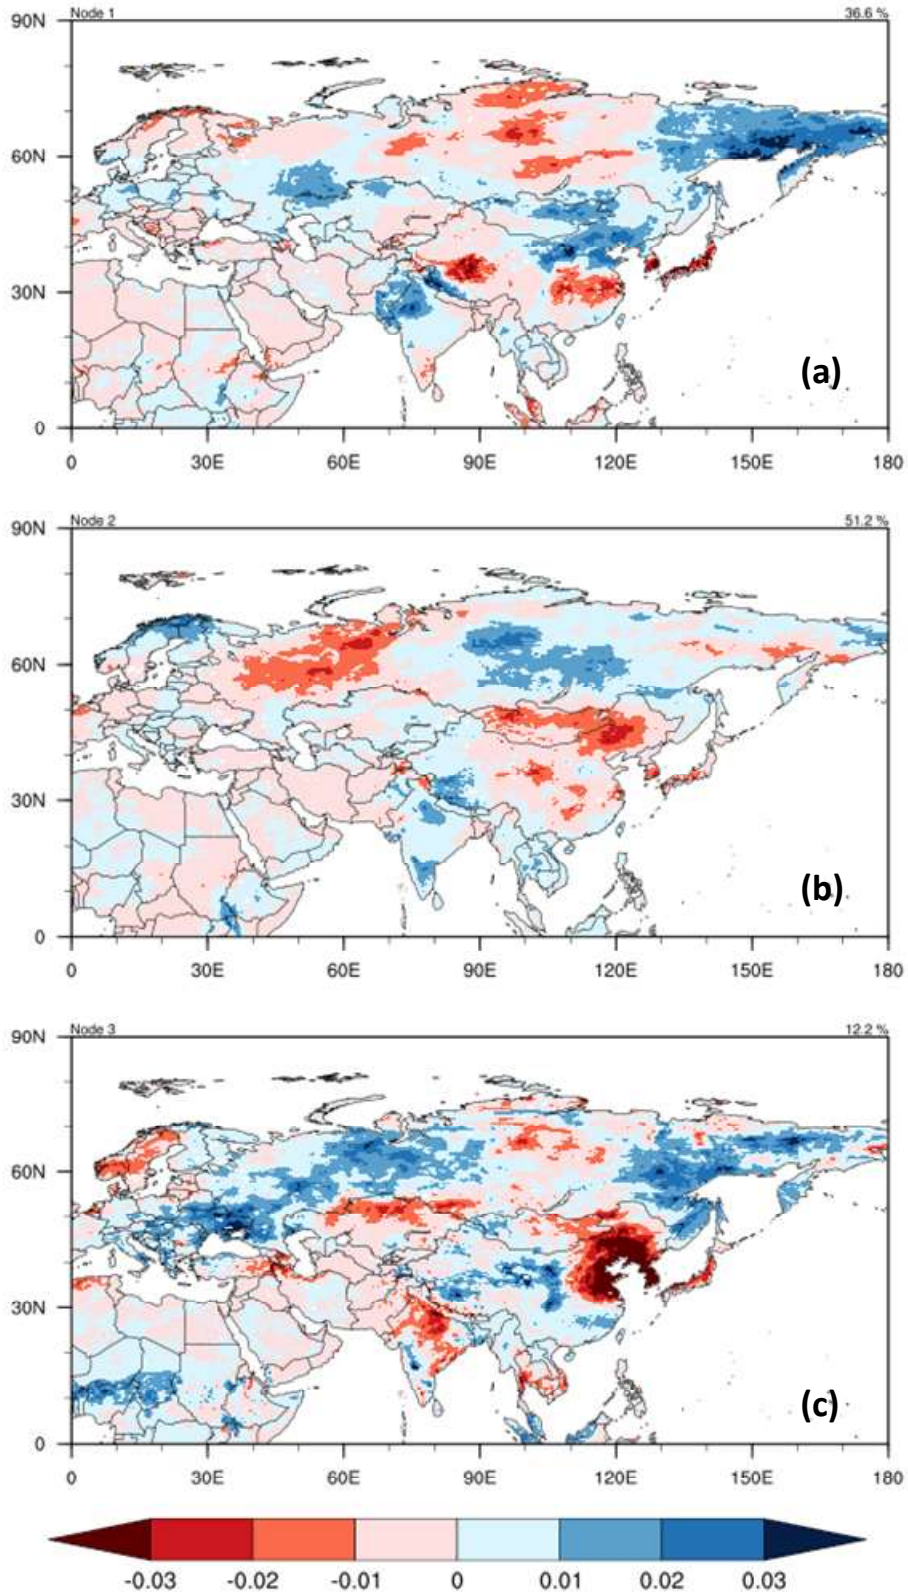


Figure 73. Composite fields of soil moisture for Node 1 (a), Node 2 (b), and Node 3(c).

② SOM 패턴별 대기순환장 및 토양수분과 지연 및 동시상관성 분석

2020년 여름철에 대하여 Figure 9에 도시한 방법으로 지역폭염을 정의하였으며, 결과를 Table 10에 요약하여 제시하였다. 2020년 한반도 여름철에는 6월 2회와 8월 2회 등 총 4회의 지역폭염이 발생한 것으로 나타났다. 2020년 6월 폭염은 Table 8과 Figures 68과 69와 유사하게 폭염지속일이 2~3일로 매우 짧은 것으로 나타나 3번 노드와 유사한 SOM 패턴으로 추정할 수 있다. 지면조건과 폭염의 상관성을 분석하기 위해, 500-hPa GPH와 850-hPa 바람장 아노말리의 4개 선행시간에 대해(0일, 15일, 30일, 60일 선행시간) 합성장을 구축하였다(Figure 74e-h). 이렇게 구축한 합성장을 기준(말하자면, 1979-2019) 3번 노드 군집에 대한 각각 선행시간에 대한 아노말리 합성장(Figure 74a-d)과 서로 비교하였다. 대기순환장의 경우 2020년 경우와 1979-2019년의 합성의 경우 Figure 74a와 e에서 한반도와 한반도 북부에 쌍극구조가 나타나는 유사성을 제외하고는 크게 유사한 부분은 발견되지 않았다.

Table 10. Regional heatwaves in the year 2020.

RHW_s ^a	RHW_e ^b	HWD (day)
2020.6.8	2020.6.9	2
2020.6.21	2020.6.23	3
2020.8.13	2020.8.20	8
2020.8.24	2020.8.26	3

a RHW_s: regional heatwave starting dates

b RHW_e: regional heatwave ending dates.

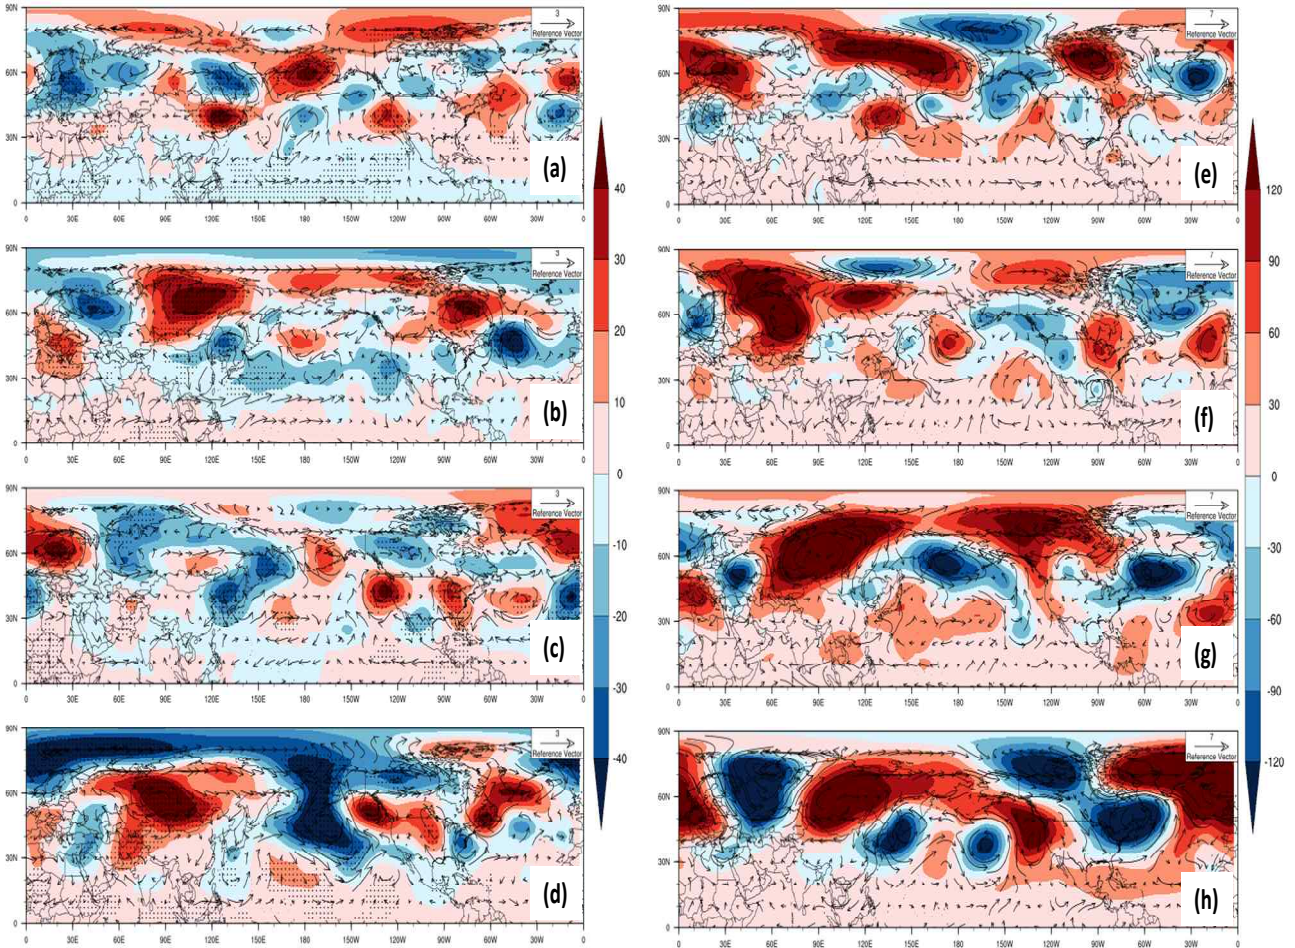


Figure 74. Lagged composite fields of 500-hPa GPH (shading) and 850-hPa wind vector (arrow) for 1979-2019 (Node 3) (a)-(d) and for 2020 (June) (e)-(h). (a) and (e) 0-day lagged, (b) and (f) 15-day lagged, (c) and (g) 30-day lagged, and (d) and (h) 60-day lagged fields.

위의 대기순환의 동시 및 지연상관 분석을 위한 아노말리 합성장(Figure 74)과 유사한 방법으로 토양수분의 아노말리 합성장을 0일, 15일, 30일, 60일 선행시간에 대한 1979-2019 기간(Figure 75a-d)과 2020년 6월 폭염(Figure 75e-h)에 대하여 각각 구축하였으며, 서로 비교 및 분석하였다. 먼저, 지역폭염일에 대한 합성장(말하자면 0일 선행시간)의 경우(Figure 75a와 e), 한반도 주변에서 강한 토양수분 음의 아노말리가 나타났으며, 선행시간 15일(Figure 75b와 f)과 30일(Figure 75c와 g)에 대한 합성장의 경우에도 한반도 주변에서 유사한 패턴이 나타났다. 선행시간 30일(Figure 75c와 g)과 60일(Figure 75d와 h)에 대한 합성장의 경우, 40-60°N과 0-30°E 영역의 토양수분이 강한 음의 아노말리가 나타났으며, 유의확률 90%에서 유의한 것으로 분석되었다. 이러한 결과로부터, 5월과 4월의 40-60°N과 0-30°E 영역의 토양수분이 6월 폭염발생 감시인자로 활용성이 커 보이며, 이에 대한 후속 연구가 필요할 것으로 판단된다.

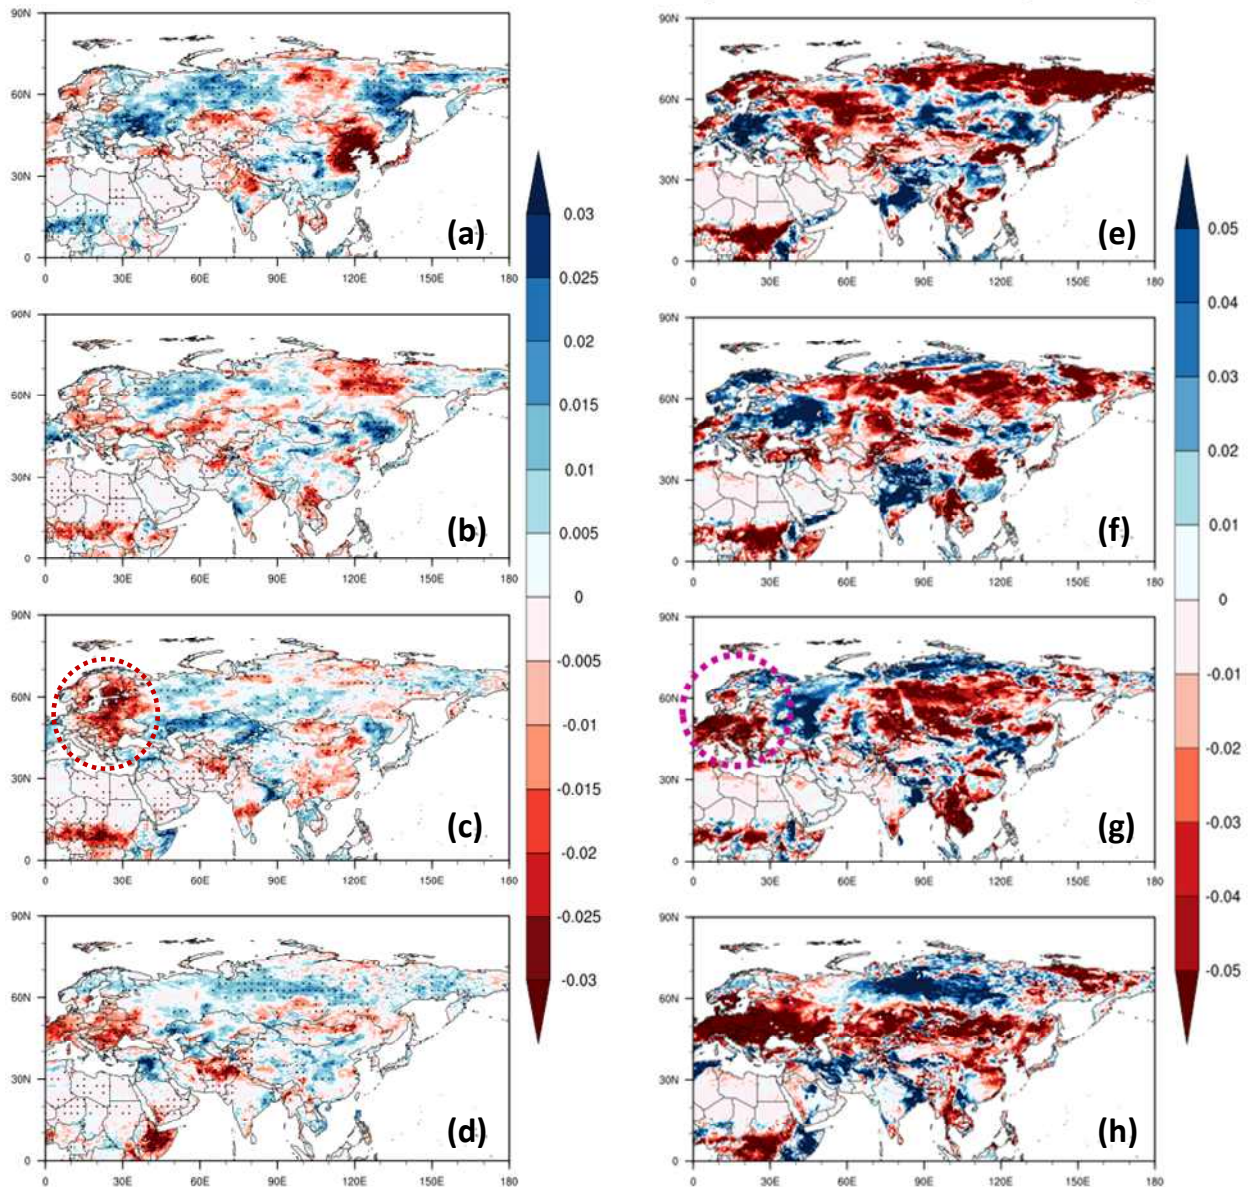


Figure 75. Lagged composite fields of soil moisture for 1979-2019 (Node 3) (a)-(d) and for 2020 (June) (e)-(h). (a) and (e) 0-day lagged, (b) and (f) 15-day lagged, (c) and (g) 30-day lagged, and (a) and (e) 60-day lagged fields.

(4) 2020년 흑서기 원인 분석서

(가) 2020년 흑서기 이상 기후 현황

2020년 흑서기 여름철 이상 기온 및 강수는 월변동이 심하였다. Figure 76은 2020년 6월부터 8월의 동아시아에서 기온과 강수의 평년 편차장의 분포를 보여준다. 6월에 강수의 평년보다 증가가 중국 남부에서 일본 남부 후쿠오카 지역까지 확장된 형태로 나타나고, 한반도에서 강수는 평년 수준의 값을 보였다. 그리고 남중국해와 필리핀해 근처에서는 동서 방향으로 펼쳐진 강수 부족의 밴드가 형성되었다. 7월에는 양의 강수 편차 밴드가 그 값이 강화된 상태로 한반도까지 북진하여 일본, 우리나라 남한, 중국 남동부 지역에 많은 비를 뿌려 홍수를 유발하였다.

8월 평균 양의 강수 평년 편차 장은 좀 더 복잡한 형태로 중국 베이징, 한반도 전역, 중국 북동부 지역까지 평년보다 강수가 증가하였다. 하지만 일본 지역은 강수가 평년 보다 감소하였다.

기온은 6월 동안 중국 동부, 한반도, 일본 전 지역에서 평년보다 높은 기온을 보였다. 하지만 강수의 증가 및 일사량 감소로 7월 기온은 같은 지역에서 평년보다 낮은 기온을 나타내고, 8월에는 기온이 평년 보다 상당히 증가하는 양상을 보였다. 다음 절들에서 한반도에서 발생한 이상 기온/강수를 중심으로 좀더 자세하게 설명하고자 한다.

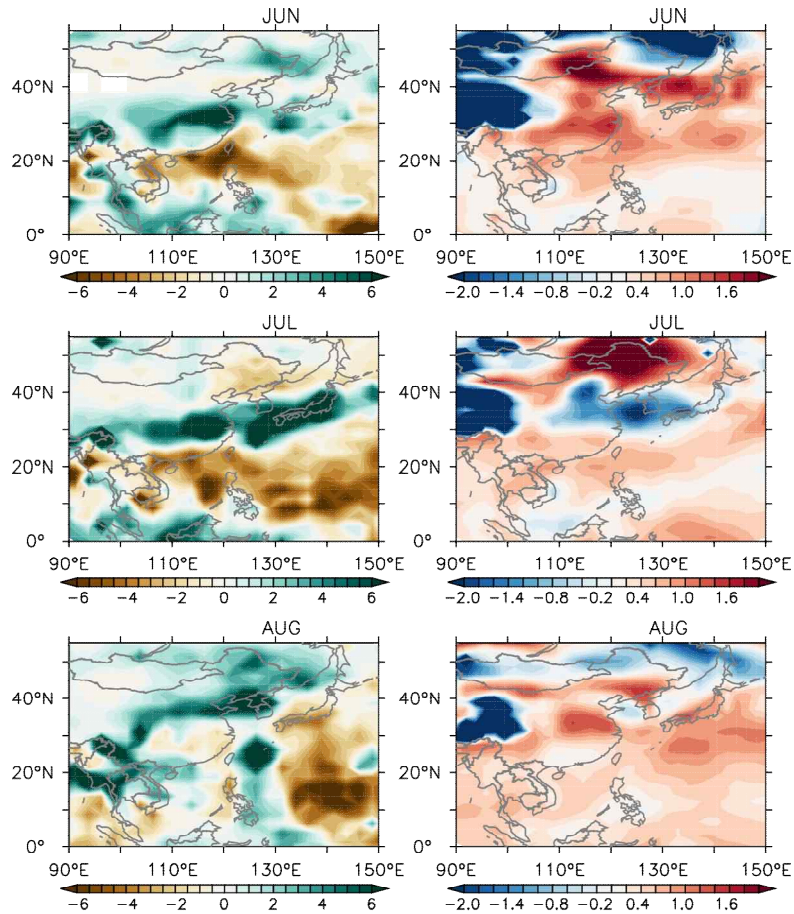


Figure 76. Spatial patterns of monthly-mean (Left) total precipitation and (Right) surface air temperature anomalies over the East Asian region from June to August, 2020.

① 6월

6월은 한반도에서 폭염이 일찍 시작하였고, 한달간 지속하였다. 특히, 경상도와 강원도에 상대적으로 폭염일수가 높았다. 즉, 월평균 일 최고 기온 평년 편차와 백분위 값(Figure 77a, b)은 한반도 서부 지역 보다는 동부 지역에서 최고기온 편차 증가가 상대적으로 더 높았고, 그 값의 대부분은 90백분위 값 이상 이었다. 일 최고 기온이 90 백분위 값보다 높은 날들 즉 이상 고온 일수(Figure 77b)는 한반도의 동부 지역들에서 7일 이상을 기록하였고, 강원도 해변 지역과 부산 지역에서 10-11일 이상을 기록하여 한반도 남한 지역들 중 가장 많은 이상 고온 날수를 기록하였다. 이들 지역에서 열대야의 날 수도 다른 지역 보다 높은 값을 보여 이 지역의 시

민들이 밤잠을 설치게 하였다(Figure 77d). 충청도의 일부 지역에서 이상고온 날수는 그렇게 높지 않았지만 열대야 날 수는 17일로 최고 기록을 달성하였다. 2020년 6월의 한반도 43개 관측소들의 값을 평균하였을 때 (Table 11) 최고기온(28°C /평균 21.2°C)과 폭염일수($2.0\text{일}/\text{평균 } 0.6\text{일}$)은 1973년 이후 1위의 기록이다.

6월 한반도 이상고온 발생 관련 대기 순환 변동의 주요 모드를 추출하기 위해 주변 200-hPa 남북 방향 바람장과 한반도 43개 관측소에서 이상 고온 날수에 대하여 SVD 분석을 수행하였다(Figure 78). 첫 번째 SVD 모드는 서쪽보다는 동쪽에 이상 고온 날수가 상대적으로 많은 분포를 보이고, SVD 모드의 expansion coefficient (EC)의 값은 1981년 이후 증가하는 경향을 보였다. 두 번째 SVD 모드는 한반도 북쪽 보다는 남쪽 지역에 상대적으로 많은 분포를 보였는데, 관련 EC는 추세 경향 보이지는 않았고 2000년 이후 변동 폭이 증가하는 양상을 나타내었다. 첫 번째 모드의 EC의 시계열과 500-hPa 지위고도와 회귀분석을 수행하였을 때 대서양에서 활모양으로 한반도 주변 상공까지 양-음의 지위고도 편차장이 반복되는 파동 형태의 원격상관 패턴을 보였다. 한반도 주변에서 관련된 지위고도 편차장을 보면 북동쪽에 저기압성 편차 순환, 남쪽으로 고기압성 순환 편차가 한반도 동쪽에 이상 고온 날수가 증가하는 데 영향을 미치는 것으로 분석된다. 한반도에서 북쪽과 남쪽에 부호가 다른 편차장이 어떻게 한반도 이상고온 날 수 변동에 영향을 미치는 지 아래에서 열수지 분석등을 통해서 자세하게 다루겠다. 두 번째 모드는 한반도 주변 음의 지위고도 편차 즉 저기압성 순환과 관련이 있음을 보여주는데, 이는 한반도 남쪽 지역에 남풍을 발생시켜 저위도 해양의 고온 다습한 공기가 유입되어 이상 고온 날 수 증가의 원인이 되는 것으로 보인다.

첫 번째 SVD 모드의 패턴은 Figure 77의 이상 고온 날수의 관측 분포와 상당히 유사하였으며, 더군다나 2020년 6월의 EC 값을 보면 1981년 이후 가장 큰 값을 보였다. 이 모드 관련 원격상관 패턴에 대한 해양 강제력을 분석하기 위해서 6월 해수면 온도 편차 장과 동시 상관계수를 계산하였다(Figure 79a). 통계적으로 5% 이상 유의한 상관계수값을 갖는 지역은 서태평양 남인도양 그리고 북 열대 대서양이었다. 이 상관계수 분포는 2020년 6월 해수면 온도 편차 장 분포와 상당히 유사하다는 것을 확인 할 수 있는데, 즉 대서양에서 한반도 까지 파동 형태의 지위고도 편차장은 열대 해양의 해수면 온도 변화 관련 강제력이 일부 기여하고 있음을 나타낸다.

특히 5월 열대 대서양에서 해수면 온도 상승과 한반도 여름철 이상 고온 날수 증가가 유의한 관계가 있으며, 이는 해수면 온도 상승이 강제력으로 작용하여 대서양에서 동쪽으로 전파되는 로스비 파동을 발생시키기 때문이라는 최근 연구가 있는데 (Choi and Ahn, 2019), 5월 해수면 온도 편차 장과 상관계수 분포는 열대 대서양에서 상관계수가 값이 동시 상관일 때 보다 증가하는 것으로 보아 2020년 6월의 한반도 이상 고온 날 수 증가에 영향을 미치는 지위고도 편차장은 열대 대서양에서 봄철 해수면 온도 상승과 어느 정도 관련이 있으므로 결론을 내릴 수 있겠다.

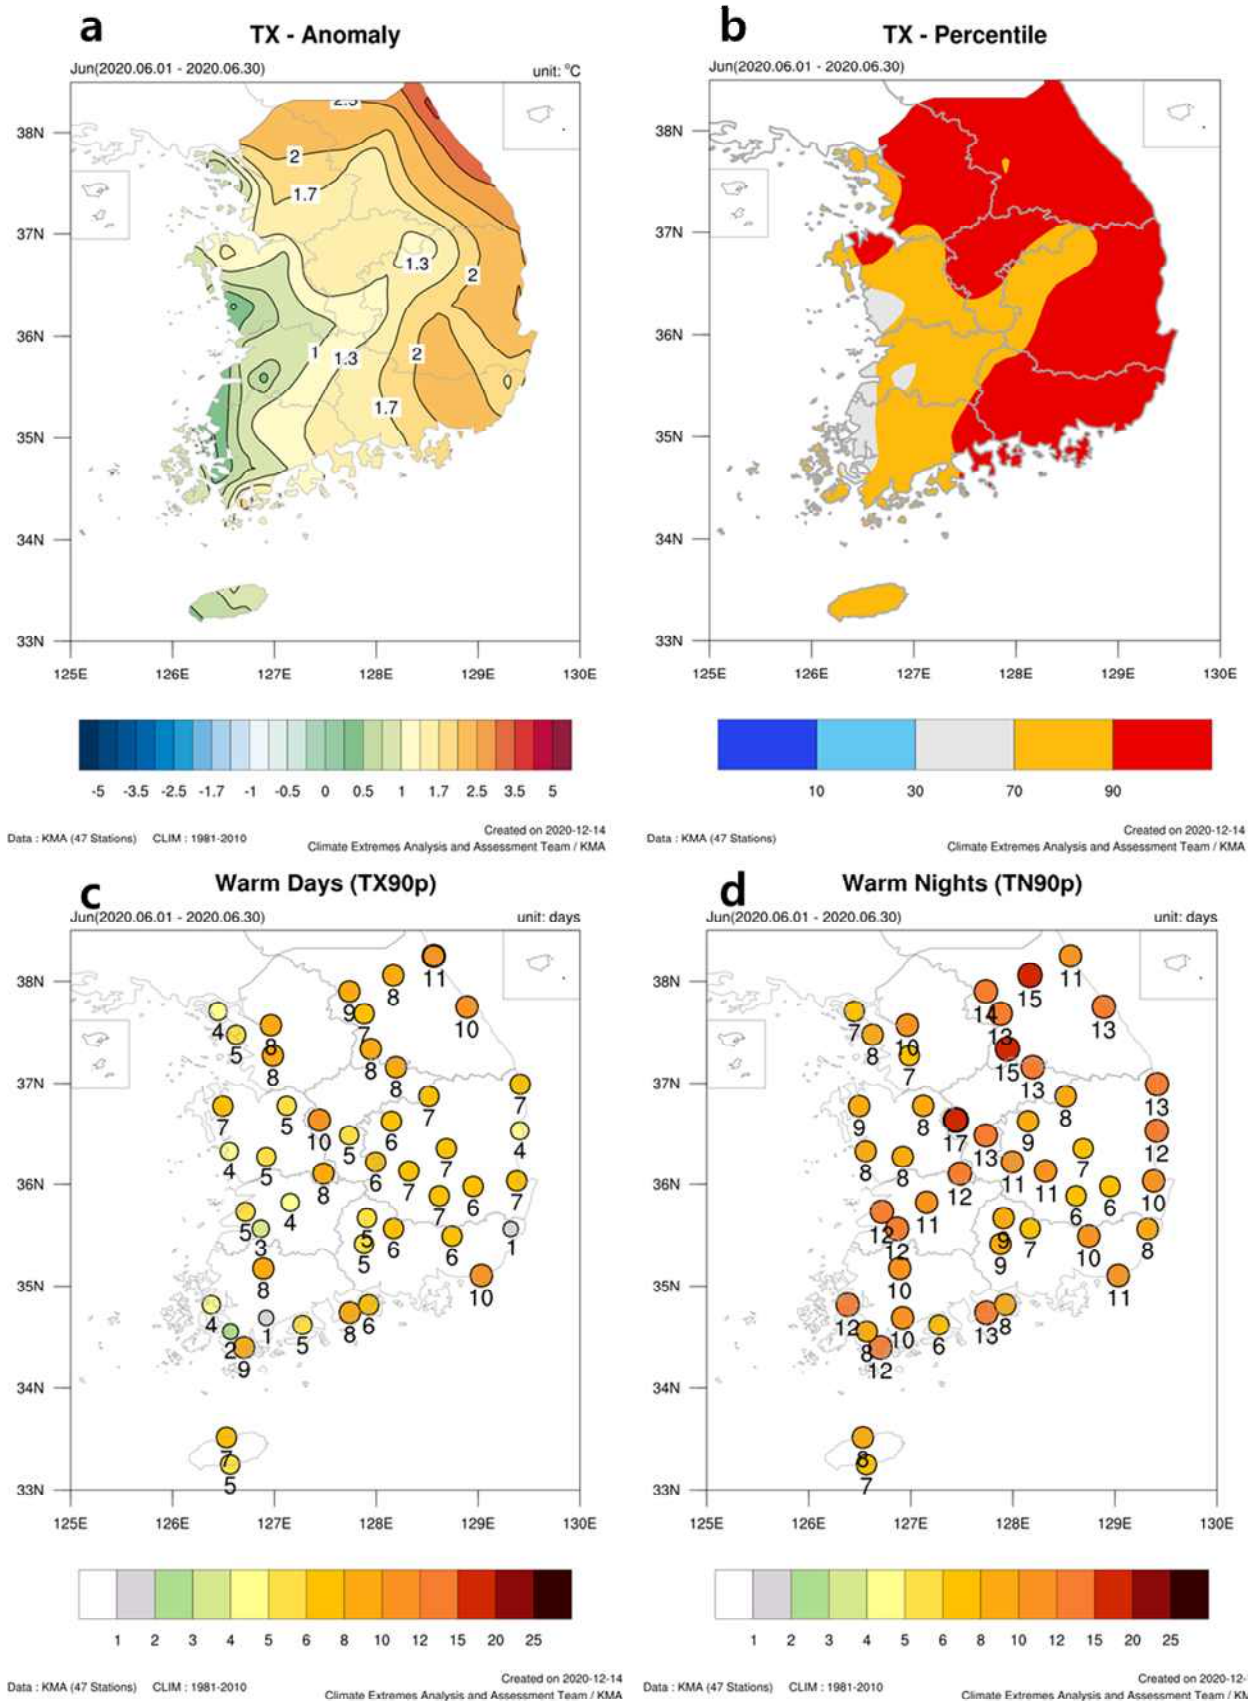


Figure 77. (a) Monthly mean daily maximum temperature (Tx) anomaly, (b) Percentile of monthly mean Tx, and the number of days with (c) Tx and (d) minimum temperature (Tn) greater than 90 percentile value of Tx and Tn, respectively. Taken from (co-anal.kma.go.kr)

그리고 2020년 6월 500-hPa 지위고도 편차장을 첫 번째 SVD 모드와 회귀 분석된 패턴과 비교하면(Figure 79b) 대서양에서 동향 전파되는 패턴에 대해서 상당히 유사하다는 것을 확인할 수 있다. 즉, 한반도 6월 기온은 관측과 SVD 패턴을 보면 한반도 북쪽의 저기압성 편차에 의한 북서풍과 남쪽의 남서풍의 영향을 받은 것으로 분석될 수 있다.

Table 11. Statistical features of monthly mean temperature (Tm), maximum temperature (Tx), minimum temperature (Tn), heat wave days, and tropical nights from June to August, 2020.

	Jun		Jul		Aug	
	Rank	Total/Anomaly	Rank	Total/Anomaly	Rank	Total/Anomaly
Tm	1st	22.8/+1.6	44th	22.7/-1.8	6th	26.6/+1.5
Tx	1st	28.0/+1.5	46th	26.3/-2.5	14th	30.7/+0.9
Tn	2nd	18.4/+1.7	41th	19.8/-1.3	2nd	23.7/+2.2
Heat Wave Days	1st	2.0/+1.4	45th	0.1/-3.8	19th	6.4/+1.1
Tropical Night Days	14th	0/0	43th	0.3/-2.0	5th	7.9/+5.2

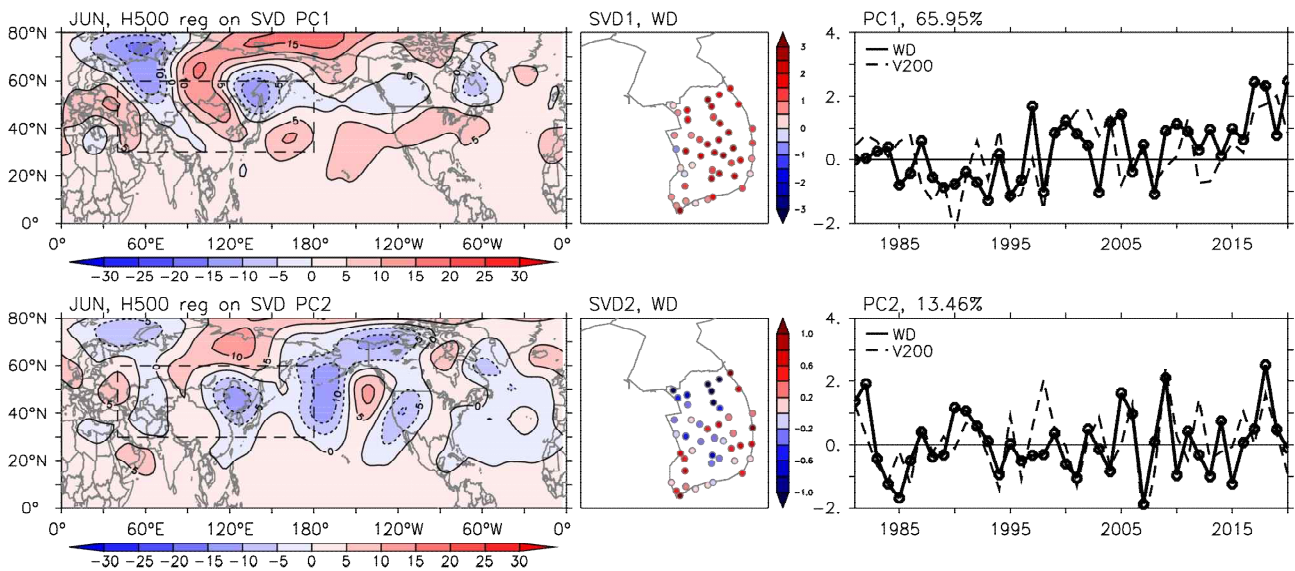


Figure 78. (left and middle panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of June 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020. (upper) first and (lower) second SVD modes. Contours and shadings are the regressions of the 500-hPa geopotential height to the corresponding expansion coefficients.

먼저 한반도 남쪽의 북서 태평양에서 고기압 발달에 의한 남서풍 (1000-hPa 지상 기온과 바람 편차장을 보여주는 Figure 6에서 확인)은 열대 서태평양의 고온 다습한 공기를 특히 한반

도의 남부 지역으로 유입시켜 한반도 기온을 높이는 데 기여하였다. 이 북서 태평양 고기압은 엘니뇨 발달 이후 봄철 북 인도양 해수면 온도 상승과 관련이 있다. 이 부분에 대해서는 다음 절 들에서 자세하게 다루겠다.

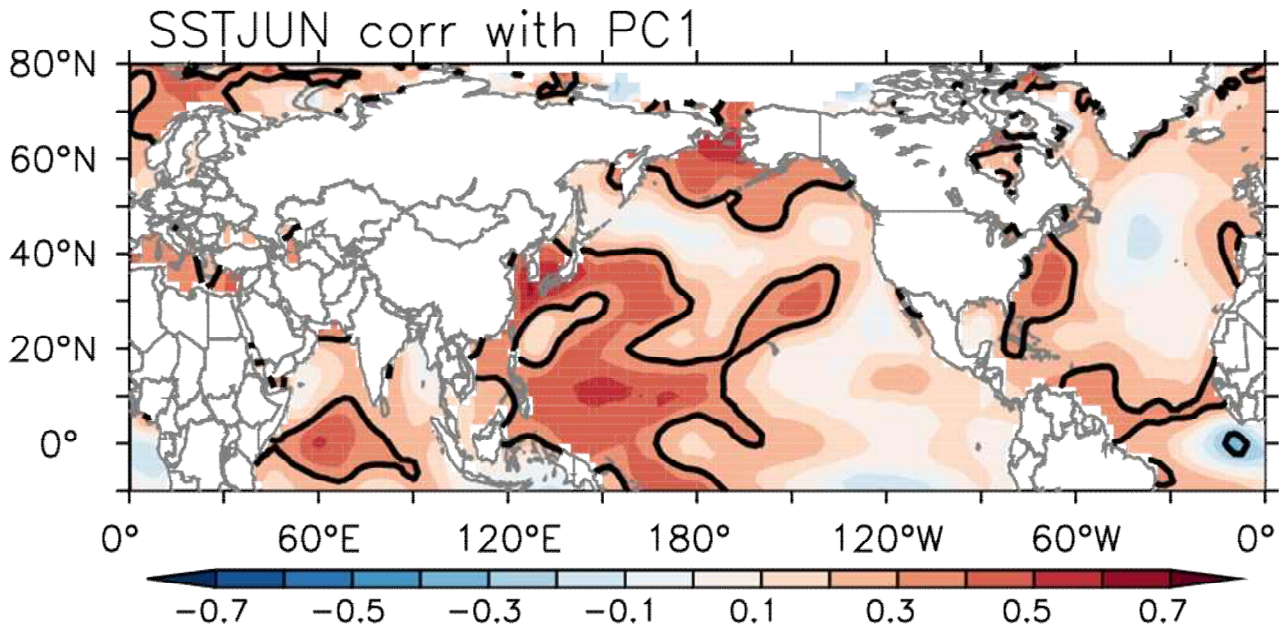


Figure 79. Spatial pattern of correlation coefficients between JUN sea surface temperature and expansion coefficients from the first SVD mode based on the analysis of June 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020. Black contours indicate the correlation coefficients corresponding the 5% significance level based on a student t-test.

한반도 북동쪽에서 저기압성 순환 편차에 의한 북서풍 편차는 중국 북부 지역에서 북한을 거쳐 남한의 동쪽으로 부는 경향을 보이는데 이 북서풍 편차에 의해서 상대적으로 높은 기온 편차를 보였던 중국 북부 지역에서 고온 건조한 공기를 남한 동부 지역으로 수송하여 이 지역에 기온을 높이는 역할을 한 것으로 보인다(Figure 6).

고온 건조 공기의 유입으로 인한 우리나라 남한의 동부지역에서 기온 상승에 대한 관련 역학을 분석 하기 위해서 열수지 분석을 수행하였다. Figure 82을 보면 북서풍 편차에 의한 평균 기온 남북 경도의 이류향이 남한의 동남부 지역의 기온 증가에 대하여 다른 항들 보다 가장 기여가 크다는 것을 확인할 수 있다. 북동쪽에서 발달한 저기압성 순환 편차는 대서양 기원 원격상관 패턴과 관련이 있으므로, 기록적인 6월 한반도 이상 고온 발생은 대서양과 태평양의 다중 영향에 의해 비롯된 것으로 볼 수 있다.

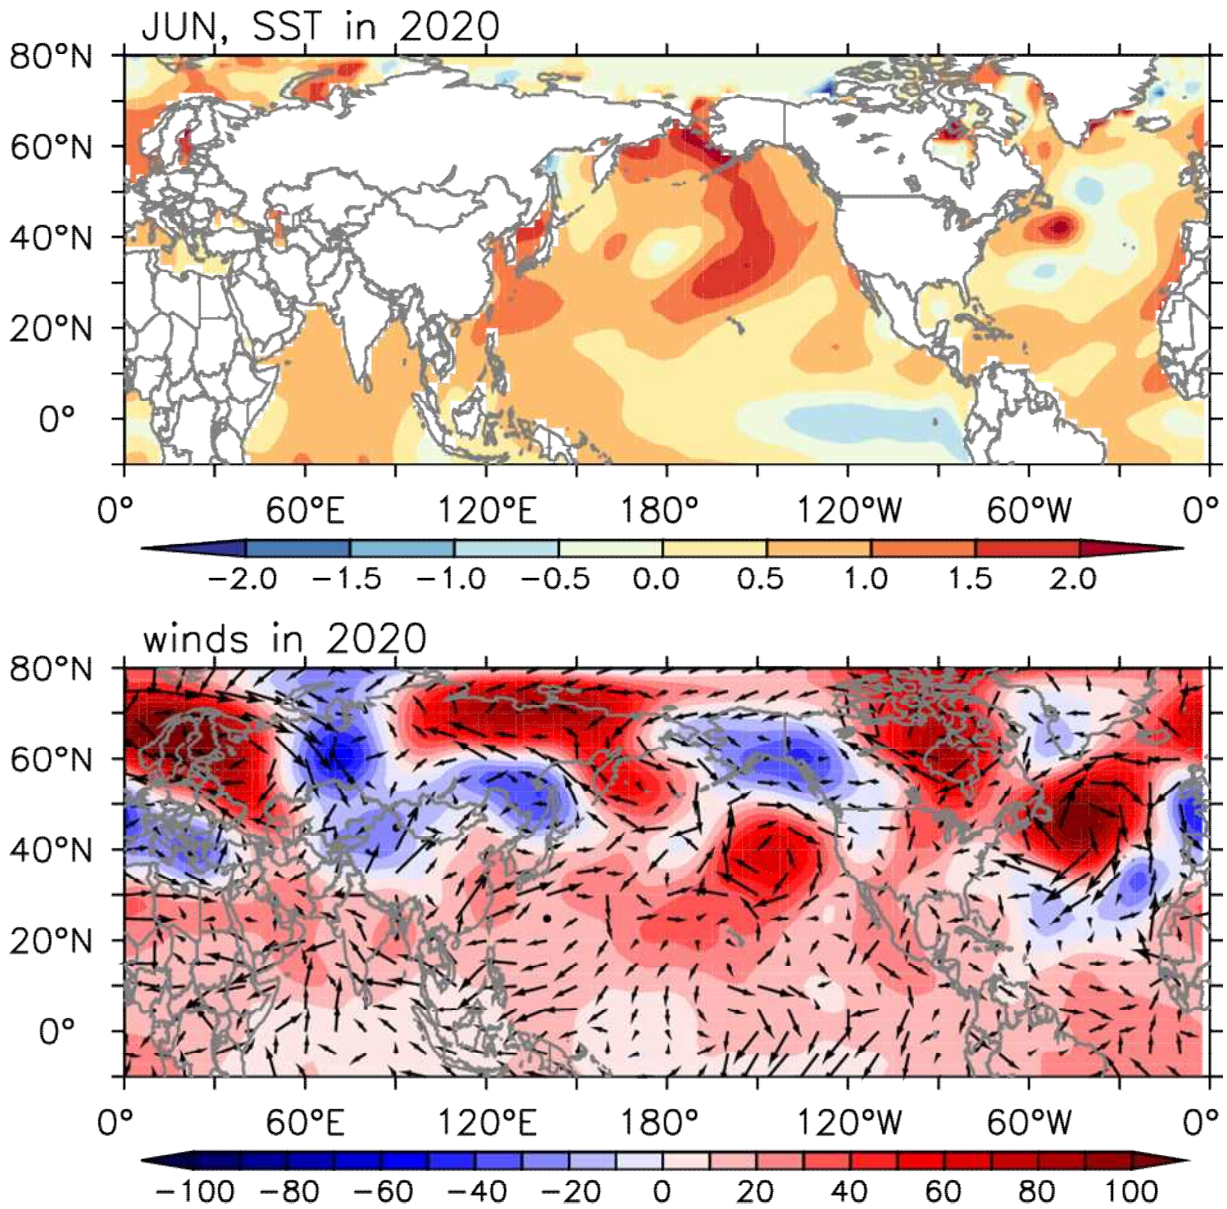


Figure 80. Spatial patterns of (upper panel) SST, and (lower) 500-hPa geopotential height (shades) and horizontal wind (vectors) anomalies in June, 2020.

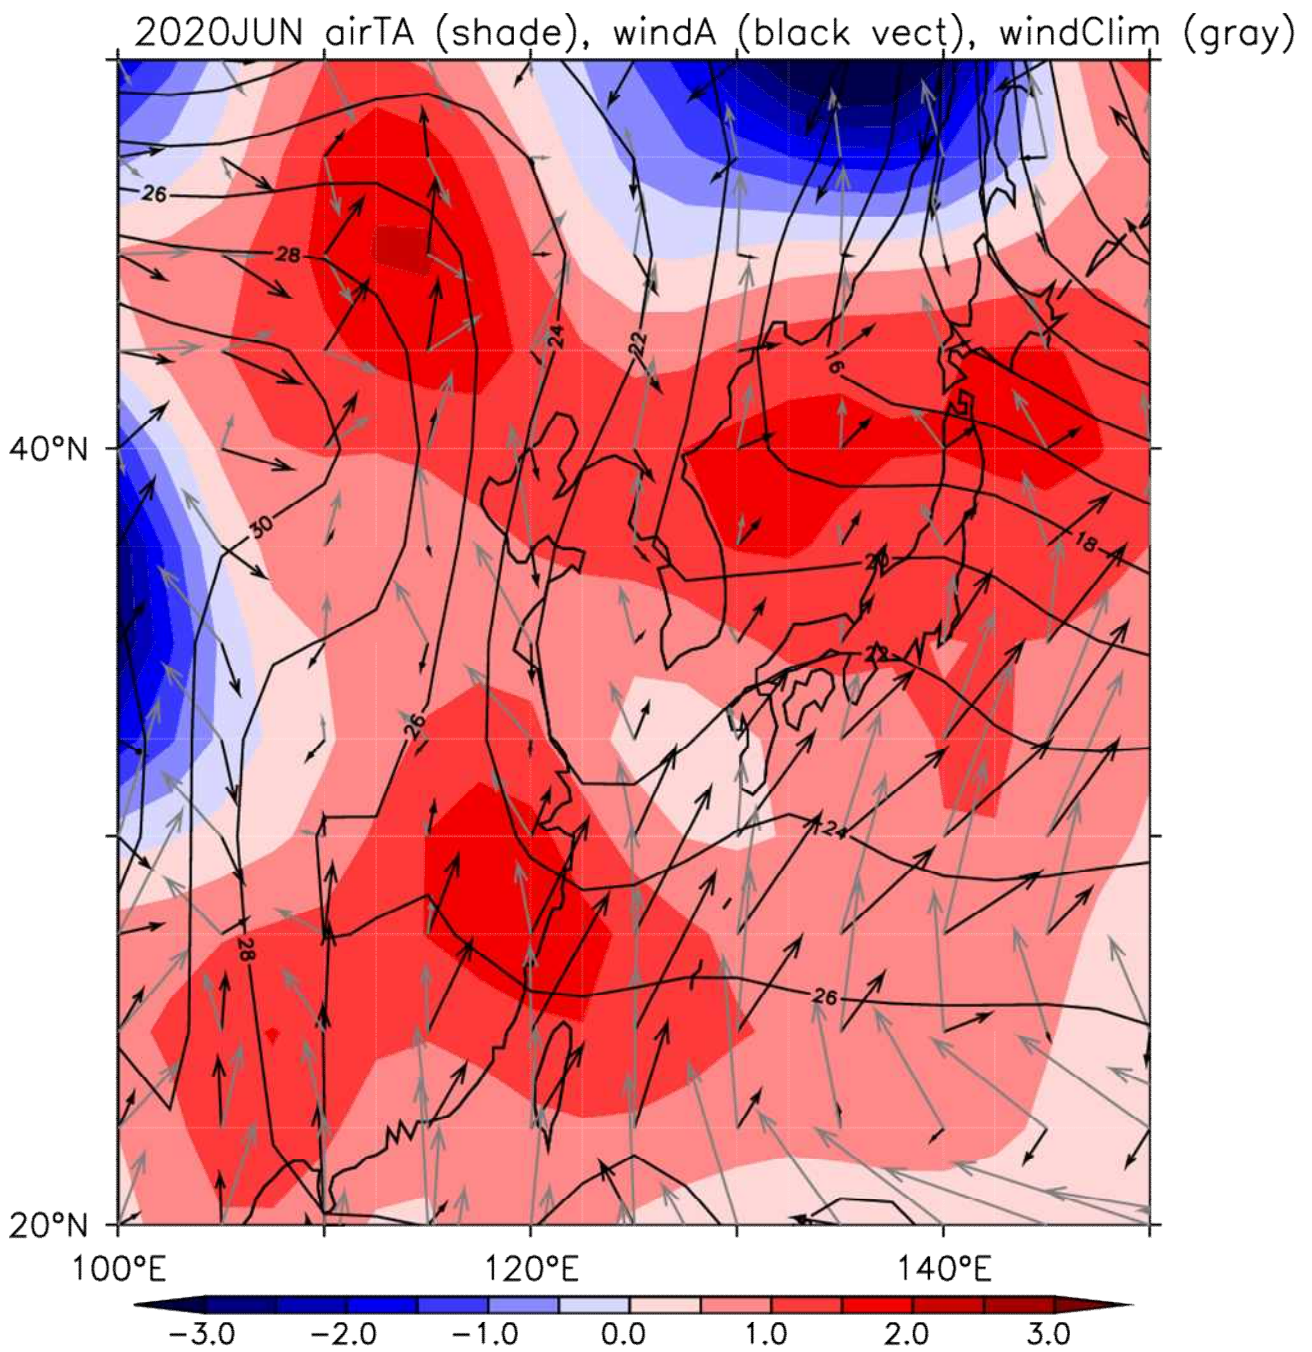


Figure 81. Spatial patterns of 1000-hPa air temperature (shades) and wind (black vectors) anomalies in June, 2020 and their climatology (contours for air temperatures and gray-colored vectors for 1000-hPa winds). The climatology is defined over the period of 1981-2020.

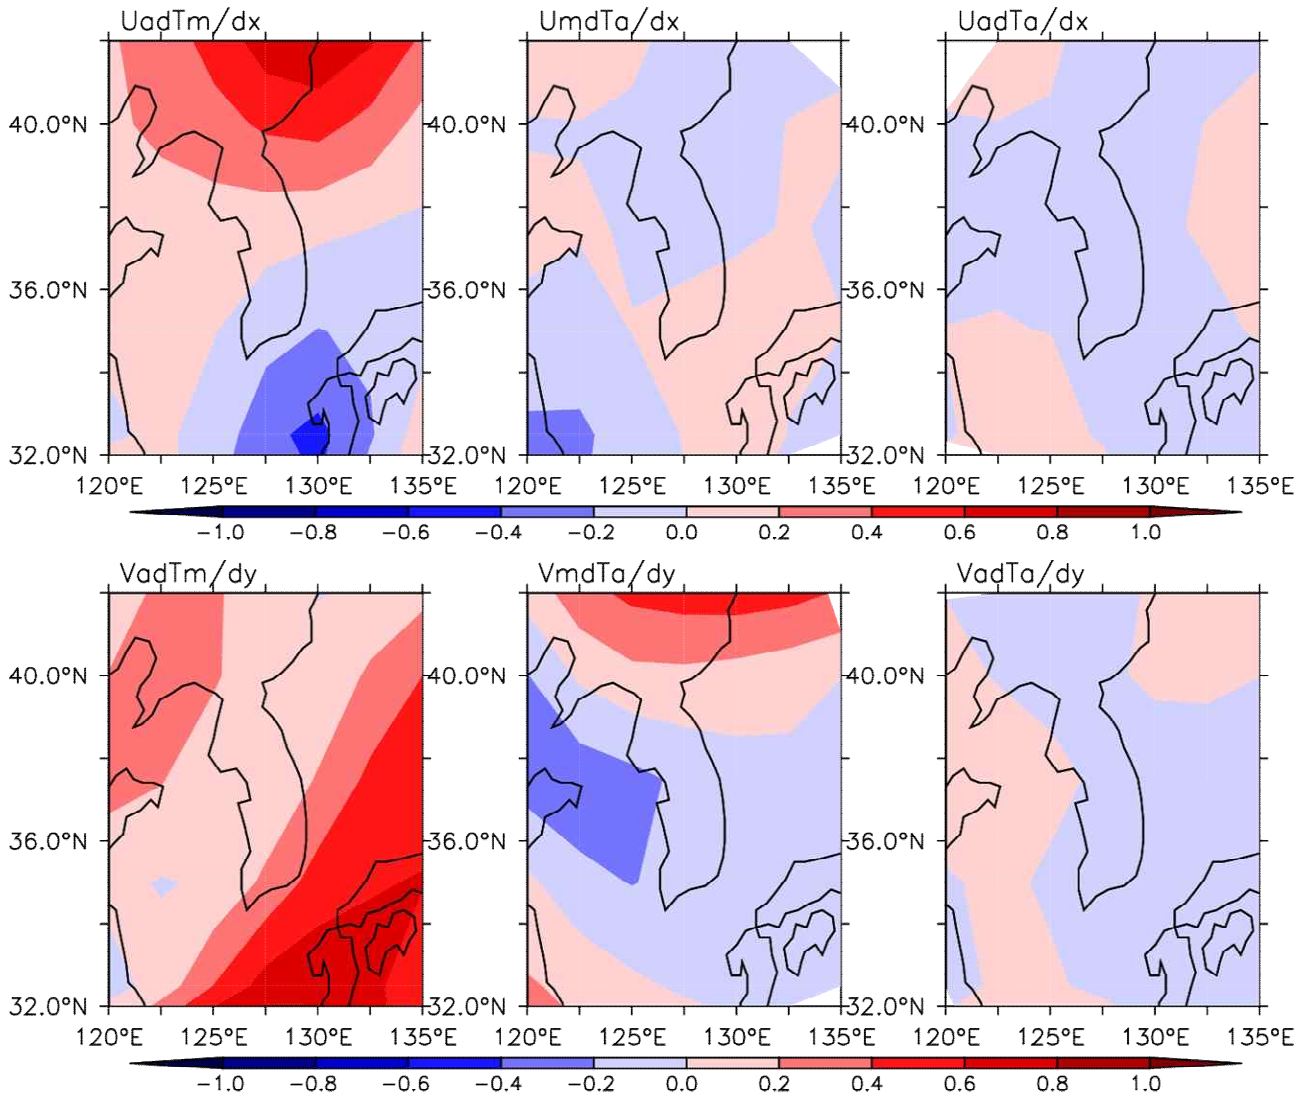


Figure 82. Heat budget analysis at 1000 hPa in June, 2020: $u' \frac{d\bar{T}}{dx}$, $\bar{U} \frac{dT'}{dx}$, $u' \frac{dT'}{dx}$, $v' \frac{d\bar{T}}{dy}$, $\bar{V} \frac{dT'}{dy}$ and $v' \frac{dT'}{dy}$.

② 7월

7월의 경우 한반도에서 장마가 기록적으로 오래 지속 하였다. 강수일수(18.8일/평년 4.4일)는 4위를 기록하였으며, 특히, 남부지방 중심으로 평년 대비 300% 이상 증가가 있었다. 이상 저온 날수(최고기온<10번째 퍼센타일의 최고기온값, 9.1일/평년 3.0일)는 2위를 기록하였고 폭염 일수(0.1일/평년 3.9일)는 상당히 낮아서 45위를 기록하였다(Table 11)

우리나라 남한 일 최저기온 월평균의 편차와 퍼센타일 값의 분포를 보면(Figure 83a, b), 남부/남동부 지역에서 다른 지역보다 편차 값이 -1.0°C 이상 낮았으며, 일부 지역에서 10번째 퍼센타일 값에 해당할 정도로 최저기온이 상당히 낮았다. 이들 지역에서 다른 지역보다 상대적으로 이상 저온 날수가 더 많았는데(Figure 83c, d), 경상남도과 전라북도 일부 지역에서는 이상 저온 날수가 가장 많은 13일을 기록하기도 하였다.

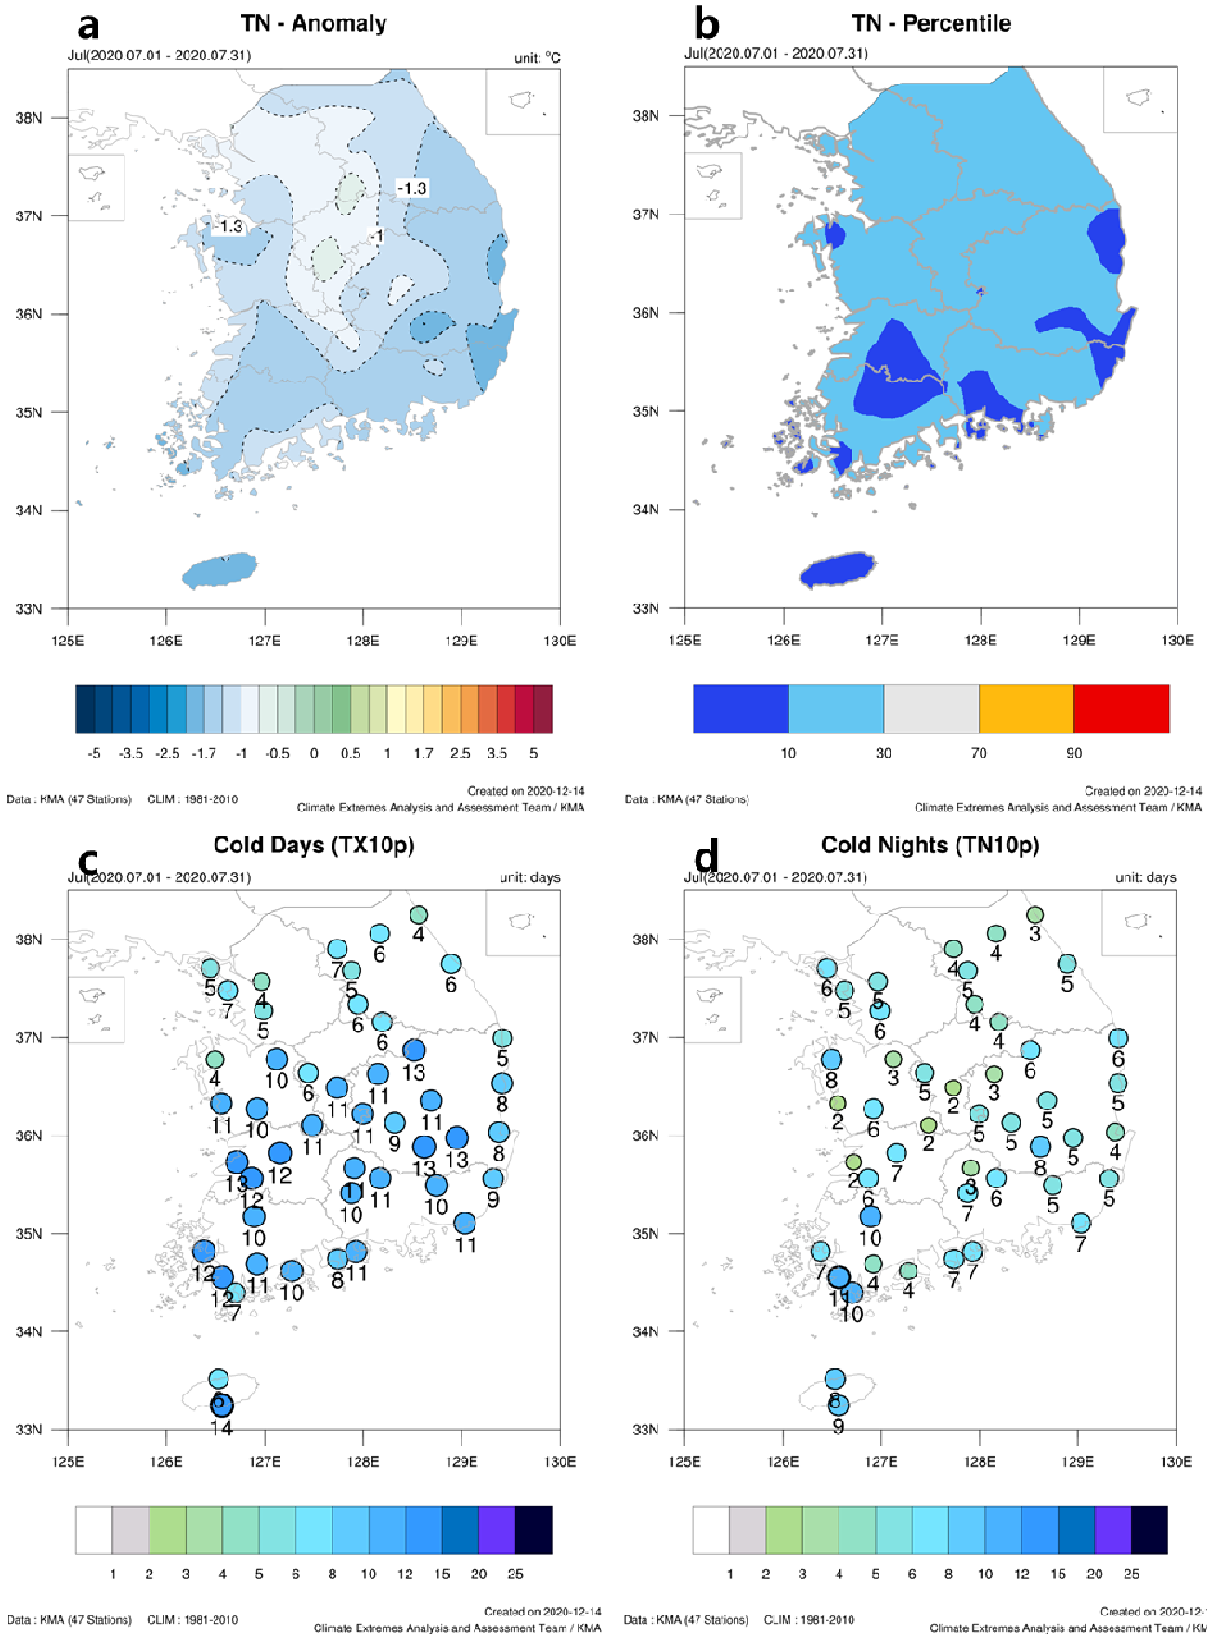


Figure 83. (a) Monthly mean daily minimum temperature (Tn) anomaly, (b) Percentile of monthly mean Tn, and the number of days with (c) monthly mean daily maximum temperature (Tx) and (d) Tn greater than 10 percentile value of Tx and Tn, respectively. Taken from (co-anal.kma.go.kr)

역시 7월 한반도 이상저온 발생 관련 대기 순환 변동의 주요 모드를 추출하기 위해 주변 200-hPa 남북 방향 바람장과 한반도 43개 관측소에서 이상 저온 날수에 대하여 SVD 분석을 수행하였다(Figure 84). 첫 번째 SVD 모드 관련 우리나라 남한 이상 저온 날수 분포는 남부지역에서 상대적으로 높은 날수를 보여주는데, Figure 83과 비교하면 상당히 그 분포가 유사함을 확인 할 수 있다. 이 모드와 관련된 500-hPa 지위고도 편차장 분포를 보면 대서양에서 전파되어 오는 파동 형태의 패턴과 열대 서태평양에서 전파되어오는 패턴이 동시에 나타나 있는 것을 확인 할 수 있는데, 이는 한반도 이상 저온 날 수 증가에 대하여 대양 간의 상호작용의 역할을 추측해 볼 수 있는데 다음 절들에서 자세하게 분석 될 것이다. 첫 번째 모드의 EC의 시계열을 보면 추세경향은 거의 없으며, 2020년 값이 가장 컸다.

두 번째 SVD 모드 이상 저온 날수 분포도 남부 지역에서 날 수가 더 높은 경향을 보여주는데 관련된 지위고도 편차장의 분포는 CGT (CircumGlobal Teleconnection; Ding and Wang 2005) 같은 패턴을 보인다. 이 모드와 관련된 우리나라 상공에 저기압성 순환의 발달은 일사량을 감소 시켜 기온을 낮추는 역할을 하는 것으로 보인다. 이 모드와 관련된 EC의 시계열은 뚜렷한 추세는 역시 보이지 않았으며, 2020년에 대하여 다른 연도들과 비교하였을 때 그 값이 상대적으로 상당히 작았다.

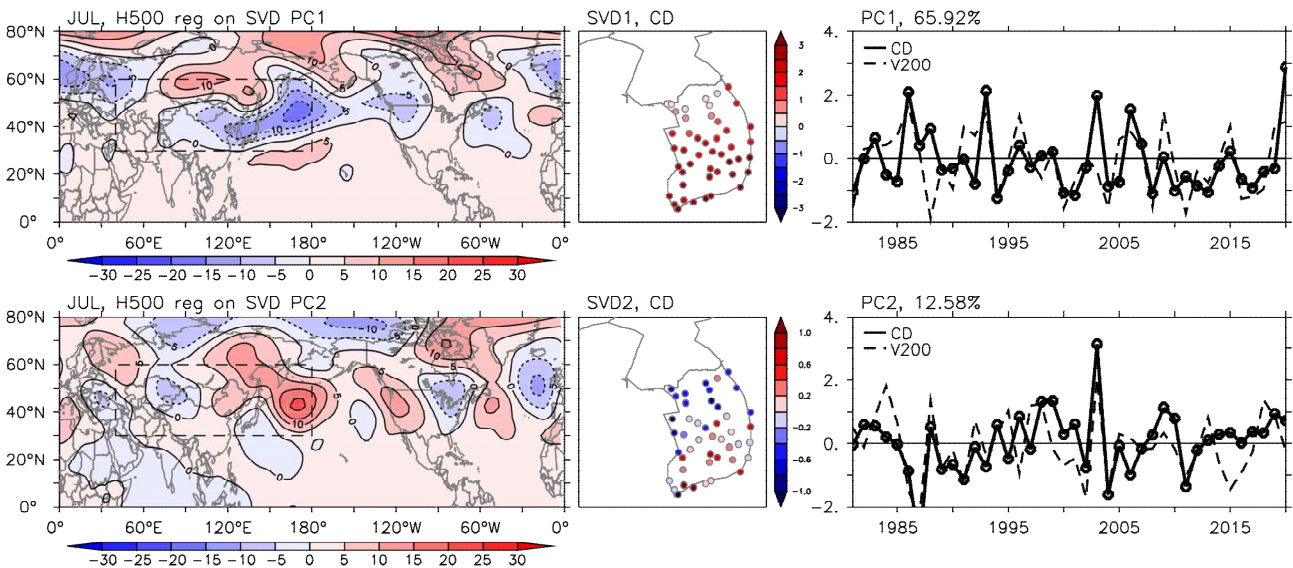


Figure 84. (left and middle panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of July 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely cold days over South Korea during 1981-2020. (upper) first and (lower) second SVD modes. Contours and shadings are the regressions of the 500-hPa geopotential height to the corresponding expansion coefficients.

Figure 85은 2020년 7월 500-hPa 지위고도 평년 편차장을 보여주는데, 대서양에서 파동형태의 구조, 북서 태평양에서 양의 지위고도 편차장 등은 Figure 84에서 첫 번째 SVD 모드 관련 지위고도 편차장 분포와 상당히 유사함을 확인할 수 있다. 그러므로 이 모드와 관련된 EC 시계열과 해수면 온도 편차장과 동시상관 분석을 수행하였을 때(Figure 86), 북인도양의 양의

해수면 온도와 유의한 관계를 보였으며, 이는 북인도양 해수면 온도 상승이 첫 번째 모드 관련 지위고도 편차장 발생의 주요한 인자로 작용 하였음을 시사하는 것이다. 실제로 2020년 7월 인도양의 해수면 온도는 평년에 비해 1.0°C 이상 상승하였다(Figure 87)..

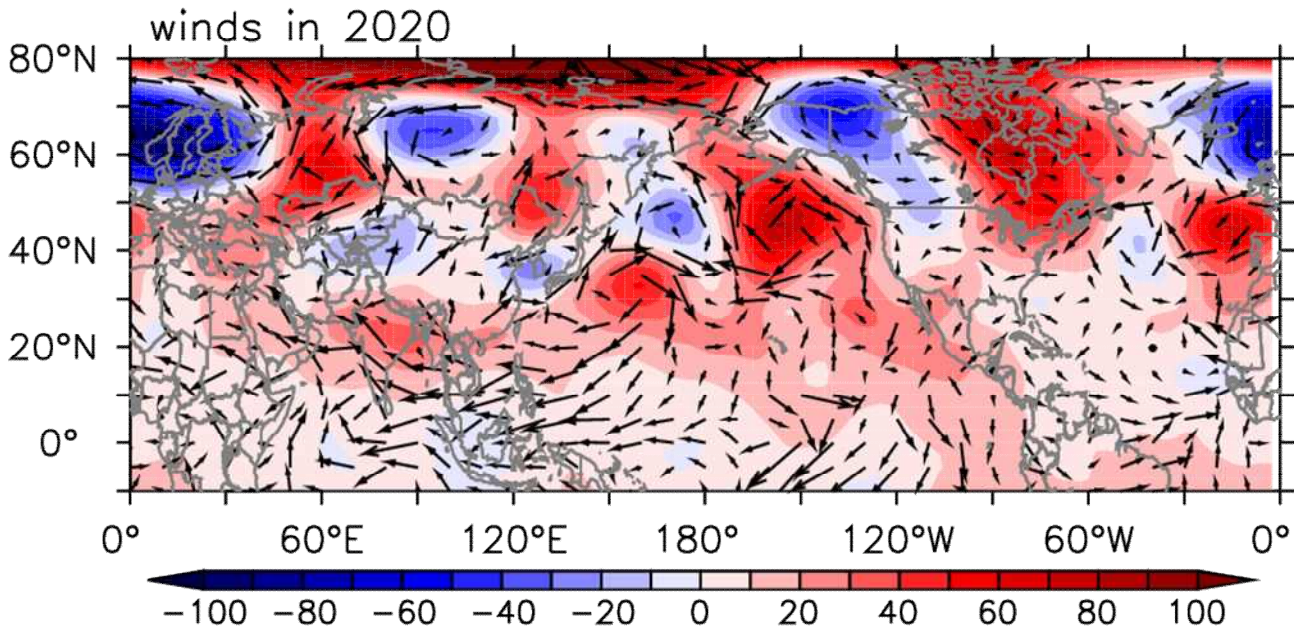


Figure 85. Spatial patterns of 500-hPa geopotential height (shades) and horizontal wind (vectors) anomalies in July, 2020.

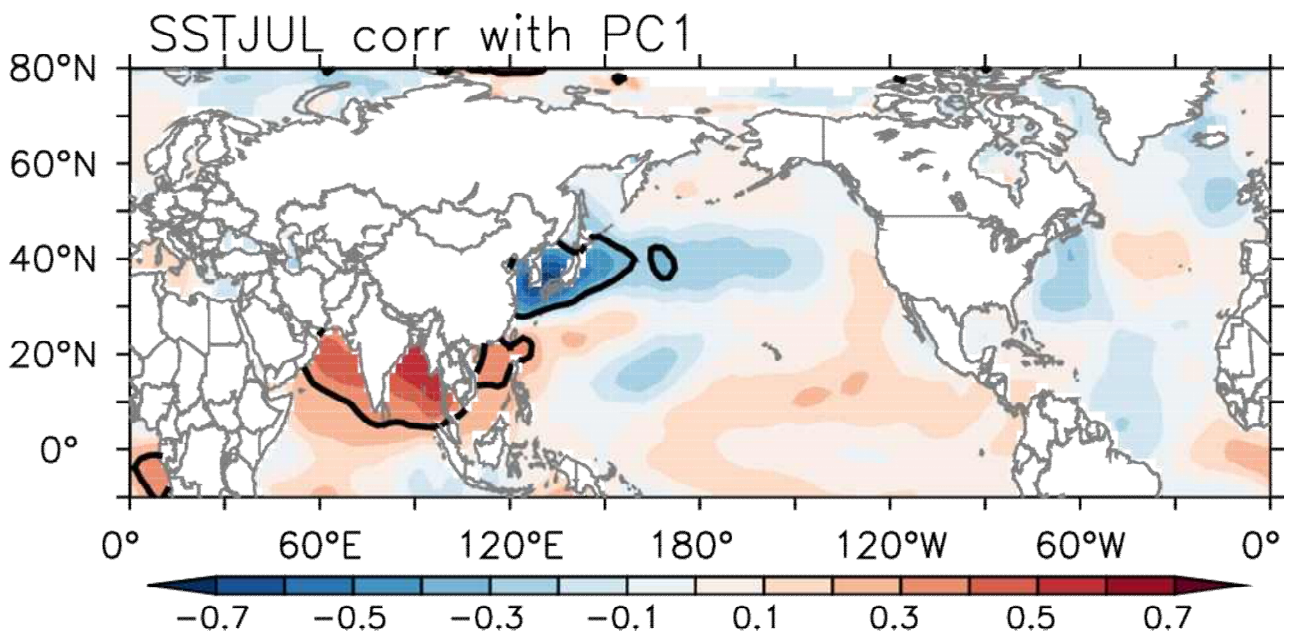


Figure 86. Spatial pattern of correlation coefficients between JUN sea surface temperature and expansion coefficients from the first SVD mode based on the analysis of July 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020. Black contours indicate the correlation coefficients corresponding the 5% significance level based on a student t-test.

북인도양 해수면 온도의 역할은 Xie et al. (2009) 인도양의 capacitor effect라 불리는 역학으로 설명이 가능한데 엘니뇨 발달 이후 북인도양에서 해수면 온도 상승이 있으며, 이 온도 상승에 의한 대기에서 반응으로 북서 태평양 고기압성 편차가 발생한다는 현상이다(Figure 85). 북서 태평양에서 고기압성 순환에 의해서 고온 다습한 공기가 유입되어 한반도, 중국, 일본을 포함하는 동아시아에 이상 강수를 발생시키는 호조건을 형성하였다.

아울러 북대서양에서 500-hPa 지위고도 편차장 분포는 음의 NAO (North Atlantic Oscillation)의 발달을 보여주며, 한반도 북동부 지역에서 고기압성 순환의 발달은 이 NAO의 원격상관과 관련이 있음을 추측해볼 수 있다. 즉 NAO 원격 상관에 의한 북동부 지역의 고기압성 순환의 발달에 의한 동아시아 지역에 한기가 유입되어, 고온 다습한 공기와 만나 많은 강수를 유발한 것으로 보인다. 자세한 역학들은 다음 절들에서 다루도록 하겠다.

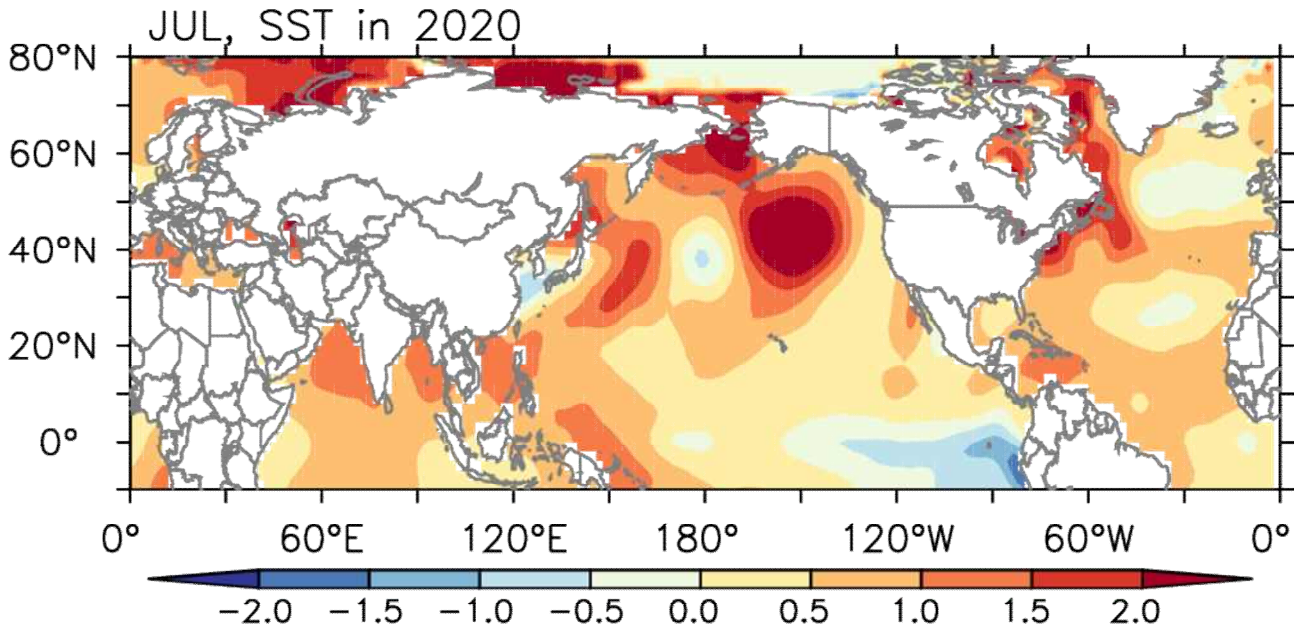


Figure 87. Spatial patterns of SST anomalies in July, 2020.

위에서 언급했듯이 기록적인 강수가 한반도 뿐만 아니라 중국 동부, 일본에서도 나타났는데, 7월 총 강수량의 평년 편차장 분포를 보면(Figure 88), 강한 양의 강수 밴드가 중국 남동부에서 남한을 거쳐 일본으로 확장되어 있는 것을 확인할 수 있다. 7월 동아시아 강수 발생 관련 대기 순환장 등 주요 모드를 추출하기 위해서 중국, 한반도, 일본 지역의 강수량과 (30°-60°N, 30°-180°E) 지역에서 200-hPa 지위고도 편차장과 SVD 분석을 수행 하였다.

Figure 89는 첫 번째 와 두 번째 SVD 모드의 500-hPa 지위고도 와 동아시아 강수 편차장의 패턴과 이와 관련된 EC의 시계열들을 보여준다. 첫 번째 모드는 동아시아 전반에 걸친 강수량 증가 패턴을 나타내고 있고, 이 같은 패턴은 2000년 이후 증가 하고 있는 추세를 보였다. 두 번째 모드는 2020년 7월 관측에서 보여주는 것과 같이 중국 남부에서 일본까지 동서 방향으로 확장된 형태를 나타내었다. 두 번째 모드와 관련된 지위고도 편차장 분포는 위에서 보여

준 우리나라 남한 이상 저온 날씨에 대한 첫 번째 SVD모드 관련 지위고도장 분포와 상당히 유사하다는 것을 확인할 수 있다. 이는 강수가 많은 경우 일사량이 감소하므로 기온이 대폭 하강하는 것과 일관성이 있다.

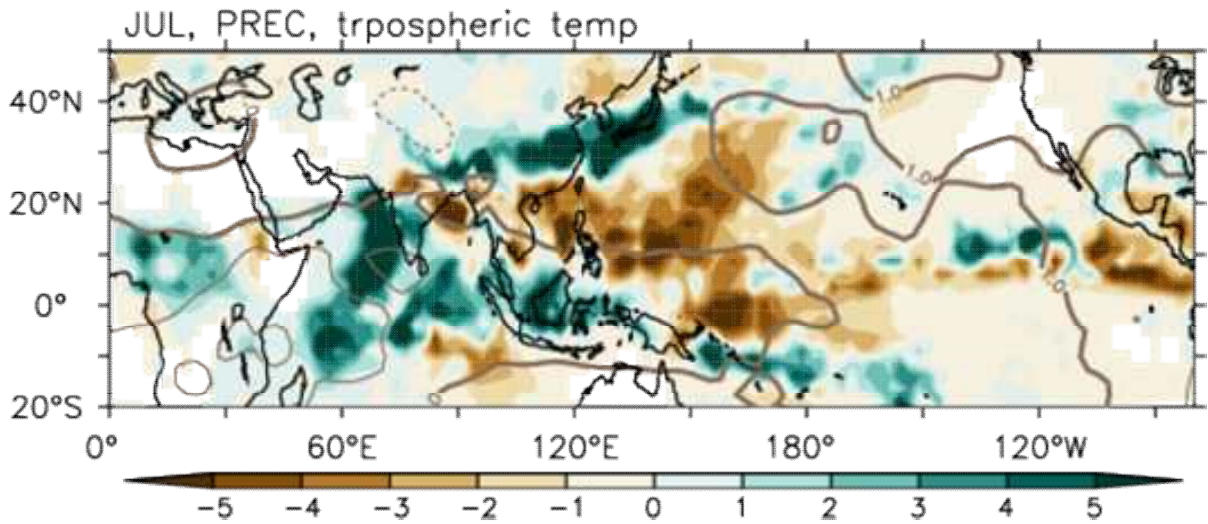


Figure 88. Spatial patterns of July precipitation (shading) and normalized tropospheric (850-250 hPa mean) temperature (contours) anomalies in 2020.

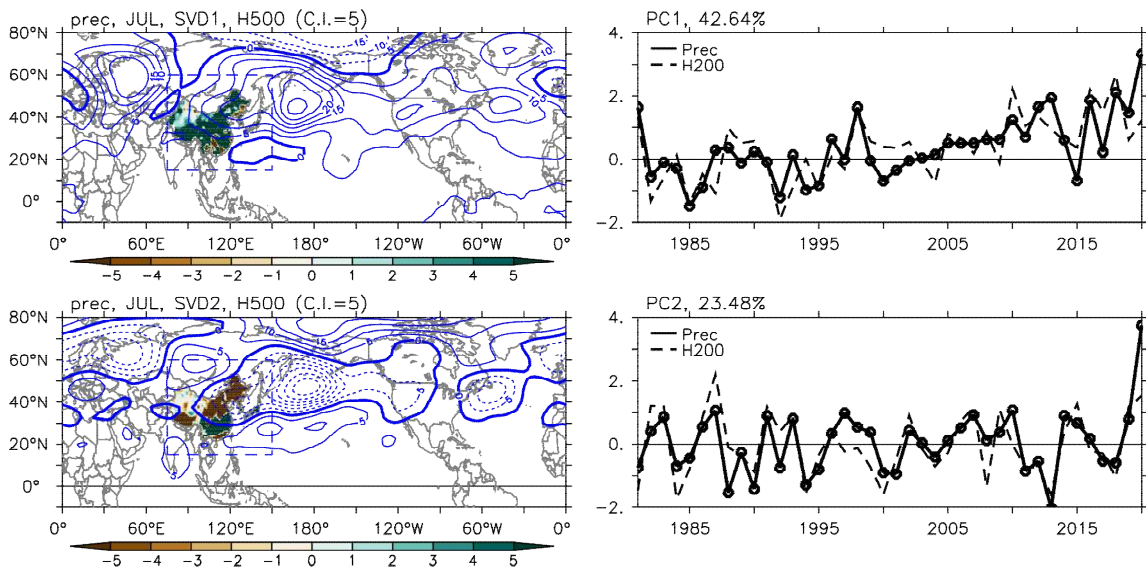


Figure 89. (left panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of July 200-hPa geopotential height over the region of (30° -60° N, 30° -180° E) and total precipitation over East Asia (China, Korea and Japan) during 1981-2020. (upper) first and (lower) second SVD modes. Contours are the regressions of the 500-hPa geopotential height to the corresponding expansion coefficients and shadings are the SVD modes for precipitation.

8월은 장마가 우리나라 남한 중부지방에서 16일 종료하여 1973년 이후 역대 가장 긴 장마(54일)로 기록되게 하였으며, 바로 이후 8월 후반까지 폭염 및 열대야가 지속되어 기온이 급격히 증가하는 변동성을 보여주었다. 월평균 일 최저기온(23.7°C/평년 21.5°C)은 2위를 기록하며 높았으며, 열대야 날수(7.9일/평년 2.7일)는 5위로 높았다. 월평균 기온은 6위로 높았고, 최고 기온은 14위로 기록하여 그렇게 높지 않았다(Table 11).

기록적인 8월의 우리나라 남한의 최저기온에 대한 평년 편차와 상응하는 퍼센타일 값에 대한 전국 분포(Figure 90a, b)를 보면 전반적으로 전 지역에서 2°C 이상 높았다. 해당하는 퍼센타일 값은 90번째 이상으로 높았다. 특히 강원도 산간지역, 세종특별자치시/대전광역시 주변에서 최저기온이 평년보다 2.5°C 이상 높았다. 위와 같은 지역에서 열대야 날수도 다른 지역보다 상당히 많았는데 최고 15-17일 이상이었다(Figure 90d). 8월 이상 고온 날수 전국 분포는 6월과 비슷하게 우리나라 남한 동부와 남부 지역에서 상대적으로 높거나 많았다.

7월 한반도 이상고온 발생 관련 대기 순환 변동의 주요 모드를 추출하기 위해 주변 200-hPa 남북 방향 바람장과 한반도 43개 관측소에서 이상 고온 날수에 대하여 SVD 분석을 수행하였다(Figure 91). 첫 번째 SVD 모드 관련 우리나라 남한 이상 고온 날수 분포는 전국에서 이상 고온 날수의 증가를 나타내었다. 이 모드와 관련된 500-hPa 지위고도 편차장 분포를 보면 서유라시아 지역과 알류산 지역 주변에서 상당히 높은 양의 지위고도 편차와 그 사이에 한반도 주변 양의 지위고도 편차가 존재하는 특징을 보이는데, 이는 스칸디나비아 원격상관 패턴과 상당히 유사하다(see figure 5 of Choi et al. 2019). 아울러 서유라시아 지역과 알류산 지역에서 블로킹이 존재하고 한반도 주변 양의 지위고도 편차가 정체하는 듯한 모습이다. 즉 한반도 전역에서 이상 고온의 증가는 서유라시아/알류산 블로킹이 역할을 할 수 있다는 것을 시사한다. 첫 번째 SVD 모드의 EC의 시계열을 보면 2010년 이후 증가하는 경향을 보이는데, 최근 한반도의 폭염 증가에 대한 스칸디나비아 원격 상관 패턴의 역할의 증가 경향이 있다는 최근 연구 결과와 일관된다(Choi et al. 2010).

두 번째 SVD 모드의 이상 고온 날수의 분포는 우리나라 남한 남부지역에 상대적으로 이상 고온 날수가 많고 북부 지역에 적은 특징을 보였다. 관련된 500 hPa 지위고도 편차장 분포는 한반도를 중심으로 북서 태평양까지 확장된 고기압성 순환 편차 그리고 서쪽으로 인도 주변 고기압성 순환 편차 그 지역에서 북서쪽으로 저기압성 순환과 고기압성 순환 편차가 이어져 존재하는 특징을 보인다. 이 패턴은 CGT 패턴과 상당히 유사하며(see figure 5 of Choi et al. 2019), 이 모드와 관련된 EC는 추세 경향은 거의 보이지 않았다. 두 번째 SVD 모드의 이상 고온 및 지위고도 편차장의 분포가 2020년 8월의 분포(Figure 90c 와 92)와 상당히 유사하므로, 이 모드 발생에 대한 열대 해양에서의 강제력을 분석하기 위해서 두 번째 SVD 모드 관련 EC와 8월 해수면 온도 편차와 상관관계수 값들을 계산 하였다(Figure 93). 유의한 상관관계수 값들을 갖는 지역들 중 북 아열대 대서양에서 해수면 온도와 양의 상관관계를 갖는 것을 확인 할 수 있는데, 두 번째 모드 발생의 대서양의 역할을 지시한다. 상관관계수가 높은 지역에서 8월 해수면 온도는 평년 보다 약 0.5°C 이상 높았다(Figure 94).

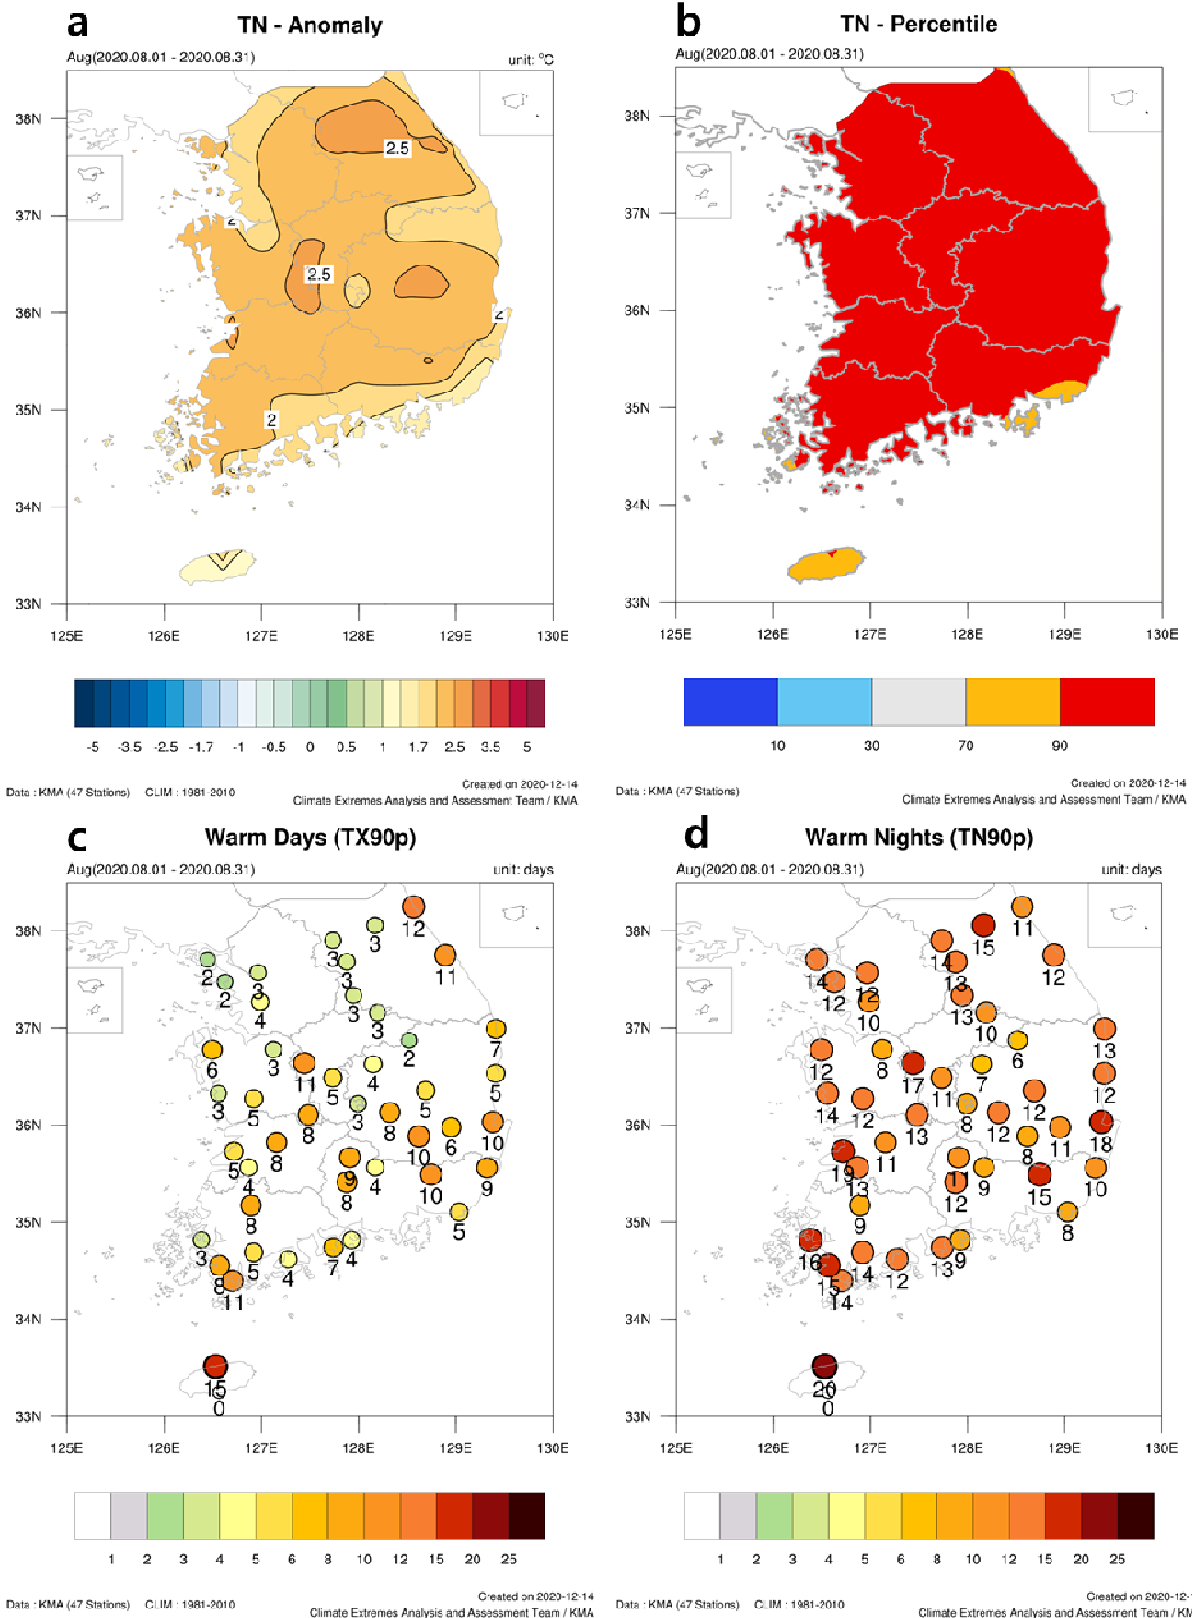


Figure 90. (a) Monthly mean daily minimum temperature (Tn) anomaly, (b) Percentile of monthly mean Tn, and the number of days with (c) maximum temperature (Tx) and (d) Tn greater than 90 percentile value of Tx and Tn, respectively. Taken from (co-anal.kma.go.kr)

아울러 북인도양의 해수면 온도도 유의한 양의 상관관계를 보이는데, 엘니뇨 발달 이후 북인도양의 해수면 온도의 편차는 양의 값을 계속 유지 하고 있었으며(Figures 80, 87, 94), 북서 태평양에서 고기압의 2020년 여름 내내 유지할 수 있도록 기여 한 것으로 보인다. 그러므로 8월 기온 상승은 이 고기압 관련 고온 다습한 공기의 유입이 일부 원인이 있는 듯 보인다.

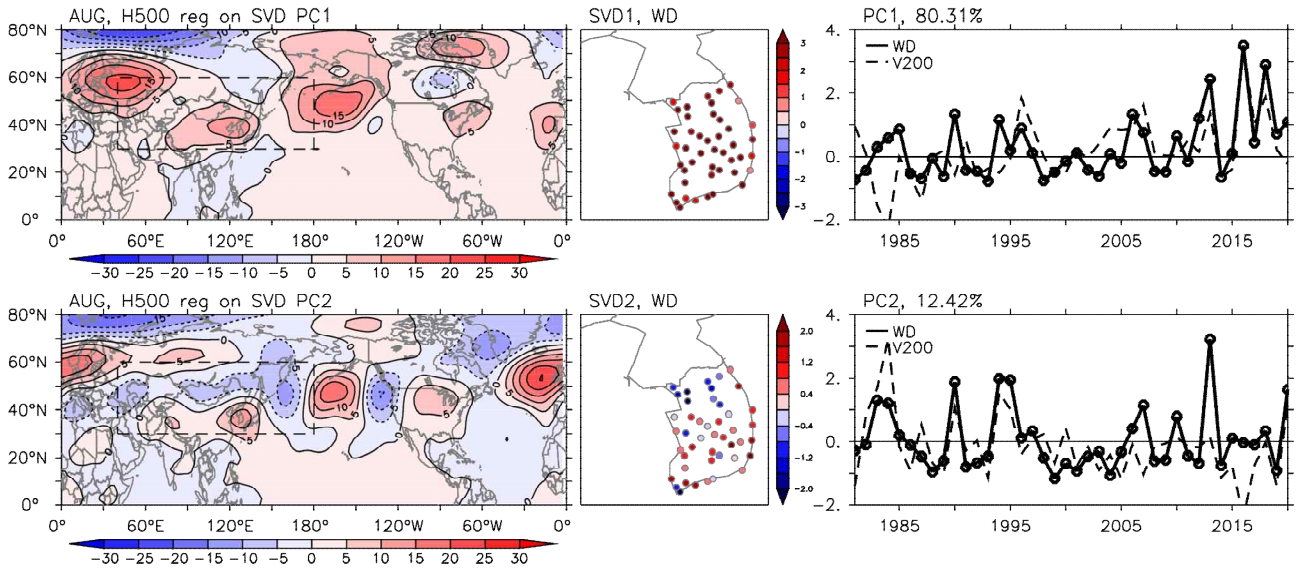


Figure 91. (left and middle panels) Leading two SVD modes and (right panels) their expansion coefficients based on the analysis of August 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020. (upper) first and (lower) second SVD modes. Contours and shadings are the regressions of the 500-hPa geopotential height to the corresponding expansion coefficients.

그리고 두 번째 SVD 모드를 CGT와 연결시킨다면, CGT 발생의 인도 몬순 역할을 고려할 수 있다(Ding and Wang 2005). Figure 92에서 인도양에서 바람장 분포를 보면 인도 몬순이 상당히 강했음을 알 수 있다. 그러므로 강한 인도 몬순과 관련하여 인도 주변에서 강수 증가 및 비단열 가열에 의한 강제력이 두 번째 모드 발생에도 역시 기여한 것으로 보인다.

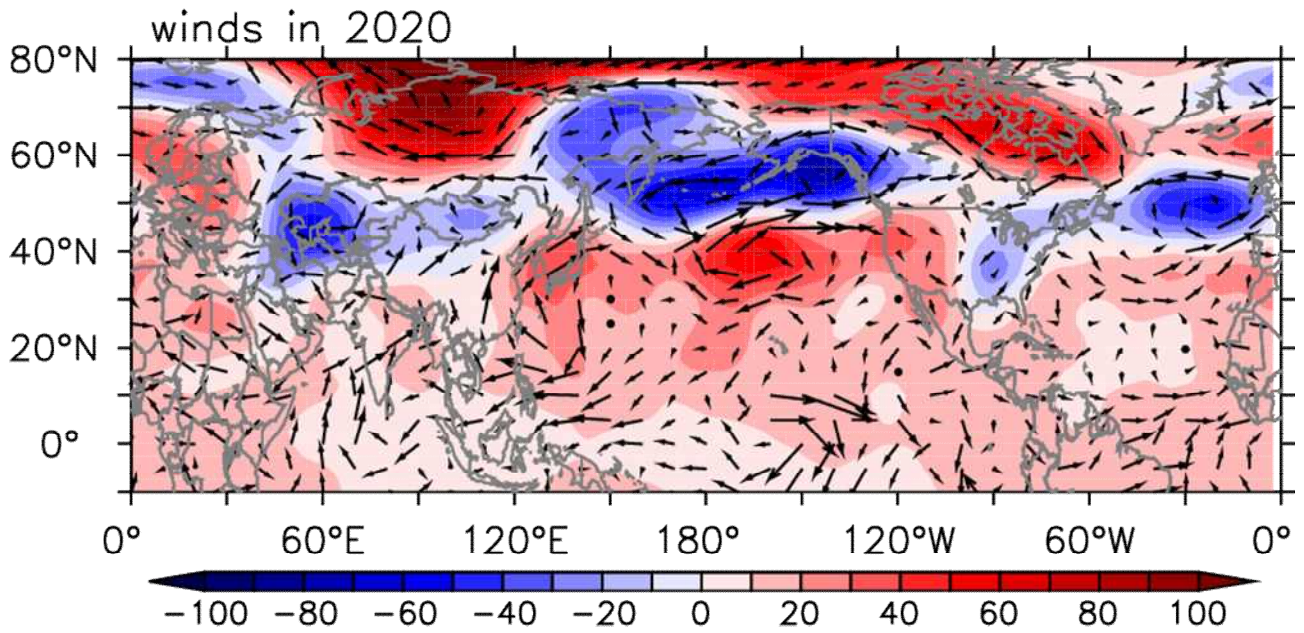


Figure 92. Spatial patterns of 500-hPa geopotential height (shades) and horizontal wind (vectors) anomalies in August, 2020.

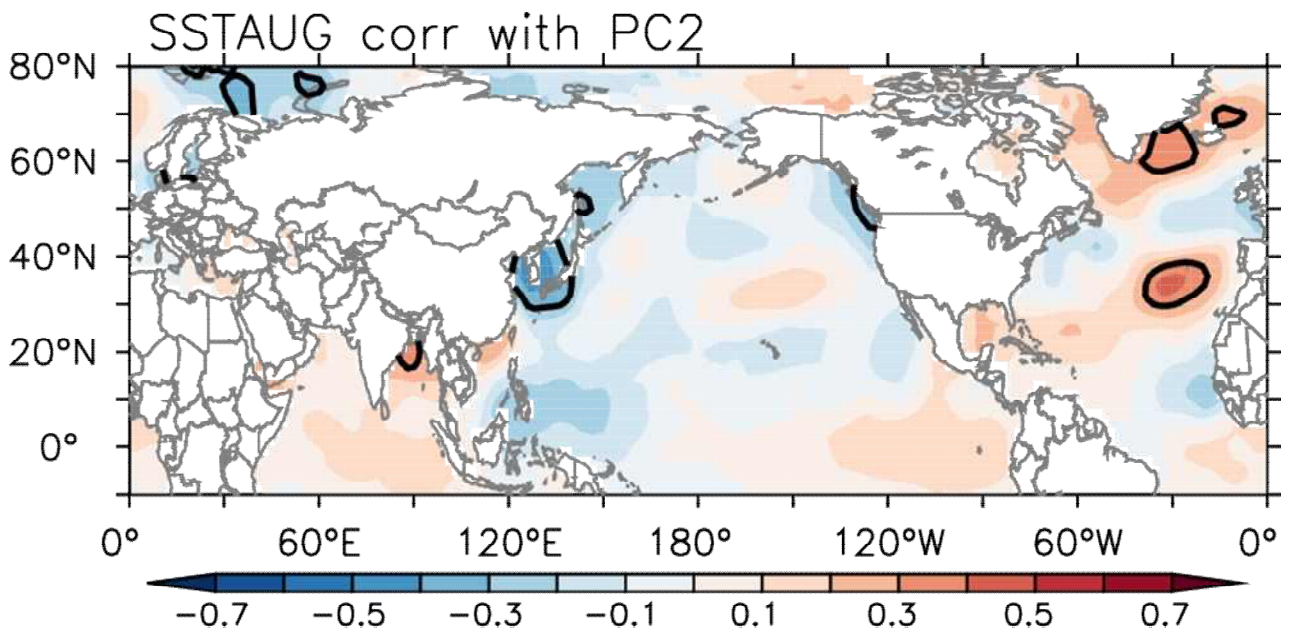


Figure 93. Spatial pattern of correlation coefficients between August sea surface temperature and expansion coefficients from the second SVD mode based on the analysis of August 200-hPa meridional wind velocity over the region of (30° -60° N, 30° -180° E) and extremely warm days over South Korea during 1981-2020. Black contours indicate the correlation coefficients corresponding the 5% significance level based on a student t-test.

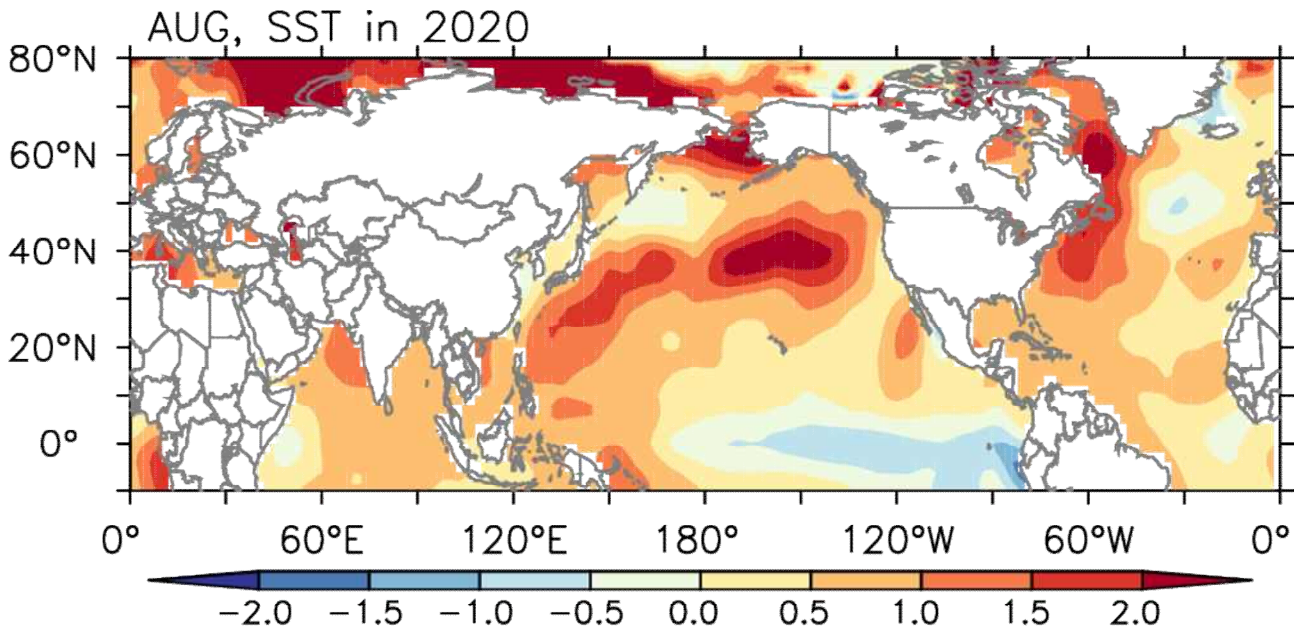


Figure 94. Spatial patterns of SST anomalies in August, 2020.

(나) 2020년 혹서기 이상 기후 발생 원인 분석

이전 절들에서 2020년 한반도 여름철 기후는 변동성이 상당히 컸다는 것을 보여주었으며, SVD 분석을 통해서 간단한 역학 설명 들을 제시하였다. 다음 절들에서 각각의 역학들에 대한 자세한 분석 결과들이 서술될 것인데, 그 역학들의 중요한 기작은 엘니뇨 이후 세 대양 인도양, 태평양, 대서양의 상호작용이다. 특히 엘니뇨 쇠퇴기 동안 인도양, 열대 대서양에서의 해수면 온도 변화가 한반도에서 2020년 여름철 기후 변동 관련 주변 대기 순환장 형성에 영향을 준 주요 요소들이다.

적도 태평양에서 해수면 온도 변동성과 관련된 인도양과 대서양의 해수면 온도 변동성 경향을 보기 위해서 Table 2에 나와 있는 엘니뇨와 라니냐 이벤트가 발생했던 년도들에 대하여 엘니뇨와 라니냐가 시작하는 봄철에서 이듬해 쇠퇴하는 봄까지 해수면 온도 편차에 대한 합성장 분석을 수행 하였다. Figure 95은 엘니뇨와 라니냐 이벤트들의 발달에서 쇠퇴기까지 적도를 따라서 인도양, 태평양, 대서양에서 해수면 온도 편차의 변화를 보여준다. 엘니뇨가 시작하는 봄철에 중앙 적도 태평양에서 양의 해수면 온도 편차가 나타나고, 시간이 지나면서 점점 그 양의 편차가 동쪽으로 확장해가며, 북반구 겨울철에 엘니뇨 관련 해수면 온도 편차가 최성기에 도달한다. 그리고 엘니뇨가 본격적으로 발달하는 8월부터 서태평양에서 강한 음의 해수면 온도 편차가 나타나며, 엘니뇨가 쇠퇴할 때까지 지속되었다. 이와 관련하여 인도양에서는 엘니뇨 최성기 이전 가을철에 양의 인도양 쌍극자 패턴이 보이고, 대서양에서는 전반적으로 음의 해수면 온도 편차가 발달한다. 그리고 엘니뇨 최성기 이후 봄철 인도양과 대서양에서 전체적으로 양의 해수면 온도 편차가 발달한다. 관측에서 라니냐에 대해서는 대체적으로 부호만 바뀐 엘니뇨 발달 동안 적도에서 해수면 온도 편차 변동과 비슷한 특징을 보였다. 엘니뇨/라니냐 발달 이후 봄철 인도양 및 대서양 해수면 온도 변화는 엘니뇨/라니냐 관련 해수면 온도가 강제력이 되어

대기 원격상관 패턴을 변화시키는 대기 bridge의 영향에 의해서 설명이 가능하다 (Klein et al., 1999; Enfield and Mayer, 1997; Alexander et al., 2002).

Table 12. Lists of El Niño and La Niña events classified by Atlantic Multidecadal Oscillation (AMO) phases.

Classification	Years
+AMO/El Niño	57/58, 97/98, 02/03, 04/05,06/07, 09/10, 14/15, 15/16,18/19, 19/20 (총 11개)
+AMO/La Niña	50/51, 54/55, 56/57, 61/62, 96/97, 89/99, 99/00, 00/01, 05/06, 07/08,08/09, 10/11, 11/12, 17/18 (총 15개)
-AMO/El Niño	63/64, 65/66, 68/69, 72/73, 76/77, 77/78, 82/83, 86/87, 87/88, 91/92, 94/95 (총 11개)
-AMO/La Niña	62/63, 64/65, 66/67, 67/68, 70/71, 71/72, 73/74, 74/75, 75/76, 83/84, 84/85, 85/86, 88/89, 94/95, 95/96 (총 14개)

이와 같은 엘니뇨 이후 인도양과 대서양에서 해수면 온도 변화는 북서 태평양과 한반도 북동쪽에서 고기압 순환 편차 발달에 영향을 미쳤다. Figure 96은 한반도 2020년 여름 혹서기 이상고온과 이상 강수 발생과 관련된 역학들을 설명한 간단한 모식도이다. 2019/20 엘니뇨 발달 이후 늦은 봄 부터 여름철 까지 북인도양 해수면 온도 상승이 유지되었으며, 관련된 고기압이 여름 내내 북서 태평양에 유지 되어 한반도에 더운 공기 유입의 원인이 되었다. 습도가 높고 더운 공기의 유입으로 6월과 8월은 이상 고온 증가의 원인이 되었으며, 7월은 이때 발달한 음의 NAO 관련한 중국 북동부 고기압 때문에 찬공기가 유입되어 이상 강수 형성의 호조건을 만들었고, 이 때문에 일사량 감소로 이상 저온이 증가하였다.




Figure 95. Longitude-time section for composite sea surface temperature anomalies along the equator (5° S- 5° N) from (upper panel) El Niño and (lower) La Niña onset to their decays (from March in El Niño or La Niña developing years to August in their decaying years).



Figure 96. Schematic diagram describing how interactions of climate modes over the Pacific, Indian and Atlantic Oceans affect temperature and precipitation over South Korea during 2020 summer.

① 열대 태평양과 인도양의 상호 작용

Figure 97는 2020년 1-8월 동안 인도양에서 해수면 온도, 해면 바람, 잠열의 변화상황을 보여준다. 2020년 봄철까지 주로 남 인도양에서 평년 보다 해수면 온도 상승이 있었고, 북인도양에서 북동풍 남인도양에서 남서풍이 편차가 우세하였다. 봄철을 지나면서 남인도양의 남서풍 편차는 약해지고, 북인도양에서는 북동풍의 편차가 증가하였다. 해양에서 대기로의 잠열 속 감소는 봄철까지 남인도양에서 존재하다가, 봄철이 지나면서 여름철까지 대기로의 잠열 속 감소가 우세하였다. 이 같은 변화는 겨울철 Niño 3.4 지수와 이후 월별 편차장을 기반으로 회귀 분석을 수행한 Figure 98과 상당히 유사하다는 것을 확인할 수 있는데, 다시 말해서 2020년 1-8월 동안 인도양에서 편차장들의 변화는 일반적으로 엘니뇨 쇠퇴기에 발생하는 것으로 설명될 수 있다는 것을 의미한다.

좀 더 자세하게 관련된 역학들을 설명하면(Du et al., 2009; Xie et al., 2009, 2016), 엘니뇨 발달 동안 워커 순환 강도의 감소로 남인도양 상공에서 고기압성 순환 편차가 발달하고 이 대기 순환은 해양의 downwelling 로스비 파동을 발생시키고 이 파동이 서쪽으로 전파하게 되고 남서 인도양의 수온약층을 깊게 만들어서 남서 인도양의 해수면 온도가 상승하게 된다. 북인도양에서 북동풍, 남인도양에서 북서풍 편차의 존재는 남서 인도양 해수면 온도 상승에 의한 남

북 방향의 해면 기압 경도의 감소로서 설명 될 수 있으며, 봄철을 지나 북인도양의 해수면 온도 상승은 봄철에 접어들면서 북인도양에서 평균 바람장이 동풍에서 서풍으로 바뀌는데, 북인도양에서 북동풍 편차가 해수면에서 바람장을 약하게 하여, 해양에서 대기 로의 잠열속이 감소 하게 되기 때문이다.




Figure 97. Time-latitude section for sea surface temperature (shading), latent heat flux (white-colored contours) and 1000-hPa wind (vectors) anomalies and the climatological zonal winds (black contours) zonally averaged in the tropical IO (40° -100° E) from January to August in 2020. For latent heat flux anomalies, its positive values indicate increase in fluxes going out from the ocean.

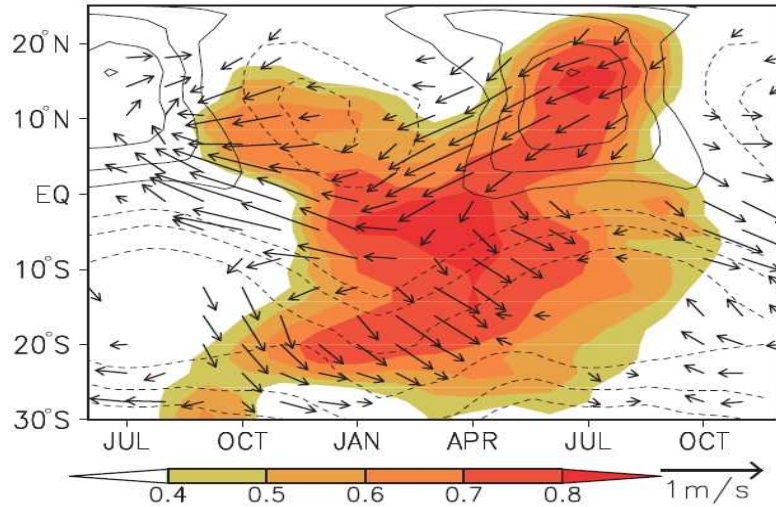


Figure 98. Time-latitude section of regression upon ND(0)J(1) Niño3.4 SST: SST (shaded; ° C) and surface wind velocity (vectors) zonally averaged in the tropical IO (40° -100° E). Zonal wind climatology is indicated with black contours. Taken from Xie et al. (2016)

북인도양에서 해수면 온도 상승은 깊은 대류에 의한 습윤 단열 적응에 의해서 대류권 온도의 증가를 야기하게 되고, 대기의 경압 켈빈 파동을 태평양에서 발생시키게 된다. 북서 태평양에서 이 켈빈 파동은 북서풍 편차 및 대기의 발산을 야기하게 되고, 대류 억제를 유도하여 여름철 북서 태평양에서 고기압성 순환 편차의 발달을 촉발하게 된다. 이러한 엘니뇨 쇠퇴 이후에도 엘니뇨가 여름철에 동아시아 기후에 영향을 미칠 수 있는 중요 인자는 봄철 인도양의 승온이 있는데, 이러한 기작을 이전 절에서 언급한 인도양의 capacitor effect (Xie et al., 2009, 2016)라고 불리운다. Figure 99는 겨울철 Niño 3.4 지수와 다음 여름철 해수면온도, 해면 바람, 강수, 대류권 온도 편차와 회귀 분포를 보여주는데, 잘 형성된 인도양 승온, 북서태평양에서 중앙 아시아까지 넓게 확장된 고기압성 순환 편차, 대기 켈빈 파동 반응을 나타내는 워플 지역에서 썩기 모양의 대류권 온도 분포가 관측된다. 이러한 capacitor effect에 의한 해양과 대기에서의 분포가 2020년 여름철에서도 잘 관측되었다(Figures 85, 87, 88).

결국 한반도를 포함한 동아시아에서 여름철 이상기온을 유발하는데 중요한 역할을 담당했던, 북서태평양 고기압성 순환 편차의 발달은 인도양과 태평양의 상호작용과 연관이 있다는 것을 시사한다.

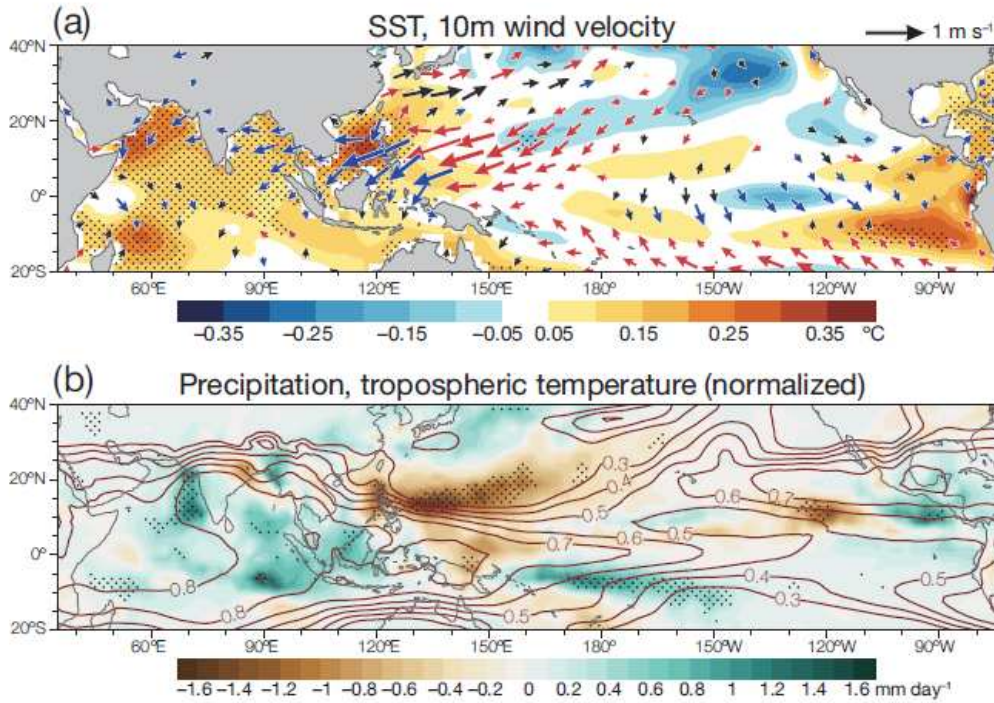


Figure 99. June-July-August anomalies of (a) SST (shading), surface wind velocity (vectors), (b) precipitation (shading) and normalized tropospheric (850-250 hPa mean) temperature regressed against Niño 3.4 SST index in the preceding NDJ for 1978-2010. Taken from Xie et al. (2016)

② 열대 태평양 대서양의 상호 작용

이전 절에서 7월 이상저온/강수 발생의 주요 원인 중 하나인 북서 태평양 고기압은 엘니뇨 쇠퇴기 동안 북인도양 해수면 온도 상승에 의한 대기 반응으로 설명 하였다. 또 다른 원인으로 한반도에서 북동부 지역의 고기압성 순환에 의한 찬공기의 유입을 들 수 있는데, 이 고기압성 순환 편차는 7월 대서양에서 음의 NAO 원격 상관 패턴(Figure 100)과 관련된 것으로 설명될 수 있다. 2020년 NAO 지수는 3월 까지 양의 값을 유지하다가 4월에 급격히 1 표준편차보다 큰 음의 값으로 변화 하게 되었고, 5-6월 달에 잠시 평년 수준까지 감소 하다가 7월에 다시 큰 음의 값을 보였다.

7월 NAO 관련 원격 상관 패턴을 분석 하기 위해서, 500-hPa 지위고도와 상관계수를 계산 하였다(Figure 101). 7월 NAO가 음의 값을 가졌으므로, 상관계수 분석 전에 NAO 지수에 (-1) 값을 곱하였다. 즉 Figure 101은 음의 NAO일 때 원격 상관 패턴으로 해석할 수 있다. 음의 NAO 일 때 북 대서양에서 전형적인 남에서 북 방향으로 음과 양의 지위고도 편차가 보이며, 이 패턴 남동쪽 방향으로 음과 양의 지위고도 편차가 변갈아 나타난다. 특히 한반도 북동쪽에 양의 지위고도 편차 발달과 음의 NAO와 유의한 상관 관계가 있다는 것을 보여준다. 이 상관 관계 분포는 최근 20년 기간에서 혹은 추세 제거 유무의 관계 없이 비슷한 결과를 보였다. 그러므로 이 상관 관계 분석은 7월 한반도 북동쪽에 고기압성 순환 편차의 발달과 음의 여름철 NAO와 관계가 있음을 시사한다. 북동쪽에 발달한 고기압성 순환 편차는 북쪽의 한기를 동아

시아 지역에 가져와서, 북서 태평양에서 고기압성 순환 편차에 의한 고온 다습한 남서풍과 만나 중국, 일본, 한반도 지역에서 이상 강수 및 이상 저온을 유발 하였다.




Figure 100. Change in NAO index from January to July in 2020.

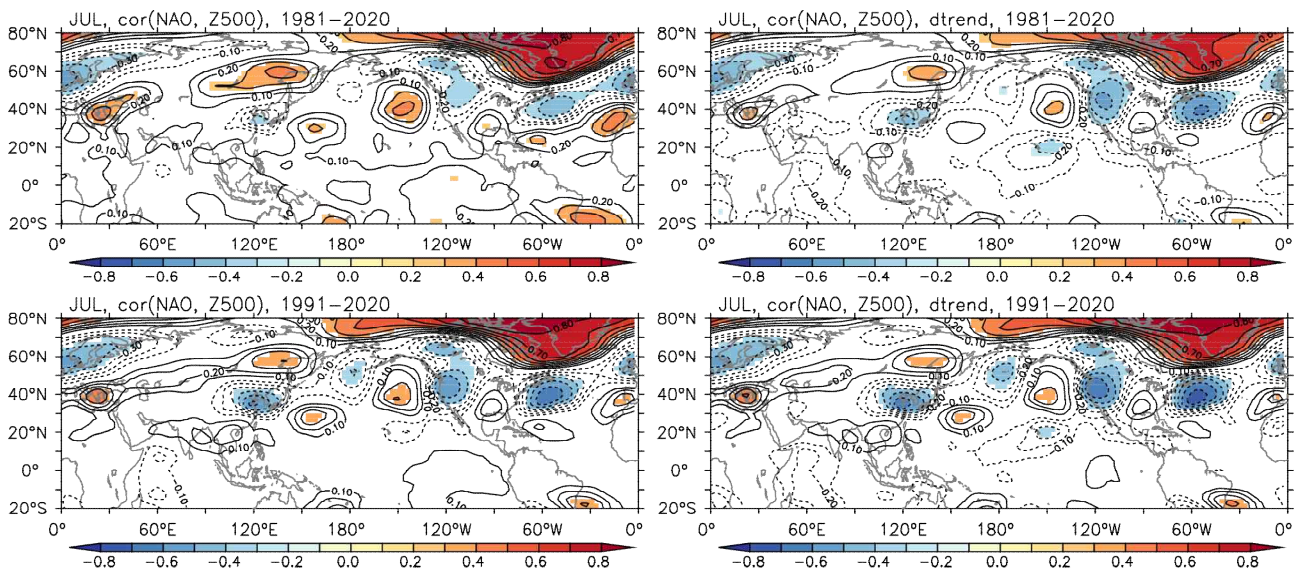


Figure 101. Spatial patterns of simultaneous correlation coefficients between NAO index and 500-hPa geopotential height in July: Upper panels are for 1981-2020 and lower panels for 1991-2020. Left panels show the analysis for detrended data.

여름철 음의 NAO 발달은 엘니뇨 쇠퇴기 동안 열대 대서양에서 해수면 온도 상승과 관련 지을 수 있다. 즉 엘니뇨 최성기 이후 대기 bridge 기작에 의해서, 열대 대서양 해수면 온도 변동을 야기 할 수 있다 (예, Enfield and Mayer, 1997). 즉, 워커 순환의 약화는 대서양에서의 무역풍 감소를 유발하고, 해양에서 대기로의 잠열 방출이 감소하게 되어 열대 대서양 해수면 온도 증가하게 된다 (Figure 102). 이 지연된 열대 북 대서양에서 해수면 온도 상승이 강제력이 되어 여름철 음의 NAO를 발달시킨 것으로 보인다 (Robertson et al. 2000). 열대 북 대서양에서

의 해수면 온도 상승이 강제력이 되었다는 증거는 비단열 가열과 500-hPa 연직 순환 편차장(오메가) 분포를 통해서 확인될 수 있다(lower panel of Figure 102). 즉 2020년 초여름에 열대 대서양에서 해수면 온도의 지연 상승과 이 시기에 양의 비단열 가열과 상승류의 증가가 동시에 존재하는 것을 확인할 수 있다. 위에서 설명된 7월 한반도 이상저온/강수 발달에 대한 주요 기작들 즉 태평양-인도양-대서양 간의 상호작용을 모식도로 정리 하였다(Figure 103).

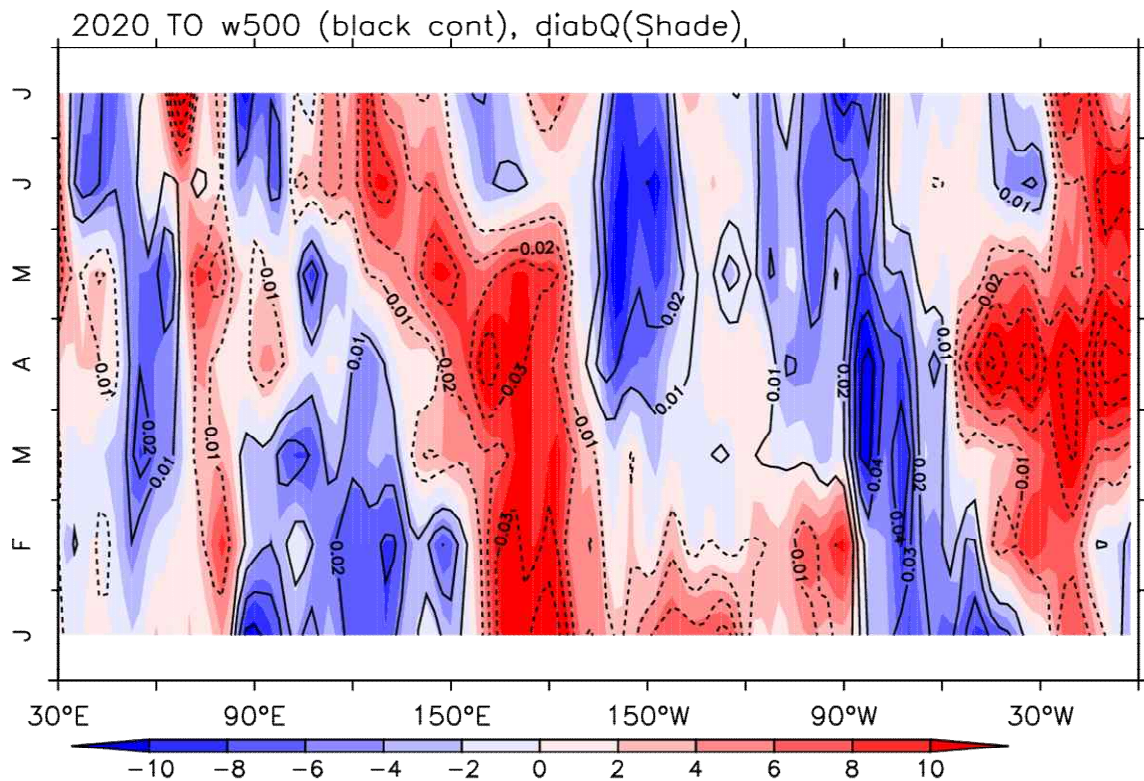
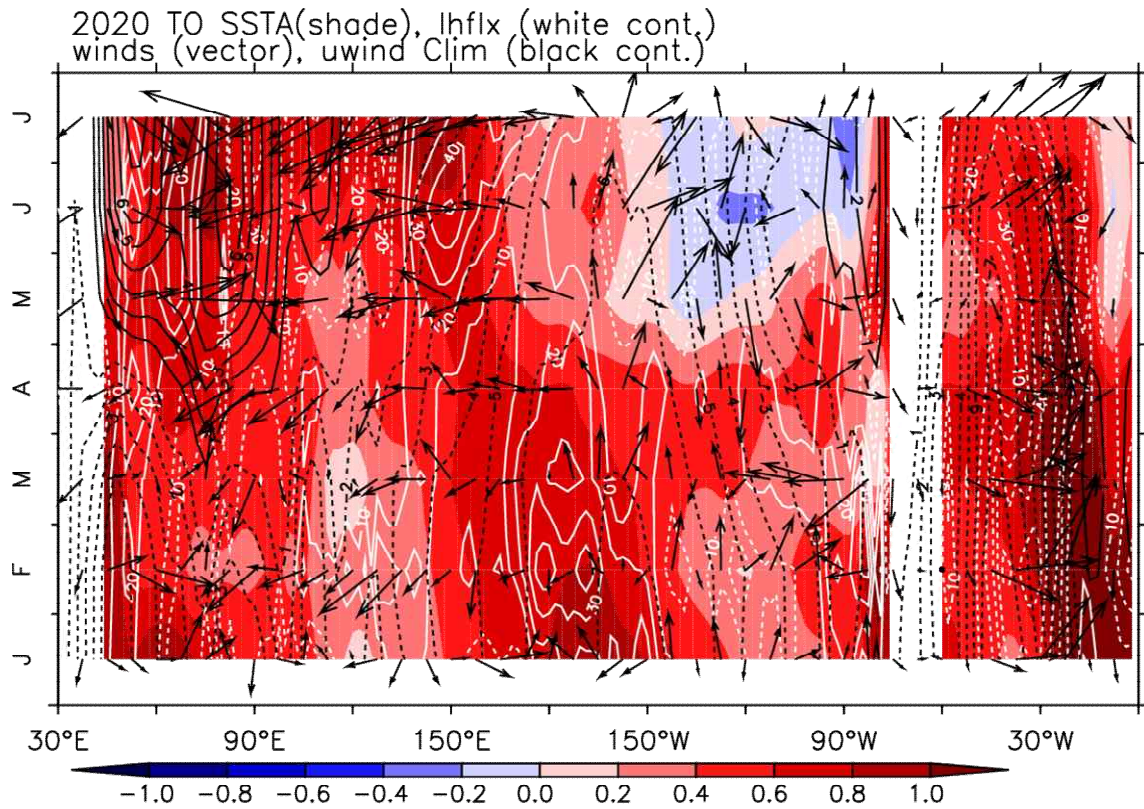


Figure 102. Longitude-time section for (upper panels) sea surface temperature (shading), latent heat flux (white-colored contours) and 1000-hPa wind (vectors) anomalies and the climatological zonal winds (black contours) and for 500-hPa pressure velocity (shading) and diabatic heating (contours) anomalies averaged meridionally in 10° -20° N from January to July in 2020.

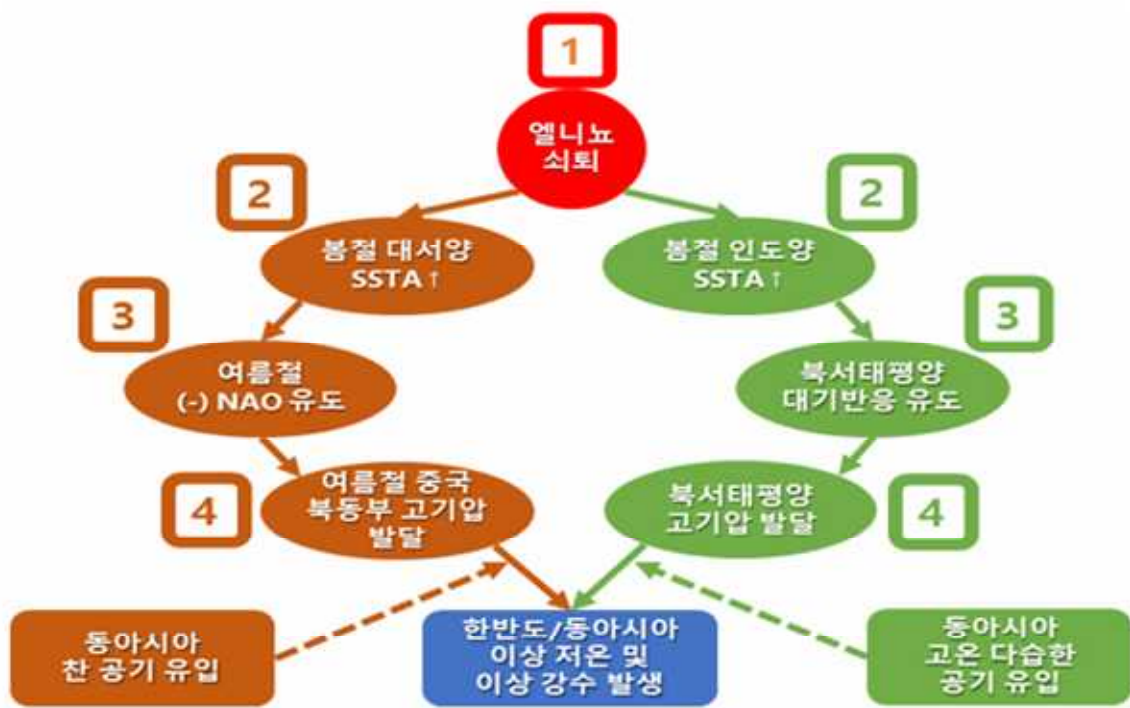


Figure 103. Schematic diagram describing how interactions of climate modes over the Pacific, Indian and Atlantic Oceans affect temperature and precipitation over South Korea in July, 2020.

③ 대서양 장주기 변동의 조절

이전 절에서 설명된 엘니뇨-인도양 승온-북서태평양 고기압, 엘니뇨-북대서양 승온-음의 NAO-한반도 북동부 지역 고기압의 관계가 다른 엘니뇨 해들에서도 존재하였는지 보기 위해서

관련된 지수들에 대한 시계열을 그려 보았다(Figure 104). 1980년 이후 14개의 엘니뇨 이벤트 중 9개의 엘니뇨 이벤트에서 위의 관계가 작동하여 이상 강수 혹은 이상 저온이 발생하였다. 그런데 9개의 이벤트 중 8개가 양의 AMO (Atlantic Multidecadal Oscillation) 위상에서 발생하였다. 이는 엘니뇨-인도양-대서양 결합 관계를 더 시간 주기를 가진 AMO가 조절 할 수 있다는 것을 시사한다.

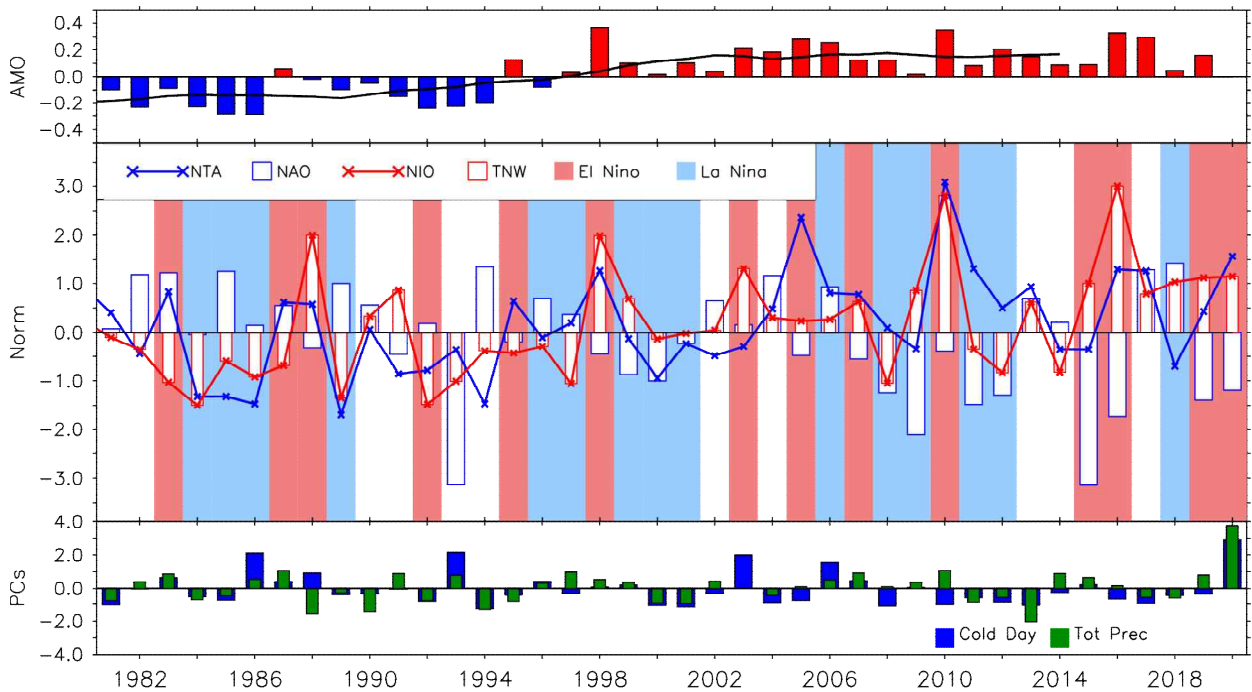


Figure 104. Time series of (upper panel) AMO, (middle) normalized north Atlantic SST, NAO, North Indian SST, tropical North Western Pacific SLP and Niño 3.4 SST indices, and (lower) expansion coefficients from the SVD analysis of July South Korean extremely cold days and east Asian total precipitation.

더욱이 과거 장주기의 AMO가 단주기의 모드들간의 관계에 영향을 미칠 수 있다는 연구들이 많이 진행 되었는데, 특히 ENSO와 NAO의 관계를 AMO가 조절할 수 있다는 과거 연구가 있다 (Zhang et al. 2019). ENSO와 AMO가 같은 위상일 때 NAO와의 관계가 뚜렷해진다는 연구로서, 즉 양의 AMO위상에서 엘니뇨와 음의 NAO 관계가 유의하고, 음의 AMO 위상에서는 라니냐와 양의 NAO와 관계가 유의하다고 밝혀내었다. 그러므로, AMO가 본 연구에서 밝혀낸 엘니뇨-인도양-대서양 그리고 동아시아/한반도 여름철 기후 관계를 조절의 역할을 할 수 있을 가능성이 존재한다.

그러므로, AMO 위상별로 1950년 이후의 ENSO 이벤트를 분류하여(Table 12), 엘니뇨-인도양 승온-북서태평양 고기압, 엘니뇨-북대서양 승온-음의 NAO-한반도 북동부 지역 고기압 관계 관련 지수들에 대하여 ENSO 위상과 AMO위상으로 구분하여 산포도 분석을 수행하였다 (Figure 105-108). 양의 AMO 위상에서 11개의 엘니뇨 이벤트와 15개의 라니냐 이벤트가 발생하

였으며, 음의 AMO 위상에서 11개의 엘니뇨 이벤트와 14개의 라니냐 이벤트가 있었다.

먼저 겨울철 ENSO 지수와 이듬해 봄철의 북인도양 해수면 온도 지수와의 관계는 AMO와 ENSO와의 위상이 같을 때(Figure 105) 상관 계수 값이 상대적으로 컸다. 라니냐 일 때 AMO 위상의 봄철 인도양 해수면 온도 하강 관계에 대한 영향이 그리 크지 않아 보인다. 하지만 엘니뇨와 양의 인도양 상승 관계가 양의 AMO 위상 일 때 분명히 나타났으나, 음의 AMO 위상 일 때 그 관계가 유의하지 않았다.

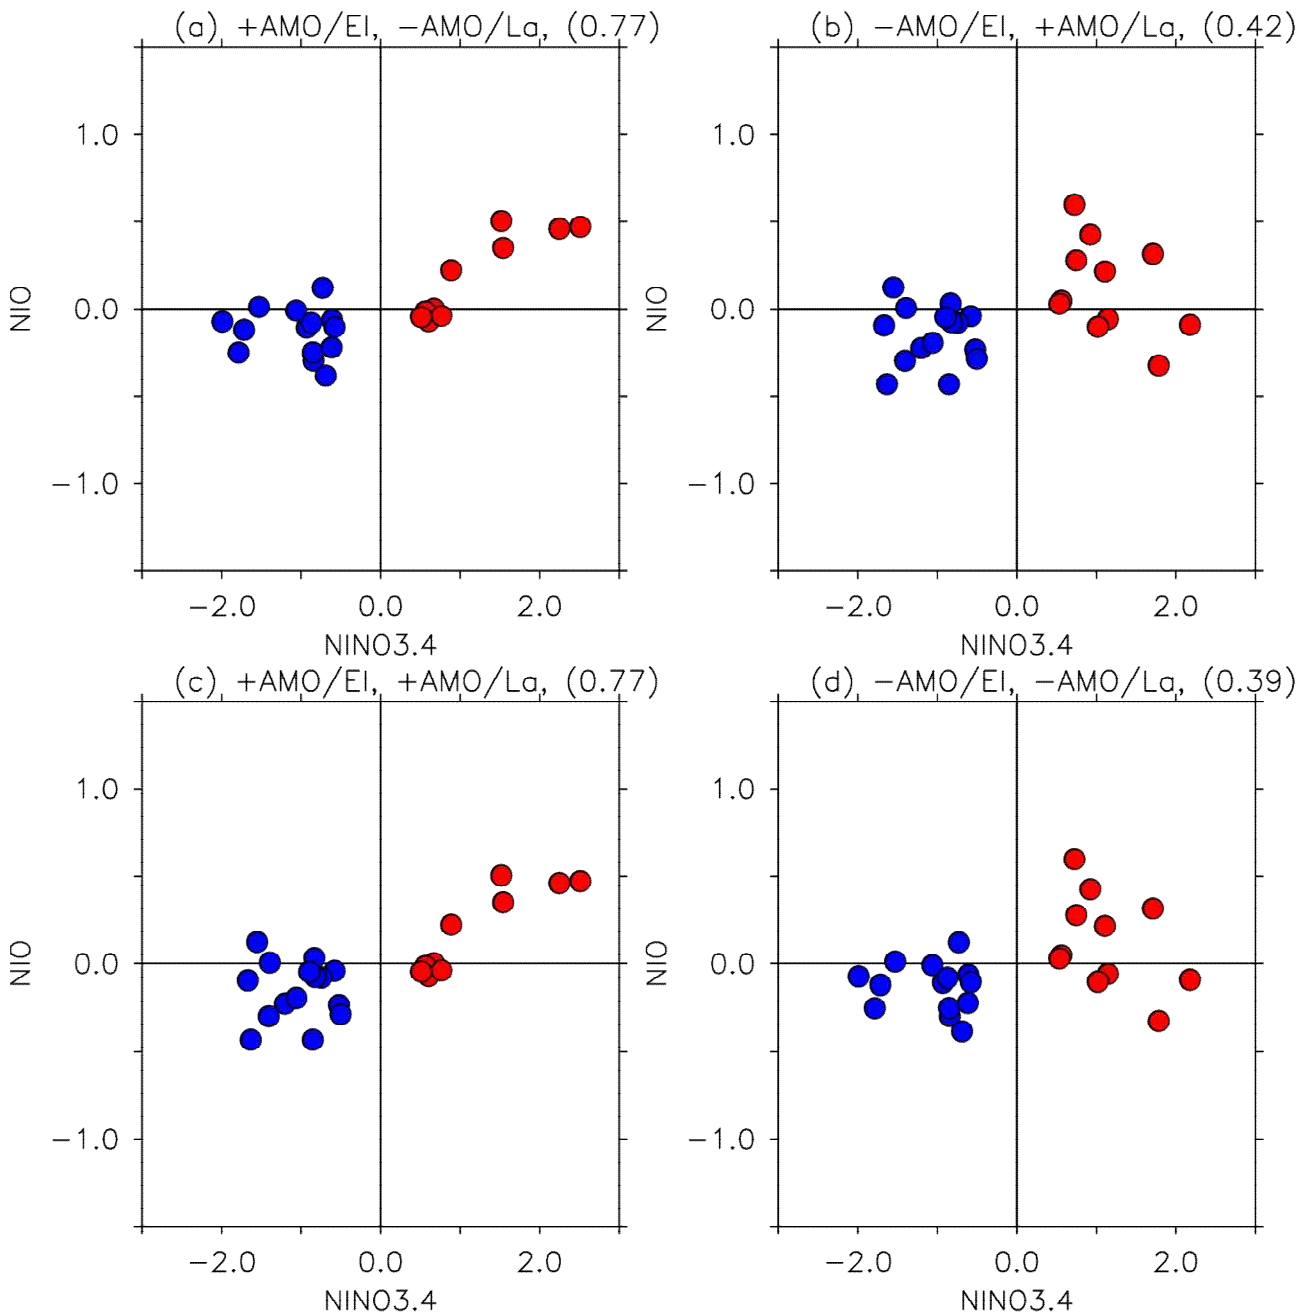


Figure 105. Scatter plots of MAM(1) North Indian SST index and D(0)JF(1) Niño 3.4 SST index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña. Correlation coefficient is shown in a parenthesis on the upper right side of each panel.

또한 북 열대 대서양 해수면 온도 지수와 ENSO 지수와 관계(Figure 106), 봄철 북인도양 해수면온도와 북서태평양 고기압(Figure 107), 북 열대 대서양 해수면 온도와 여름철 NAO 지수의 관계(Figure 108) 에서도 역시 ENSO와 AMO위상이 같을 때 상관 관계에 대한 통계적 유의성이 더 증가하였다.




Figure 106. Scatter plots of MAM(1) North Tropical Atlantic SST index and D(0)JF(1) Niño 3.4 SST index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña. Correlation coefficient is shown in a parenthesis on the upper right side of each panel.

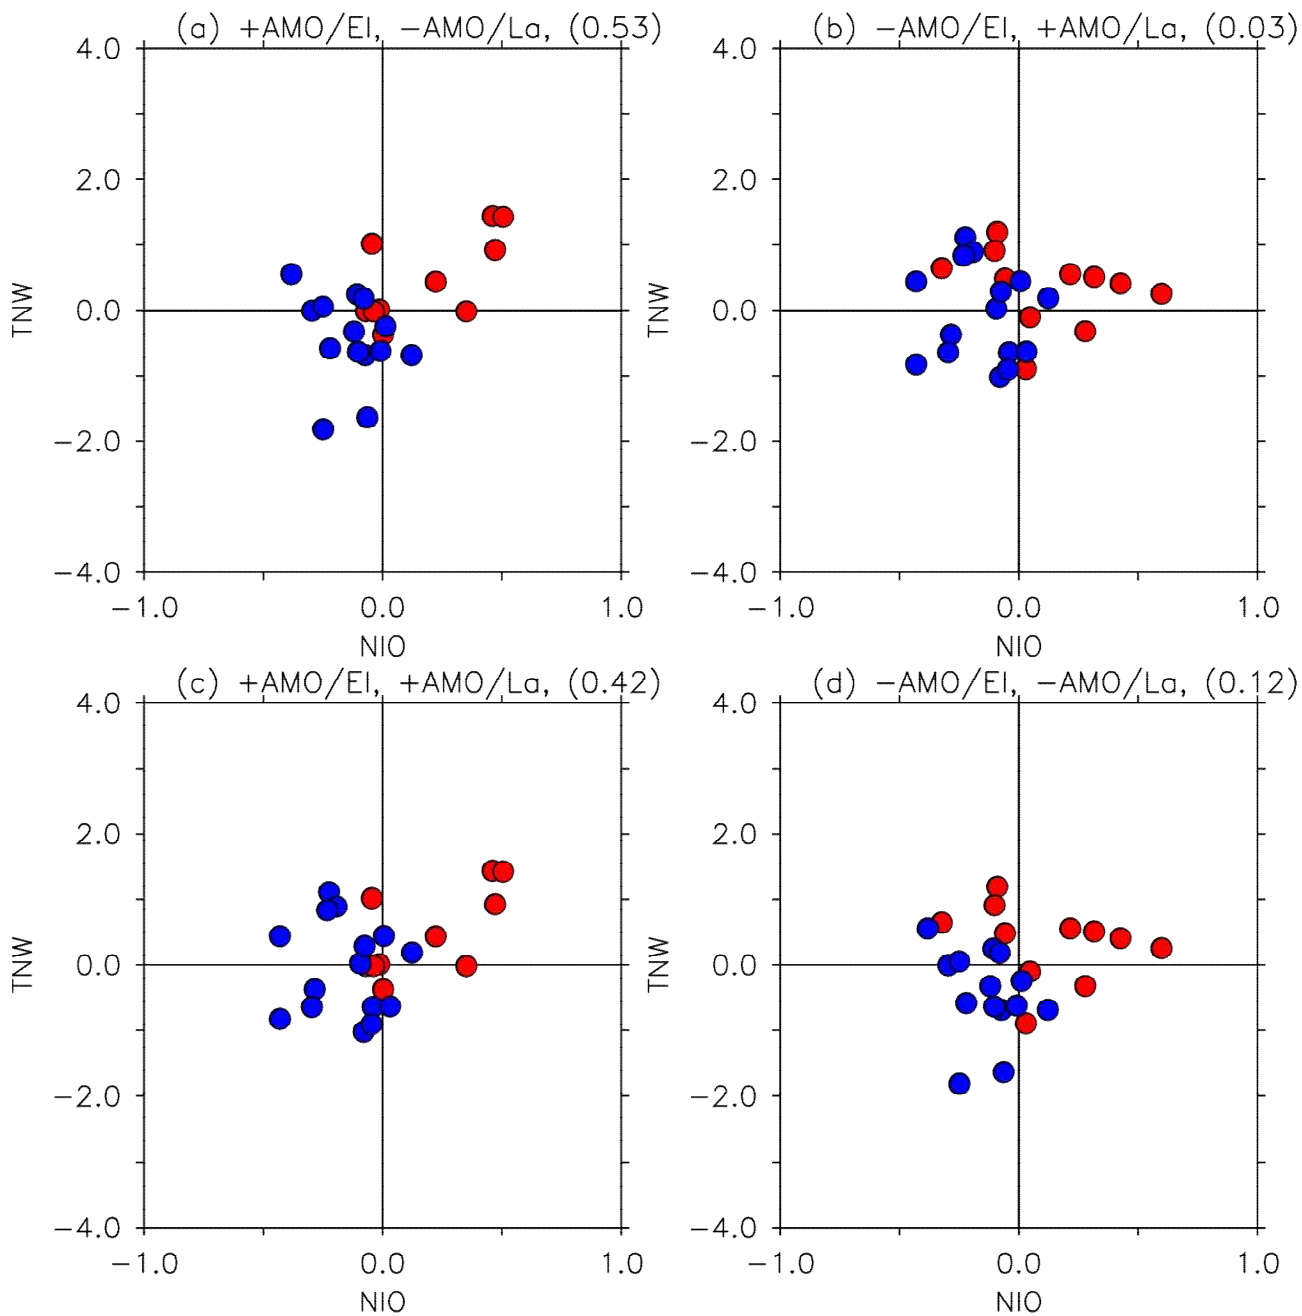


Figure 107. Scatter plots of MAM(1) Tropical North Western Pacific SLP index (TNW) and MAM(1) North Indian SST index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña. Correlation coefficient is shown in a parenthesis on the upper right side of each panel.




Figure 108. Scatter plots of MAM(1) Tropical North Atlantic SST index (TAO) and JJ(1) NAO index in (a) +AMO/El Niño and -AMO/La Niña, (b) -AMO/El Niño and +AMO/La Niña, (c) +AMO/El Niño and +AMO/La Niña, (d) -AMO/El Niño and -AMO/La Niña. Correlation coefficient is shown in a parenthesis on the upper right side of each panel.

결국 위의 AMO 위상별 산포도 분석은 본 연구에서 밝혀낸 인도양-태평양-대서양 결합기작에 대한 AMO 조절 역할의 가능성을 어느 정도 지지 하는 것이다. 지역 기후에 대한 장기 전망 정보를 제공하기 위해서 경년변동 주기의 기후 모드들과 지역 기후와의 관계를 활용하는데 있어서 그 관계에 대하여 AMO 같은 더 긴주기의 기후 변동의 조절 가능성을 고려해야 한다는 것을 시사한다.

Figure 76에서 2020년 6월부터 8월까지 한반도를 중심으로 동아시아 지역의 여름 기온과 강수의 변동이 심하였음을 언급하였다. 이러한 변동 분포는 양의 AMO 위상 동안 엘니뇨 해들에 대하여 합성장 분석을 수행하였을 때 올해와 비슷한 기온/강수 분포를 보였으며(Figure 109), 음의 AMO 위상에서 라니냐 해들의 합성장 분석(Figure 110)에서는 부호가 바뀐 상태로 비슷한 분포를 보였다.

이는 올해 여름처럼 들쭉날쭉한 기온 변동의 특징이 양의 AMO 위상에서 엘니뇨가 발달한 겨울철 다음의 여름에, 음의 AMO 위상에서 라니냐가 발달한 겨울철 다음의 여름에 나타날 가능성이 있다는 것을 보여준다. 좀더 확실한 결론을 내리기 위해서는 좀 더 긴 관측 자료를 가지고 분석을 수행할 필요가 있다.

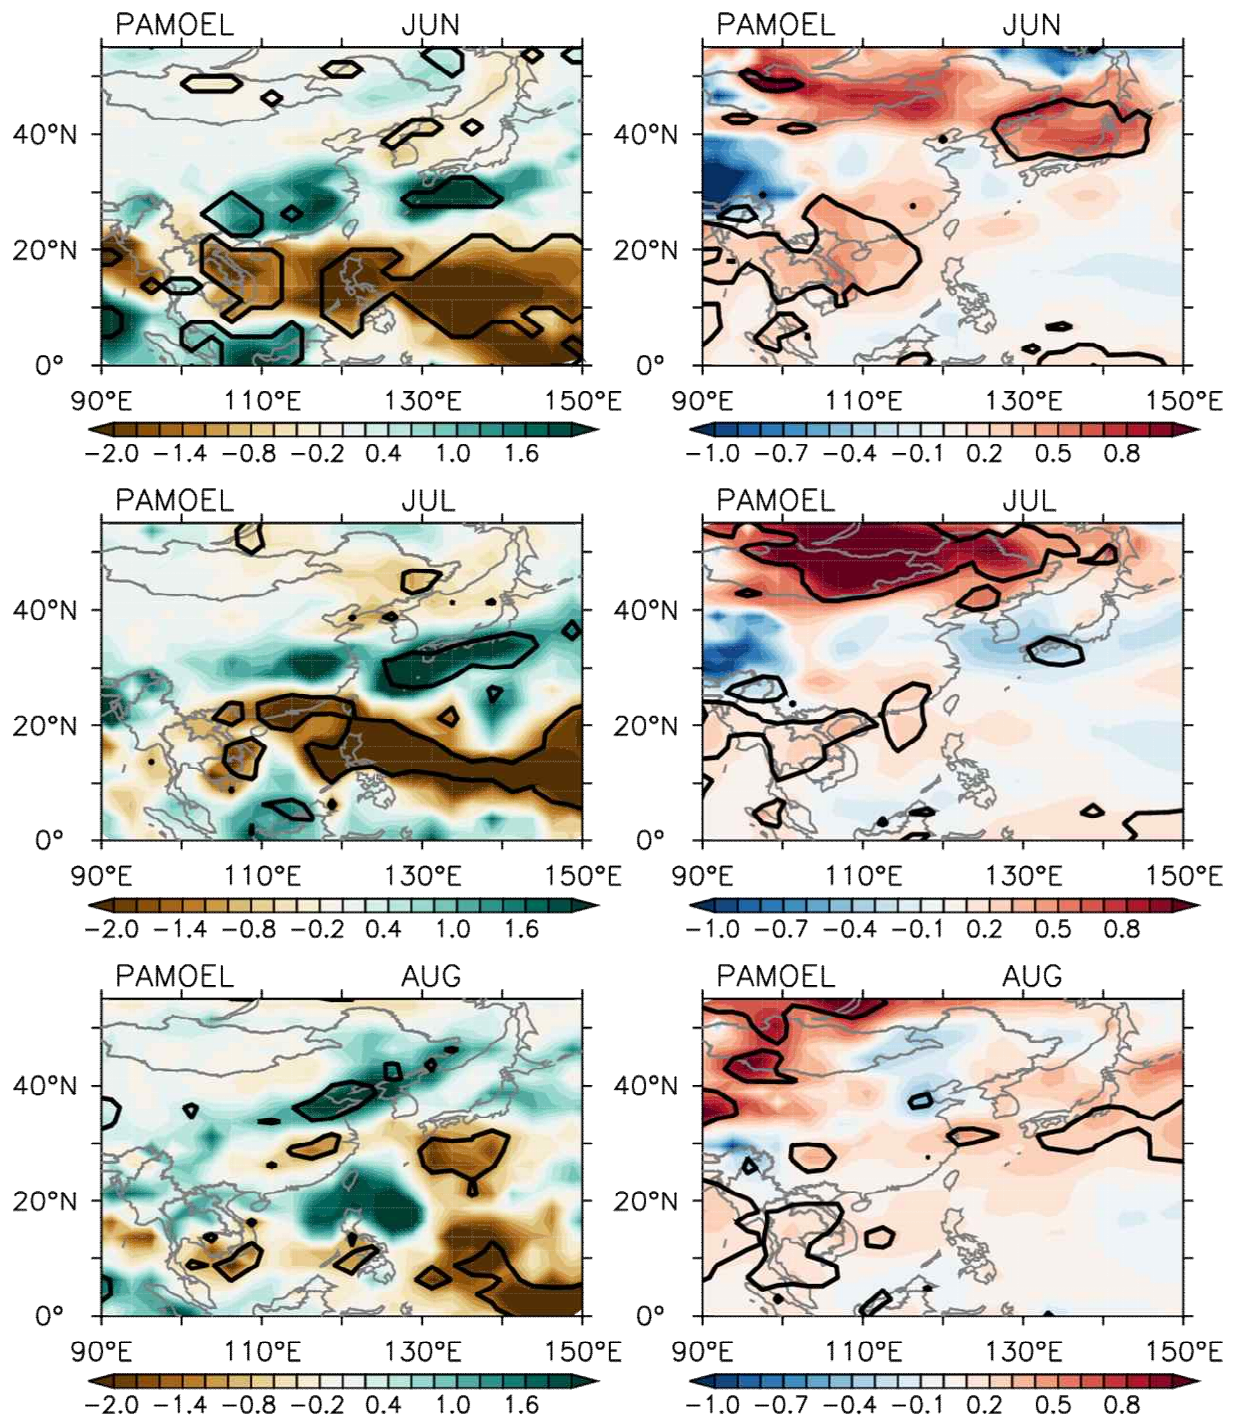


Figure 109. The temporal evolution of the aggregated (left panels) monthly total precipitation and (right) surface air temperature anomalies after a peak season of El Niño events in a positive AMO phase

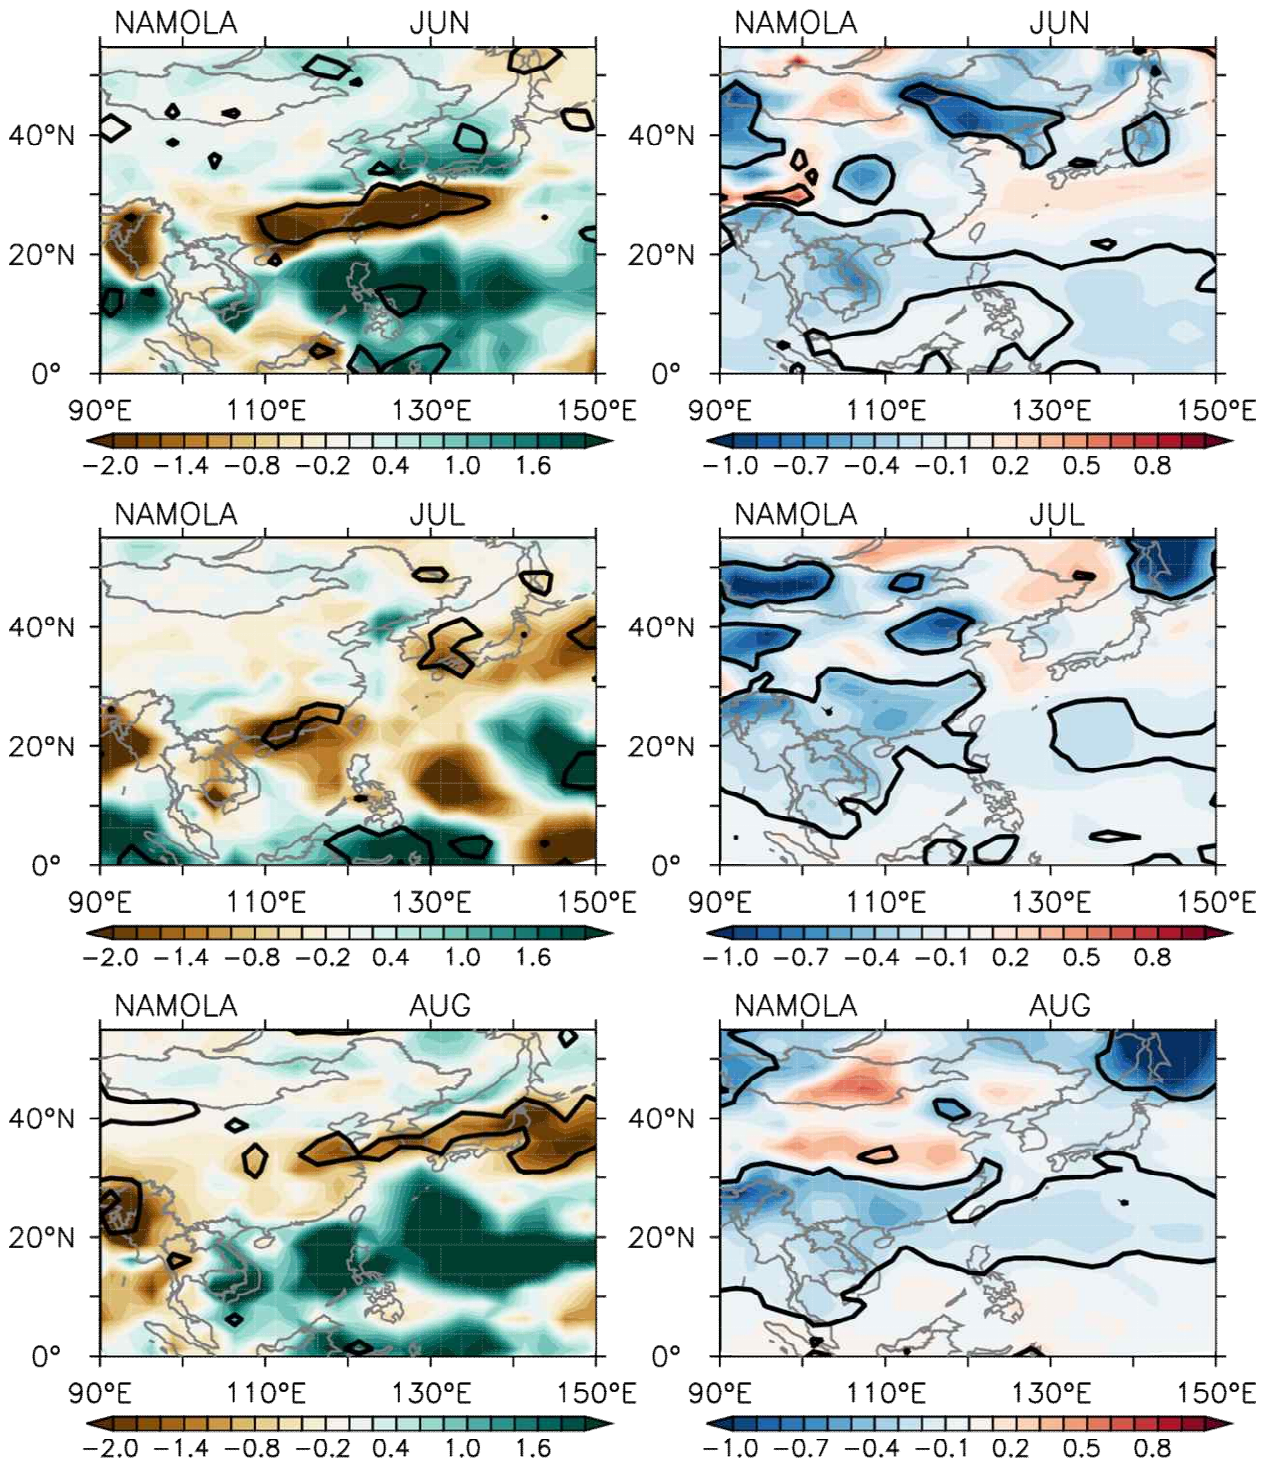


Figure 110. The temporal evolution of the aggregated (left panels) monthly total precipitation and (right) surface air temperature anomalies after a peak season of La Niña events in a negative AMO phase

나. 이상기후 장기 전망 콘텐츠

(1) 유사성 기반 추계학적 폭염예측

(가) 상관분석을 이용한 유사해 추출

본 연구의 목적은 한국의 여름철 이상고온 예측이기 때문에 5월 시점의 6-8월 T_{max} 예측, 6월 시점의 7-8월 T_{max} 예측, 7월 시점의 8월 T_{max} 예측을 위한 상관분석을 먼저 수행하였다. 예를 들어 5월에 6-8월 T_{max} 예측을 수행하기 위해서는 1-4월 GPH 자료만 가용하기 때문에 1-4월 상관도만이 유사해 선정에 사용되었다. Figure 111은 한국 6월 평균 폭염일수와 1월-4월 500 hPa GPH 사이의 Pearson r의 공간분포를 나타낸다. 상관도는 6월 폭염일수가 높게 나타났을 때에는 1월 베링해 부근에는 GPH가 양의 편차를 보였고 북서태평양 부근에서는 음의 편차, 중앙아시아 부근에서는 양의 편차와 관계가 있는 것을 알 수 있고 2월에는 북극 주변 GPH가 양의 편차를 보였음을 알 수 있다.

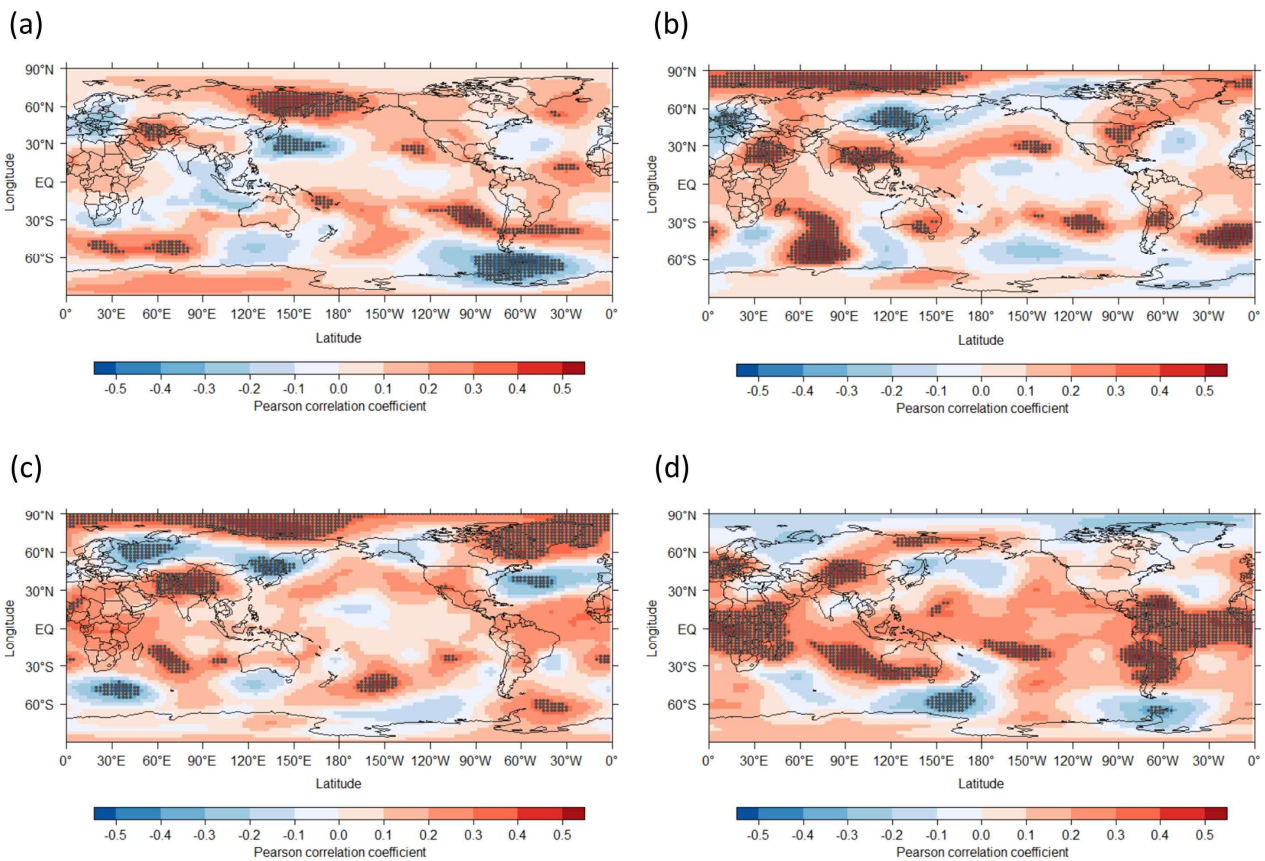


Figure 111. Correlation maps between June heat days with $T_{max} > T_{90}$ in Korea and 500 hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April for 1981-2019.

유의한 상관성이 나타는 모든 지역의 GPH 편차와 한국의 폭염일수의 상관성을 역학적으로 설명하지 못하기 때문에 설명이 되는 일부 GPH 편차를 회귀모형과 같은 통계적 모형 개발에 사용하는 것이 지금까지는 일반적이었다. 특히 선형 GPH와 특정지역의 폭염현상의 상관성은 우연히 발생할 수 있기 때문에 물리적 연관성이 없는 인자가 되어 오히려 Overfitting의 위험을 가중시킬 수도 있다(기상청, 2018). 하지만 본 연구에서는 GPH 편차 자체가 예측인자로

사용되는 것이 아니고 유사해 선정을 위한 Euclidean distance가 될 뿐이며 예측은 관측자료에 의해 제한되기 때문에 Overfitting의 위험은 사실 없다고 할 수 있다.

7월 폭염일수와 1월-5월 선행 GPH 편차와의 상관도에서도 물리적으로 설명할 수 있는 상관성과 그렇지 않은 상관성이 뒤섞여 있다 (Figure 112). 예를 들어, Figure 112d에서 기상청 (2018)은 4월 북미지역 쌍극 지위고도 편차는 대서양 지역 해수면 온도 강제력 및 열대 동태평양 해수면의 온도에 의한 반응으로 한국 7월 평균기온 상승을 설명한다. 또한 극지역 해수면 온도 역시 북미지역 기압분포를 형성하는데 영향을 미치는 물리적 인자로 볼 수 있다. 이에 반해 동유럽의 고기압 편차와 한국의 7월 기온상승과의 물리적 관계는 확실히 설명되지 않는다.

그러나 동유럽의 고기압 편차 역시 대서양 해수면 온도변화 영향이라면 한국의 고온과 같은 원인으로부터 발생한 현상이기 때문에 동일한 인자로부터 생긴 상관성이라고 볼 수도 있다. 물리적 인과관계는 역학적 해석으로 이루어지기 때문에 확실한 인자를 제안하는 방법이기도 하지만 설명이 되지 않았다고 해서 완전히 예측에 사용할 수 없다고 가정하는 것은 유의한 예측인자를 잃을 수 있는 가능성을 내포한다. 빅데이터 기반 통계모형 혹은 기계학습 모형은 유의한 상관성을 최대한 고려하면서 Overfitting을 방지하기 때문에 오히려 해석적으로 찾지 못한 인자를 예측에 고려하는 방법이 되기도 한다 (e.g., Wang et al., 2019). Figure 113의 1-2월 극지방 GPH 편차와 8월 폭염일수 역시 완전히 물리적으로 설명되지 않지만 경험적으로 고려할 수 유사해 선정에 고려될 수 있는 부분이다.

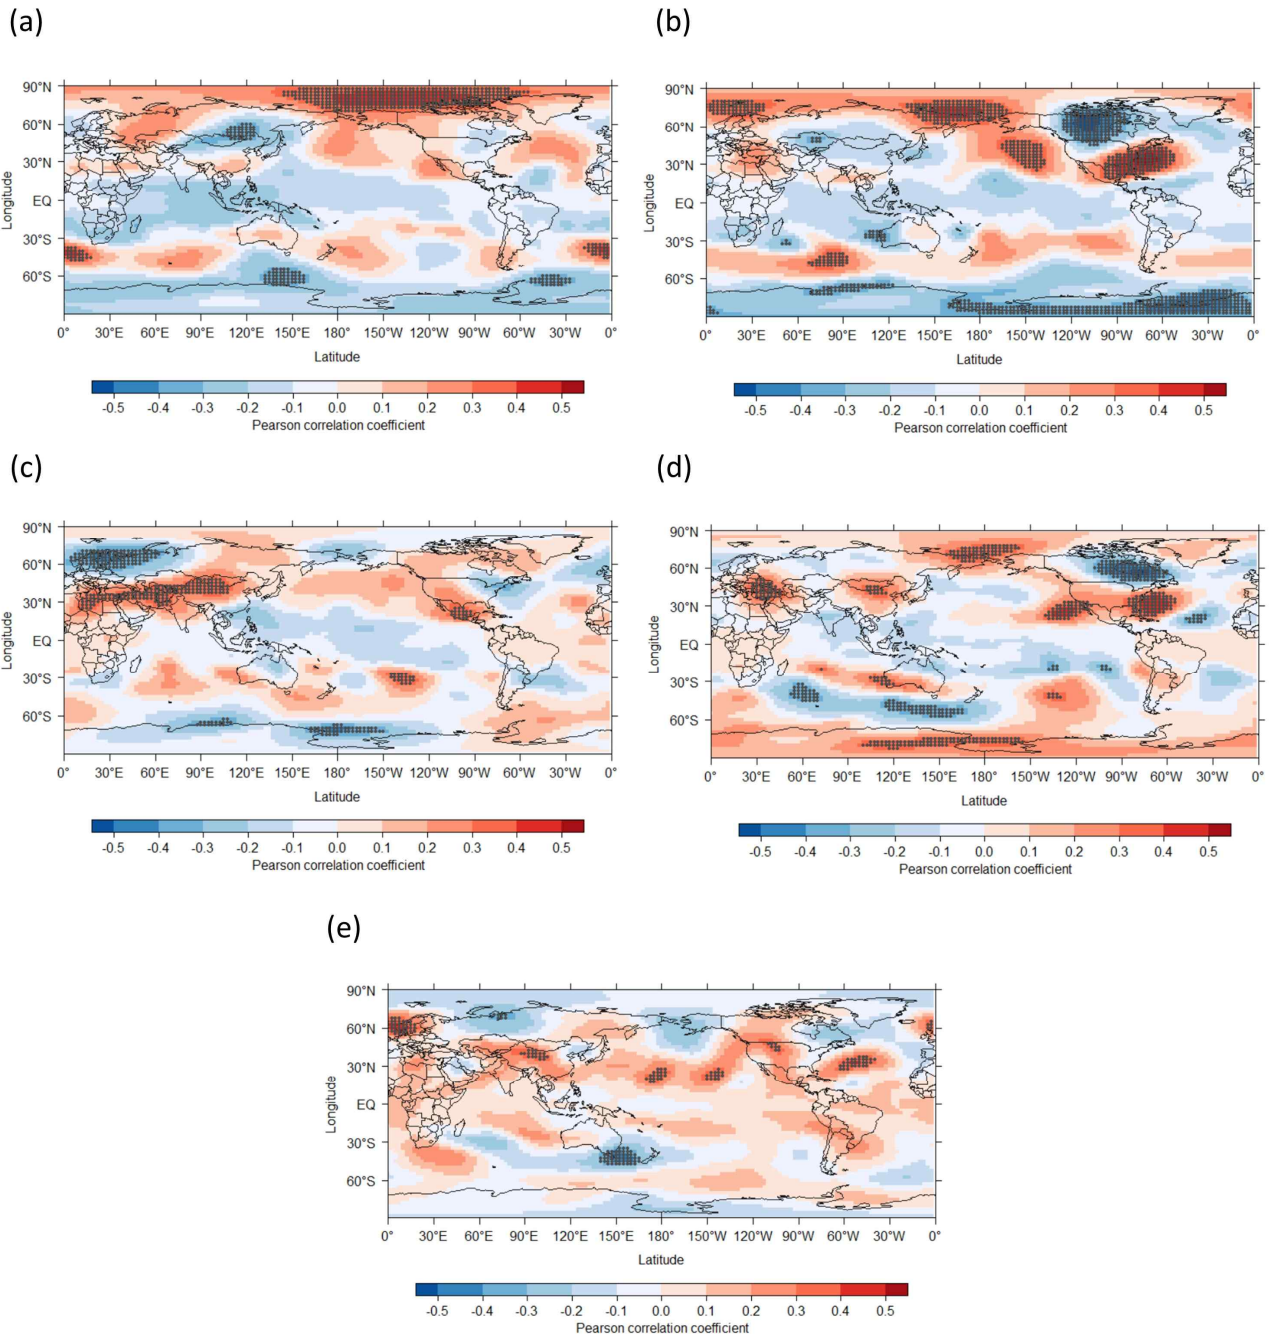


Figure 112. Correlation maps between July heat days with $T_{max} > T_{90}$ in Korea and 500 hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April, and (e) May for 1981-2019.

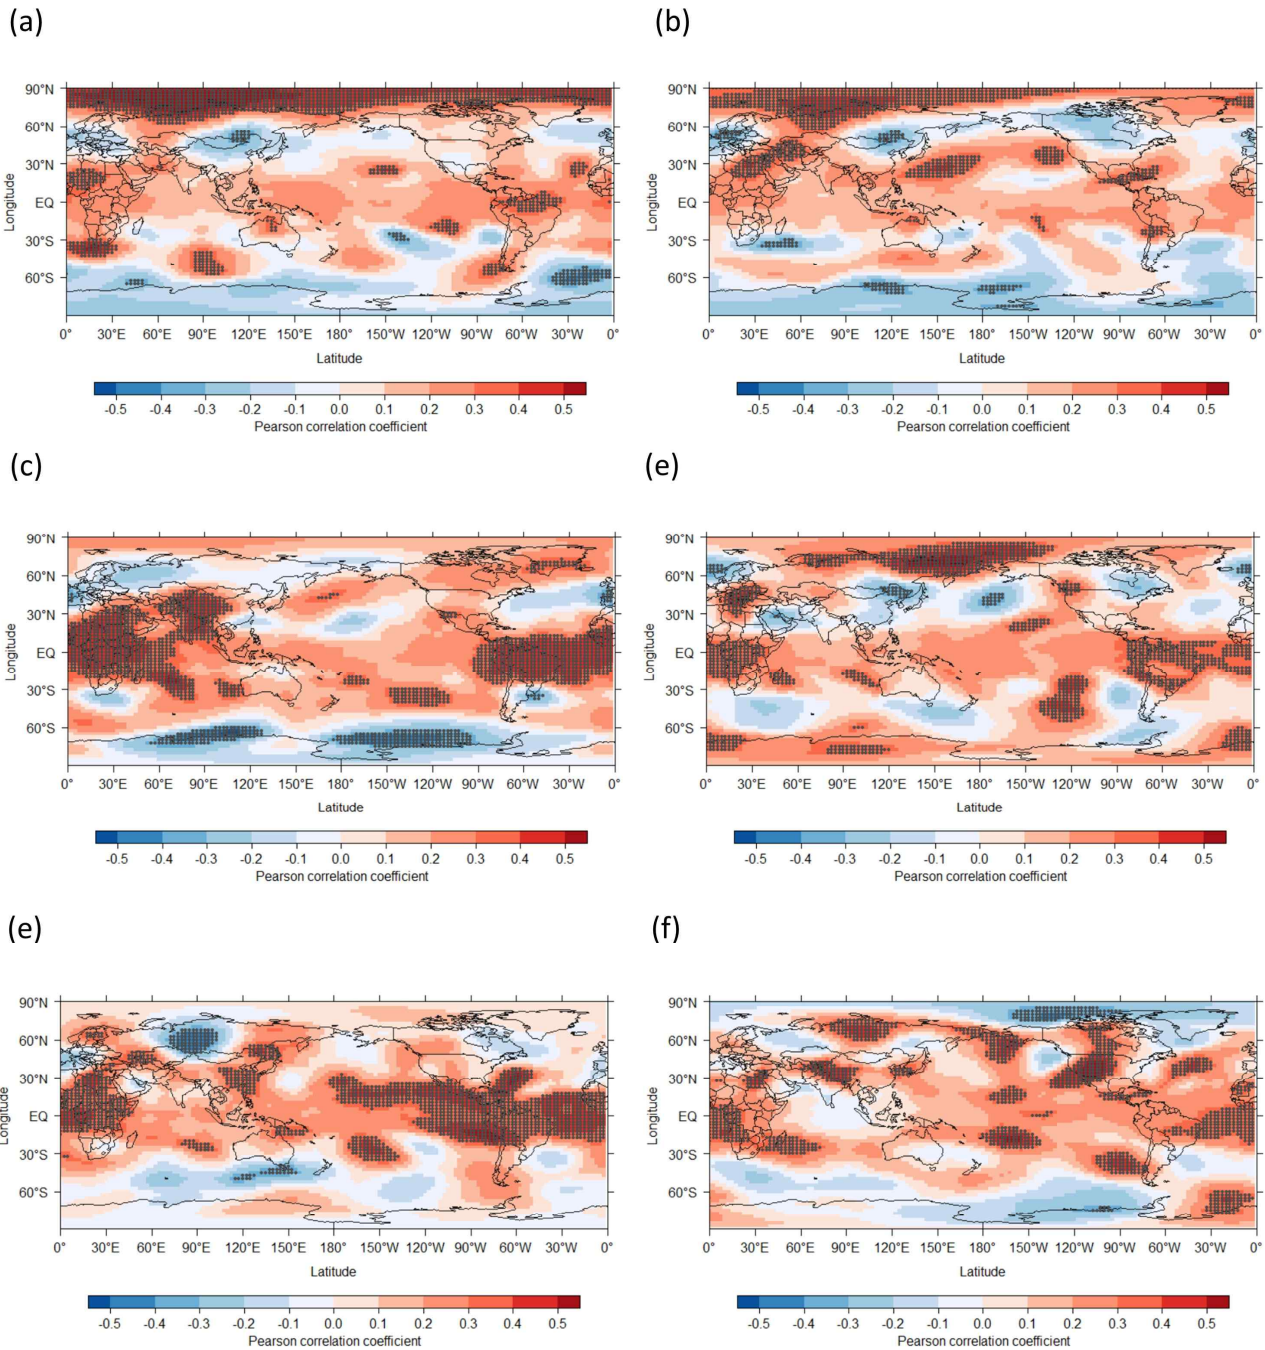


Figure 113. Correlation maps between August heat days with $T_{max} > T_{90}$ in Korea and 500 hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April, (e) May, and (f) June for 1981–2019.

Figures 111-113에서 유의한 상관성이 나타난 지역은 1981-2020년 각 해의 폭염일수를 예측하기 위한 유사해 선정에 사용되었다. 예를 들어 2020년 5월에 6월 폭염일수를 예측한다고 가정하면, 2020년 1월에서 4월까지의 GPH 편차 자료가 현업 운영상 가용하므로 Figure 111a-d의 상관도를 이용해 예측해와 관측해 사이의 1월-4월 GPH 차이를 이용해 유사해를 선정하였다. 2018년 7월의 경우, 1994년, 2013년, 2014년, 1985년, 2011년, 1990년이 선정되었고 같은 방법으로 1981년부터 2020년 7월에 폭염 예측을 위한 유사해를 선정한 결과는 Table 13과 같다. 2018

년 여름은 한국에 가장 강력하고 긴 폭염이 발생한 해로, 두 번째로 강력한 폭염 해로 꼽히는 1994년과 자주 비교 된다. 2018년에는 여러 기상관측지점에서 40°C가 넘는 T_{max} 가 관측되었고 절대기준 33°C가 넘는 일수가 30일이 넘는 경우가 속출했다 (Min et al., 2020). 2018년 이전 가장 강력했던 7월 폭염은 1994년이었고 1월-4월 GPH 변화를 비교했을 때 이 두 해는 매우 유사한 해로 나타났다. 선행 GPH의 상관분석을 기반으로 한 유사해 선정에 어느 정도 신뢰성이 있음을 알 수 있는 결과이다.

Table 13. Correlation maps between August heat days with $T_{max} > T_{90}$ in Korea and 500 hPa geopotential height anomalies in (a) January, (b) February, (c) March, and (d) April, (e) May, and (f) June for 1981-2019.

Year	Neighbor years						Year	Neighbor years					
1981	2017	2000	1997	2009	2005	2001	2001	2006	2019	2012	2017	1991	2000
1982	2014	2003	2015	1985	1995	1988	2002	1990	2000	2015	2009	2008	1997
1983	1992	1987	1984	1991	2017	1999	2003	1982	2001	2011	2015	1988	1991
1984	1987	1991	2012	1999	1988	1983	2004	2016	2015	1998	2003	1982	1985
1985	1982	1988	2014	2003	1995	2011	2005	2009	2012	1988	1984	2006	1981
1986	1991	1983	1984	2001	1992	2003	2006	2009	2012	2001	1984	1999	2005
1987	1999	1992	1984	1983	1996	2012	2007	2017	1987	2009	1992	2015	1984
1988	1985	1984	2005	2015	2009	2003	2008	2000	1997	2009	2017	1989	2002
1989	1993	2008	1997	2000	1992	2017	2009	2006	2012	2005	1999	2008	2019
1990	2002	2011	2001	2013	2009	2000	2010	1983	1987	2017	1991	1984	1992
1991	1986	1984	1992	2001	1983	2017	2011	2019	1990	2003	2001	2002	2009
1992	1983	1987	2017	1991	2000	1996	2012	2006	2001	2009	2000	1984	2005
1993	1989	1992	2000	1997	1987	2017	2013	2005	1994	2016	2011	1990	1985
1994	2014	2018	2013	1982	1985	2016	2014	1982	1985	2016	1995	1994	2005
1995	2015	1982	2016	2014	1988	1985	2015	1995	1982	1988	2016	2003	2002
1996	1987	1992	1999	1984	1991	2012	2016	2004	2015	2014	1995	1982	2013
1997	2000	2008	1981	1992	1993	2017	2017	1981	2000	1992	2001	2007	1983
1998	2004	2016	1995	2015	2012	1982	2018	1994	2013	2014	1985	2011	1990
1999	1987	1984	2012	2009	1996	1983	2019	2001	2011	2009	2012	2003	2006
2000	1997	2017	2012	2008	1992	2001	2020	2000	2009	1990	2001	2019	2002

Table 14. As in Table 13, but the heat-day record in the prediction year was not used for the correlation analyses by the LOOCV concept.

Year	Neighbor years						Year	Neighbor years					
1981	2017	1997	2000	1992	2009	2008	2001	2019	2006	2012	1991	2017	2003
1982	2014	2015	2003	1985	1995	2016	2002	1990	2000	2015	2009	2008	2005
1983	1992	2017	1987	1984	1991	1999	2003	1982	2011	2015	1981	2014	2001
1984	1987	1991	2012	1999	1988	1983	2004	2016	1998	2003	1982	2015	1991
1985	1982	2014	1988	1995	2015	2013	2005	2009	2012	1988	1981	2013	1984
1986	1991	1983	1984	2001	2003	2017	2006	2009	2001	2012	2005	1984	2008
1987	1999	1992	1984	1983	2012	1996	2007	2017	1988	2009	1987	2005	1984
1988	1985	1984	2005	2015	2009	2003	2008	1997	2000	2017	2009	1989	2002
1989	2008	1993	1997	2017	1992	2007	2009	2006	2005	2019	2017	2008	1990
1990	2002	2011	2001	2013	2000	2009	2010	1983	2017	2001	2007	1987	2005
1991	1984	1986	2001	1983	2017	1992	2011	2019	1990	2003	2001	2002	2009
1992	1983	1987	2017	2000	1991	1996	2012	2006	2009	2000	2001	1984	1999
1993	2000	1989	1997	2008	2007	1987	2013	2005	2016	2011	1990	1994	1985
1994	2000	2017	1990	1982	2009	1995	2014	1982	1985	2016	1995	2015	2005
1995	2015	1982	2014	2016	1988	1985	2015	1995	1982	2016	1988	2003	2007
1996	1987	1992	1999	1984	1991	2012	2016	2004	2015	1995	2014	1998	2013
1997	2000	2008	1992	1981	1993	2017	2017	1992	1981	1983	2000	2009	2007
1998	2004	2016	1995	1982	2005	2012	2018	2014	1982	1985	1995	2016	1990
1999	1987	2009	2012	1984	1996	2006	2019	2011	2001	2009	2003	2006	2012
2000	1997	2017	1992	2012	2008	2001	2020	2000	2009	1990	2001	2019	2002

하지만 이는 2018년 폭염일수를 상관분석 자료에 포함시킨 ad-hoc 분석으로 2018년 기록을 제외한 상관분석으로 유사해를 선정하면 결과는 달라진다. Leave-one-out-cross-validation을 적용해 2018년 폭염기록과 GPH자료를 제외한 상관도를 구한후 다시 2018년의 유사해를 찾으면 2014년, 1982년, 1985년, 1995년, 2016년, 1990년으로 나타나고 2014년, 1985년, 1990년을 제외하면 3개 해는 유사해에서 제외된다. 특히 가장 가까운 유사해이면서 두 번째로 큰 폭염기록이 나타난 1994년은 유사해에서 제외되어 버린다. 다시 말하면 상관분석의 기록에서 벗어나는 폭염사상을 본 연구의 유사해 선정방식으로 예측하기는 어렵다는 의미이다. 하지만 Table 13과 Table 14에 나타난 다른 해들의 유사해는 거의 유사하기 때문에 T_{max} 가 관측기록 이내일 것이라고 가정할 수 있을 때에는 다른 방법들과 함께 예측 현업에 사용되는 정도는 가능할 것으로 보인다.

Figure 114는 Figures 111-113의 상관도와 1-4월 선행 GPH 편차 자료를 이용해 선정된 1981-2019년 각 해의 유사해들의 평균값과 관측된 T_{max} 와 폭염일수를 1:1로 비교한 그림이다. 6

개의 유사해를 평균한 값은 통계학적으로 당연히 1개의 관측값의 분산보다 변동성이 작게 나타나는 것을 확인할 수 있다. 이는 역학모형에 의한 ensemble 예측 역시 1회 관측보다 분산이 작게 나타남을 의미하기 때문에 다중모형에 의한 예측은 불확실성은 ensemble의 크기에 맞춰 키워서 추정해야 함을 의미하기도 한다. 5월에 예측한 6, 7, 8월 (선행시간 1-3개월) 평균 T_{max} 는 선행시간이 짧을수록 예측력이 대체로 높은 것으로 나타났다. 하지만 폭염일수는 2개월 뒤 예측인 7월이 가장 좋은 것으로 나타났고 상대적으로 낮기는 하지만 8월도 T_{max} 에 대한 예측력보다 높게 나타났다. 상관분석 자체를 폭염일수를 기준으로 했기 때문에 유사해 분석의 기준이 아닌 평균 T_{max} 에 대한 예측력이 낮게 나타나는 것은 당연한 현상이다.

6월에 새로운 상관도를 이용해 다시 선정된 유사해의 7월, 8월 평균 폭염일수는 5월에 수행한 예측 결과보다 조금 더 나은 것으로 나타났지만 현업 운영에 영향을 줄 정도로 예측력이 크게 상승했다고 보기는 어려운 정도였다 (Figure 115). 하지만 7월 수행한 8월 예측 결과는 유의미하게 성능이 좋아졌다고 볼 수 있다 (Figure 116). 5월 GPH 자료는 7, 8월 폭염예측에 큰 의미는 없지만 6월 GPH 편차는 8월 폭염 예측에 비교적 큰 영향을 주는 것으로 보인다. 유사해 선정을 통한 폭염일수 예측 성능은 최대 Pearson $r = 0.7$ 정도로 나타나는 것으로 판단되고 lead time 이 길어질수록 점점 작아질 것으로 예상된다.

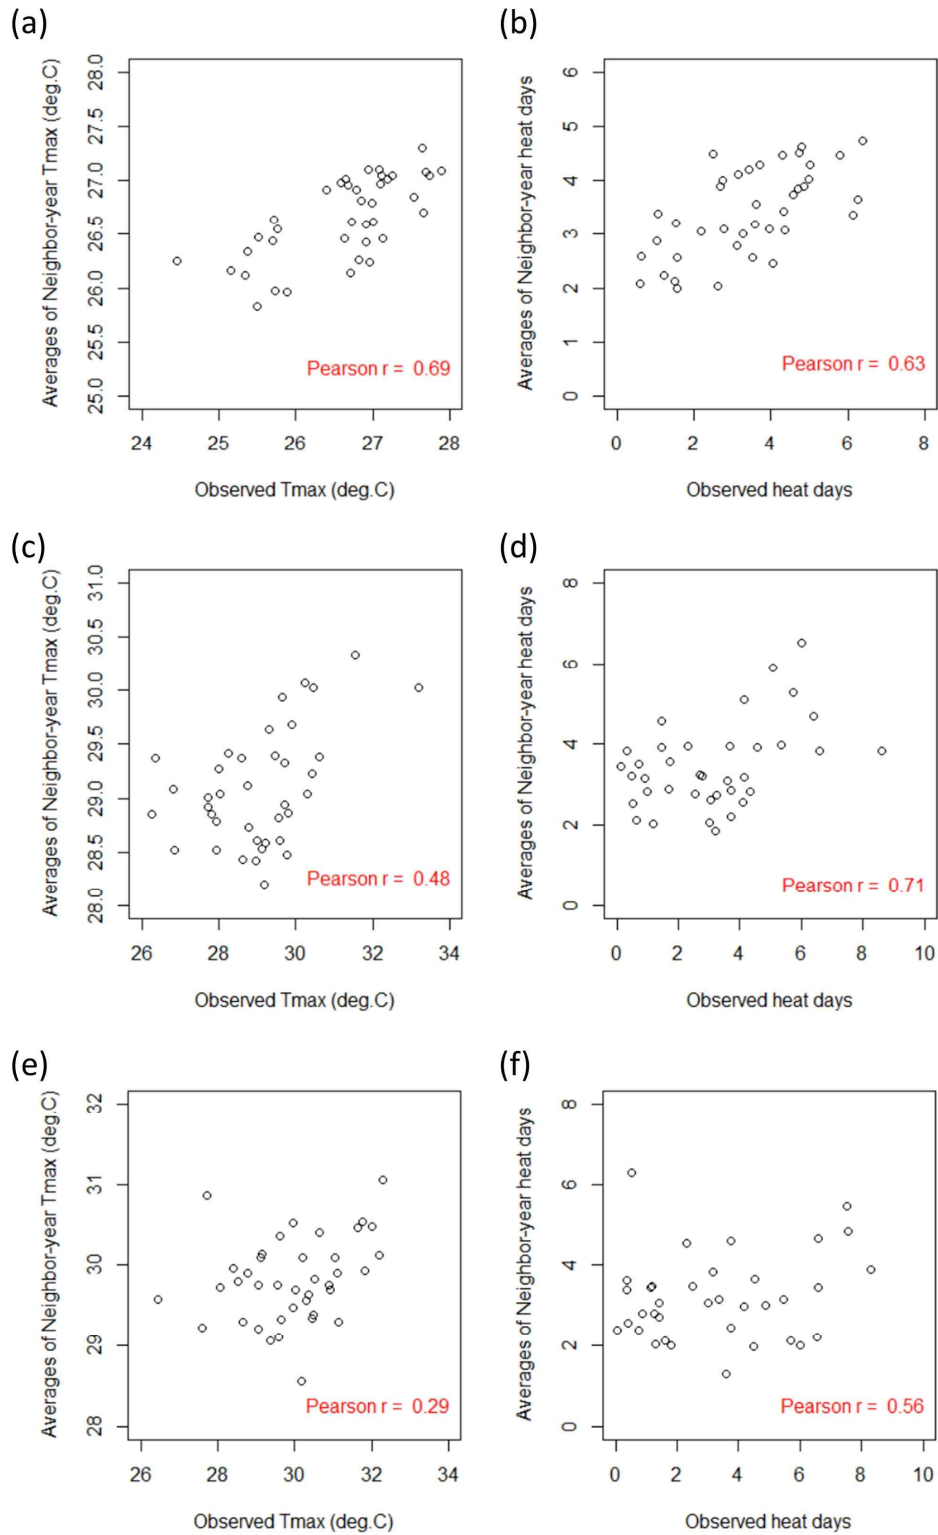


Figure 114. (a, c, and e) Comparisons between observed mean Tmax and weighted averages of neighbor-year Tmax for June, July, and August, and (b, d, and f) between observed heat days and averages of neighbor-year heat days predicted in May, respectively.

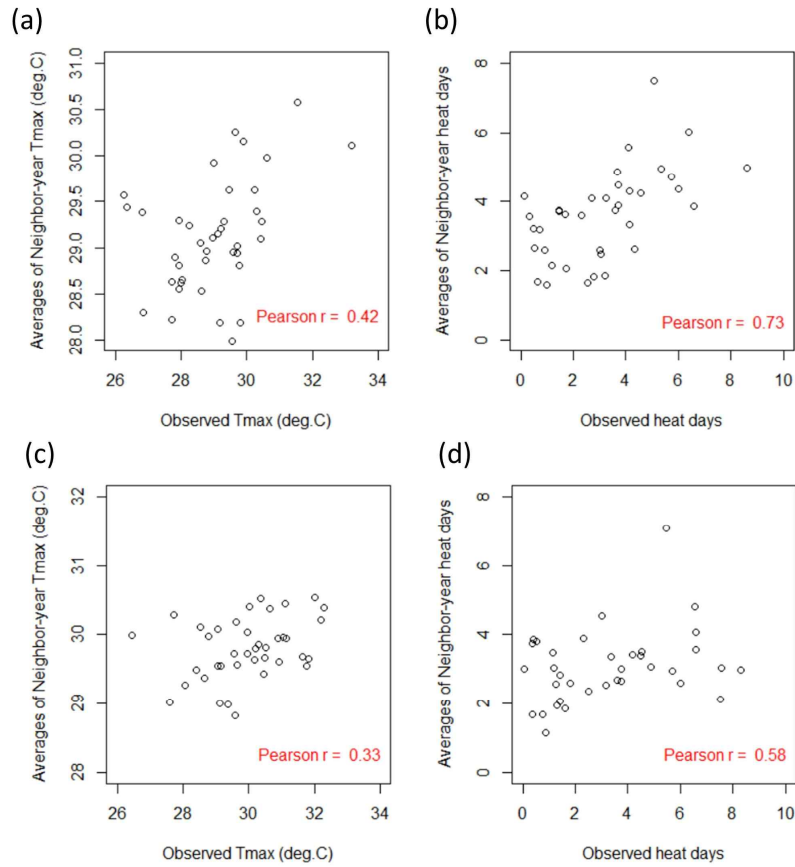


Figure 115. Comparisons between observed mean Tmax and weighted averages of neighbor-year Tmax for July and August (a and c) and between observed heat days and averages of neighbor-year heat days (b and d) predicted in June, respectively.

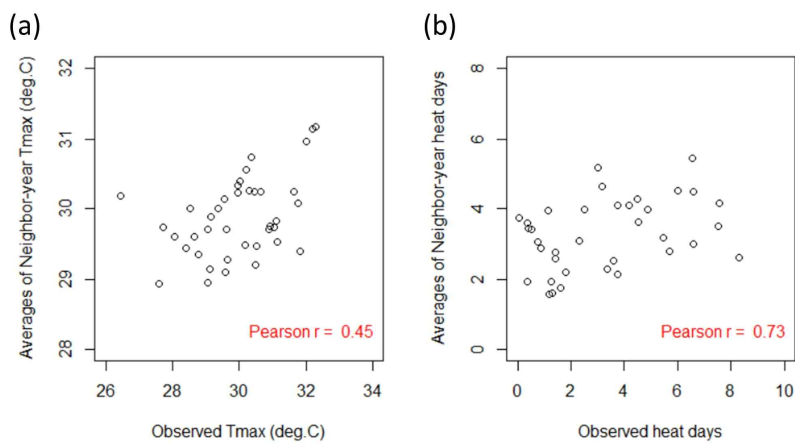



Figure 116. Comparisons between (a) observed mean Tmax and weighted averages of neighbor-year Tmax and between (b) observed heat days and averages of neighbor-year heat days (b and d) for August predicted in July, respectively.

(나) Markov-chain 기반 폭염확률 예측

선정된 유사해의 일 T_{max} 시계열을 Markov-chain weather bootstrapper에 입력하면 간단히 T_{max} 시계열의 변동범위를 확률적으로 예측할 수 있다. Figure 117는 1974년부터 2019년까지 P01과 P11의 경년변동을 나타낸다. P01과 P11은 각각 $T_{max} \leq T_{90}$ 에서 $T_{max} > T_{90}$ 인 상태로 바뀔 전이확률과 $T_{max} > T_{90}$ 에서 $T_{max} > T_{90}$ 로 지속될 전이확률을 의미한다. 따라서 폭염의 발생확률과 지속확률로 볼 수 있는데 2010년 이후로 둘 모두 상승 추세를 보이고 있다.

(a)



(b)




Figure 117. Interannual changes of (a) P01 and (b) P11 in Korea for 1974-2019.

특히 2018년과 1994년은 $T_{max} > T_{90}$ 지속확률 P11이 0.8이 넘을 정도로 매우 강력한 고온이 지속되었던 해이다. Markov chain의 전이확률은 이런 폭염의 시간적 지속특성을 무작위 샘플링에 반영할 수 있게 하는 장점이 있으며 지난 40년동안 평균적으로 P01은 0.05-0.2, P11은 0.2-0.4 이지만 비교적 자주 0.5 이상으로 상승하는 것을 알 수 있고 2010년 이후에는 상승추세가 매우 강한 상태이다. P11이 P01보다 크게 나타났는데 이는 폭염이 발생할 확률보다 발생했을 때 지속될 확률이 더 큰 것을 의미한다. P01이 통상 0.2 이하이기 때문에 폭염이 발생하지 않은 상태에서는 그 다음날도 발생하지 않을 확률이 0.8 정도이지만 한번 발생하게 되면 지속될 가능성이 높다는 의미로도 해석할 수 있다. T_{90} 을 폭염의 기준치로 사용했지만 평균 P01은 0.07정도로 0.1을 밑돌고 평균 P11 값은 0.27로 0.1을 훌쩍 넘어선다. 이는 폭염 시계열에는 분명한 자기상관성, 즉 지속특성이 있고 이를 고려해 확률적 위험을 평가해야 함을 의미하기도 한다.

Figure 118은 2020년 5월 시점에 1-4월 GPH 편차자료와 6월 폭염일수와의 상관성을 이용해 선정된 유사해 6월 T_{max} 자료로 생성한 2020년 6월 T_{max} 의 예상범위이다. 총 1000회의 무작위발생에 의해 얻어진 범위이고 1981-2010년 baseline 평균(붉은선)에 비해 Markov chain 모형으로 생성된 평균(파란선)이 비교적 높을 것으로 보인다. 2020년 6월에는 Baseline 평균보다 예측 평균이 높은 날이 더 많을 것으로 예상되었다. 예측 T_{max} 의 확률밀도함수는 baseline 확률밀도함수보다 우측으로 이동하게 되고 이에 따라 P_{AN} (above-normal probability)과 P_{NN} (near-normal probability)이 상대적으로 증가하고 P_{BN} (below-normal probability)는 감소하였다. 따라서 2020년 6월은 유사해를 기준으로 판단했을 때 다른 해보다 폭염위험이 클 것으로 예상된다.

Figure 118a는 Markov chain 모형으로 샘플링된 관측일의 기록을 모두 이용해 산정한 47개 지점의 6월 예상 T_{max} 와 폭염일수이고 Figure 118b는 100년 빈도에 대한 각각의 예상치이다. 한국은 편서풍의 영향을 받는 지역이고 남서풍을 타고 유입된 수분에 의해 여름철 강수가 발생하기 때문에 동남쪽 지역에 해당하는 경상북도의 온도가 예상된다. Figure 118a는 이러한 한국의 강수 공간분포를 잘 반영하고 있고 $T_{max} > 33^{\circ}\text{C}$ 길게 나타날 것으로 예상되는 지역 또한 동남부 지역이다. 예측된 T_{max} 확률밀도함수로 인해 6월임에도 불구하고 동남부지역과 강원도 서부지역에 비교적 높은 폭염위험이 있는 것으로 평가되었다. 6월임에도 불구하고 서부지역이나 해안 지역에서도 $T_{max} > 33^{\circ}\text{C}$ 인 경우가 수일정도는 발생할 가능성이 있고 100년에 한번 정도 발생하는 규모는 대략 작은 곳에서는 6일 이상, 큰 곳에서는 20일 이상이다.

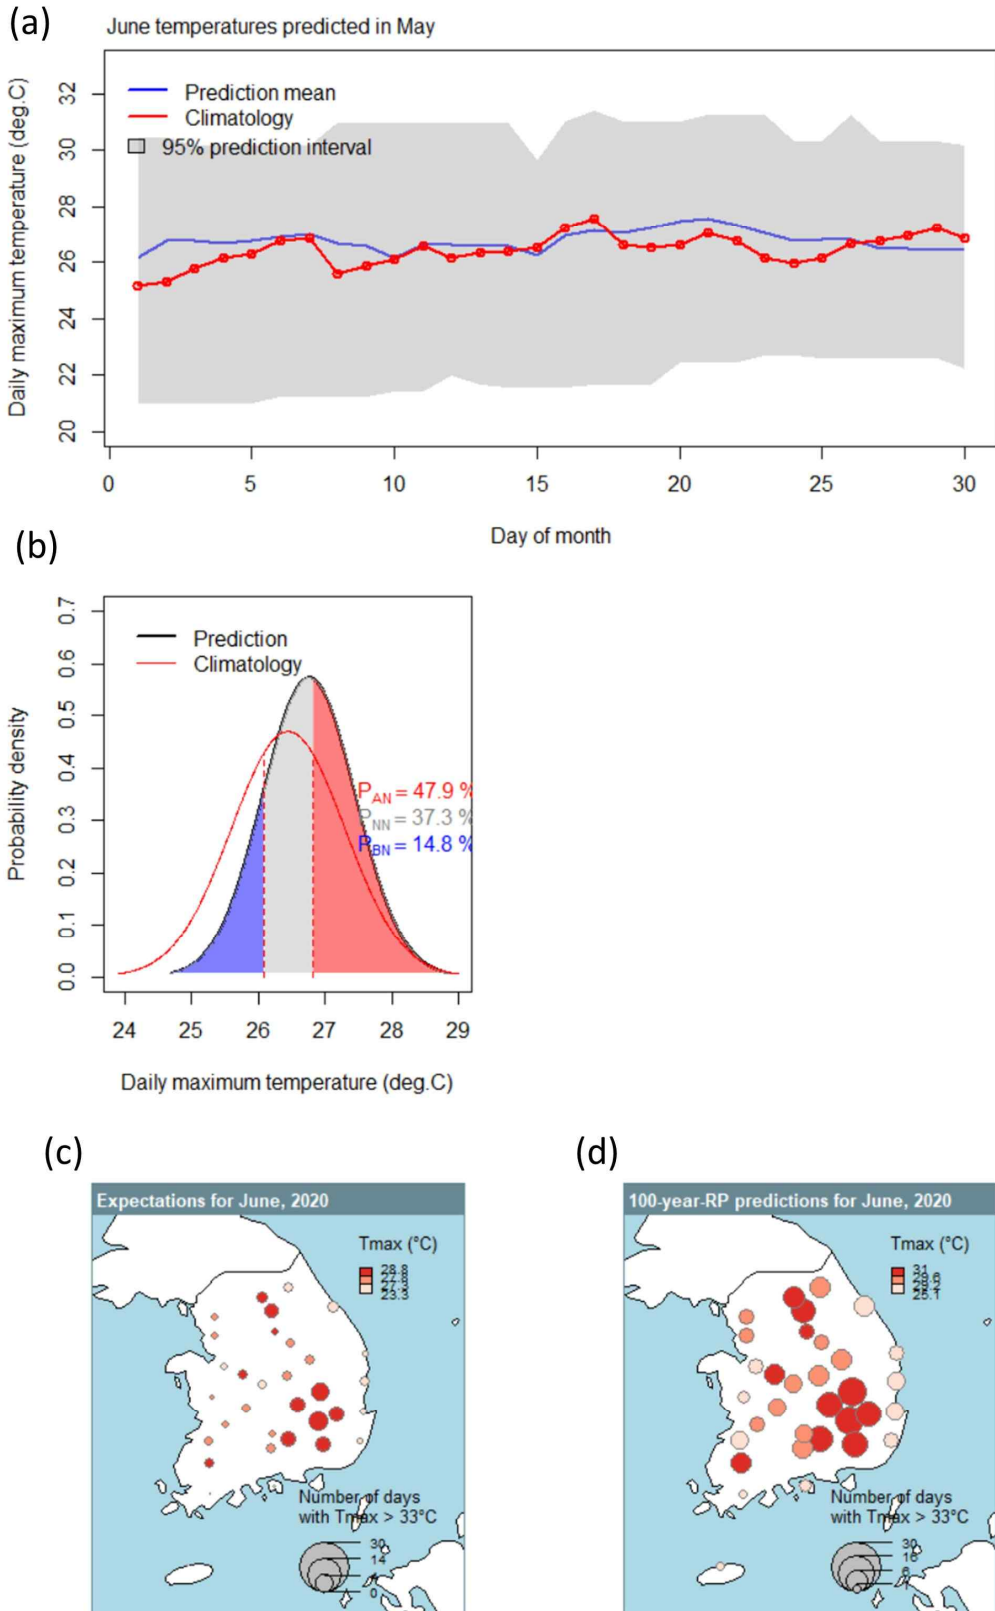


Figure 118. (a) The range of Tmax for June predicted in May, (b) the above-normal, near-normal, and below-normal probabilities of the mean Tmax, the spatial distributions of (c) mean Tmax and (d) 100-year-return-period mean Tmax , respectively.

5월에 예측된 7월 T_{max} 는 상당히 높았는데 (Figure 119a) Markov chain으로 생성된 T_{max} 평균값은 거의 모든 날이 baseline T_{max} 평균보다 높았고 이에 따라 예측 P_{BN} 값이 매우 낮은 것을 확인할 수 있다. 하지만 모형의 특성상 아주 극단적으로 높은 평균 T_{max} 를 예측되지는 않았고 $P_{NN}=48.3\%$ 로 평균적인 수준의 T_{max} 가 나타날 확률이 가장 높았다. 공간평균 T_{max} 가 33°C 를 넘는 날이 6월 예측에는 없을 것으로 예측되었지만 7월은 이런 현상이 5일까지 나타날 수 있는 것으로 예측되었다. 동남부 지역 외의 지점에서 T_{max} 가 가장 상당히 높을 것으로 예상되었고 100년 빈도 T_{max} 의 역시 유사한 공간분포를 나타냈다. Figure 119 결과는 7월 기온의 계절변동성, 공간변동성과 유사해의 경년변동성이 모두 고려된 결과라고 할 수 있다.

8월 평균 T_{max} 역시 평년보다 비교적 높을 것으로 예상되었는데 (Figure 120). 평균기온이 가장 높은 달이기 때문에 평균 T_{max} 가 33°C 를 넘는 날이 6, 7, 8월 중 당연히 가장 많을 것으로 예측되었다. $T_{max} > 33^{\circ}\text{C}$ 를 넘는 날이 연속으로 12일 까지 나타날 수 있고 특히 동남부지역에서는 15일 이상 나타날 가능성이 있는 것으로 분석되었다. 100년 빈도로 판단했을 때는 8월의 모든 날이 33°C 를 넘는 지역이 나타나기도 했는데 사실 이 예측이 현실화 될 가능성은 1/100로 상당히 낮다. T_{max} 가 평균보다 높을 것으로 예측되기는 했지만 8월 예측도 7월과 마찬가지로 평년 수준에 머무를 확률(P_{NN})이 가장 높았기 때문에 아주 높은 폭염위험이 예측되었다고 하기는 어렵다.

6월에 2-5월 GPH 편차자료를 이용해 다시 7월 T_{max} 를 예측했을 때 (Figure 121), P_{AN} 이 51%로 가장 높게 나타나 5월 예측보다 좀 더 큰 폭염위험이 예측되었고 $T_{max} > 33^{\circ}\text{C}$ 폭염일수도 최대 7일까지 나타날 수 있을 것으로 나타났다. 같은 방법으로 8월 T_{max} 예측했을 때 (Figure 122) P_{AN} 는 90% 이상으로 치솟았고 7, 8월 T_{max} 가 5월 예측보다 더 높을 것으로 예상되었다. 하지만 3-6월 GPH 편차자료를 이용해 다시 유사해를 구한 후 8월 T_{max} 를 예측했을 때는 P_{AN} 는 63% 정도로 감소하였다(Figure 123). 요약하면 2020년 1월에서 6월까지의 대기 GPH는 한국에 6, 7, 8월에 대해 모두 이상고온 위험이 비교적 높았던 과거패턴으로 변화했고 선정된 유사해 자료를 이용한 Markov chain 모형은 이를 반영한 결과를 생산했다고 할 수 있다.

유사해 기반 방법으로 2020년 6, 7, 8월 T_{max} 는 모두 평균이상으로 나타날 것으로 예상되었지만 실제로 6월을 제외하면 7월은 평년 기준보다 낮았고 8월은 평년 수준이었다. 1-6월 대기패턴은 고온이 많이 발생할 것처럼 변화하였고 실제로 많은 역학모형에 의한 계절예측(e.g. <https://iri.columbia.edu/our-expertise/climate/forecasts/seasonal-climate-forecasts/>)에서도 한국의 여름철 폭염을 비교적 높은 확률로 예측하였지만 모두 빗나갔다. 다만 역학모형은 동아시아의 강수가 상당히 많을 것으로 예측했는데 이 예측이 잘 들어맞았고 기온과 강수량이 역상관을 갖는 한국의 7월 기후특성과 일관되게 T_{max} 가 나타났다. 한 가지 변량만을 목적으로 하는 통계적 모형은 한국 여름철 기온의 변동성을 모두 설명하기에는 한계가 있는 것으로 보인다. 하지만 여전히 GPH와 기온간의 통계적 상관성은 상당히 유의하며 1회의 성능 평가만으로 모형의 성능을 완전히 판단하는 것은 성급할 수 있다. 유사해 자료를 뒤섞는 Markov chain 모형은 시공간적 gradient에 미래 예측이라기보다 과거자료에 완전히 의존한 폭염위험평가 기법으로 보는 것이 실무적으로는 적당하다.

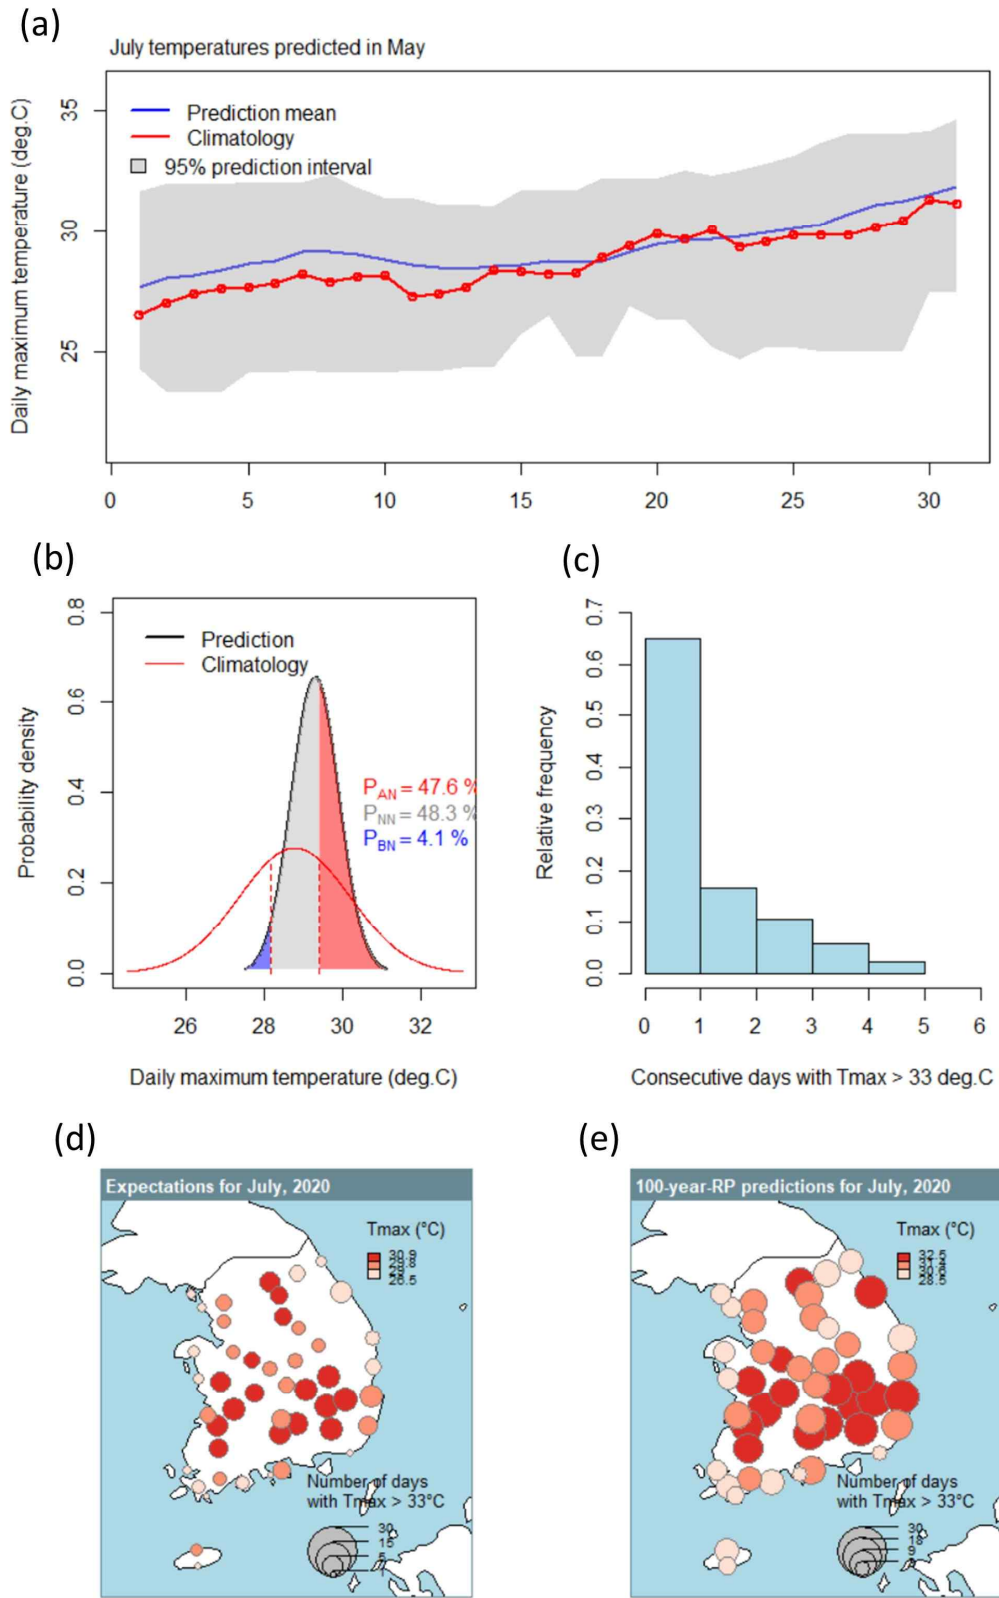


Figure 119. (a) The range of T_{max} for July predicted in May, (b) the above-normal, near-normal, and below-normal probabilities of the mean T_{max} , (c) histogram of consecutive days with $T_{max} > T_{90}$, (d) mean T_{max} and (e) 100-year-return-period mean T_{max} , respectively.

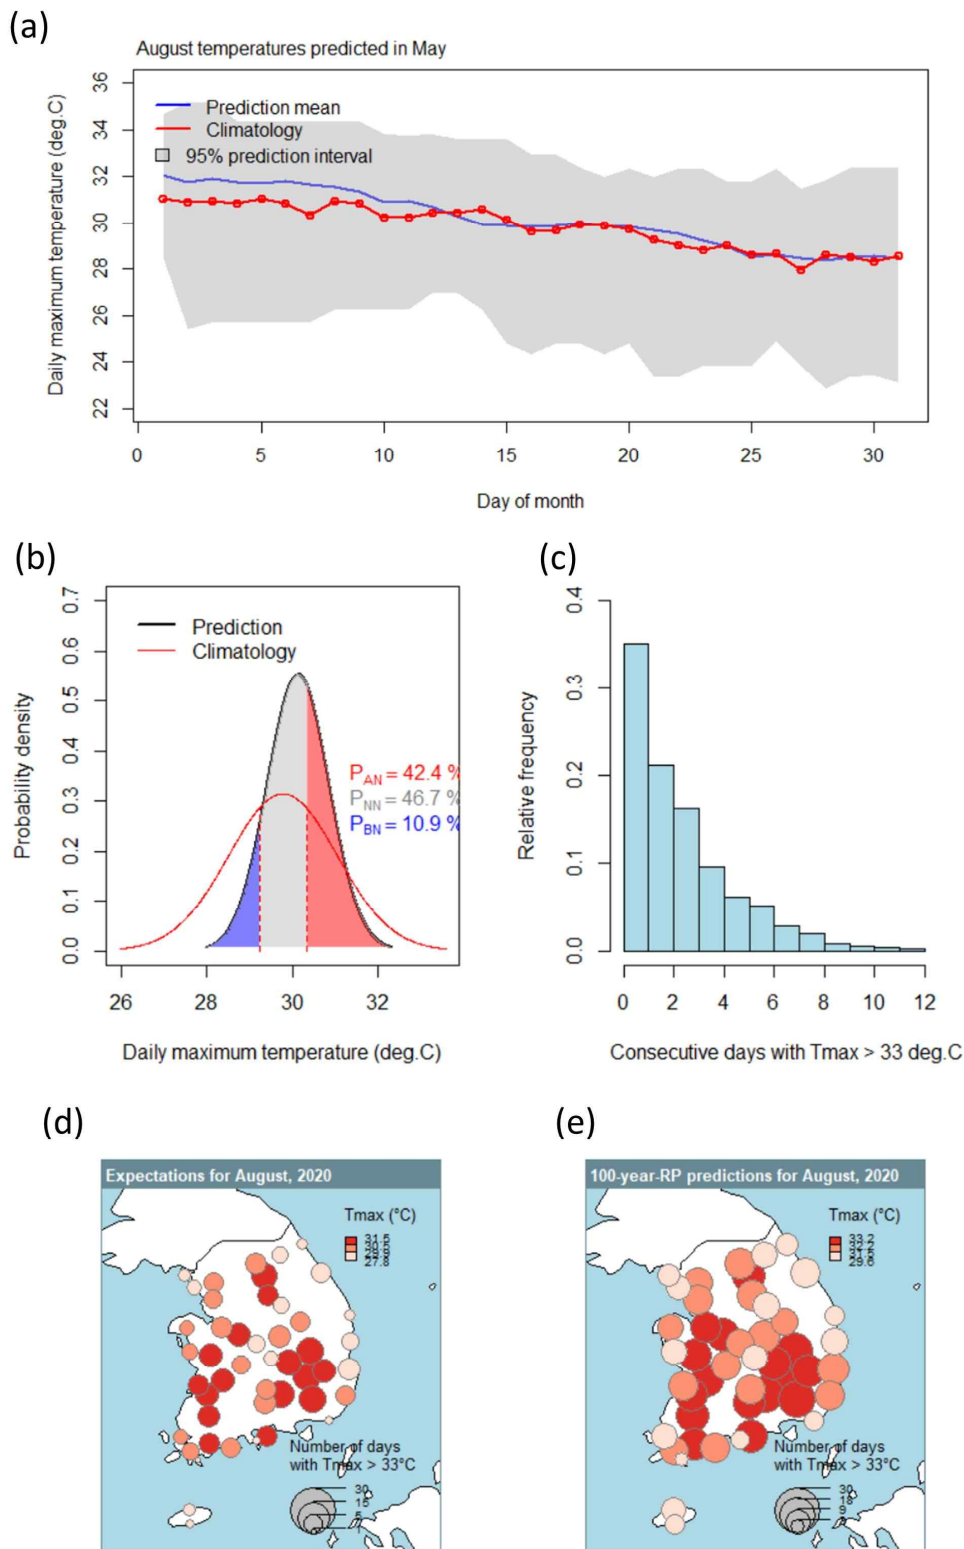


Figure 120. (a) The range of T_{max} for August predicted in May, (b) the above-normal, near-normal, and below-normal probabilities of the mean T_{max} , (c) histogram of consecutive days with $T_{max} > T_{90}$, (d) mean T_{max} and (e) 100-year-return-period mean T_{max} , respectively.

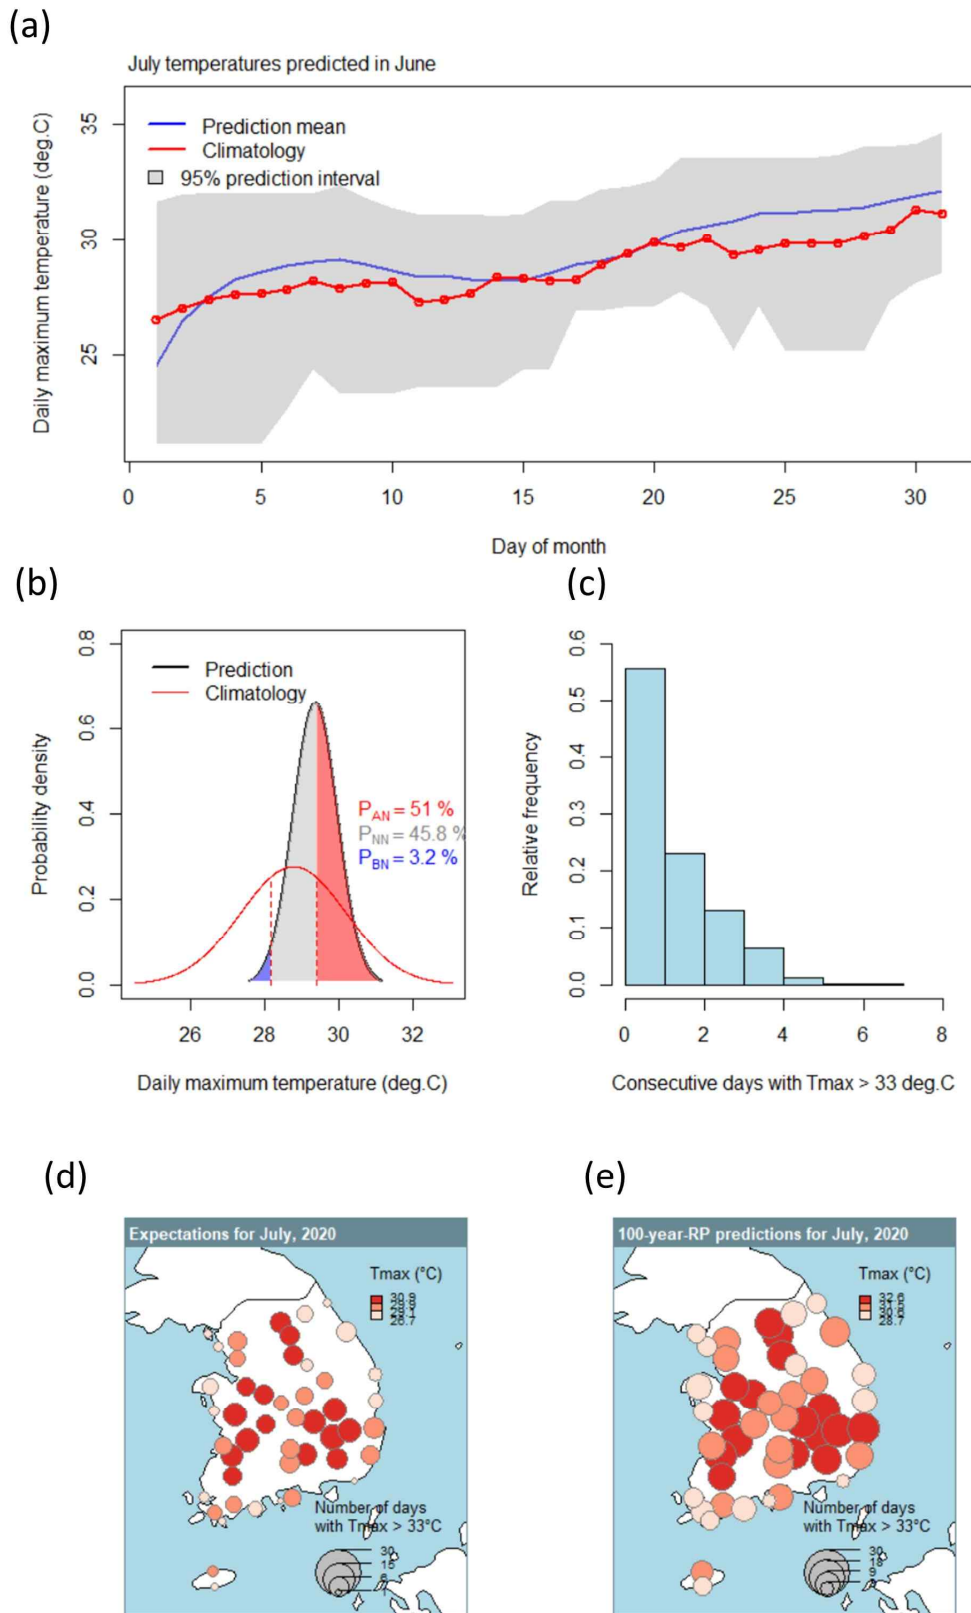


Figure 121. (a) The range of T_{max} for July predicted in June, (b) the above-normal, near-normal, and below-normal probabilities of the mean T_{max} , (c) probabilities of consecutive days with $T_{max} > T_{90}$, (d) mean T_{max} and (e) 100-year-return-period mean T_{max} , respectively.

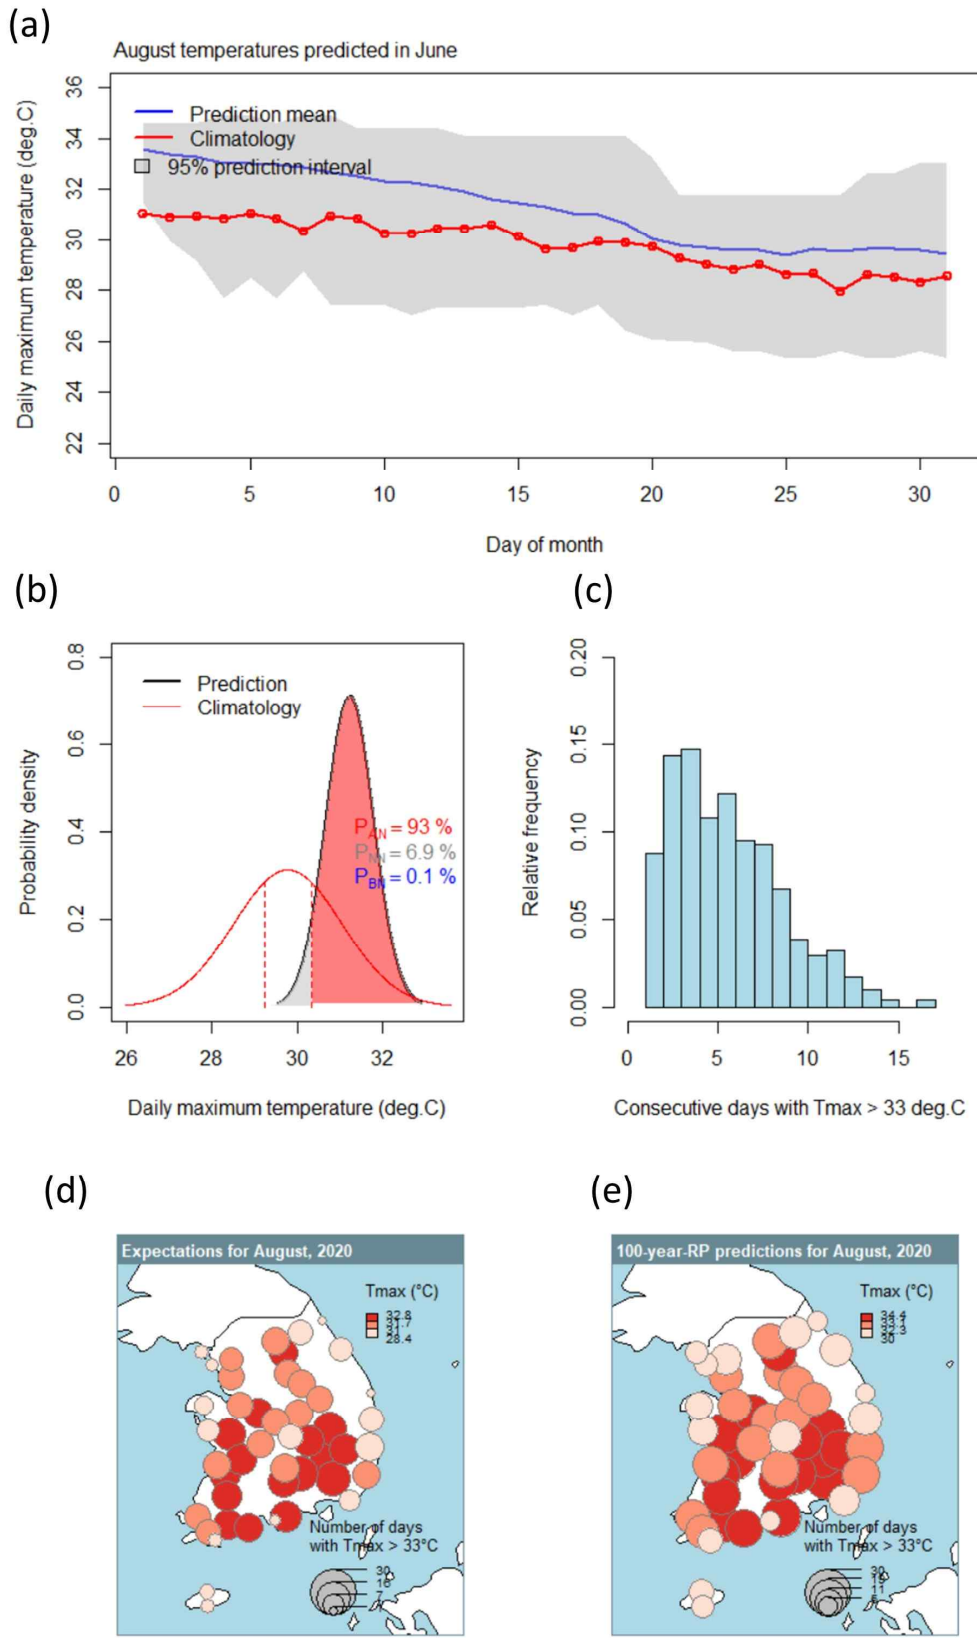


Figure 122. (a) The range of T_{max} for August predicted in June, (b) the above-normal, near-normal, and below-normal probabilities of the mean T_{max} , (c) histogram of consecutive days with $T_{max} > T_{90}$, (d) mean T_{max} and (e) 100-year-return-period mean T_{max} , respectively.

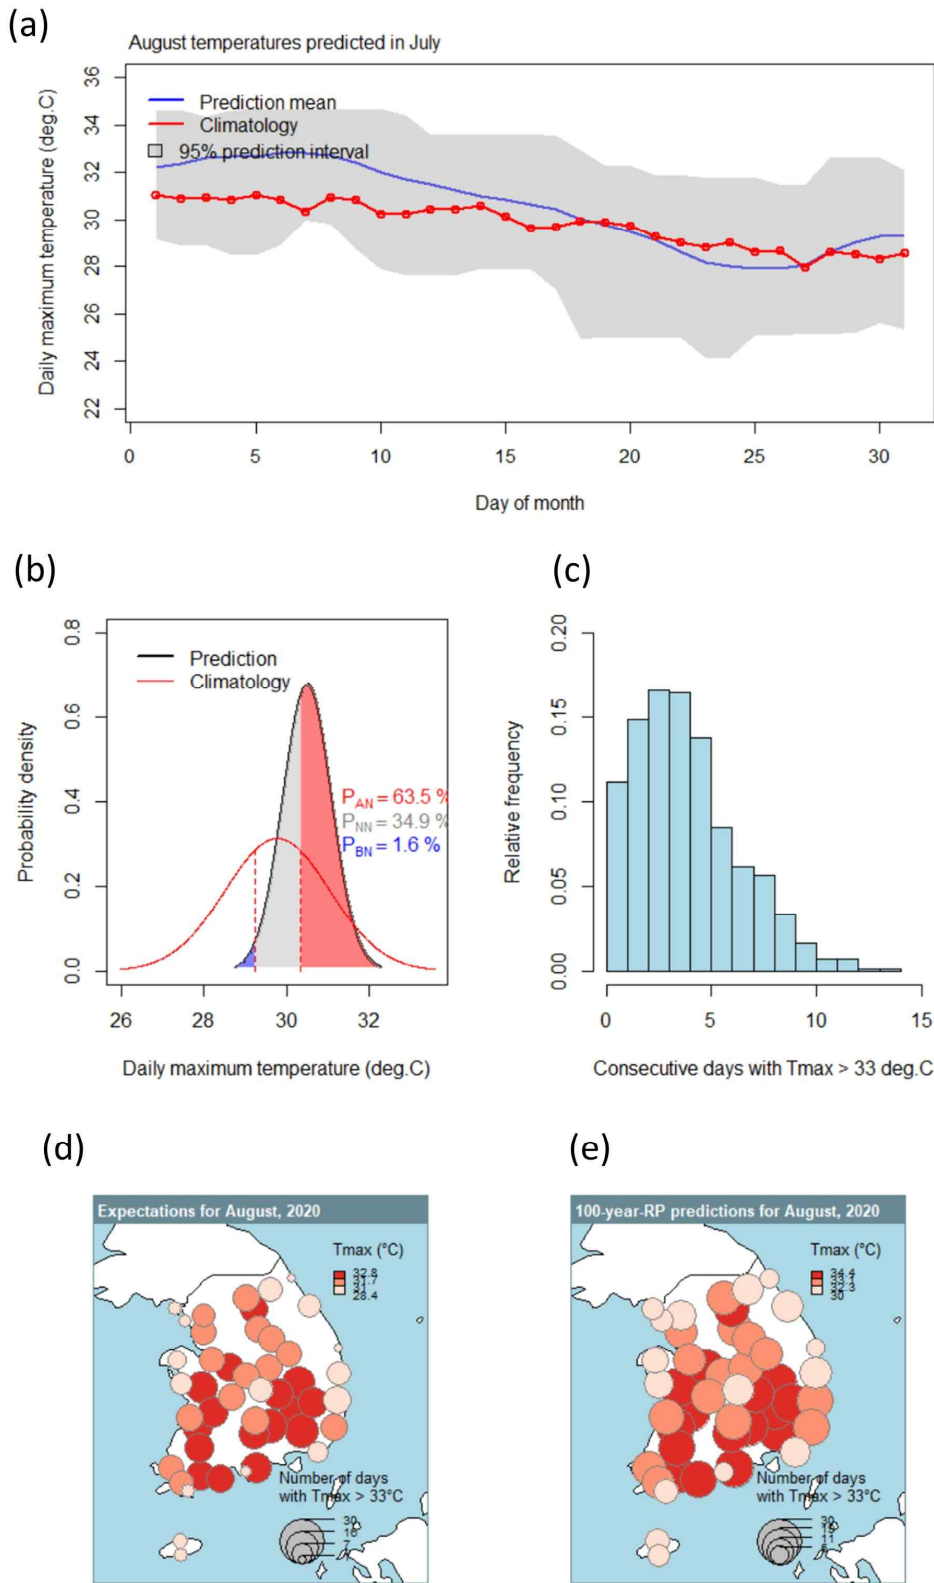


Figure 123. (a) The range of T_{max} for August predicted in July, (b) the above-normal, near-normal, and below-normal probabilities of the mean T_{max} , (c) histogram of consecutive days with $T_{max} > T_{90}$, (d) mean T_{max} and (e) 100-year-return-period mean T_{max} , respectively.

(2) 기계학습모델을 이용한 혹서기 이상기후 3개월 확률전망정보 생산

(가) 폭서기 이상기후 발생과 주요 기후인자의 통계적 상관성

① 전국 및 지역별 폭서기 이상기후지수 통계 분석

전국 및 지역별 이상기후 발생의 차이를 살펴보기 위해 평균, 분산, 표준편차 등의 기초통계분석을 실시하고 box-plot과 시계열 그래프를 작성하여 비교하였다(Figures 124, 125). 연간 지수의 경우 SU의 경우 강원영동과 제주도에서 값이 낮으며 TR은 제주도의 값이 높게 나타났으며 TXm은 강원영동이 높고 TNm은 제주도가 높게 나타났다. TX90p, TN90p의 경우 백분율 기준을 사용하여 지역차가 크게 드러나지 않았다. 월별 지수의 경우 6월은 SU, TXm의 경우 강원영동과 제주도가 낮게, 7, 8월은 SU, TXm에서 강원영동만 조금 높게 나타나고 6, 7, 8월 모두 TR, TNm은 제주도가 높게 나타났다.




Figure 124. Box-plots for South Korea and subregions.

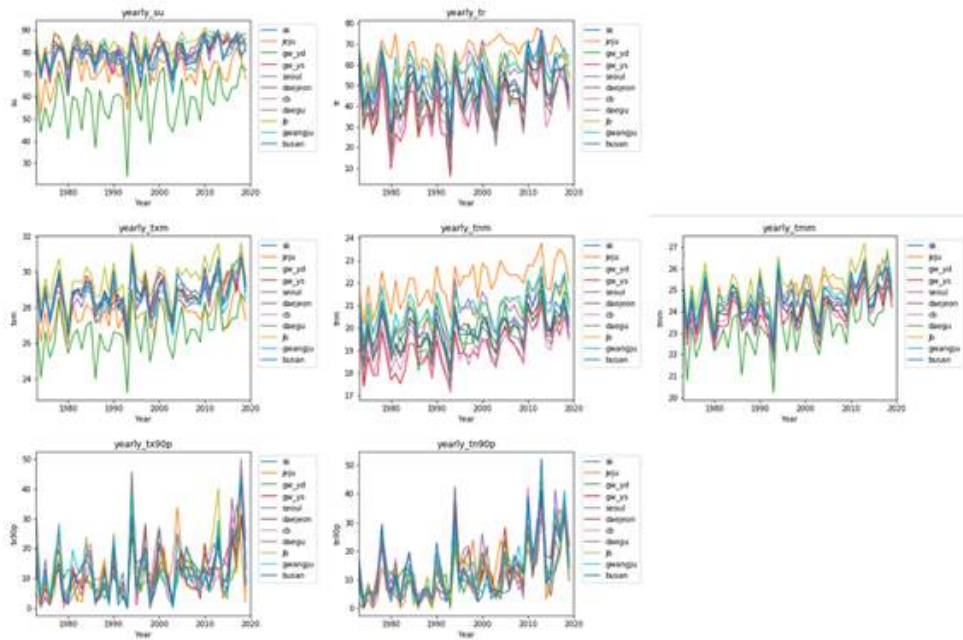


Figure 125. Time-series graphs for South Korea and subregions.

지역별 차이가 통계적으로 유의한지 검증하기 위해 우선 각 시계열의 정규성을 Kolmogorov-Smirnov, Shapiro-Wilk, Anderson-Darling 테스트를 이용하여 검정하고 히스토그램과 QQ-plot을 작성하여 확인하였다(Figures 126, 127). 연간 지수를 살펴보면 대부분 K-S 테스트에서는 정규분포 귀무가설을 기각하였으며 Shapiro-Wilk나 Anderson-Darling 테스트는 주로 TXm, TNm, TMm에서는 기각하지 않았다. 월별 지수를 살펴보면 6, 7, 8월의 경우 K-S 테스트는 대부분 귀무가설을 기각하였으며 Shapiro-Wilk나 Anderson-Darling 테스트는 월과 지수에 따라 다르게 나타났다.

지역별 차이의 통계적 검정은 정규분포의 경우 Paired two sample t-test로 수행하였다. 정규분포가 아니더라도 t-test의 강건함(robustness) 덕분에 t-test를 활용하기도 한다. 정규분포가 아닌 경우 Wilcoxon Signed Rank test를 수행한다. 검정 결과 연간 지수의 경우 전국을 다른 지역과 비교해보면, TX90p, TN90p에서는 대부분 차이가 없는 것으로 나타났지만(귀무가설 기각하지 못함) 대부분의 다른 경우 차이가 관찰되었다(귀무가설 기각).

지역별, 지수별로 비매개변수 추세분석을 Mann-Kendall 테스트를 이용하여 수행하였다. 검정 결과 연간 지수의 경우 전국을 보면 대부분의 지수에서 증가하는 추세가 관찰되며 TR과 TN90p는 추세가 없는 것으로 나타났으나 p-value 값을 살펴보면 경계에 있다(각각 0.056, 0.060). 전국에 대해 월별 지수를 보면 6월은 6개 지수 모두 증가 추세가 나타났으며 7, 8월은 TNm만 증가하는 것으로 나타났다.




Figure 126. Histograms for South Korea and subregions.




Figure 127. QQ-plots for South Korea and subregions.

최종적으로 기계학습을 이용하여 예측전망을 생산할 월별 지수로 정규분포에 가까운 TXm, TMm, TNm을 선정하였다. 기상청에서 활용하는 방법과 같이, 지점별로 이상기후지수를 먼저 산정하고 이 값을 지역별로 평균하며, 지역 평균을 구하는 경우 티센망을 이용하지 않고 단순 평균하였다.

② 흑서기 이상기후 발생과 주요 기후인자의 상관성 분석

장기예보 가이드스 III(2018)에 수록된 흑서기 기온 및 강수 예측인자와 이상기후지수의 상관성을 분석하였다. 해수면온도의 경우 북대서양 지역의 지역 차, 북태평양, 북인도양, 열대서태평양, 필리핀동쪽해, 호주북쪽, 열대인도양, 북대서양 등 많은 지역에서 이상기후지수와 통계적으로 유의한 상관관계를 보이는데 월과 지수에 따라 약간씩 상이하게 나타났다(Table 15, Figure 128). 예를 들어, 6월 TMm과 1월 열대서태평양의 상관계수는 0.57로 매우 높다($p < 0.001$).

Table 15. Sea Surface Temperature predictors of the long-range forecast guidance III (2018).

Target Variables	Target Period	Time of Interest	Area of Interest	latS	latN	lonL	lonR	Static
Prec	Changma	April	North Atlantic	55	60	320	345	Anomaly Difference
			North Atlantic	30	45	280	320	
		(April 11 ~ April 30) - (March 22 ~ April 10)	North Pacific	20	35	160	210	Temporal Anomaly Difference
		April	Tropical Mid Pacific	-15	10	200	220	Anomalies
		April	North Indian	11	22	67	85	Anomalies
		March	Bering	55	65	175	195	Anomalies
		May	Northwest Pacific	0	20	110	140	Anomalies
Tair	June	January	Tropical West Pacific	-10	15	145	180	Anomalies
	July	April	East Indian ~ East of Philippines	-40	20	90	140	Anomalies
			East of Philippines	0	20	120	140	
	August	February	North of Australia	-20	0	110	145	Anomalies
	July ~ August Mean	April	Tropical Indian	-10	0	90	105	Anomalies
April		North Atlantic	55	65	320	360	Anomalies	

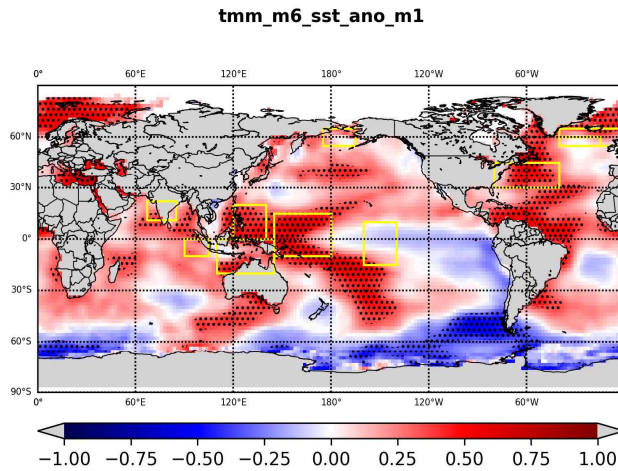


Figure 128. Correlation map between June Tmm anomaly and January SST anomaly.

눈덮임의 경우 6월과 8월의 이상기후지수는 아래 표의 거의 모든 지역 및 지역 차와 통계적으로 유의한 상관관계를 보이는데, 7월은 중국 북동부와 만주) 지역과만 유의한 관계를 보였다(Table 16, Figure 129). 예를 들어 8월 Tmm과 4월 동아시아-서아시아 지역차의 상관계수는 0.55로 높게 나타났다($p < 0.001$).

Table 16. Snow cover predictors of the long-range forecast guidance III (2018).

Target variable	Target Period	Time of Interest	Area of Interest	latS	latN	lonL	lonR	Static
Pre	Changma	March ~ May	Eurasia	50	60	20	50	Anomaly
			Eurasia	50	60	100	130	Difference
Tair	June	March	Northeast Chima	45	50	103	133	Anomalies
	August	April	East Asia	48	60	105	135	Anomaly
			West Asia	45	55	50	70	Difference
	July ~ August Mean	April	Manchuria	40	50	120	140	Anomalies

tmm_m8_snow_ano_m4

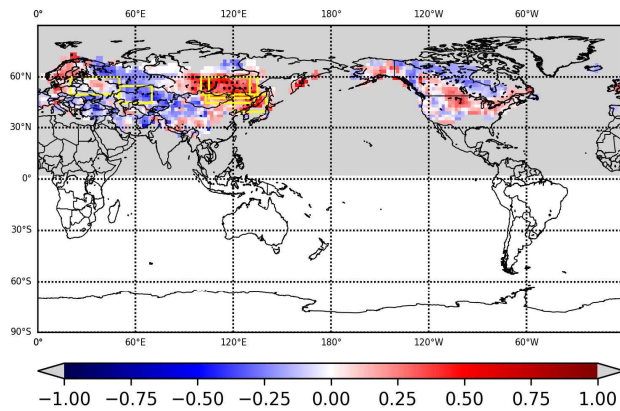


Figure 129. Correlation map between August TmM anomaly and April snow cover anomaly.

강수의 경우 6월 TMm은 전년도 12월, TNm은 3월의 호주 북쪽 강수 아노말리와 약한 양의 상관관계를 보이며 8월의 경우 TNm이 2월 호주 부근 강수 아노말리와 약한 양의 상관관계 보인다. 8월 TXm, TMm, TNm 모두 호주 북쪽과는 강한 상관관계를 보이는데, 3월 강수 아노말리와는 강한 양의 상관관계를, 2월 강수 아노말리와는 약한 음의 상관관계를 보인다(Table 17, Figure 130).

Table 17. Precipitation predictors of the long-range forecast guidance III (2018).

Target Variable	Target Period	Time of Interest	Area of Interest	latS	latN	lonL	lonR	Static
Tair	June	April	Near Australia	20	35	185	200	Anomaly Difference
			Near Australia	25	35	120	180	
	August	March	Near Australia	-20	-5	110	180	Anomalies

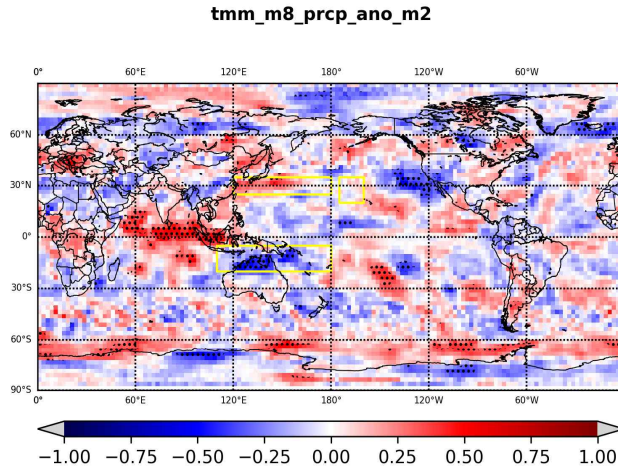


Figure 130. Correlation map between August TmM anomaly and February precipitation anomaly.

850hPa 지위고도의 경우 중위도(+) 고위도(-)의 쌍극자 패턴을 살펴보도록 되어 있으므로 대서양 지역을 중위도와 고위도 지역으로 나누어 각각의 지역과 지역 차와 이상기후지수의 상관성을 분석하였다(Table 18, Figure 131). 7월의 TXm, TMm은 고위도 지역 4월의 지위고도 편차와 음의 상관관계를 가지며 4월 및 2월의 중위도 지역 지위고도 편차와 양의 상관관계를 가지므로 4월 지역 차와 음의 상관관계를 가진다. 7월의 TNm은 중위도 지역과의 양의 상관관계가 지역 차와의 음의 상관관계를 가진다. 8월 TMm, TNm도 850hPa 지위고도와 유의한 상관관계가 있다. 예를 들어, 7월 TXm과 4월 대서양 지역차는 상관계수 -0.50로 높은 음의 상관관계가 있다($p = 0.0013$).

Table 18. 850hPa Geopotential height predictors of the long-range forecast guidance III (2018).

Target Variable	Target Period	Time of Interest	Area of Interest	latS	latN	lonL	lonR	Static
Tair	July	April	Atlantic	20	65	255	300	Anomalies
				50	65	255	300	Anomaly
				20	45	255	300	Difference

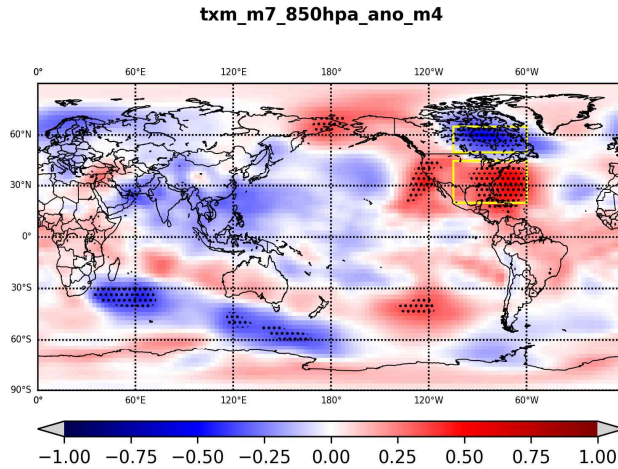


Figure 131. Correlation map between July TXm anomaly and 850hPa geopotential height anomaly.

500hPa 지위고도의 경우 중위도(+) 고위도(-)의 쌍극자 패턴을 살펴보도록 되어 있으므로 유라시아 지역을 중위도와 고위도 지역으로 나누어 각각의 지역과 지역 차와 이상기후지수의 상관성을 분석하였다(Table 19, Figure 132). 6, 7, 8월 TXm, TMm, TNm이 전체적으로 고위도, 중위도 지역 500hpa 지위고도 편차와 상관관계를 보이는데 특히 7월 TMm, TNm이 상관관계가 강하다. 예를 들어 7월 TNm과 3월 유라시아 지역차는 상관계수 -0.59의 높은 음의 상관관계를 가진다($p < 0.0001$).

Table 19. 500hPa geopotential height predictors of the long-range forecast guidance III (2018).

Target Variable	Target Period	Time of Interest	Are of Interest	latS	latN	lonL	lonR	Static
Tair	July	March	Eurasia	20	70	0	90	Anomalies
				50	75	0	60	Anomaly
				20	45	0	90	Difference

tnm_m7_500hpa_ano_m3

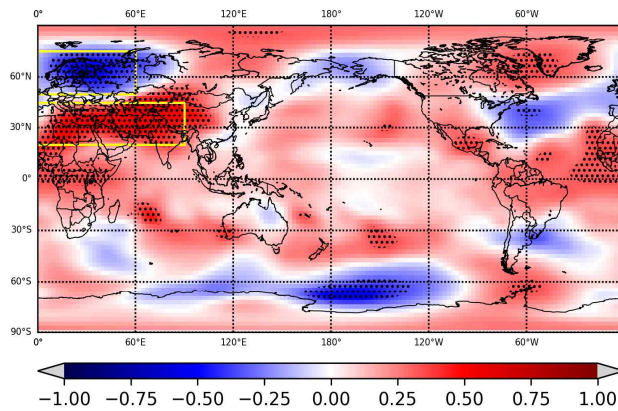


Figure 132. Correlation map between July TNm anomaly and March 500hPa geopotential height anomaly.

장기예보 가이드언스의 예측인자와 선행감시시점을 이상기후지수와의 상관관계를 이용하여 선정된 모델(GD_MOD)을 위해 각 월별 지수에 대해 통계적으로 유의한 상관관계를 보이는 예측인자와 시기를 선정하였다. 완전히 같은 지역에서는 가장 높은 상관관계를 보이는 한 시기만 선정하였다. NOAA에서 제공하는 대기해양 예측인자도 장기예보 가이드언스 예측인자와 같은 방식으로 선정하였다.

③ 흑서기 이상기후 발생과 지역별 기후 및 공간정보의 상관성 분석

토양수분의 경우 전국 평균한 6월 TNm은 3월의 토양수분과 상관계수 0.36의 약한 양의 상관관계를 가진다($p = 0.02$). 식생지수의 경우 전국 평균한 6월 TXm은 12월에서 3월까지의 식생지수와 양의 상관관계를 가지는데 3월과의 상관관계가 가장 강하게 나타났다. 전국 평균한 6월 TMm, TNm은 11월에서 3월까지의 식생지수와 양의 상관관계를 가지는데 TMm은 3월 및 12월, TNm은 12월과 상관관계가 가장 강하였다. 7월에도 TXm, TMm, TNm이 11월의 식생지수와 양의 상관관계를 보이며 8월에는 TNm이 겨울철 식생지수와 양의 상관관계를 나타냈다.

전체 지역을 모두 포함한 다중회귀분석 결과 목표변수가 각 지역의 지수 편차일 때 입력 변수로 전국 지수편차만을 사용한 단순회귀분석보다 전국 평균한 지수의 편차, 토양수분 편차의 차(지역 편차 - 전국 편차), 식생지수 편차의 차(지역 편차 - 전국 편차)와 함께 강수 및 온도의 기후 값의 편차의 차, 위도, 경도, 고도, 경사, 향의 편차의 차를 모두 포함한 다중회귀분석의 경우가 약간 높은 상관계수 값을 생산하므로 토양수분, 식생지수의 정보가 지역별 이상기후발생의 차이를 설명하는데 약간 기여했다고 볼 수 있다. 전반적으로 70~90% 설명력을 가지는 것으로 나타났다. 지역별 다중회귀분석은 목표변수로 해당 지역의 지수 편차, 입력변수로 전국 평균한 지수의 편차, 토양수분 편차의 차(지역 편차 - 전국 편차), 식생지수 편차의 차(지역 편차 - 전국 편차)

역 편차 - 전국 편차)를 설정하여 수행하였는데 강원영동, 제주, 서울이 특히 모델 결과가 낮아 전체적으로 10~99%의 지역 편차 설명력을 가지는 것으로 나타났다.

지역에 따라 공간적인 요인 중 특히 토양수분 등으로 지역적 이상기후 발생의 차이를 설명할 수 있었다. 하지만 이상기후 발생에 나타나는 기후인자의 영향이 전국의 평균적인 영향과 가깝고 여기에서 살펴본 공간요인으로는 지역의 발생 차이를 상세히 설명할 수 없는 지역이 있으므로 본 연구에서 이상기후지수 확률전망 모델의 구축에 지역별 기후 및 공간정보를 활용하지 않고 전국 평균 및 지역별로 확률전망 모델을 각각 구축하였다. 추후 추가적인 요인을 발굴하여 지역별 모델을 구축하는 것이 바람직하다.

(나) 가우시안 프로세스를 이용한 전국 및 지역별 혹서기 이상기후지수 3개월 전망정보 생산

① 전국 혹서기 이상기후지수 3개월 확률전망정보 생산

GD, GD_MOD, CL, CL_PC의 모델에 대해 6, 7, 8월 이상기후지수 3개월 확률전망정보를 생산하고 결과 및 성능을 비교하였다. 군집분석을 통해 예측인자를 도출 및 활용한 경우 혹서기 이상기후지수 예측 성능이 향상되었음을 알 수 있다(Figures 133~136). 특히 2020년 6, 7, 8월의 확률예측 결과를 보면 군집분석을 활용한 CL의 경우 특히 7월 예측이 개선되었다(Figures 137, 138).




Figure 133. Heidke Skill Score (HSS).




Figure 134. Total Accuracy.




Figure 135. Mean Square Skill Score (MSSS).




Figure 136. Area Under the ROC Curve.

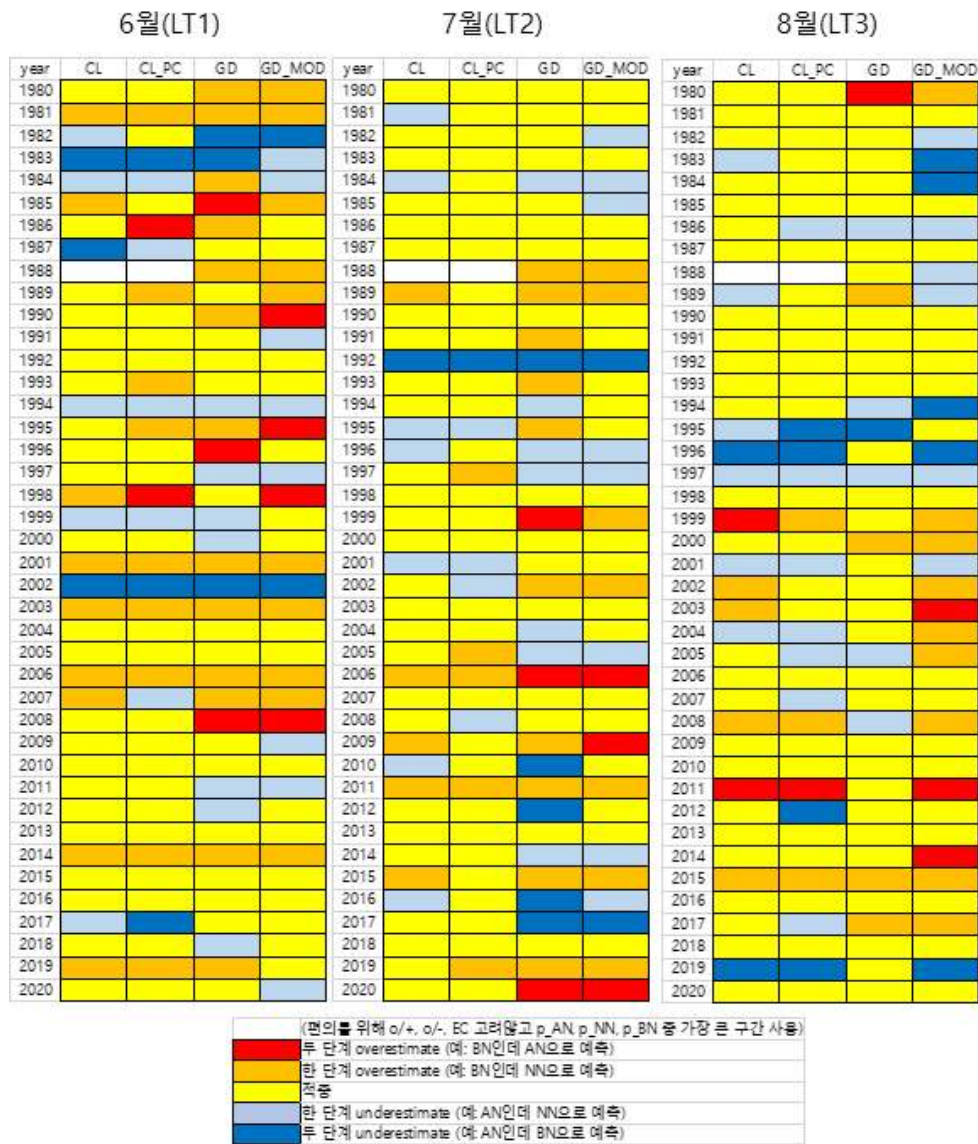
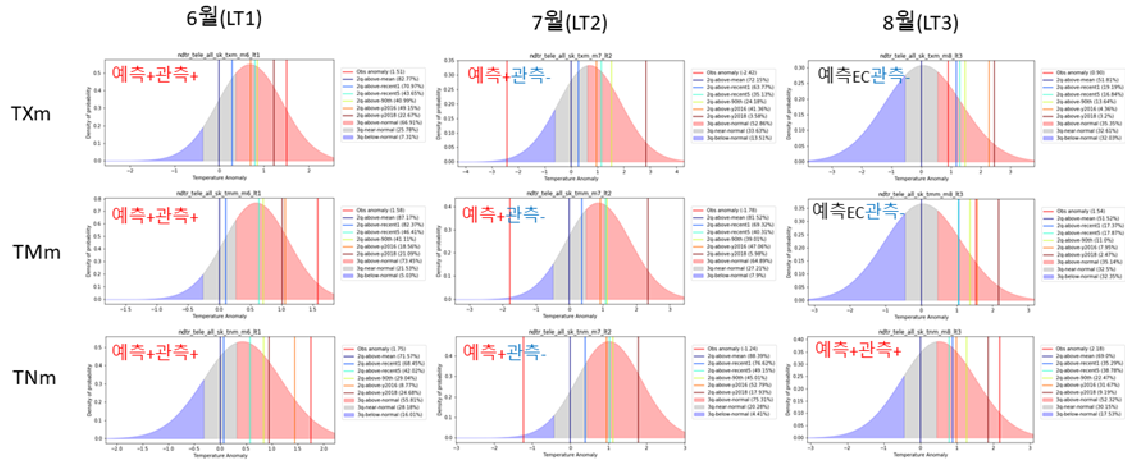


Figure 137. Comparisons of cross year validation forecast results during 1980-2020.

2020년 혹서기 이상기후 확률예측(GD모델)



2020년 혹서기 이상기후 확률예측(CL모델)

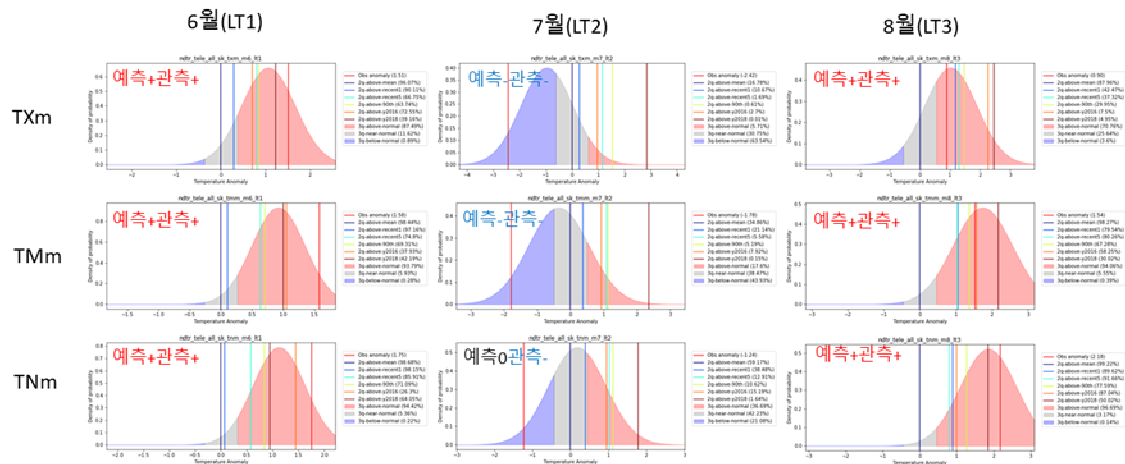


Figure 138. Comparisons of probabilistic forecast outputs between GD (upper) and CL (lower) in 2020.

② 지역별 혹서기 이상기후지수 3개월 확률전망정보 생산

앞서 가장 우수한 결과를 보인 CL 모델을 이용하여 전국 뿐 아니라 북한을 제외한 10개 지역에 대해 군집분석을 이용한 기계학습모델을 구축하고 지역별 혹서기 이상기후지수 전망정보를 생산하였으며 지역별 성능을 살펴보았다. Heidke Skill Score의 경우 강원영동의 6월 TXm 예측의 경우 $HSS = 0.23$ 으로 비교적 낮았으며 부산경남의 7월 TXm 예측의 경우 0.70 으로 가장 높은 성능을 보였다(Figure 139).



Figure 139. Heidke Skill Scores of South Korea as well as ten regions for Tm (top), TNm (middle), and TXm (bottom).

Mean Squared Skill Score의 경우 광주전남의 6월 TXm 예측의 경우 MSSS = 0.23으로 가장 낮았으며 부산경남의 6월 TNm 예측과 강원영서의 8월 TNm 예측의 경우가 0.8로 성능이 가장 우수하였다(Figure 140).




Figure 140. Mean Squared Skill Scores of South Korea as well as ten regions for Tm (top), TNm (middle), and TXm (bottom).

Area Under the ROC Curve의 경우 대구경북과 부산경남의 7월 TNm 예측 시 $AUC = 0.76$ 으로 가장 낮았으며 강원영서의 8월 TNm 예측 시 0.94로 가장 우수한 성능을 보였다(Figure 141).




Figure 141. Area Under the ROC Curve of South Korea as well as ten regions for TMm (top), TNm (middle), and TXm (bottom).

Total Accuracy의 경우 강원영동의 6월 TXm 예측의 경우가 0.51로 가장 낮으며 부산경남의 6월 TNm 예측과 7월 TXm 예측이 0.8로 가장 높았다(Figure 142).




Figure 142. Total Accuracy of South Korea as well as ten regions for Tm (top), TNm (middle), and TXm (bottom).

확률예측 기댓값의 관측과의 상관계수의 경우 광주전남의 6월 TXm 예측의 경우가 상관계수 0.51로 가장 낮고 강원영서의 8월 TNm 예측과 부산경남의 6월 TNm 예측의 경우가 상관계수 0.9로 가장 높은 값을 보였다(Figure 143).




Figure 143. Correlation coefficients between expected values of probabilistic forecasts and observations of South Korea as well as ten regions for Tm (top), TNm (middle), and TXm (bottom).

확률예측 기댓값의 관측과의 평균절대오차의 경우 강원영동의 7월 TXm 예측의 경우 평균절대오차가 1.09도로 가장 크며 전북의 6월 Tm 예측의 경우가 0.26도로 가장 작았다(Figure

144).



Figure 144. Mean Absolute Error between expected values of probabilistic forecasts and observations of South Korea as well as ten regions for Tm (top), TNm (middle), and TXm (bottom).

(다) 혹서기 이상기후지수 3개월 확률전망정보 표현방식 개발

① BMA (Bayesian Model Averaging)을 이용한 전망정보 결합

Expectation-Maximization(EM) 알고리즘을 이용하여 각 확률분포의 가중치를 산정하고 BMA를 적용하여 장기에보 가이드스 기반의 기계학습모델(2개)과 군집분석 기반의 기계학습모델(2개)인 GD, GD_MOD, CL, CL_PC의 전망정보를 결합하였다. 우리나라 혹서기 이상기후지수 TXm, TMm, TNm에 대해 결합된 BMA와 개별모델의 예측성능을 비교하였다. 결합된 BMA 모델이 모든 개별모델과 비교하여 가장 우수한 성능을 보이는 것은 아니지만 일관적으로 비교적 우수한 성능을 보임을 확인하였다(Figures 145-150).




Figure 145. Comparisons of cross year validation forecast results between BMA and various models during 1980-2020.




Figure 146. Heidke Skill Score (HSS).




Figure 147. Total Accuracy.




Figure 148. Mean Square Skill Score (MSSS).




Figure 149. Area Under the ROC Curve.

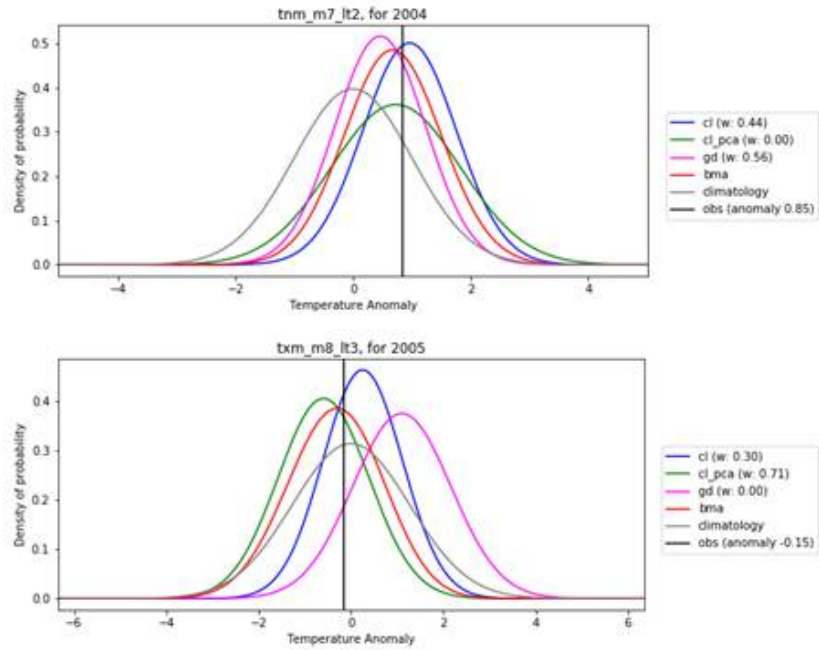


Figure 150. Examples where BMA outperforms various individual models.

② 삼분위 다이어그램을 이용한 이상기후 확률전망정보 표현

삼분위 다이어그램과 Hue-Saturation-Value (HSV) 색상 모델을 이용하여 삼분위 확률예측정보를 지역별 색상으로 표시하는 이상기후 전망정보 표현방식을 제시하였다. 아래 그림은 2020년 6월(왼쪽 위), 7월(왼쪽 중간), 8월(왼쪽 아래)의 지역별 삼분위 확률예측값을 HSV 색상으로 나타낸 것으로, 6월 예측 지도를 살펴보면 모든 지역이 Above Normal의 확률이 크게 나타나 있는 가운데 대구경북과 부산경남을 비교할 때 대구경북이 AN의 확률이 더 큰 것을 알 수 있다(대구경북의 경우 AN 확률 91.65%, 부산경남은 86.77%). 우측 지도는 실제 관측된 온도 편차 지도로, 왼쪽에서 예측한 확률정보의 공간적 분포와 상당히 유사한 공간적 분포를 보이고 있다 (Figures 151, 152).

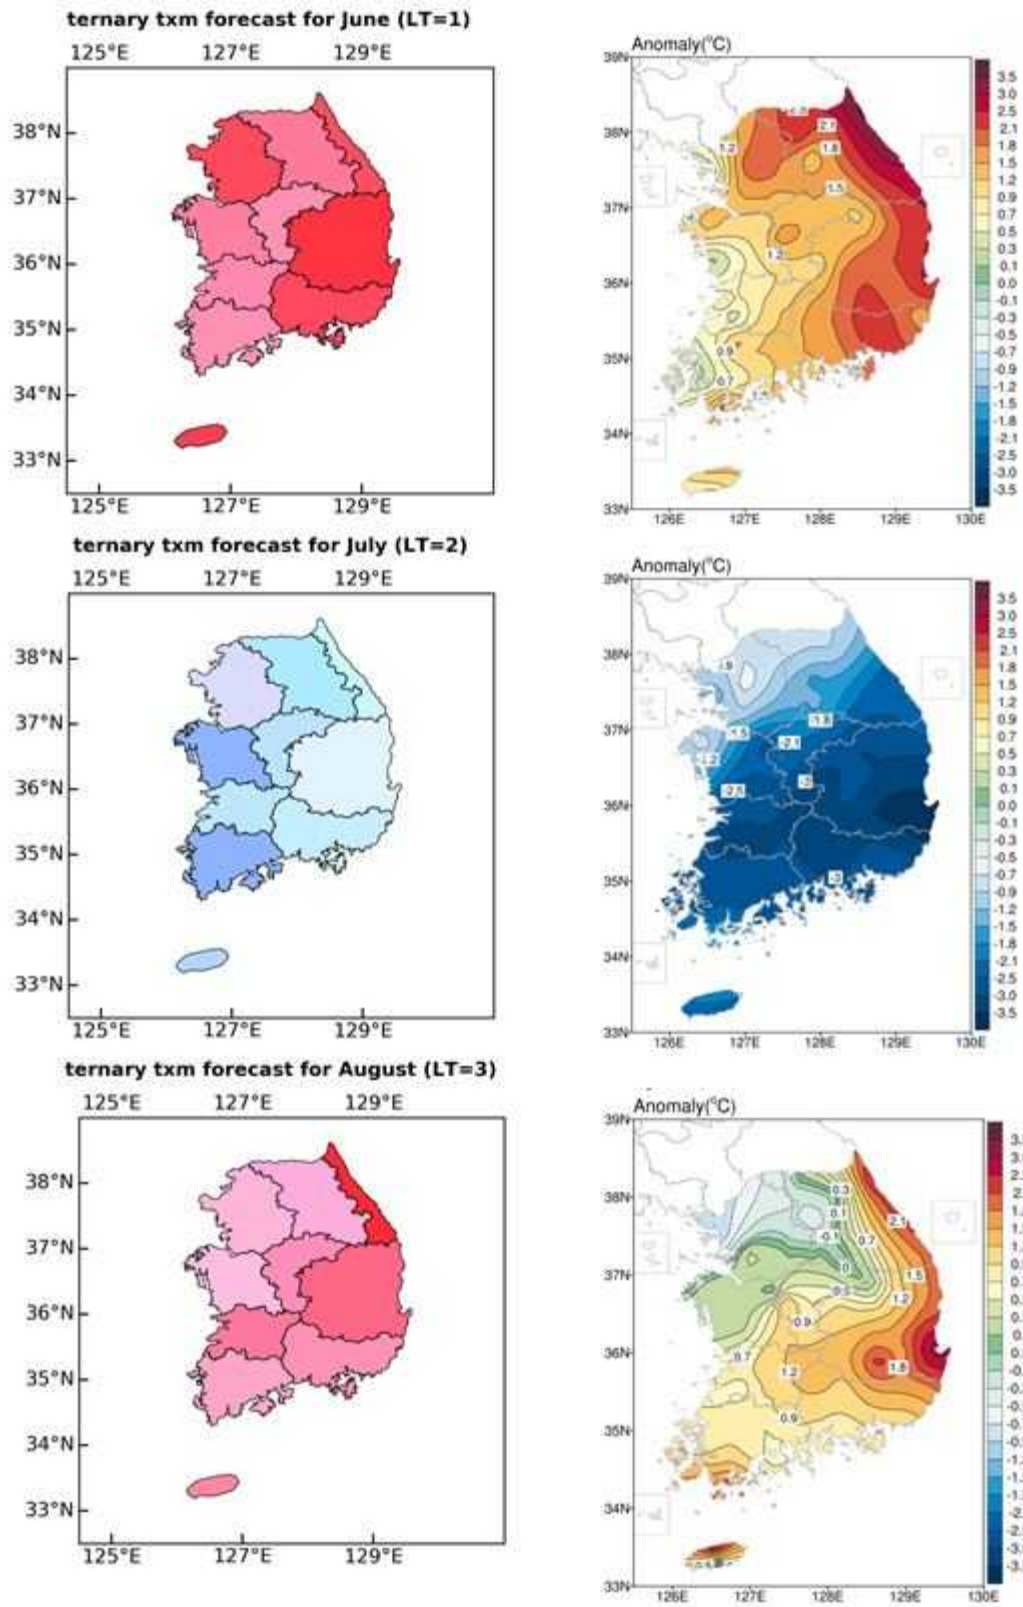


Figure 151. Ternary probabilistic forecast maps (left) and observed temperature anomaly maps (right) for June, July, and August 2020.

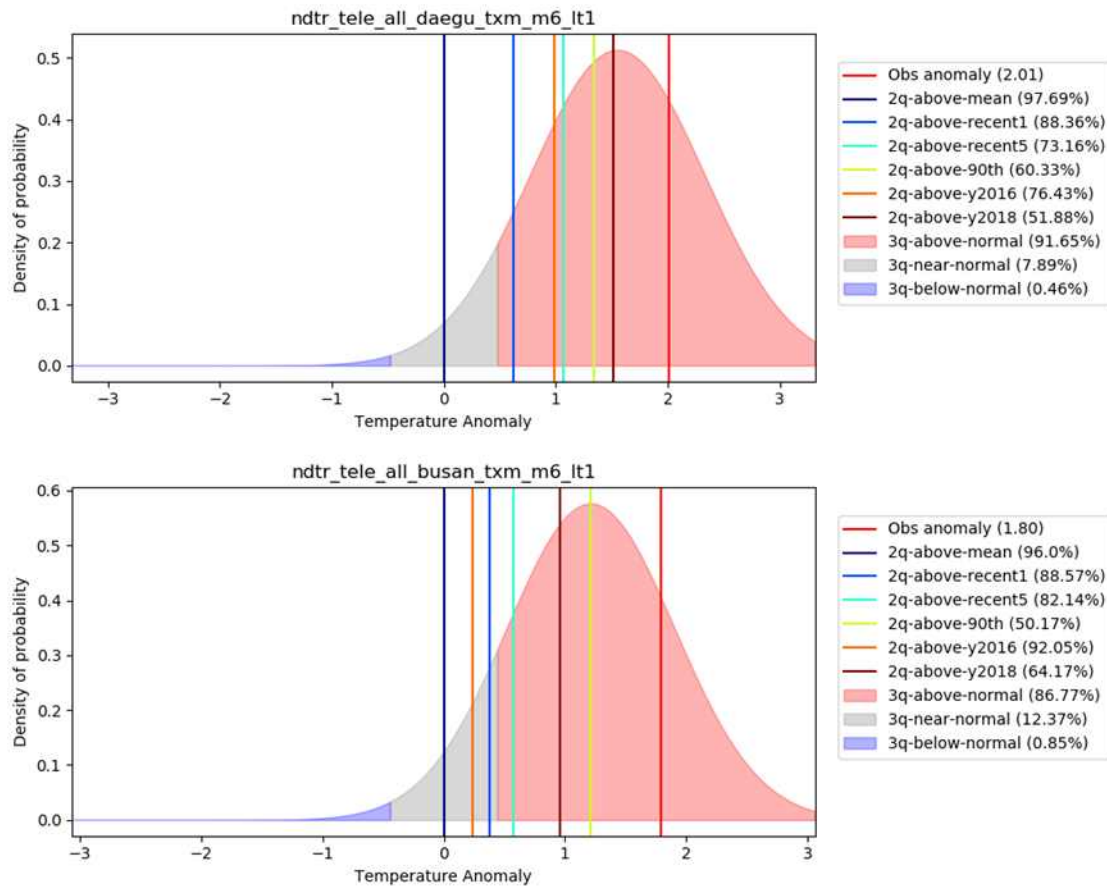


Figure 152. Probabilistic forecast results for Daegu-Gyeongbuk (upper) and Busan-Gyeongnam (lower) for June TXM in 2020.

(3) 3개월 기온 장기예보 개선안

(가) 극한기후 확률예측추정기법

GloSea5의 hindcast (2019v과 2020v)는 Tmax 경우 6월, 7월, 8월, JJA에서 cold bias가 발견되며, Tmin의 경우는 warm bias가 발견되었다(부록 D의 Figure D1). 이 연구에서 사용하는 방법이 일종의 Empirical Quantile Mapping(EPM)의 Bias Correction방법이므로, 별도의 Bias Correction은 실시하지 않았다. GloSea5모델의 현행 3분위 예보에서 5분위 예보로의 확장성을 평가하기 위해, 10/15/20 퍼센타일과 80/85/90 퍼센타일을 기준값을 했을 경우, 확률예보에 대한 AUC값을 비교하여 Figure 153에 도시하였다. 극한기온 기준값은 JJA의 예측성에 대해 우선 고려하고, 6월, 7월, 8월의 권역별 예측성이 가장 많은 경우를 선택하였다. 예를 들어, Tav_g 경우 p85(85 퍼센타일)에서 JJA 예측성이 가장 높았고, 6월에서는 80/85/90 퍼센타일 경우 예측성이 모두 안 좋았으나, 7월과 8월은 p85에서 예측성이 비교적 높아, p85로 선정하였다. 이러한 결과로부터, Tav_g의 경우, p15와 p85를 추가하여 5분위 예보가 가능할 것으로 판단되었다. Barnston and Mason (2011)은 85퍼센타일을 기준값으로 할 경우, IRI 3분위 계절전망과 비슷한 예측 수준을 보인다고 하였다. 이와 유사한 방법으로 Tmax와 Tmin에 대해서도 기준값을 선정했으며, p50으로 2분위 예보가 가능할 것으로 판단되었다. 한편, 이러한 결과는 ECMWF(Figure 154)의 예측

성과도 비슷한 결과를 보였다.




Figure 153. Climate extreme thresholds for GloSea5.




Figure 154. Climate extreme thresholds for ECMWF.

(나) 극한기후 확률예측추정기법 적용 및 검증

Tavg의 경우, 극한기온 예보의 기준값으로 p15와 p85가 선정되어 5분위 확률 예보를 2020년 GloSea5 예측자료에 적용하였다. 한 달 lead time(말하자면, 5월에 예보한 6월 전망자료(Figure 155), 6월에 예측한 7월 전망자료(Figure 156), 7월에 예측한 8월 전망자료(Figure 157))의 결과를 Figures 155-157에 도시하였다. 예를 들어, Figure 155a에서 보여주듯이, 5월에 발표한 6월 Tavg의 경우, 90% 확률로 Extremely high (>p85)가 가장 높았으며, 평년보다 Tavg가 높은 확률과 평년과 비슷할 확률이 동일하게 5%이었다. Tmax와 Tmin의 경우에도, 95:5로 평년보다 높은 확률을 훨씬 크게 전망하였다. 특정년도와 비교하여 높거나 낮은 확률을 전망하였으며, 6월 전망(Figure 158)과 7월과 8월 전망(부록 D의 Figures D2과 D3)에 적용하였다. 예를 들면, 폭염이 심했던 해 중의 하나인 2018년과 비교했을 때, 올 6월에는(Figure 158b, e, and h) Tavg 경우, 75:25, Tmax와 Tmin의 경우, 80:20으로 각각 2018년 보다 높을 것으로 전망하였다.

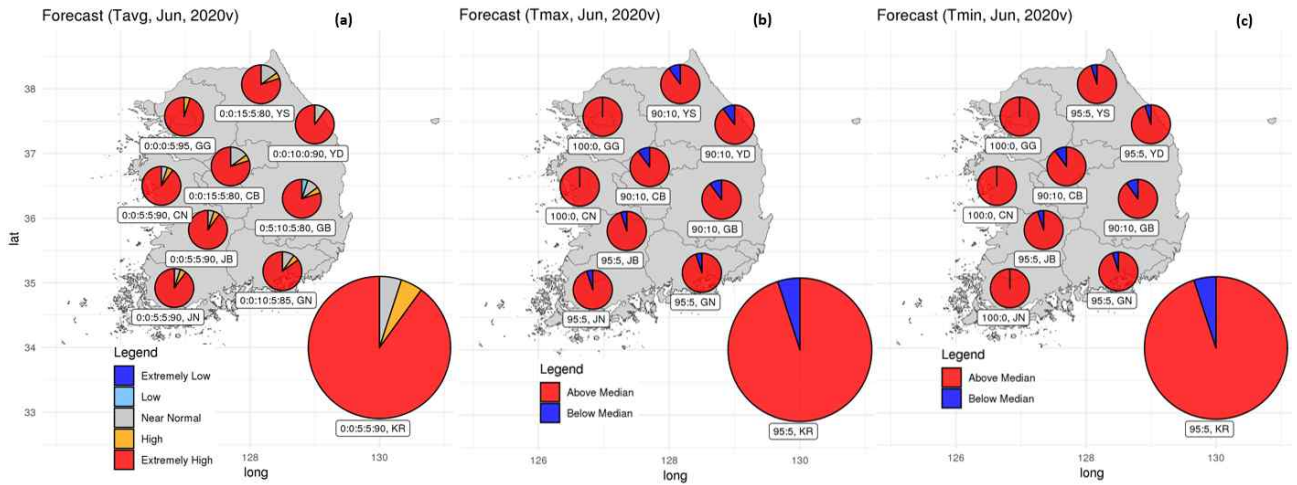


Figure 155. One month lead time forecast for June 2020. (a) Tavg, (b) Tmax, and (c) Tmin

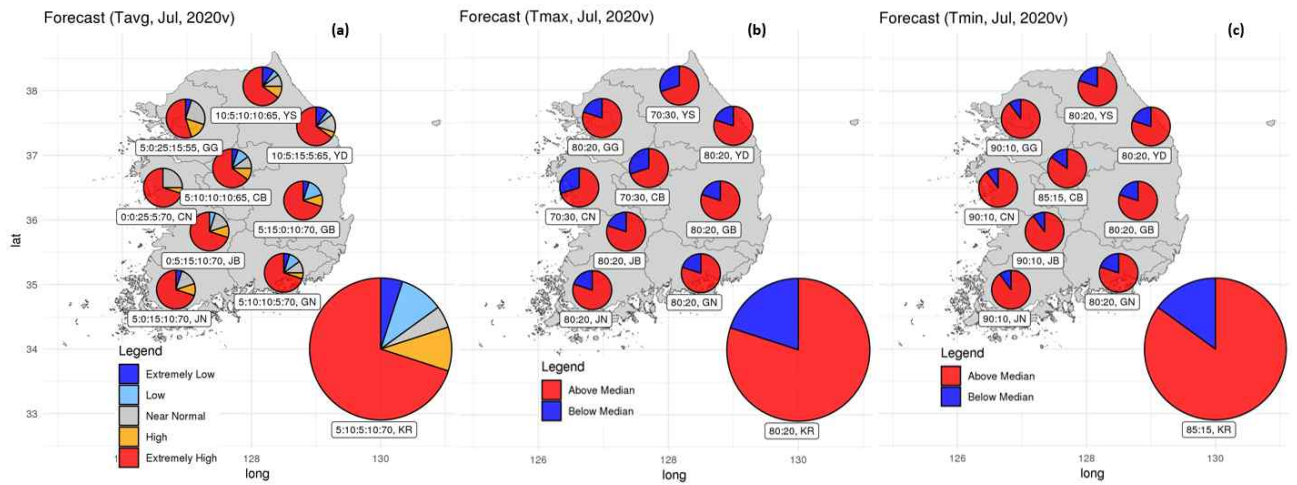


Figure 156. One month lead time forecast for July 2020. (a) Tavg, (b) Tmax, and (c) Tmin.

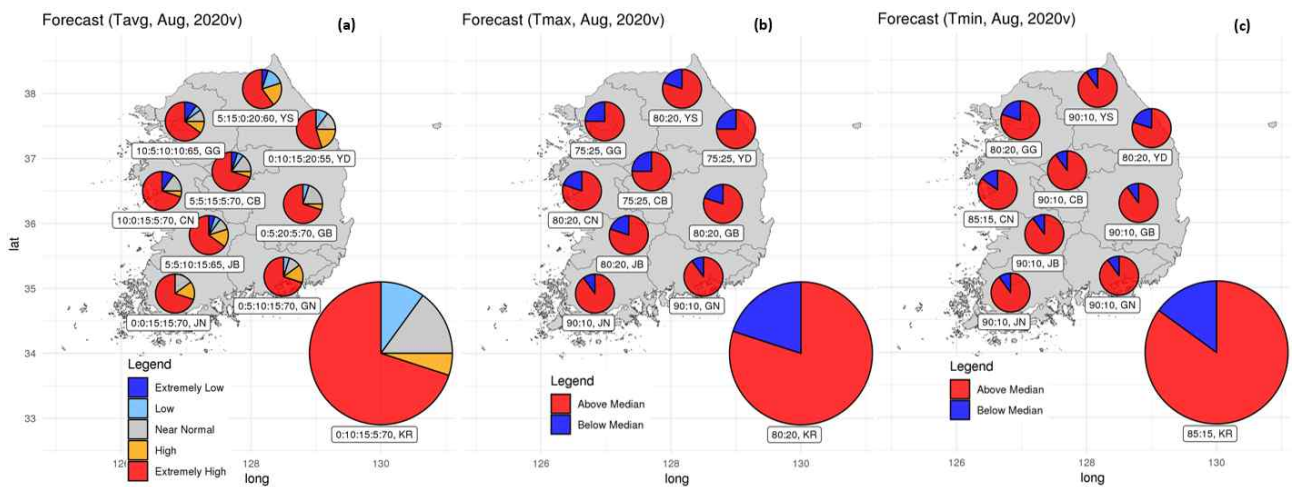


Figure 157. One month lead time forecast for August 2020. (a) Tavg, (b) Tmax, and (c) Tmin.

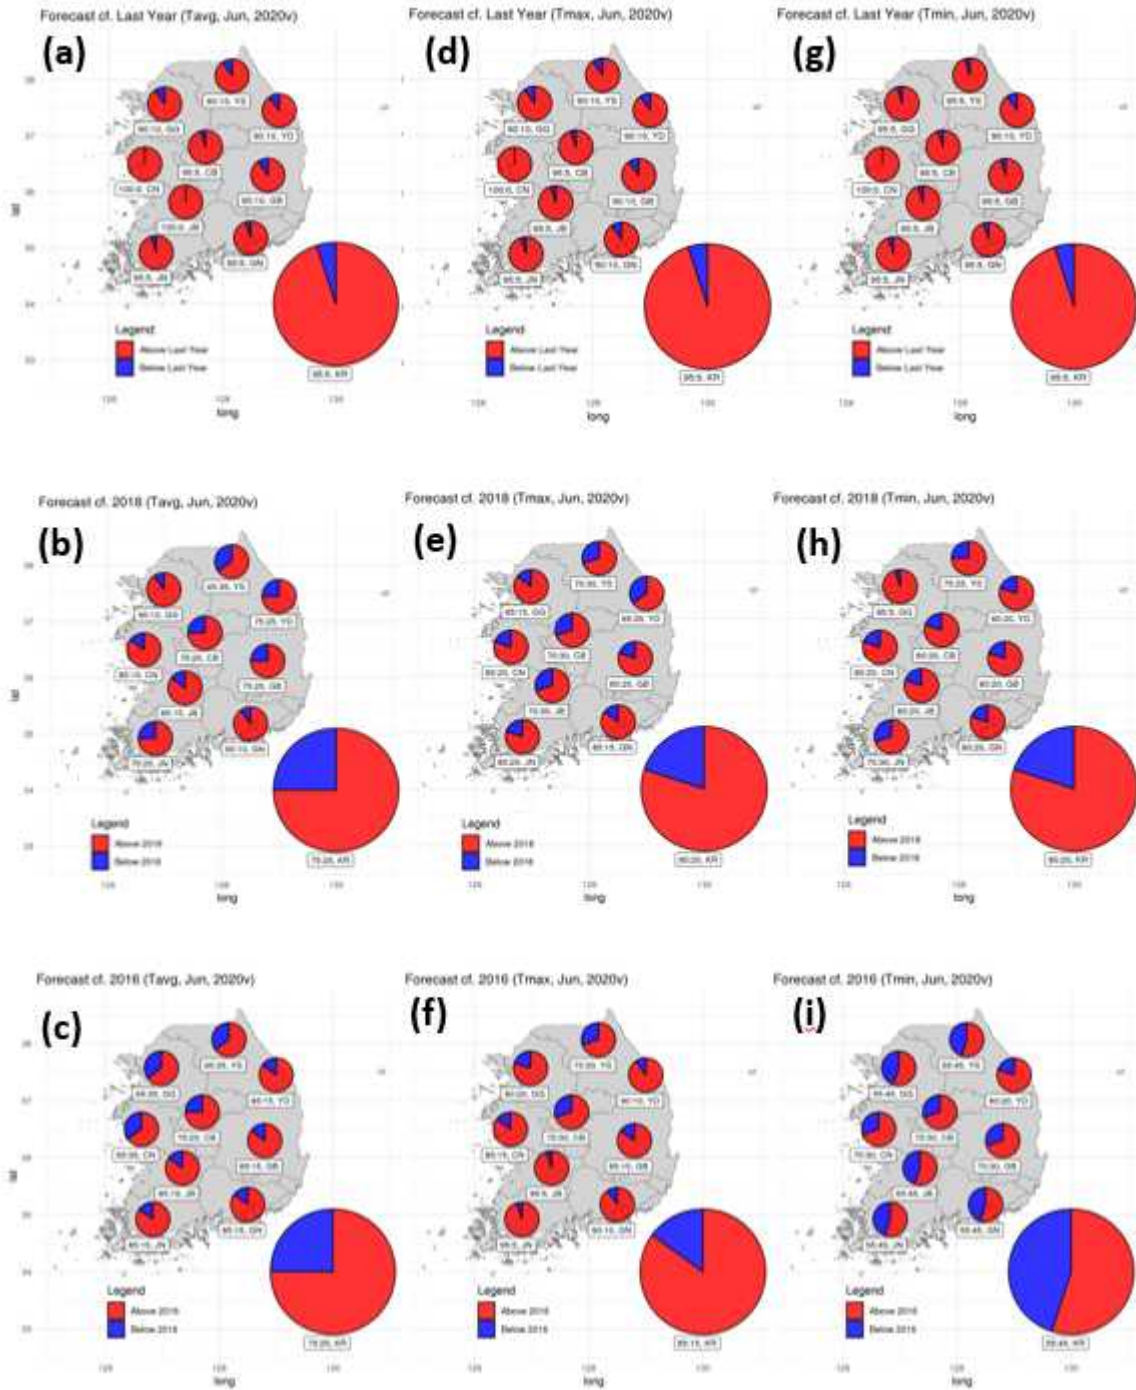


Figure 158. Probabilistic forecasts for June 2020 compared to last year ((a), (d), and (g)), the year 2018 ((b), (e), and (h)) and the year 2016 ((c), (f), and (i)).

우리나라 2020년 6월과 7월의 관측 Tavg, Tmax, Tmin의 권역별 및 우리나라 전체 퍼센타일을 요약하여 Table 20에 제시하였다. 6월은 우리나라의 Tavg와 Tmin이 최고기온을 기록할 정도로 매우 높았고, Tmax는 95 퍼센타일에 해당하는 매우 더운 달이었다. 권역별로는 Tavg와 Tmin의 경우, 대부분의 권역에서 최고기온을 기록하였고, Tmax의 경우 80퍼센타일을 기록한 곳(전북권역)도 있었다. 그러나 7월의 경우, Tavg, Tmax, Tmin 모두 15퍼센타일 이하의 평년보다 매우 낮은 기온을 기록하였다. GloSea5를 활용하여 전망한 확률예측값을 관측값을 이용하여 평가하였다(Figure 159). Figure 159a-c는 6월의 검증결과이며, Figure 159d-f는 7월의 검증결과이다. Figure 155에서 보여주듯이, 6월은 Tavg의 경우, Extremely high 확률을 가장 높게 전망했으며, Tmax와 Tmin의 경우 중앙값보다 높은 확률을 가장 높게 전망하였고, 이는 관측치에서도 잘 나타나, 예측이 모두 적중하였다. 그러나 7월의 경우, 관측에서는 Tavg, Tmax, Tmin 모두 평년값보다 매우 낮았으나, GloSea5는 여전히 높게 전망하여, 예측이 모두 틀린 결과를 보였다. GloSea5의 여름철 기온에 대한 물리적 작용과 관측에서 대기순환 등에 대한 추가 연구를 통하여 GloSea5의 확률예측성을 개선할 필요가 있다.

Table 20. Observed percentiles in each division.

Division	June 2020			July 2020		
	Tavg	Tmax	Tmin	Tavg	Tmax	Tmin
GG	0.95	0.85	1.00	0.15	0.15	0.15
GN	1.00	0.95	1.00	0.10	0.05	0.10
GB	1.00	1.00	1.00	0.10	0.10	0.10
YD	1.00	1.00	1.00	0.15	0.25	0.10
YS	1.00	0.95	1.00	0.15	0.10	0.15
JN	0.95	0.85	0.95	0.10	0.05	0.10
JB	1.00	0.80	1.00	0.01	0.01	0.05
CN	1.00	0.90	1.00	0.00	0.05	0.15
CB	1.00	0.95	1.00	0.15	0.05	0.10
KR	1.00	0.95	1.00	0.10	0.05	0.10

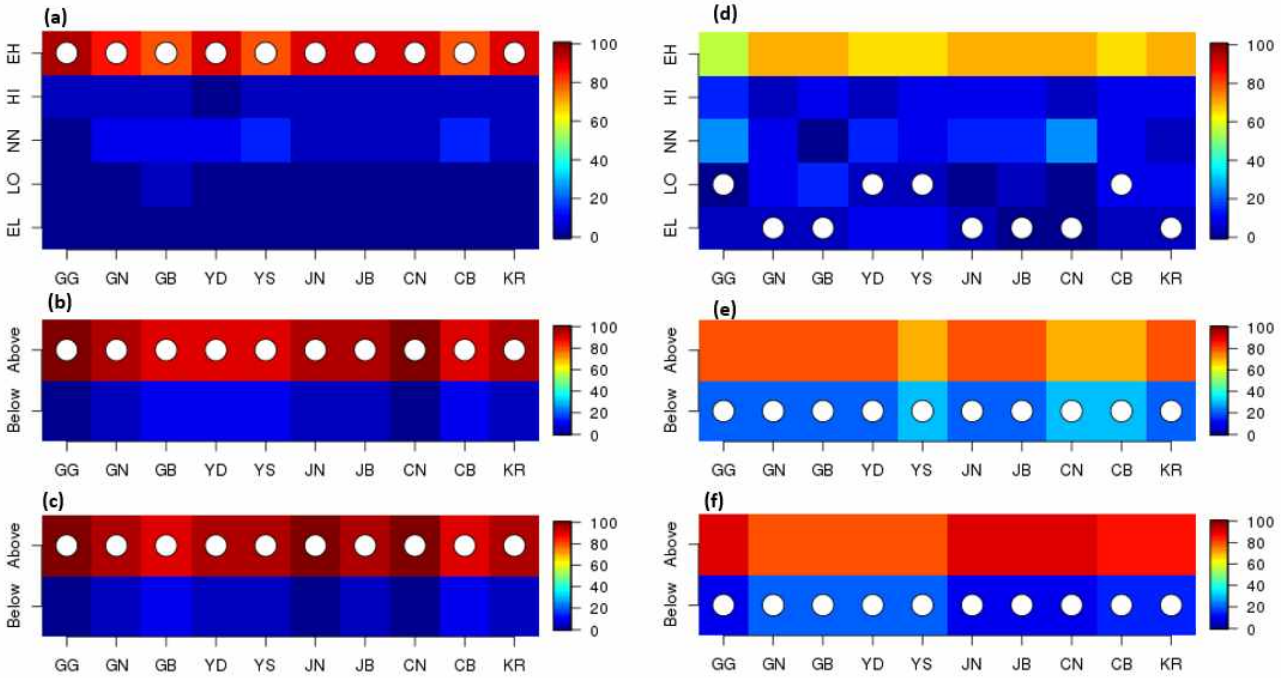


Figure 159. Validation of the probabilistic forecasts for June 2020 ((a)-(c)) and July 2020 ((d)-(f)). (a) and (d) for Tavg, (b) and (e) for Tmax, and (c) and (f) for Tmin.

(4) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안 제시

(가) 최고·최저기온 편차보정 결과 및 검증

① 앙상블 구성을 위한 민감도 비교 결과

2장에서 설명한 바와 같이 최고·최저기온의 lead-time에 따른 오차경향 및 주별 평균오차 (mean error) 분석을 통해 편차보정을 하였다. 편차보정에 대한 방법을 다시 설명하자면, 예보타겟(3주~6주, 주별)의 앙상블 평균한 예측값과 동일한 기간의 관측값의 차이로 편차(bias)를 한다. 그리고 이를 기후예측모델의 기후값 20년(1991~2010년)의 과거재현자료동안 평균하여 편차기후값(bias climatology)를 구하되, 예보타겟 기간을 기준으로 적정한 window(예, ±15일, 30일) 동안 초기화하여 3주~6주를 예측한 값의 평균으로 정의한다.

따라서 편차기후값을 정의할 때 window를 어떻게 정하느냐에 따라 결과가 달라질 수 있기에, 이에 대한 민감도 비교 결과를 먼저 분석해보았다. Figure 160은 time window에 따른 기후예측모델의 과거재현자료에서 나타나는 bias 값을 나타내는데, 이때 window를 0로 했을 경우 (window 없음), ±15일로 했을 경우, 그리고 -7일로 했을 경우를 비교하였다. -7일은 기후예측과 의 현업일정을 고려한 것으로, 예측 시작 시점에 미래 시점에 대한 hindcast가 가용하지 않기 때문에 별도로 고려한 것이다. Figure 160에서 알 수 있는 바와 같이 time window가 0일 때를 제외하고는 window에 따른 bias가 크지 않음을 알 수 있다. 즉, time window가 일정 이상일 때는 편차보정 후 예측성에 미치는 영향이 미미하다고 할 수 있다. 여기서 특이할 점은, 예측 타겟일을 기준으로 전/후 window(=±15일)를 사용한 경우와, 예측 타겟 전 시간의 window(=-7일)

을 사용한 경우, bias의 차이가 크지 않다. 따라서 본 연구 결과에서는 기후예측과의 현업 가용 자료를 활용하여 -7일 window를 사용하여 편차보정 시스템을 개발하였다.

다음으로, 편차보정을 위한 bias climatology 추정에 있어 training year이 어떠한 영향을 미치는지 알아보았다. Figure 161은 training year에 따른 bias를 비교한 것이다. GloSea5의 과거재현기간은 1991부터 2010년까지 20년으로, 20년(1991~2010), 15년(1996~2010), 10년(2001~2010), 5년(2006~2010)년을 비교하였다. 더불어, 2020년 8월부터 GloSea5의 과거재현기간이 1991년부터 2016년까지 26년으로 확장되었으므로, 26년 training year을 이용한 bias도 함께 비교하였다. 과거재현기간동안의 bias는 5년에서 가장 크게 나타났으며, 그 이후로는 training year에 따른 차이가 크지 않은 것으로 나타났다. 특히, GloSea5의 과거재현기간이 20년에서 26년으로 늘어났음에도 불구하고, bias 차이는 별로 크지 않은 것으로 나타났으므로 편차보정에는 큰 영향을 미치지 않은 것으로 나타났다. 또한, 최고기온과 평균기온의 경우 training year에 따른 차이가 가장 미미하게 나타났고, 최저기온은 그 차이가 상대적으로 큰 것으로 나타났다. 그림으로 나타내진 않았으나, bias뿐 아니라 RMSE도 비슷한 경향을 나타내어, 전반적으로 training year에 따른 편차 및 편차기후값은 크지 않은 것으로 나타났다. 따라서 본 연구에서는 현업운영의 편의성을 고려하여 GloSea5의 과거재현기간을 모두 사용하여 편차 및 편차기후값을 정의하고, 편차보정을 하였다. 따라서 2020년 7월까지의 20년(1991~2010), 8월이후로는 26년(1991~2016)의 과거재현기간동안의 편차기후값을 추정하고, 이를 사용하여 편차보정하였다.

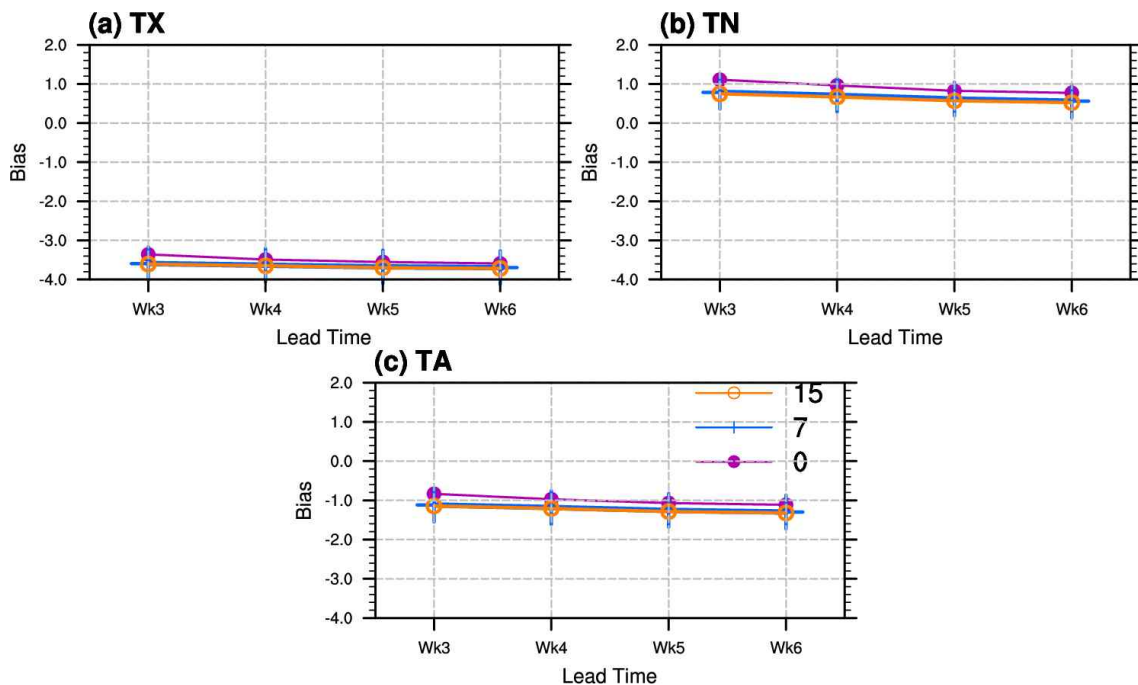


Figure 160. GloSea5 hindcast bias for each lead time, which is with respect to width of time window: orange line for ± 15 day(=30day), blue line for -7day, and purple line for no window.

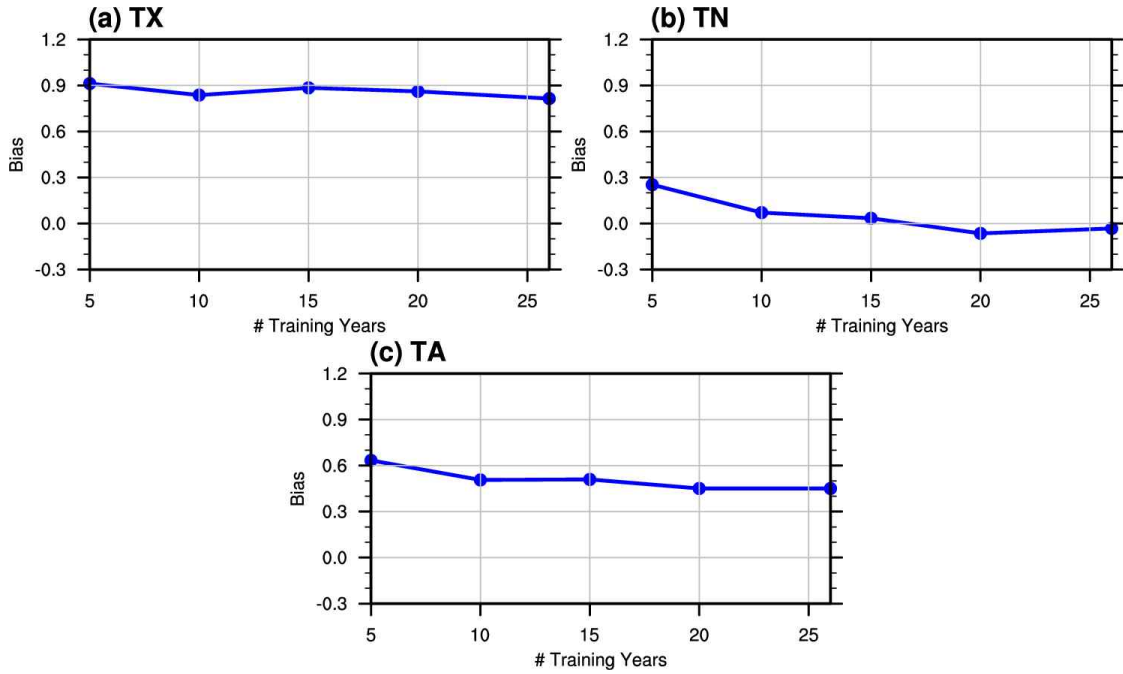


Figure 161. GloSea5 hindcast bias for week3, which is with respect to the number of training years. The years used are from the 2010 to the previous 5, 10, 15, 20, 26 years.

② 정량적 검증: BIAS 및 RMSE 비교

편차보정에 따른 정량적 검증을 위해 Bias와 RMSE를 비교하였다. Figure 162은 실제예측 기간(2017년 1월~2020년 9월) 동안 편차보정 전(RAW)과 후(BC)의 최고, 최저, 평균기온에 대한 bias의 분포를 나타낸다. 분포에서 알 수 있는 바와 같이, 편차보정 전 최고기온의 bias는 최저기온 및 평균기온의 bias 보다 크게 나타났는데, 편차보정의 효과도 최고기온이 가장 크고, 최저기온과 평균기온의 비슷하게 나타났다. 그리고 편차보정 후 변수와 관계없이 bias는 0에 가깝게 나타났으므로, 편차보정의 효과를 뚜렷이 알 수 있었다. 평균적으로는 최고기온의 bias는 2.6도, 최저기온은 0.6도, 평균기온은 0.3도 감소한 것으로 나타났으며, lead-time에 따른 차이도 크지 않아, 편차보정의 효과가 lead-time에 관계없이 유지되는 것으로 나타났다(Figure 163).

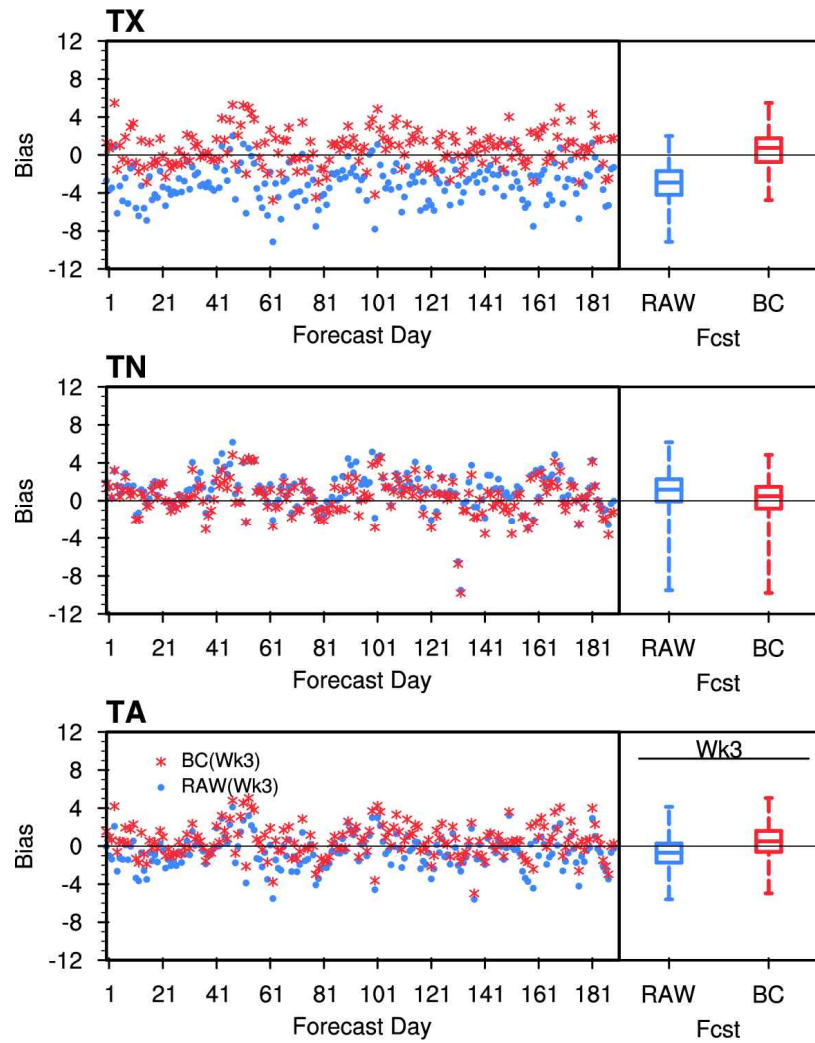


Figure 162. Scatterplot and box-plot for GloSea5 bias for lead-time week3, estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).

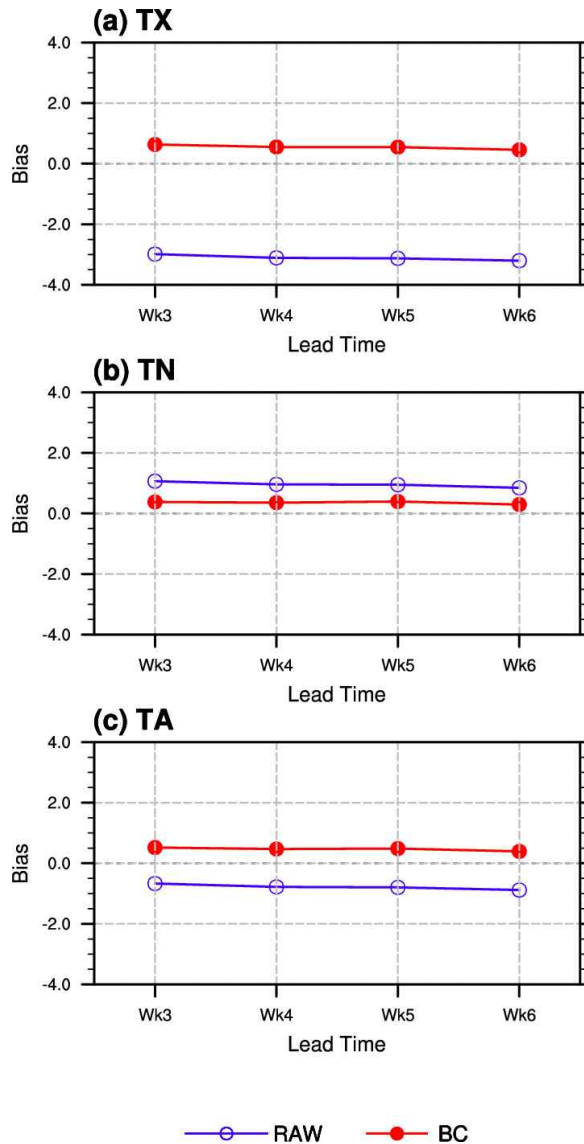


Figure 163. GloSea5 bias for each lead-time(wk3~wk6), estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).

다음으로 각 변수별로 편차보정 전, 후에 대해 평균제곱근오차(RMSE)도 함께 비교하였다 (Figure 164). RMSE의 경우도 bias와 마찬가지로 최고기온의 편차보정 전 절대값(MABE) 오차가 크게 나타났고, 평균기온과 최저기온의 절대값 오차는 비슷한 수준으로 나타났다. 전체 예측기간에 대한 평균제곱근오차 또한, 최고기온이 가장 크고, 최저기온 및 평균기온은 비슷했다. 편차보정 후, 최고기온의 보정효과가 가장 크게 나타났는데, 적중률에 대해 최고기온은 -40.65%, 최저기온은 -4.86%, 평균기온은 -7.50% 정도로 개선되었다. Bias와 마찬가지로 lead-time에 따른 RMSE 감소율 차이는 크지 않은 것으로 나타났으므로 본 연구에서 제시한 편차보정 방법으로 주별 1개월 예보가 개선됨을 알 수 있다(Figure 165).

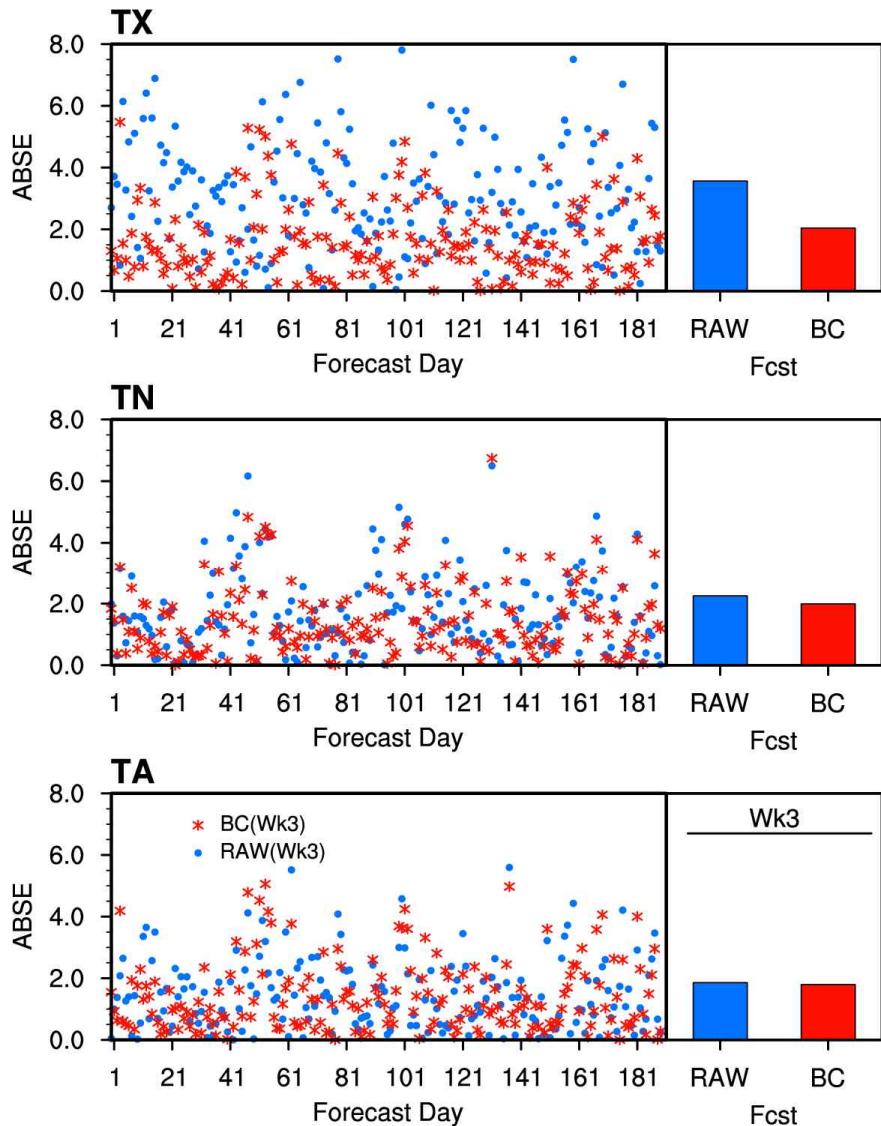


Figure 164 Scatterplot and histogram for GloSea5 rmse for lead-time week3, estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).

한반도 전체 평균한 최고, 최저, 평균기온에 대한 편차보정과 더불어, 한반도 영역에 대한 최고, 최저, 평균기온에 대해 주별 편차보정 전, 후 Bias 및 RMSE의 공간적 분포를 비교하였다. 공간적 분포에서도 최고기온과 평균기온의 경우 음의 bias가 뚜렷하고, 최저기온은 음의 bias가 뚜렷한 것으로 나타났다. 또한 월별 분포에서도 최고기온의 경우 7월 bias가 1월 bias보다 크고, 최저기온의 경우 그 반대로 나타났다. 하지만, 편차보정 후에는 모두 bias가 작아지고, 0에 수렴하는 것으로 나타났다.

기상청 현업모델 과거재현자료의 최고기온은 강한 음의 bias, 최저기온은 약한 양의 bias로 인해 지표기온은 음의 bias가 나타난다. 이로 인해 지표기온의 기후예측모델 기후값(climatology) 또한 음의 bias를 가진다. 따라서 기후예측모델의 실시간 예측자료에서는 양의 아노말리가 나타나는데, 실시간 예측자료의 평균기온은 과거재현자료와 마찬가지로 음의 bias를 보인다. 따라

서 최고·최저·평균기온 편차보정을 통한 확률예측이 필요하다(Monhart et al. 2018).

Kharin et al. (2017)등의 연구에서는 기후예측모델의 격자별 관측과의 공분산과 분산의 비율로 보정계수를 산출하고 이를 활용하여 편차보정된 예측자료를 산출한 바 있다. 동일한 방법의 경우, 전구 영역에서는 조금 개선되지만, 우리나라와 같이 좁은 지역에서는 개선 효과가 매우 미비한 것으로 나타났다. 따라서 본 연구에서는 격자별 공분산 및 분산의 영향을 고려할 만큼 영역이 넓지 않는 우리나라에서는 systematic한 평균보정을 통해서도 충분히 편차보정 효과가 나타나는 것을 알 수 있다.

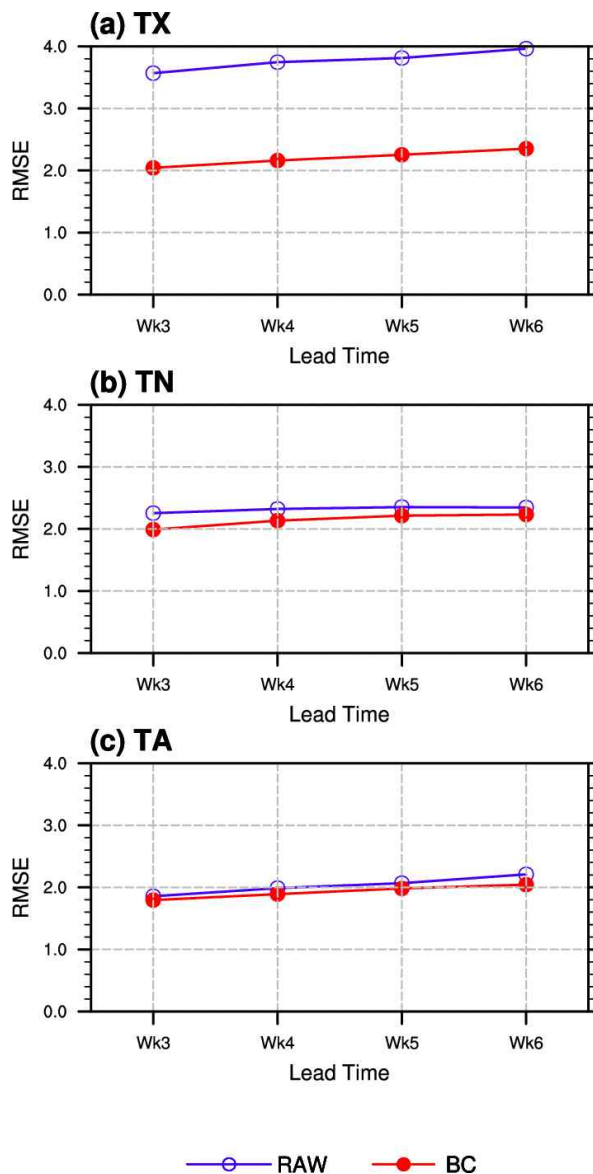


Figure 165 GloSea5 rmse for each lead-time(wk3~wk6), estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).

③ 정량적 검증: Categorical 예측 정확도(Accuracy) 비교

또 다른 정량적 검증방법으로써, 관측 및 예측에 대한 3×3 confusion matrix의 정확도(accuracy)를 비교하였다. 이 때 관측 및 예측에 대한 category를 높음(above)/비슷(normal)/낮음(below)로 구분하여 검증하는데, 비슷범위(normal range)는 과거 30년(1981~2010) 동안의 ±0.43표준편차로 정의하였다.

본 검증해서 사용한 실제예측기간은 2017년 1월부터 2020년 8월이고, 이 기간 동안 매주 1개월(주별) 예측을 한다고 했을 때, 3주 예측에 대한 각 category별 횟수를 Table 21~Table 23에 구분하였다. 본 연구의 검증에 사용한 실제예측기간동안 평년이상(AN)인 경우가 우세하게 나타났고, 이는 지구온난화와 관련이 있다. 이러한 경향은 최고, 최저, 평균기온 모두에서 동일하게 나타났음을 알 수 있다. 특히 관측의 평년이하(BN)인 경우보다, 기후예측모델에서 평년이하를 거의 예측하지 않는 것으로 나타났으며, 관측에서의 평년이상(AN) 또는 평년(NN)인 경우를보다 기후예측모델에서 훨씬 빈번이 나타났음을 알 수 있다. 따라서 이러한 기후예측모델의 bias를 보정하여 예측할 필요가 있을 것이다.

Table 21. The number of cases in each category of confusion matrix for maximum temperature. Bold numbers indicate accurate forecast

		Observation			
		AN	NN	BN	Total
Forecast	AN	71	35	20	126
	NN	22	17	22	61
	BN	0	0	3	3
	Total	93	52	45	190

Table 22. The number of cases in each category of confusion matrix for minimum temperature. Bold numbers indicate accurate forecast

		Observation			
		AN	NN	BN	Total
Forecast	AN	77	42	16	135
	NN	22	18	14	54
	BN	0	0	1	1
	Total	99	60	31	190

Table 23. The number of cases in each category of confusion matrix for mean temperature. Bold numbers indicate accurate forecast

		Observation			
		AN	NN	BN	Total
Forecast	AN	75	41	21	137
	NN	19	19	13	51
	BN	0	0	2	2
	Total	94	60	36	190

Figure 166은 전체 3×3 카테고리에 대한 전체 정확도(accuracy)를 나타낸다. 관측 기후값 기간(1981~2010)의 비슷범위에 따른 예보적중률 결과, 최고기온과 평균기온은 전체 정확도가 상승하고, 최저기온의 경우 전체 정확도가 감소하였다. 특히, 최고기온(Figure 167a)은 음의 bias 보정으로 ‘높음’ 정확도가 큰폭으로 상승한 반면, ‘비슷/낮음’ 정확도가 소폭 하락함으로써 전체 정확도는 상승한 것을 알 수 있다(Figure 166a). 최저기온은 전반적으로 정확도가 소폭하락 했는데(Figure 166)), 이는 관측기간 ‘높음’이 지배적인 상황에서 양의 bias의 보정으로 ‘높음’ 정확도가 떨어지고, ‘비슷/낮음’ 정확도는 상승했기 때문이다(Figure 167b). 그리고 평균기온은 전체 정확도가 비슷하거나 소폭 하락했는데(Figure 166c), 이는 ‘높음’ 정확도가 상승한 반면, ‘비슷’ 정확도는 하락했기 때문이다(Figure 167c). 요약하자면, 관측 기후값기간(1981~2010)의 비슷범위에 따른 예보적중률 결과, 최고기온과 평균기온은 음의 bias 보정으로 ‘높음’ 정확도가 상승하고, 최저기온은 양의 bias 보정으로 ‘비슷/낮음’ 정확도가 상승한 것으로 나타났다. 최고기온은 7.7% 상승, 평균기온은 1.1% 상승, 최저기온은 18.5%가 감소하여, 적중률에 대해 최고기온과 평균기온은 개선된 반면, 최저기온은 하락하여 이에 대한 추가 연구가 필요하다.

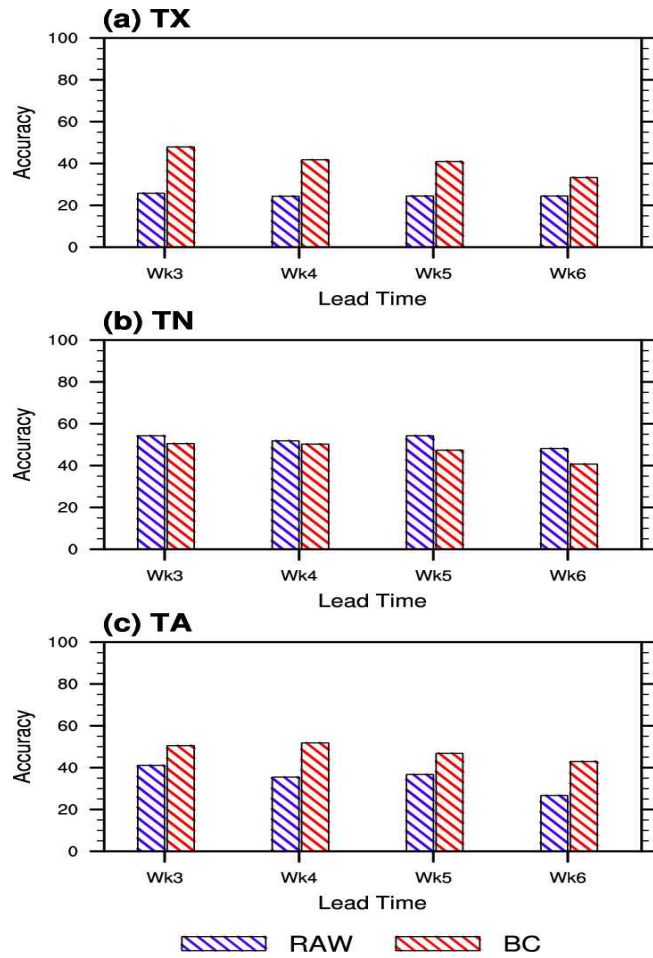


Figure 166. Accuracy for confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).

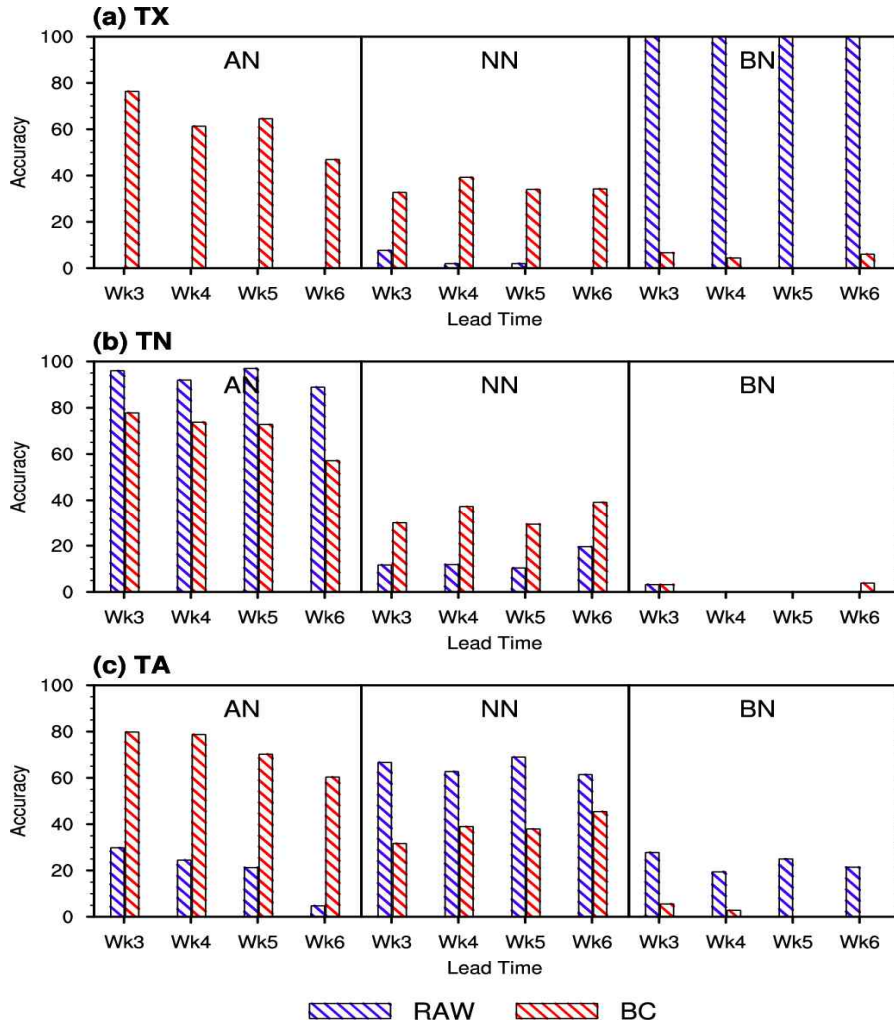


Figure 167. Accuracy for each category(AN: above normal, NN: near normal, BN: below normal) in confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red).

④ 기후값 변경에 따른 편차보정 영향 분석 및 예측성 검증

앞서 언급한 바와 같이, 2021년 관측 기후값 변경(1981~2010년→1991~2020년)이 예정되어 있는데, 이는 최근의 지구온난화 경향에 따라 필수불가결할 것이다. 따라서 본 연구에서는 기후값 변경에 따른 평년범위의 변화를 살펴보고, 이에 따른 confusion matrix 상에서의 예측 정확도를 함께 살펴보았다.

Table 24~Table 26은 기후값 변화(1981~2010→1990~2019)에 따른 평년범위를 알기 위해 2017년 1월부터 2020년 8월까지의 주별 3주 예측 기간에 대해, 각 범주별로 case를 비교한 것이다. 전반적으로 기후값 변화 후에도 여전히 ‘높음’이 지배적임을 알 수 있으며, 각 category별 경우의 수는 높음>비슷>낮음 순으로 나타났다. 특히, 최저기온의 경우 최고 및 평균온도에 비해 ‘비슷’이 상대적으로 많이 증가하였으며, ‘낮음’은 크게 증가하지 않은 것으로 나타났다.

Table 24. The number of cases in each category for maximum temperature. Bold numbers indicate accurate forecast

		90-19			
		AN	NN	BN	Total
81-10	AN	79	14	0	93
	NN	0	46	6	52
	BN	0	0	45	45
	Total	79	60	51	190

Table 25. The number of cases in each category for minimum temperature. Bold numbers indicate accurate forecast

		90-19			
		AN	NN	BN	Total
81-10	AN	78	21	0	99
	NN	0	49	11	60
	BN	0	1	30	31
	Total	78	71	41	190

Table 26. The number of cases in each category for mean temperature. Bold numbers indicate accurate forecast

		90-19			
		AN	NN	BN	Total
81-10	AN	83	11	0	94
	NN	0	55	5	60
	BN	0	0	36	36
	Total	83	66	41	190

이에 대해 좀 더 자세히 살펴보고 위해 Figure 168에서는 기후값 변경 전/후에 대한 평년 범위 비율과 그 차이를 살펴보았다. 전체적으로 겨울철(특히 12월)을 제외하고 평년값이 증가하는 것으로 나타났다. 최고기온의 경우, 봄철 평년 증가가 뚜렷하고(최고 1.1도), 평년범위 또한 0.7배~1.3배 정도로 나타났다. 최저기온은 여름철 평년 증가가 뚜렷했으며(최고 0.95도), 평년범위 또한 증가(최고 1.6배)가 뚜렷했는데, 이것이 평년과 비슷범위(NN) 증가 요인이 되었다. 따라서 기후값 변경에 따른 1개월 주별 예보 시 여름철 평년보다 ‘높음’ 예보시 주의가 필요하다. 평균기온은 봄철 평년 증가(0.9도)가 뚜렷하게 나타났고, 평년범위(0.8배~1.3배) 증가 또한 뚜렷하게 나타났다.

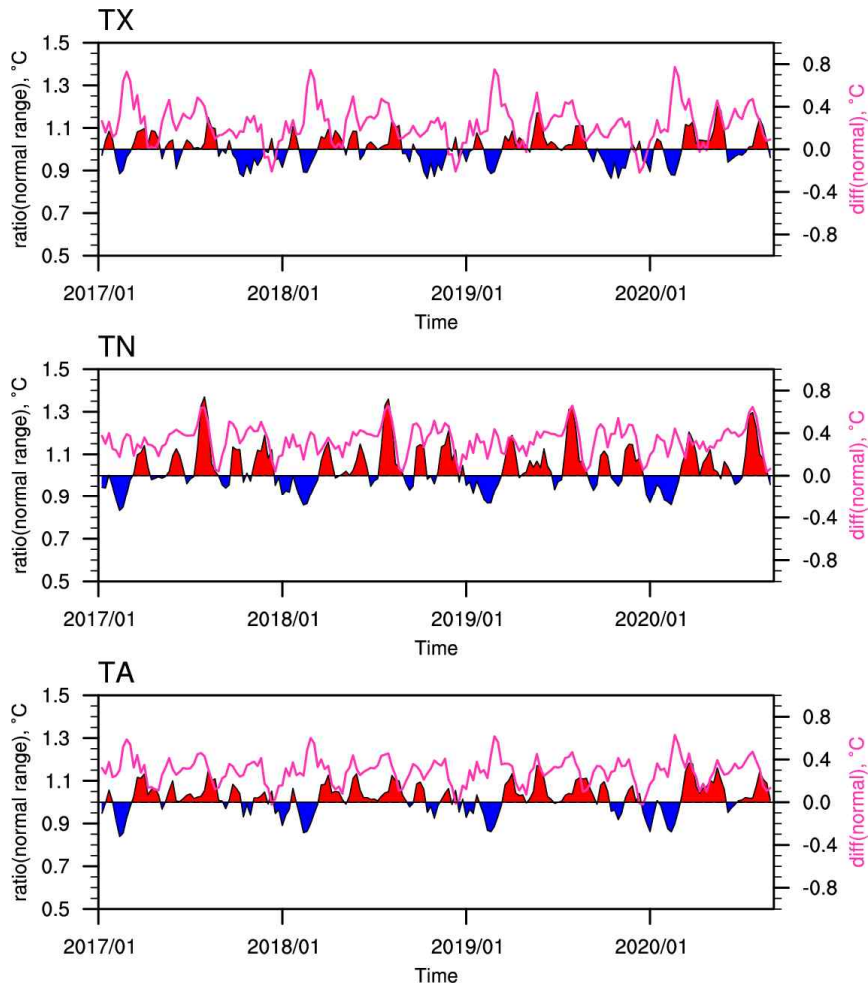


Figure 168. Normal range ratio(shading) and normal difference(solid line) for weekly (top) maximum, (middle) minimum, and (bottom) mean temperature (4-week running mean).

기후값 변화에 따른 편차보정 영향을 살펴보기 위해, Figure 169에서는 전체 3×3 카테고리 에 대한 전체 정확도(accuracy)를 나타낸다. 기후값 변화에 따른 전체 정확도는 감소하는 경향 을 보이는데, 특히 관측의 평년 비슷한 범위 및 편차감소의 영향으로 ‘비슷/낮음’의 정확도가 증가하였기 때문이다. 즉, 기후값 변화에 따른 전체 정확도 감소는 ‘비슷/낮음’의 정확도 감소 에 따른 것으로 분석되었다.

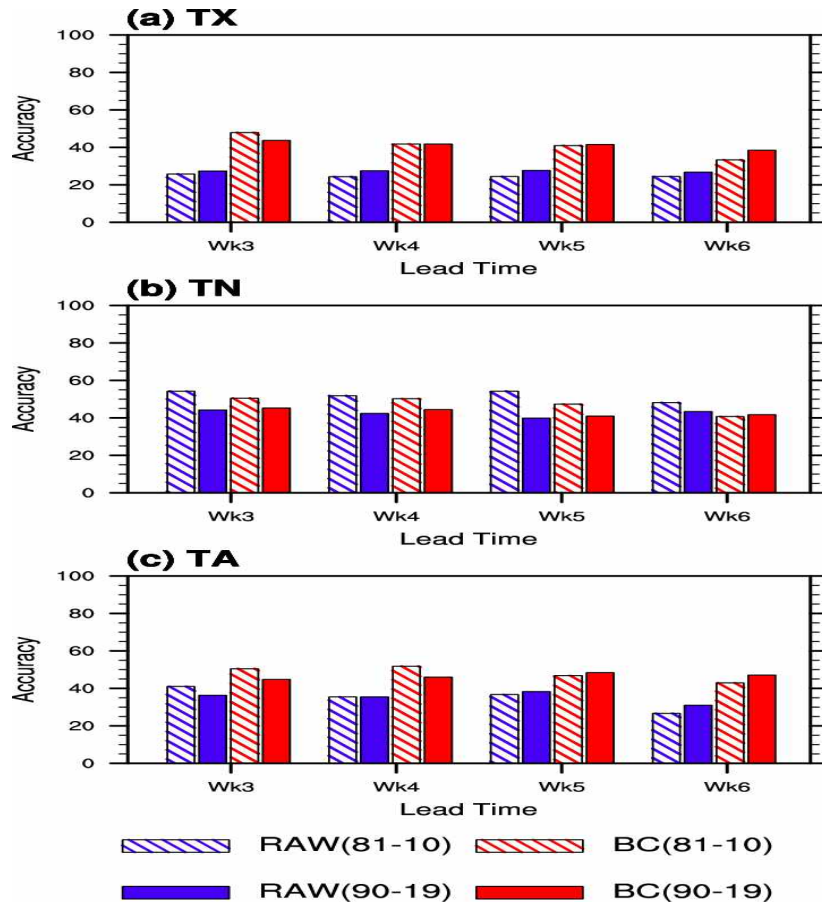


Figure 169. Accuracy for confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red). Dashed box indicates present climatology, and solid box shows upcoming climatology.

최고기온(Figure 170a)의 경우, 기후값 변화와 편차보정의 영향으로 편차보정 전보다 ‘높음’ 정확도 상승이 뚜렷하게 나타났는데, 이는 ‘높음(AN)’이 지배적인 기후조건과 더불어 기후 예측모델의 최고기온 음의 bias 보정효과 때문인 것으로 보인다. 또한, 최저기온(Figure 170b)의 경우는, 기후값 변화와 편차보정의 영향을 살펴보면, 양의 bias 보정으로 ‘높음’ 정확도는 하락한 반면, ‘비슷/낮음’ 정확도는 상승하였다. 이는 기후값 변화에 따라 ‘비슷/낮음’이 상대적으로 많이 상승하고 기후예측모델의 양의 bias 보정효과 때문이다. 평균기온의 경우, ‘높음’ 정확도가 증가한 반면, ‘비슷’ 정확도는 감소하였는데, 이는 ‘높음’이 지배적인 기후조건에서 기후예측모델 평균기온의 음의 bias 보정효과 때문인 것으로 판단된다.




Figure 170. Accuracy in each category for confusion matrix estimated from RAW(raw forecast, blue) and BC(bias-corrected forecast, red). Dashed box indicates present climatology, and solid box shows upcoming climatology.

⑤ 3분위 확률예보 검증

앞서 설명한 기후예측모델의 편차보정된 최고·최저·평균기온을 바탕으로 3분위 확률예보 결과를 살펴보았다. Figure 171은 한 예로써, 예보일 2020년 8월 3일 기준으로, 예보 3주에 대한 최고, 최저, 평균기온 3분위 확률예보 결과로써, 왼쪽은 편차보정 전, 오른쪽은 편차보정 후 기후예측모델 결과에 대한 확률예보를 나타낸 것이다. 확률분포에서 나타나듯이, 편차보정을 통해 최고기온 및 평균기온의 음의 bias가 보정되고, 최저기온의 양의 bias가 보정된 것으로 나타났다. Figure 172는 최고, 최저, 평균기온에 대해 주별 3분위 확률예보를 했을 때의 ROC curve 및 score를 나타낸다. 편차보정 후, 최고 및 평균기온의 3분위 확률예보에 대한 ROC score 상승이 뚜렷하고, 특히 ‘높음’의 정확도 상승이 크게 나타난다. 또한, 최고기온의 경우 ‘비슷/낮음’경우도 ROC score가 뚜렷하다. 최저기온의 경우, ‘높음/낮음’, 평균기온의 경우 ‘높음’의 ROC score가 상승했다. 이로부터 기후예측모델의 편차보정을 통한 최고, 최저, 평균기온의 3분위 확률예보 개선이 가능함을 나타낸다.

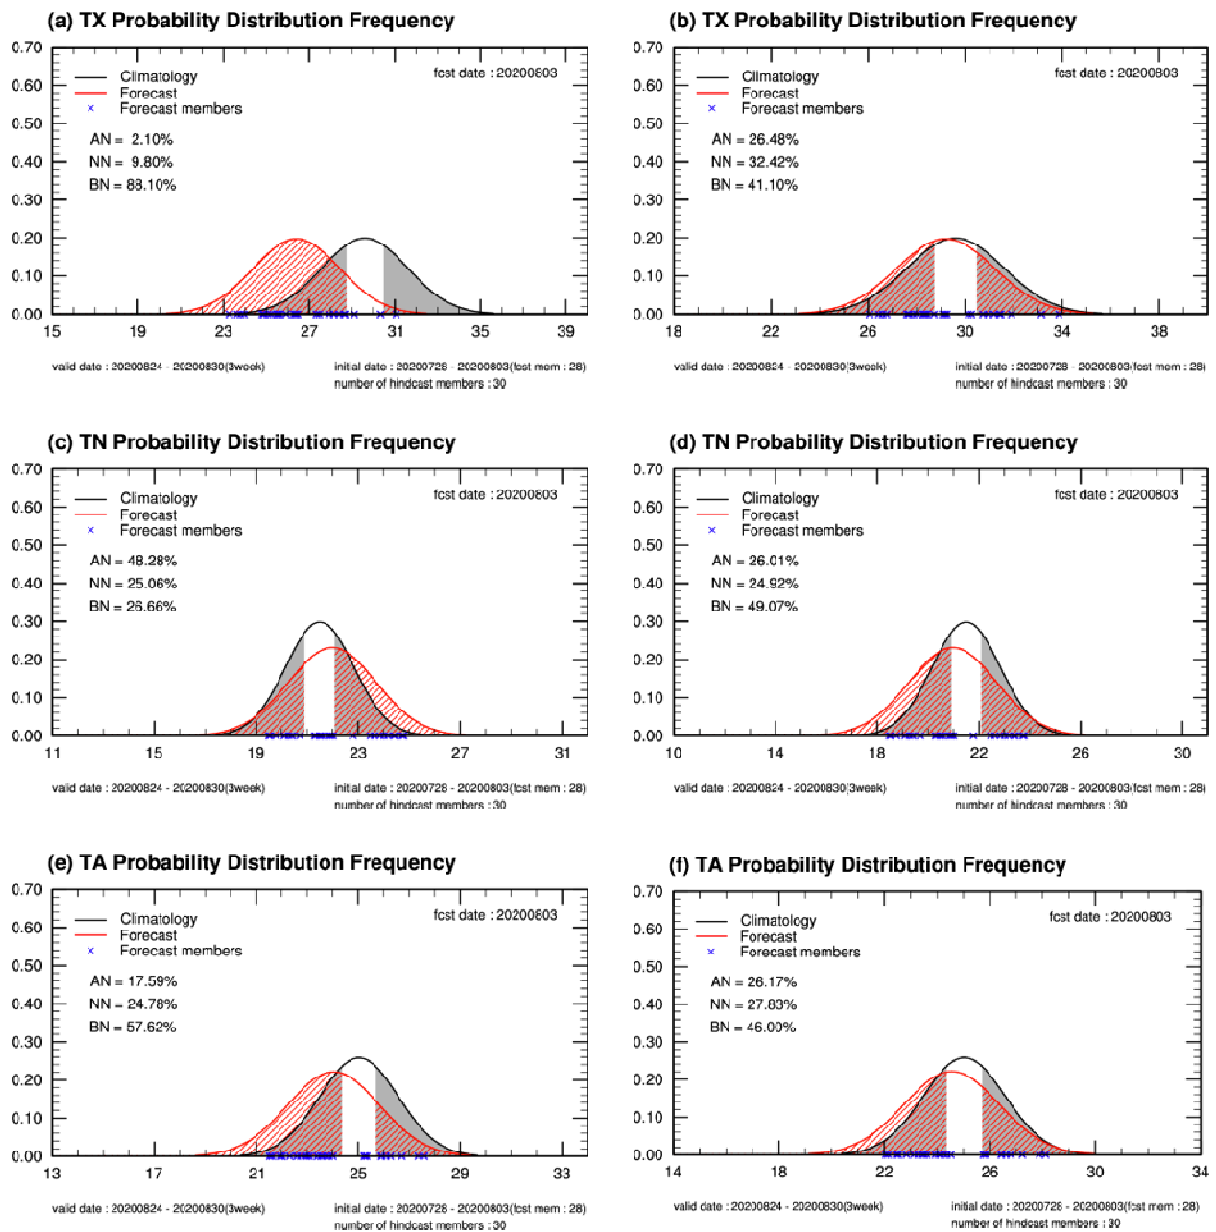


Figure 171. Week 3 tercile-based probabilistic forecast of (top) maximum, (middle) minimum, and (bottom) mean temperature, forecasted at Aug 3, 2020.

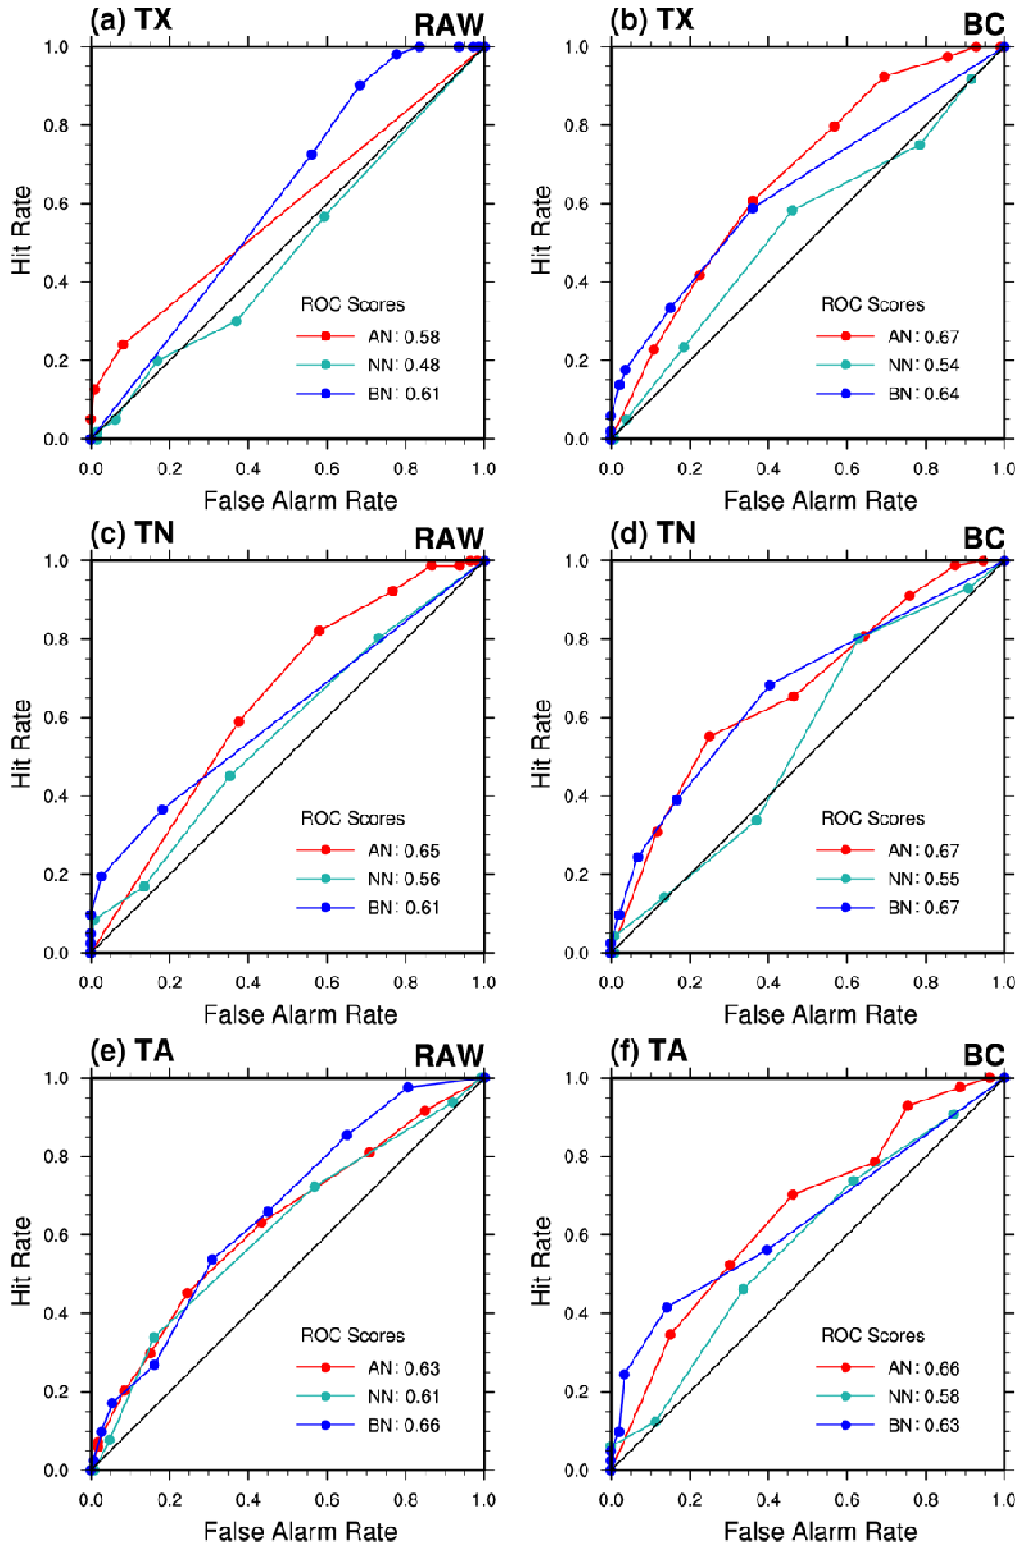


Figure 172. ROC curve and score for week3 tercile-based forecasts: (left) raw forecast and (right) bias-corrected forecast.

(나) 기상청 현업모델 편차보정을 통한 최고·최저기온 1개월 확률예보 방안

① 평균기온에 대한 1개월 장기예보 현업활용

본 연구결과는 기상청 기후예측과와의 주기적인 실무협력회의를 통해 결과를 공유하였으며, 최종 결과는 기상청 1개월 장기예보 현업에 활용되는 토대를 마련하였다. 특히, 기상청에서 수행 중이던 편차보정 관련 연구결과와 비교하여, 세부적인 방법론 비교를 통해 기존 결과보다 개선된 결과를 도출할 수 있었다. 또한 우리나라를 중심으로 최고, 최저기온에 대한 편차보정 특성을 분석한 결과로써, 기상청 기후예측과의 장기예보 서비스 개선 계획에 따라, 최고, 최저기온의 3분위 확률예측 가능성을 제시하였다. 그리고 본 연구에서 제시한 1개월 전망을 위한 편차보정 알고리즘을 기후예측과의 “확률장기예보가이던스시스템/역학모델예측”에 반영함으로써, 단정예보의 편차값을 보정하여 평균, 최고, 최저기온 예측정확도 향상과 함께 최고, 최저기온 장기전망 서비스 개발에 기여할 수 있을 것이다(Figure 173).

APCC 편차보정 알고리즘(1개월 전망) 적용 및 현업화 알림

【 2020. 11. 25(수) / 기후과학국 기후예측과 】

배경 및 목적

- (배경) GLoSea5의 3분위 예측결과 '높음'의 비중이 상대적 높고, 기온 예측의 편의(bias)가 일정값을 유지(최저/평균/최고:-4/+1/-1)
- (목적) 단정예보의 편차값을 보정하여 평균·최고·최저기온 예측정확도 향상과 함께 최고/최저기온 장기전망 서비스 개발에 기여

추진 경과 : 주요 개발 및 검증

- (방법1) 관련 논문*의 알고리즘을 활용하여 통계보정계수 산출 및 적용
 - * 참고논문: Kharin et al. 2017, A Post-processing Method Seasonal Forecasts Using Temporally and Spatially Smoothed Statistics
 - 보정계수 산출 알고리즘 : **적자별 관측과의 공분산과 분산의 비율** 생성

$$\sigma_{i,m} = \frac{Cov(F_{i,m}, O_{i,m})}{\sqrt{Var(F_{i,m})}}$$
 - Cov : 앙상블 평균 예측과 관측의 공분산
 - Var : 예측의 분산
 - F : i번째 적자, m번째 앙상블 평균 예측 편차
 - O : 관측
 - 통계적 훈련자료 및 기간 : GLoSea5의 과거재현자료(26년/1991~2016) ↔ ECMWF 재분석장(ERA5)
- ☞ **글로벌 영역에서는 조금 개선되었지만, 남한 영역은 개선 효과 미미**
 - * 평균기온에 대해 '높음'보다 상대적으로 '비슷' 비중 상향 조정되어서, '높음'의 정확도 하락, '비슷' 정확도 상승, 평균기온 적중률 하락(12.4%p↓)
- (방법2) 남한지역을 중심으로 1개월 전망의 기온예측 보정 개선 추진*
 - * APCC 협업: 2차례 협력회의를 통한 검증으로 APCC의 자체 통계보정식 개발
 - 보정 산출 알고리즘: 편의값(Bias)과 편의기후값(Bias climatology) 사이의 통계산출식 개발 [참고1]
 - 통계적 훈련자료 및 기간: GLoSea5의 과거재현자료(91~16) 및 예측자료(17~20)
- ☞ **최고기온>평균기온>최저기온 순으로 보정효과 검증**
 - * (적중률) 최고기온: 7.7%p↑ / 평균기온: 1.1%p↑ / 최저기온: 18.5%p↓
 - * (RMSE) 최고기온: 1.5↓, 평균기온: 0.1↓, 최저기온: 0.18↓
 - * (BIAS) 최고기온: 2.6↓, 평균기온: 0.3↓, 최저기온: 0.6↓

현업화 반영

- 최고/최저기온, 평균기온에 대한 보정치를 관측과 연계하여 시계열 그래프 형태로 시스템 반영
 - 변수: 1.5m 최고/최저/평균 예측 기온
 - 남한지역 평년관측지점(45개소)의 3주간 편차값을 8주간 예측편차값과 이에 대한 보정값을 시계열로 연속 표현
 - 표출메뉴위치: 확률장기예보가이던스시스템/역학모델예측(11월16일 이후)

향후 계획

- (21년 상반기) 편차보정된 예측자료(최고, 평균)에 대한 예측성 평가와 최저기온 보정에 대한 적용을 개선
- (21년 하반기) 실행년 적용에 따른 예측성 검증 및 개선

Figure 173. A document from KMA/CPD for operational use of APCC bias correction method for the purpose of 1-month forecast(공문서: 기후예측과-2746(2020. 11. 25.).

② 우리나라 1개월 기온 장기예보 서비스 개선(안)

현재 제공되는 1개월 기온 장기전망(3분위 예보)와 최고·최저기온 전망(3분위 예보)의 통합 방안을 아래와 같이 제시하였다. 즉, 본 연구결과를 통해 최고·최저기온 뿐 아니라, 평균기온에 대해서도 본 연구결과물을 활용하여 기존 기상청 1개월 기온 전망을 개선할 수 있을 것이다(Figure 174).



1개월전망

(2020년 6월 1일 ~ 6월 28일)

기 상 청
2020년 5월 21일 11시 발표
※ 다음 1개월 전망은 2020년 5월 28일 11시 발표




Figure 174. (top) Released from KMA at Mary 21, 2020 for 1-month forecast and (bottom) an example of tercile-based probabilistic forecast of maximum and minimum temperature.

③ 최고·최저기온에 대한 2분위 확률예보 방안

기상청 현업모델 예측정보를 활용한 이상기후(여름철) 1개월 장기예보 방안을 Figure 175 와 같이 제시해 보았다. 이 때, 주별 폭염 및 열대야 정의는 기후평년(30년; 1990~2019년) 동안 예보기간에 해당하는 최고, 최저기온의 95퍼센타일 값으로 정의하였다. 실제 기상청에서 사용하는 폭염의 경우, 폭염 주의보는 일 최고 기온이 33도 이상인 상태가 2일 이상 지속될 것으로 예상될 때, 그리고 폭염 경보는 일 최고 기온이 35도 이상인 상태가 2일 이상 지속될 것으로 예상될 때로 정의한다. 하지만 이는 단기예보에 적합한 기준으로, 장기예보에서는 그대로 사용할 수 없기 때문이다. 하지만 기후예측모델의 95퍼센타일 값으로 정의했을 때, 주별 일 최고

기온 또한 33도~35도로 근접하기 때문에 이와 같이 정의하였다.

또한, 폭염을 정의하기 위해 다양한 방법이 제시된 바 있다. Mandal et al.(2019)는 3월~6월까지의 최고기온의 일별 기후값의 95퍼센타일 이상인 경우인 동시에 최고기온이 36도 이상이고, 그 아노말리가 3.5도 이상인 경우로 정의하였다. Kuglitsch et al.(2010)는 6월~9월까지의 최고, 최저기온의 기후값의 95퍼센타일 이상인 값을 hot day 와 hot night으로 정의하였는데, 이 값이 3일 이상 지속된 경우로 정의하였으며, 이를 사용하여 폭염 강도, 폭염 기간, 폭염일수 등을 정의한 바 있다. Lee et al.(2016)은 최고기온이 관측기후값의 95퍼센타일 이상인 경우, 모델 기후값의 95퍼센타일 이상인 경우가 동시에 발생할 때로 정의하였고, 이를 잘 설명할 수 있는 대기순환지수로서 200hPa 와도(vorticity)의 차이로 폭염강도(HWI)를 정의하였다. 한편, Hong et al.(2018)은 폭염과 열대야를, 각 최고기온과 최저기온이 90퍼센타일 이상일 때로 정의하였다.

Figure 175는 편차보정한 최고, 최저기온을 활용하여 여름철 폭염 또는 열대야에 대한 주별 확률예보 예이다. 주별 2분위 확률예보에 대한 검증 결과는 WPC(Weighted Percent Correct) 기준 최고기온은 80, 최저기온은 65로 2분위 확률예보에 대한 정확도가 어느 정도 확보되며, 주별로 큰 차이가 없는 것으로 나타났다. WPC의 경우, 100일 때 완벽한 예보, 50 이하일 때 정확도가 없는 것으로 판단한다. 따라서 본 연구결과물을 바탕으로 현재 1개월 전망에서는 제공되지 않는 이상저온 및 이상고온에 대한 보완자료로 활용할 수 있을 것이다(예시: Figure 176).




Figure 175. An example of two-category forecasts of heatwave and tropical night from the GloSea5 bias-corrected maximum and minimum temperature.

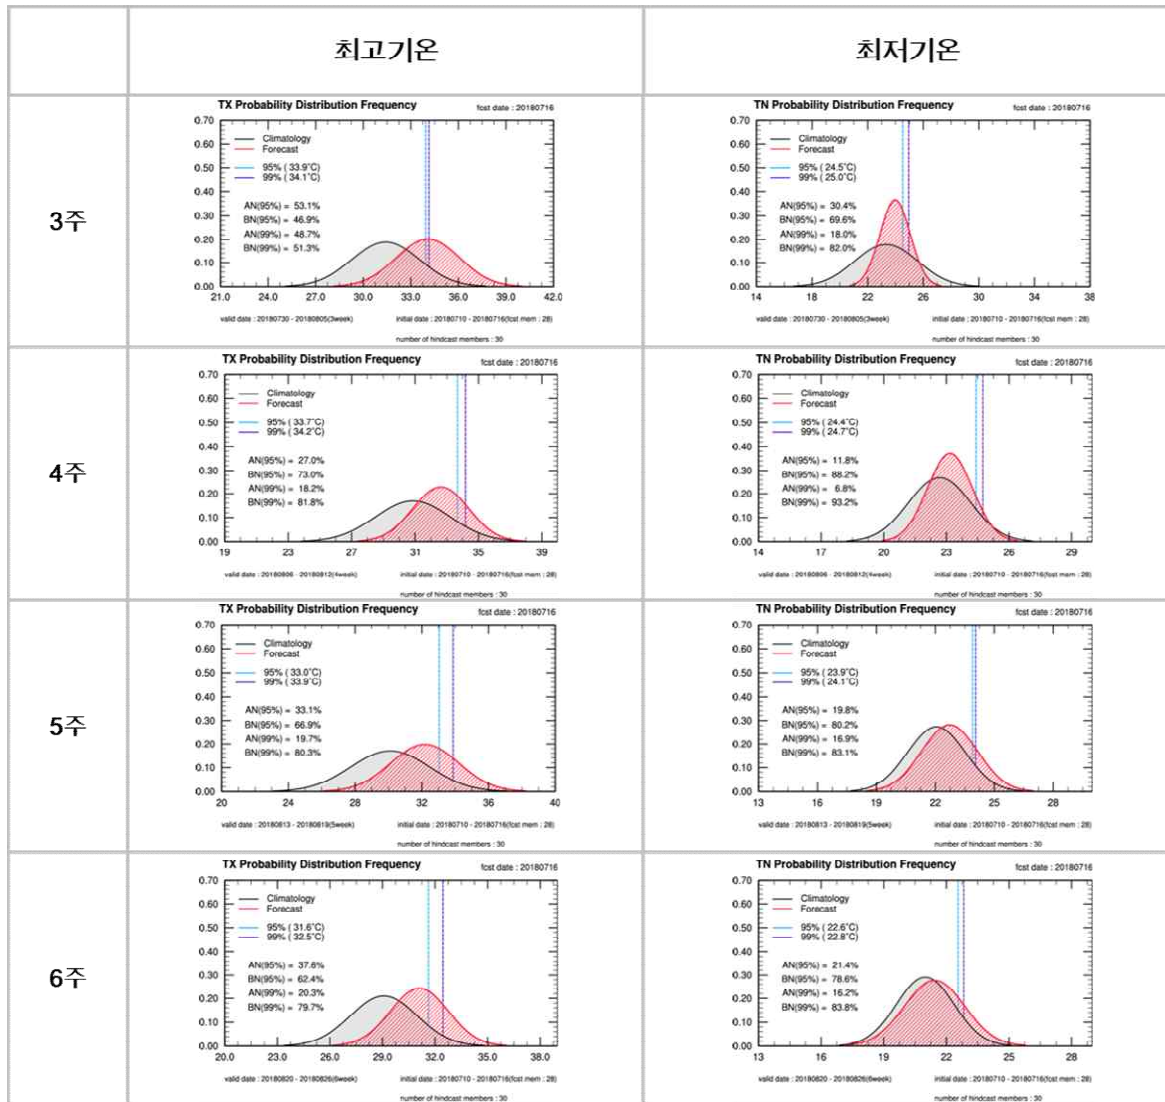


Figure 176. An example of two-category forecasts of (left) maximum and (right) minimum temperature for each week (forecast date: Jul. 16, 2018).

4. 요약 및 결론

본 과제에서는 우리나라 이상기후 장기 전망 정보 개선을 위해서 흑서기 감시 정보 및 원인 분석서 생산, 1-3개월 예측 콘텐츠 개발을 목표로 하여 연구가 수행되었으며, 주요 연구 결과들을 정리하면 다음과 같다.

먼저 이상기후 감시 정보 콘텐츠 확대 및 가시화 개선을 위해서 2019년에 구축된 APEC 기후센터 웹 페이지 내 이상기후 감시 정보 자동화 시스템 체계와 관련하여, 월별 및 주별로 나뉘어져 있는 감시 정보들을 월별 자료로 통합하면서 자동화 체계는 더욱 단순화 시키면서 웹 서비스로 제공하는 감시 정보는 더욱 풍부하게 생산하고자 했다. 월별 및 주별 감시 정보를 모두 월별 감시정보로 통합하고, 이에 다양한 부가 정보를 추가하여 월별 감시 정보 하나로도 여러 가지 양상을 함께 살펴 볼 수 있도록 개선하였다. 월별 감시 정보로 통합하면서, 공

간적인 분포 설명과 더불어 한반도 지역에 대한 과거 값 대비 현재의 순위를 알 수 있는 랭크 부가 정보, 그리고 주별 정보를 대신할 순별 이상기후 발생일수 등을 추가하여 매월 동아시아 및 한반도 지역에 대한 이상기후 분석에 대한 이해를 더욱 높이고자 했다. 또한 다양한 감시 정보를 카테고리 별로 합치며 통합맵을 추가로 생산하여 제공하였다. 최대 강수 사상 및 재현 기간 정보를 통합하여 이상기후 통합맵으로, SPI, SEDI, SMI를 통합하여 가뭄 통합맵으로 추가 생산하였다. 또한 이러한 감시 정보를 해석하는 데에 있어 더욱 더 쉽게 이상기후를 이해할 수 있도록 각 감시 정보에 대한 설명 및 부가 정보에 대한 설명을 더하여 해석 가이드를 생산하고 웹 페이지에 감시 정보와 함께 제공된다. 이 연구를 통해 웹 서비스 시스템을 더욱 효율적으로 개선할 수 있었으며, 이상기후 감시 정보에 대한 이해도를 더욱 높여 이상기후 감시 정보 통합 시스템으로 활용도가 더욱 높아질 것이라고 기대할 수 있다.

또한 본 연구에서는 이상 기후 전망에서 활용되는 혹서 감시인자 정보 개선 및 확대를 위해서 예측성의 변동성을 포함한 기존의 혹서기 기온에 대한 감시 인자의 특성을 분석하고 감시 인자 상세 역학과정 검증 시스템을 개발하여 2020년 7월의 경우에 적용하였다. 개발된 상세 역학 과정 검증 시스템은 1) 감시 인자와 대기 변수(HGT200, HGT850, OMG500)와의 지점별 상관관계(과거 39년, 1981-2019)를 감시 인자가 한반도 주변에 미치는 영향으로 규정, 2) 2020년 예측하고자 하는 월에 해당 대기 변수의 편차장(지점별)을 계산, 3) 1)과 2)의 공간적 유사성을 동아시아 지역의 패턴 상관관계(PCC)로 계산함으로써 해당 감시 인자가 상층, 하층 지위 고도와 중층 수직운동장에 미치는 영향이 2020년에 잘 구현되었는지를 확인하는 시스템이다. 본 연구에서는 세 대기변수 중 최소 두 변수의 PCC가 0.25 이상일 경우를 상세 역학 과정이 구현된 경우로 정의하였다. 그 결과 6월, 7월, 8월의 감시 인자 중 7월의 경우 4월 동인도양 SST 인자, 8월의 경우 2월의 호주 북쪽 SST 인자의 상세 역학 과정이 2020년에 잘 구현된 것으로 나타났다. 기대한 바와 같이, 이 인자들이 전망한 2020년 한반도 기온 경향성(7월 평년 이하, 8월 평년 이상)은 실제로 적중하였다.

위와 같은 긍정적인 결과를 바탕으로 상세 역학 과정 검증 시스템을 향후 예측에 활용하는 방안도 제시하였다. 2개월 선행 시점(예, 7월 예측의 경우 5월 과거 상관관계와 2020년 5월 편차장 비교)에서 상세 역학 검증 시스템으로 계산된 PCC(예, 7월 예측의 경우 5월 과거 상관관계와 2020년 5월 편차장 비교)를 고려할 경우 ACC가 최대 47% 까지 증가하였기 때문이다. 이는 감시 인자의 모니터링 뿐 아니라 감시 인자가 대기와 해양에 미치는 영향을 함께 모니터링 할 경우 감시 인자 모니터링을 통한 예측성이 향상될 수 있음을 시사한다. 이러한 시스템이 실질적으로 예측에 활용되기 위해서는 다양한 인자들에 대해 다양한 검증 기준에 대한 추가적인 테스트가 필요하다. 예를 들어 SST_WP, SST_IO등과 같이 열대 해양에 기반을 둔 감시 인자들의 경우 HGT200, HGT850, OMG500의 인자에 대한 한반도 주변 동아시아 지역의 PCC 값이 동일한 부호의 높은 PCC 값을 갖는 경우가 많았다. 그러나 북극이나 대서양 지역에 기반한 감시 인자들의 경우 한개의 인자(주로 HGT200)와 주로 높은 상관성을 보였는데 이는 이러한 인자들이 상층 파동 전파를 통해 한반도 기온에 영향을 끼치는 경우가 많기 때문인 것으로 추측된다. 따라서 인자별로 PCC 계산 지역과 변수 등의 기준을 조절함으로써 상세 역학 과정 검증 시스템의 유용성을 증가시킬 수 있을 것으로 보인다.

한편 1990년대 이후로 한반도 여름철 온도와 관련성이 높은 이른 봄철 POL 원격상관 패

턴이 여름철 한반도 기온에 미치는 역학을 분석하여 새로운 예측인자로 제시하였다. POL 패턴은 극지역인 동시베리아 해로부터 열대 서태평양에 걸친 지역에 파동 형태의 지위도고 편차를 유도하는 것으로 알려져 있다. 봄철 음의 POL 패턴은 대기 저층 남아시아에 저기압성 흐름, 북서태평양에 고기압성 흐름을 유도하여 열대 서태평양 및 필리핀 해에 남동풍을 유도, 봄철 필리핀해 SST를 증가 시킨다. 이때 필리핀해 주변에서 상층 양의 지위고도 편차와 하강기류가 나타나 대류는 억제된다. 여름철이 되면서 비로소 극심히 가열된 필리핀해 주변에서 대류가 활발해지며 그 보상작용으로 북쪽에 위치한 한반도와 동아시아에 하강기류와 함께 키 큰 고기압이 발달하여 한반도에 고온과 폭염이 발생하게 된다. 이러한 이른 봄철의 대기 패턴이 한반도 여름철 기온과 폭염에 미치는 상세한 기작을 모식도(Figure 22)로 나타내었다.

지면 조건의 이상기후 감시 인자로서 활용을 위해서 자기조직화지도(Self-organizing Map) 기법 등을 도입 하였다. 지면조건과 한반도의 폭염의 상관성을 분석하기 위해, 1979년부터 2019년까지 45개 표준관측지점(ASOS)의 일최고기온으로 지역폭염 발생일을 산정하였다. 총 172회 지역폭염이 발생한 것으로 나타났으며, 7월이 83회로 가장 많이 발생했고, 6월은 19회로 가장 적은 발생횟수를 보였다. 각 지역폭염일에 해당하는 ERA-5 T2m 자료(20-50°N과 110-150°E)로부터 자기조직화지도 기법을 사용하여 3개 군집으로 분류하였다. 군집 분류 결과, 2번 노드가 88개로 가장 많았으며, 3번 노드에는 21개로 가장 적게 분류되었다. 노드별 Z500 합성장으로부터 1번 노드는 P-J 패턴과 유사하였으며, 3번 노드에서 해양보다는 지면의 영향이 한반도 폭염에 영향을 주는 것으로 판단 되어, 3번 노드에 대해 토양수분 합성장 추가 분석을 실시하였다. 3번 노드의 토양수분 합성장에서 폭염 발생 30일과 60일 전 유라시아(40-60°N과 0-30°E) 지역 토양 수분 부족이 나타났으며(유의확률 90%에서 유의), 올해 6월 폭염에 대해서도 선행시간 30일과 60일에 동일한 지역에 비슷한 패턴을 보여 감시인자 활용 가능성이 있을 것으로 판단 된다. 다만, 감시인자로 활용하기 위해 해당 영역의 토양수분과 한반도 폭염과의 상관성 및 상호작용에 대한 추가 연구가 필요할 것으로 판단 된다.

올해 2020년 여름철은 기온/강수의 월 변동이 심한 해들 중 하나였으며, 특히 6월 이상 고온과 7월 이상 강수/저온 발생은 기록적으로 높았다. 본 연구에서 2020년 여름철 한반도 기후 변동은 태평양-인도양-대서양의 기후 모드들의 결합 기작이 주요 원인으로 제시되었다. 2019/20 엘니뇨 발달 이후 2020년 봄철에 쇠퇴하는 동안 대기 bridge 기작에 의해서 북인도양의 해수면 온도가 상승하였으며, 이것이 강제력이 되어 북서태평양 고기압 편차가 발달하였다. 이 북서태평양 고기압 편차는 한반도에 고온 다습한 공기를 유입하여 6월과 8월 동안 한반도 기온 상승을 7월에는 한반도 북동쪽에서 발달한 고기압성 순환 편차에 의하여 유입된 찬공기와 만나 한반도에 이상 강수를 유발 하였다. 한반도 북동쪽에서 발달한 고기압성 순환 편차는 여름철 음의 NAO 관련 원격상관과 관련이 있는 것으로 분석 되었는데, 여름철 NAO 발생은 엘니뇨 발달 이후 대기 bridge 기작에 의한 봄철 북 열대 대서양 해수면 온도 상승과 관련이 있었다. 1980년 이후 14개의 엘니뇨 이벤트 중 9개의 엘니뇨 이벤트에서 위의 관계가 작동하여 이상 강수 혹은 이상 저온이 발생하였다. 그런데 9개의 이벤트 중 8개가 양의 AMO 위상에서 발생한 것으로 확인되었다. 태평양-인도양-대서양 결합 관계와 관련된 인자들의 상관관계 분석은 AMO와 ENSO가 같은 위상일 때 통계적 유의성이 증가함을 보여주었으며, 이는 격년 변동의 기후 모드와 한반도 기후와의 관계를 더 시간 주기를 가진 AMO 같은 기후 모드가 조절할 수 있다는 것을 시사한다. 즉, 상대적으로 짧은 격년 변동의 시간 규모를 가진 기후 인자와

여름철 한반도 기후와의 관계가 장 주기 기후 모드의 위상에 따라 달라 질 수 있다는 의미이다. 더욱이 한반도 기후와 높은 상관관계를 갖는 기후 인자들이 최근 decade에서 유의성이 급격히 감소하는 한가지 이유인 것으로 보인다. 그러므로 장주기 기후 전망에서 예측 기후 인자들의 최선의 활용을 위해서 장주기 기후 모드의 위상을 고려하는 격년 변동 모드와 한반도 기후 관계에 대한 포괄적인 분석이 필요하다. 위와 같은 원인 분석 결과들을 기반으로 하여 2020년 혹서기 원인 분석서가 작성 되었다(부록 C).

그리고 본 연구에서 이상기후 예측 정보 개선 및 확대를 위해서 두 개의 통계적 기반 모델들을 구축하였다. 첫 번째로 지위고도 편차와 폭염일수사이의 상관성을 기반으로한 유사해를 선정하여 추계학적 폭염 예측 모델을 개발하였는데, Tmax와 폭염일수를 Pearson r 기준 0.3-0.7 정도의 예측성능을 보였고 선행시간이 길어질수록 성능은 감소하는 것으로 나타났다. 기존의 통계모형의 성능 정도로 볼 수 있지만 그 모형들이 고려하지 못했던 최장 폭염지속시간과 같은 폭염의 시간의존성을 고려할 뿐만아니라 폭염위험의 공간적 상관까지 모두 간단히 고려할 수 있는 실용적인 예측기법이라 할 수 있다. 특히 Markov chain bootstrapper는 전이확률을 제외하면 매개변수가 전혀 없고 관측자료를 뒤섞는 방법이기 때문에 분포 적합성과 같은 기술적 문제를 구조적으로 가지지 않는 것이 장점이다. 그러나 2020년 6-8월 예측 결과에서 나타난 것처럼 과거 자료에만 의존하기 때문에 기록의 범위 바깥에 있는 사상은 잡아낼 수 없는 단점은 분명하다. 2020년 한 달이 넘는 긴 장마는 증발량을 증가시켜 평년에 비해 현열이 크게 감소했을 것이고 이에 따라 7월 기온은 평년 수준을 밑돌게 되었다. 2020년 폭염예측이 벗어난 원인은 기온 그 자체가 아닌 많은 강수에 있었기 때문에 다변량 분석이 유사해를 선정할 때 필수적임을 의미한다. 또한 Weather bootstrapper에 장기 기온 변화 추세를 샘플링 기법에 추가하는 것은 온난화 신호를 Tmax 예측에 반영할 수 있도록 하기 위한 주요 개선사항 중 하나이다.

두 번째로 이상기후 3개월 장기예보 콘텐츠를 개발하고 이를 효과적으로 나타낼 수 있는 표현방식을 제시하고자 베이지안 추론 기반 모델인 가우시안 프로세스의 기계학습을 이용하여 전국 및 지역별 혹서기 이상기후지수 3개월 확률전망정보를 생산하였다. 이를 위해 장기예보 가이드언스의 예측인자와 선행감시시점을 이용한 모델, 장기예보 가이드언스의 예측인자와 선행감시시점을 이상기후지수와의 상관관계를 이용하여 선정한 모델, 군집분석을 통해 도출한 예측인자를 이용한 모델, 군집분석 도출 예측인자의 주성분을 이용한 모델을 각각 구축하여 확률전망정보를 생산하였으며, Bayesian Model Averaging을 이용하여 다양한 전망정보를 통합하였다. 특히 군집분석을 통한 모델들과 결합 모델의 이상기후지수 예측 성능이 우수함을 확인하였다. 또한 삼분위 다이어그램과 Hue-Saturation-Value (HSV) 색상 모델을 이용하여 삼분위 확률예측정보를 지역별로 시작적으로 전달하는 이상기후 전망정보 표현방식을 제시하였다.

이상기후 전망 정보 개선/확대를 위해서 통계 기반 모델들을 구축한 것 뿐만 아니라 기존 기상청 현업모델의 예측 결과들을 이상 기후 전망에서 활용하기 위해서 개선 방안을 제시 하였다. 한반도 여름철 극한기온 확률예측성 평가를 위해 9개 권역별(경기(GG), 경남(GN), 경북(GB), 영동(YD), 영서(YS), 전남(JN), 전북(JB), 충남(CN), 충북(CB))로 나누어 GloSea5와 ECMWF의 극한기후 예측성을 AUC를 기준으로 평가하였으며, 두 모델의 AUC는 권역별로 서로 비슷한 수준으로 나타났다. GloSea5의 hindcast (2019ver과 2020ver)는 Tmax 경우 6월, 7월, 8월, JJA에서 cold bias가 발견되며, Tmin의 경우는 warm bias가 발견되었다. 두 모델의 극한기후

최적 기준값은 AUC를 기반으로 Tavg 경우, 상·하위 15%를 극한기후기준값으로 선정하면 대부분 권역별 AUC>0.5 의 예측성 보였으며, 3분위 전망의 예측성과 유사한 수준에서 5분위 예보가 가능할 것으로 나타났다. AUC를 기준으로 하는 유사한 방법으로 Tmax와 Tmin에 대한 기준값은 2분위 예보가 적절해 보였으며, 2020년 6월, 7월, 8월 예보에 적용하였다. 6월은 Tavg, Tmax, Tmin 모두 관측치와 유사하게 전망하였으나, 7월의 경우, 관측에서는 Tavg, Tmax, Tmin 모두 평년값보다 매우 낮았으나, GloSea5는 여전히 높게 전망하였다. 따라서 GloSea5의 예측성 향상을 위한 추가 연구가 필요할 것으로 판단 된다.

그리고 기상청 현업모델 편차보정을 통하여 최고·최저기온 1개월 확률예보 방안을 제시하였다. 최근 몇 년 간 기후예측모델의 3분위 예측결과 ‘높음’의 비중이 상대적으로 높고, 기온 예측의 편의가 일정값(최고/최저/평균: -1/-4/+1)을 유지하는 경향을 보여 왔다. 따라서 이러한 기후예측모델의 단정예보의 편차값을 보정하여 평균, 최고, 최저기온 예측정확도를 향상시키는 한편, 최고, 최저기온 장기전망 서비스 개발에 기여하기 위한 연구를 진행하였다. 현재, 기후예측과에서 수행해온 격자별 관측과의 공분산과 분산의 비율을 통한 보정계수 산출 알고리즘을 활용한 편차보정의 경우, 글로벌 영역에서는 조금 개선되지만, 남한 영역에서는 개선 효과가 미비하였다. 따라서 본 연구에서는 기후예측모델의 편의값과 편의기후값 사이의 통계산출식 개발을 통해 편차를 보정할 수 있는 방안을 개발하고, 실제예측자료를 활용하여 예측성을 검증하였다. 실제 본 연구에서 제시한 편차보정방법을 활용했을 때, 평균적으로 편차(bias)와 제공근오차(rmse)가 감소하였는데, 특히 최고기온에서 보정효과가 가장 크게 나타났다. 또한 적중률(accuracy)에 대해 검증한 결과에서도, 최고기온(7.7%↑)과 평균기온(1.1%↑)은 개선되었다. 하지만, 최저기온(18.5%↑)의 경우 적중률이 하락하여 이에 대한 추가 연구가 필요하다. 본 결과를 바탕으로 기온 장기전망 예측성 향상과 함께, 최고, 최저기온 장기전망 서비스 개발에 기여할 수 있으며, 특히 올해에는 기상청 ‘확률장기예보가이던스시스템’을 통해 현업화하여 예측결과를 제공함으로써, 이를 통해 예보관의 의사결정을 지원하고 있다.

본 연구 결과에서 제시한 편차보정을 통한 예측결과는 다음과 같이 이상기후 장기예보 서비스 콘텐츠로 활용가능 할 것이다. 특히, 주별 폭염 및 열대야 정의를 기후평년(30년; 1990~2019)동안 예보기간에 해당하는 최고, 최저기온의 95퍼센타일 값으로 정의하는 등, 최고, 최저기온에 대해 일정 threshold 이상/이하일 2분위 확률을 제시하여, 여름철 폭염 또는 열대야 주별 예보에 참고자료로 활용 가능하다. 주별 2분위 확률예보에 대한 검증에서도 일정 수준 이상의 정확도를 보였으며, 주별 정확도도 비슷하기 때문에 이상기후 현업예보에 활용 가능할 것이다.

사사

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

References

- 기상청 기후예측과, 2018: 기후감시 및 분석 기반의 장기예보 가이드스(III). 기상청, 266 pp.
- 백승윤, 김상욱, 정명일, 노준우, 손석우, 2018: 자기조직화지도를 이용한 서울 폭염사례 분류연구. *한국기후변화학회지* 9(3), 209-221.
- 임슬희, 2018: 우리나라 기온과 강수량의 과거 극값 사례 분석집. 기상청. 187p.
- 임슬희, 2019: 우리나라 기온의 과거 극값사례 심층분석집. 기상청. 71p.
- 임원일, 서경환, 2018: 자기조직화지도(Self-Organizing Map)를 이용한 최근 우리나라 여름철 극한온도 특성 분류. *한국기상학회 대기*, 28(3), 305-315.
- 추정은, 하경자, 2011: 동아시아 여름몬순 지수의 자기조직화지도(SOM)에 의한 강수량의 계절 내 진동 분류, *한국기상학회 대기*, 21(3), 221-228.
- Alexander, M. A., I. Blade, M. Newman, J. R. Lanzante, and N.-C. Lau, 2002: The atmospheric bridge: the influence of ENSO teleconnection on air-sea interaction over the global oceans. *Journal of Climate*, **15**, 2205-2231.
- Apipattanavis, S., G. Podestá, B. Rajagopalan, and R. W. Katz, 2007: A semiparametric multivariate and multisite weather generator, *Water Resources Research*, **43**, W11401, doi:10.1029/2006WR005714.
- Arribas A., M. Glover, A. Maidens, K. Peterson, M. Gordon, C. Maclachlan, R. Graham, D. Fereday, J. Camp, A. Scaife, P. Xavier, P. McLean, A. Colman, S. Cusack, 2011: The GloSea4 Ensemble Prediction System for Seasonal Forecasting. *Monthly Weather Review* **139**, 1891-1910.
- Baldwin, J. W., J. B. Dessy, G. A. Vecchi, and M. Oppenheimer, 2019: Temporally compound heat wave events and global warming: An emerging hazard. *Earth's Future*, **7**, 411-427. <https://doi.org/10.1029/2018EF000989>.
- Bárdossy, A., 1998: Generating precipitation time series using simulated annealing, *Water Resources Research*, **34**(7), 1737-1744.
- Barnston, A. G., and S. J. Mason, 2011: Evaluation of IRI's seasonal climate forecasts for the extrem 15% tails. *Weather and Forecasting*, **26**, 545-554.
- Becker, E. J., van den Dool, and Pena M., 2013: Short-term climate extremes: prediction skill and predictability. *Journal of Climate*, **26**, 512-530.
- Buishand, T. A., and T. Brandsma, 2001: Multisite simulation of daily precipitation and

- temperature in the Rhine basin by nearest-neighbor resampling, *Water Resources Research*, **37**(11), 2761–2776.
- Camargo, S. J., M. C. Wheeler, A. H. Sobel, 2009: Diagnosis of the MJO Modulation of Tropical Cyclogenesis Using an Empirical Index. *Journal of Atmospheric Science*, **66**, 3061–3074.
- Chand, S. S., K. J. E. Walsh, 2010: The Influence of the Madden-Julian Oscillation on Tropical Cyclone Activity in the Fiji Region. *Journal of Climate*, **23**, 868–886.
- Chen, X. C. Li, J. Ling, Y. Tan, 2017: Impact of East Asian winter monsoon on MJO over the equatorial western Pacific. *Theoretical and Applied Climatology*, **127**, 551–561.
- Choi, N., M.-I. Lee, D.-H. Cha, Y.-K. Lim, and K.-M. Kim, 2020: Decadal changes in the interannual variability of heat waves in East Asia caused by atmospheric teleconnection changes. *Journal of Climate*, **33**, 1505–1522.
- Choi, Y.-W., and J.-B. Ahn, 2019: Possible mechanisms for the coupling between late spring sea surface temperature anomalies over tropical Atlantic and East Asian summer monsoon. *Climate Dynamics*, **53**, 6995–7009.
- Ding, Q., and B. Wang, 2005: Circumglobal teleconnection in the northern hemisphere summer. *Journal of Climate*, **18**, 3483–3505.
- Donaldson, G. C., W. R. Keatinge, and R. D. Saunders, 2003: Cardiovascular responses to heat stress and their adverse consequences in healthy and vulnerable human populations. *International Journal of Hyperthermia*, **19**, 225–235.
- Enfield, D. B., and D. A. Mayer, 1997: Tropical Atlantic sea surface temperature variability and its relation to El Niño–Southern Oscillation, *Journal of Geophysical Research*, **102**(C1), 929.
- Fischer, E. M., Seneviratne, S. I., Vidale, P. L., Luthi, D., & Schar, C. (2007). Soil moisture–atmosphere interactions during the 2003 European summer heat wave. *Journal of Climate*, **20**(20), 5081–5099.
- Foufoula-Georgiou, E., and K. P. Georgakakos, 1991: Hydrologic advances in space-time precipitation modeling and forecasting, in *Recent Advances in the Modeling of Hydrologic Systems*, edited by D. S. Bowles, and P. E. O’Connell, pp. 47– 65, Springer, New York.
- Gusan H., Y. Zhu, E. Sinsky, W. Li, X. Zhou, D. Hou, C. Melhauser, R. Wobus, 2019: Systematic error analysis and calibration of 2-m temperature for the NCEP GEFS reforecast of the subseasonal experiment(SubX) Project. *Weather and Forecasting*, **34**, 361–376.
- Hall, J. D., A. J. Matthews, D. J. Karoly, 2001: The Modulation of Tropical Cyclone Activity in

- the Australian Region by the Madden-Julian Oscillation. *Monthly Weather Review*, **129**, 2970–2982.
- Ham H., D. Won, Y.-S. Lee, 2017: Performance Assessment of Weekly Ensemble Prediction Data at Seasonal Forecast System with High Resolution. *Korean Meteorological Society*, **27**, 261–276. (in Korean).
- Hong, Jin-Sil, S. W. Yeh, K.-H. Seo, 2018: Diagnosing physical mechanisms leading to pure heat waves versus pure tropical nights over the Korean Peninsula. *Journal of Geophysical Research: Atmospheres*, **123**, 7149–7160.
- Huang, B., V. F. Banzon, E. Freeman, J. Lawrimore, W. Liu, T. C. Peterson, T. M. Smith, P. W. Thorne, S. D. Woodruff, and H.-M. Zhang, 2014: Extended Reconstructed Sea Surface Temperature version 4 (ERSST.v4): Part I. Upgrades and intercomparisons. *Journal of Climate*, **28**, 911–930.
- Im, E.-S., Thanh, N.-X., Kim, Y.-H., and Ahn, J.-B. (2019), 2018 summer extreme temperatures in South Korea and their intensification under 3°C global warming. *Environmental Research Letters*, **14**, 094020, <https://doi.org/10.1088/1748-9326/ab3b8f>.
- Jupp, T. E., R. Lowe, C. A. S. Coelho, and D. B. Stephenson, 2012: On the visualization, verification and recalibration of ternary probabilistic forecasts. *Philosophical Transactions of the Royal Society A*, **370**, 1100–1120.
- Kalnay, E., and Coauthors, 1996: The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, **77**, 437–471.
- Katz, R. W., 1977: Precipitation as a chain-dependent process, *Journal of Applied Meteorology*, **16**(7), 671–676.
- Katz, R. W., and M. B. Parlange, 1995: Generalizations of chain-dependent processes: Application to hourly precipitation, *Water Resources Research*, **31**(5), 1331–1341.
- Kharin, V. V., W. J. Merryfield, G. J. Boer, W. S. Lee, 2017: A postprocessing method for seasonal forecasts using temporally and spatially smoothed statistics. *Monthly Weather Review*, **145**, 3545–3561.
- Klein, S. A., B. J. Soden, and N.-C. Lau, 1999: Remote Sea Surface Temperature Variations during ENSO: Evidence for a Tropical Atmospheric Bridge. *Journal of Climate*, **12**(4), 917–932.
- Kuglitsch, F. G., A. Toreti, E. Xoplaki, P. M. Della-Marta, C. S. Zerefos, M. Turkes, J. Luterbacher, 2010: Heat wave changes in the eastern Mediterranean since 1960. *Geophysical Research Letters*, **237**, L05802.

- Lall, U., and A. Sharma, 1996: A nearest neighbor bootstrap for time series resampling, *Water Resource Research*, **32**(3), 679–693.
- Lee, E., R. Bieda, J. Shanmugasundaram, and H. Basara Richter, 2016: Land surface and atmospheric conditions associated with heat waves over the Chickasaw Nation in the South Central United States. *Journal of Geophysical Research: Atmospheres*, **121**, 6284–6298. <https://doi.org/10.1002/2015JD024659>.
- Lee, H.-J., W.-S. Lee, J. H. Yoo, 2015: Assessment of medium-range ensemble forecasts of heat waves. *Atmospheric Science Letters*, **17**, 19–25.
- Lee, W. S., and M. I. Lee, 2016: Interannual variability of heat waves in South Korea and their connection with large-scale atmospheric circulation patterns. *International Journal of Climatology*, **36**, 4815–4830, <https://doi.org/10.1002/joc.4671>.
- Ledford, A. W. and J. A. Tawn, 1996: Statistics for near independence in multivariate extreme values. *Biometrika*, **83**, 169–187.
- Lettenmaier, D., 1995: Stochastic modeling of precipitation with applications to climate model downscaling, in *Analysis of Climate Variability: Applications of Statistical Techniques*, edited by H. von Storch, and A. Navarra, pp. 197– 212, Springer, New York.
- Li, X., G. Gollan, R. J. Greatbatch, R. Lu, 2017: Intraseasonal variation of the East Asian summer monsoon associated with the Madden-Julian Oscillation. *Atmospheric Science Letters*, **19**, e794.
- Lim, W., and K. Seo, 2019: Physical-Statistical Model for Summer Extreme Temperature Events over South Korea. *Journal of Climate*, **32**, 1725–1742.
- Lissner, T. K., A. Holsten, C. Walther, and J. P. Kropp, 2012: Towards sectoral and standardized vulnerability assessments: the example of heatwave impacts on human health. *Climate Change*, **112**, 687–708.
- MacLachlan C., A. Arribas, K. A. Peterson, A. Maidens, D. Ferday, A. A. Scaife, M. Gordon, M. Vellinga, A. Williams, R. E. Comer, J. Camp, P. Xavier, G. Madec, 2015: Global Seasonal forecast system version5(GloSea5): a high-resolution seasonal forecast system. *Quarterly Journal of Meteorological Society*, **141**, 1072–1084.
- Mandal, R., S. Joseph, A. K. Sahai, R. Phani, A. Dey, R. Chattopadhyay, D. R. Pattanaik, 2019: Real time extended range prediction of heat waves over India. *Scientific Reports*, **9**, 9008.
- McMichael, A. J., R. E. Woodruff, and S. Hales, 2006: Climate change and human health: present and future risks. *The Lancet*, **367**, 859–869.
- Min, S.-K., Y.-H. Kim, S.-M. Lee, S. Sparrow, S. Li, F. C. Lott, P. A. Stott, 2020: Quantifying human impact on the 2018 summer longest heat wave in South Korea. *Bulletin of*

American Meteorological Society, **101**, S103–S108.

- Monhart S., C. Spirig, J. Bhend, L. Bogner, C. Schar, M. A. Liniger, 2018: Skill of subseasonal forecasts in Europe: Effect of bias correction and downscaling using surface observations. *Journal of Geophysical Research: Atmospheres*, **123**, 7999–8016.
- Nitta, T., 1987: Convective activities in the tropical western Pacific and their impact on the Northern Hemisphere summer circulation. *Journal of Meteorological Society, Japan*, **65**, 373–390, https://doi.org/10.2151/jmsj1965.65.3_373.
- Raftery, A. E., T. Gneiting, F. Balabdaoui, and M. Polakowski, 2005: Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review*, **133**, 1155–1174.
- Rajagopalan, B., and U. Lall, 1999: A k-nearest-neighbor simulator for daily precipitation and other variables, *Water Resources Research*, **35**(10), 3089– 3101.
- Rajagopalan, B., U. Lall, D. G. Tarboton, and D. S. Bowles, 1997: Multi-variate nonparametric resampling scheme for generation of daily weather variables, *Stochastic Hydrology and Hydraulics*, **11**(1), 523–547.
- Ren, F., D. Cui, Z. Gong, Y. Wang, X. Zou, Y. Li, S. Wang, and X. Wang, 2012: An objective identification technique for regional extreme events, *Journal of Climate*, **25**(20), 7015–7027.
- Robertson, A. W. , C. R. Mechoso, and Y.-J. Kim, 2000: The influence of the Atlantic sea surface temperature anomalies on the North Atlantic Oscillation, *Journal of Climate*, **13**, 122–138.
- Semenov, M. A., and J. R. Porter, 1995: Climatic variability and the modeling of crop yields, *Agricultural and Forest Meteorology*, **73**, 265–283.
- Semenze, J. C. et al., 1996: Heat-related deaths during the July 1995 heat wave in Chicago. *New England Journal of Medicine*, **335**, 84–90.
- Stefanon, M., F. D’ Andrea, and P. Drobinski, 2012): Heatwave classification over Europe and the Mediterranean region, *Environmental Research Letters*, **7**(1), 014023.
- Tachibana, Y., T. Iwamoto, M. Ogi, and Y. Watanabe, 2004: Abnormal meridional temperature gradient and its relation to the Okhotsk high. *Journal of Meteorological Society of Japan*, **82**(5), 1399–1415.
- Taraphdar, S., F. Zhang, L. R. Leung, X. Chen, O. M. Pauluis, 2018: MJO Affects the Monsoon Onset Timing Over the Indian Region. *Geophysical Research Letters*, **45**, 10011–10018.
- Trigo, R. M., and J. P. Palutikof, 1999: Simulation of daily temperatures for climate change scenarios over Portugal: A neural network model approach, *Climate Research*, **13**, 45– 59.

- Vanos, J. K., L. S. Kalkstein, and T. J. Sanford, 2015: Detecting synoptic warming trends across the US Midwest and implications to human health and heat-related mortality. *International Journal of Climatology*, **35**, 85–96.
- Wang, P., J. Tang, S. Wang, X. Dong, and J. Fang, 2017: Regional heatwaves in China: a cluster analysis. *Climate Dynamics*, **50**(5–6), 1901–1917, doi:10.1007/s00382-017-3728-4.
- Wang, Y., Q. Song, Y. Du, J. Wang, J. Zhou, Z. Du, and T. Li, 2019: A random forest model to predict heatstroke occurrence for heatwave in China. *Science of the Total Environment*, **650**, 3048–3053. <https://doi.org/10.1016/j.scitotenv.2018.09.369>.
- Wheeler, M. C., H. H. Hendon, 2004: An All-Season Real-Time Multivariate MJO Index: Development of an Index for Monitoring and Prediction. *Monthly Weather Review*, **132**, 1917–1932.
- Wheeler, M. C., H. H. Hendon, S. Cleland, H. Meinke, A. Donald, 2009: Impacts of the Madden-Julian Oscillation on Australian Rainfall and Circulation. *Journal of Climate*, **22**, 1482–1498.
- Wehrens, R., and J. Kruisselbrink, 2018: Flexible Self-Organizing Maps in kohonen 3.0. *Journal of Statistical Software*, **87**(7), 1–18. doi:10.18637/jss.v087.i07.
- Wehrens, R., and L. M. C. Buydens, 2007: Self- and Super-Organizing Maps in R: The kohonen Package. *Journal of Statistical Software*, **21**(5), 1–19. doi: 10.18637/jss.v021.i05.
- Wilks, D. S., and R. L. Wilby, 1999: The weather generation game: A review of stochastic weather models. *Progress in Physical Geography*, **23**, 329– 357.
- Winter, H. C., and J. A. Tawn, 2017: kth-order Markov extremal models for assessing heatwave risks. *Extremes*, **20**, 393–415. <https://doi.org/10.1007/s10687-016-0275-z>
- Woolhiser, D. A., 1992: Modeling daily precipitation: Progress and problems, in *Statistics in the Environmental and Earth Sciences*, edited by A. T. Walden, and P. Guttorp, pp. 71– 89, Edward Arnold, London.
- Winter, H.C., and J. A. Tawn, 2017: kth-order Markov extremal models for assessing heatwave risks. *Extremes*, **20**, 393–415.
- Xie, S.-P., K. Hu, J. Hafner, H. Tokinaga, Y. Du, G. Huang, and T. Sampe, 2009: Indian Ocean Capacitor Effect on Indo-Western Pacific Climate during the Summer following El Niño. *Journal of Climate*, **22**, 730–747.
- Xie, S.-P., Y. Kosaka, Y. Du, K. Hu, J. S. Chowdary, and G. Huang, 2016: Indo-western Pacific Ocean capacitor and coherent climate anomalies in post-ENSO summer: A review. *Advances in Atmospheric Sciences*, **33**, 411–432.

- Yates, D., S. Gangopadhyay, B. Rajagopalan, and K. Strzepek, 2003: A technique for generating regional climate scenarios using a nearest-neighbor algorithm, *Water Resources Research*, **39**(7), 1199, doi:10.1029/2002WR001769.
- Yoon, D., D.-H. Cha, M.-I. Lee, K.-H. Min, J. Kim, S.-Y. Jun, and Y. Choi, 2020: Recent changes in heatwave characteristics over Korea. *Climate Dynamics*, **55**, 1685–1696.
- Yoon, D., D.-H. Cha, G. Lee, C. Park, M.-I. Lee, K.-H. Min, 2018: Impacts of synoptic and local factors on heat wave events over southeastern region of Korea in 2015. *Journal of Geophysical Research: Atmosphere*, **123**(21), 12081–12096.
- Young, K. C., 1994: A multivariate chain model for simulating climatic parameters from daily data, *Journal of Applied Meteorology*, **33**, 661–671.
- Zhang, W., X. Mei, and X. Geng, 2019: A nonstationary ENSO-NAO relationship due to AMO modulation. *Journal of Climate*, **32**, 33–43.
- Zhang, X., G. Hegerl, F. W. Zwiers, and J. Kenyon 2005: Avoiding Inhomogeneity in Percentile-Based Indices of Temperature Extremes. *Journal of Climate*, **18**, 1641–1651.

부록 A. 기후 이슈 선제 기후 자료 기상청 지원

호주 산불 관련

【 2020. 1. 21.(화)/ APEC기후센터 기후분석과 】

□ 현황

- 9월 초 뉴사우스웨일스 주 북부지역에서 시작하여, 호주 전역에서 2020년 1월 현재까지 진행
 - 특히 뉴사우스 웨일스 주를 비롯하여 빅토리아 주 등 호주 남동부 지역에서 큰 피해(그림 1)
- 호주 정부 당국 발표를 보면, 1월 8일 기준으로 산불로 숲 1,070만 헥타르가 불에 탐. 건물 5,900여 채가 불에 탔고, 최소 28명이 사망. 산불 피해 지역에서 산불 연기로 인해 많은 주민들이 호흡곤란 호소
 - ※ 호주 전문가들은 산불로 인해 10억 마리 이상의 동물의 죽은 것으로 추정

□ 기상 현상

- 12월 폭염이 아주 강했으며, '20년 1월 중순까지 이어졌고, 강한 바람까지 동반되어 산불 활동을 더욱 증가시킴.
 - 특히 12월 18일 호주 전 지역 평균이 41.9도였고, 이는 기존의 최고 기록이었던 2013년 1월 7일의 40.3도를 경신
- '20년 1월 16일 호주 남동부에 폭우가 내리면서, 산불은 잠시 소강상태가 됨.
 - 한편, 잿더미로 변한 산에서 산사태 발생과 흘러내린 빗물이 강과 호수 등 수원을 오염시킬 수 있다는 우려가 있음.
- 산불로 배출된 대량의 이산화탄소는 지구 온난화에 기여할 가능성

이 있음.

□ 원인

- 2019년 9월~12월(봄철) 강수량이 최근 120년 기간 중 최저치를 기록하면서 심각한 봄 가뭄 발생, 가뭄의 여파로 산불 위험이 컸음.(그림 2)
 - 열대 서인도양이 따뜻하고 동인도양이 차가운 양의 IOD 현상이 5월부터 시작되어 7월부터 매우 강하게 발달
 - 9월 이후 IOD 현상이 더욱 강화되었으며, 강도가 역대 최고였던 '06년보다 훨씬 컸으며 12월 말까지 유지됨(그림 2a).
- ※ IOD: Indian Ocean Dipole
- 양의 IOD는 남인도양의 고온 다습한 공기의 유입을 감소시켜 호주에 강수가 억제됨(그림2b).
 - 즉, 호주 봄철 양의 IOD는 호주의 강수를 감소(특히 호주 남동부 지역)시켜 여름철 산불의 전제 조건(precondition)을 제공
- 장기화된 가뭄과 강한 폭염 상황이 산불 발생을 더욱 악화
 - 뇌우를 동반하는 산불적란운(pyrocumulonimbus)이 비를 동반하지 않고 번개를 발생시켜 외딴 곳에 산불 발화시키며 상황을 악화시킴.
- 최근 양의 IOD 발생이 증가하는 추세이며, 지구 온난화가 진행되면, 양의 IOD가 더 빈번해질 것이라는 연구들이 있음. 기후변화가 호주의 산불을 더 악화시킬 수 있다고 호주 과학자들은 경고

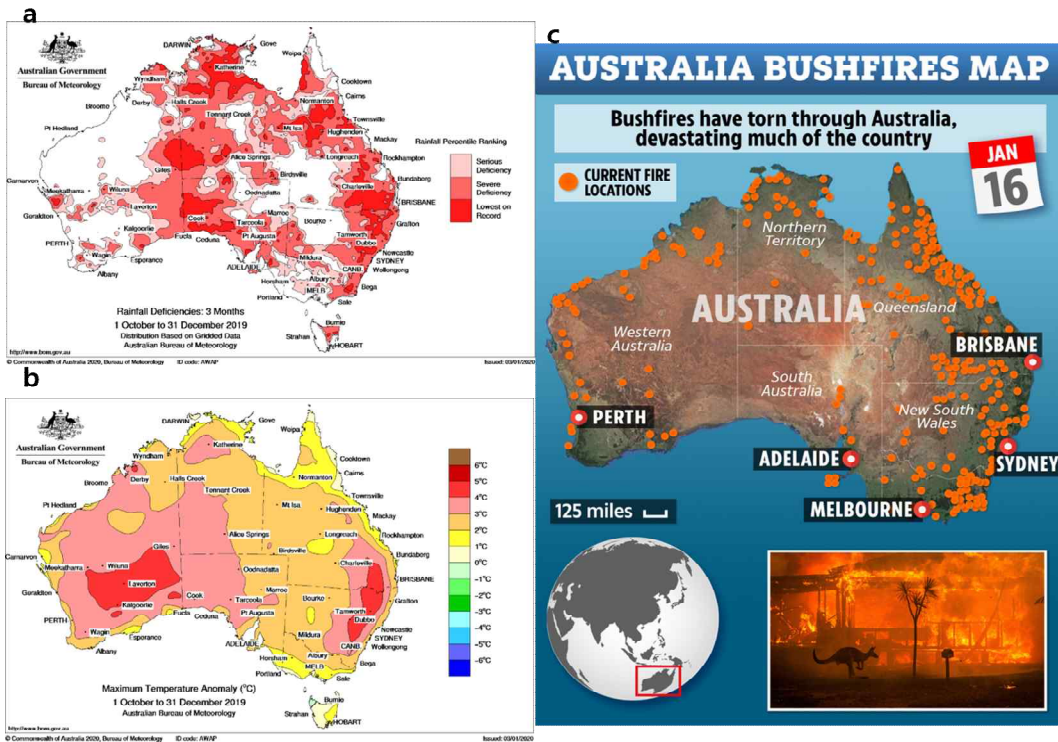


그림 177. (a) 호주 3개월(10월-12월) 평균 강수 부족량, (b) 최대 기온 3개월 평균 편차도(출처: www.bom.gov.au/climate/maps) (c) 2020년 1월 16일 호주 산불 상황 지도(출처:thesun.co.uk)

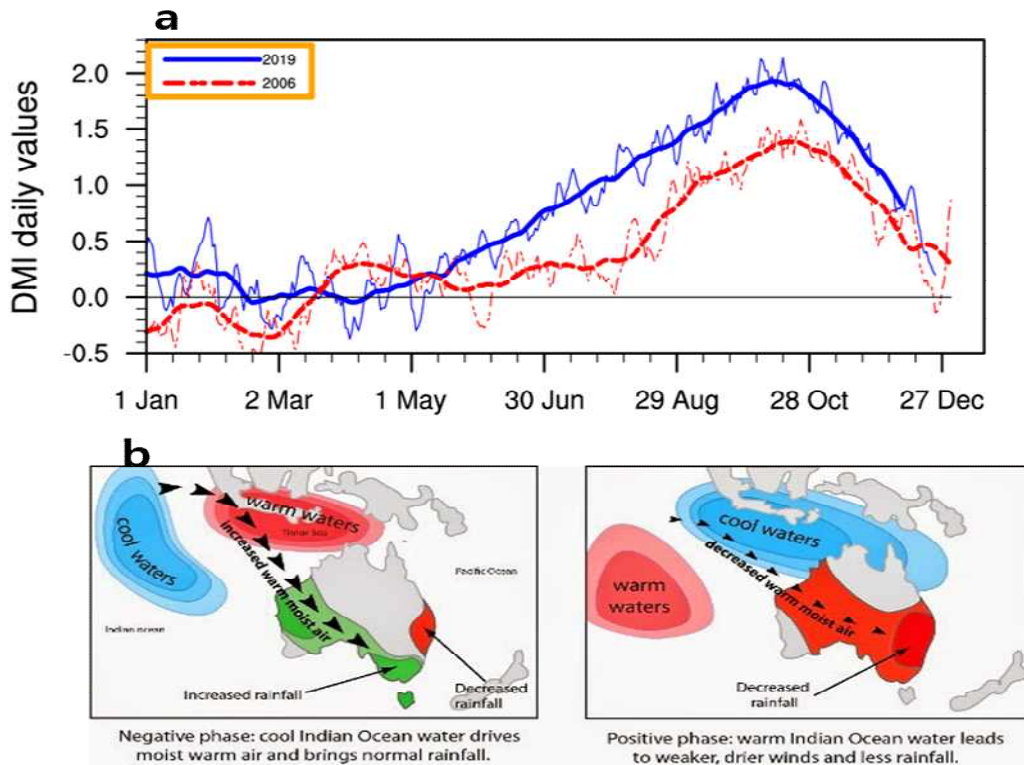


그림 178. (a) 2019년 동안 IOD 지수의 시계열(출처: <http://enformtk.u-aizu.ac.jp>), (b) IOD 위상별 호주 강수 영향 모식도(출처: <https://takvera.blogspot.com/2014/06/indian-ocean-dipole-set-to-triple.html>)

6월 중국 폭우 관련

【 2020. 7. 2.(목) / APEC기후센터 기후분석과 】

□ 현황

- 아주 드문 경우로 중국 기상청은 6월 2일 부터 29일째 계속해서 중국 남부 지역에 폭우 경보를 내리고 있음(그림 1). 중국 남부 지역 평균(20N-35N, 110E-120E)된 6월 30일까지 총강수량은 306mm 이며, 이는 1998년과 2017년 기록(각각 292mm, 301mm)을 넘긴 것임

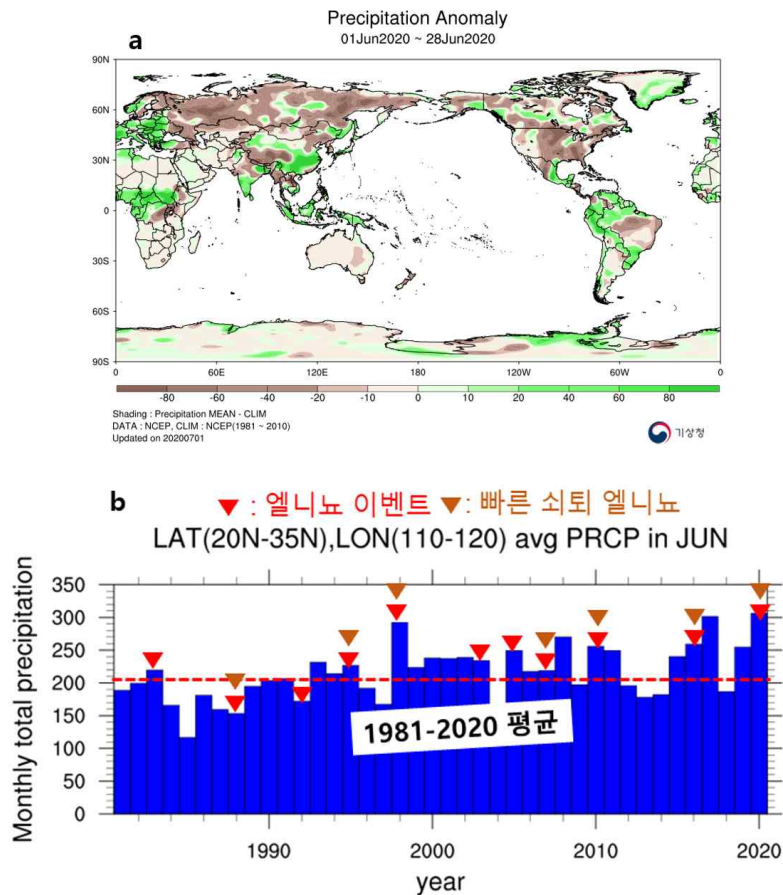


그림 1. (a) 2020년 6월 총강수량 평년 편차 분포 와 (b) 중국 남부지역 평균 총강수량 시계열 (NOAA CPC Daily Gauge-based 강수량 자료)

- 세계 최대 댐인 산샤댐 인근의 후베이성 이창에는 27일까지 폭

우 경보가 내린 가운데 가장 높은 등급으로 3시간 이상 내린 강우량이 100mm 이상인 경우 발령되는 3일 연속 ‘홍색 폭우 경보’가 내려짐. 29일부터는 올해 처음 들어 산샤댐의 수문을 개방하여 긴급 방류를 시작함.

- 중국매체에 의하면 수해 피해자가 1200만 명, 10만여 채의 가옥 붕괴 등 약 4조 3000억 원에 달하는 경제 손실을 입었다고 잠정 평가했음.

□ 기상 현상

- 6월 동안 중국 남부 오른쪽으로 고기압성 순환이 발달하였으며, 이는 중국 남부 지역으로 고온 다습한 공기를 유입시켰으며, 이는 동아시아 북동쪽으로 형성된 저기압성 순환에 의한 찬공기와 만나 강수를 유발함(그림 2).

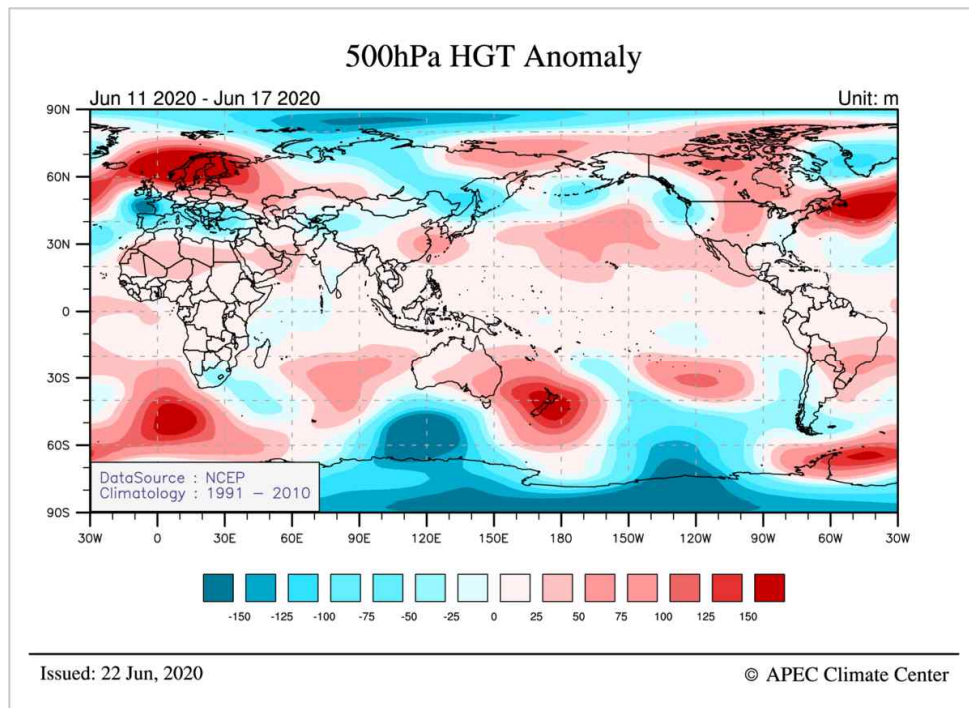


그림 2. 최근 7일 500hPa 지위고도 편차장 분포

□ 원인분석

- 현재 북서 태평양의 고기압성 순환의 발달은 엘니뇨 발달 이

후, 인도양과의 상호 작용과 일부 관련이 있음.

- 동태평양에서는 지난 겨울 (2019.12-2020.2) 약한 엘니뇨가 발달하였으며, 봄철을 지나 쇠퇴하였고, 라니냐로 발달 하고 있음 (그림 3).




그림 3. Niño3.4 지수 시계열

- 엘니뇨 발달 이후 봄철 쇠퇴기 동안, 인도양의 해수면 온도의 상승을 가져왔으며, 이는 켈빈 파 반응으로 인도양에 고기압성 순환을 유발. WES (wind-evaporation-SST) 피드백으로 고기압성 순환이 북서 태평양으로 확장함(그림 4).
- 최근 연구(Zhou et al., 2019)에서 엘니뇨 발달 이후 여름철 이전 빠르게 쇠퇴 하는 경우, 고기압성 순환이 중국 남부 근처에 잘 형성되어 이 지역에 강수를 유발함을 보여줌.

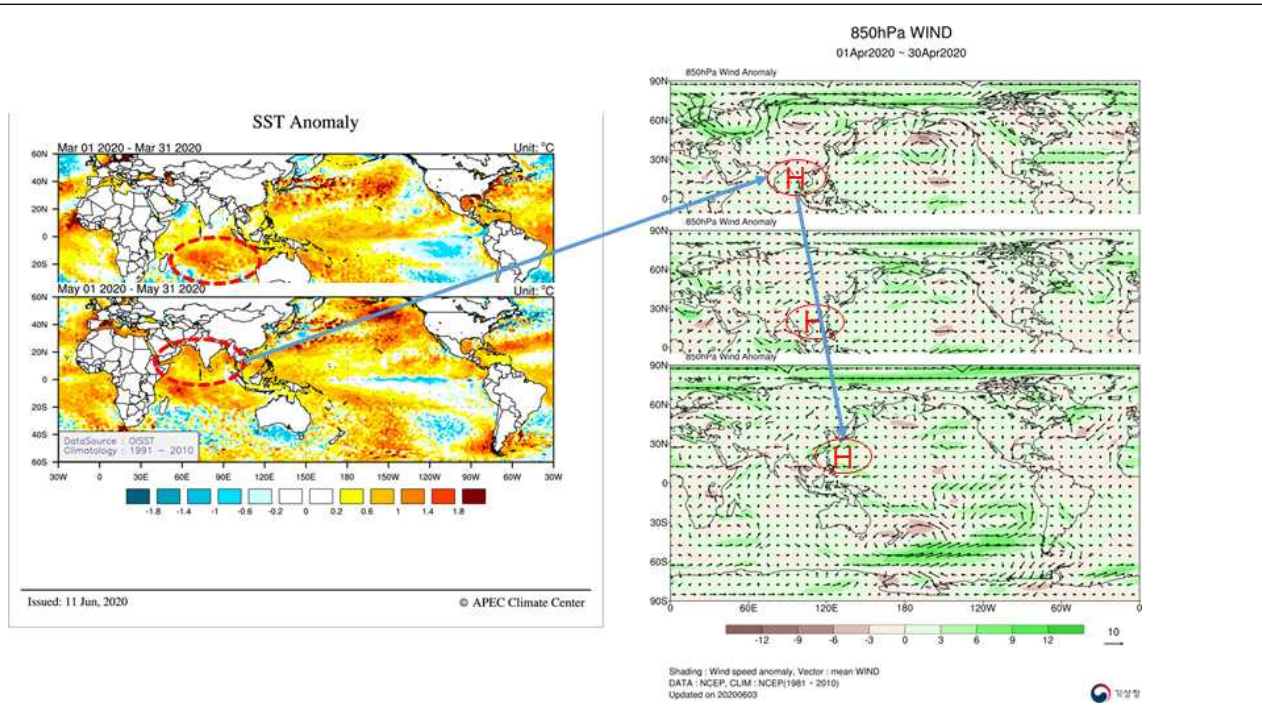


그림 4. (왼쪽) 3월, 5월 평균 해수면 온도 편차장 분포 (오른쪽) 4-6월 850hPa 바람 편차장 분포

Zhou, X., F. Liu, B. Wang, B. Xiang, C. Xing, and H. Wang, 2019: Different responses of East Asian summer rainfall to El Niño decays. *Climate Dynamics*, 53, 1497-1515.

- 비슷한 사례로는 강한 엘니뇨 이후 발생했던 1998년 대홍수가 있으며, 엘니뇨 이후 인도양 SST 편차 상승, 고기압 발달, 엘니뇨의 빠른 쇠퇴 등 비슷한 기작에 의해서 설명될 수 있음(그림 1b, 5). 그 때처럼 강한 엘니뇨가 아니었음에도 이와 버금가는 대홍수가 발생한 이유는 서태평양이 최근 강한 온난화 경향을 유지하였고, 이 때문에 다량의 고온 다습한 공기가 유입될 수 있었던 것으로 보임.

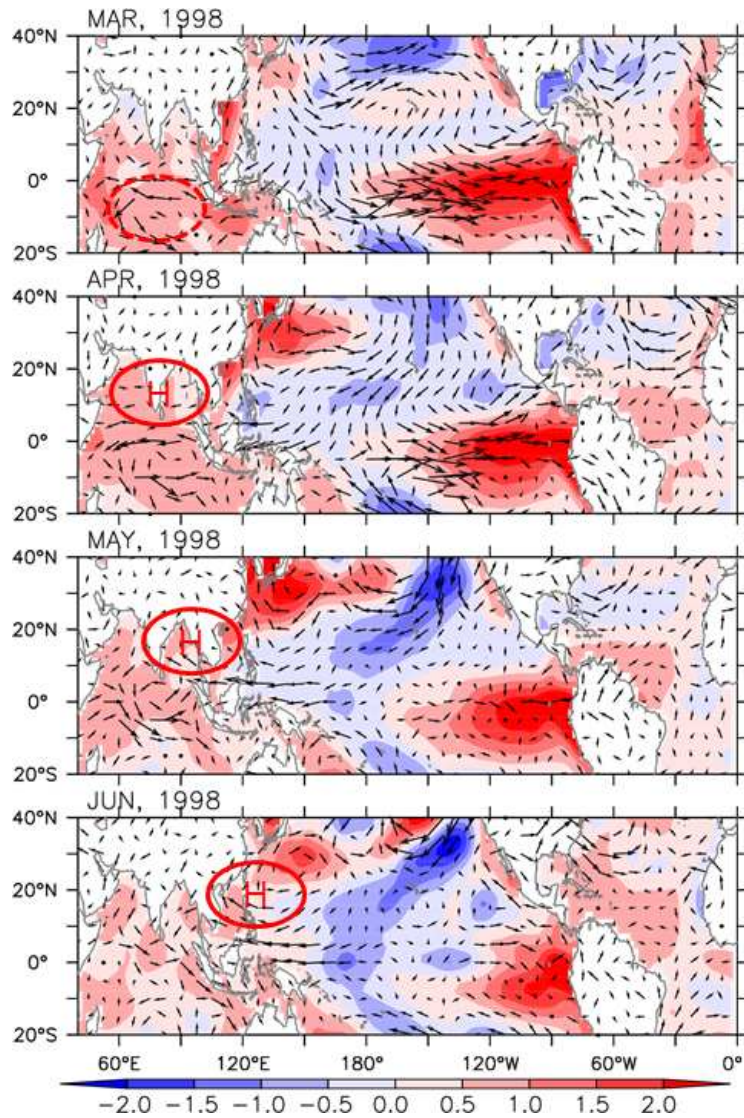


그림 5. 1998년 3-5월 평균 해수면 온도 (명암) 와 850hPa 바람장 편차장(벡터) 분포

2020년 여름철 전세계 폭염 현황

【 2020. 9. 17.(목) / APEC기후센터 기후분석과 】

이상고온 발생 현황

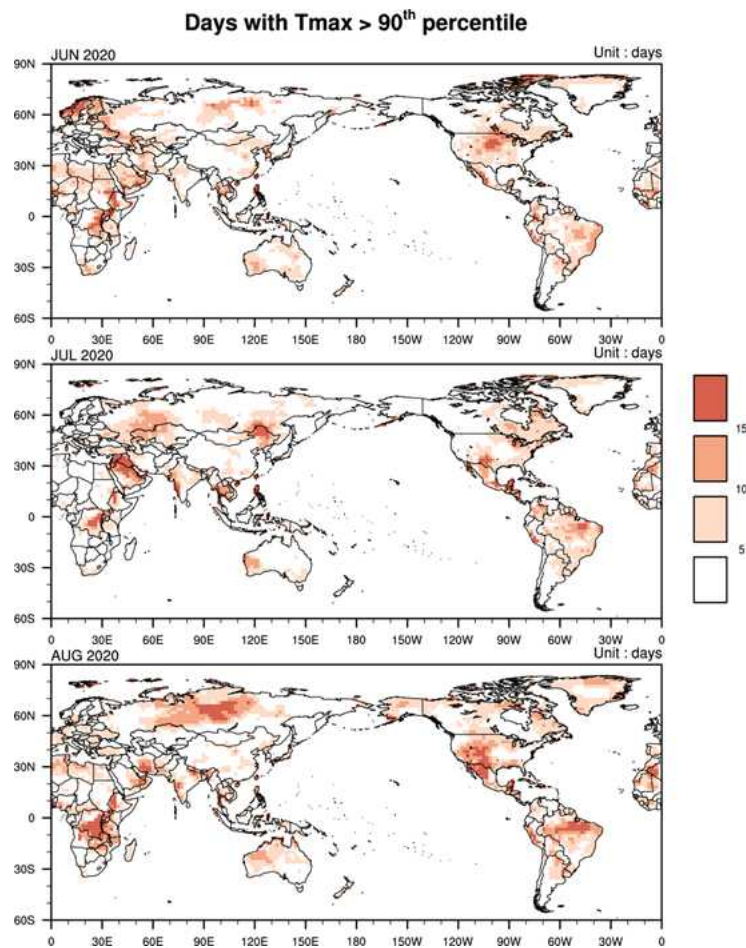


그림 184. 2020년 6, 7, 8월의 이상고온 발생일수의 전지구 공간 분포

- 그림 1은 2020년 6, 7, 8월에 발생한 전지구 이상 고온 발생일수의 공간 분포를 나타냄. 6월에는 스칸디나비아 반도, 미국 중부와 남미, 아프리카에서 이상 고온이 주로 발생하였으며, 7월에는 사우디아라비아, 북미 남서부, 시베리아 서부에서 많이 발생하였음. 8월에는 알래스카, 러시아 중북부, 북미 서부, 중남미, 아프리카 등에서 이상 고온 발생일수가 높게 나타남.
- NOAA에 따르면 2020년 6월 전지구 기온은 평년 대비 $+0.92^{\circ}\text{C}$, 전지구 육지 평균은 $+1.29^{\circ}\text{C}$ 로 역대 3위 고온을 기록하였음. 지역별로는 노르웨이에서 $+3.2^{\circ}\text{C}$ 로 1900년 관측 이래 고온 2위를

기록함. 북극에 인접한 러시아의 베르호얀스크 지역에서도 6월 20일에 1885년 관측 이후 최고기온(38℃)을 기록했으며, 6월 북극 해빙 면적은 1979년 관측 이래로 최저 3위를 기록함. 홍콩 평균 기온은 역대 2위, 최저 기온은 역대 1위를 기록함. 미국 최고 기온은 +1.7℃로 3위, 서호주는 평균 기온은 3위, 최고 기온은 1위를 기록함.

- 2020년 7월 전지구 기온은 평년 대비 +0.92℃, 전지구 육지 평균 +1.23℃로 역대 2위로 따뜻한 7월이었고, 역대 1위 기온과는 단 0.01℃ 차이를 보임. 지역적으로 카리브해 지역은 기록상 가장 더운 7월을 보였으며, 북미는 +1.31℃로 기록상 2위로 따뜻했음. 홍콩의 평균 기온은 +1.5℃로 가장 더운 7월을 기록함. 스페인의 평균 기온은 평년보다 +2.0℃로 56년 관측 역사상 3위를 기록하였고, 최고 기온은 +2.3℃로 2위를 기록. 프랑스는 7월 평균 기온이 +0.9℃로 1900년 관측 이후 1위를 기록했으며, 7월 30일에 일 최고 기온이 41.9℃를 달성하여 역대 최고 기온을 기록함. 바레인은 7월 중 23일 동안 기온이 40.0℃보다 높았으며, 1902년 이후 가장 높은 7월 평균 기온 기록. 또한 1979년 이후 가장 적은 북극 해빙 면적을 기록하였음.
- 2020년 8월에는 전지구 평균 기온이 +0.94℃로 1880년 관측 이래 2위, 육지 기온은 +1.26℃으로 3위를 기록함. 미국은 평년보다 +1.4℃로 관측 역사 126년 중 3위였으며, 8월 16일에는 캘리포니아 데스밸리의 최고기온이 54.4℃를 기록함. 북미 대륙 평균은 +1.52℃로 최고 1위, 남미는 +1.48℃로 최고 4위를 기록함. 영국은 최저 기온이 평년보다 +1.0℃로 1884년 관측 이래 3위, 프랑스도 1900년 관측 이래 3위, 유럽 대륙 또한 +2.0℃로 3위를 기록함. 일본의 하마마츠 시는 8월 17일에 최고기온이 41.1℃까지 치솟아 오르며 일본 기상청 관측 사상 최고기온을 기록함. 홍콩 또한 가장 따뜻한 8월을 기록하며, 2020년 여름철

평균 또한 기록상 가장 높았음. 뉴질랜드는 +1.2°C로 1909년 관측 이후 4번째로 높은 기온을 기록함. 8월 북극 해빙은 최저 3위를 기록함.

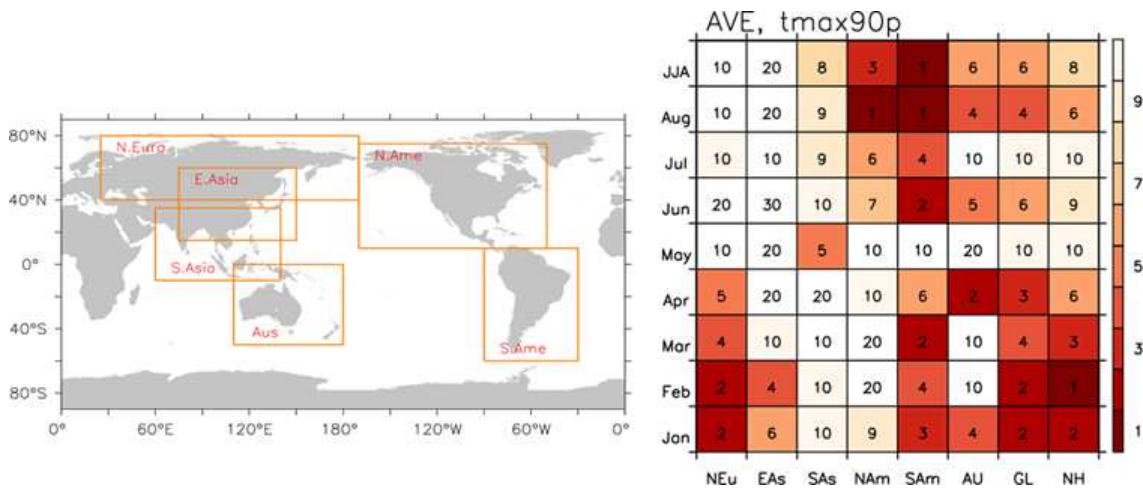


그림 185. 1981년 이후 (왼쪽) 전지구 지역별(북유라시아 NEu, 동아시아 EAs, 남아시아 SAs, 호주 AU, 북미 NAm, 남미 SAm) (오른쪽) 평균 이상 고온 발생 순위

- 2020년 여름은 대체적으로 아시아(EAs, SAs), 북유라시아(NEu) 지역의 이상 고온이 과거(1981년 이후) 대비 많이 발생하지 않았음. 특히 동아시아에서 영역 평균된 이상 고온 날수(순위)는 6월 2.8일(30위), 7월 4.1일(10위), 8월 3.7일(20위)이었음.
- 절기상 겨울인 호주(AU)는 서부 지역을 중심으로 이상 고온이 많이 발생하였음. 호주 영역 평균된 이상 고온 날수는 6월 5.2일(5위), 7월 4.2일(10위), 8월 5.8일(4위)이었음.
- 북미(NAm)와 남미(SAm)에서는 이상고온 발생이 심했음. 북미(영역평균 7.1일)와 남미(6.4일) 모두 8월에 이상 고온 발생 일수에서 1위를 기록함. 특히 8월에 미국 서부 캘리포니아 지역 주변에서 이상 고온이 15일 이상 발생하였음. 이와 관련하여 현재까지도 이어지고 있는 대형 산불이 발생함.

- 남미에서는 브라질 아마존 지역을 중심으로 이상고온이 많이 발생하였으며, 아마존 동부 지역에서는 8월까지 계속 증가하는 경향을 보임 (6월 5.4일 역대 2위, 7월 5.5일 역대 4위). 또한 아마존 열대 우림 지역 산불은 6월은 13년 만에, 8월에는 10년 만에 최악의 수준을 기록함.

□ 기상 현상


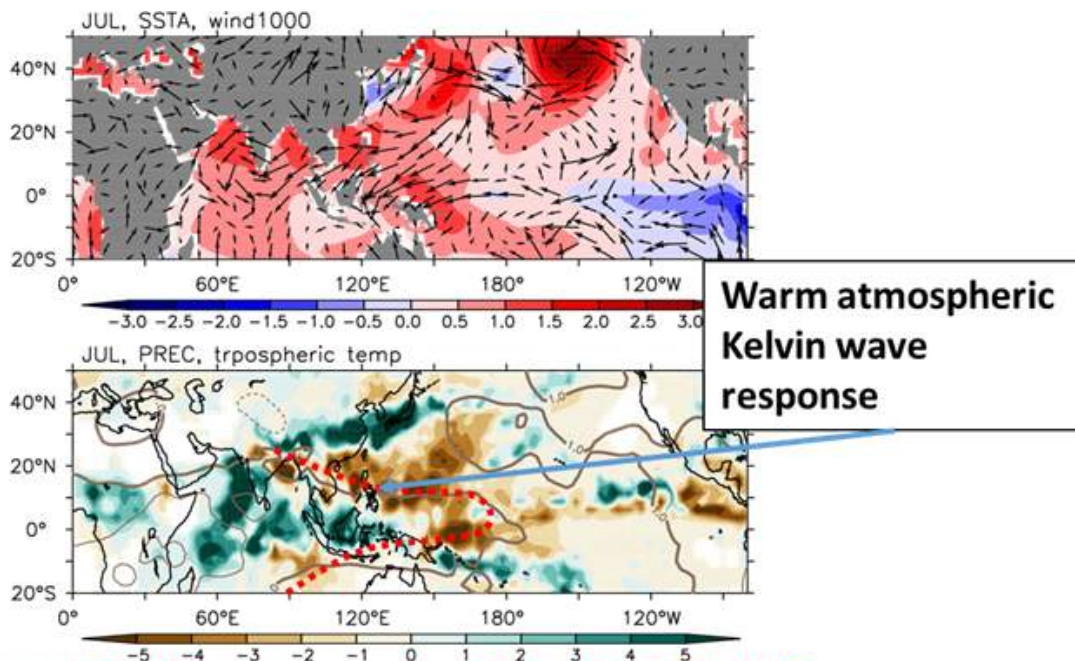


그림 186. 2020년 6-8월 500hPa 지위고도와 1000hPa 바람 편차장 분포

- 6월 동안 북서태평양에서 고기압성 순환이 발달하여 중국 남부 지역으로 해양의 고온 다습한 공기를 유입시켰으며, 중국 북동부지역에 발달된 저기압성 순환은 대륙의 고온 건조한 공기를 한반도에 유입시킴.
- 7월은 북 대서양에서 음의 NAO가 발달하였고, 북서 태평양의 고기압성 편차와 중국 북동부 지역에서 발달한 고기압성 편차 사이인 한반도 주변은 저기압성 편차를 보임.
- 8월은 북태평양에서 북미 지역까지 동서방향으로 넓게 확장된 양과 음의 지위고도 편차가 남북 방향으로 발달함. 8월과 9월에 발달하며, 북미 서부의 양의 기온 편차와 관련이 있다고 알려져 있는, PT(Pacific Transition 패턴)의 지수 값이 0.56이었음.

□ 원인분석

- 동아시아의 여름철 이상고온 발생이 적었던 이유는 북서태평양에 지속되었던 고기압 편차 발달과 관련이 있음. 6월에는 이 고기압 관련 고온 다습한 공기가 중국 남부 지역에 상당한 폭우를 발생시켰고, 7월에는 중국 북동부 지역에 발달한 고기압 편차에 의한 찬 공기와 만나 중국 남부, 한반도, 일본 지역에 폭우가 발생하게 되었고, 특히 한반도는 긴 장마를 경험함.
- 6월 한반도는 이상 고온날 수에서 2위를 기록하였는데, 이렇게 따듯했던 이유는 중국 북동부 지역에서 발달한 저기압성 편차 발달과 관련이 있으며, 이 저기압성 편차의 왼쪽의 북서풍의 고온 건조한 공기가 한반도 주변에 유입되어, 기온을 높였음.



2020년 7월 SSTA, winds, 강수, 대류권 기온

그림 187. (위) 7월 SST, 1000hPa 바람 편차장과 (아래) 강수, 250-850hPa 기온 평균 편차장 분포

- 6-7월의 북서 태평양에서 고기압성 편차의 발달은 엘니뇨 쇠퇴

이후 봄철에서 여름철 북인도양 해수면온도의 상승과 관련이 있음. 이는 인도양 Capacitor effect라고 알려져 있는데, 겨울철 엘니뇨 동안 발달한 북서 태평양 고기압성 순환 편차가 엘니뇨 쇠퇴 이후 이듬해 여름철까지 유지되어 동아시아 여름철 기후에 영향을 미친다는 것으로서, 관련된 역학(Kelvin wave 대기반응)이 잘 관측됨.(그림4)

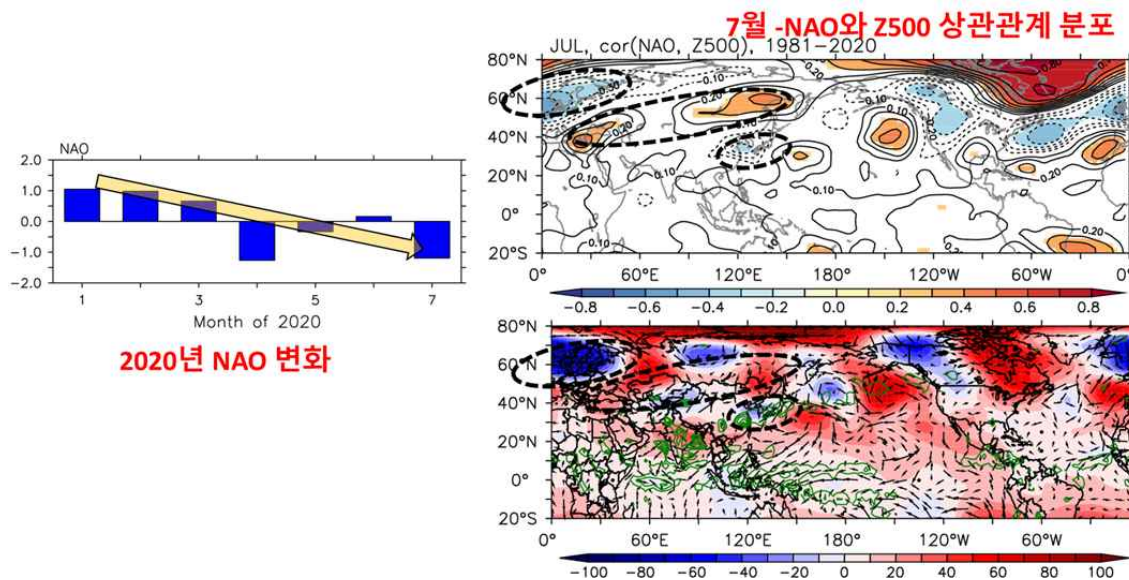


그림 188. (왼쪽) 2020년 1-7월 NAO 지수 변화 (오른쪽) 7월 음의 NAO와 500hPa 지위고도의 상관관계 분포와 7월 500hPa 지위고도 편차장

- 7월은 음의 NAO가 중국 북동쪽의 고기압성 편차의 발달과 일부 관련이 있으며, 이 고기압성 순환에 의해서 북쪽의 찬 공기가 동아시아 지역으로 유입됨. 이 찬 공기는 북서태평양에서 유입된 고온 다습한 공기와 만나 폭우를 유발 했으며, 아울러 이상 고온 발생을 감소시킴. (그림 5)
- 8월 미국 서부의 이상고온 발생은 북태평양 전반부터 미국 서부 주변까지 확장된 고기압성 편차 순환 때문인데, 이는 단열 승온과 일사량 증가를 유발함.

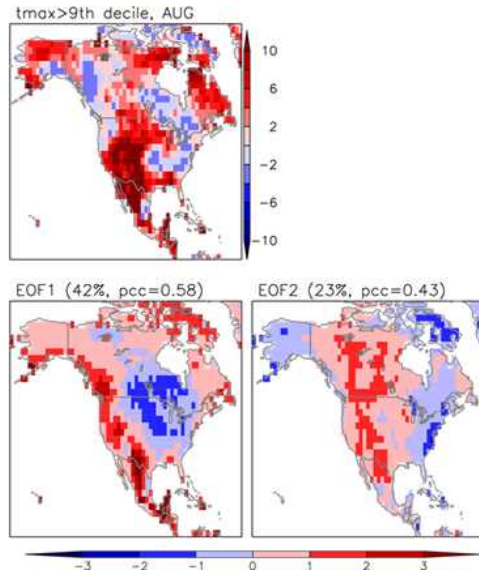


그림 189. (위) 7월 북미 이상 고온 날수 편차장 분포 (아래) 첫 번째 와 두 번째 주 성분 모드 분포

- 북미 이상 고온 발생 원인을 분석하기 위해서 북미 이상고온 날수와 주변 상층 대기장과 SVD 분석을 수행, 트렌드 (지구온난화?) 모드와 자연 변동성 관련된 모드를 분리함. 전자 관련 첫 번째 모드는 주로 북미 서부 해안 지역 이상고온 발생, 후자 관련 두 번째 모드는 북미 서부 내륙지역의 이상 고온 발생과 관련됨. (그림 6)

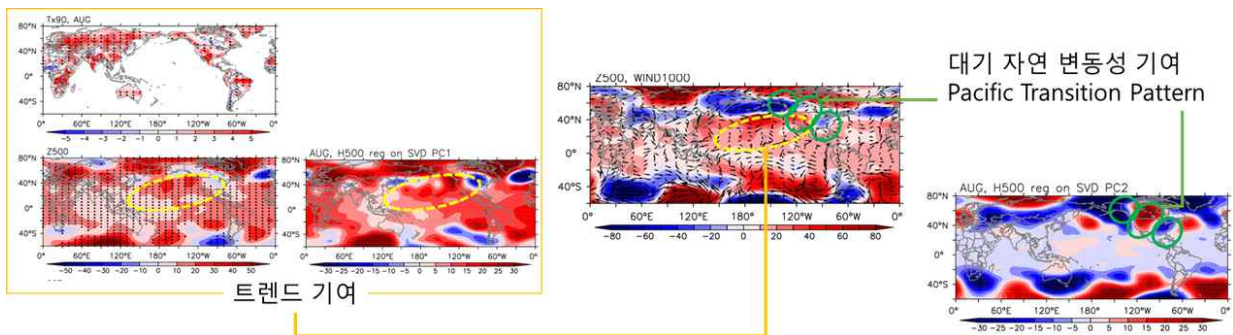


그림 190 (왼쪽) 이상고온 날수와 500hPa 지위고도 트렌드 분포, 주성분 첫 번째 모드 확장계수와 500hPa 지위고도 상관관계 분포 (중간) 500hPa 지위고도 편차장 분포 (오른쪽) 주성분 두 번째 모드 확장계수와 500hPa 지위고도 상관관계 분포

- 첫 번째 모드의 확장계수와 지위고도 편차장의 상관관계 분석 결과는 최근 트렌드 경향성과 일치하며(그림 7 왼쪽), 이는 첫 번

째 모드 관련 이상 기후 발생에 최근 기후 트렌드의 기여를 의미함. 두 번째 모드의 확장계수와 PT 지수와 상관계수는 0.5 이상으로, 여름철 발달하는 PT 패턴이 북미 주변 양의 지위고도 편차장 발달에 일부 기여했음을 의미함(그림 7 오른쪽).

- 즉, 8월 이상고온 발생은 기후 트렌드와 대기 자연 변동성의 조합으로 유례없이 심했던 것으로 보이며, 현재 진행되고 있는 북미 서부 산불의 호조건을 만듦.

11월 19일 폭우 관련

【 2020. 11. 20.(금)/ APEC기후센터 기후분석과 】

□ 현황

- 11월 19일 폭우로 일 전국 평균 강수량은 28mm를 기록하였고, 이는 1973년 이후로 동일 날짜의 역대 일 강수량 1위임. 특히 서울 관측지점에서는 86.9mm의 강수량으로 11월 하루 강수량 1위를 기록하였고, 이는 104년 만(이전 기록은 1916년 67.4mm)에 나타난 기록적인 최다 강수량임.

※1973년 이래 11월 19일의 일 강수량 1위는 27.4mm(1990)이었음.




그림 1. 2020년 11월 19일 총 강수량, 퍼센타일 분포 및 시계열

□ 원인 분석

- 2020년 동안 열대 북서태평양의 해수면온도는 평년보다 높은 값을 유지하였음. 이로 인해 열대 북서태평양 주변으로 대기 중의 수증기가 증가하였음.
- 지난 11월 12일 태풍 “VAMCO”가 필리핀을 지나 14일쯤 베트남에 상륙하여 소멸됨. 소멸된 태풍에 의하여 열대 북서태평양 주변 대기 중의 수증기량이 더 많아져서, 수증기 멍치(Moisture envelope)가 형성됨
- 중앙아시아에서 남중국지역으로 저기압이 이동하였음. 11월 17일 중국 남부지역에 접근, 저기압성 순환 전면으로 남서풍이 발달하면서, 열대 수증기는 중국 남부 및 한반도 지역으로 유입되었음 (그림 1).

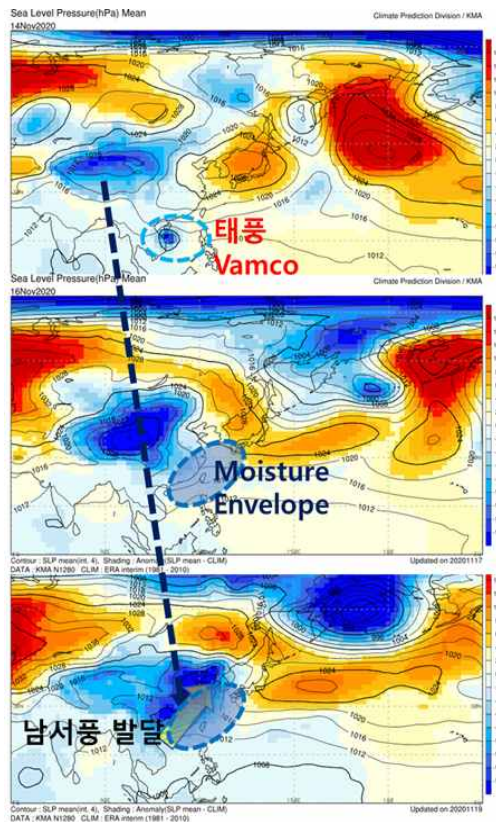


그림 1. 2020년 11월 14, 16, 18일 일 평균 해면 기압 평년(등치선) 편차(명암) 변화 (그림출처: co-anal.kma.go.kr)

- 유입된 열대 수증기가 17-18일 한반도와 중국 북쪽의 차고 건조한 공기와 만나 전선을 형성, 강풍을 동반한 많은 양의 강수량을 기록함(그림 2).

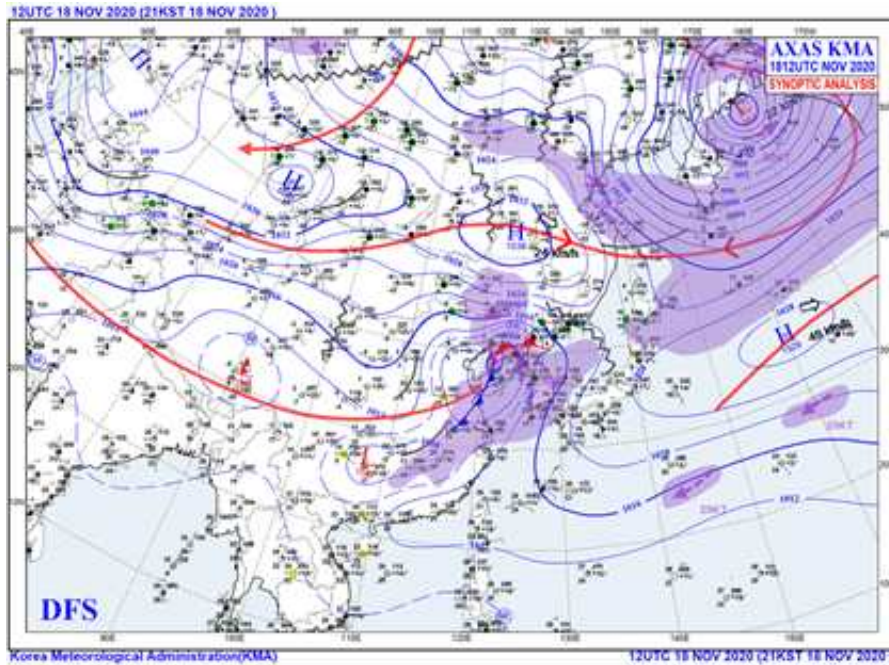


그림 2. 2020년 11월 18일 21시 지상 일기도 (그림출처: weather.go.kr)

□ 유사 사례

- 2019년 11월 17일에 있었던 중부 지방 폭우 사례
 - 올해와 유사하게 중앙아시아에서 저기압성 순환이 우리나라로 접근하고 있었음. 북서태평양의 해수면 온도 또한 양의 편차 값을 유지하고 있었으며, 필리핀 해에 발달해 있던 태풍 갈매기와 관련된 다량의 수증기가 유입되어 한반도에 폭우가 발생하였음(그림 3).

※ 2019년 11월 17일 전국 평균 강수량: 19.0 mm, 부여 일강수량: 92.5mm

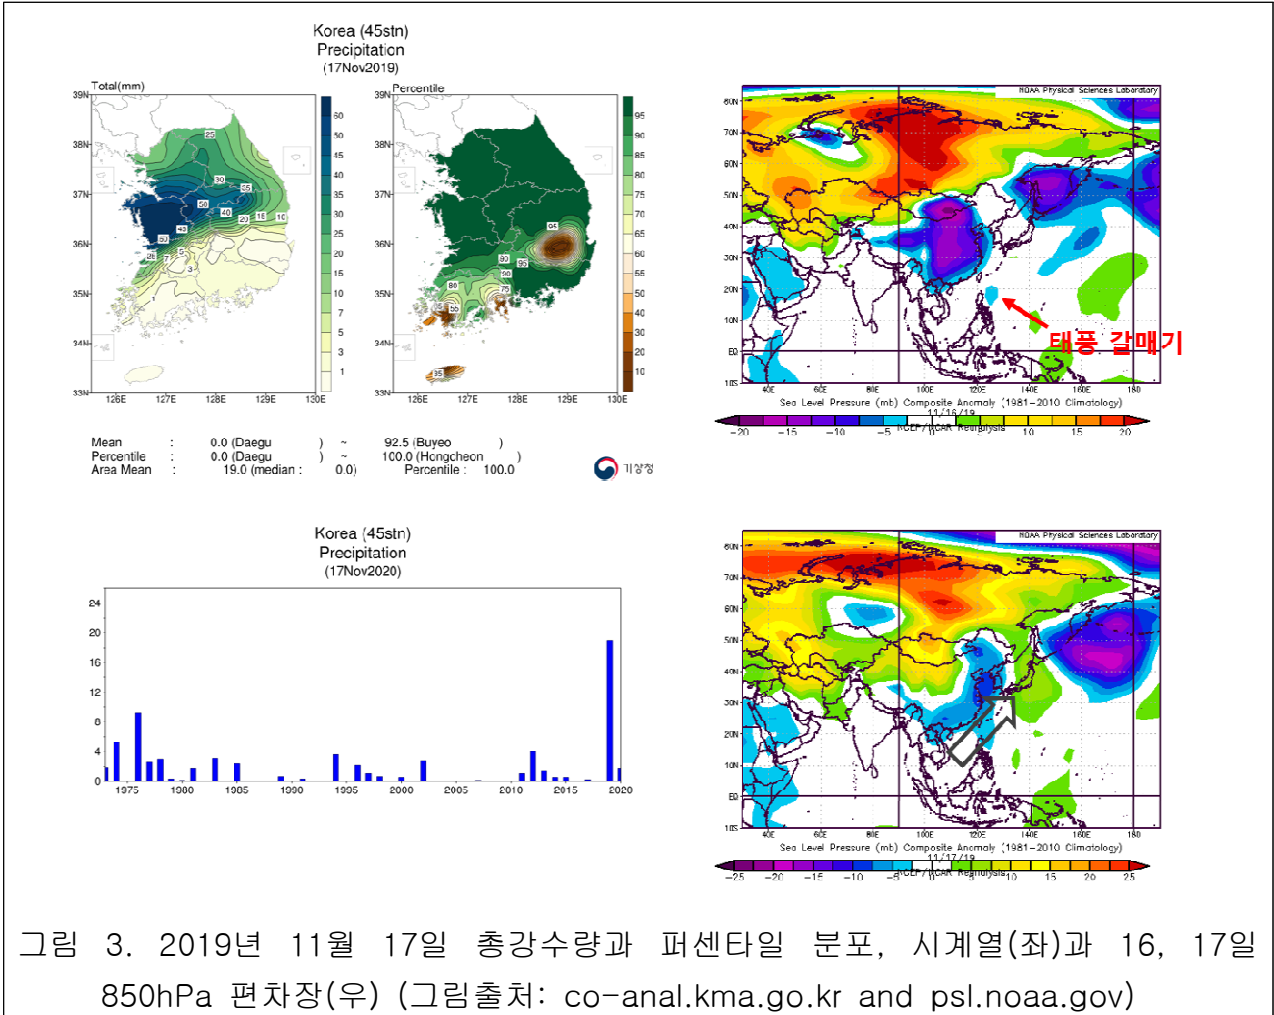


그림 3. 2019년 11월 17일 총강수량과 퍼센타일 분포, 시계열(좌)과 16, 17일 850hPa 편차장(우) (그림출처: co-anal.kma.go.kr and psl.noaa.gov)

부록 B. 운영매뉴얼: 동아시아 이상기후 감시 시스템
(개선)

APEC Climate Center (APCC)

운영매뉴얼:
동아시아 이상기후 감시 시스템
(개선)

2020년 12월

APEC기후센터 기후사업본부
기후분석과 이상기후팀

1. 서론

지구온난화에 의한 기후변화의 위험과 함께 이상기후는 세계 곳곳에서 발생하는 인명피해뿐만 아니라 일상적으로 사회경제적 영향을 미치고 있다. 한국과 동아시아에서도 폭염, 한파, 가뭄, 폭우의 강도, 지속시간, 빈도가 점점 증가할 것으로 예상되며 이에 따라 시의성 있는 대응체계 마련이 시급한 상황이다. 본 시스템에서는 준 실시간 재분석 자료를 이용하여 한국 및 동아시아 지역의 이상기후 감시 및 분석 정보를 효과적으로 제공할 수 있는 체계를 제안한다.

2. 업무 내용

가. 생산 일정

본 시스템은 매월 12일경 APCC 웹페이지에 동아시아 이상기후 월별 감시 정보가 업로드 되도록 자동화 구축되어있다. 자동화 shell 스크립트의 내용은 표 1과 같으며, 계산 및 가시화 코드에 대한 설명은 2-나, 2-다에 서술하였다. 2-라에는 전체적인 흐름도를 나타내었다.

```
#!/bin/bash
module load ncl/6.4.0 grads/2.1.a0 pgi netcdf/4.3.2 wgrib/1.8.1.2a wgrib2/2.0.1 R-InstallPackages/3.6.0
R/3.6.0
export PATH=/usr/local/bin:/usr/bin:/bin
export NCARG_ROOT=/app/sw/ncarg/6.4.0/gnu-bin
CodeDir="/ifs/data12/Monitoring/code"
echo "*****run start for East Asia*****" >
${CodeDir}/ncl_error_monthly.log
/app/sw/ncarg/6.4.0/gnu-bin/bin/ncl ${CodeDir}/01.cal/01.nc_count_anomaly_using_daily_percentile_Final.ncl
>> ${CodeDir}/ncl_error_monthly.log
/app/sw/R/3.6.0/lib64/R/bin/Rscript ${CodeDir}/01.cal/02.Evaluate_RP_MaxVol.R
/app/sw/R/3.6.0/lib64/R/bin/Rscript ${CodeDir}/01.cal/03.OCR_SIM_CalPTcoef.R
/app/sw/R/3.6.0/lib64/R/bin/Rscript ${CodeDir}/01.cal/04.Compute_SPI_SPEI_SEDI_Global_CPC.R
echo "*****plot start for East Asia*****" >
${CodeDir}/ncl_error_monthly.log
/app/sw/ncarg/6.4.0/gnu-bin/bin/ncl ${CodeDir}/02.plot/01.plot_monthly_temp_EA_new.ncl >>
${CodeDir}/ncl_error_monthly.log
/app/sw/ncarg/6.4.0/gnu-bin/bin/ncl ${CodeDir}/02.plot/02.plot_monthly_Max_P_event_EA.ncl >>
${CodeDir}/ncl_error_monthly.log
/app/sw/ncarg/6.4.0/gnu-bin/bin/ncl ${CodeDir}/02.plot/03.plot_monthly_drought_map.ncl >>
${CodeDir}/ncl_error_monthly.log
/app/sw/ncarg/6.4.0/gnu-bin/bin/ncl ${CodeDir}/02.plot/04.plot_monthly_EA_climate_map.ncl >>
${CodeDir}/ncl_error_monthly.log
```

표 1. 자동화 shell script

나. 계산 코드 설명

월별 이상기후 감시정보를 계산하기 위해 총 5개의 계산 코드가 구성되어 있다. 각 코드의 계산 수행 결과 자료는 아래와 같다.

- 01.nc_count_anomaly_using_daily_percentile_Final.ncl
: 이상기후 발생일수를 계산하는 프로그램 (언어 : ncl)
- 02.Evaluate_RP_MaxVol.R
: 최대강수사상 및 재현기간을 계산하는 프로그램 (언어 : R)
- 03.OCR_SIM_CalPTcoef.R
: 습구온도를 구하기 위한 프로그램 (언어 : R)
- 04.Compute_SPI_SPEI_SEDI_Global_CPC.R
: 가뭄 지수를 계산하기 위한 프로그램 (언어 : R)

다. 가시화 코드 설명

- 01.plot_monthly_temp_EA_new.ncl
: 이상고온 및 이상저온 감시정보 그림 표출 프로그램 (언어 : ncl)
- 02.plot_monthly_Max_P_event_EA_new.ncl
: 최대 강수 재현기간 그림 표출 프로그램 (언어 : ncl)
- 03.plot_monthly_drought_map.ncl
: 가뭄 통합맵 그림 표출 프로그램 (언어 : ncl)
- 04.plot_monthly_EA_climate_map_new.ncl
: 이상기후 통합 맵 그림 표출 프로그램 (언어 : ncl)

라. 흐름도



마. 수행 결과

흐름도에 따라 계산 및 표출하게 되면 결과로 나오는 그림은 다음과 같다.

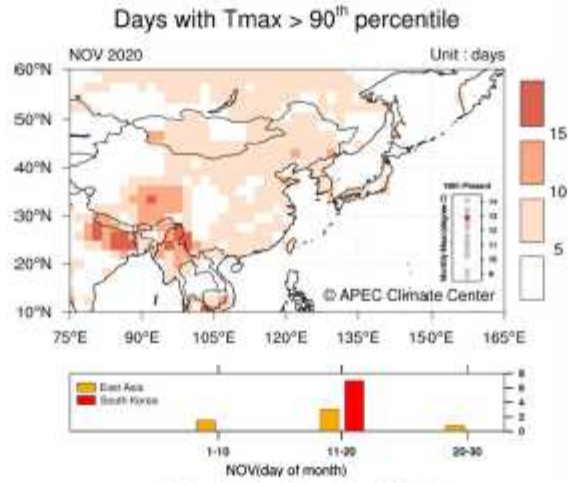


그림 1. 월별 이상고온 감시정보

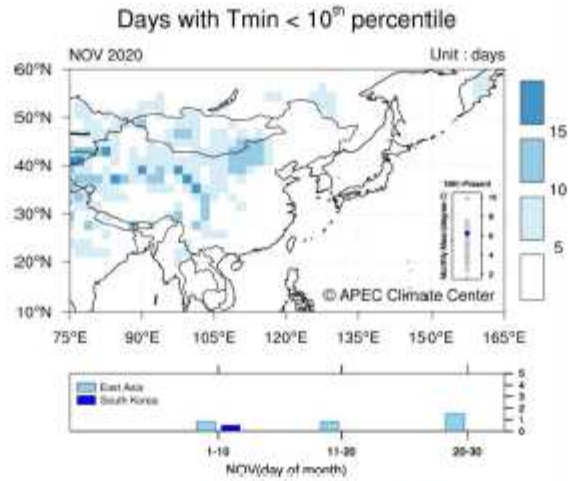


그림 2. 월별 이상저온 감시정보

Return period of the largest P event

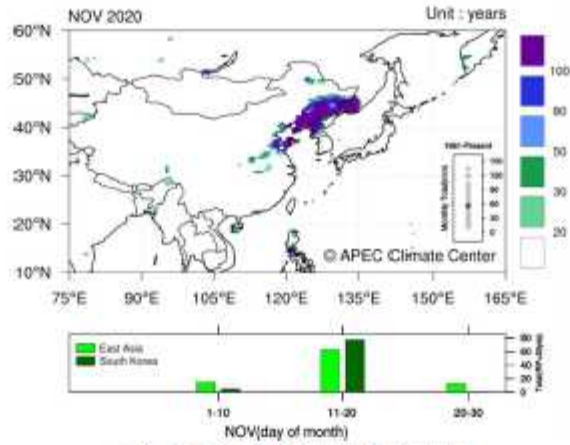


그림 3. 월별 최대강수사상 감시정보

East Asia Drought Map

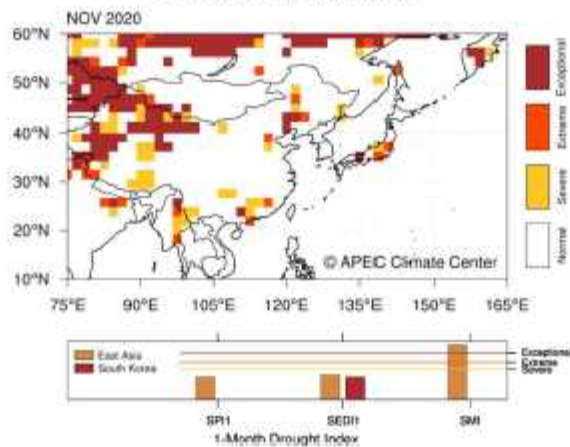


그림 4. 월별 동아시아 가뭄 통합맵

East Asia Extreme Climate Map

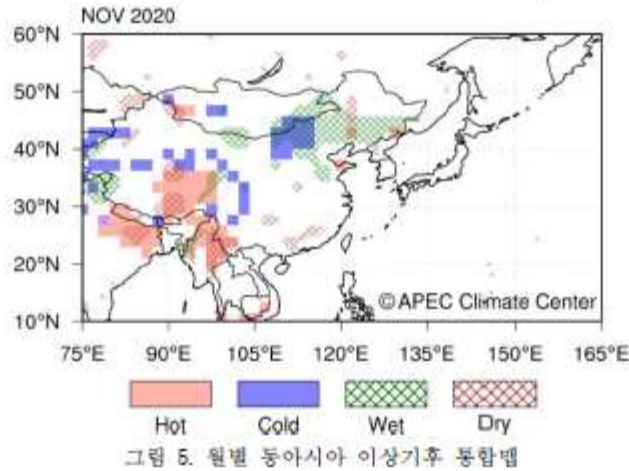


그림 5. 월별 동아시아 이상기후 통합맵

바. 해석 가이드

이상기후 감시정보 웹서비스는 사용자가 이해하기 어려운 정보다 다소 포함되어 있어, 이를 한 눈에 보고 더욱 쉽게 이해할 수 있도록 해석 가이드를 PDF 형식으로 제공한다. 해석 가이드의 내용은 아래와 같다.

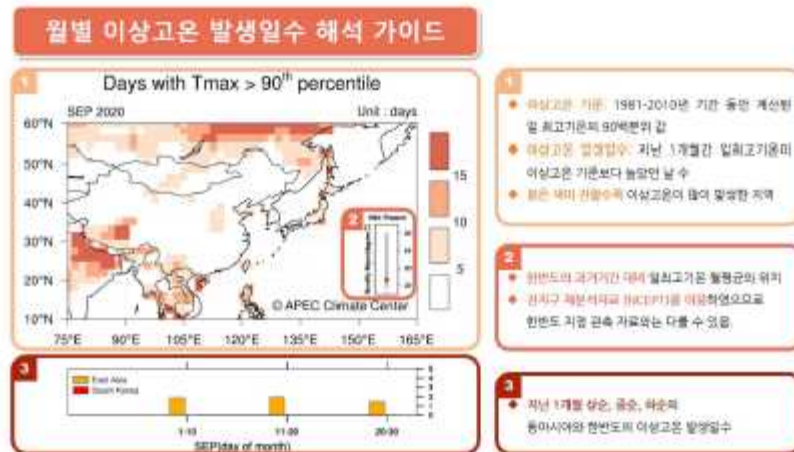


그림 6. 월별 이상고온 발생일수 해석가이드

월별 이상저온 발생일수 해석 가이드

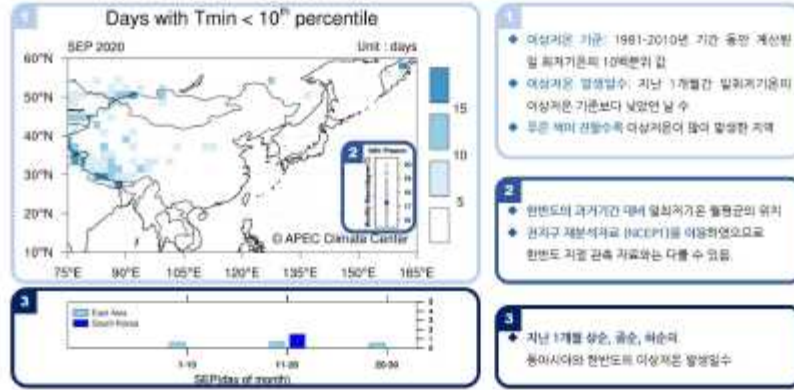


그림 7. 월별 이상저온 발생일수 해석가이드

월별 이상강수 통합맵 해석 가이드

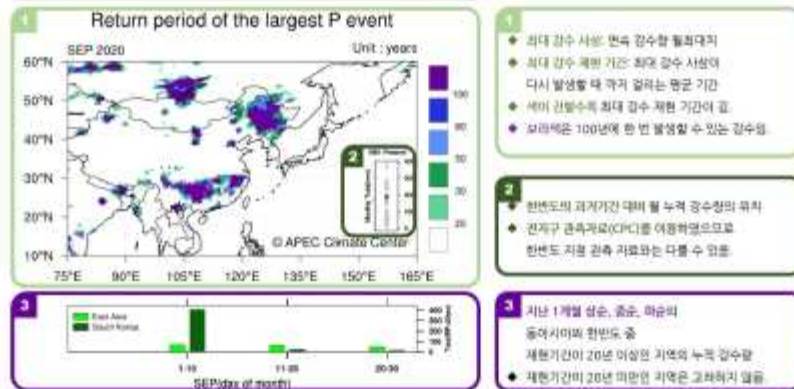


그림 8. 월별 이상강수 통합맵 해석 가이드

월별 가뭄 감시 통합맵 해석 가이드

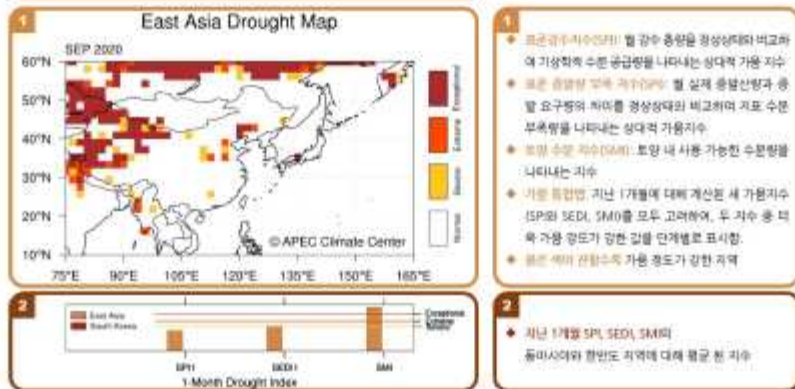


그림 9. 월별 가뭄 감시 통합맵 해석 가이드

월별 이상기후 통합맵 해석 가이드

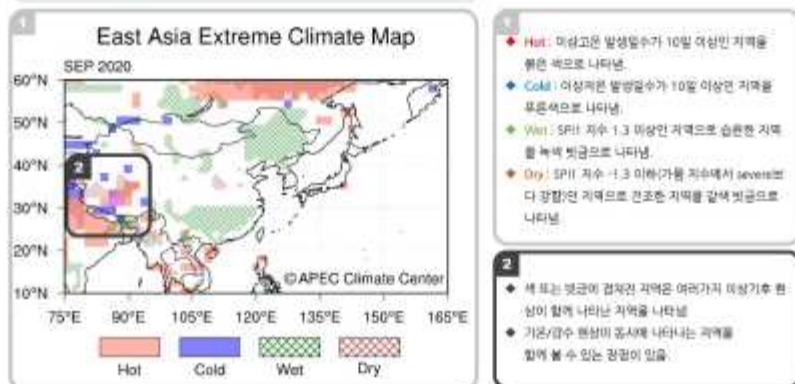


그림 10. 월별 이상기후 통합맵 해석 가이드

부록 C. 2020 흑서기 이상기후 원인 분석서




여름철 현황

들쭉날쭉한 기온, 역대 긴 장마

7월


이상 저온 날수 평년대비 증강수량



- 장마가 오래 지속 되어 강수일수는 4위를 (18.8일, 평년 4.4일) 기록함. 남부 지방을 중심으로 평년 대비 300 퍼센트 이상 증가
- 기온은 낮아서 이상 저온 날수(최고기온 10 퍼센타일 날수, 9.1일, 평년 3.0일)는 역대 2위까지 높았음.
- 상대적으로 폭염 일수(0.1일, 평년 3.9일)는 상당히 적어 역대 45위를 기록함.

6월


폭염 날수



- 폭염이 일찍 시작해서 한달 간 지속 되었음. 특히 경상도와 강원도에 상대적으로 폭염 일수가 높았음.
- 최고 기온 (28 ℃, 평년 21.2 ℃) 및 폭염일수(2.0일, 평년 0.6일)는 1973년 이후 1위를 기록함.

8월

열대야 날수



- 장마가 중부 지방에서 16일에 종료됨 (1973년 이후 역대 가장 긴 장마로 기록, 54일)
- 이후 8월 초반 까지 폭염 및 열대야가 지속되었음. 열대야 날수는 서부 지역과 동부 해안 지역에서 상대적으로 많았음.
- 최저 기온은 역대 2위 (23.7 ℃, 평년 21.5 ℃), 열대야 날수는 역대 5위 (7.9일, 평년 2.7일)로 높았음

예측 인자 현황

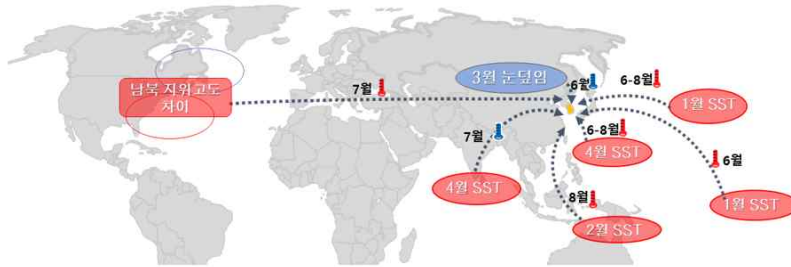
봄철 예측 인자들은 6-8월 폭염의 증가 가능성에 우세

봄철 예측 인자

- 봄철 관측에서 예측 인자들은 6-8월 폭염이 평년보다 증가하는 가능성에 우세했음.
- 7월의 경우 4월 동인도양 해수면 온도의 증가로 폭염 감소의 가능성을 보여주었지만, 다른 예측 인자들이 평년보다 증가 경향이 우세하였음.



평년보다
6-8월
폭염 증가
전망



이상기후 원인

2020년 여름철 이상기후 원인 개요

- 2019/20 엘니뇨 발달 이후 늦은 봄부터 여름철 까지 북인도양 해수면 온도 상승이 유지되었으며, 관련된 고기압이 여름 내내 북서태평양에 유지 되어 한반도에 더운 공기 유입의 원인이 됨
- 습도가 높고 더운 공기의 유입으로 6월과 8월은 이상 고온증가의 원인이 되었으며, 7월은 이때 발달한 음의 북대서양 대기 변동 (NAO) 관련한 중국 북동부 고기압 때문에 찬공기가 유입되어 강수 형성의 호조건을 만들었고, 이 때문에 일사량 감소로 이상 저온이 증가하였음.



*NAO: North Atlantic Oscillation, 북대서양에서 남북 방향으로 양과 음 반대 기호의 해면 기압이 분포되어 있는 현상이며, 일정한 주기로 남북 방향의 기호가 바뀜

이상기후 원인

7월 역대급 장마와 이상 저온
태평양-대서양-인도양 기후 변동의 합작품


주요 대양 기후 모드의 상호작용

- ①2019/20 엘니뇨 발달 이후 봄철 동안 ②북인도양의 해수면 온도 상승이 ③북서태평양 고기압 성 순환 발달에 원인이 됨. 이 고기압성 순환은 한반도에 고온 다습한 공기를 유입 시킴.
- 동시에 ②북 열대 대서양의 해수면 온도 상승은 ④음의 북 대서양 대기 변동 (NAO) 발달의 원인이 되었고, 이와 관련한 대기 원격 상관 패턴은 ④한반도 북동부 지역에 고기압 발달의 원인 됨. 이 고기압성 순환은 차가운 공기를 한반도에 유입 시킴.
- 남쪽의 고온 다습한 공기와 북쪽의 찬공기가 만나서 한반도에서 7월 기록적인 장마를 유발, 이로 인한 일사량의 감소로 이상 저온의 원인이 됨.

장주기 변동의 역할

- 20-40년의 주기로 변하는 북대서양 해수면 온도(AMO, Atlantic Multidecadal Oscillation)가 더 작은 시간 규모로 변하는 태평양-대서양-인도양 기후변동의 상호작용을 조절함.
- 현재 양의 AMO 상태이며, 태평양-대서양-인도양 기후 변동의 상호 작용을 강화하여 올해 여름철 기록적 장마와 이상 저온을 유발 하였음.


모식도



사후분석


역학 모델은 7월 기록적인 이상 저온 예측 실패함.

역학모델




- 예측된 7월 해면 기압 평년 편차 장을 보면, 음의 NAO 관련 원격 상관 편차장은 잘 재현되지 않았으며, 이때문에 한반도 북동쪽의 고기압성 편차가 모의 되지 못함.
- 북서 태평양의 고기압성 순환은 잘 예측되었으며, 이로 인해 따뜻한 공기의 유입을 유발함.
- 북쪽에서 찬 공기의 유입이 없어서 강수를 유발할 수 있는 호조건이 형성되지 못하였고, 이 때문에 따뜻한 공기의 유입과 함께 일사량 증가로 한반도의 기온을 높였음.

유사성 기반



- 선정된 유사해 들에서 7월 500mb 지위 고도 평년 편차장의 합성장은 음의 NAO 관련 원격 상관의 기여는 보이지만, 북서태평양의 고기압성 순환은 나타나지 않음.
- 즉, 인도양 해수면 온도 변동에 의한 북서태평양 고기압 발달에 의한 이상 강수 강화는 유사성 기반 모델에서는 재현하지 못함.
- 이 때문에 모델에서 이상 기온을 더 낮추지는 못하고, 평년수준으로 예측함.

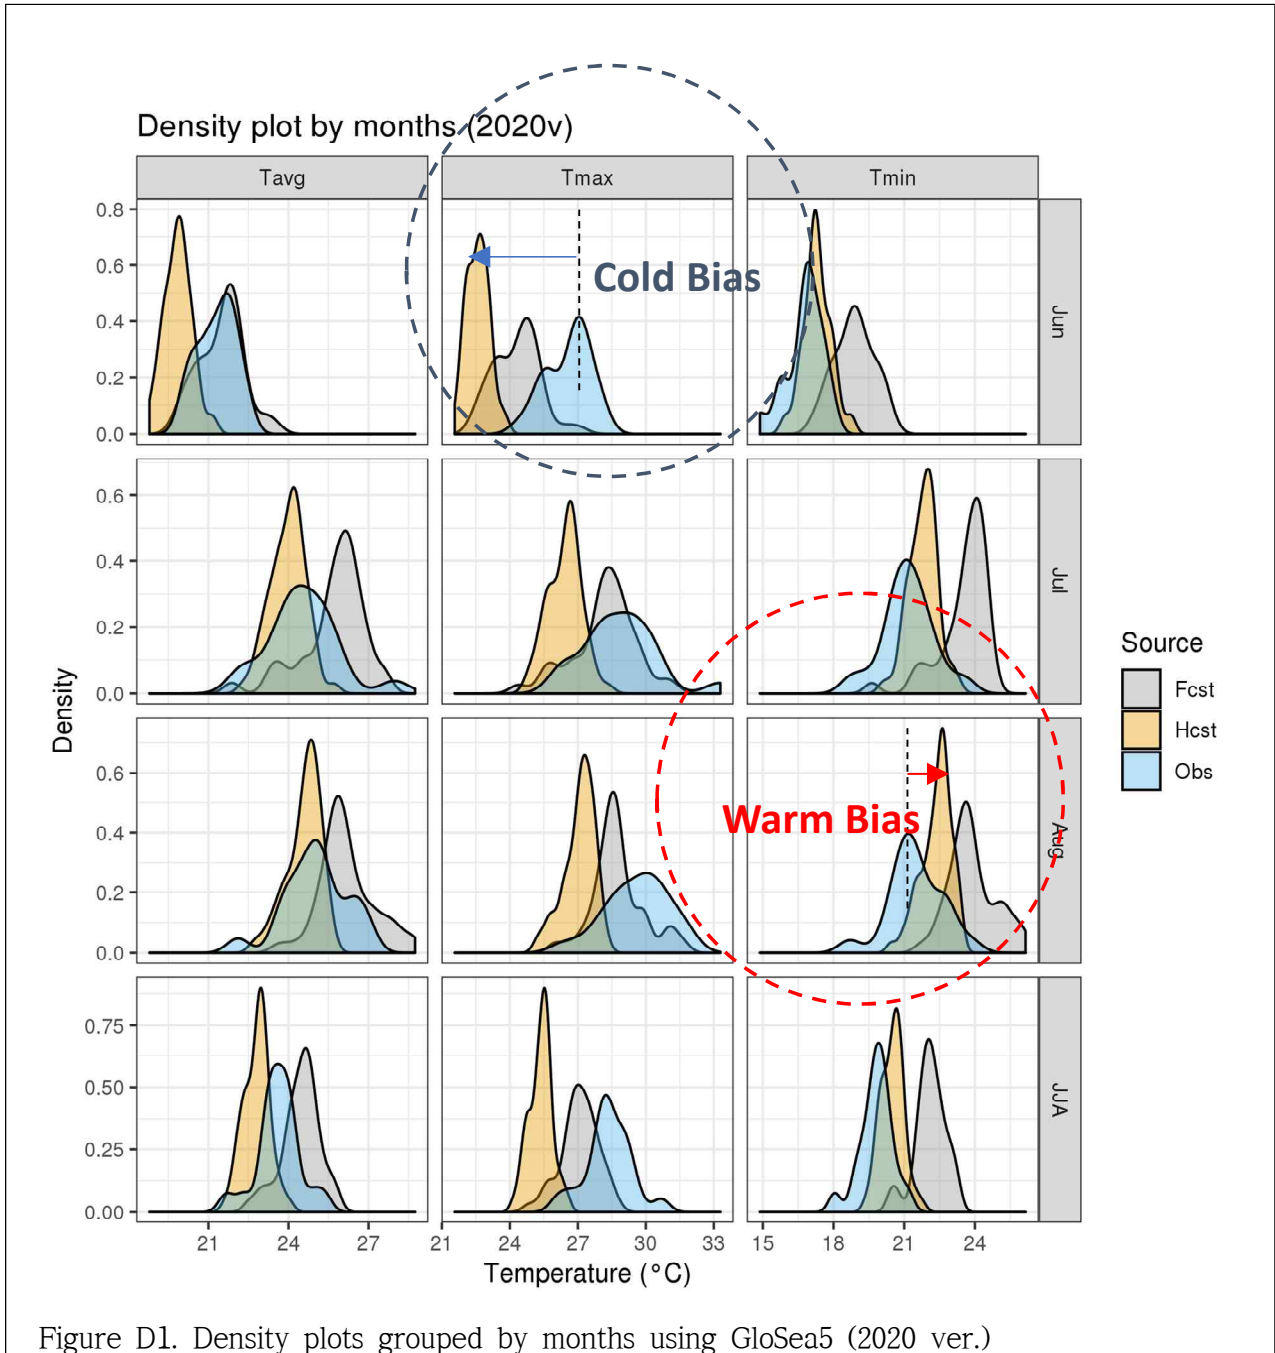
기계학습



기계학습 모델에서 사용된 예측인자의 표준화된 anomaly

- 거의 모든 인자들이 겨울철 엘니뇨 쇠퇴 및 봄철 인도양 가열 현상과 연관된 것으로, 이는 여름철 북서태평양에 고기압성 흐름을 유도하여 한반도에 강수 증가 및 저온 현상을 유발한 것으로 분석되었음.

부록 D. 2020 7월과 8월 특정년도 대비 확률예보



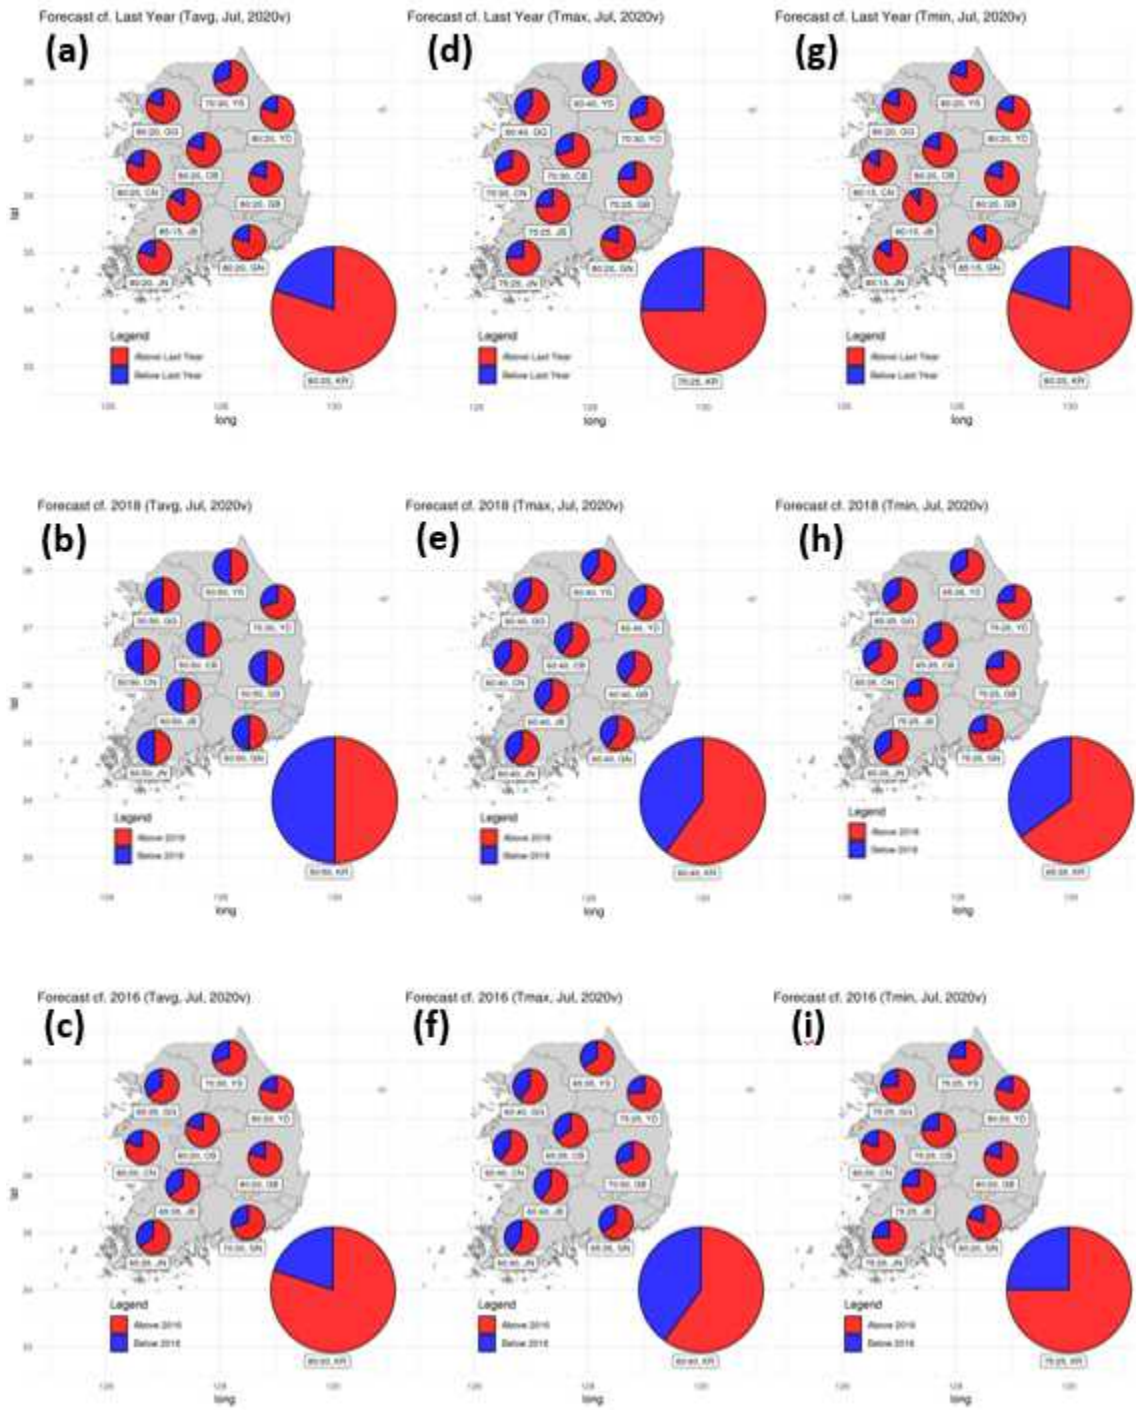


Figure D2. Probabilistic forecasts for July 2020 compared to last year ((a), (d), and (g)), the year 2018 ((b), (e), and (h)) and the year 2016 ((c), (f), and (i)).

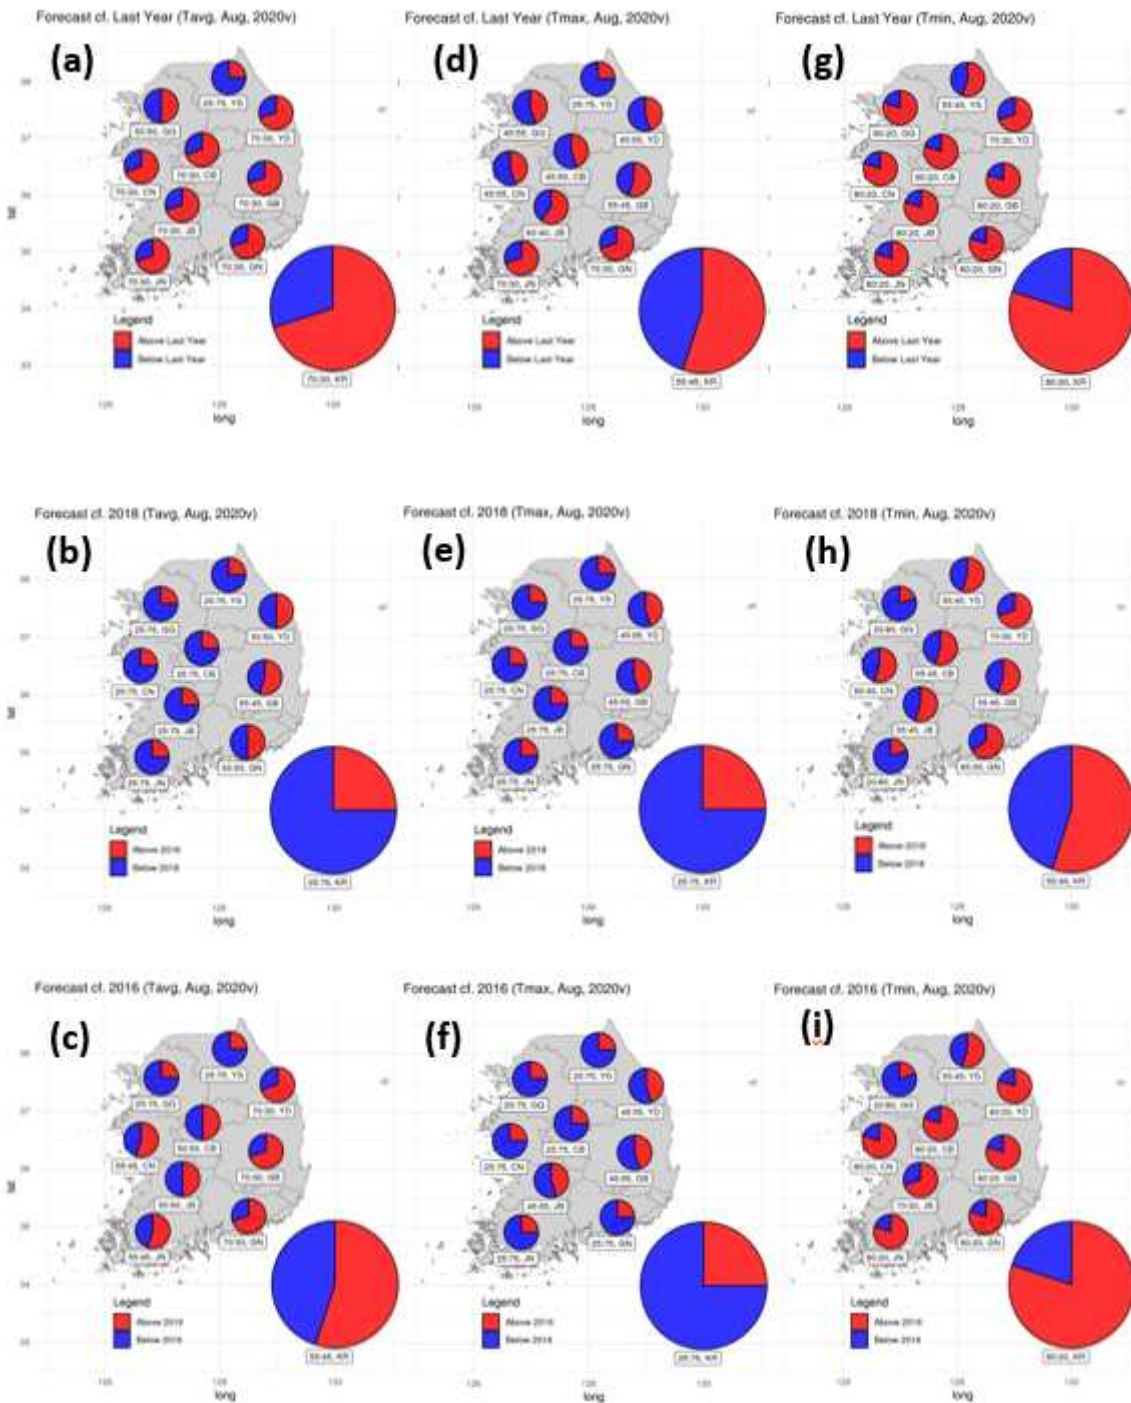


Figure D3. Probabilistic forecasts for August 2020 compared to last year ((a), (d), and (g)), the year 2018 ((b), (e), and (h)) and the year 2016 ((c), (f), and (i)).