

발간등록번호
11-1360709-000072-01



최종보고서

사업명	한국형앙상블모델의 섭동 및 팽창기법 연구
수행기관	(사)한국기상학회 컨소시엄

2022. 11.



기상청

Korea Meteorological
Administration

제 출 문

기 상 청 장 귀 하

본 보고서를 “한국형앙상블모델의 섭동 및 팽창기법 연구” 최종보고서로 제출 합니다.

2022년 11월 30일

- 주관연구기관명 : 한국기상학회
- 연구 기간 : 2022.03.02.~11.30.
- 주관연구책임자 : 김 백 민
- 참여연구원
 - ◆ 연구원 : 윤 진 호
 - ◆ 연구원 : 정 지 훈
 - ◆ 연구원 : 김 형 준
 - ◆ 연구원 : 우 성 호
 - ◆ 연구원 : 옥 정
 - ◆ 연구원 : 고 민 희
 - ◆ 연구원 : 김 하 림
 - ◆ 연구원 : 류 지 훈
 - ◆ 연구원 : 성 광 제

- ◆ 연구원 : 현 종 훈
- ◆ 연구원 : 소 재 은
- ◆ 연구원 : 강 상 현

I. 연구배경

1. 연구 필요성 및 목적

(1) 연구의 필요성

대기의 비선형성에 기인한 카오스적 성질에 의해 단일 모델을 활용한 예측은 수치예보가 가질 수밖에 없는 결정론적인 예측성의 한계를 가질 수밖에 없다 (Lorenz, 1963 a,b; Palmer, 2002). 이러한 수치예보 과정의 결정론적 불확실성을 극복하고 결정론적 예측 한계를 넘어서는 중기 예측 정보를 생산하기 위해 미국과 영국을 비롯한 기상 선진국에서 1980년대 이후 모델의 초기값에 임의의 작은 변화를 주어 단일 모델의 다중 앙상블을 만들고 이를 활용하여 확률론적 예보를 시작하게 되었다 (Kalnay, 2003; 2010). 중·장기 시간 규모에 대한 예보는 현업 예측 시스템의 필수적인 영역으로 전 세계에서 지속적으로 예측하고자 하는 시도는 끊임없이 진행됐다 (Oldenborgh et al., 2012; Vitart et al., 2017).

우리나라 기상청에서도 체계적인 앙상블 예보 시스템을 구축하여 수치예보 모형을 활용한 중·장기 시간 규모 예보 기반의 현업 운영을 진행해왔으며, 2020년부터 현업 활용되고 있는 한국형 수치예보모델을 기반으로 2021년 10월부터 한국형 수치예보모델 기반 앙상블예측시스템(이하 한국형앙상블모델)을 현업 운영 중에 있다. 현업용 한국형 앙상블모델이 개발됨에 따라 주요 기상 선진국 모델과의 체계적인 성능 비교와 개선점 도출, 지속적인 개선을 통한 예측성 향상 연구가 빠르게 추진되어야 할 필요성이 있다.

본 사업에서는 2021년부터 현업 운영 중인 한국형앙상블모델의 전반적인 예측 특성을 진단하고 모델의 구조적 오차 특성 분석을 통해 성능 개선 방안을 제시하고자 한다. 특히 관측자료 뿐만 아니라 국외 현업에서 운용되는 주요 앙상블 예보모델의 결과와 비교 분석을 통해 정량적인 예측 성능 및 오차 특성을 파악하고자 한다. 일반적인 예측의 경향성뿐만 아니라 최근 기후 변화에 따라 발생하는 이상 기후 현상 사례 등을 선정하여 실제 사례에 대한 예측특성을 분석하여 계절별 또는 지역별 중·장기 시간 규모의 예측성 향상 개선에 기여하고자 한다.

(2) 연구 목적

한국형양상불모델의 예측 성능을 향상시키기 위하여 모델의 특성을 진단하고 평가하는 기술을 확보하고, 모델 예측 특성을 기반으로 하는 양상불 섭동 및 팽창기법의 최적화 방안을 탐색하여 한국형양상불 모델의 성능 평가 및 개선에 의의가 있다. 또한, 성능평가 및 개선을 효과적으로 제시하기 위하여 가시화 시스템 구축에 목적이 있다.

2. 사업 범위

- 한국형양상불모델의 성능 개선을 위한 전반적인 모델의 예측 성능 및 오차 분석을 통한 모델 특성 진단 및 평가
- 한국형양상불모델의 성능 개선을 위한 양상불 분포(Spread) 중심의 상관성 분석 및 국외 현업 양상불예측모델 결과와의 비교 분석을 통한 진단 성능 평가
- 한국형양상불모델의 성능 개선을 위한 모델 예측 특성 기반의 양상불 섭동 및 팽창 기법의 최적화 방안 탐색 및 제시
- 한국형양상불모델의 예측 성능 진단 및 특성 결과의 효과적인 제시를 위한 시각화 방안 탐색 및 표출

3. 연구개발 내용

- 한국형양상불모델의 성능 개선을 위한 전반적인 모델의 예측 성능 및 오차 분석을 통한 모델 특성 진단 및 평가
 - 한국형양상불모델의 일반적인 예측경향과 계절별 편차 분석 및 진단
 - 한국형양상불모델의 양상불 예측 특성 평가를 위한 진단기술 활용 분석 및 평가
- 한국형양상불모델의 성능 개선을 위한 양상불 분포(Spread) 중심의 상관성 분석 및 국외 현업 양상불예측모델과의 비교 분석을 통한 진단 성능 평가

- 국외 앙상블모델과의 섭동기법 비교 분석
 - 앙상블 Spread와 앙상블 에러의 상관성 분석
 - 한국형앙상블모델 앙상블 Spread와의 상관성 분석
 - 한국형앙상블모델 팽창 기법과 앙상블 Spread와의 상관성 분석
- 한국형앙상블모델의 성능 개선을 위한 모델 예측 특성 기반의 앙상블 섭동 및 팽창 기법의 최적화 방안 탐색 및 제시
 - 앙상블 자료동화 시스템을 위한 섭동 및 팽창 기법 분석
 - ◆ 한국형앙상블모델의 예측 성능 진단 및 특성 결과의 효과적인 제시를 위한 시각화 방안 탐색 및 표출
 - 웹 기반 앙상블 모델의 예측특성을 효과적으로 진단할 수 있는 시각화 방안 연구

4. 연구개발 방안

본 과제의 연구개발은 부경대학교(김백민 교수), 광주과학기술원(윤진호 교수), 상명대학교(성광제 교수), (주)투씨솔루션(현종훈 대표)의 컨소시엄과 협력을 통해서 이루어지며, 전반적인 모델의 예측 성능 및 오차분석을 통한 모델 특성 진단 및 평가는 부경대학교, 앙상블 분포 중심의 상관성 분석 및 국외 현업 앙상블 예측모델 결과 비교 평가는 광주과학기술원, 모델의 성능 개선을 위한 앙상블 섭동 및 팽창 기법의 최적화 방안 탐색 및 제시는 상명대학교, 시각화 방안 탐색 및 표출은 (주)투씨솔루션에서 주도적으로 수행한다.

◆ 연구팀 및 세부과제 구성

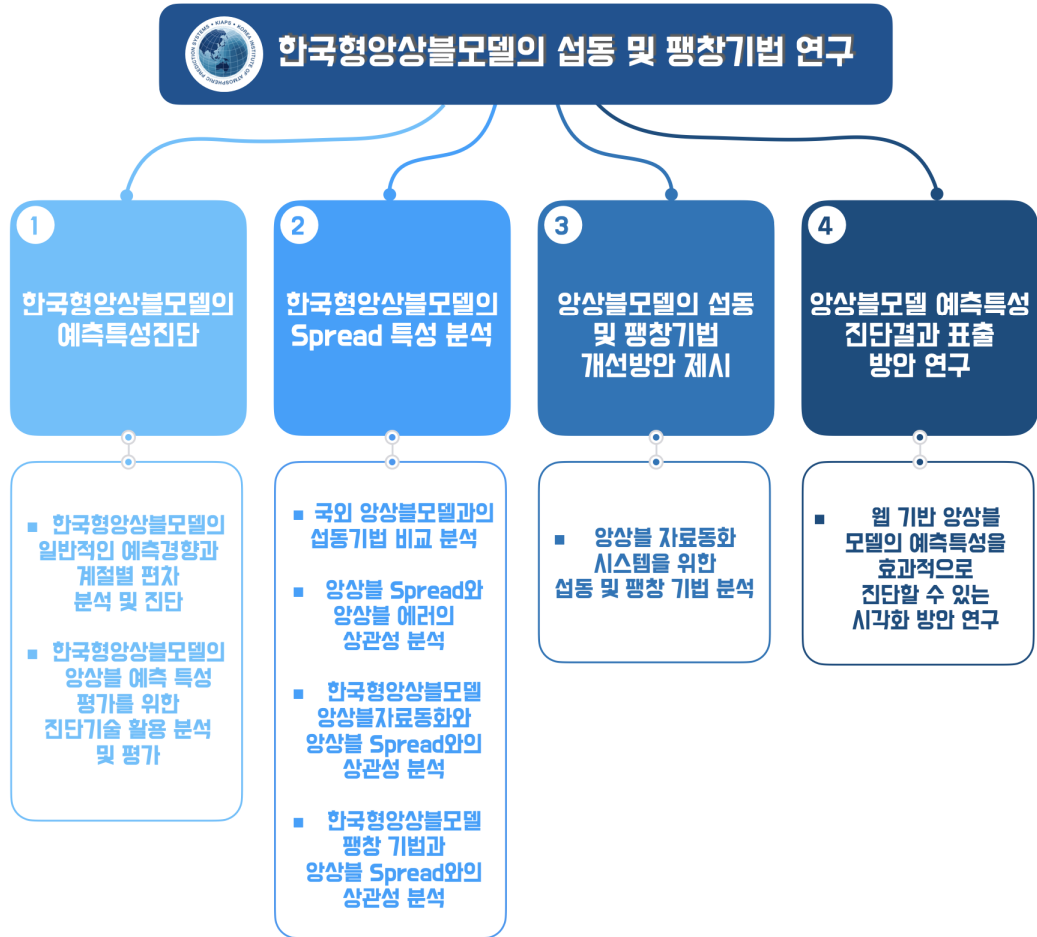


그림 1. 한국형양상블모델의 섭동 및 팽창기법 연구의 추진사항

II. 세부과제별 연구 결과

제 1 세부과제

“한국형앙상블모델의 예측특성 진단”

연구기관

한국기상학회

요 약 문

제 1 세부과제는 한국형앙상블모델의 일반적인 예측경향을 파악하고, 중/장기 시간규모의 대표적인 사례를 조사하여 이를 활용한 계절별, 지역별 예측특성 분석을 평가하는 것을 목표로 하였다. 이에 본 연구에서는 2021년부터 현업 운영 중인 한국형앙상블모델의 전반적인 예측 특성을 진단하고 모델의 구조적 오차 특성을 통해 성능 개선 방안을 제시하였다. 특히, 관측자료 뿐만 아니라 국외 현업에서 운용되는 주요 앙상블 예보 모델의 결과와 비교 분석을 통해 정량적인 예측 성능 및 오차 특성을 파악하였으며, 일반적인 예측 경향성뿐만 아니라 최근 기후 변화에 따라 발생하는 극한 기상 현상 사례 등을 선정하여 실제 사례에 대한 예측 특성을 분석하였다, 이러한 예측 성능 진단 및 평가 정보는 한국형앙상블모델의 계절별 또는 지역별 중·장기 시간 규모의 예측성 향상 및 모델 성능 개선에 기여할 수 있다.

1) 한국형앙상블모델의 예측특성 진단

- 한국형앙상블모델의 일반적인 예측경향과 계절별 편차 분석 및 진단
- 한국형앙상블모델의 앙상블 예측 특성 평가를 위한 진단기술 활용 분석 및 평가

2) 한국형앙상블모델의 Spread 특성 분석

- 국외앙상블모델과의 섭동기법 비교 분석
- 앙상블 Spread와 앙상블 에러의 상관성 분석
- 한국형앙상블모델 앙상블 자료동화와 앙상블 Spread와의 상관성 분석
- 한국형앙상블모델 팽창 기법과 앙상블 Spread와의 상관성 분석

차 례

제 1 장 사업의 필요성	1
제 2 장 사업 목적	3
제 3 장 사업 개요	4
제 4 장 사업 수행 내용 및 결과	5
1. 자료	5
2. 한국형양상불모델의 예측특성 진단	10
2.1 한국형양상불모델의 일반적인 예측 경향과 계절별 편차(Bias) 분석 및 진단	10
2.2 한국형양상불모델의 양상불 예측 특성 평가를 위한 진단기술 활용 분석 및 평가	165
2.3 한국형양상불모델의 Spread 특성 분석	191
제 5 장 사업수행결과의 활용 계획	249
제 6 장 참고문헌	250

표 차례

표 1.1.1 ECMWF ERA5 재분석 자료 정보	5
표 1.1.2 NASA GPM 관측 자료 정보	6
표 1.1.3 한국형양상블모델과 기상청 UM 양상블 모델 비교 (한국형수치모델링센터 제공)	7
표 1.1.4 분석에 활용된 한국형양상블모델 자료 정보	7
표 1.1.5 TIGGE Project 활용 모델 정보: ECMWF, UM(KMA), UKMO	8
표 1.1.6 분석에 활용된 TIGGE Project 모델 자료 정보	9
표 1.1.7 요소별 블로킹 탐지 기법 (출처: 허혜숙 외, 2002)	16
표 1.1.8 블로킹 발생 영역 정의	18
표 1.2.1 양상블 모델 분석 방법 예시	166
표 1.2.2 2021년과 평년(1991~2020년)의 장마철 시작일과 종료일 및 기간 (출처: 2021년 이상 기후보고서, 기상청)	181

그림 차례

그림 1.1.1 북극진동 모드 (Arctic Oscillation; AO) Loading Pattern (1979–2000; ERA5)	14
그림 1.1.2 태평양-아메리카 모드 (Pacific/North Atlantic; PNA) Loading Pattern (1979–2000; ERA5)	16
그림 1.1.3 블로킹 탐지 방법: 블로킹 형태를 수치로 계산하는 법	18
그림 1.1.4 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 북반구	20
그림 1.1.5 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 북반구	20
그림 1.1.6 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 남반구	21
그림 1.1.7 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 남반구	21
그림 1.1.8 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 한반도	22
그림 1.1.9 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 한반도	22
그림 1.1.10 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 동아시아	23
그림 1.1.11 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 동아시아	23
그림 1.1.12 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 북반구	25

그림 1.1.13 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 북반구	25
그림 1.1.14 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 남반구	26
그림 1.1.15 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 남반구	26
그림 1.1.16 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 한반도	27
그림 1.1.17 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 한반도	27
그림 1.1.18 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 동아시아	28
그림 1.1.19 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 동아시아	28
그림 1.1.20 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 북반구	30
그림 1.1.21 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 북반구	30
그림 1.1.22 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 남반구	31
그림 1.1.23 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 남반구	31
그림 1.1.24 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 한반도	32
그림 1.1.25 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 한반도	32

그림 1.1.26 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 동아시아	33
그림 1.1.27 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 동아시아	33
그림 1.1.28 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 북반구	35
그림 1.1.29 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 북반구	35
그림 1.1.30 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 남반구	36
그림 1.1.31 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 남반구	36
그림 1.1.32 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 한반도	37
그림 1.1.33 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 한반도	37
그림 1.1.34 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 동아시아	38
그림 1.1.35 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 동아시아	38
그림 1.1.36 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 북반구	40
그림 1.1.37 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 북반구	40
그림 1.1.38 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 남반구	41

그림 1.1.39 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 남반구	41
그림 1.1.40 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 한반도	42
그림 1.1.41 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 한반도	42
그림 1.1.42 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 동아시아	43
그림 1.1.43 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 동아시아	43
그림 1.1.44 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 북반구	45
그림 1.1.45 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 북반구	45
그림 1.1.46 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 남반구	46
그림 1.1.47 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 남반구	46
그림 1.1.48 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 한반도	47
그림 1.1.49 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 한반도	47
그림 1.1.50 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 동아시아	48
그림 1.1.51 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 동아시아	48

그림 1.1.52 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	51
그림 1.1.53 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 12UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	53
그림 1.1.54 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	55
그림 1.1.55 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 12UTC T1000 (위-아래: Forecast Time 000~288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	57
그림 1.1.56 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 00UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)	58
그림 1.1.57 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 12UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)	59
그림 1.1.58 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 00UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)	60
그림 1.1.59 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 12UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)	61
그림 1.1.60 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast	

Time 이후 UKMO 모델 자료 없음)	63
그림 1.1.61 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	65
그림 1.1.62 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	67
그림 1.1.63 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	69
그림 1.1.64 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	73
그림 1.1.65 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 12UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	78
그림 1.1.66 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	83
그림 1.1.67 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 12UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO	

모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	88
그림 1.1.68 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 00UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	91
그림 1.1.69 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 12UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	93
그림 1.1.70 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 00UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	95
그림 1.1.71 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 12UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	97
그림 1.1.72 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	101
그림 1.1.73 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: KIM, ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	105
그림 1.1.74 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO	

모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	109
그림 1.1.75 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)	113
그림 1.1.76 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY AO Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	115
그림 1.1.77 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY AO Index 12UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	117
그림 1.1.78 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY AO Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	119
그림 1.1.79 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY AO Index 12UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	121
그림 1.1.80 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY PNA Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	123
그림 1.1.81 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY PNA Index 12UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	125
그림 1.1.82 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY PNA Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	127
그림 1.1.83 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY PNA	

Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	129
그림 1.1.84 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2021 JULY 00UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	131
그림 1.1.85 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2021 JULY 12UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	133
그림 1.1.86 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2022 JANUARY 00UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	135
그림 1.1.87 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2022 JANUARY 12UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)	137
그림 1.1.88 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2021 JULY 00UTC Temperature	139
그림 1.1.89 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2021 JULY 12UTC Temperature	140
그림 1.1.90 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2022 JANUARY 00UTC Temperature	142
그림 1.1.91 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2022 JANUARY 12UTC Temperature	143
그림 1.1.92 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2021 JULY 00UTC Geopotential	145
그림 1.1.93 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2021 JULY 12UTC Geopotential	146

그림 1.1.94 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2022 JANUARY 00UTC Geopotential	148
그림 1.1.95 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2022 JANUARY 12UTC Geopotential	149
그림 1.1.96 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY 00UTC Temperature	151
그림 1.1.97 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY 12UTC Temperature	152
그림 1.1.98 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 00UTC Temperature	154
그림 1.1.99 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 12UTC Temperature	155
그림 1.1.100 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY 00UTC Geopotential	157
그림 1.1.101 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY120UTC Geopotential	158
그림 1.1.102 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 00UTC Geopotential	160
그림 1.1.103 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 12UTC	

Geopotential	161
그림 1.2.1 2021년 6월 29일 발생한 북미 폭염 현상 (출처: (좌) Patrick Duplessis of Dalhousie University (우) Thomson et al. 2022)	165
그림 1.2.2 (상) 6월 7~13일 500hPa 지위고도 편차 (하) 850hPa stream function, wace activity flux, outgoing longwave radiation(OLR) (출처: Tokyo Climate Center; TCC)	166
그림 1.2.3 European heat wave 2018 사례에 대한 ECMWF 예측 모델의 앙상블 확률분포와 관측자료 (Domeisen, Daniela IV, et al., 2022)	168
그림 1.2.4 초기시간 00UTC 모델 예측자료 분석을 위한 2021년 6월 23일 00UTC부터 7월 3일 00UTC까지 재분석자료 1000hPa 기온 분포	169
그림 1.2.5 초기시간 12UTC 모델 예측자료 분석을 위한 2021년 6월 23일 12UTC부터 7월 3일 12UTC까지 재분석자료 1000hPa 기온 분포	170
그림 1.2.6 한국형앙상블모델 초기시간별 앙상블 평균 분석 결과 (00UTC)	171
그림 1.2.7 ECMWF 앙상블모델 초기시간별 앙상블 평균 분석 결과 (00UTC)	172
그림 1.2.8 한국형앙상블모델 초기시간별 앙상블 평균 분석 결과 (12UTC)	173
그림 1.2.9 ECMWF 앙상블모델 초기시간별 앙상블 평균 분석 결과 (12UTC)	174
그림 1.2.10 앙상블 모델 초기시간별 평균제곱근오차(°C) 박스플롯 분석 (Target time: 6/29, 초기시간 00UTC(위)/12UTC(아래), 회색박스플롯: 한국형앙상블모델, 노란박스플롯: ECMWF 앙상블모델, 회색실선: 한국형앙상블모델 앙상블평균, 노란실선: ECMWF 앙상블평균)	176
그림 1.2.11 KIM, ECMWF 모델의 초기시간별 확률분포 분석 결과 (점선은 관측자료를 의미, 검은 점선: 00/12UTC 평균, 파란 점선: 00UTC, 빨간 점선: 12UTC)	177
그림 1.2.12 KIM, ECMWF 모델의 초기시간별 확률분포 분석 결과 (점선은	

관측자료를 의미, 검은 점선: 00/12UTC 평균, 파란 점선: 00UTC, 빨간 점선: 12UTC)	178
그림 1.2.13 한국형양상블모델의 초기시간 00/12UTC의 1000hPa 기온 바이어스 분석장 (a-b) 및 24시간 예측장 (c-d) (Target Time: 2021.06.29)	179
그림 1.2.14 한국형양상블모델의 초기시간 00/12UTC의 2m 기온 바이어스 분석장 (a-b) 및 24시간 예측장 (c-d) (Target Time: 2021.06.29)	180
그림 1.2.15 2021년 7~8월 강수량 일별 시계열 (출처: 2021년 이상 기후보고서, 기상청)	181
그림 1.2.16 6월 19~30일 500hPa 지위고도 분포 (빨강/파랑 채색: 평년보다 높/낮은 지위고도) (출처: 2021년 이상 기후보고서, 기상청)	182
그림 1.2.17 ‘손에 잡히는 예보 기술’에 적합한 잘못된 장마 지수	183
그림 1.2.18 잘못된 장마 지수를 수정한 수식	183
그림 1.2.19 2021년 6월 27일부터 7월 14일까지의 장마 지수 (00UTC 기준, 검은 점선: 관측값, 회색 칸: 선정된 장마 기간)	184
그림 1.2.20 2021년 7월 1일부터 7월 21일까지 동아시아 지역 1일 누적 강수량 분포(00UTC 기준)	185
그림 1.2.21 예측일 2021년 7월 2일 기준 6월 21일부터 7월 2일의 강수량 패턴상관계수 박스플롯 분석 (회색 실선: 양상블 멤버 평균)	186
그림 1.2.22 예측일 2021년 7월 11일 기준 6월 30일부터 7월 11일의 강수량 패턴상관계수 박스플롯 분석(회색 실선: 양상블멤버 평균)	187
그림 1.2.23 2021년 6월 27일부터 7월 14일까지의 장마 지수, 초기시간 6/21~6/26 (검은 점선: 관측, 회색 칸: 장마 기간, 진한 빨간 선: 양상블 평균, 얇은 빨간 선: 양상블 멤버)	188
그림 1.2.24 2021년 6월 27일부터 7월 14일까지의 장마 지수, 초기시간 6/27~7/2 (검은 점선: 관측, 회색 칸: 장마 기간, 진한 빨간 선: 양상블 평균,	

얇은 빨간 선: 앙상블 멤버)	189
그림 1.3.1 Fig.11 of Miyoshi et al. 2010 [Miyoshi, T., Y. Sato, and T. Kadowaki, 2010: Ensemble Kalman filter and 4D-Var intercomparison with the Japanese operational global analysis and prediction system, Mon. Wea. Rev.]	191
그림 1.3.2 한국형앙상블모델과 기상청 UM앙상블모델의 비교	193
그림 1.3.3 앙상블 평균에러와 스프레드의 관계에 대한 예 (Courtesy of confluence.ecmwf.int)	194
그림 1.3.4 해면기압의 전지구평균에 대한 앙상블 평균의 절대 오차 (a), 앙상블 스프레드의 예보선행시간에 따른 변화 2021년 7월 1일부터 7월 22일 예보결과를 사용하였음	196
그림 1.3.5 위 그림과 같으나 2022년 1월 예보결과를 사용함.	197
그림 1.3.6 해면기압의 북반구(북위20도-90도)평균에 대한 앙상블 평균의 절대 오차 (a), 앙상블 스프레드의 예보선행시간에 따른 변화 2021년 7월 1일부터 7월 22일 예보결과를 사용하였음.	198
그림 1.3.7 위의 그림과 같으나 2022년 1월 예보결과를 사용한 결과임.	199
그림 1.3.8 해면기압의 열대(남위30도-북위30도)평균에 대한 앙상블 평균의 절대 오차 (a), 앙상블 스프레드의 예보선행시간에 따른 변화 2021년 7월 1일부터 7월 22일 예보결과를 사용하였음.	200
그림 1.3.9 위의 그림과 같으나 2022년 1월 예보결과를 사용한 결과임.	201
그림 1.3.10 2021년 7월 1일 00Z 초기조건으로 한 예보의 선행시간 1일 짜 해면기압의 오차	202
그림 1.3.11 위 그림과 같으나 예보선행시간 5일	203
그림 1.3.12 2022년 1월 1일 00Z 초기조건으로 한 예보의 선행시간 1일 짜 해면기압의 오차	204
그림 1.3.13 위 그림과 같으나 예보선행시간 5일	205

그림 1.3.14 해수면 기압에 대한 앙상블 표준편차로 추정된 앙상블 스프레드, 2021년 7월 예보에 대한 결과로 선행시간 1, 3, 5, 7일에 대한 분석임	207
그림 1.3.15 옆의 그림과 같으나 2022년 1월 예보자료에 대한 결과임	208
그림 1.3.16 앞의 그림과 같으나 지위고도장 200hPa	209
그림 1.3.17 옆의 그림과 같으나 2022년 1월 자료 분석한 결과임	210
그림 1.3.18 앞의 그림과 같으나 1,000hPa 온도	211
그림 1.3.19 옆의 그림과 같으나 2022년 1월 자료 분석한 결과임	212
그림 1.3.20 앞의 그림과 같으나 500hPa 온도	213
그림 1.3.21 옆의 그림과 같으나 2022년 1월 자료 분석한 결과임	214
그림 1.3.22 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 해수면기압 2021년 7월 평균장, 예보선행시간 1일에 대한 결과임	216
그림 1.3.23 왼쪽그림과 같으나 예보선행시간 7일에 대한 결과임	217
그림 1.3.24 위 그림과 같으나 2022년 1월에 대한 결과임	218
그림 1.3.25 왼쪽그림과 같으나 예보선행시간 7일에 대한 결과임	219
그림 1.3.26 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 해수면기압 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임	221
그림 1.3.27 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	222
그림 1.3.28 앞의 그림과 같으나 예보선행시간 5일	223
그림 1.3.29 왼쪽과 같으나 예보선행시간 7일	224
그림 1.3.30 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 해수면기압 2022년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임	225

그림 1.3.31 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	226
그림 1.3.32 앞의 그림과 같으나 예보선행시간 5일에 대한 결과임	227
그림 1.3.33 왼쪽과 같으나 예보선행시간 7일에 대한 결과임	228
그림 1.3.34 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 200hPa 지위고도장 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임	229
그림 1.3.35 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	230
그림 1.3.36 앞의 그림과 같으나 예보선행시간 5일에 대한 결과임	231
그림 1.3.37 왼쪽과 같으나 예보선행시간 7일에 대한 결과임	232
그림 1.3.38 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 200hPa 지위고도장 2022년 1월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임	233
그림 1.3.39 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	234
그림 1.3.40 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 1,000hPa 온도 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임	235
그림 1.3.41 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	236
그림 1.3.42 앞의 결과와 같으나 예보선행시간 5일에 대한 결과임	237
그림 1.3.43 왼쪽과 같으나 예보선행시간 7일에 대한 결과임	238
그림 1.3.44 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 1,000hPa 온도 2022년 1월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임	239
그림 1.3.45 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	240
그림 1.3.46 앞의 그림과 같으나 예보선행시간 5일에 대한 결과임	241
그림 1.3.47 왼쪽과 같으나 예보선행시간 7일에 대한 결과임	242

그림 1.3.48 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형양상블모델의 500hPa 온도 2021년 7월 양상블 표준편차, 예보선행시간 1일에 대한 결과임	243
그림 1.3.49 왼쪽과 같으나 예보선행시간 3일에 대한 결과임	244
그림 1.3.50 위 그림과 같으나 예보선행시간 5일에 대한 결과임	245
그림 1.3.51 왼쪽과 같으나 예보선행시간 7일에 대한 결과임	246
그림 1.3.52 위의 그림과 같으나 예보선행시간 5일에 대한 결과임	247
그림 1.3.53 위의 그림과 같으나 예보선행시간 7일에 대한 결과임	248

제 1 장 사업의 필요성

현업 예측 시스템을 활용한 중·장기 시간 규모 예측의 향상을 위해서는 물리 과정 개선, 고해상도 격자 체계와 같은 물리 역학 과정 개선을 통한 구조적 오차 개선, 예보 오차를 효과적으로 추정하고 적용된 다양한 자료동화 사이클을 고려한 비용 효과가 큰 앙상블 생성 방안 채택 등 다양한 방면의 향상 방법이 존재하나 (Oldenborgh et al., 2012; Vitart et al., 2017), 그에 앞서 초기 생산된 앙상블 자료에 대해 정량적으로 예측성을 진단하고 그 결과를 분석 및 검증하는 연구 단계가 필수적이다 (Lee et al., 2016; Ham et al., 2019; Hong et al., 2018). 일반적인 앙상블 모델의 예측 성능 및 모델의 구조적 오차 분석뿐만 아니라 계절별, 지역별로 세분화하여 통계 분석을 수행하여 앙상블 모델이 갖는 다양한 측면에서의 성능 진단을 진행할 필요가 있다.

뿐만 아니라, 중·장기 시간 규모의 대표적인 대기 현상 및 상태 사례 조사를 통해 극한 기상 현상(Extreme weather events) 사례에 대해 앙상블 예측 모델을 활용하여 예측성 분석 및 평가를 진행하여 모델의 성능을 파악할 필요가 있다. 특히, 극한기상현상은 사람의 건강, 경제활동, 생태계 등에 치명적인 영향을 미치기 때문에 이러한 피해에 대비하기 위해 최근 들어 기상 모델을 활용한 극한기상현상 예측의 필요성이 부각되고 있다 (Domeisen et al., 2022). 이에 따라, 앙상블 모델의 확률론적 예보는 단일이 아닌 여러 개의 예상 가능한 시나리오를 제공하기 때문에 앞으로 발생할 수 있는 극한 기상 현상에 대한 대비의 기회를 늘려줄 수 있다.

따라서 본 연구에서는 한국형앙상블모델의 예측 성능 및 모델의 구조적 오차를 국외 연구기관에서 활용되는 다양한 앙상블 모델 자료와의 비교를 통해 정량적으로 평가하고, 계절별, 지역별 분석 등 세분화한 분석 접근법을 기반으로 다양한 예측 진단 분석을 진행하였다. 뿐만 아니라, 앙상블 평균 및 앙상블 Spread 자료를 모두 활용하여 앙상블 모델 예측 자료의 평균적인 성능 평가와 동시에 앙상블 분포에 대한 평가도 진행하여 현재 수행되고 있는 자료 동화 시스템 활용 능력에 대한 정보도 객관적으로 평가하였다. 마지막으로, 예측 활용 성능 진단을 위해 대표적인 극한기상현상 사례를 선정하여 예측 특성을 진단 및 평가하고 성능 개선을 위한 개선점을 제시하였다.

국외 예보모델의 경우, 4DVar(4D-Variational Data Assimilation) 혹은 그 변형 형태를 활용하고 있으며, 한국형앙상블모델의 경우 앙상블자료동화 (Local Ensemble Transform Kalman Filter; LETKF)를 사용하고 있다. EnKF(Ensemble Kalman Filter)와 4DVar 기법은 서로 상보적일 수 있음이 많은 선행 연구를 통해 알려져 있으며, 가령 4DVar와 EnKF가 북반구에서는 거의 같은 성능을 보여주지만 남반구에서는 EnKF가 좀 더 나은 결과를 보여주는 연구가 있다. 이와는 달리 EnKF가 북반구에서는 좀 더 나은 결과를, 4DVar가 남반구에서 더 나은 결과를 보여주는 연구도 소개되고 있다. EnKF는 Adjoint Model이 필요하지 않고 계산 속도 등이 빠를 수 있다는 장점은 널리 알려져 있다. 이에 본 연구에서는 확보된 예보 앙상블 자료를 분석하고 한반도를 포함한 동아시아 지역에서의 자료동화 기법에 의한 차이점을 확인하였다.

앞서 언급한 선행연구에서 일본기상청(Japan Meteorological Agency; JMA)현업예보모델에 4DVar 기법과 LETKF 기법을 동일하게 적용하여 그 성능을 비교하였으며, LETKF가 좀 더 빠른 계산 성능과 적도와 북반구에서 좀 더 나은 결과를 보인 반면, 남반구에서는 4DVar가 더 나은 성능을 보여주고 있다 (Miyoshi et al., 2010). 이 원인으로 LETKF 앙상블 기법은 모델의 에러에 좀 더 민감한 것으로 알려져 있다. 본 연구에서는 활용 가능한 현업 예보 모델의 앙상블 spread와 앙상블 error 상관성을 분석하였다.

이와 함께 앞서 언급한 분석을 한국형앙상블모델과 UM 모델 결과와 비교 분석함으로써 모델간의 차이와 기법에 의한 차이를 확인하였으며, 또한 이러한 차이가 팽창기법에 민감한지에 대해서도 앙상블 spread와의 상관성 분석을 진행하였다.

제 2 장 사업 목적

1) 한국형양상불모델의 예측특성 진단

- 한국형양상불모델의 일반적인 예측경향과 계절별 편차 분석 및 진단
- 한국형양상불모델의 양상불 예측 특성 평가를 위한 진단기술 활용 분석 및 평가

2) 한국형양상불모델의 Spread 특성 분석

- 국외양상불모델과의 섭동기법 비교 분석
- 양상불 Spread와 양상불 에러의 상관성 분석
- 한국형양상불모델 양상불 자료동화와 양상불 Spread와의 상관성 분석
- 한국형양상불모델 팽창 기법과 양상불 Spread와의 상관성 분석

제 3 장 사업 개요

1) 한국형양상불모델의 예측특성 진단

- 한국형양상불모델의 일반적인 예측 경향과 계절별 편차(Bias) 분석 및 진단
 - 한국형양상불모델의 예측 성능 및 모델의 구조적 오차 분석을 위한 관측자료 및 국외 양상불 모델 예측 자료 확보
 - 한국형양상불모델의 예측 성능 파악을 위한 예측 진단 변수 및 계절별, 지역별 예측 경향성의 시계열 상관성 분석과 공간 분포 분석 수행
 - 한국형양상불모델의 구조적 오차 파악을 위한 통계적 분석 수행
- 한국형양상불모델의 양상불 예측 특성 평가를 위한 진단기술 활용 분석 및 평가
 - 한국형양상불모델의 양상불 예측 성능을 진단하기 위한 중·장기 시간 규모의 대표적인 대기 현상 및 상태 사례 조사와 이를 활용한 계절별, 지역별 예측 특성 분석 수행 및 평가

2) 한국형양상불모델의 Spread 특성 분석

- 국외양상불모델과의 섭동기법 비교 분석
 - 국외 현업예보모델 결과 확보 및 자료 구축
- 양상불 Spread와 양상불 에러의 상관성 분석
 - 한국형양상불모델의 양상불 멤버 분포(Spread) 기반의 정량적·통계적 분석 수행 및 양상불 에러와의 상관성 분석 수행
 - 다양한 양상불 산포를 활용한 예측 성능 평가 기법 조사 및 분석
- 한국형양상불모델 양상불자료동화와 양상불 Spread와의 상관성 분석을 통한 모델 개선점 제시
- 한국형양상불모델 팽창기법과 양상불 Spread와의 상관성 분석을 통한 모델 개선점 제시

제 4 장 사업 수행 내용 및 결과

1. 자료

(1) 재분석 자료: ECMWF Reanalysis version 5 (ERA5)

- 유럽중기예보센터(European Centre for Medium-Range Weather Forecasts; ECMWF)에서 제공하는 ERA5는 1979년 이후 대기장에 대해 2006년부터 제공하기 시작한 ERA-Interim 자료를 대체한다. ERA5는 2016년에 운영된 통합예측시스템(Integrated Forecasting System; IFS) Cy41r2를 기반으로 하여 10년간 발전해온 모델 물리과정, 역학코어, 자료동화를 적용한 자료이다. 또한 ERA5의 수평 해상도는 ERA-Interim의 80km 해상도 보다 고해상도인 31km 해상도를 가지고 있다 (Hersbch, Hans, et al., 2020).
- 본 연구에서는 고해상도인 한국형양상블모델과 비교·검증을 위해 상대적으로 고해상도 재분석자료인 ERA5를 재분석자료로 선택하여 분석에 활용하였다 (표 1.1.1).

표 1.1.1 ECMWF ERA5 재분석 자료 정보

Institution	European Centre for Medium-Range Weather Forecasts (ECMWF)
Data	https://www.ecmwf.int/en/forecasts/dataset/ecmwf-reanalysis-v5
Variables	(1) Temperature (°C) (2) Geopotential height (gpm) (3) U-wind and V-wind (m/s) (4) Mean Sea Level Pressure (hPa)
Temporal coverage	June - February 2021 - 2022 (Hourly)
Spatial resolution	0.25°×0.25°
Vertical resolution	37-levels

(2) 관측 자료: NASA Global Precipitation Measurement Mission (GPM)

- NASA의 GPM (Global Precipitation Measurement Mission) 위성은 2014년에 발사되어 현재까지 65°S-65°N의 관측범위에서 관측을 수행하고

있다. GPM 위성에 탑재된 DPR (Dual-frequency Precipitation Radar)은 두 주파수로 강수 구름을 관측하여 과거 관측 방법에 비해 높은 정확도를 가지는 강수 변수를 얻을 수 있다.

- 본 연구에서는 극한기상분석 파트의 짧은 장마사례를 분석하기 위해 GPM 데이터를 활용하였다. 또한 모델 데이터와의 시간 해상도 일치를 위해 30분 간격의 누적 강수량 데이터를 일 누적 강수량으로 변환하여 분석하였다 (표 1.1.2).

표 1.1.2 NASA GPM 관측 자료 정보

Institution	National Aeronautics and Space Administration (NASA)
Data	https://gpm.nasa.gov/data/directory
Variables	Precipitation (mm/h)
Temporal coverage	June - July 2021 (30 Minute)
Spatial resolution	0.1°×0.1°

(3) 모델 자료: 한국형양상블모델 (Korean Integrated Model; KIM)

- 2020년부터 현업 활용되고 있는 한국형 수치예보모델을 바탕으로 2021년 10월부터 한국형 수치예보모델 기반 양상블예측시스템(이하 한국형양상블모델)이 운영되고 있다. 한국형양상블모델은 기후학적 배경오차공분산과 이전 사이클의 양상블 모델에서 생성된 오차공분산을 혼합하여 사용하는 Hybrid-4DVar(four-dimensional variational data assimilation) 자료동화 체계로 구성되어있다. 또한, 한국형양상블모델 기반의 중기 확률예측 정보를 제공할 수 있도록 기존의 시스템을 활용하여 수평 해상도 32km의 양상블 예측 시스템을 구축하였으며, 00, 12UTC 예측 자료를 기준으로 모델 수행이 진행되었다. 기존 자료 검증에 따르면, 해상도에 따른 예측 성능은 확률 예측에 사용된 양상블 멤버의 개수에 상관없이 전반적으로 50km 해상도 대비 32km 양상블 예측 시스템의 예측 성능이 안정적으로 해상도 개선의 효과를 보여주고 있음을 입증하였다.

또한, 동일한 해상도의 경우, 섭동 멤버가 26개인 경우 51개 앙상블 개수 대비 성능이 다소 저하되었으나, 그 차이가 미비하여 26개의 앙상블로도 전체 시스템이 가지는 효과를 보여주는 것을 확인하였다 (권순일 외 2019; 신현철 외, 2021). 이에 본 연구에서는 위와 같은 시스템 구성을 기반으로 한 한국형앙상블모델의 앙상블 예측 자료를 활용하였다 (표 1.1.3-1.1.4).

표 1.1.3 한국형앙상블모델과 기상청 UM 앙상블 모델 비교 (한국형수치모델링센터 제공)

		한국형앙상블모델	UM 앙상블모델
수평해상도		32 km (ne090np3)	32km (N400)
연직층		91층	70층
초기 섭동	방법	LETKF (50개)	ETKF(48개)
	Inflation	AdditiveInflation, RTPS inflation	Multiplicative Inflation
	Localization	모든 격자	수평 80 지점, 연직 4층
초기 지면 섭동		SST	SST, SMC, Tsoil
통계 물리		SPPT, SPDT, SSST	RP2, SKEB2
Analysis Recentering		u, v, t, q (50%) ps(100%)	u, v, t, q, π(100%)
중기예측		이른분석 00/12UTC (컨트롤+25 개 섭동) 26개 멤버	이른분석 00/12UTC (컨트롤+시간차24개 섭동)

표 1.1.4 분석에 활용된 한국형앙상블모델 자료 정보

Institution	Korea Meteorological Administration (KMA)
Variables	(1) Temperature (°C)
	(2) Geopotential height (gpm)
	(3) U-wind and V-wind (m/s)
	(4) Mean Sea Level Pressure (hPa)
Temporal coverage	June, July, August, September, December, January 2021 - 2022 (Hourly)
Spatial resolution	0.25°×0.25° (Interpolation to 1°×1°)
Vertical resolution	6-levels (1000, 925, 850, 700, 500, 200hPa)

(4) 모델 자료: THORPEX Interactive Grand Global Ensemble (TIGGE) Project

- WMO 산하의 WWRP(World Meteorological Organization)의 프로그램 중 하나인 THORPEX(The Observation, Research and Predictability

Experiment)에서는 전 세계 현업 기관에서 사용하는 앙상블 모델들을 이용하여 1일에서 2주 규모의 위험 기상에 대한 예측성을 향상시키기 위해 2005년부터 TIGGE(THORPEX Interactive Grand Global Ensemble) 사업을 수행하고 있다 (Bougeault et al., 2010; Swinbank et al., 2016). 우리나라 기상청을 포함하여 전 세계 약 10여개 현업 기관들이 앙상블 모델 자료를 ECMWF 아카이브 센터를 통해서 grib2 포맷으로 제공한다. 최근 들어 2006년부터 축적된 TIGGE 자료를 활용하여 앙상블 모델의 성능 비교, 다중모델 앙상블 기법 개발, 편차 보정, 다운 스케일링 등에 관한 다양한 연구들이 활발하게 진행되고 있다 (Hagedorn et al., 2016; Amiyavati et al., 2018; Amini et al., 2021). 이에 본 연구에서도 한국형앙상블모델의 예측 성능을 정량적으로 평가하고 객관적으로 진단하기 위해 TIGGE 모델 자료를 이용하여 비교 분석하였다. 분석에는 ECMWF, UM(KMA), UKMO 세 기관의 자료를 비교 자료로 활용하였다 (표 1.1.5-1.1.6).

표 1.1.5 TIGGE Project 활용 모델 정보: ECMWF, UM(KMA), UKMO

Center	Ensemble member	Base time	Model resolution	Initial perturbation	Data assimilation method	Forecast length
ECMWF	51	00, 12	TL399	Singular vectors	4D-Var 12h window	360h at 6h
UM(KMA)	24	00, 12	N320	ETKF (Ensemble Transform Kalman Filter)	4D-Var (interpolated from operational N320 resolution analysis)	240h at 6h
UKMO	24	00, 12	N214	ETKF (Ensemble Transform Kalman Filter)	4D-Var (interpolated from operational N512 resolution analysis)	360h at 6h

표 1.1.6 분석에 활용된 TIGGE Project 모델 자료 정보

Institution	THORPEX Interactive Grand Global Ensemble (TIGGE) Project
Data	https://apps.ecmwf.int/datasets/data/tigge/levtype=sfc/type=cf/
Variables	(1) Temperature (°C) (2) Geopotential height (gpm) (3) U-wind and V-wind (m/s) (4) Mean Sea Level Pressure (hPa)
Temporal coverage	June, July, August, September, December, January 2021 - 2022 (Hourly)
Spatial resolution	1°×1°
Vertical resolution	6-levels (1000, 925, 850, 700, 500, 200hPa)

2. 한국형앙상블모델의 예측특성 진단

2.1 한국형앙상블모델의 일반적인 예측 경향과 계절별 편차(Bias) 분석 및 진단

(1) 분석 방법

- 앙상블 평균 월별 예측 성능 평가: Averaged Score
 - 앙상블 평균 월별 예측 성능은 각 모델별 앙상블 평균에 대해 월별로 분석을 진행하였으며, 총 4개의 영역에 대해 분석을 진행하였다. 1) 북반구 (20-90°N), 2) 남반구 (20-90°S), 3) 한반도 (33-34°N, 124-132°E) , 4) 동아시아 (20-60°N, 90-160°E) 영역으로 각각의 분석을 진행 후 영역에 대한 평균을 진행하여 Forecast Time 별로 모델의 예측 성능 변화를 정량적으로 평가하였으며, 비교 자료는 ECMWF ERA5 재분석 자료를 활용하였다. 앙상블 모델의 경우 00, 12UTC 각각에 대한 분석을 진행하였으며, 본 보고서에는 지표 온도 (T1000), 850hPa 기온 (T850), 500hPa 지위 고도장 (Z500) 분석 결과를 중심으로 기술하였다. 앙상블 Forecast Time의 경우 0~288hr 시간을 24hr 간격으로 총 13개의 Forecast Time에 대해 살펴보았으며, UKMO의 경우 자료의 한계로 144hr Forecast Time까지 분석을 진행하였다.
 - 앙상블 모델의 예측성을 객관적, 정량적으로 비교하기 위해 다양한 예측성 분석 기법을 활용할 수 있는데, 본 연구에서는 전통적인 예측성 평가 기법들 중 이상상관계수(Anomaly Correlation Coefficient; ACC), 평균제곱근편차(Root Mean Square Error; RMSE)를 활용하였으며, 앙상블 산포에 대한 정량적인 정보를 확인하기 위해 앙상블 분산 분석 (Ensemble Spread), Spread Skill (Rate) 분석을 진행하였으며 상세한 방법은 아래에 기술하였다.
- 1) 이상상관계수 (Anomaly Correlation Coefficient; ACC)
 - 이상상관계수는 모델의 예측 결과 편차와 관측 자료 편차의 상관성을 기준으로 진단하며, 값이 1에 가까울수록 모델의 결과가 관측 자료와의 높은 상관성을 보임을 의미한다 (Choi et al., 2016).

$$ACC(\tau) = \frac{\frac{1}{n} \sum_{j=1}^n [H_{j\tau} - \bar{H}_\tau][O_{j\tau} - \bar{O}_\tau]}{\sqrt{\frac{1}{n} \sum_{j=1}^n [H_{j\tau} - \bar{H}_\tau]^2} \sqrt{\frac{1}{n} \sum_{j=1}^n [O_{j\tau} - \bar{O}_\tau]^2}}$$

이때, $H_{j\tau}$ 는 각 초기장에 따른 앙상블을 평균한 모델 값을 의미하며, j 는 대상이 되는 월에 대한 총 20년 동안 각 해에 해당하는 값을 의미함. τ 는 예측 시기와 초기된 시기의 차이 즉 Lead Time 이며, $O_{j\tau}$ 는 $H_{j\tau}$ 에 상응하는 시기의 관측(재분석)값을 의미함. \bar{O}_τ 와 \bar{H}_τ 는 각 Forecast Time에 따른 전체 시기의 평균으로 아래와 같이 정의 된다.

$$\bar{H}_\tau = \frac{1}{n} \sum_{j=1}^n H_{j\tau}, \quad \bar{O}_\tau = \frac{1}{n} \sum_{j=1}^n O_{j\tau}$$

2) 평균제곱근오차 (Root Mean Square Error; RMSE)

- 평균제곱근오차는 모델이 예측한 값과 관측값의 차이를 다룰 때 사용되는 통계적인 척도로서 예측의 정밀도(Precision)를 측정하는데 적합하다. 각각의 차이값은 잔차(Residual)이라고도 하며, 평균제곱근오차는 이러한 잔차들을 하나의 척도로 종합할 때 활용되며 앙상블 예측 결과를 $\hat{\theta}$ 라고 할 때, 이 $\hat{\theta}$ 값의 평균 제곱근 편차를 평균 제곱 오차의 제곱근으로 정의하면 아래와 같이 표현할 수 있다 (Kim et al., 2018).

$$RMSE(\hat{\theta}) = \sqrt{MSE(\hat{\theta})} = \sqrt{E((\hat{\theta} - \theta)^2)}.$$

3) 앙상블 분산(Spread)

- 앙상블의 Spread 분석은 각 모델의 개별 앙상블들이 앙상블 평균으로부터 얼마나 떨어진 곳에 분포하는지를 판단할 수 있다. 이 분석은 앙상블 평균을 뺀 값을 제공하고 그것을 모두 더한 후 전체 앙상블 개수로 나눠서 구하는 방법이다. 즉, 차이값의 제곱의 평균으로 앙상블 평균을 뺀 값인 편차를 모두 더하면 0이 나오기 때문에 제곱해서 더하는 방식으로 계산을 진행한다. 앙상블 분산은 각 모델의 앙상블에 대해서 각각 분석하여 진행한다. 확률변수 X 의 분산은 X 의 기댓값 $\mu = E[X]$ 로부터 확률 변수가 얼마나 떨어져 있는지 그 정도를 제공한 것의 기댓값과 같으므로 이를 수식으로

나타내면 다음과 같다 (Kolczynski et al., 2011).

$$\text{Var}(X) = \text{E}[(X - \mu)^2]$$

4) Spread Skill

- Spread Skill은 분산과 평균제곱근오차의 차이를 이용하여 성능을 평가하는 기법으로 각 모델 별로 앙상블 개수(m)를 자유도에 반영하여 나타낸다. 분석 방법은 아래와 같다 (Scherrer et al., 2004).

$$\text{Spread Skill}(\text{Rate}) = \frac{((m+1) \times \text{Spread}^2)}{((m-1) \times \text{RMSE}^2)}$$

- 앙상블 평균 공간 분포 예측 성능 평가 (Spatial Distribution Analysis)
 - 앙상블 공간 분포 예측 성능은 편차(Bias) 분석, 평균제곱근오차(RMSE) 분석, 분산(Spread) 분석을 진행한다. 이는 앞선 영역 평균이 아닌 각 격자에 대해서 분석하여 공간으로 표출하여 성능을 평가한다. 공간 분포 예측 성능은 1) 북반구 (20-90°N), 2) 동아시아 (20-60°N, 90-160°E) 지역에 대해 분석을 진행한다. 앞선 평균제곱근오차 방법과 분산 방법은 공간 분포 분석에도 동일하게 적용된다. 앙상블 공간 편차 분석은 본 연구에서 기준 자료로 사용되는 ERA5 재분석 자료와 각 모델별 앙상블 평균 자료와의 차이로 계산한다.
- 앙상블 평균 원격상관 예측 성능 평가 (Teleconnection Analysis)
 - 원격상관은 내부 대기 역학에 따라 자연적으로 발생하며 (Barnston and Livezey, 1987), 이 패턴들은 대기 파동과 제트류를 변화시켜 먼 거리에 위치한 지역에 온도, 강수 등 기후를 변화시킨다. 특히, 중위도 날씨와 밀접한 연관이 있는 북극 진동(Arctic Oscillation; AO Pattern)과 태평양-북아메리카 패턴(Pacific/North Atlantic Pattern; PNA Pattern)을 선정하여 앙상블 모델에서의 예측 성능을 평가하고, 원격상관 지수 분석을 통해 모델의 원격상관 예측 성능을 진단하였다.

1) 북극진동 지수 (Arctic Oscillation, AO Index) 분석

- 북극진동(Arctic Oscillation; AO)이란, 북극에 존재하는 찬 공기의 소용돌이가 수십 일 또는 수십 년 주기로 강약을 되풀이하는 현상으로서, 이 변동을 지수화 한 것이 북극진동지수(Arctic Oscillation Index; AOI)이다. 일반적으로, 북극진동지수가 음(-)의 위상이 되면, 북극의 찬 공기 소용돌이(Polar Vortex)가 약화됨에 따라 북극 지방의 한랭 공기가 중위도로 남하하게 되어 중위도에 엄동이 나타난다. 반대로 양(+)의 위상일 때는 중위도에 난동이 나타난다.

- 최근 중위도에 자주 발생하는 한파의 경우 북극 진동과의 연관성을 살펴보면, 북극의 온도가 상승하여 해수면 대기압이 상대적으로 고기압이 되고, 주변의 중위도 해수면 대기압이 저기압이 되어 이 두 지역 사시에 상대적으로 온도 경도가 약해질 때를 음(-)의 값은 갖는 북극 진동이라 하는데, 제트기류는 온도 경도에 의해서 발생하기 때문에 온도 경도가 약해지면 제트기류를 이루고 있는 흐름에서 평균 흐름(Mean Flow)의 벡터가 약해지면서 동요된 흐름(Perturbation Flow)이 차지하는 부분이 상대적으로 커지기 때문에 다른 방향으로의 벡터 요소(Component)가 발생하게 되어 위, 아래로의 큰 진폭(Amplitude)을 나타내며 진동하게 된다. 이런 위, 아래로의 큰 진폭은 결국 북극의 찬 공기를 중위도까지 끌고 내려오게 되며 이에 따라 결과적으로 우리나라에 차가운 공기가 도달하며 한파가 발생하게 된다. 또한, 북극진동은 성층권(Stratosphere)과도 밀접한 연관이 있는데, 특히 성층권 돌연 승온(Stratospheric Sudden Warming; SSW)과 북극 진동 사이는 성층권 돌연 승온으로 인하여 성층권의 기온이 갑자기 상승하게 되면 극지역의 온도 상승에 영향을 주어 북극 진동이 음의 값을 갖는 변화를 야기하여 우리나라 한파에 영향을 줄 수 있다는 가능성을 제시할 수 있다. 하지만, 성층권 돌연 승온에 따른 북극 진동 변화 사이의 역학적인 해석에 관해서는 아직 다양한 원인들이 언급되고 있다.

- 분석 방법: 북극진동 지수 분석을 위해, NOAA CPC(National Oceanic and Atmospheric Administration Climate Center)에서 제공하는 원격상관 패턴을 기반으로 북극 진동 모드(Arctic Oscillation Loading Pattern; 1979-200, 그림 1.1.1)를 정의하였다. 북위 20-90°N의 해수면 기압(Mean

Sea Level Pressure; MSLP) 변수를 활용하여 경험적 직교 함수(Empirical Orthogonal Function; EOF) 방법으로 AO 패턴을 계산하였다. AO 패턴은 주성분 모드로 1st 모드로 정의되며 본 모드에 재분석 자료 및 각 모델 자료들의 일별 자료를 투영(Projection)하여 얻은 각각의 지수들을 표출하였으며, 예측 성능을 정량적으로 판단하기 위해 지수에 대한 이상상관계수 분석을 진행하였다.

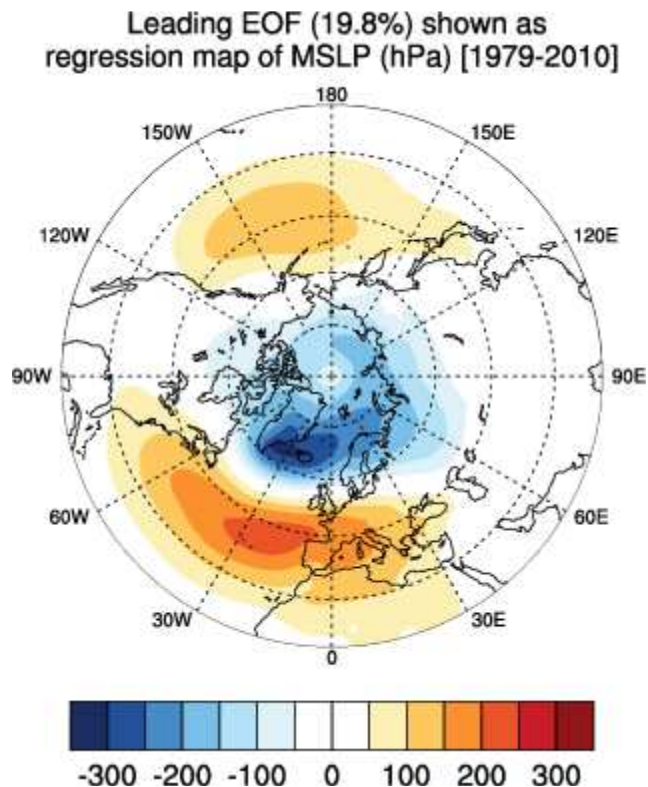


그림 1.1.1 북극진동 모드 (Arctic Oscillation; AO) Loading Pattern (1979-2000; ERA5)

2) 태평양-북아메리카 지수 (Pacific/North Atlantic; PNA Index) 분석

- 파동이 먼 지역까지 영향을 미치는 현상을 ‘대기의 원격상관(Teleconnection)’이라고 하는데 그 중 태평양 지역과 북미 지역과 밀접한 연관이 있는 PNA 패턴은 태평양과 북미 대륙과의 대규모 날씨 패턴으로, 제트기류의 변화와 관련되어 있으며, ENSO(El Niño-Southern Oscillation) 현상과도 관련되어 있다.

- PNA 패턴의 양(+의 위상)은 엘니뇨와 관련되어 있으며, 음(-의 위상)은

라니냐와 관련되어 있다. 엘니뇨 시기에는 중태평양의 대류가 활발해져 강수량이 증가하며, 대류의 영향이 북쪽으로 전파되면서 고기압과 저기압의 파동을 만나는데 이런 기압 배치의 가장 대표적인 예가 바로 PNA 패턴이다. 엘니뇨 시기의 PNA 패턴은 북태평양 고기압과 알류산 저기압을 강화시키고, 알류산 저기압을 동쪽으로 이동시킨다. 이때, 태평양 대기 상층의 제트기류도 동쪽으로 확장 또는 강화된다. 이러한 기압 배치는 결국 중위도 대기 순환에도 영향을 준다. 이렇게 파동이 먼 지역까지 영향을 미치는 현상을 앞서 말한 '대기의 원격상관'이라고 한다.

- PNA 패턴의 위상 별 특징을 보면, 양(+의 위상일 때) 중앙 태평양의 수온이 평년에 비해 낮지만 북미 서해안의 수온은 높다. 중위도 제트기류는 동아시아에서 태평양으로 이동하면서 강화되는데 북미 서부 산맥에는 정상 시보다 강한 기압능이 위치하고, 알류산 열도와 미국 동남부에는 정상 시보다 강한 기압골이 위치하기 때문에 상층에는 강한 남북 흐름이 존재한다. 이와 같은 기압 배치 하에서 미국과 캐나다 서부 지역의 기온은 평균보다 높은 반면에, 미국의 동남부는 북극 기단이 제트기류를 따라 미국 동부에 형성된 기압골로 남하하기 때문에 평소보다 차고 습한 날씨가 지속된다. PNA 패턴이 음(-)의 위상일 때 중앙 태평양의 수온은 평년에 비해 높지만 북미 서해안의 수온은 낮다. 중앙 태평양을 가로지르는 제트기류는 약화된다. 알류산 저기압이 약화되고 북미 서해안에 기압골이 위치하기 때문에 상층의 바람 패턴은 동서 흐름이 남북 흐름 보다 강화된다. 이 경우 특히 서해안은 눈보라와 폭풍이 많고 매우 추운 반면에, 미국 중부와 동부는 평년에 비해 온화하고 건조한 날씨가 된다.

- 분석 방법: PNA Index는 AO Index와 분석 방법이 동일하나, 태평양-북아메리카 패턴(Pacific/North Atlantic Pattern; PNA Pattern)을 정의하기 위해 500hPa 지위 고도장 변수를 사용하여 Loading Pattern을 계산하였다 (그림 1.1.2). 패턴 정의를 위해 기존 EOF 방법이 아닌 회전-경험적직교함수(Rotated Empirical Orthogonal Function; REOF) 방법을 활용하였으며, PNA 패턴의 경우 REOF에서 얻은 모드들 중 2nd 모드로 정의된다. PNA 패턴에 재분석 자료 및 각 모델들의 일별 자료를 투영하여 재분석 자료에서 얻은 PNA 지수와 각 모델들에서 얻은 지수들을 시계열로

표출하였으며, 정량적 평가를 위해 지수들끼리의 이상상관계수 계산을 진행하였다.

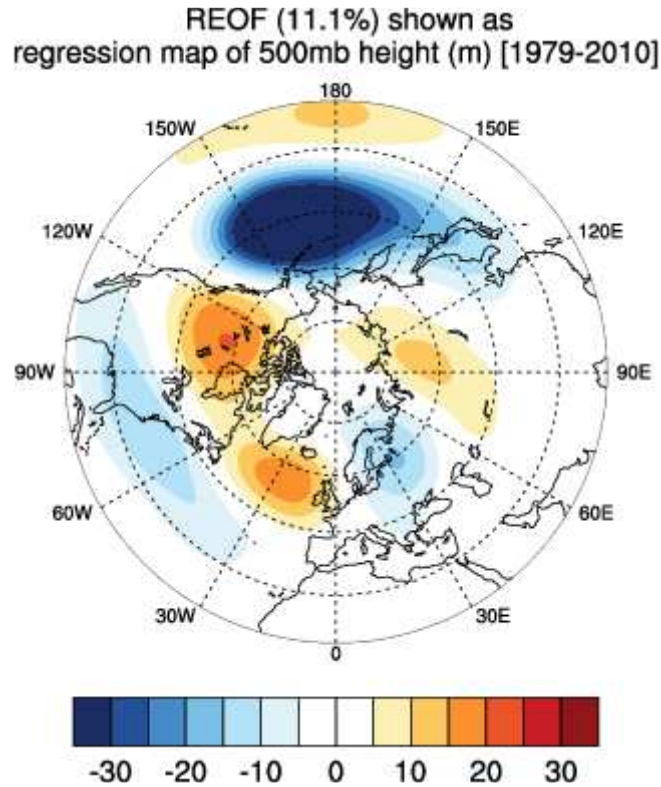


그림 1.1.2 태평양-아메리카 모드 (Pacific/North Atlantic; PNA) Loading Pattern (1979-2000; ERA5)

- 앙상블 평균 블로킹 예측 성능 평가 (Blocking Frequency)
 - 블로킹은 중위도 편서풍대에서 상층의 고·저기압이 정체하며 상층에서 동서바람(Zonal Wind)이 약화되고 남북바람(Meridional Wind)가 강화되는 현상을 말한다 (기상학 사전 1992; Glossary 2000). 일반적인 블로킹 탐지 기준은 500hPa 지위 고도장을 이용하여 분석한다. 이런 블로킹 현상을 객관적으로 정의하기 위해 여러 방법으로 연구가 시도되었으며, 기존의 블로킹 연구 결과를 총 4개의 요소(패턴 분석, 아노말리, 위도차, 파동)별로 구분하여 탐지에 적용한다 (허혜숙 외 2002; 표 1.1.7). 본 연구에서는 표 1.1.7에 정리된 방법 중 Tibaldi and Molteni (1990)의 TM90 방법을 활용하였다.

표 1.1.7 요소별 블로킹 탐지 기법 (출처: 허혜숙 외, 2002)

요소	연구자	년도	분석고도 (hPa)	블로킹 기준	지속시간
패턴 분석	Rex	1950	500	서풍이 두 갈래로 나뉘지고, 경도 45도 이상 유지	10일
	Triedl	1981	500, 지상	지상과 상층에 연결된 고기압이 30N 북쪽에 위치	5일
아노말리	Dole & Gordon	1983	500	아노말리가 +100m 이상, -100m 이하	10일
위도차	Lejens & Okland	1983	500	고도차(40N-60N). 0이하일 때	
	Tibaldi & Molteni	1990	500	$GHGS = \frac{Z(\phi_0) - Z(\phi_s)}{\phi_0 - \phi_s}$ $GHGN = \frac{Z(\phi_s) - Z(\phi_0)}{\phi_s - \phi_0}$ $\phi_s = 80N + \Delta$ $\phi_0 = 60N + \Delta$ $\phi_s = 40N + \Delta$ $\Delta = -5^\circ, 0^\circ, 5^\circ$ (a) GHGS > 0 (b) GHGN < -10 m/°N	5일
	Barriopedro et al.	2006	500	Tibaldi and Molteni(1990)와 같으나 위도가 77.5, 60, 40°N 임	5일
파동	Renwick & Revell	1999	500	파 진폭이 5일평균의 표준편차가 0.5 이상	

- 블로킹 탐지 방법 (Tibaldi & Molteni (1990); TM90)

: 대표적으로 가장 많이 사용되고 있는 Tibaldi and Molteni (1990)가 개발한 1차원 국지 역전 탐지 기법인 TM90 블로킹 탐지 기법은 그림 2.1.3과 같이 특정 위도 대를 기준으로 등거리 간격에 대해 500hPa 지위 고도의 남북 경도가 강한 지역을 역전되었다고 보고, 역전된 지역이 최소 5일 이상 지속되었을 때를 블로킹으로 간주하는 방식이다. 이 방법은 장기간에 대한 편차를 따로 구할 필요가 없으며, 원시 자료 그대로 사용할 수 있어서 모델에서도 손쉽게 적용할 수 있기 때문에, 블로킹을 평가할 수 있는 보편적인 도구로 사용되고 있다. 계산 과정은 상층 500hPa 지위 고도장의 60°N 기준(특정 위경도)에서 80°N(고위도) 보다 10gpm 이상 크며, 40°N(저위도) 보다 기압이 작지 않은 고기압이 발생한 날을 블로킹 발생일(Blocked Day)로 선정하였으며, 본 연구에서는 3일 이상 지속되었을 때를 블로킹으로 간주하였다 (그림 1.1.3).

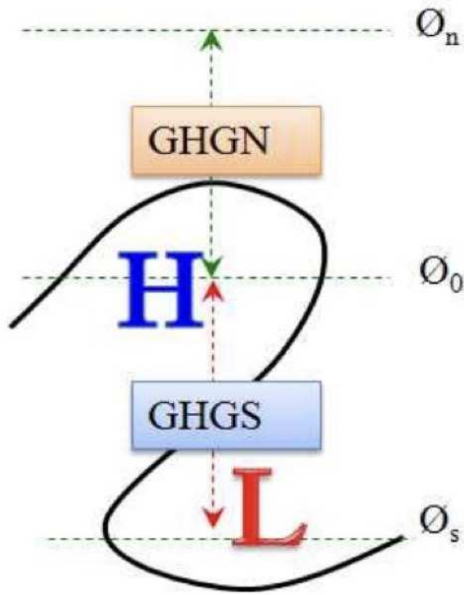


그림 1.1.3 블로킹 탐지 방법: 블로킹 형태를 수치로 계산하는 법

- 블로킹 발생 빈도 (Blocking Frequency) 정의

: 블로킹 발생 빈도는 전체 기간 중 각 앙상블 모델들에서 블로킹이 탐지된 블로킹 발생 일자에 대해 빈도로 정의한다.

$$Blocking\ Frequency(\%) = \frac{Ensemble\ Blocked\ Days}{Periods} \times 100(\%)$$

- 블로킹 발생 영역 정의

: 본 연구에서 활용된 블로킹은 전체 경도에 대해 블로킹 탐지를 진행하였으며, 각 영역별로 표 1.1.8과 같이 정의하였다.

표 1.1.8 블로킹 발생 영역 정의

블로킹 영역	블로킹 발생 영역			
	우랄 블로킹	오호츠크 블로킹	북태평양 블로킹	북대서양 블로킹
	0-90°E	90-180°E	90-180°W	0-90°W

(2) 한국형앙상블모델 예측 경향 분석 및 진단 결과

본 연구 분석 보고서의 분석 결과는 다음과 같은 정보를 바탕으로 기술하였다.

- 분석 결과는 2021년 7월(여름철), 2022년 1월(겨울철) 두 기간에 대해

작성되었다.

- 분석 변수는 지표 온도(T1000), 850hPa 온도(T850), 500hPa 지위 고도장(Z500) 변수에 대해 결과를 기술하였으며, T850의 경우 TIGGE Project 데이터 부족으로 한국형양상블모델(KIM) 모델에 대해서만 ERA5 재분석 자료와의 비교 분석을 진행하여 표출하였다. 그 외 변수들은 한국형양상블모델(KIM), ECMWF, UM(KMA), UKMO 양상블 모델들을 비교 분석 결과를 표출하였다.
- Forecast Time의 경우 0~288hr 범위에 대해 24hr 간격으로 분석하였으며 다만, UKMO 모델의 경우 Forecast Time 자료의 한계로 144hr Forecast Time 까지만 반영하여 비교 분석을 진행하였다.
- 예측 시간의 경우 00, 12UTC 각각에 대해 분석을 진행하여 기술하였으며, 재분석 자료 또한 ECMWF ERA5 자료의 Hourly 자료를 활용하여 동일한 시간대의 자료를 선정하여 동일한 비교를 진행하였다.
- 시계열 분석의 경우 1) 북반구 (30-90°N), 2) 남반구 (30-90°S), 3) 한반도 (33-34°N, 124-132°E), 4) 동아시아 (20-60°N, 90-160°E) 영역에 대해서 진행하였으며, 공간 분포의 경우 1) 북반구 (20-90°N), 2) 동아시아 (20-60° 영역에 대해서 표출하였다. 본 보고서의 공간 분포 결과는 북반구 영역에 대해서만 기술하였다.

1) 앙상블 평균 월별 예측성 진단 평가: Averaged Skill Score

2021 JULY 12UTC T1000 NH Ensemble Monthly Averaged Score

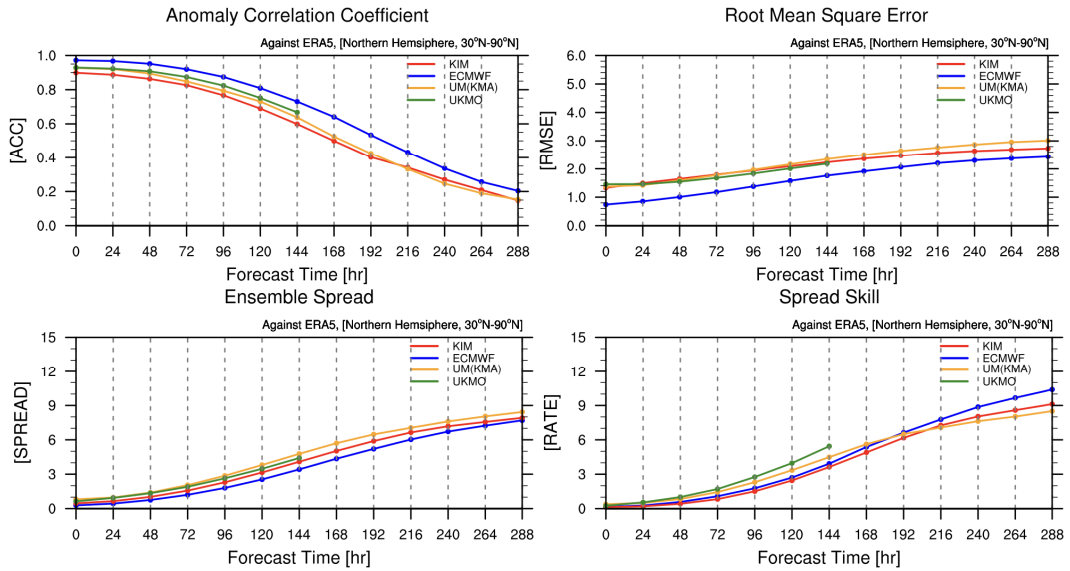


그림 1.1.4 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 북반구

2022년 7월(여름철) 00, 12UTC T1000 분석 결과

2021 JULY 00UTC T1000 NH Ensemble Monthly Averaged Score

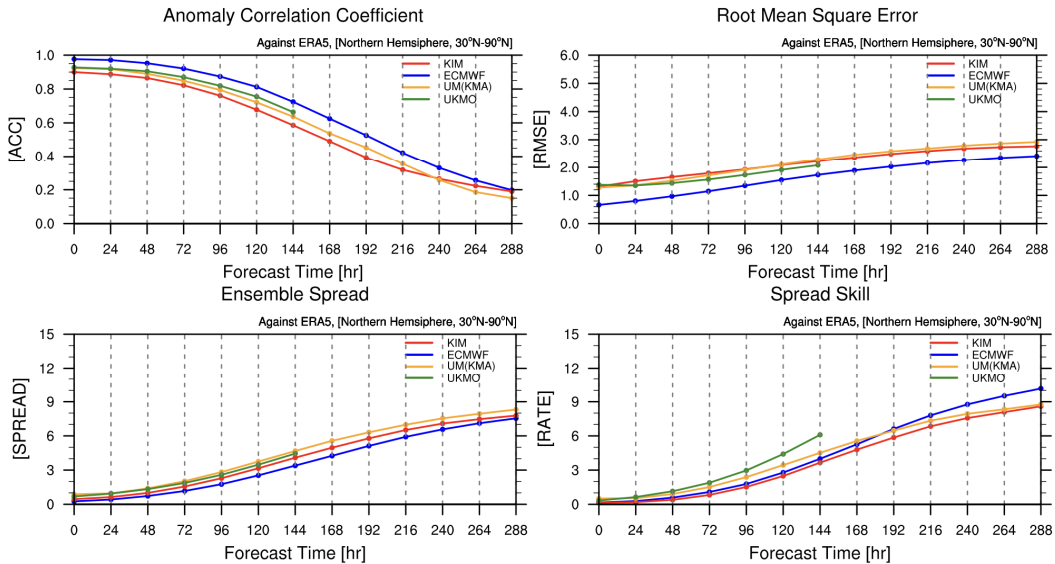


그림 1.1.5 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 북반구

2021 JULY 00UTC T1000 SH Ensemble Monthly Averaged Score

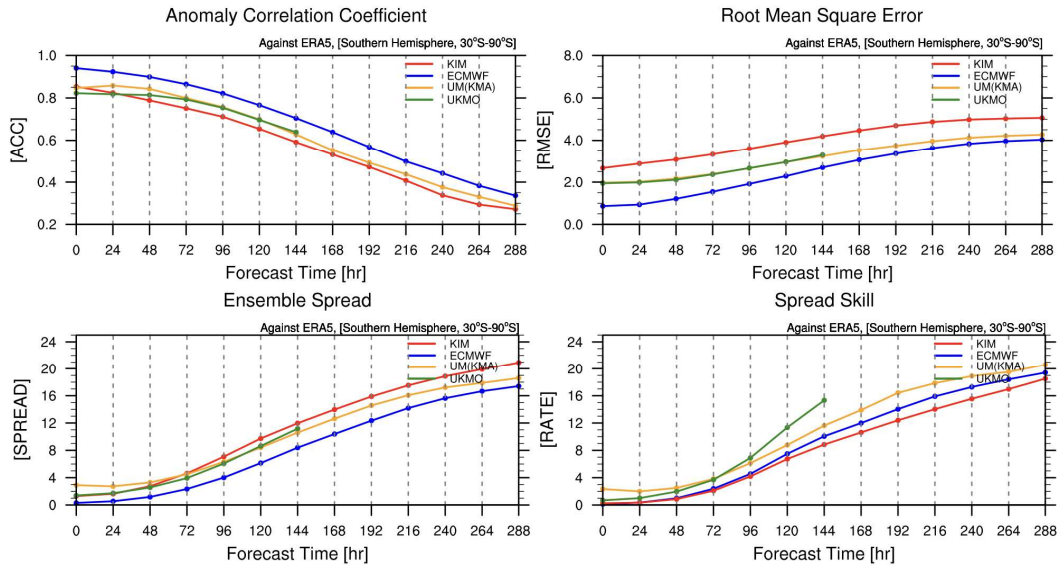


그림 1.1.6 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 남반구

2021 JULY 12UTC T1000 SH Ensemble Monthly Averaged Score




그림 1.1.7 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 남반구

2021 JULY 00UTC T1000 Korea Ensemble Monthly Averaged Score




그림 1.1.8 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 한반도

2021 JULY 12UTC T1000 Korea Ensemble Monthly Averaged Score

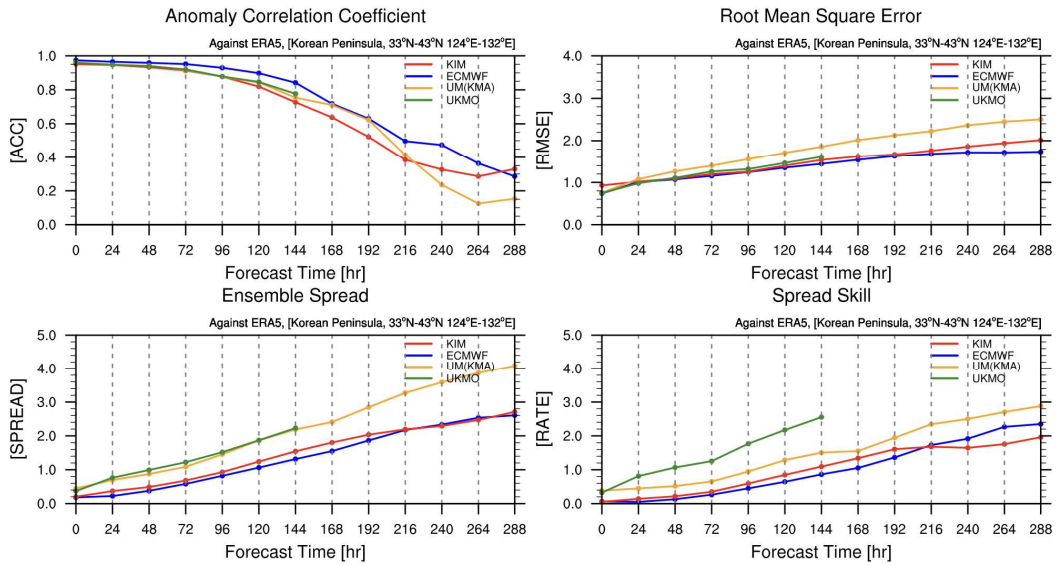


그림 1.1.9 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 한반도

2021 JULY 00UTC Z500 EA Ensemble Monthly Averaged Score




그림 1.1.10 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T1000 동아시아

2021 JULY 12UTC T1000 EA Ensemble Monthly Averaged Score




그림 1.1.11 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T1000 동아시아

- 북반구 T1000 앙상블 평균 월별 예측성은 00UTC와 12UTC 모두 큰 차이 없이 매우 유사한 예측 성능을 보이고 있으며, 예측 성능 및 모델의 오차는 ECMWF가 가장 안정적이며, 그 뒤로 UKMO, UM(KMA), 한국형앙상블모델 순으로 유사한 예측 성능을 보이고 있다 (그림 1.1.4-1.1.5)
- 남반구 T1000의 앙상블 평균 월별 예측성은 북반구와는 다르게 ECMWF와 다른 모델들 간의 예측 성능 차이가 상대적으로 크게 나타나지만, 그 트렌드는 매우 유사함을 알 수 있다. 한국형앙상블모델의 경우 북반구에 비해 남반구의 예측 성능은 상대적으로 낮음을 확인할 수 있다 (그림 1.1.6-1.1.7).
- 한반도 T1000 예측 성능의 경우 북반구, 남반구는 부드러운 커브 형태로 예측성 변화를 확인할 수 있는 반면, 한반도 영역의 경우 좁은 영역을 평균하였기 때문에 노이즈 형태의 커브를 확인할 수 있다. 또한, 한반도의 경우 ECMWF 모델 다음으로 한국형앙상블모델이 상대적으로 안정적인 예측 성능과 앙상블 분산을 보여주고 있다 (그림 1.1.8-1.1.9).
- 동아시아 T1000의 경우 다른 영역에 비해 RMSE 및 Spread Skill 분포의 차이가 크게 나타난다. 특징적인 것은 동아시아 지역에서의 ECMWF의 Spread Skill이 크게 나타난다는 점이다. ACC와 RMSE의 경우 ECMWF, 한국형앙상블(KIM), UKMO, UM(KMA) 순으로 성능이 낮아짐을 알 수 있다 (그림 1.1.10-1.1.11).

- 2022년 1월(겨울철) 00, 12UTC T1000 분석 결과

2022 JANUARY 00UTC T1000 NH Ensemble Monthly Averaged Score

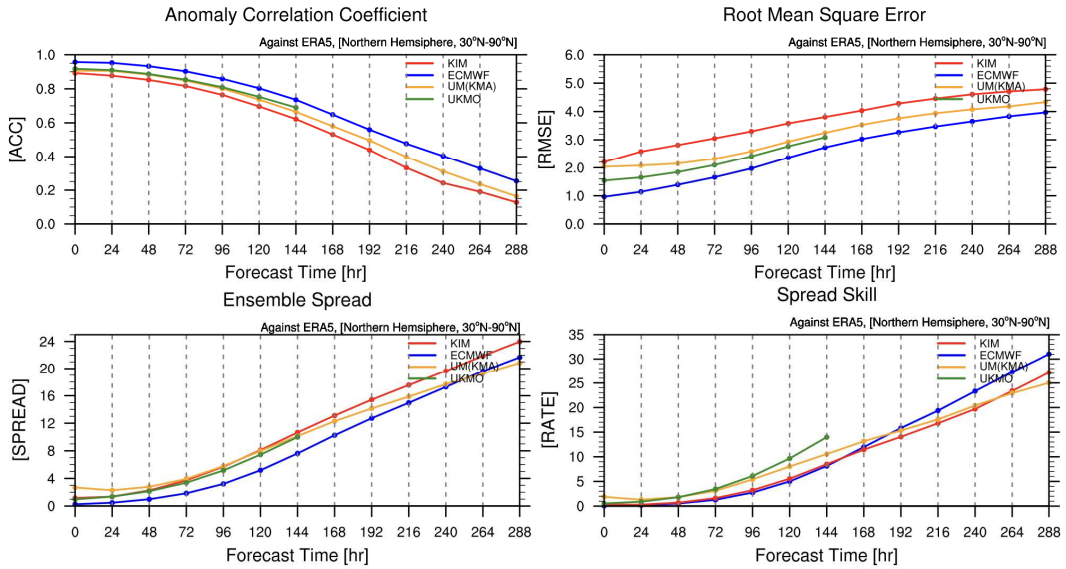


그림 1.1.12 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 북반구

2022 JANUARY 12UTC T1000 NH Ensemble Monthly Averaged Score

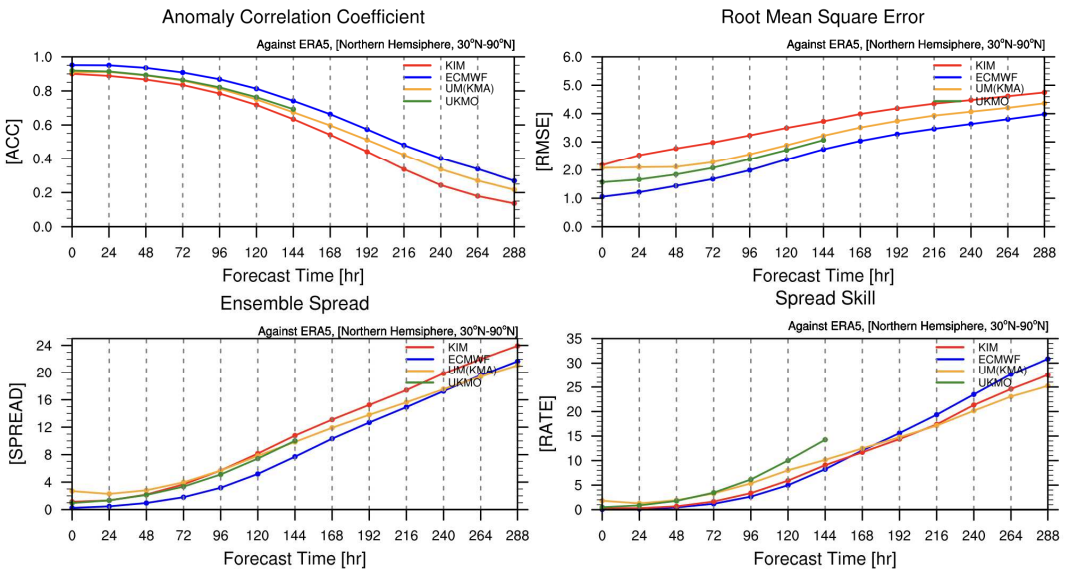


그림 1.1.13 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 북반구

2022 JANUARY 00UTC T1000 SH Ensemble Monthly Averaged Score

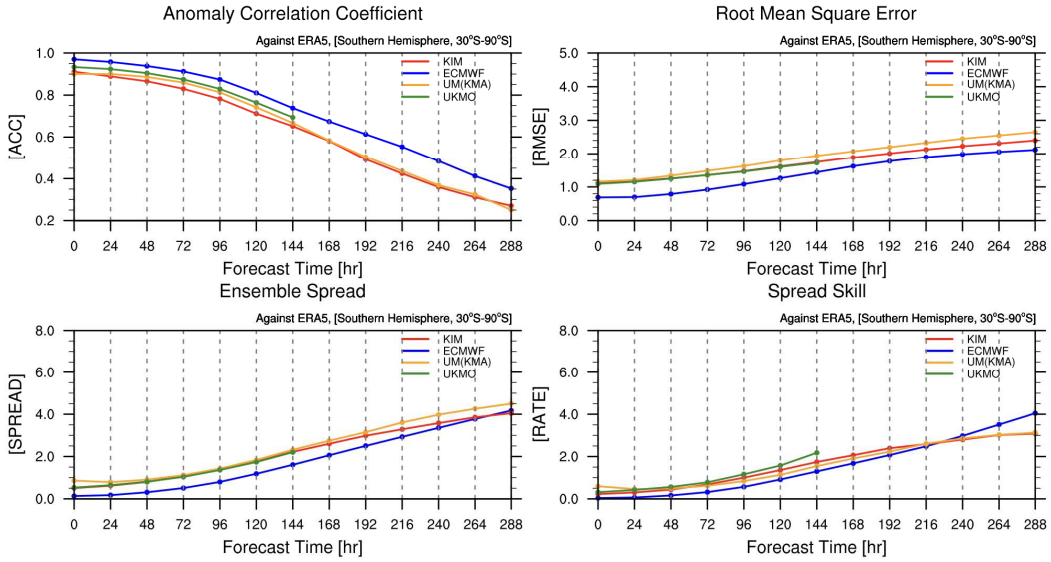


그림 1.1.14 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 남반구

2022 JANUARY 12UTC T1000 SH Ensemble Monthly Averaged Score

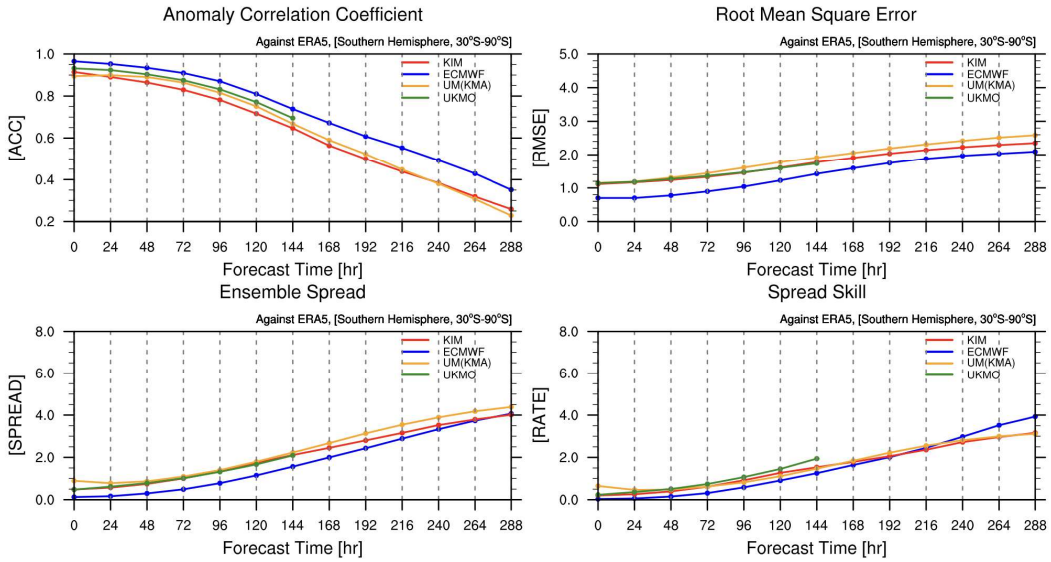


그림 1.1.15 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 남반구

2022 JANUARY 00UTC T1000 Korea Ensemble Monthly Averaged Score

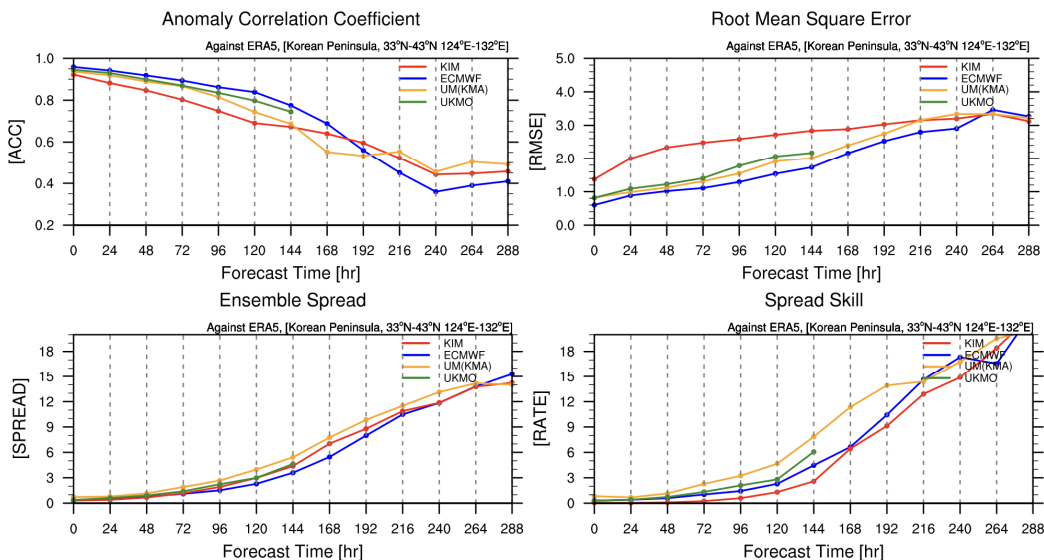


그림 1.1.16 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 한반도

2022 JANUARY 12UTC T1000 Korea Ensemble Monthly Averaged Score

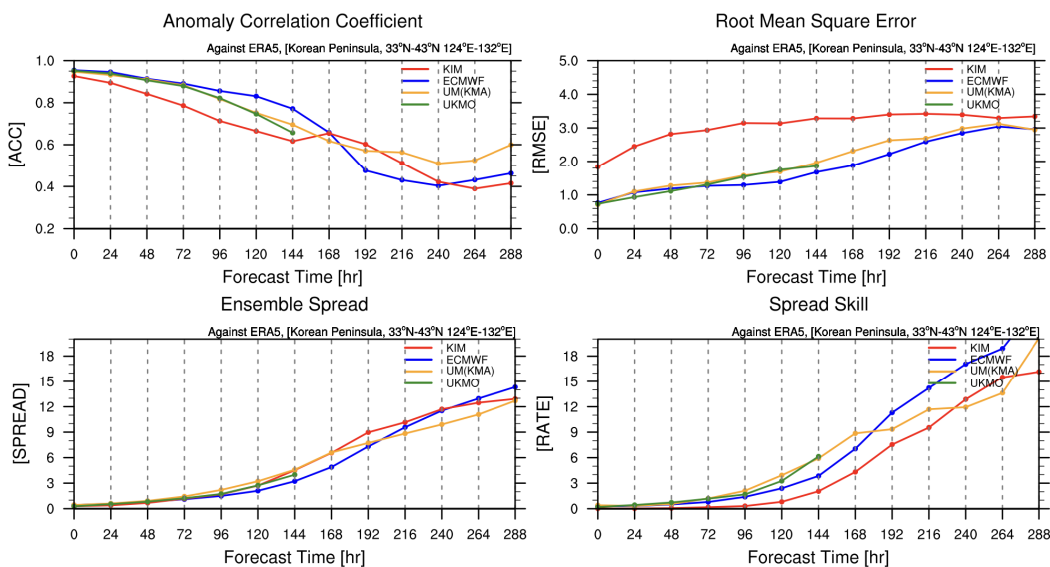


그림 1.1.17 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 한반도

2022 JANUARY 00UTC T1000 EA Ensemble Monthly Averaged Score

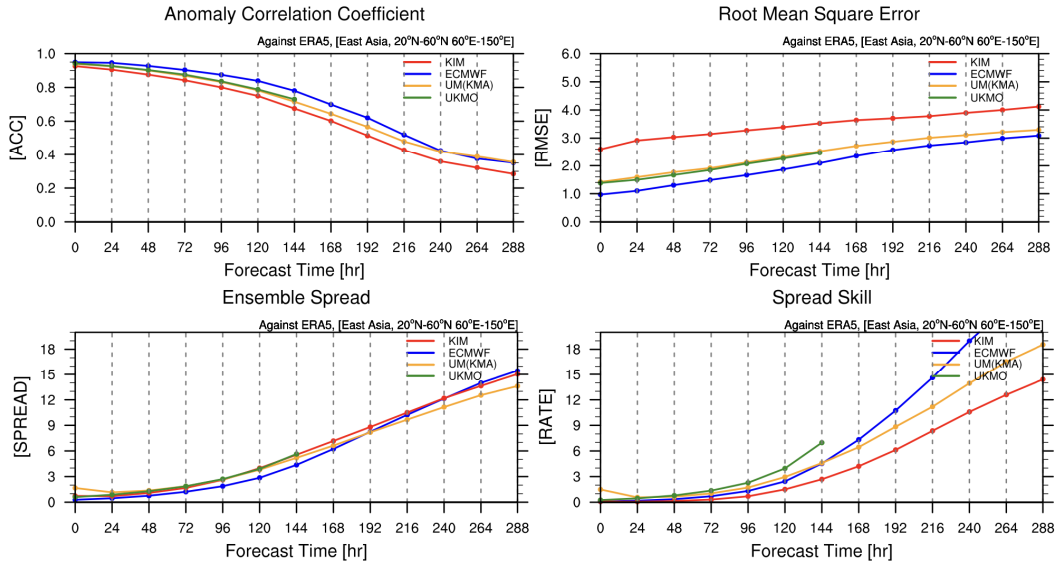


그림 1.1.18 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T1000 동아시아

2022 JANUARY 12UTC T1000 EA Ensemble Monthly Averaged Score

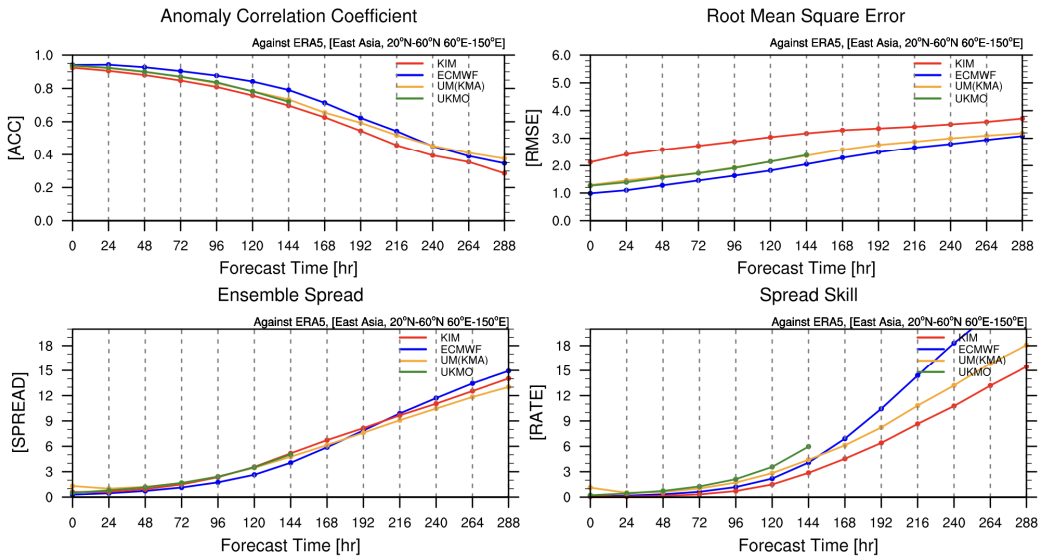


그림 1.1.19 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T1000 동아시아

- 북반구 T1000 앙상블 평균 월별 예측성은 00UTC와 12UTC 모두 큰 차이 없이 매우 유사한 예측 성능을 보이고 있으며, 상대적으로 여름철에 비해 겨울철에 한국형앙상블모델의 T1000 예측 성능이 낮게 나타남을 확인할 수 있다 (그림 1.1.12-1.1.13).
- 남반구 T1000의 예측 성능은 여름철에 비해 겨울철에는 모델들 간의 예측 성능 및 오차의 차이가 크지 않음을 확인할 수 있다 (그림 1.1.14-1.1.15).
- 한반도 T1000의 예측 성능은 상대적으로 여름철에 비해 겨울철에 한국형앙상블모델의 예측 성능이 불안정한 것을 확인할 수 있다. 특히 RMSE 성능을 보면 초기부터 매우 높은 오차를 보이고 있으며, 점점 크게 나타남을 확인할 수 있다 (그림 1.1.16-1.1.17).
- 동아시아의 T1000의 예측 성능의 경우 00UTC와 12UTC 모두 비슷한 형태를 보이고 있으며 예측 성능의 차이 또한 동일하게 나타남을 확인할 수 있다. 아주 미비한 예측 성능의 차이가 약 264hr 이후 보이는 것을 확인할 수 있다. 여름철에 비해 마찬가지로 동아시아 지역에서 겨울철 한국형앙상블모델의 오차가 상대적으로 크게 남을 확인할 수 있다 (그림 1.1.18-1.1.19).

- 2021년 7월(여름철) 00, 12UTC T850 분석 결과

2022 JANUARY 00UTC T850 NH Ensemble Monthly Averaged Score




그림 1.1.20 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 북반구

2022 JANUARY 12UTC T850 NH Ensemble Monthly Averaged Score

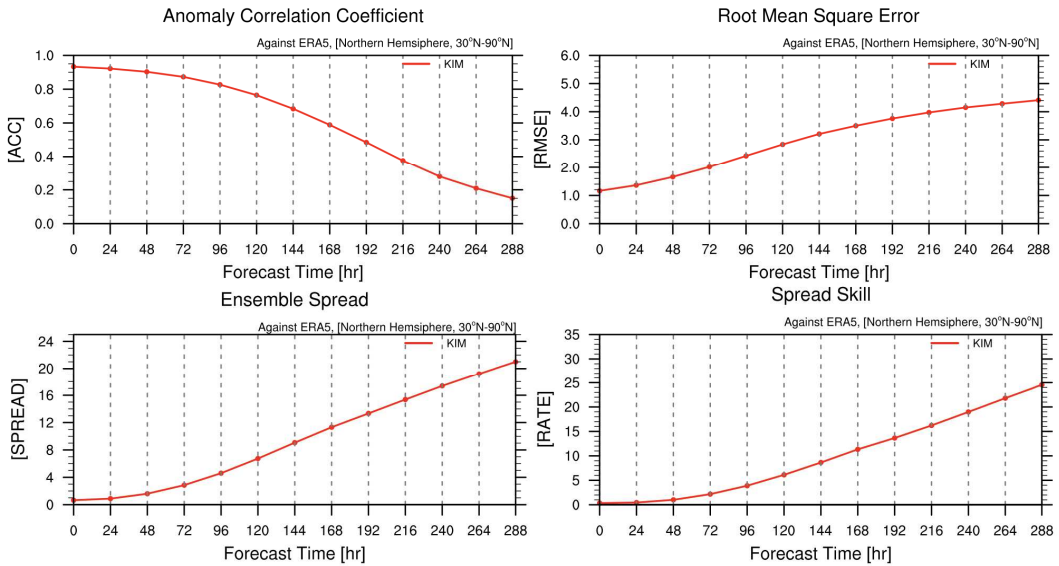


그림 1.1.21 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 북반구

2022 JANUARY 00UTC T850 SH Ensemble Monthly Averaged Score

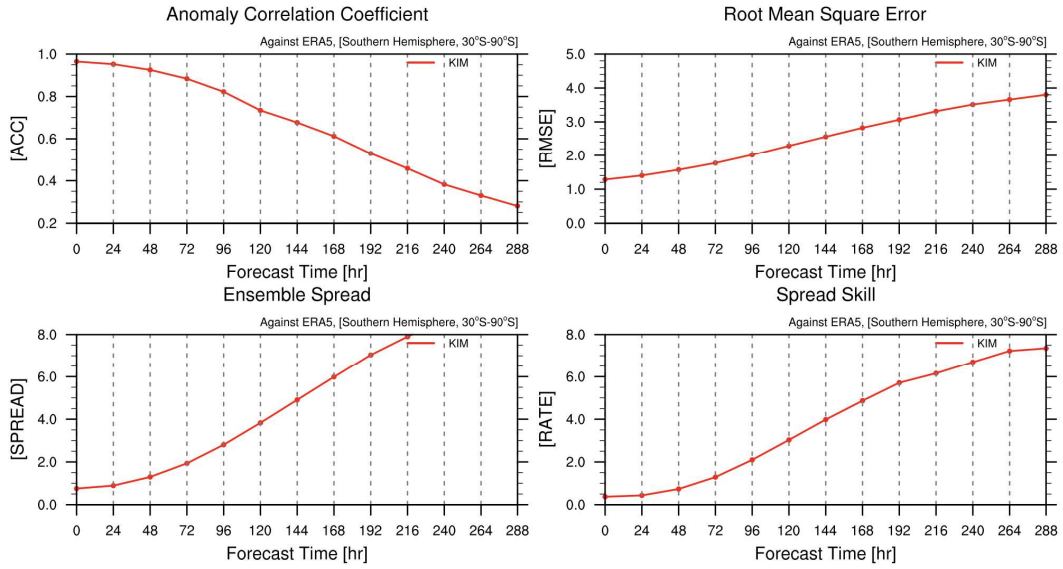


그림 1.1.22 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 남반구

2022 JANUARY 12UTC T850 SH Ensemble Monthly Averaged Score




그림 1.1.23 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 남반구

2022 JANUARY 00UTC T850 Korea Ensemble Monthly Averaged Score

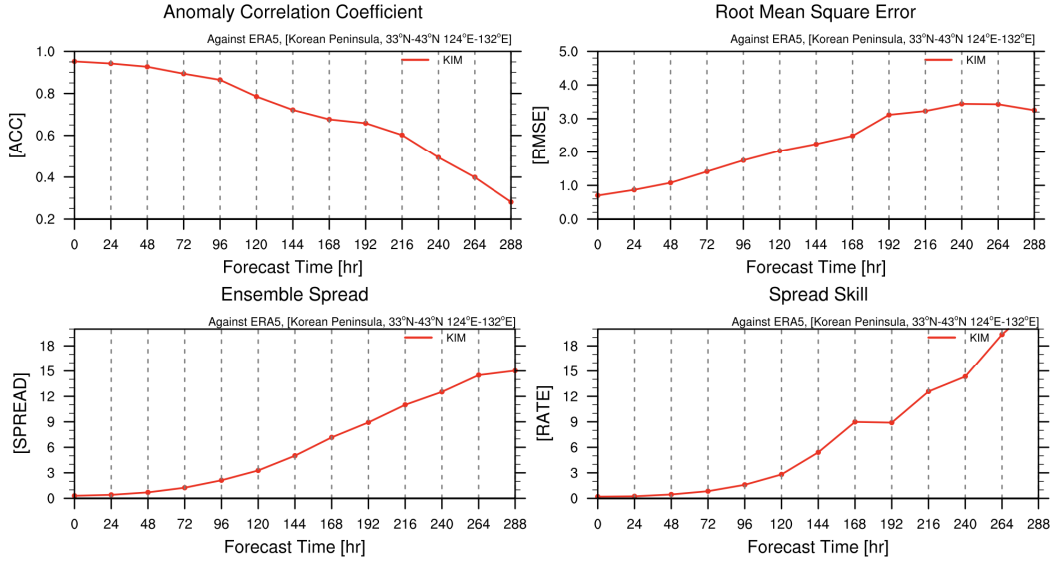


그림 1.1.24 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 한반도

2022 JANUARY 12UTC T850 Korea Ensemble Monthly Averaged Score

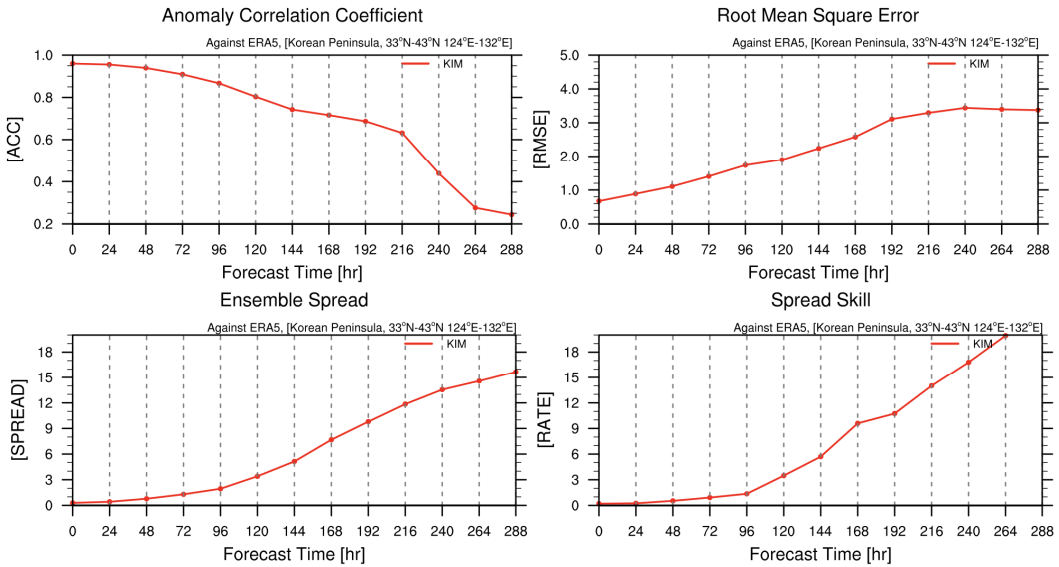


그림 1.1.25 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 한반도

2022 JANUARY 00UTC T850 EA Ensemble Monthly Averaged Score

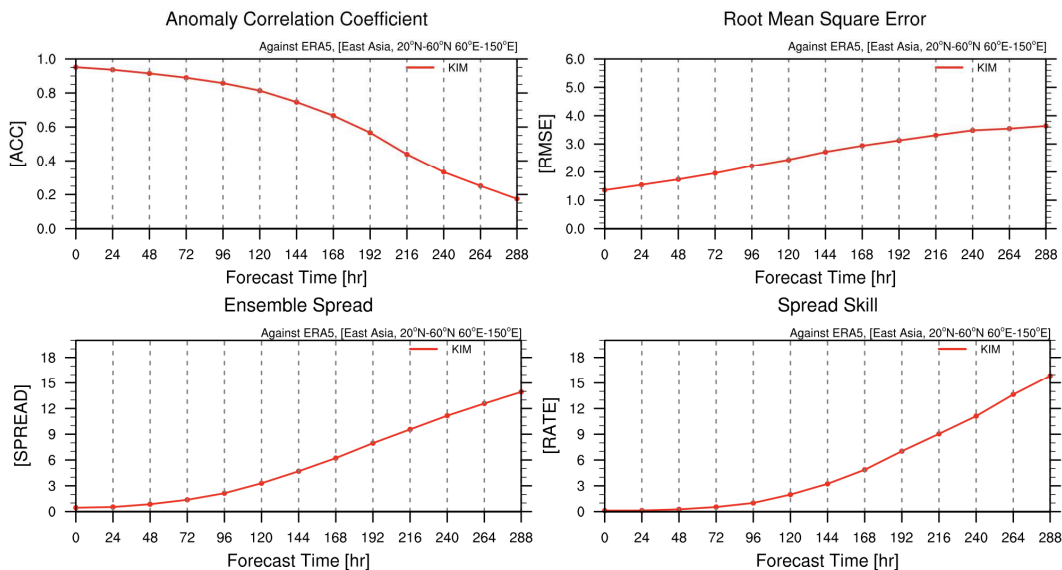


그림 1.1.26 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC T850 동아시아

2022 JANUARY 12UTC T850 EA Ensemble Monthly Averaged Score




그림 1.1.27 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC T850 동아시아

- 북반구 T850 양상블 평균 월별 예측성은 00UTC와 12UTC 모두 비슷한 양상을 보이고 있다. 144hr Forecast Time 이후로 ACC의 경우 0.6 이하로 떨어지는데 이는 약 7일의 예측성을 한국형양상블모델이 유지하고 있음을 알 수 있다. 초기 분석장의 RMSE가 존재하기는 하지만 288hr Forecast Time까지 가파르지 않은 형태로 오차가 상승하는 것을 볼 수 있다 (그림 1.1.20-1.1.21).
- 남반구 또한 북반구와 비슷한 양상을 보이며 예측 성능 및 예측 오차 범위의 차이는 존재하지만 ACC나 RMSE의 변화 차이는 비슷하다 (그림 1.1.22-1.1.23).
- 한반도의 경우 영역 평균이 매우 좁은 지역에서 이루어지기 때문에 노이즈 양상을 보인다. 특히 288hr로 갈수록 0에 가까운 ACC를 보이며 급격하게 예측 성능이 하강하는 것을 볼 수 있다. 이는 00UTC, 12UTC 모두에서 확인할 수 있다 (그림 1.1.24-1.1.25).
- 동아시아의 경우 한반도 영역 보다는 넓은 지역 평균으로 안정적인 트렌드를 보이고 있으나, 한반도와 마찬가지로 ACC는 288hr Forecast Time에서는 0에 가까운 값을 보이는 반면, RMSE의 경우 그 증가 양상이 다른 영역 보다는 낮게 나타남을 확인할 수 있다 (그림 1.1.26-1.1.27).

- 2022년 1월(겨울철) 00, 12UTC T850 분석 결과

2021 JULY 00UTC T860 NH Ensemble Monthly Averaged Score




그림 1.1.28 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 북반구

2021 JULY 12UTC T860 NH Ensemble Monthly Averaged Score




그림 1.1.29 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 북반구

2021 JULY 00UTC T860 SH Ensemble Monthly Averaged Score

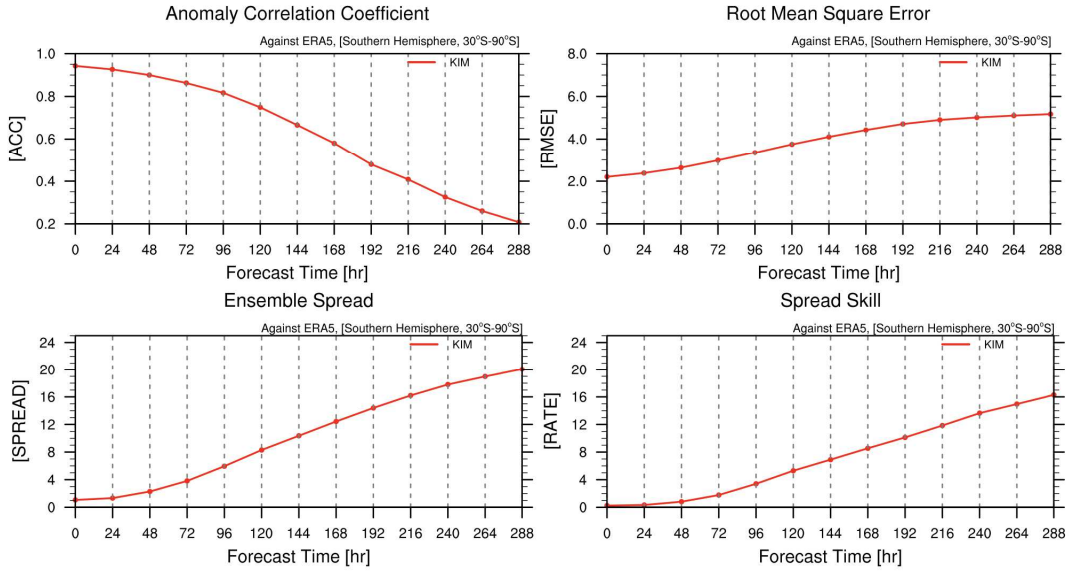


그림 1.1.30 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 남반구

2021 JULY 12UTC T860 SH Ensemble Monthly Averaged Score

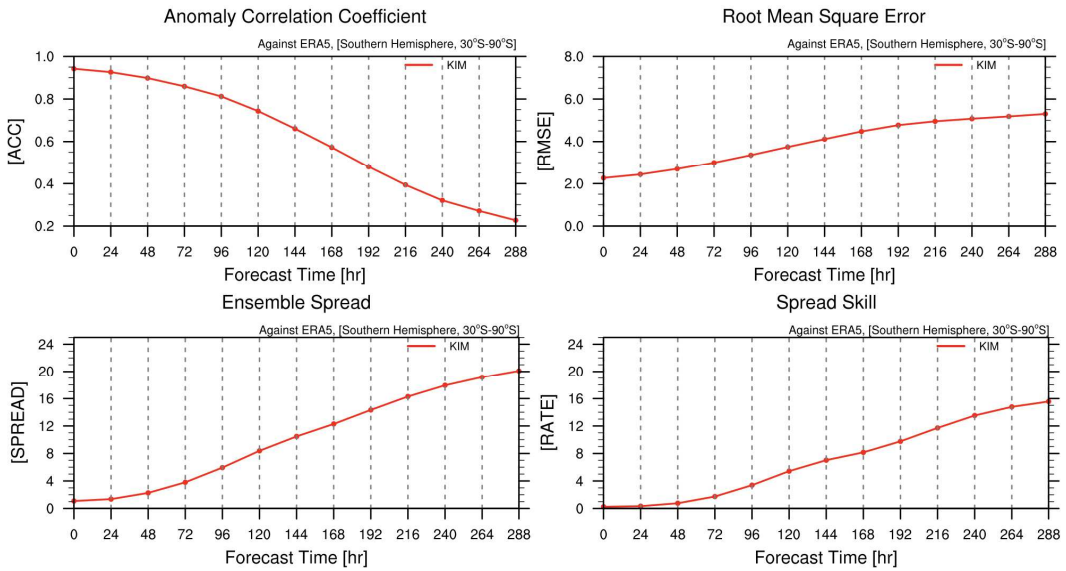


그림 1.1.31 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 남반구

2021 JULY 00UTC T860 Korea Ensemble Monthly Averaged Score




그림 1.1.32 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 한반도

2021 JULY 12UTC T860 Korea Ensemble Monthly Averaged Score




그림 1.1.33 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 한반도

2021 JULY 00UTC T860 EA Ensemble Monthly Averaged Score




그림 1.1.34 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC T850 동아시아

2021 JULY 12UTC T860 EA Ensemble Monthly Averaged Score




그림 1.1.35 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC T850 동아시아

- 북반구 T850 앙상블 평균 월별 예측성은 여름철과 비슷한 겨울철 앙상블을 확인할 수 있다. 증가 및 감소 추세는 큰 여름철과 비교하여 큰 차이는 없으나 앞선 분석과 마찬가지로 144hr Forecast Time 이후로 0.6 이하로 ACC가 떨어지는 것을 확인할 수 있으며, 상대적으로 RMSE는 그 증가 양상이 낮게 나타남을 확인할 수 있다 (그림 1.1.28-1.1.29).
- 남반구 또한 북반구와 마찬가지로 앙상블을 보이고 있으며, 288hr Forecast Time에 들어서서는 ACC가 0에 도달하는 것을 확인할 수 있다. 이는 예측 13일 이후에는 예측성능이 없음을 의미한다 (그림 1.1.30-1.1.31).
- 한반도영역의 경우 192hr Forecast 부터는 그 예측 성능이 안정적이지 않은 것을 12UTC에서 확인할 수 있다. 반면, 00UTC는 144hr Forecast Time 까지는 높은 ACC를 유지하고 있음을 확인할 수 있다 (그림 1.1.32-1.1.33).
- 동아시아 지역의 경우 앞선 영역 분석과 동일하게 상대적으로 RMSE 및 Spread 분석이 낮게 나타남을 확인할 수 있으며, 초기 분석장에서의 앙상블 Spread 또한 큰 차이가 없음을 확인할 수 있는데, 이는 앙상블 분포가 안정적으로 산포 되었음을 의미한다 (그림 1.1.34-1.1.35).

- 2021년 7월(여름철) 00, 12UTC Z500 분석 결과

2021 JULY 00UTC Z500 NH Ensemble Monthly Averaged Score

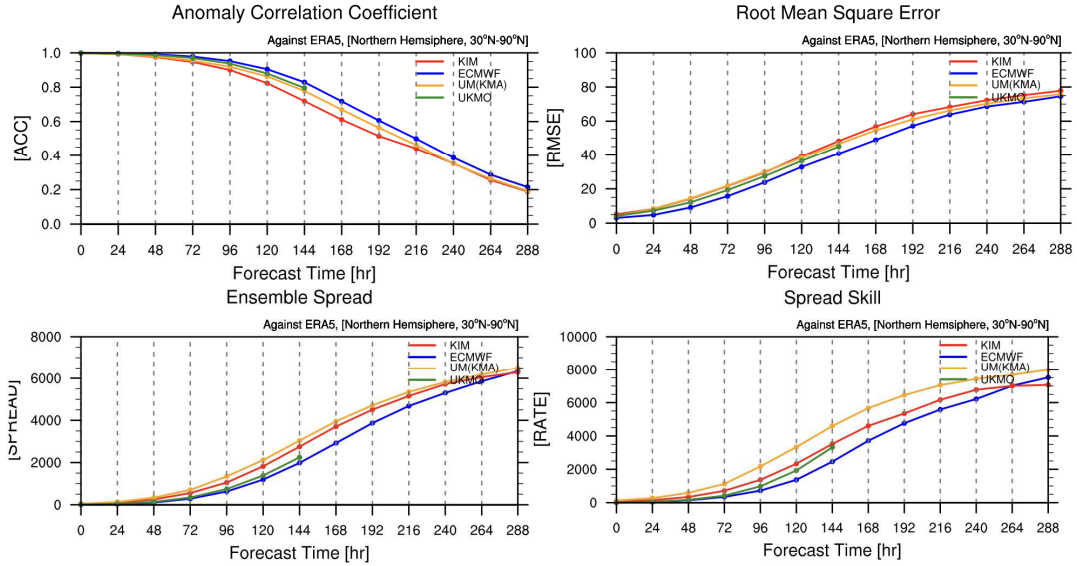


그림 1.1.36 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 북반구

2021 JULY 12UTC Z500 NH Ensemble Monthly Averaged Score

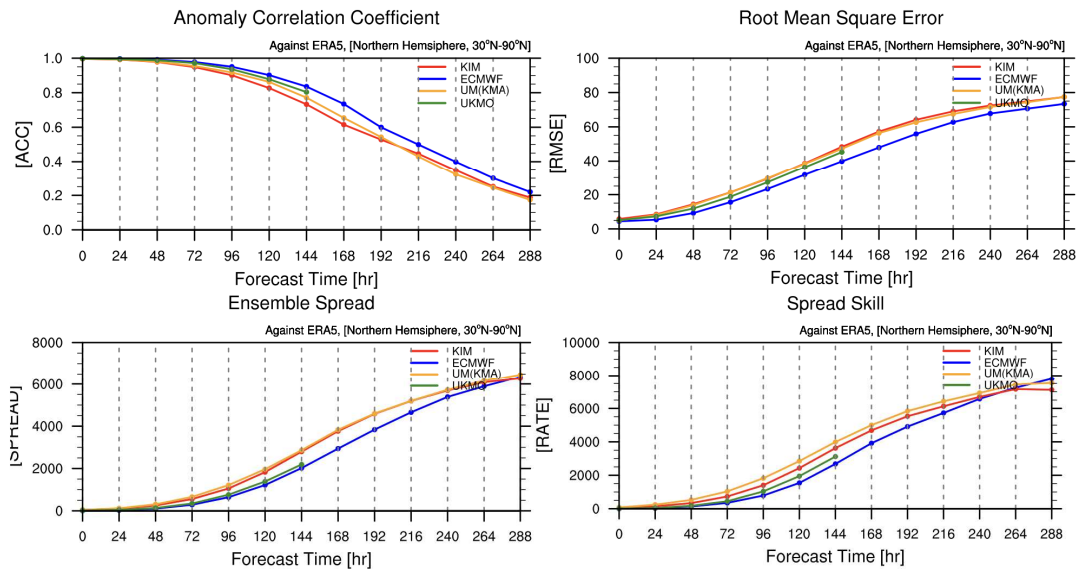


그림 1.1.37 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 북반구

2021 JULY 00UTC Z500 SH Ensemble Monthly Averaged Score




그림 1.1.38 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 남반구

2021 JULY 12UTC Z500 SH Ensemble Monthly Averaged Score




그림 1.1.39 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 남반구

2021 JULY 00UTC Z500 Korea Ensemble Monthly Averaged Score

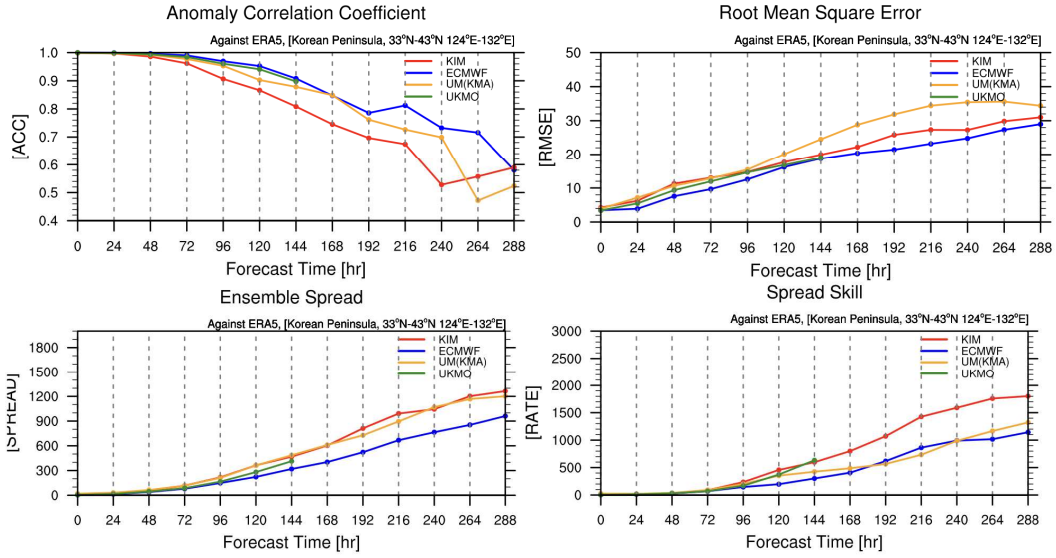


그림 1.1.40 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 한반도

2021 JULY 12UTC Z500 Korea Ensemble Monthly Averaged Score

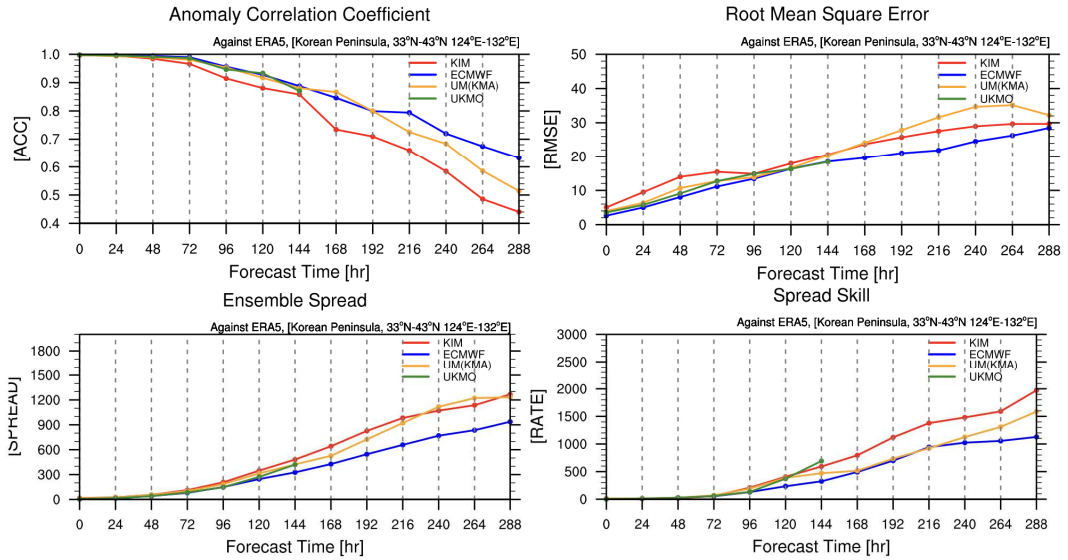


그림 1.1.41 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 한반도

2021 JULY 00UTC Z500 EA Ensemble Monthly Averaged Score




그림 1.1.42 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 00UTC Z500 동아시아

2021 JULY 12UTC Z500 EA Ensemble Monthly Averaged Score




그림 1.1.43 앙상블 평균 월별 예측성 진단 평가: 2021 JULY 12UTC Z500 동아시아

- 북반구 Z500 분석을 살펴보면 약 7일까지 예측 성능이 매우 높게 유지되는 것을 모든 모델에서 확인할 수 있다. 미미한 차이지만 ECMWF, UKMO, UM(KMA), 한국형앙상블모델 순으로 모델의 예측 안정성이 떨어짐을 확인할 수 있다 (그림 1.1.36-1.1.37).
- 남반구의 경우 상대적으로 북반구에 비해 ACC가 288hr 까지 0.3 이상을 유지하고 있음을 확인할 수 있으며, 네 모델들 간의 예측 성능 및 예측 오차의 차이가 크지 않음을 확인할 수 있다 (그림 1.1.38-1.1.39).
- 한반도의 경우 168hr Forecast time 이후 네 모델 모두에서 안정적이지 않은 노이즈 형태의 예측 성능, ACC를 확인할 수 있다. 이 이후의 Forecast Time 결과에 대해서는 분석 결과 신뢰하기 어려움을 볼 수 있다. RMSE의 경우 ECMWF, 한국형앙상블모델(KIM), UKMO, UM(KMA) 순으로 커짐을 확인할 수 있다 (그림 1.1.40- 1.1.41).
- 동아시아 영역의 경우 한반도에 비해 상대적으로 넓은 영역 평균 분석으로 보다 안정적인 예측 성능을 확인할 수 있으며, ECMWF를 제외하고 나머지 모델들 간의 ACC 및 RMSE는 비슷한 수준을 유지하고 있음을 확인할 수 있다 (그림 1.1.42-1.1.43).

- 2022년 1월(겨울철) 00, 12UTC Z500 분석 결과

2022 JANUARY 00UTC Z500 NH Ensemble Monthly Averaged Score

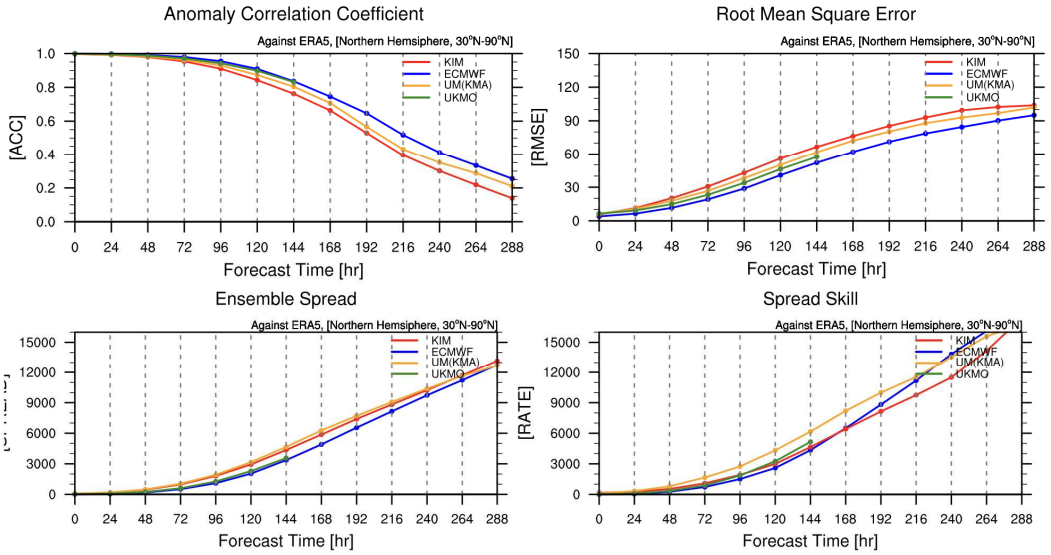


그림 1.1.44 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 북반구

2022 JANUARY 12UTC Z500 NH Ensemble Monthly Averaged Score

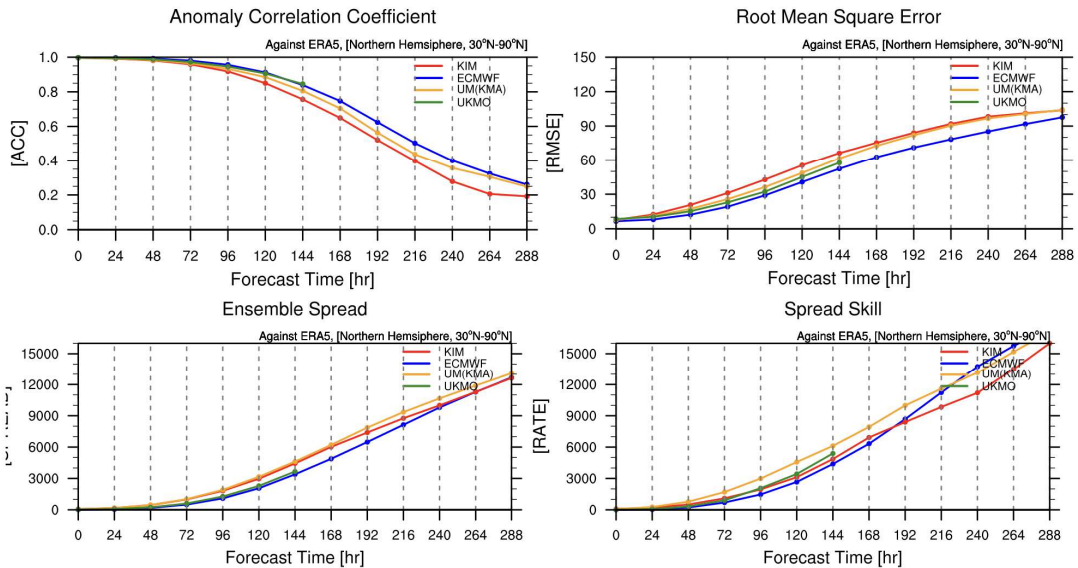


그림 1.1.45 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 북반구

2022 JANUARY 00UTC Z500 SH Ensemble Monthly Averaged Score




그림 1.1.46 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 남반구

2022 JANUARY 12UTC Z500 SH Ensemble Monthly Averaged Score




그림 1.1.47 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 남반구

2022 JANUARY 00UTC Z500 Korea Ensemble Monthly Averaged Score

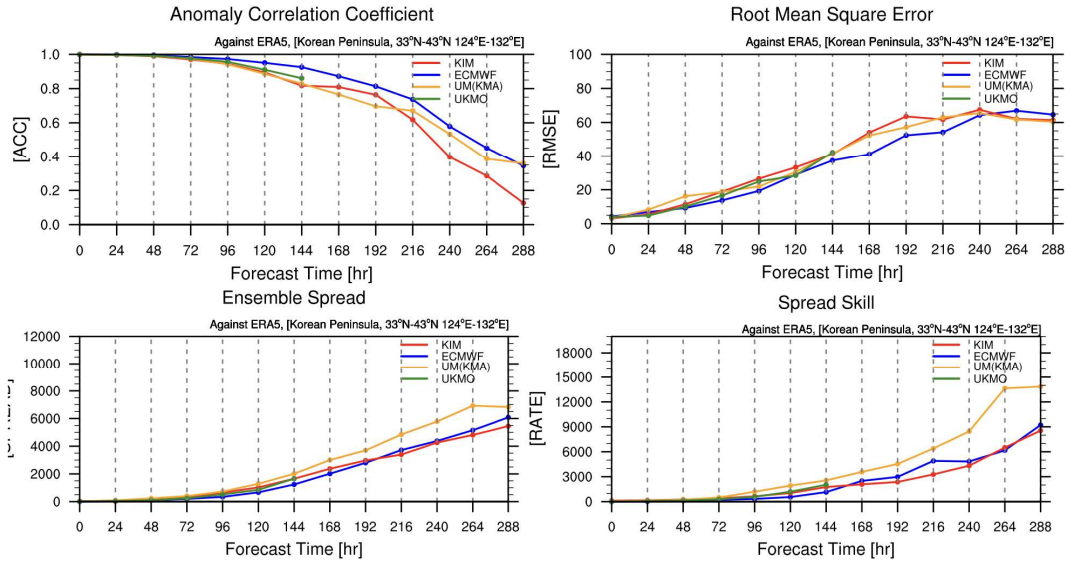


그림 1.1.48 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 한반도

2022 JANUARY 12UTC Z500 Korea Ensemble Monthly Averaged Score




그림 1.1.49 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 한반도

2022 JANUARY 00UTC Z500 EA Ensemble Monthly Averaged Score




그림 1.1.50 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 00UTC Z500 동아시아

2022 JANUARY 12UTC Z500 EA Ensemble Monthly Averaged Score




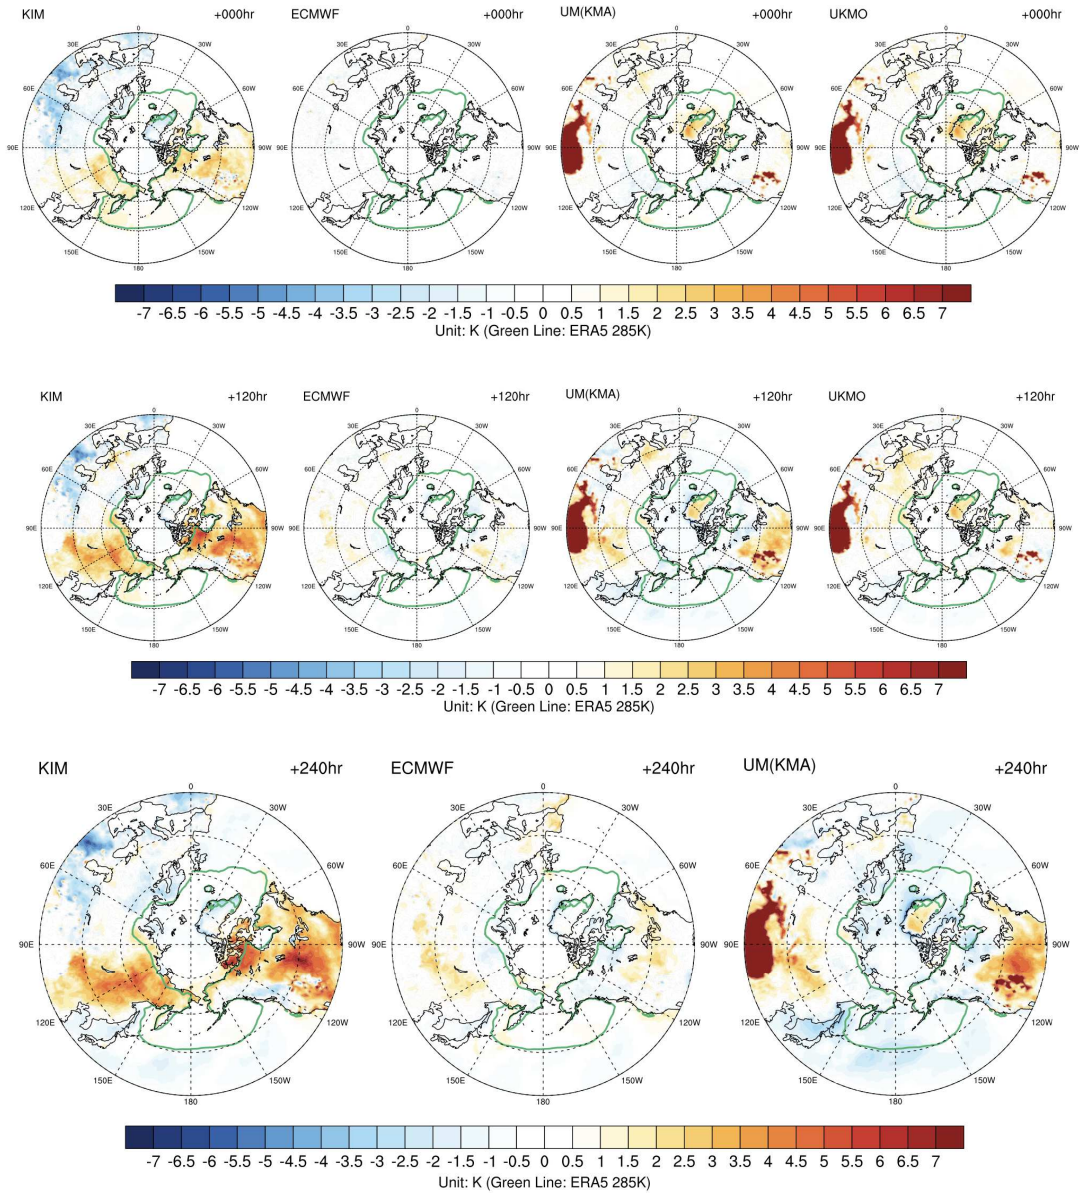
그림 1.1.51 앙상블 평균 월별 예측성 진단 평가: 2022 JANUARY 12UTC Z500 동아시아

- 북반구 Z500의 경우 여름철과 겨울철이 비슷한 예측 양상을 보이고 있으나, Spread Skill에서 차이를 보이고 있는데 이는 계절 측면에서의 예측 성능 범위의 차이에 의한 결과로 보인다. ECMWF를 제외하고 나머지 모델들의 ACC 및 RMSE는 비슷한 양상을 보인다 (그림 1.1.44-1.1.45).
- 남반구 또한 여름철과 비슷한 예측 수준을 보이는데, 상대적으로 Spread Skill의 범위가 낮게 나타나며, RMSE 또한, 평평한 트렌드를 보이며 144hr 이후 그 오차가 크게 퍼지지 않는 것을 확인할 수 있다 (그림 1.1.46-1.1.47).
- 한반도의 경우 상대적으로 Z500의 겨울철은 192hr Forecast Time 까지 높은 예측 수준을 유지하고 있으나, 그 이후로는 가파르게 떨어지는 예측 성능을 확인할 수 있다. RMSE 또한 144hr Forecast Time 이후로 노이즈와 비슷한 형태의 플랏을 볼 수 있는데 이는 여름철 결과와 비슷한 예측 양상임을 확인할 수 있다 (그림 1.1.48-1.1.49).
- 동아시아 영역의 경우 00UTC와 12UTC 모두 비슷한 예측 양상을 보이고 있으며, 상대적으로 한반도에 비해 안정적이며 높은 ACC 값을 보임을 확인할 수 있다. RMSE와 Spread 또한 Forecast Time이 증가하더라도 안정적으로 나타남을 확인할 수 있다 (그림 1.1.50-1.1.51).

2) 앙상블 평균 Bias 분포 진단 평가: Bias (Model minus Reanalysis)

- 2021년 7월(여름철) 00, 12UTC T1000 분석 결과

2021 JULY 00UTC T1000 Ensemble Mean Bias



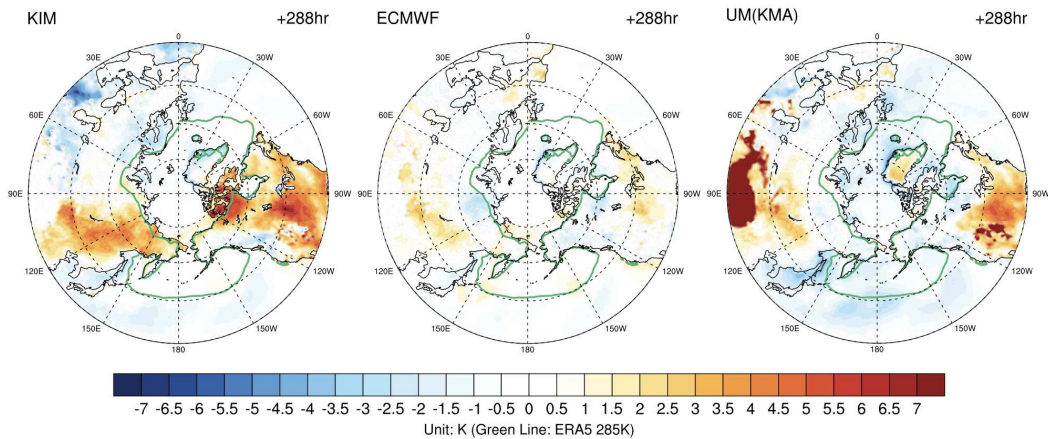
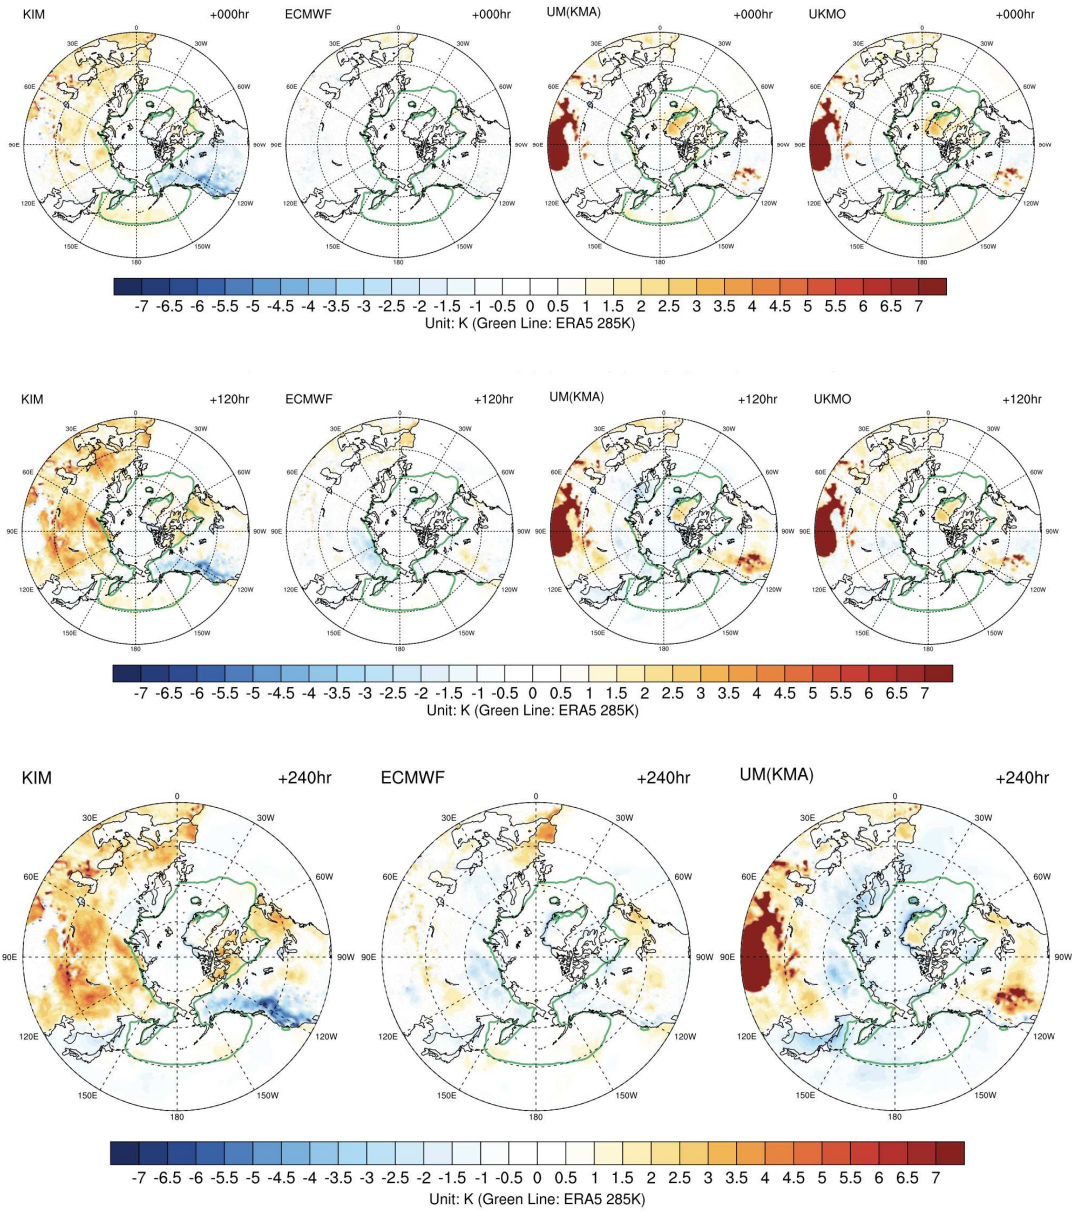


그림 1.1.52 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 여름철 00UTC T1000 앙상블 평균 Bias 분포 예측 성능을 살펴보면, ECMWF를 제외하고 한국형앙상블모델, UKMO, UM(KMA) 모델 모두 초기 분석장에 편차가 발생하는 것을 확인할 수 있다. 한국형앙상블모델의 경우 북미 대륙에 양의 편차가, 유라시아 대륙에 음의 편차가 존재한다. UM(KMA) 모델과 UKMO 모델은 매우 비슷한 형태의 예측 편차를 보이는 것을 확인할 수 있다. Forecast Time이 증가함에 따라 이 편차는 동일 지역에서 크게 발생하며, ECMWF 모델의 경우도 288hr Forecast Time에서는 편차가 나타나나 그 범위는 상대적으로 낮음을 확인할 수 있다. 특히, 한국형앙상블모델의 경우 북미 지역과 한반도를 포함한 동아시아 지역에서 전체적으로 양의 편차를, 유라시아 아래 지역에서 일부 음의 편차가 유지됨을 확인할 수 있다. UM(KMA), UKMO 모델은 초기 분석장부터 티벳 고원 지역에 양의 편차가 두드러지게 나타나는데 이는 지표에서 발생하는 모델의 구조적 오차로 평가되며 전반적으로 북미 지역의 양의 편차가 두드러지는 것을 확인할 수 있다. 반면 한반도 및 유라시아 윗 지역에서의 편차는 작은 편임을 확인할 수 있다 (그림 1.1.52).

2021 JULY 12UTC T1000 Ensemble Mean Bias



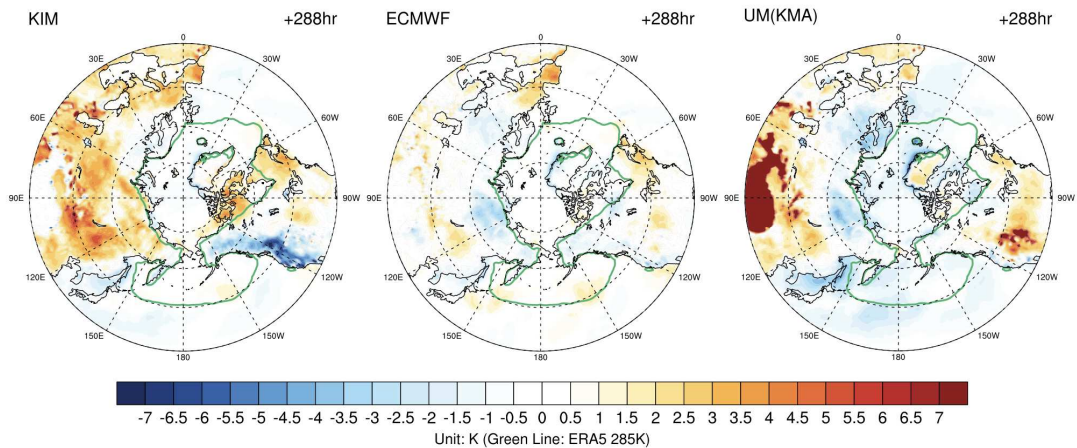
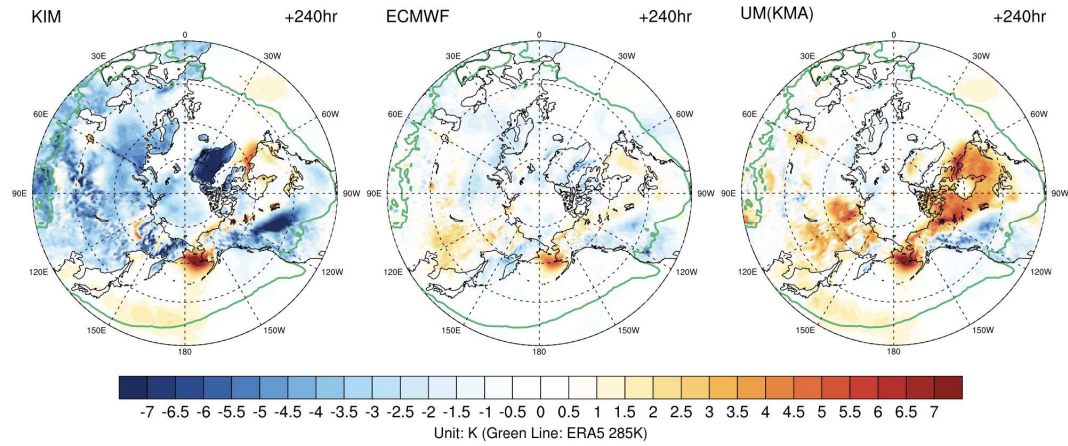
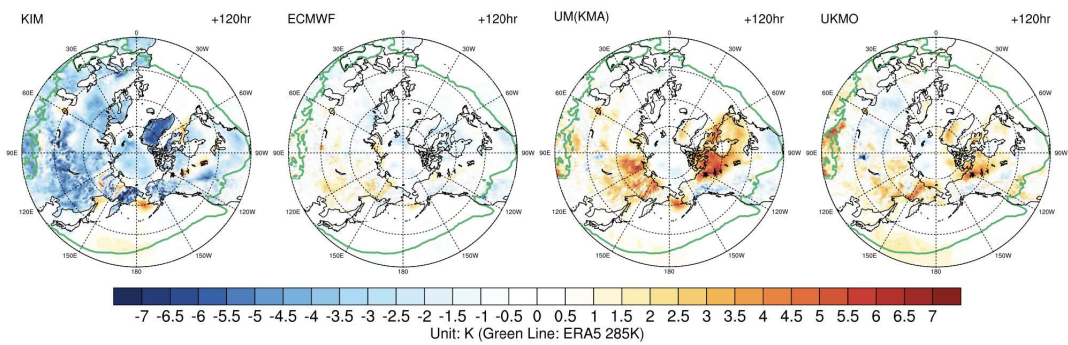
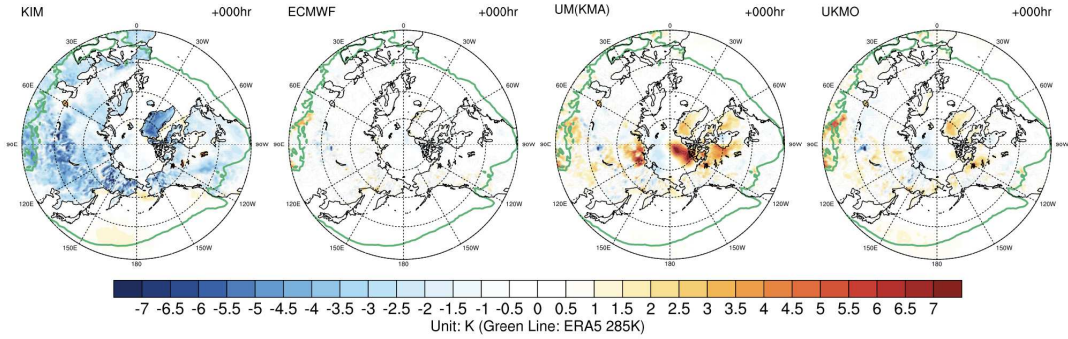


그림 1.1.53 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 12UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 여름철 12UTC T1000 앙상블 평균 Bias 분포 예측 성능을 살펴보면, 00UTC와는 매우 다른 편차 분포를 보임을 확인할 수 있다. 한국형앙상블모델이 특히 차이가 큰데, 초기 분석장(000hr)에서 유라시아 지역에 양의 편차가 크게 존재하며, 북미 지역에는 음의 편차가 크게 나타남을 확인할 수 있다. 이 편차는 288hr로 Forecast Time이 증가할수록 매우 커지는 것을 확인 할 수 있으며, 북미 지역의 서부에서는 음의 편차가, 동부에서는 양의 편차가 작게 존재하는 것을 볼 수 있으며, 동아시아를 포함한 유라시아 대부분의 지역에서 나타나는 양의 편차가 한반도를 포함한 일부 동아시아 지역에서는 편차가 매우 줄어들었으며 일부 음의 편차가 보이는 것을 확인할 수 있다. ECMWF 모델의 경우는 전반적으로 편차가 작은 편이며 일부 유라시아 러시아 지역에서 음의 편차가 나타나는 것을 확인할 수 있으나 상대적으로 그 편차는 미비한 것을 확인할 수 있다. UKMO, UM(KMA) 모델의 편차는 00UTC와 12UTC 모두 비슷한 편차 패턴을 보이는 것을 보아 한국형앙상블모델의 00UTC와 12UTC 초기장에 따라 다른 편차 분포는 모델의 구조적 문제가 있으므로 평가된다 (그림 1.1.53).

- 2022년 1월(겨울철) 00, 12UTC T1000 분석 결과

2022 JANUARY 00UTC T1000 Ensemble Mean Bias



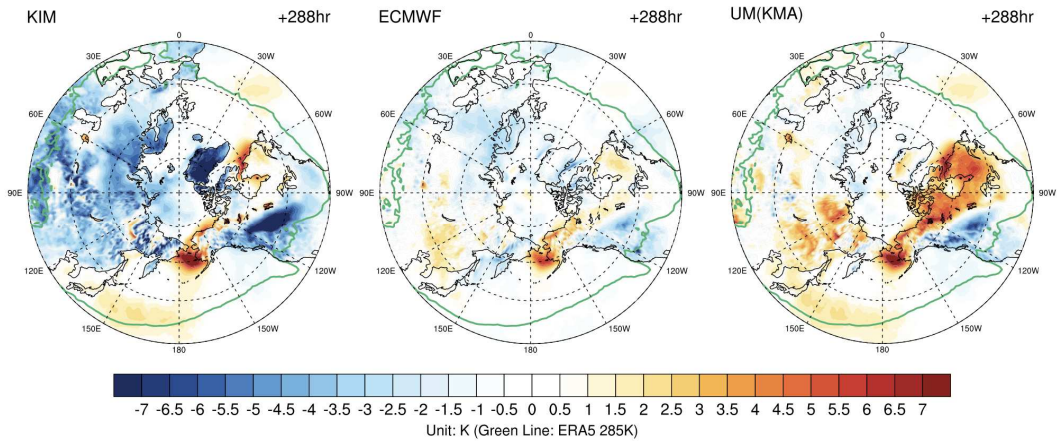
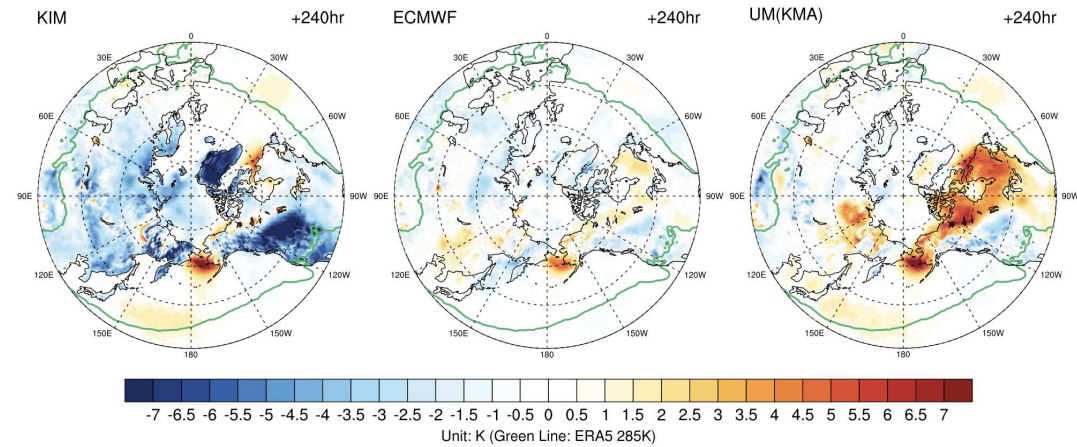
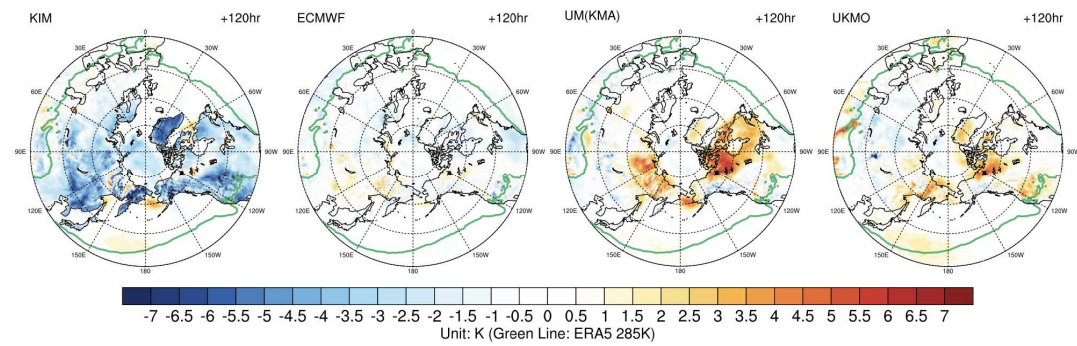
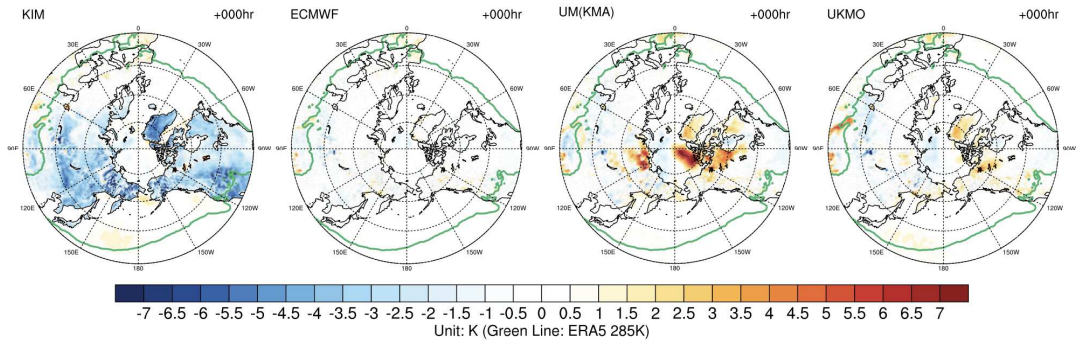


그림 1.1.54 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 겨울철 00UTC T1000 앙상블 평균 Bias 분포 예측 성능을 살펴보면, 한국형앙상블모델은 초기 분석장부터 음의 편차가 전반적으로 나타나는 것을 확인할 수 있으며, 이 음의 편차는 288hr Forecast Time 까지 유지되며 그 편차의 크기 또한 증가하는 것을 확인할 수 있다. 특히, 북미 일부 지역과 그린랜드 지역에서 음의 편차가 매우 크게 나타난다. ECMWF 모델은 초기 분석장에서는 편차가 크게 나타나지 않으며, 288hr Forecast Time에서 일부 유라시아 지역과 북미 지역에서 음의 편차가 보임을 확인할 수 있다. UKMO와 UM(KMA) 모델을 살펴보면 두 모델을 비교했을 때 UKMO 모델이 UM(KMA) 모델 보다는 초기 분석장에서 그 편차가 더 낮게 나타나는 것을 확인할 수 있다. 하지만 패턴은 비슷하게 나타나는 것을 보아 앞선 여름철 분석과 비슷한 예측 양상이 나타나는 것을 확인할 수 있다. 특히, UM(KMA) 모델에서 초기 분석장에서 부터 나타나는 양의 편차는 288hr Forecast Time 까지 유지되며 특히 북미 지역에서 두드러진 양의 편차를 확인할 수 있다 (그림 1.1.54).

2022 JANUARY 12UTC T1000 Ensemble Mean Bias



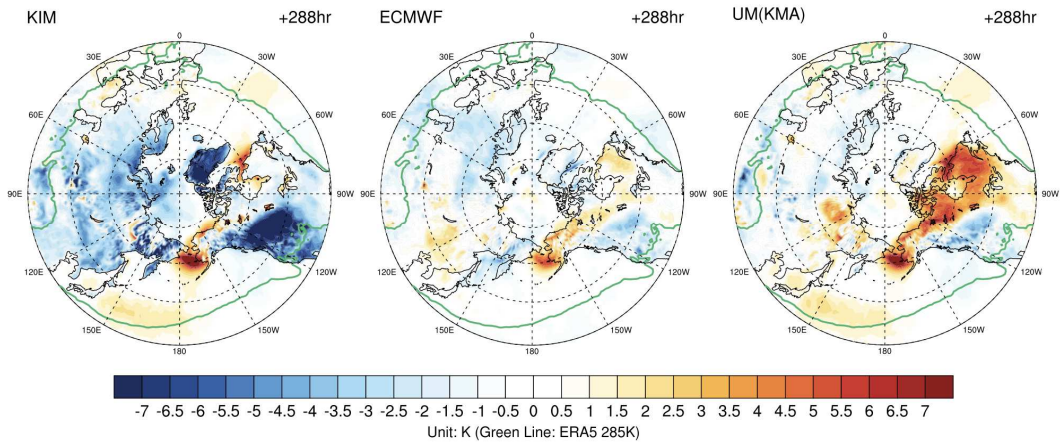


그림 1.1.55 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 12UTC T1000 (위-아래: Forecast Time 000~288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 겨울철 12UTC T1000 앙상블 평균 Bias 분포 예측 성능을 살펴보면, 앞선 00UTC 분석장과 비슷하게 초기 분석장에서부터 한국형앙상블모델의 음의 편차를 전반적으로 살펴볼 수 있으며, UM(KMA) 모델의 일부 대륙 지역에서 양의 편차를 확인할 수 있다. 이러한 편차 크기 및 위치는 앞선 00UTC와 동일하게 288hr Forecast Time 까지 유지되는 것을 확인할 수 있다. 이를 통해, 여름철 00UTC와 12UTC 초기장에 따른 편차의 큰 차이가 모델의 구조적 문제로 인해 발생했다는 점을 다시 한번 확인할 수 있으며, 이러한 부분은 겨울철의 00UTC와 12UTC에서는 발생하지 않았다는 점을 확인할 수 있다 (그림 1.1.55).

- 2021년 7월(여름철) 00, 12UTC T850 분석 결과

2021 JULY 00UTC T850 Ensemble Mean Bias

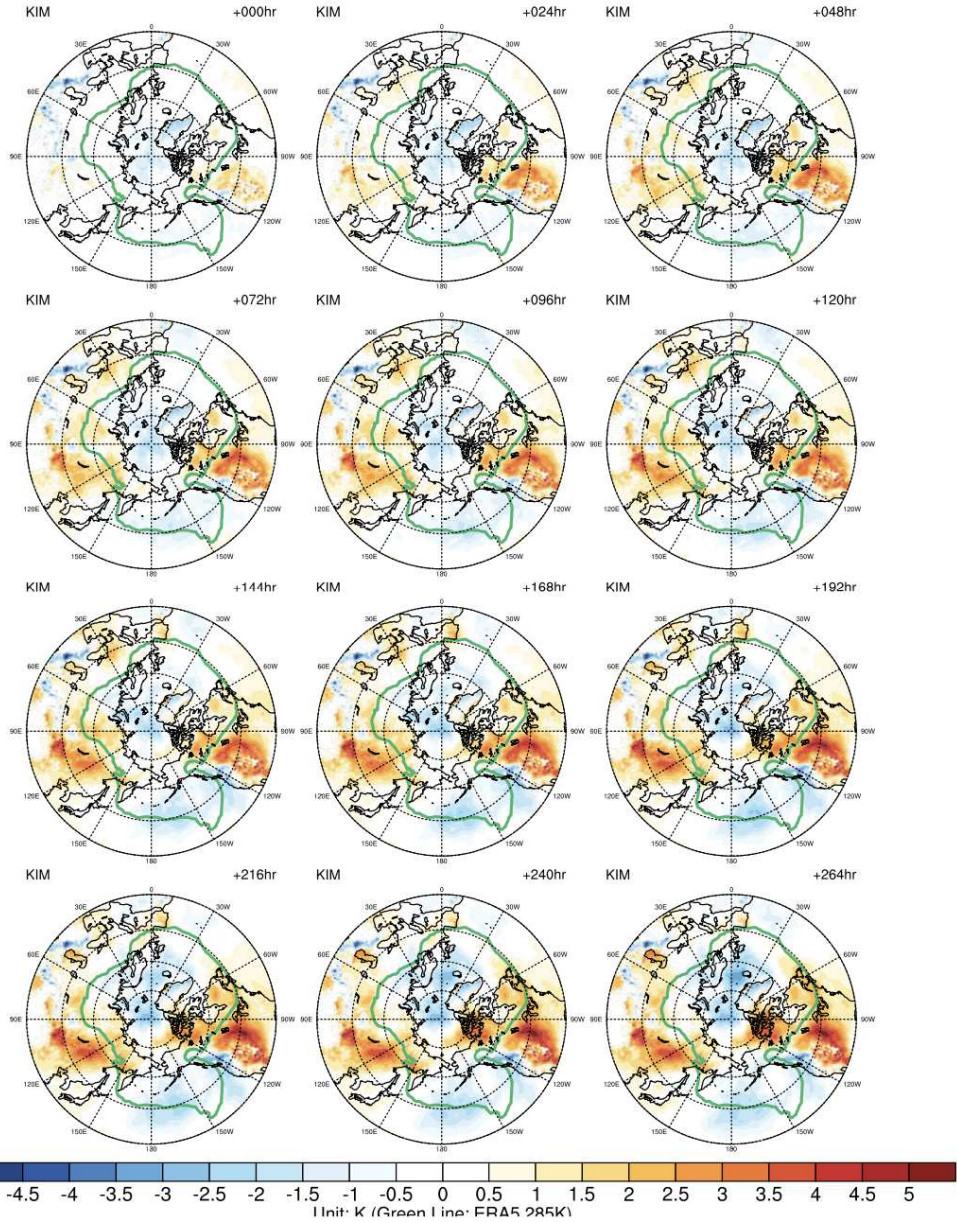


그림 1.1.56 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 00UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)

- 북반구 T850 00UTC 예측 결과를 살펴보면 초기 분석장(00UTC)에서부터 편차가 보이나 크지 않고, 북미 일부 지역의 양의 편차와 그린랜드 주변 부근의 음의 편차가 보이며 이 편차의 양상을 288hr Forecast Time까지 패턴이 유지되며 편차가 증가하는 것을 확인할 수 있다 (그림 1.1.56).

2021 JULY 12UTC T850 Ensemble Mean Bias

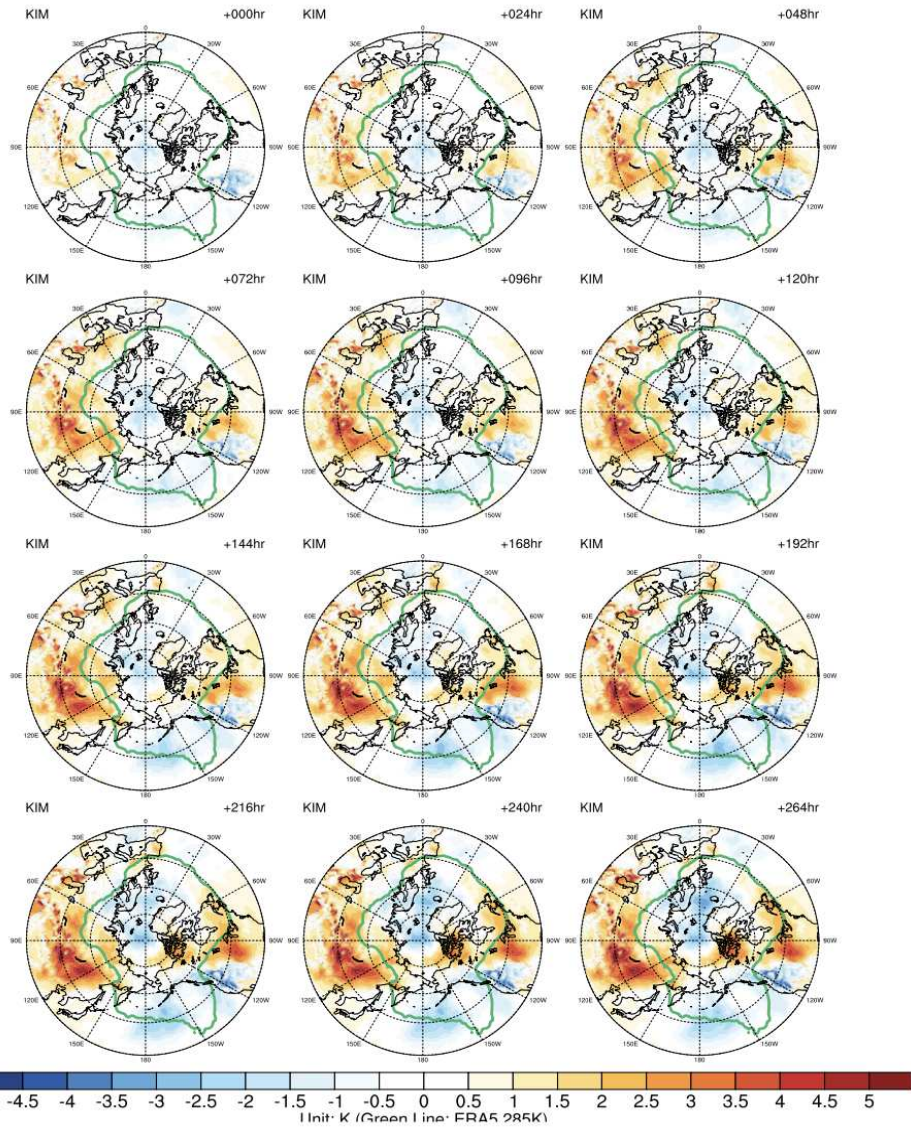


그림 1.1.57 앙상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 12UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)

- 북반구 T850 12UTC 예측 결과를 살펴보면 초기 분석장에서 북미 일부 지역에서 음의 편차가 유라시아 지역에서 전반적으로 양의 편차가 보이는데 288hr Forecast Time으로 갈수록 북미와 유라시아 지역 전반에서 양의 편차가 보이고, 그린란드와 태평양 지역에서 음의 편차가 나타나는 것을 확인할 수 있다. T850 변수에서는 00UTC와 12UTC의 편차 패턴의 차이가 크지 않고 비슷하게 나타나는 것을 보아 앞선 지표 온도에서의 문제점을 다시 한번 확인할 수 있다 (그림 1.1.57).

- 2022년 1월(겨울철) 00, 12UTC T850 분석 결과

2022 JANUARY 00UTC T850 Ensemble Mean Bias

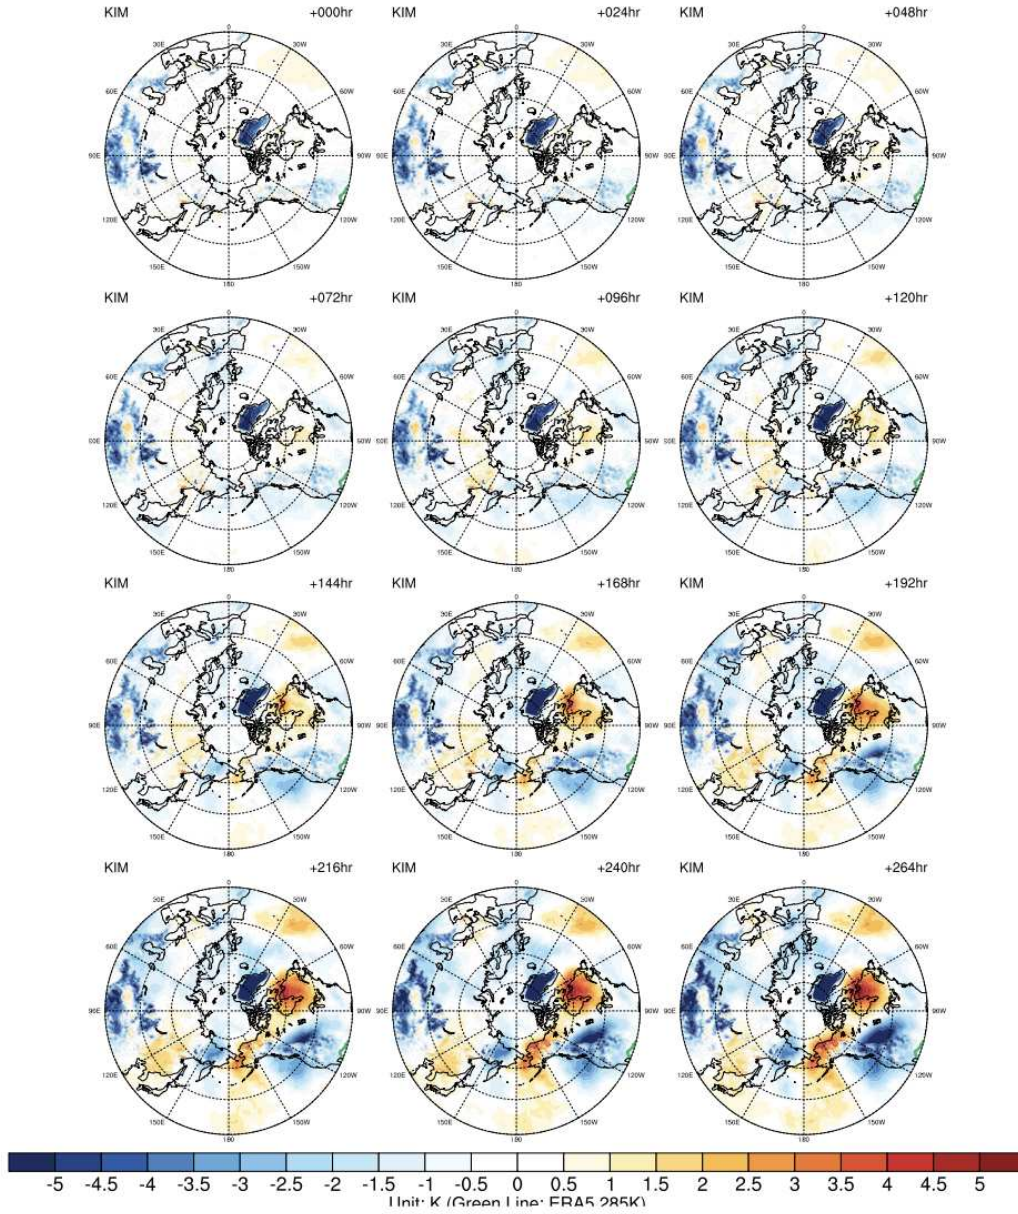


그림 1.1.58 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 00UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)

- 북반구 T850 겨울철 00UTC 예측 결과를 살펴보면 초기 분석장에서 대륙 일부에서 음의 편차가 나타나는 것을 확인할 수 있으며, 이는 288hr Forecast Time이 증가할수록 대륙에서는 전반적으로 음의 편차를 특히 그린란드 대륙에서 강하게 나타나며, 그 주변에서는 양의 편차가 확인된다 (그림 1.1.58).

2022 JANUARY 12UTC T850 Ensemble Mean Bias

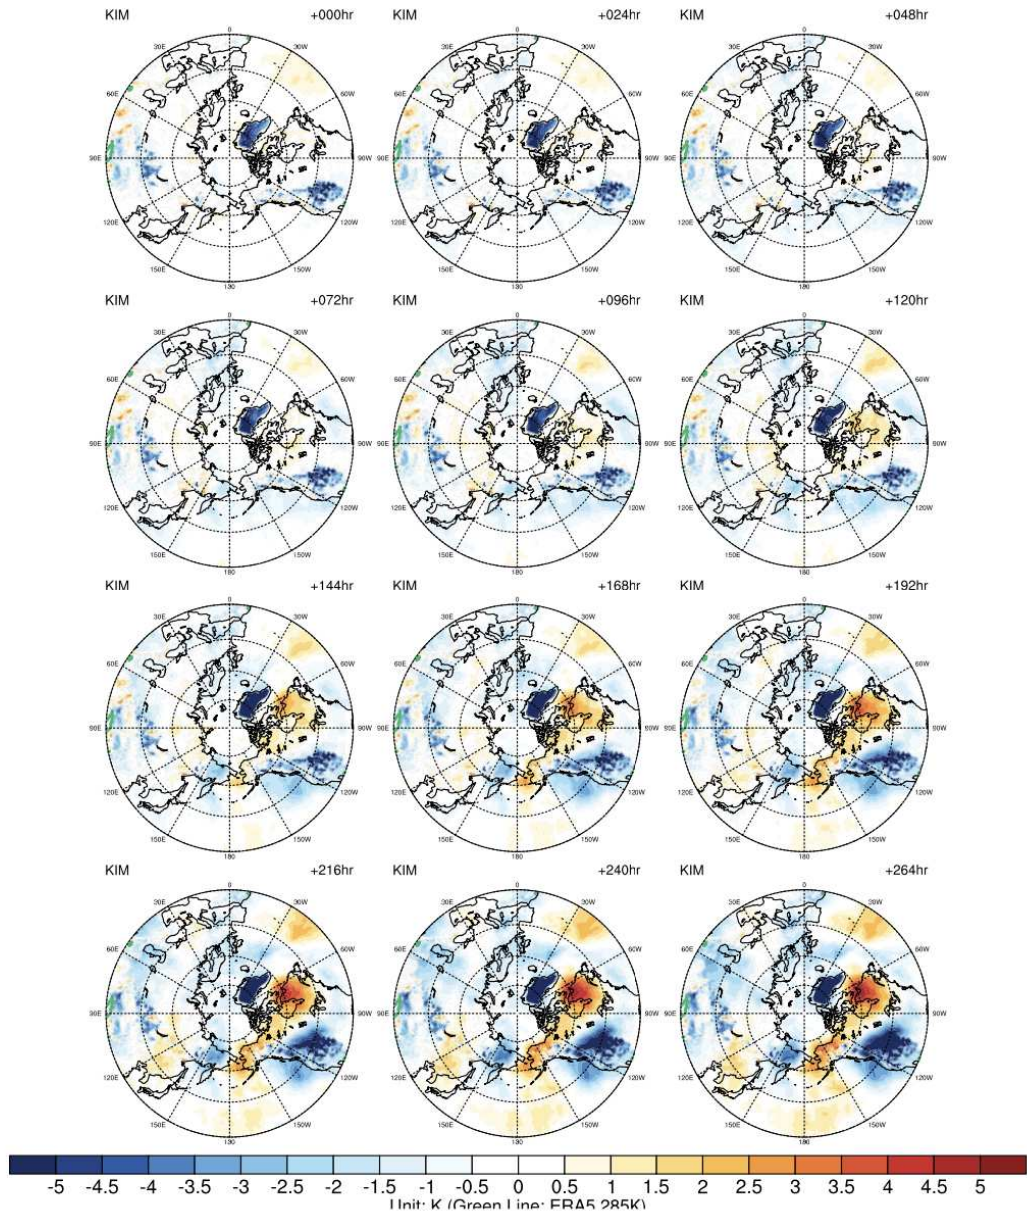
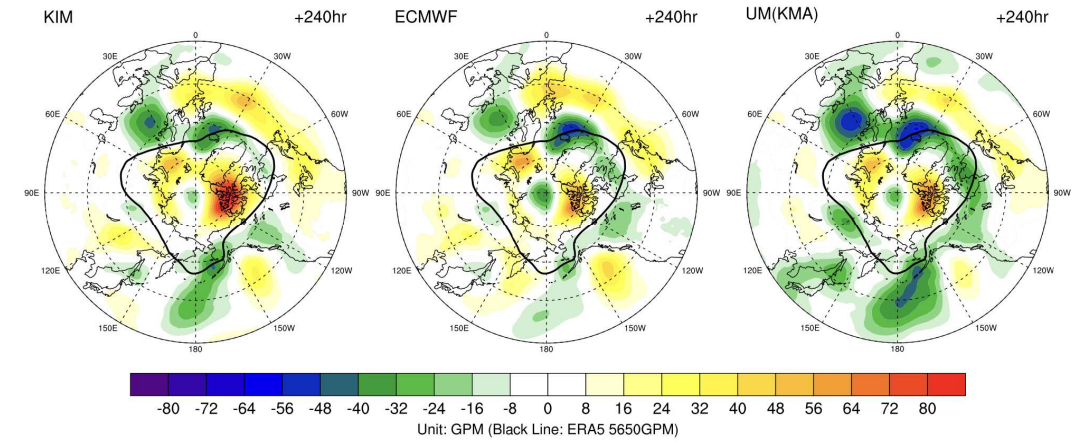
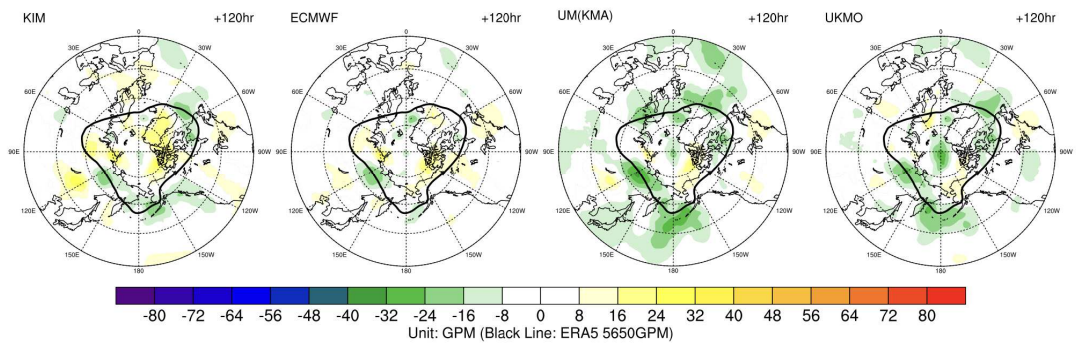



그림 1.1.59 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 12UTC T850 (위-아래: Forecast Time 000~288hr, 한국형앙상블모델)

- 북반구 T850 겨울철 12UTC 예측 결과를 살펴보면 앞선 00UTC와 매우 비슷한 편차 패턴을 보이며, 그 편차의 앙상블만 아니라 편차 범위도 매우 비슷하게 나타나는 것을 확인할 수 있으며, 이를 통해 T850 변수에서는 00UTC와 12UTC 초기장 구성에 있어 모델 구조적 오차가 없음을 확인 할 수 있다 (그림 1.1.59).

- 2021년 7월(여름철) 00, 12UTC Z500 분석 결과

2021 JULY 00UTC Z500 Ensemble Mean Bias



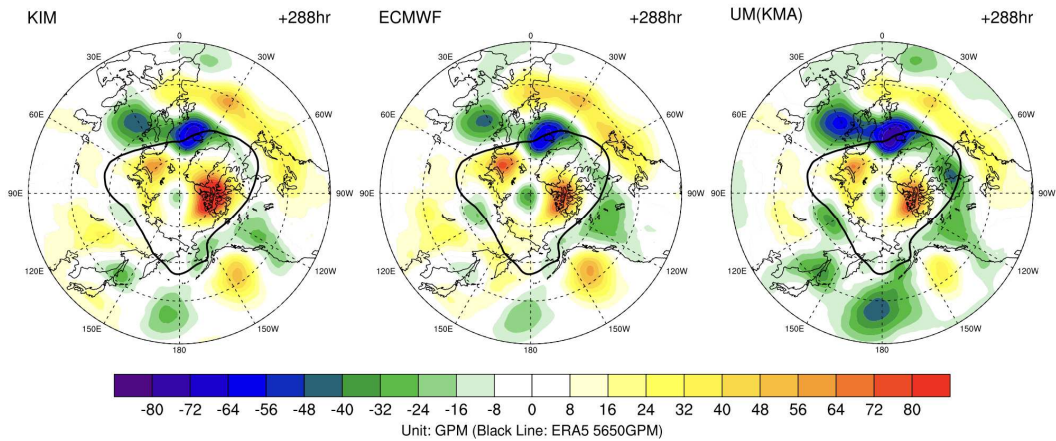
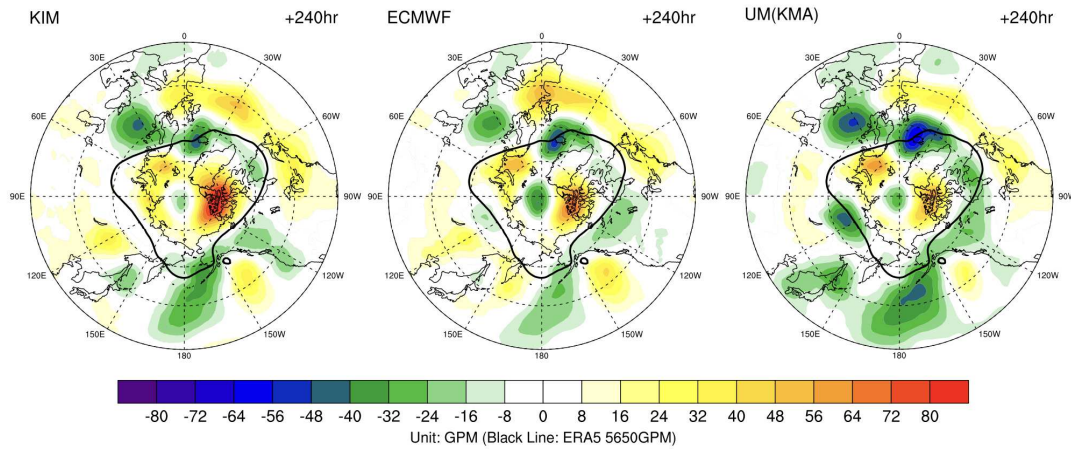
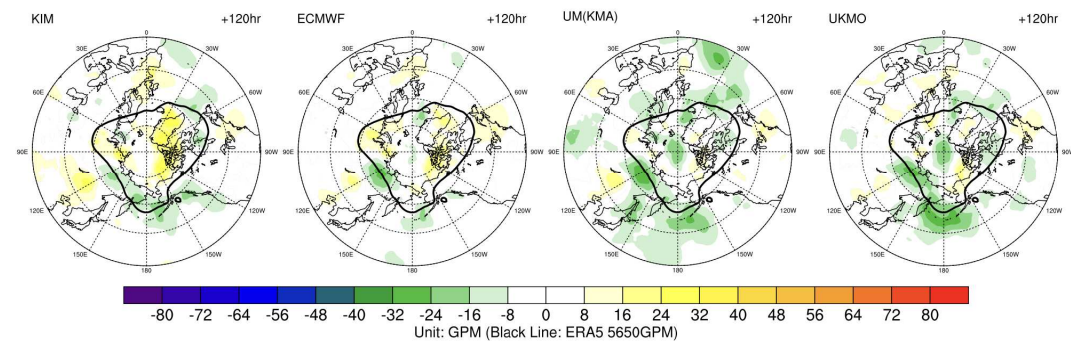



그림 1.1.60 양상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형양상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 여름철 00UTC Z500 편차 분석 결과를 살펴보면, 초기 분석장에서는 모델들 모두 편차가 거의 나타나지 않는 것을 확인할 수 있으며, 120hr Forecast Time에서 한국형양상블모델에서 북극 지역에서의 양의 편차와 주변에서의 음의 편차를 확인 할 수 있다. 유라시아 대륙 지역에서는 편차가 거의 확인되지 않는다. 이는 ECMWF 편차 패턴과 유사하나 ECMWF 모델의 경우 편차가 더 낮게 나타난다. 반면, UM(KMA) 모델과 UKMO 모델은 전반적인 음의 편차를 보이며 이 음의 편차는 다른 모델들에 비해 초기 Forecast Time에서부터 큰 양상을 보이며 288hr Forecast Time까지 유지가 되는 것을 확인할 수 있다 (그림 1.1.60).

2021 JULY 12UTC Z500 Ensemble Mean Bias



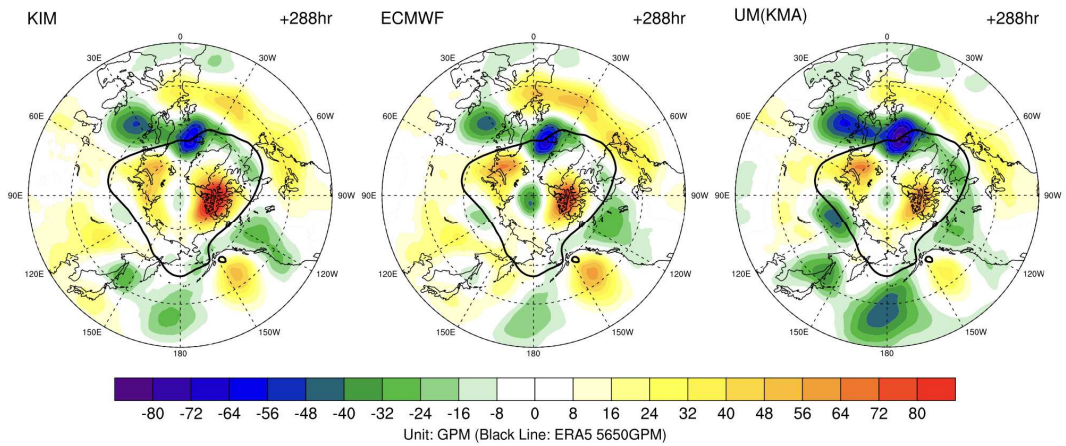
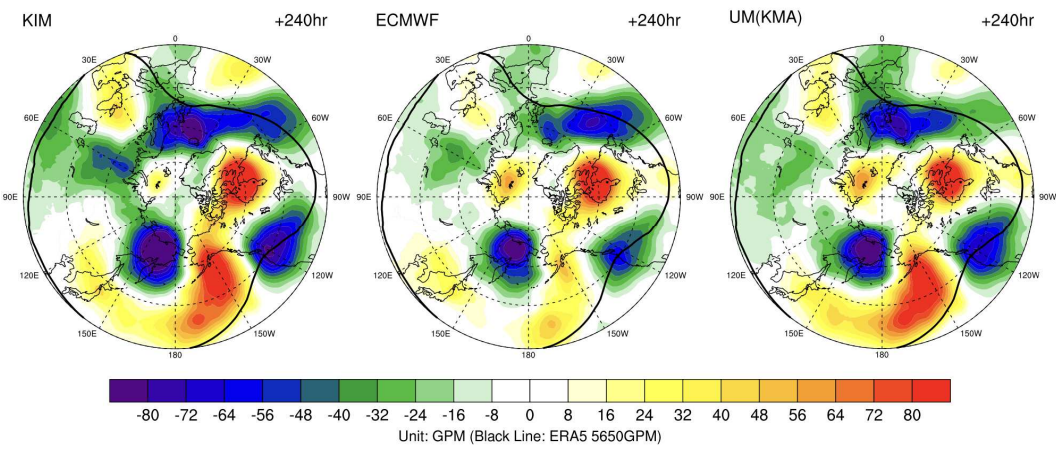

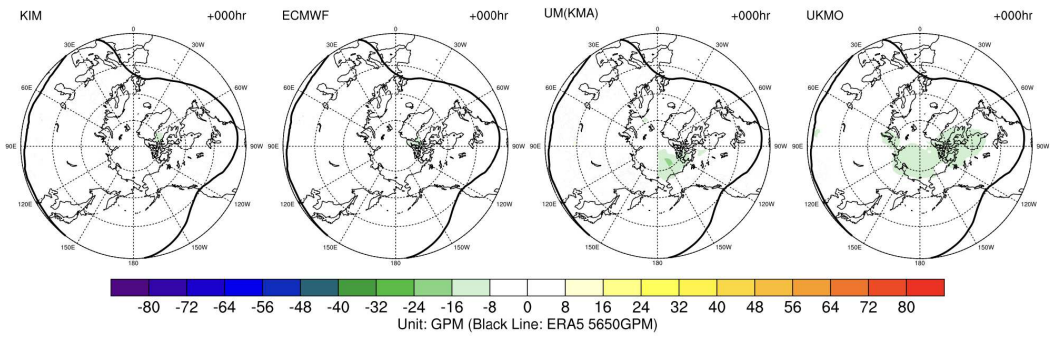


그림 1.1.61 양상블 평균 Bias 분포 예측성 진단 평가: 2021 JULY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형양상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 여름철 12UTC Z500 편차 분석 결과를 살펴보면, 초기 분석장에서는 모델들 모두 편차가 거의 나타나지 않으며 120hr Forecast Time에서는 다른 모델들에 비해 UM(KMA) 모델과 UKMO 모델의 전반적인 음의 편차가 두드러지게 확인된다. 240hr Forecast Time에서는 전반적으로 편차 값의 범위는 유사하나 UM(KMA) 모델에는 음의 편차가 더 큼을 확인할 수 있다 (그림 1.1.61).

- 2022년 1월(겨울철) 00, 12UTC Z500 분석 결과

2022 JANUARY 00UTC Z500 Ensemble Mean Bias



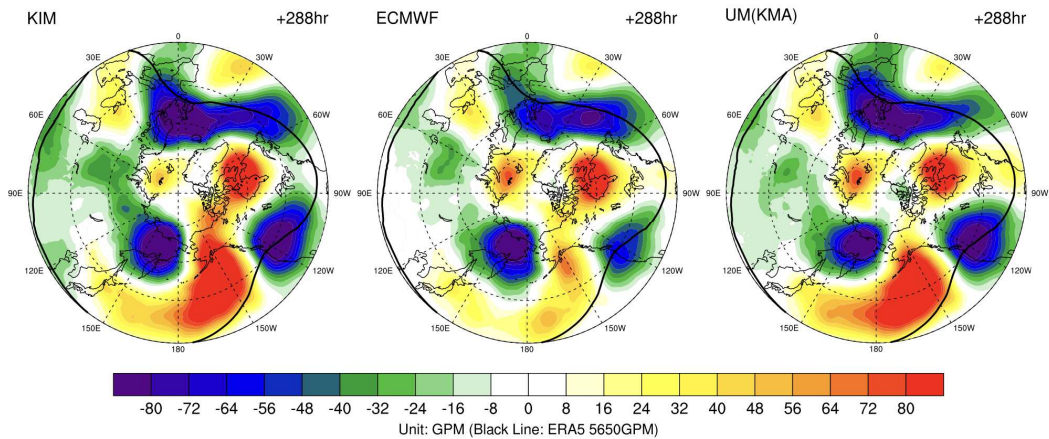
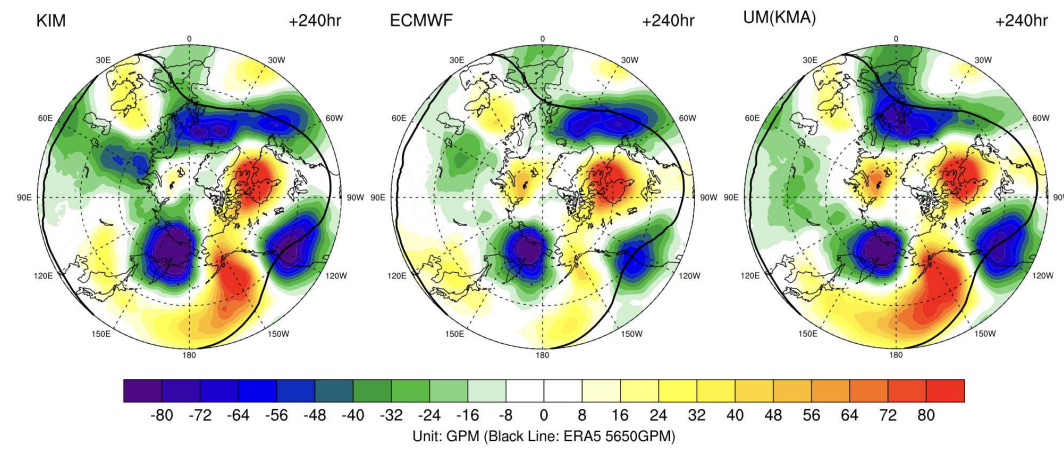
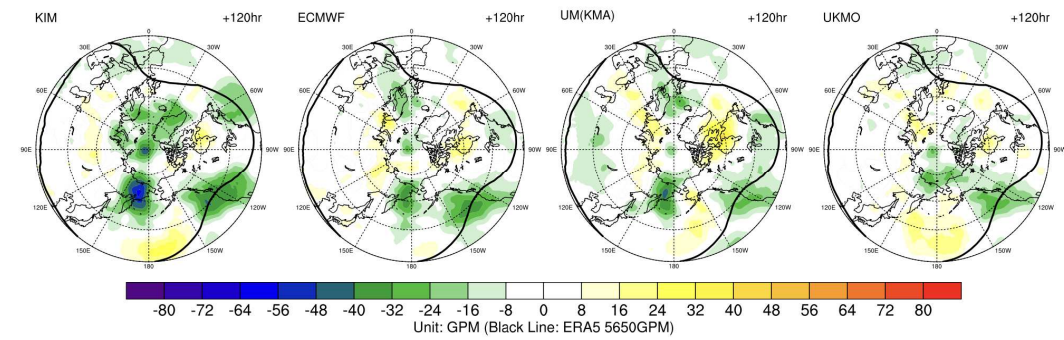
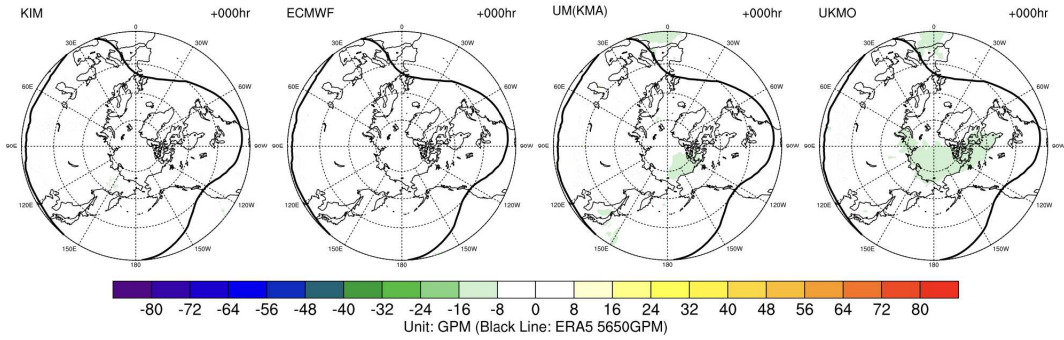


그림 1.1.62 앙상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 겨울철 00UTC Z500 편차 분석을 살펴보면, 초기 분석장에서는 한국형앙상블모델과 ECMWF 모델 모두 거의 편차를 보이지 않으나, UM(KMA)와 UKMO 모델들에서는 음의 편차가 북반구 고위도에서 두드러지게 나타난다. 하지만 120hr Forecast Time으로 증가해서는 한국형앙상블모델의 편차가 크게 나타나며 특히 북반구 고위도, 북극 지역에서 두드러진 음의 편차를 확인할 수 있으며, ECMWF를 포함한 UM(KMA), UKMO 세 모델들의 편차 양상은 비슷한 것을 확인 할 수 있다. 240hr Forecast Time에서는 세 모델 모두 편차의 양상은 비슷하나 태평양 지역에서의 양의 편차 양상은 UM(KMA)와 한국형앙상블모델이 비슷한 것을 확인 할 수 있다. 이를 통해 예측 13일 이후의 편차는 본 변수에 대해서 UM(KMA)와 한국형앙상블모델이 비슷한 것을 확인할 수 있다. 이는 상층 모델 예측 성능에 있어 한국형앙상블모델이 ECMWF 보다 UM(JKMA) 모델과 비슷한 구조적 형태를 가지고 있음을 예상할 수 있다 (그림 1.1.62).

2022 JANUARY 12UTC Z500 Ensemble Mean Bias



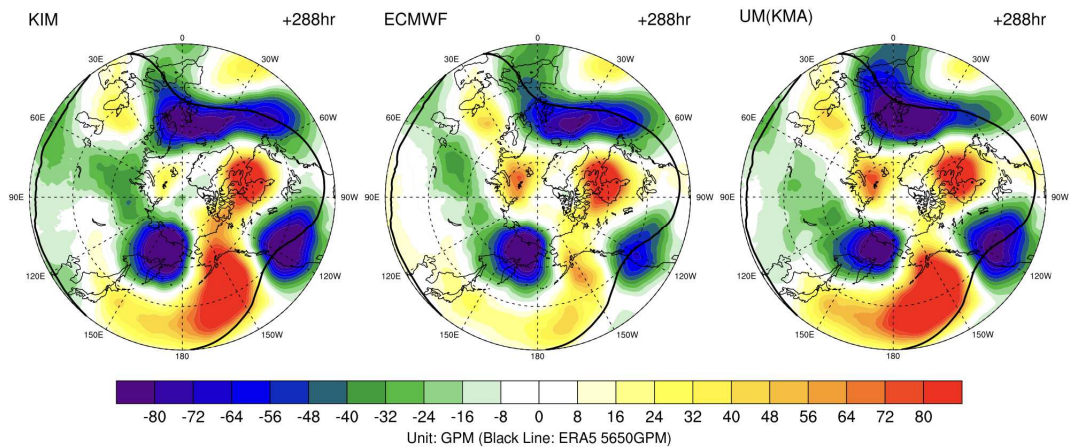


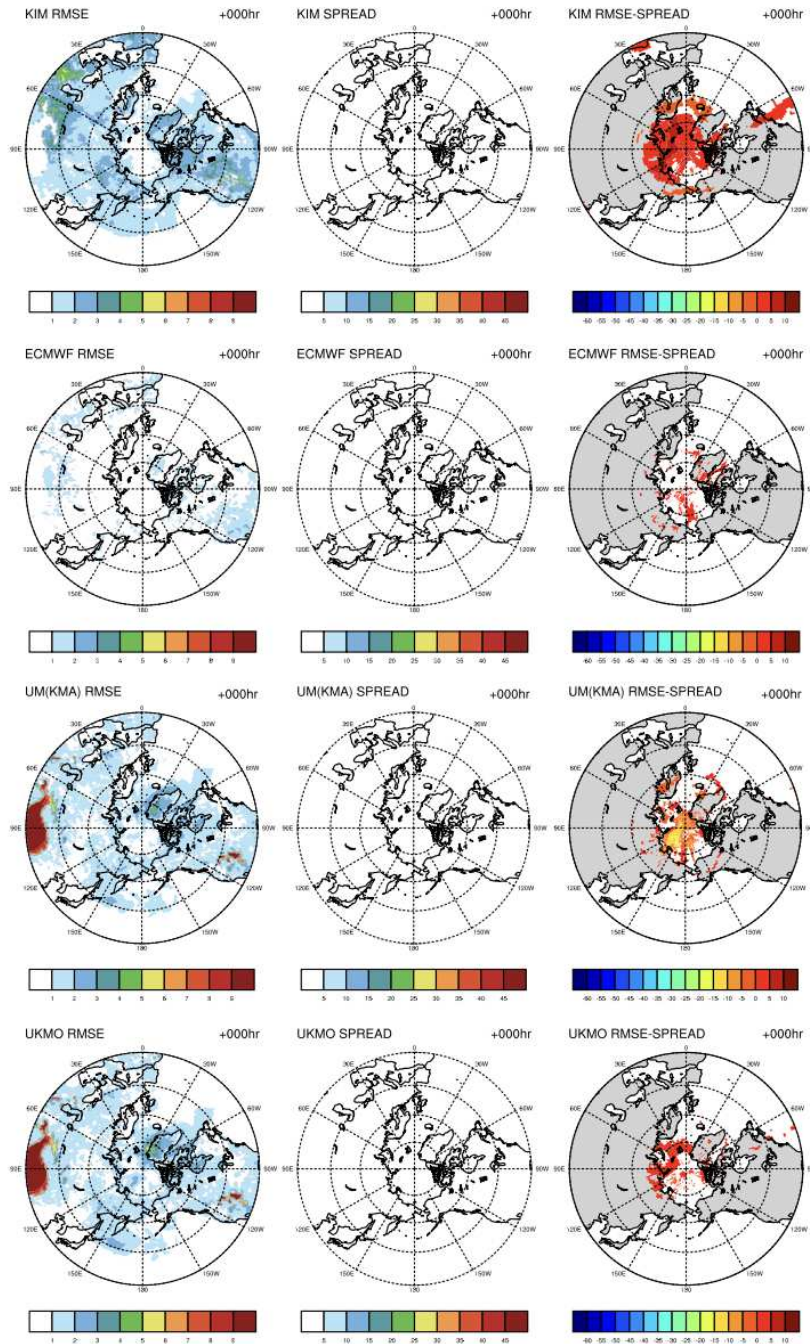
그림 1.1.63 양상블 평균 Bias 분포 예측성 진단 평가: 2022 JANUARY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형양상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 겨울철 12UTC Z500 편차 분석을 살펴보면, 전반적으로 앞선 00UTC 예측 편차 양상과 비슷한 것을 확인할 수 있다. 초기 분석장에서 모델별로 나타나는 편차 양상부터 예측 13일 후인 288hr Forecast Time에서도 비슷한 양상을 보인다. 특히, 한국형양상블모델과 UM(KMA) 모델의 편차 양상이 매우 비슷하여 음의 편차와 양의 편차가 나타나는 지역별 양상이 매우 유사하다. 특히 ECMWF와 비교하였을 때 태평양 지역에서 나타나는 양의 편차 양상이 공통적으로 나타나는 특징으로 볼 수 있다 (그림 1.1.63).

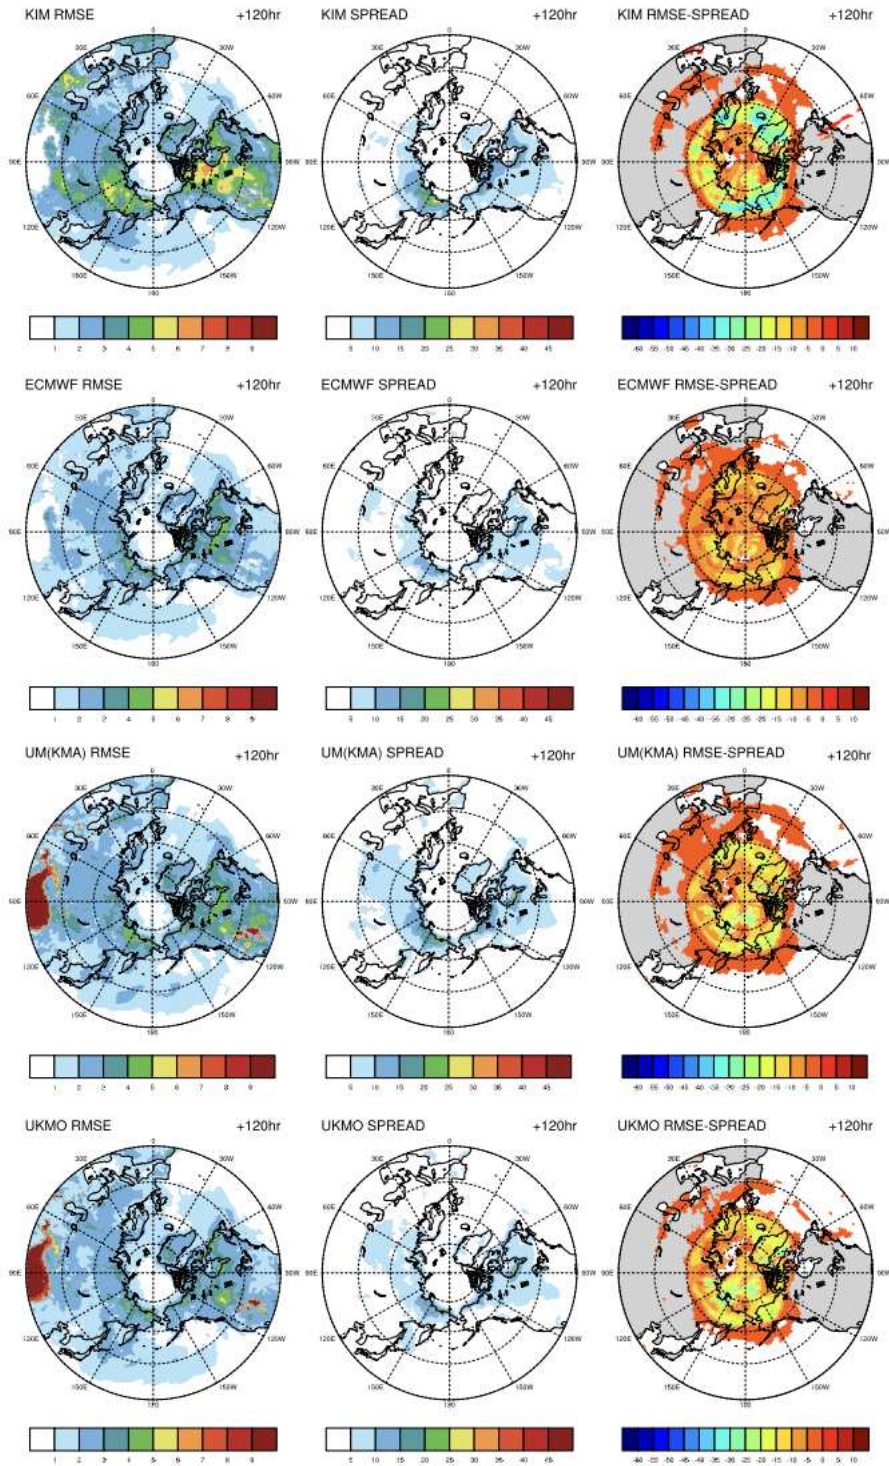
3) 앙상블 RMSE, Spread 분포 진단 평가

- 2021년 7월(여름철) 00, 12UTC T1000 분석 결과

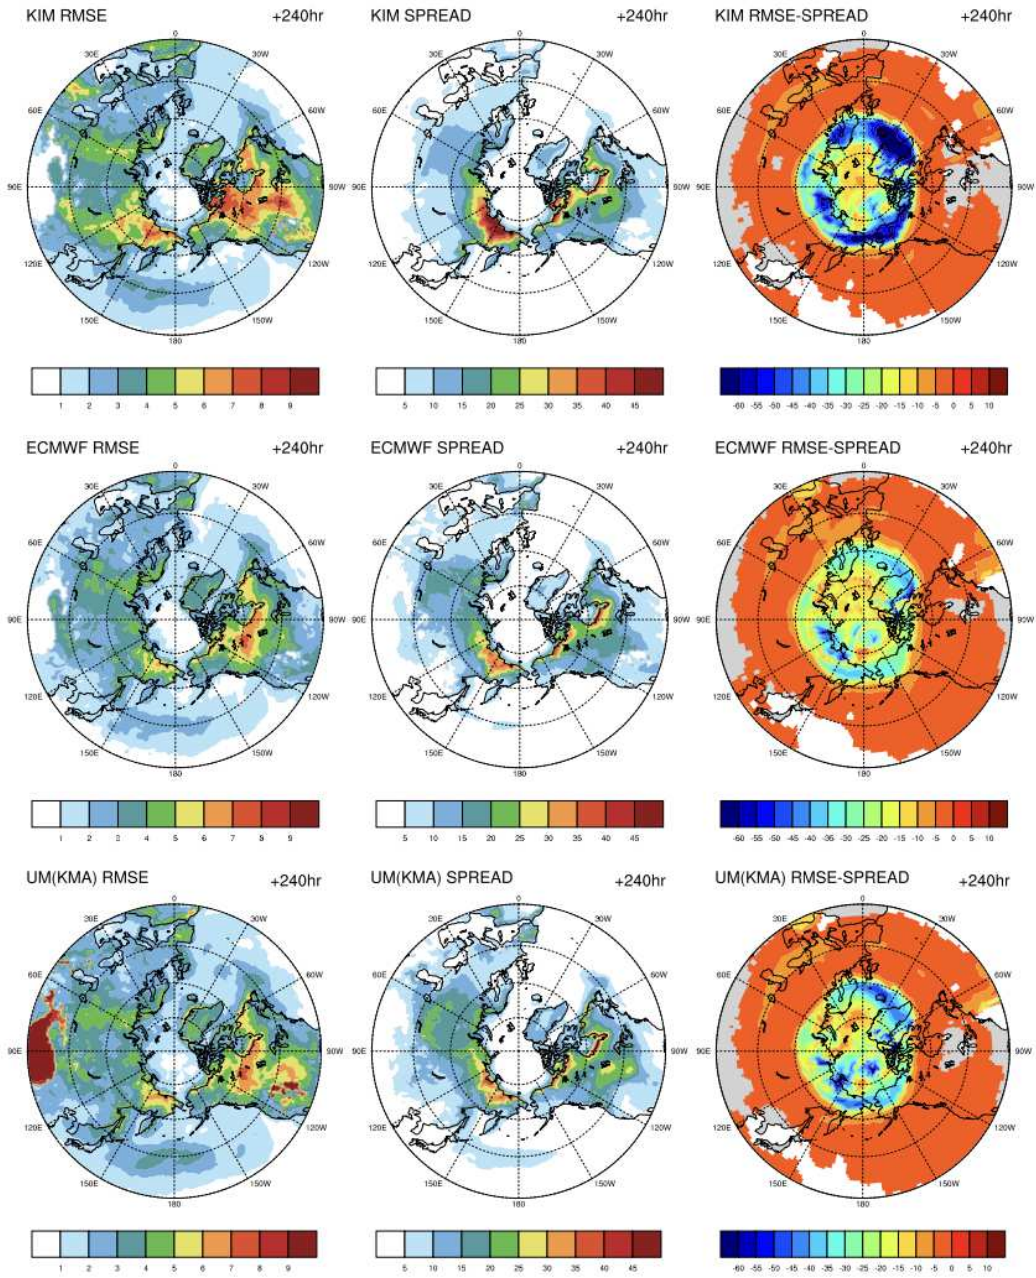
2021 JULY 00UTC T1000 RMSE & SPREAD



2021 JULY 00UTC T1000 RMSE & SPREAD



2021 JULY 00UTC T1000 RMSE & SPREAD



2021 JULY 00UTC T1000 RMSE & SPREAD

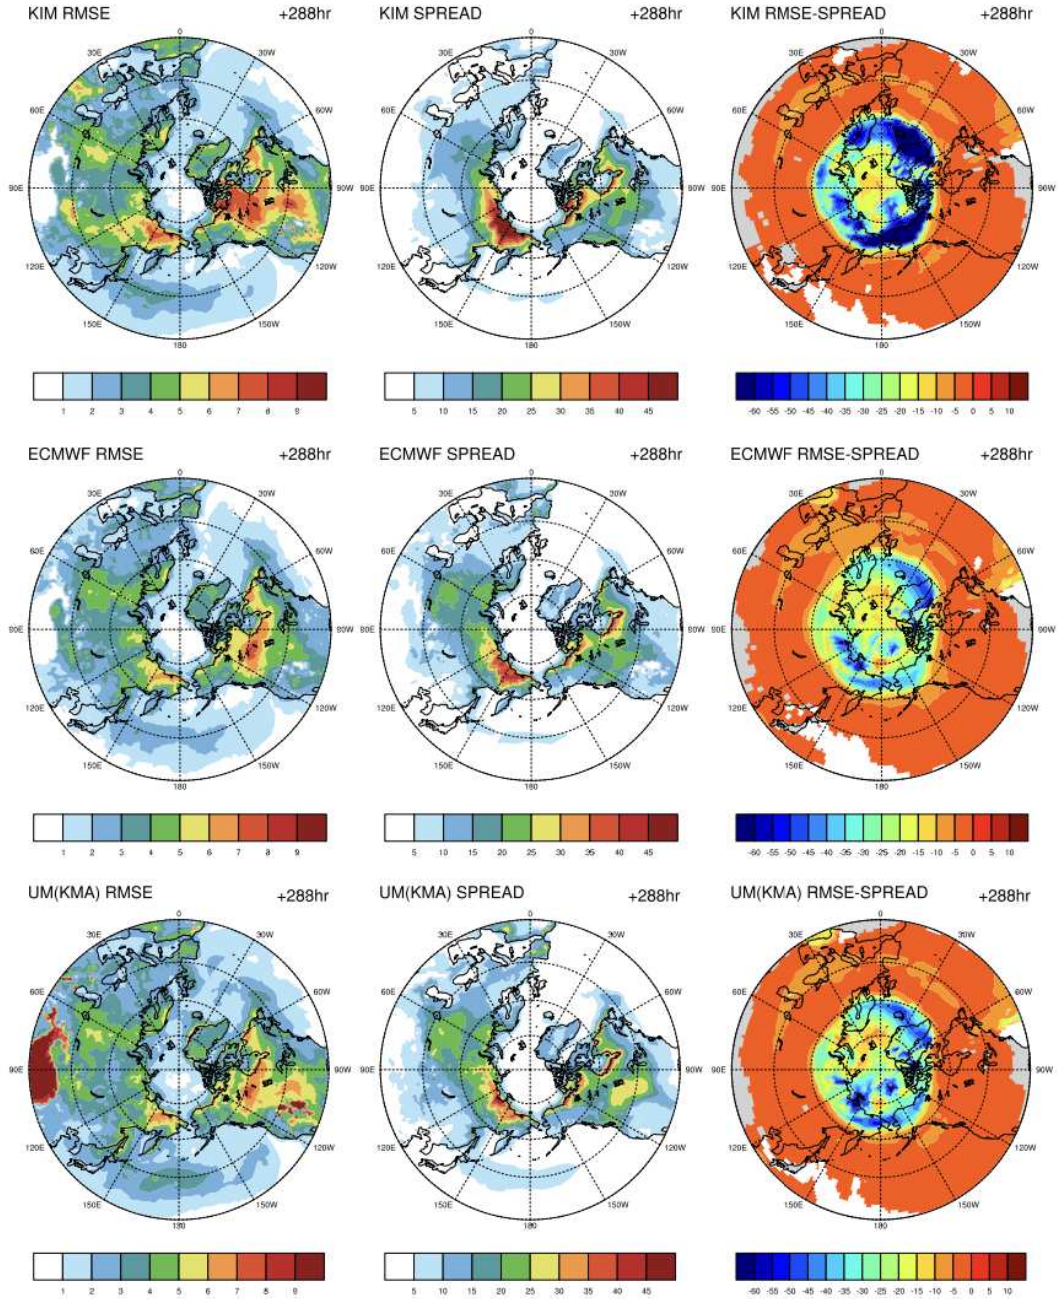
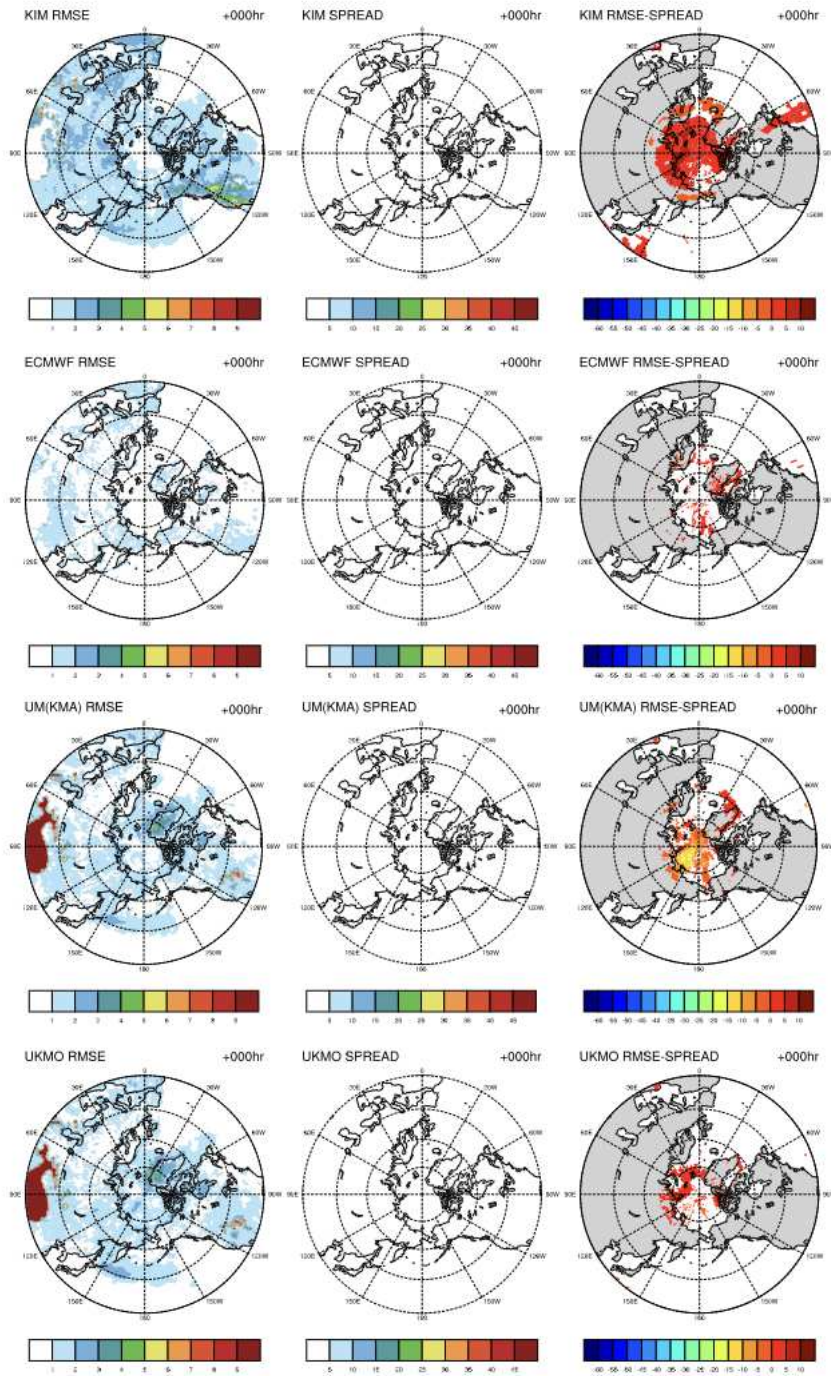


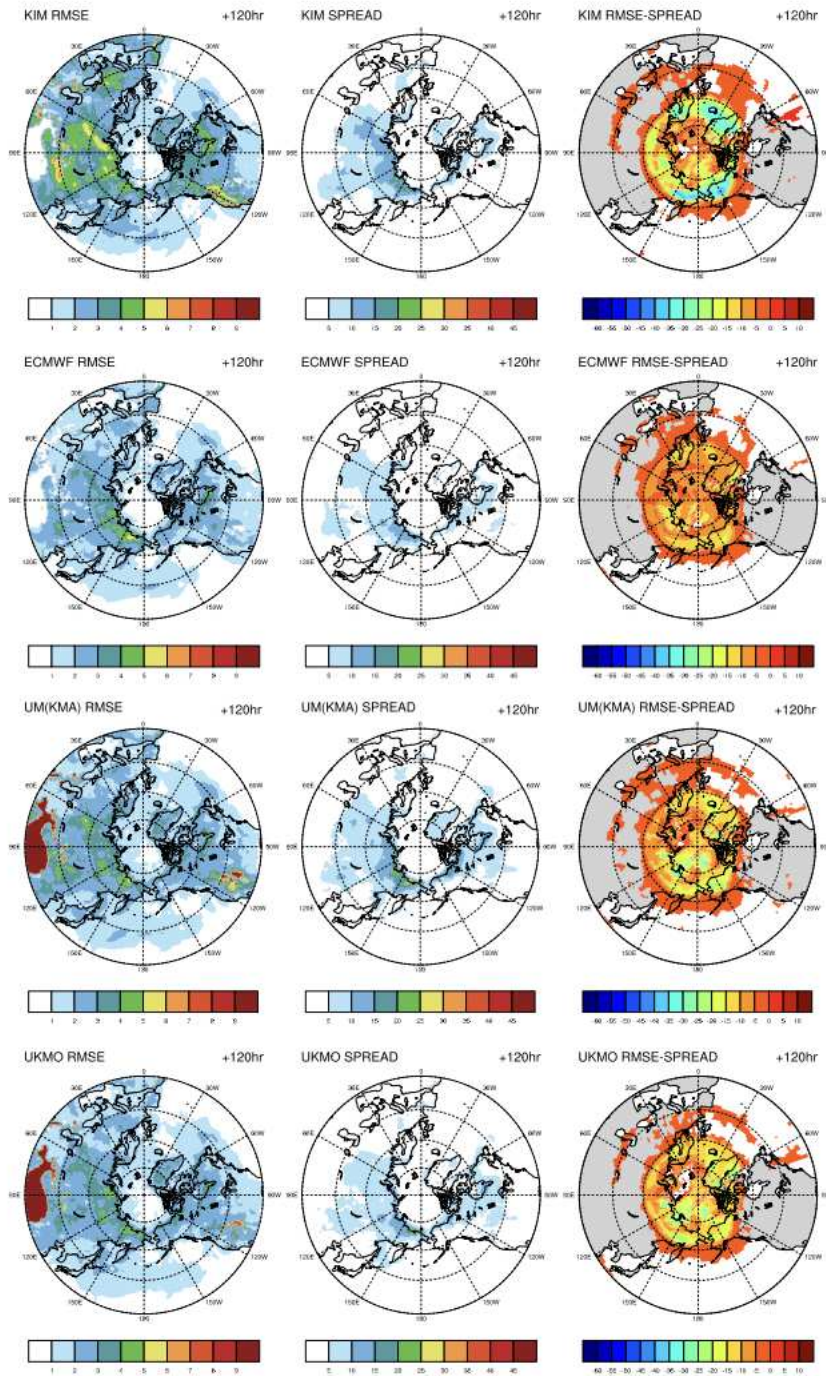
그림 1.1.64 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 00UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델 (KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 T1000 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 초기 분석장에서 RMSE 분포가 한국형앙상블모델에서 큰 오차를 보이는 것을 확인할 수 있다. 반면 ECMWF는 RMSE가 거의 나타나지 않는다. UKMO와 UM(KMA) 모델은 매우 비슷한 RMSE 패턴을 보이며, 동아시아 대륙 지역 중 티벳 고원에서 지표에 의한 모델의 오차를 확인할 수 있다. Forecast Time이 증가함에 따라 전반적으로 한국형앙상블모델은 북미 대륙 지역에서 큰 편차를 보이며, 그 양상은 ECMWF와도 유사하다 (그림 1.1.64).

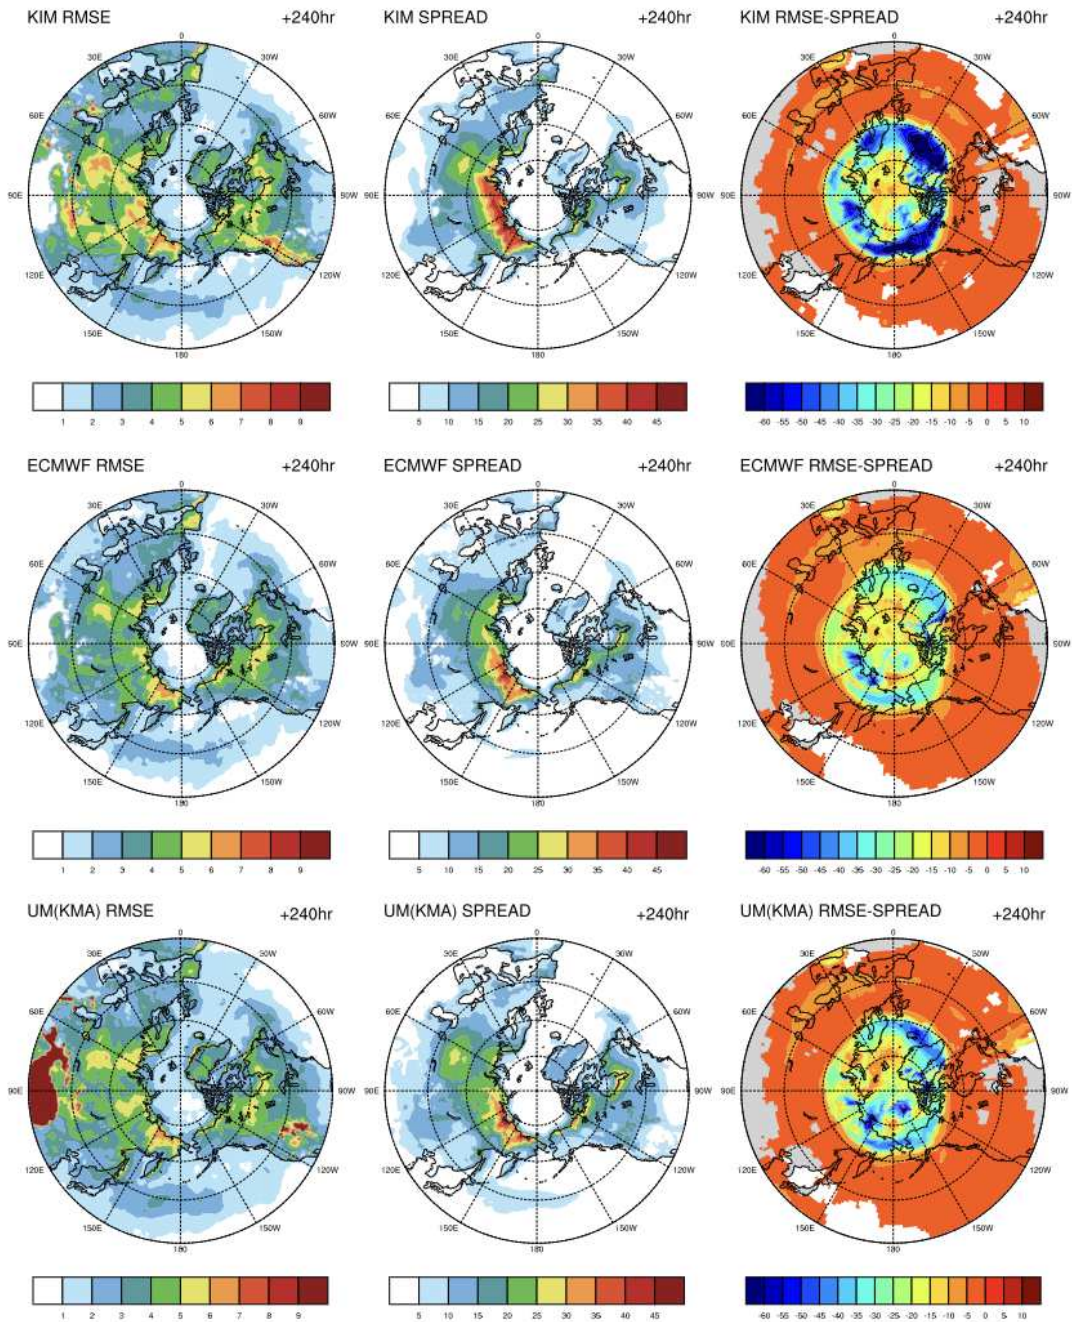
2021 JULY 12UTC T1000 RMSE & SPREAD



2021 JULY 12UTC T1000 RMSE & SPREAD



2021 JULY 12UTC T1000 RMSE & SPREAD



2021 JULY 12UTC T1000 RMSE & SPREAD

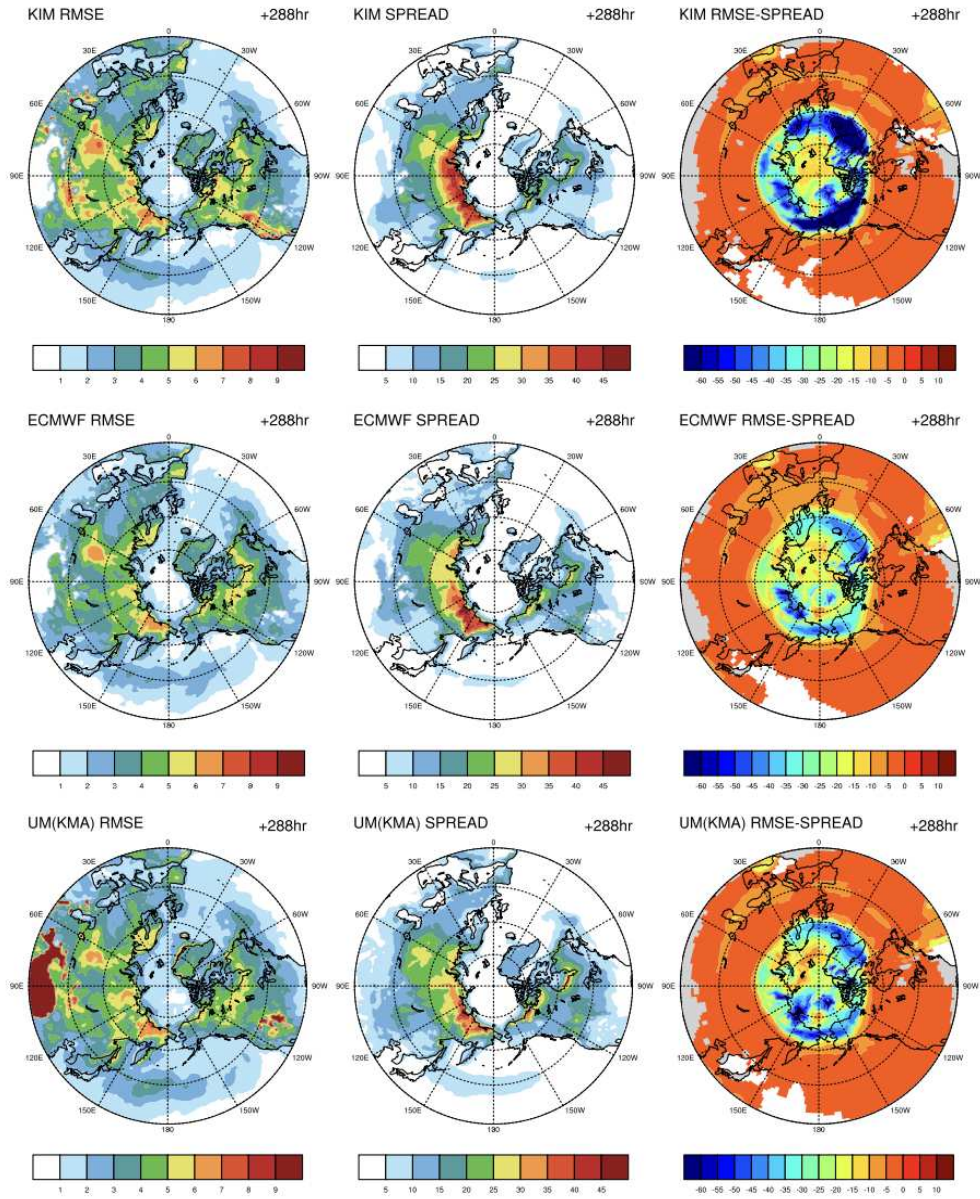


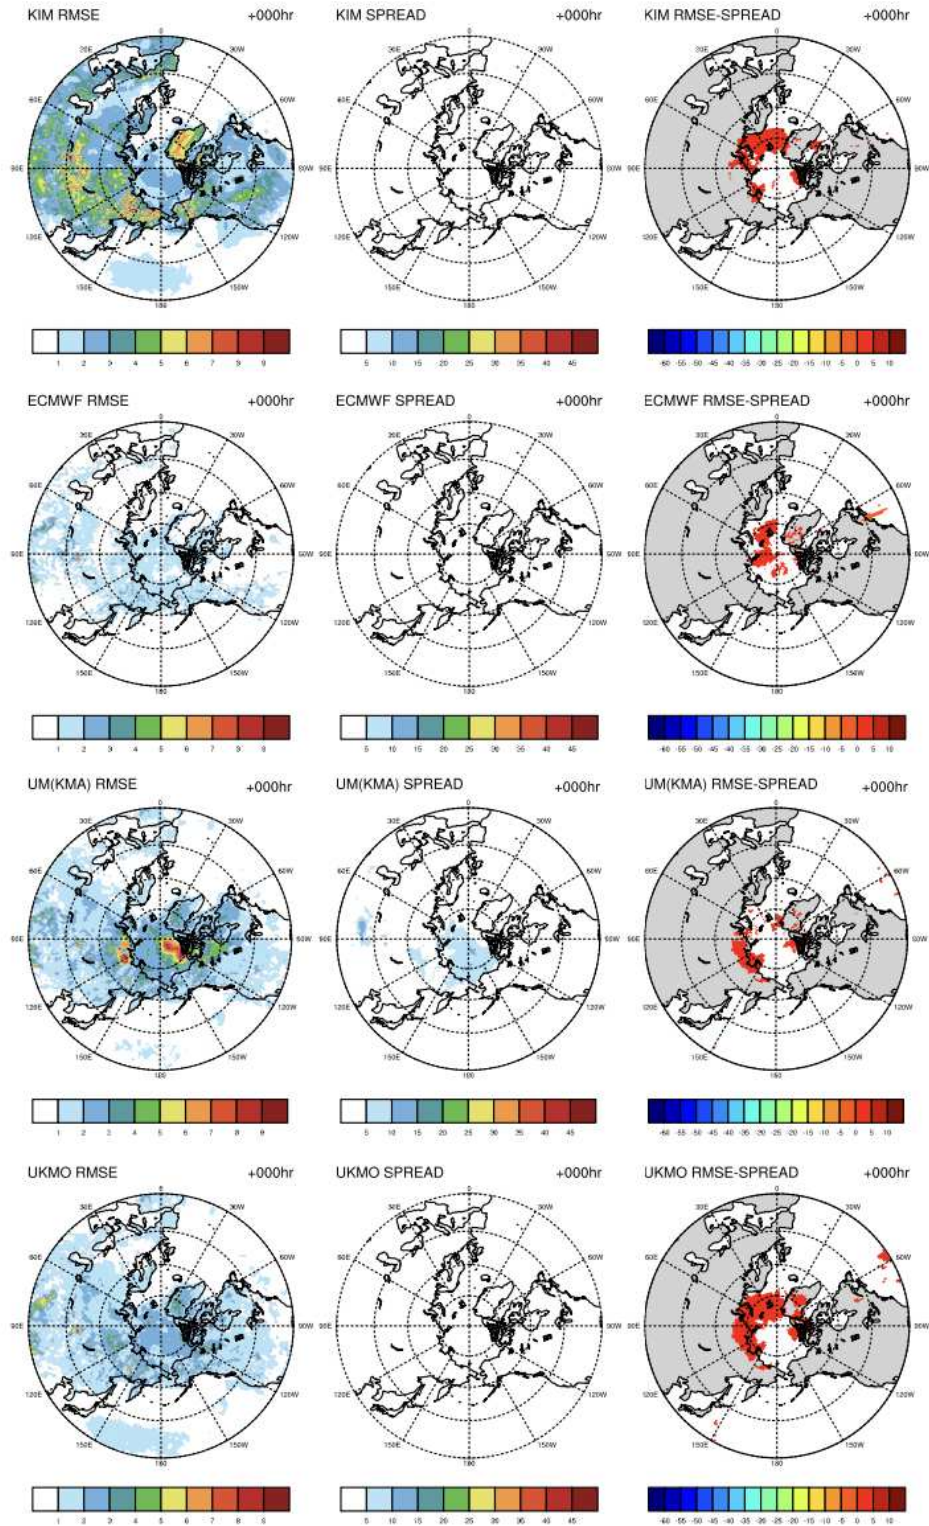
그림 1.1.65 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 12UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 T1000 12UTC RMSE, Spread 분포 예측 성능을 살펴보면, 00UTC와 유사한 패턴을 보이며, 그 차이는 Forecast Time이 증가함에 따라 함께 커지는 것을 확인할 수 있다. 특히 초기 분석장에서의 RMSE 패턴의 양상이

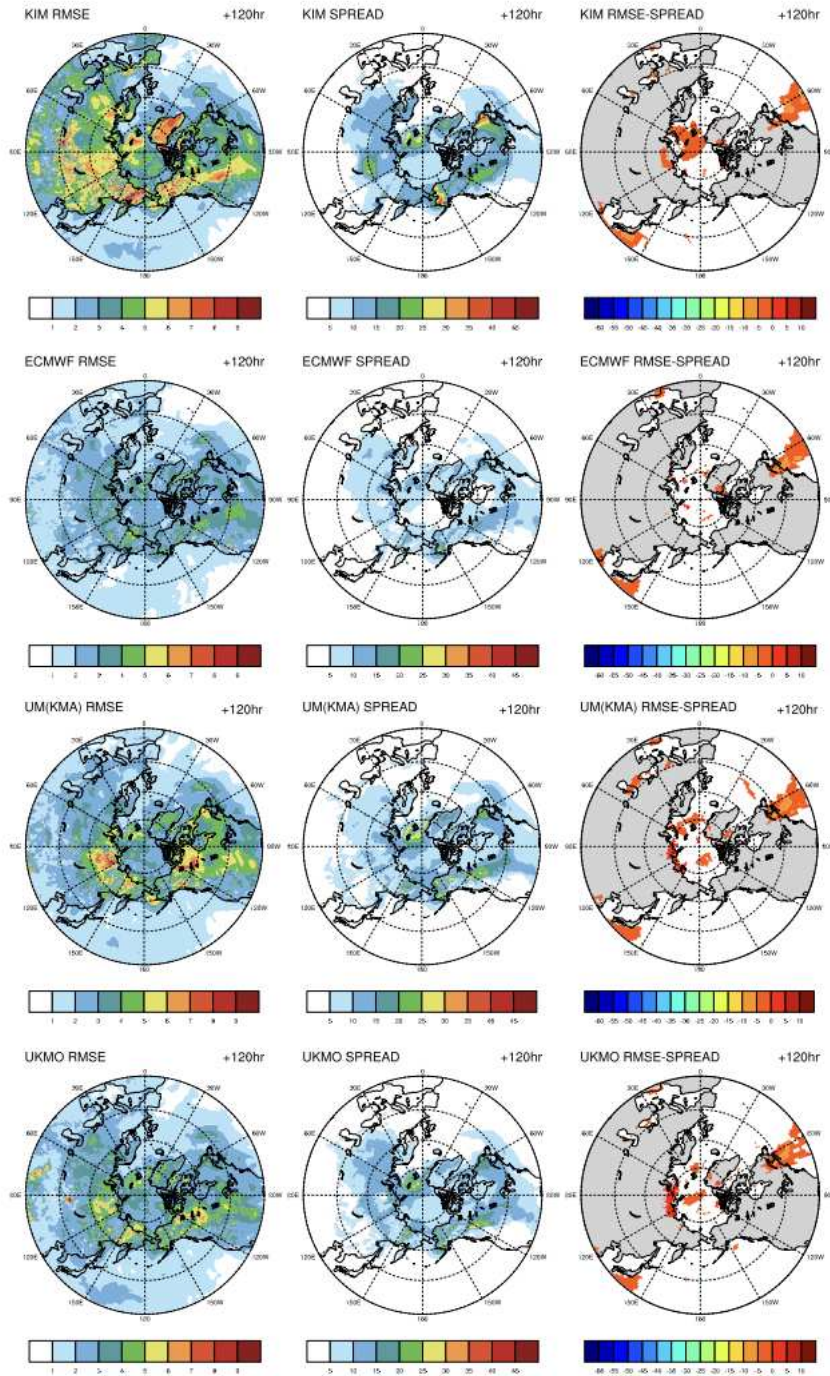
288hr Forecast Time까지 유지됨을 확인할 수 있다 (그림 1.1.65).

- 2022년 1월(겨울철) 00, 12UTC T1000 분석 결과

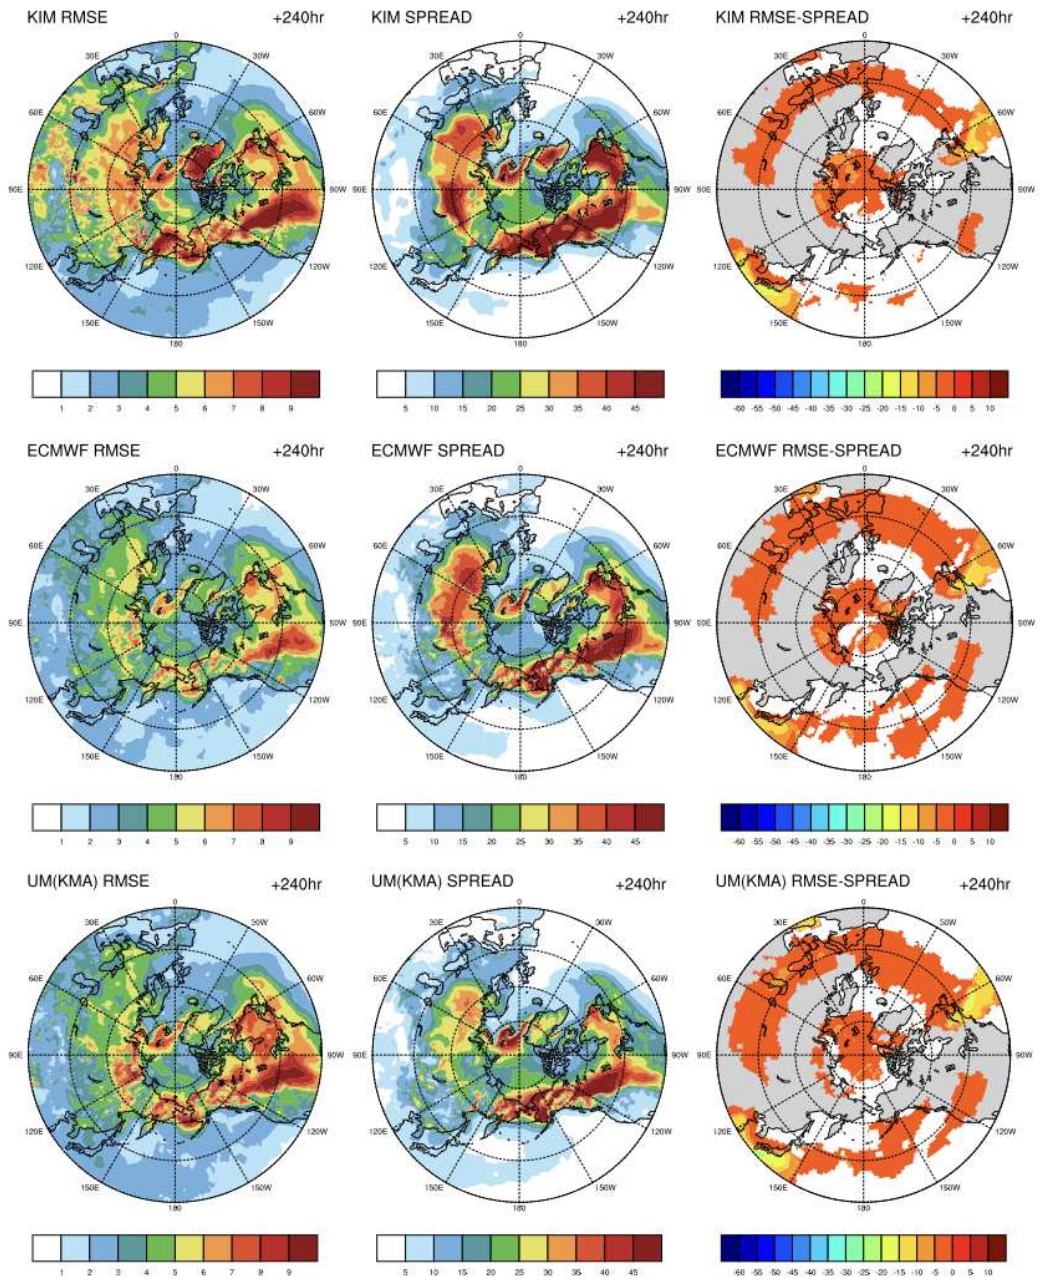
2022 JANUARY 00UTC T1000 RMSE & SPREAD



2022 JANUARY 00UTC T1000 RMSE & SPREAD



2022 JANUARY 00UTC T1000 RMSE & SPREAD



2022 JANUARY 00UTC T1000 RMSE & SPREAD

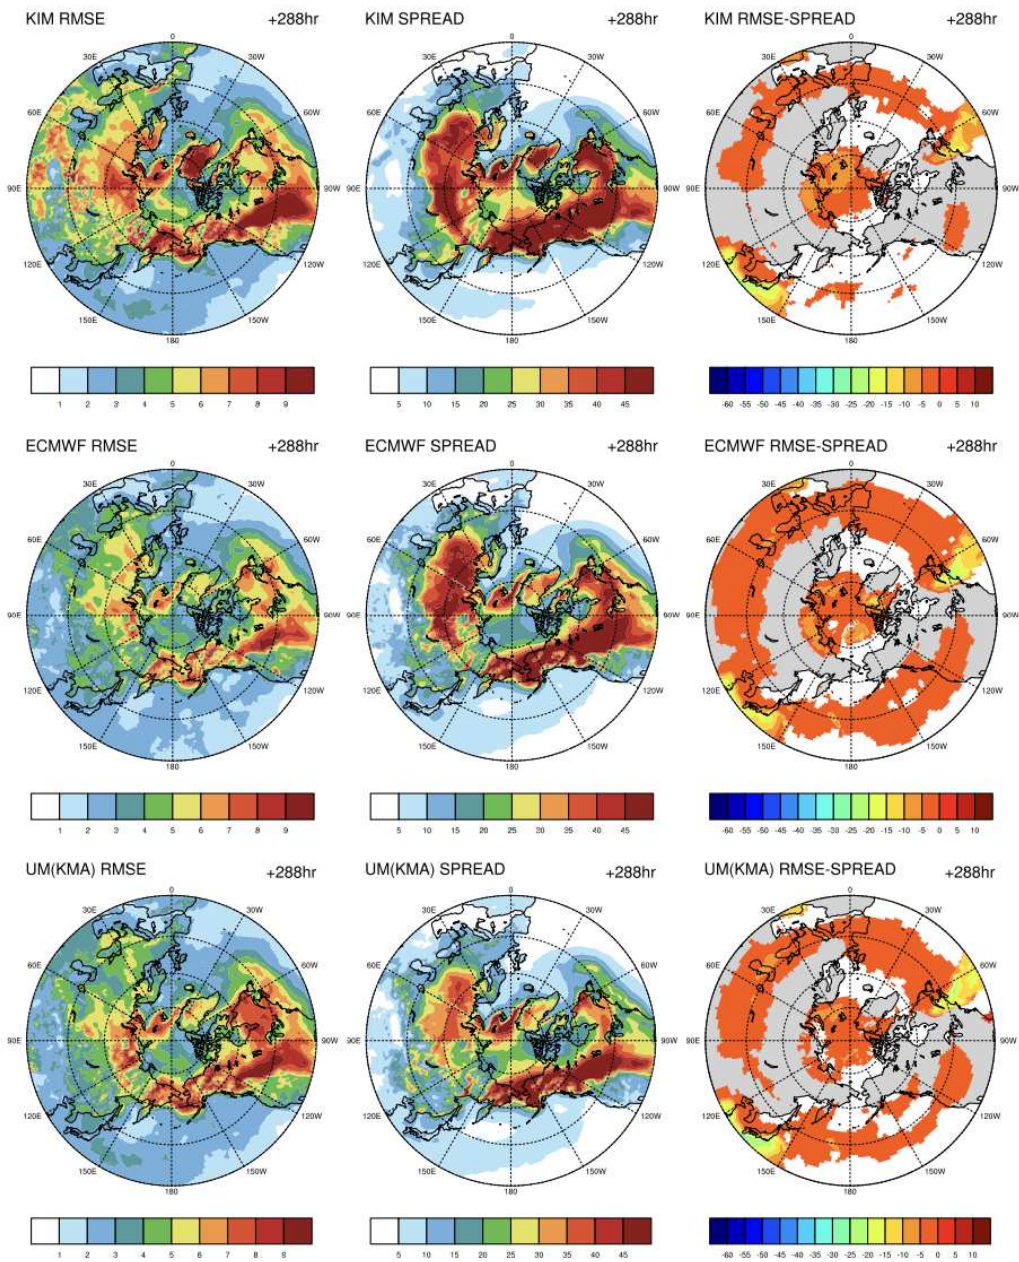
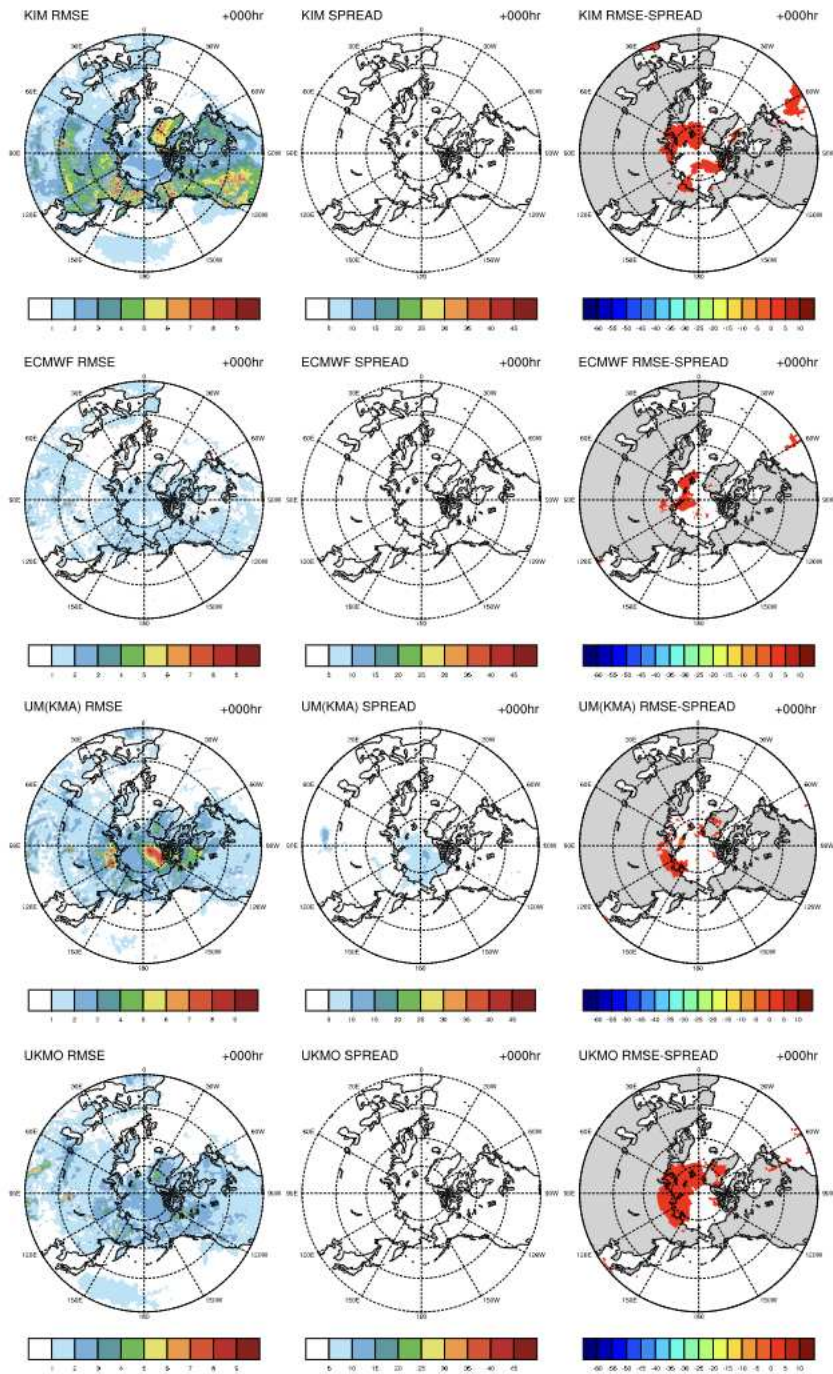


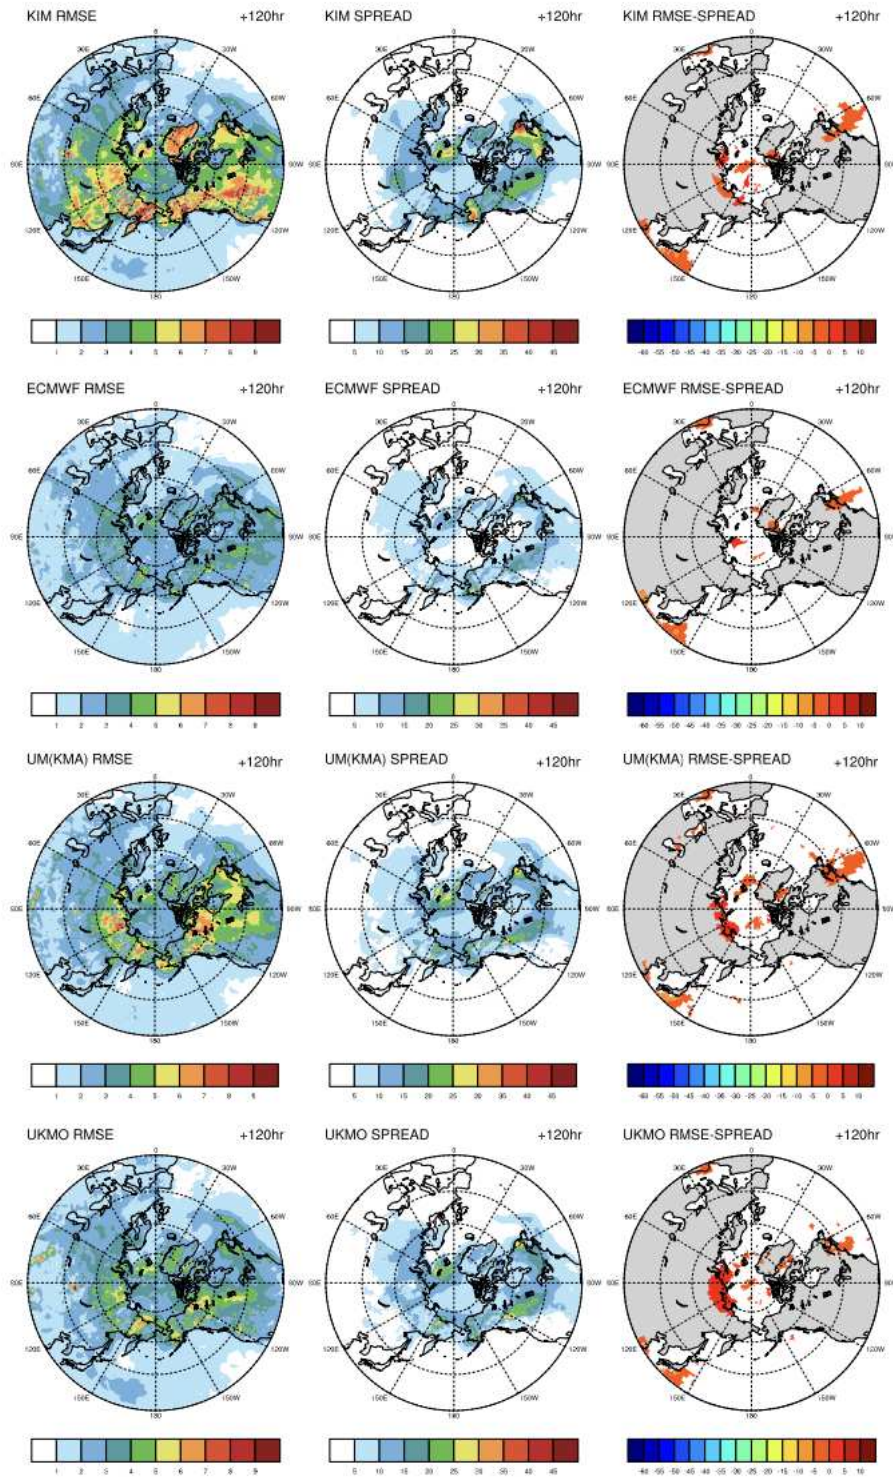
그림 1.1.66 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 00UTC T1000 (위-아래: Forecast Time 00, 120, 240, 288hr, 오른쪽-왼쪽: 한국형 앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 T1000 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 여름철과 유사한 초기 분석장의 차이를 확인할 수 있으며, 북반구 대륙 지역 전반에서 RMSE가 양의 패턴을 보이며 그 양상은 Forecast Time이 증가함에 따라 함께 증가함을 알 수 있다. Spread 분포 또한 동일한 영역에서 큰 편차 양상을 보임을 확인할 수 있다 (그림 1.1.66).

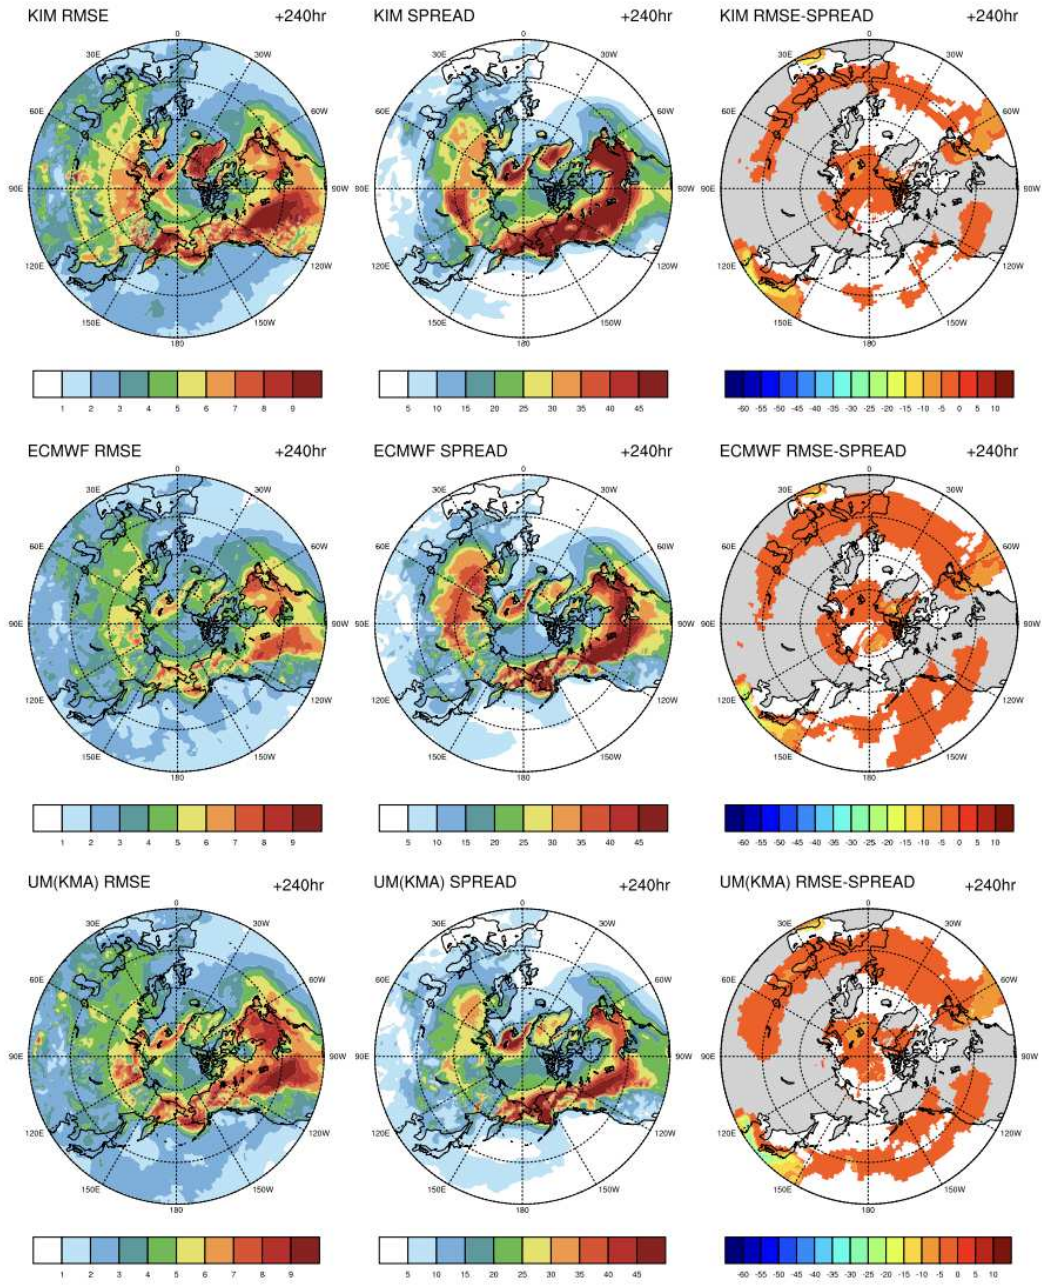
2022 JANUARY 12UTC T1000 RMSE & SPREAD



2022 JANUARY 12UTC T1000 RMSE & SPREAD



2022 JANUARY 12UTC T1000 RMSE & SPREAD



2022 JANUARY 12UTC T1000 RMSE & SPREAD

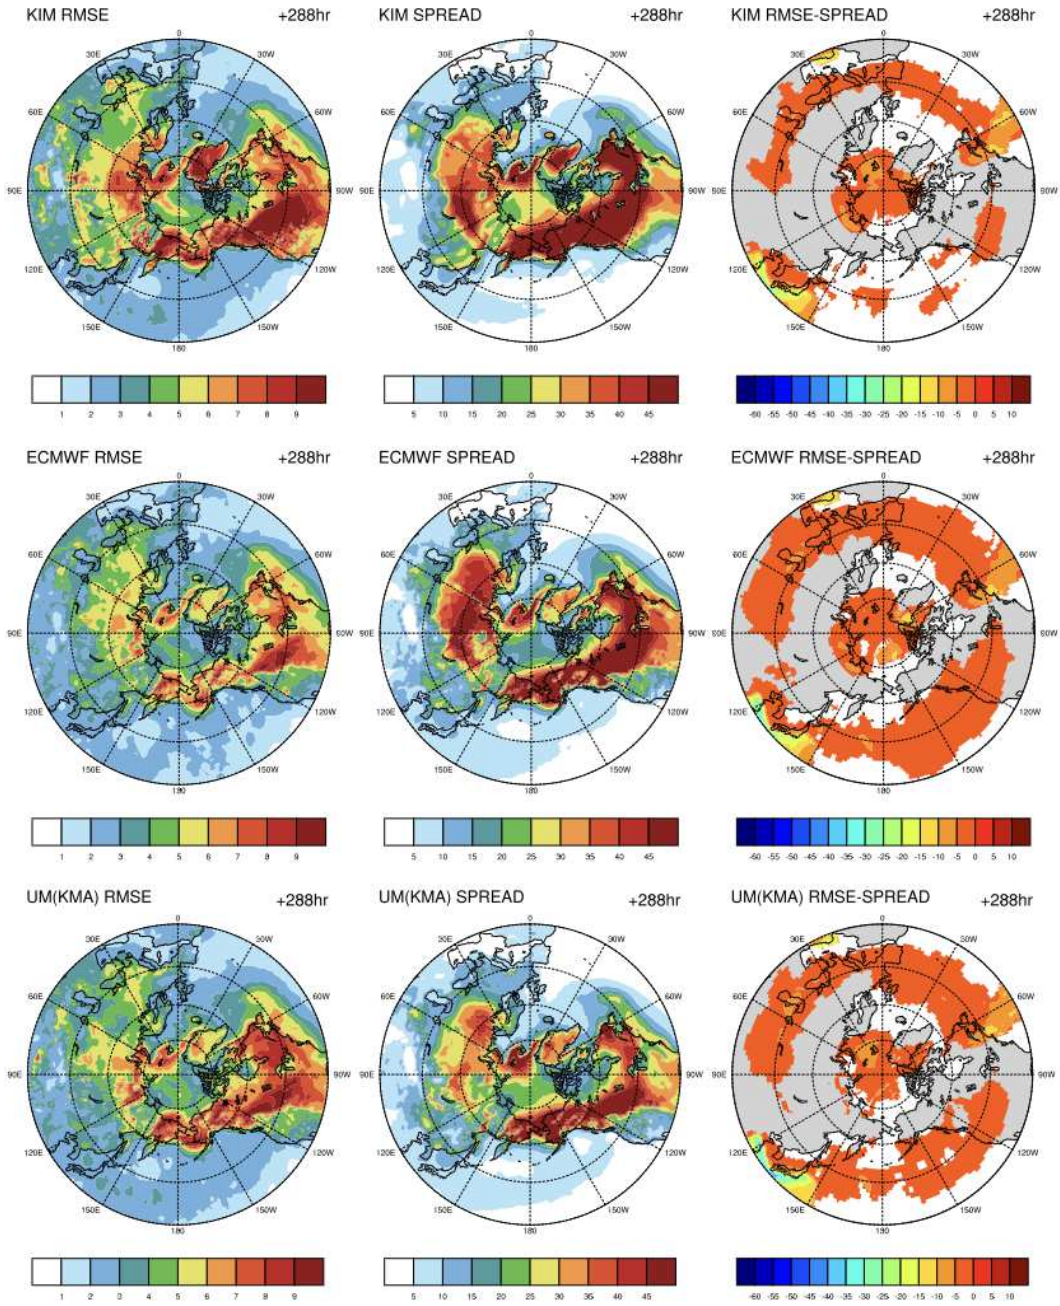
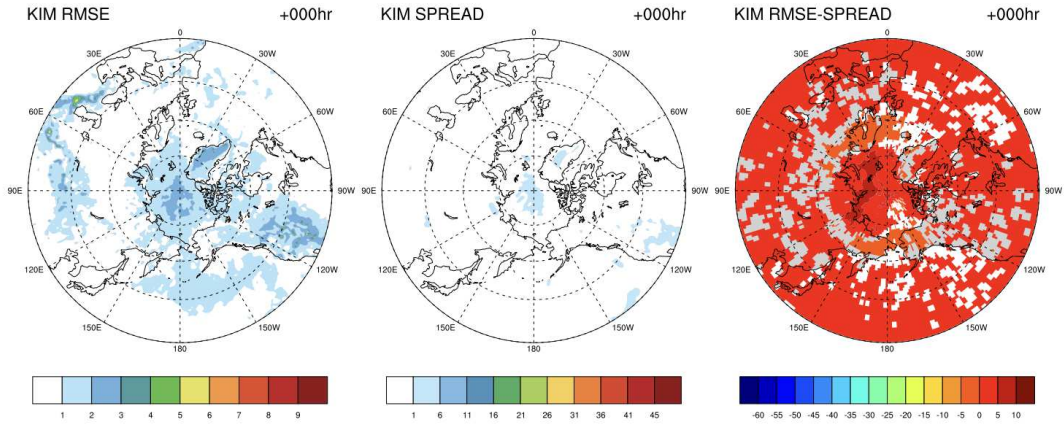


그림 1.1.67 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 12UTC T1000 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형 앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

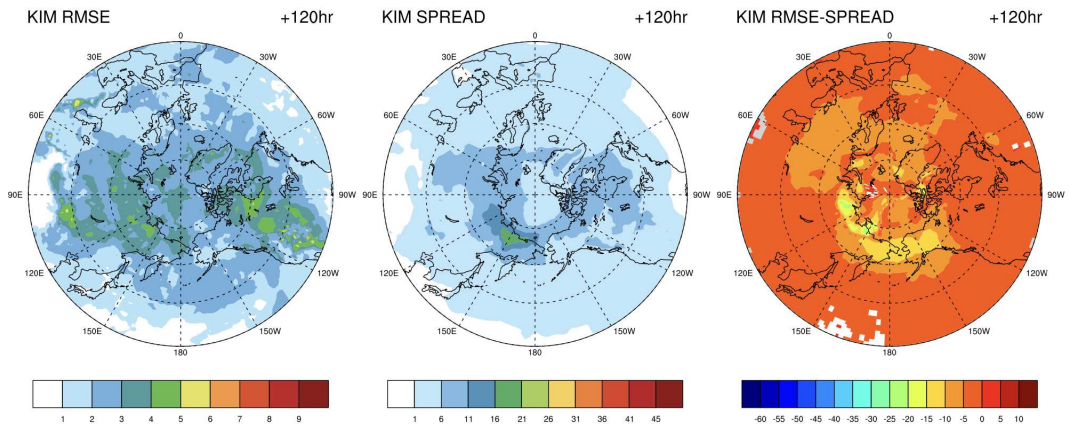
- 북반구 T1000 12UTC RMSE, Spread 분포 예측 성능을 살펴보면, 겨울철은 여름철과 달리 대륙에서의 RMSE 분포 차이는 다른 양상을 보이며, 특히 00UTC와 12UTC 차이가 다른 점이 모델의 구조적 오차가 있음을 의미한다. 앙상블 모델 대부분에서 나타나는 RMSE 양상은 북미 지역에서 두드러지게 나타남을 확인할 수 있다 (그림 1.1.67).

- 2021년 7월(여름철) 00, 12UTC T850 분석 결과

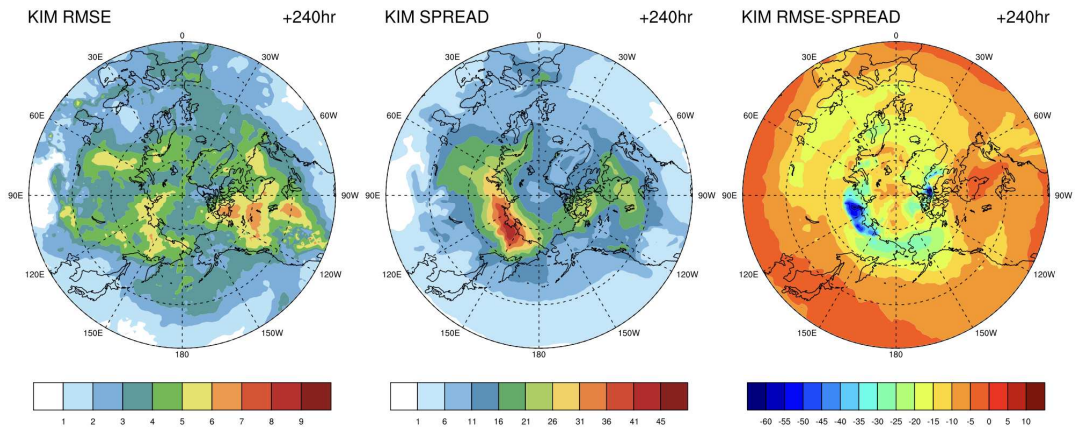
2021 JULY 00UTC T850 RMSE & SPREAD



2021 JULY 00UTC T850 RMSE & SPREAD



2021 JULY 00UTC T850 RMSE & SPREAD



2021 JULY 00UTC T850 RMSE & SPREAD

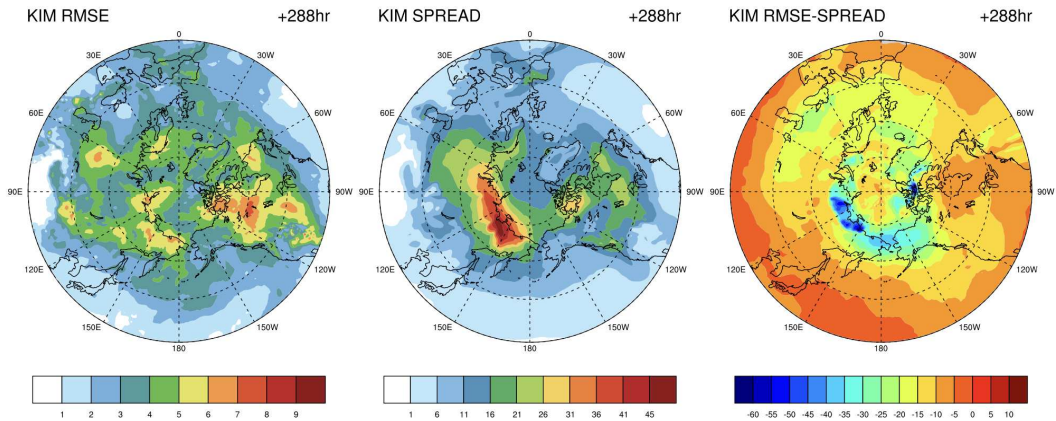
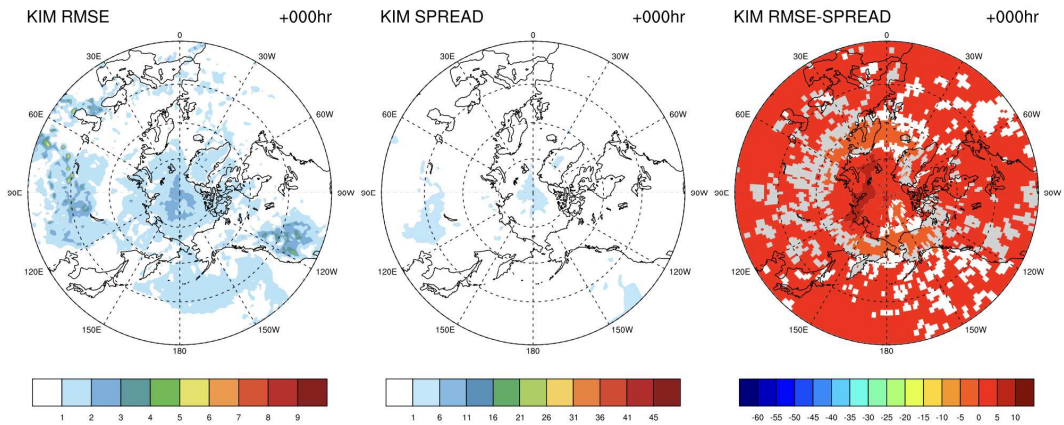


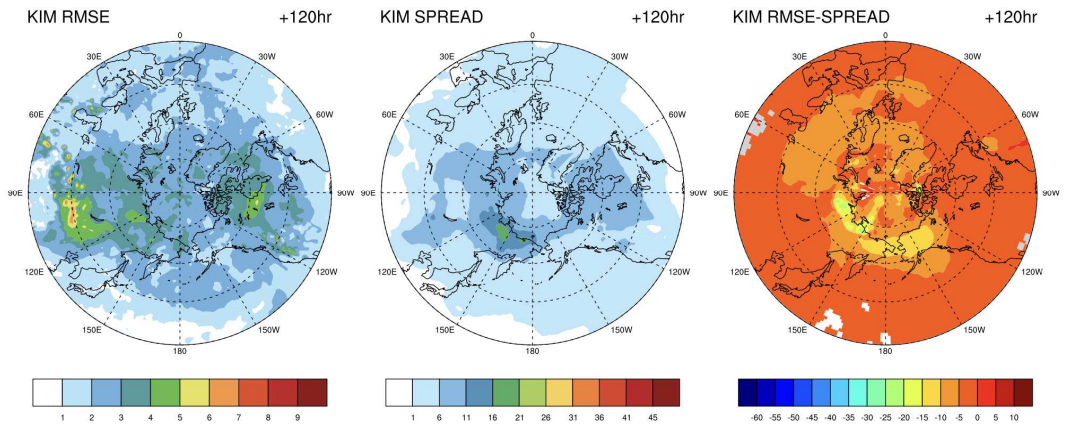
그림 1.1.68 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 00UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델 (KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 T850 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 한국형앙상블모델은 초기 분석장에서는 편차가 크지 않으나, Forecast Time이 증가할수록 음의 RMSE 패턴을 확인할 수 있으며 그 양상을 지표 온도에 비해서 크지 않음을 확인할 수 있다. 이를 통해 한국형앙상블모델의 상층 지표는 안정적인 예측 성능을 보임을 확인할 수 있다 (그림 1.1.68).

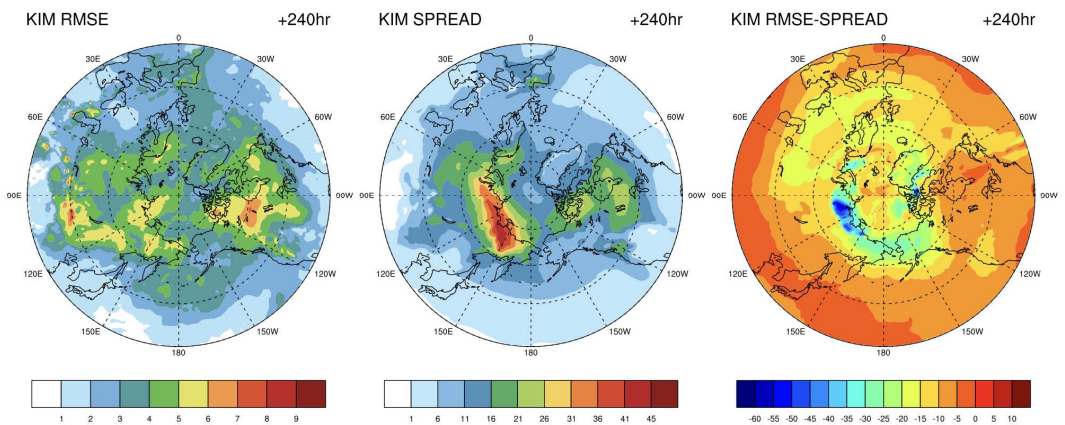
2021 JULY 12UTC T850 RMSE & SPREAD



2021 JULY 12UTC T850 RMSE & SPREAD



2021 JULY 12UTC T850 RMSE & SPREAD



2021 JULY 12UTC T850 RMSE & SPREAD

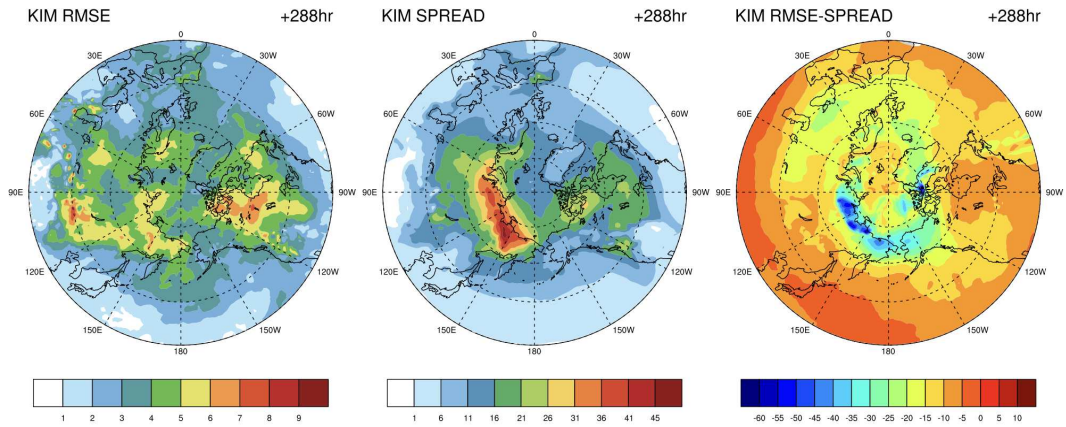
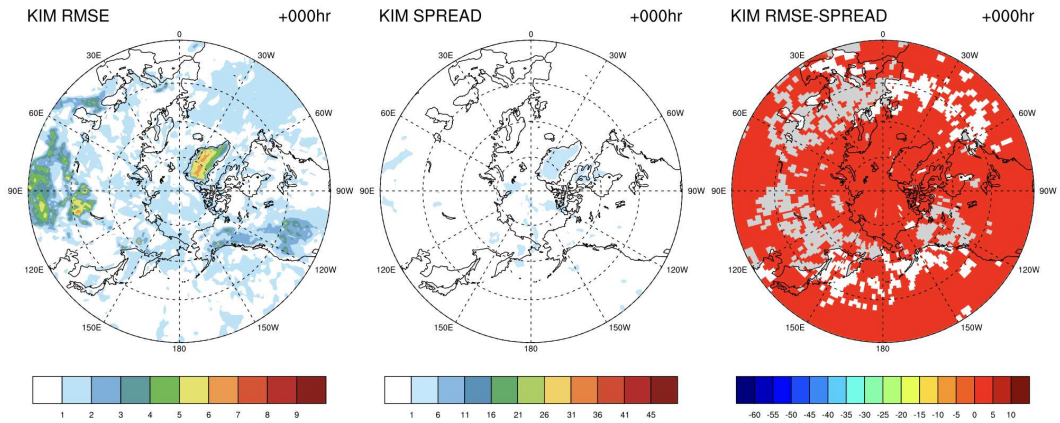


그림 1.1.69 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 12UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델 (KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

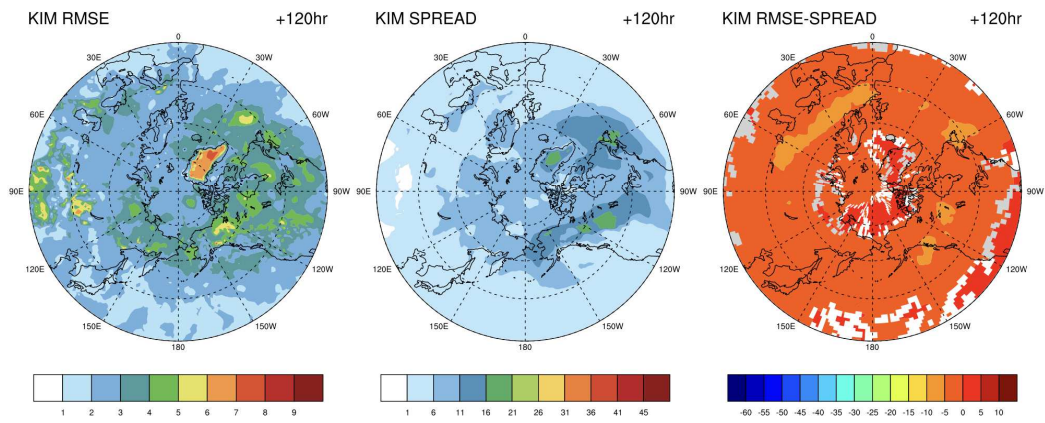
- 북반구 T850 12UTC RMSE, Spread 분포 예측 성능을 살펴보면, 앞선 00UTC와 유사한 RMSE와 Spread 분포를 살펴볼 수 있다. RMSE는 대부분 고위도 지역에서 큰 차이를 보이며, Spread 는 유라시아 대륙에서 산포가 큰 패턴을 보임을알 수 있다 (그림 1.1.69).

- 2022년 1월(겨울철) 00, 12UTC T850 분석 결과

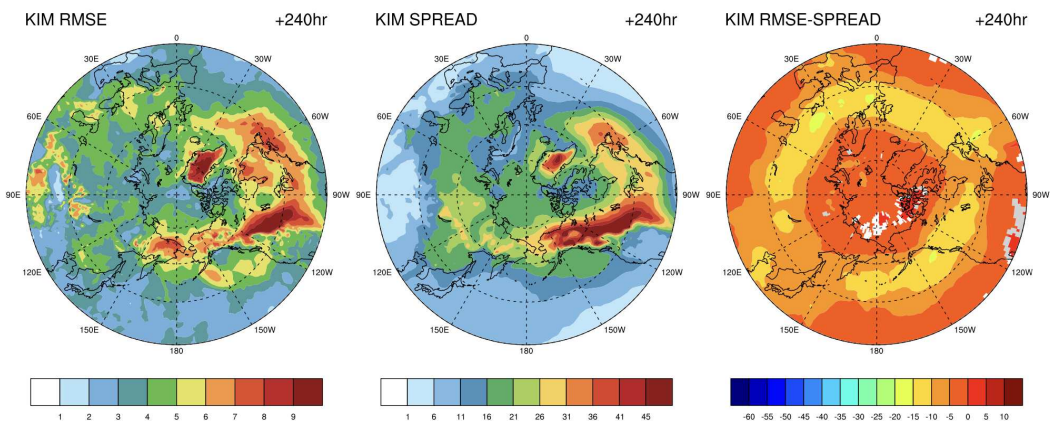
2022 JANUARY 00UTC T850 RMSE & SPREAD



2022 JANUARY 00UTC T850 RMSE & SPREAD



2022 JANUARY 00UTC T850 RMSE & SPREAD



2022 JANUARY 00UTC T850 RMSE & SPREAD

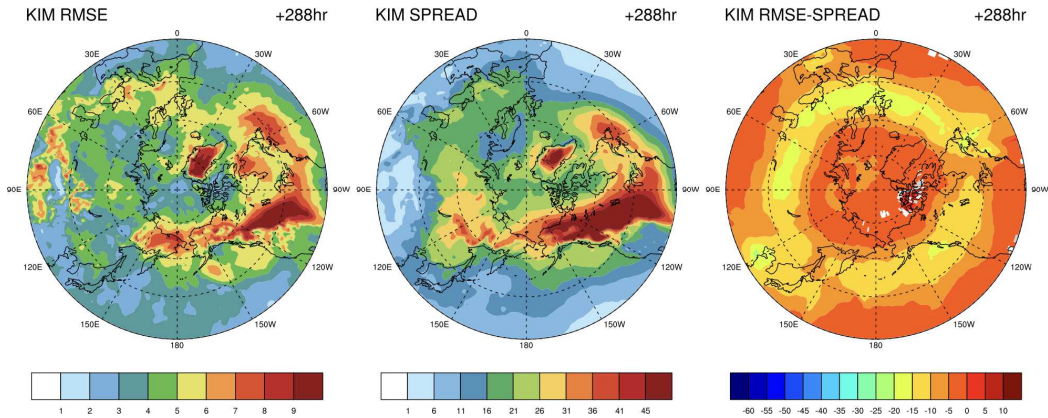
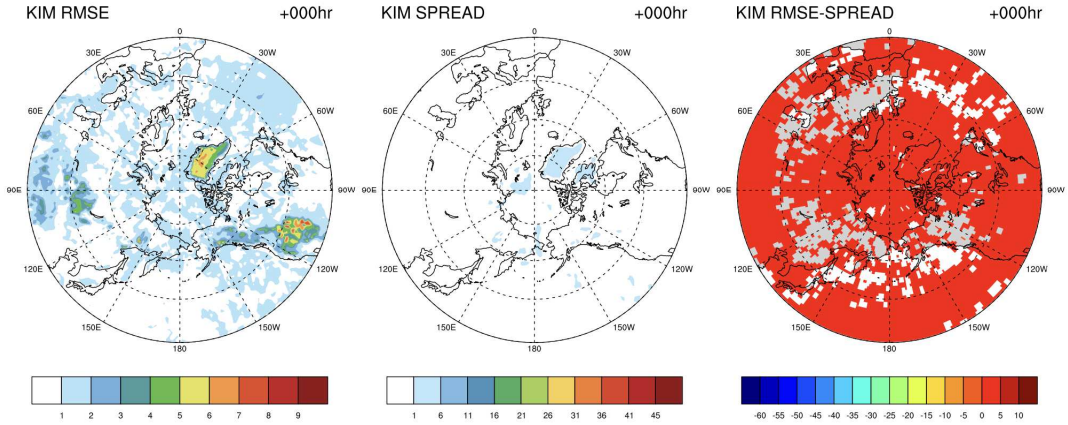


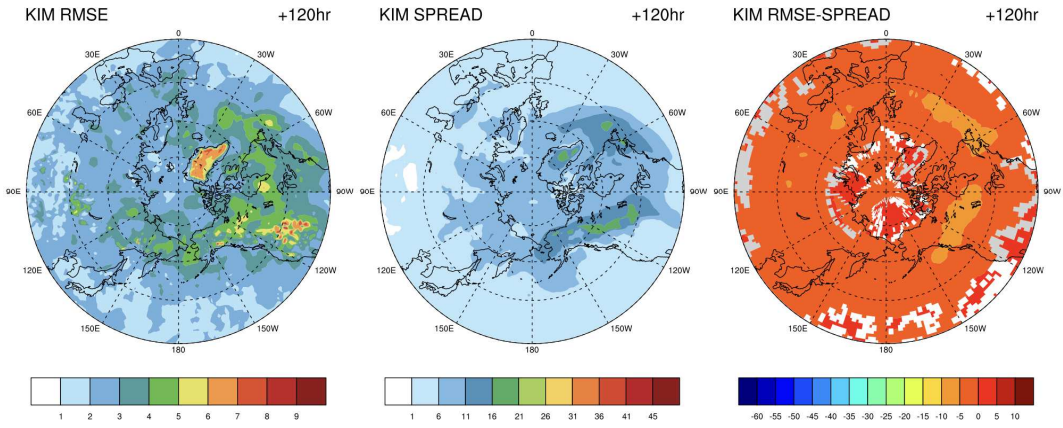
그림 1.1.70 양상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 00UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형양상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 T850 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 겨울철의 경우 여름철에 비해 북반구 대륙 중 특히 북미 지역에서 큰 차이가 나타남을 확인할 수 있으며, 이는 RMSE 뿐만 아니라, Spread 에서도 비슷한 패턴을 보임을 확인할 수 있다 (그림 1.1.70).

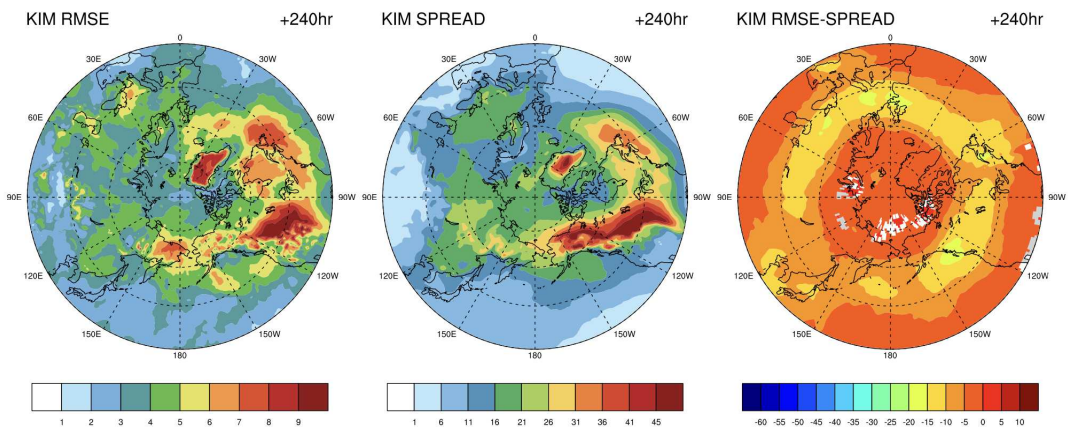
2022 JANUARY 12UTC T850 RMSE & SPREAD



2022 JANUARY 12UTC T850 RMSE & SPREAD



2022 JANUARY 12UTC T850 RMSE & SPREAD



2022 JANUARY 12UTC T850 RMSE & SPREAD

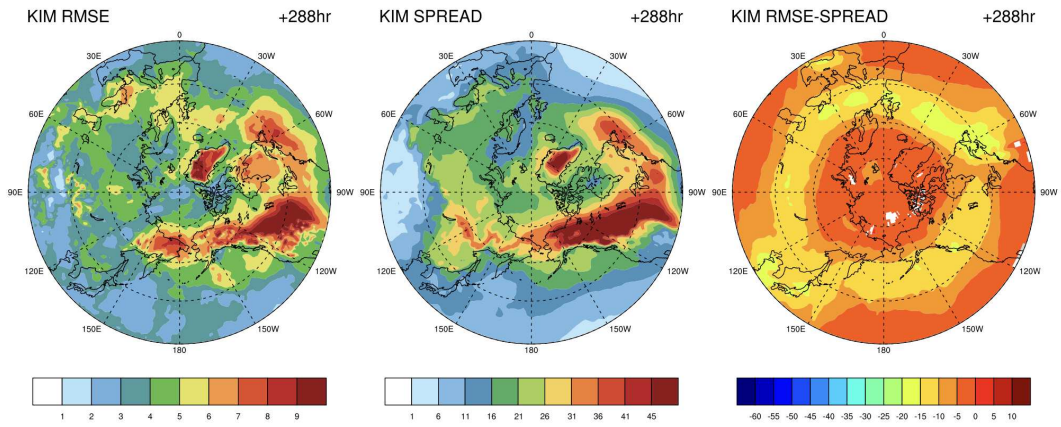
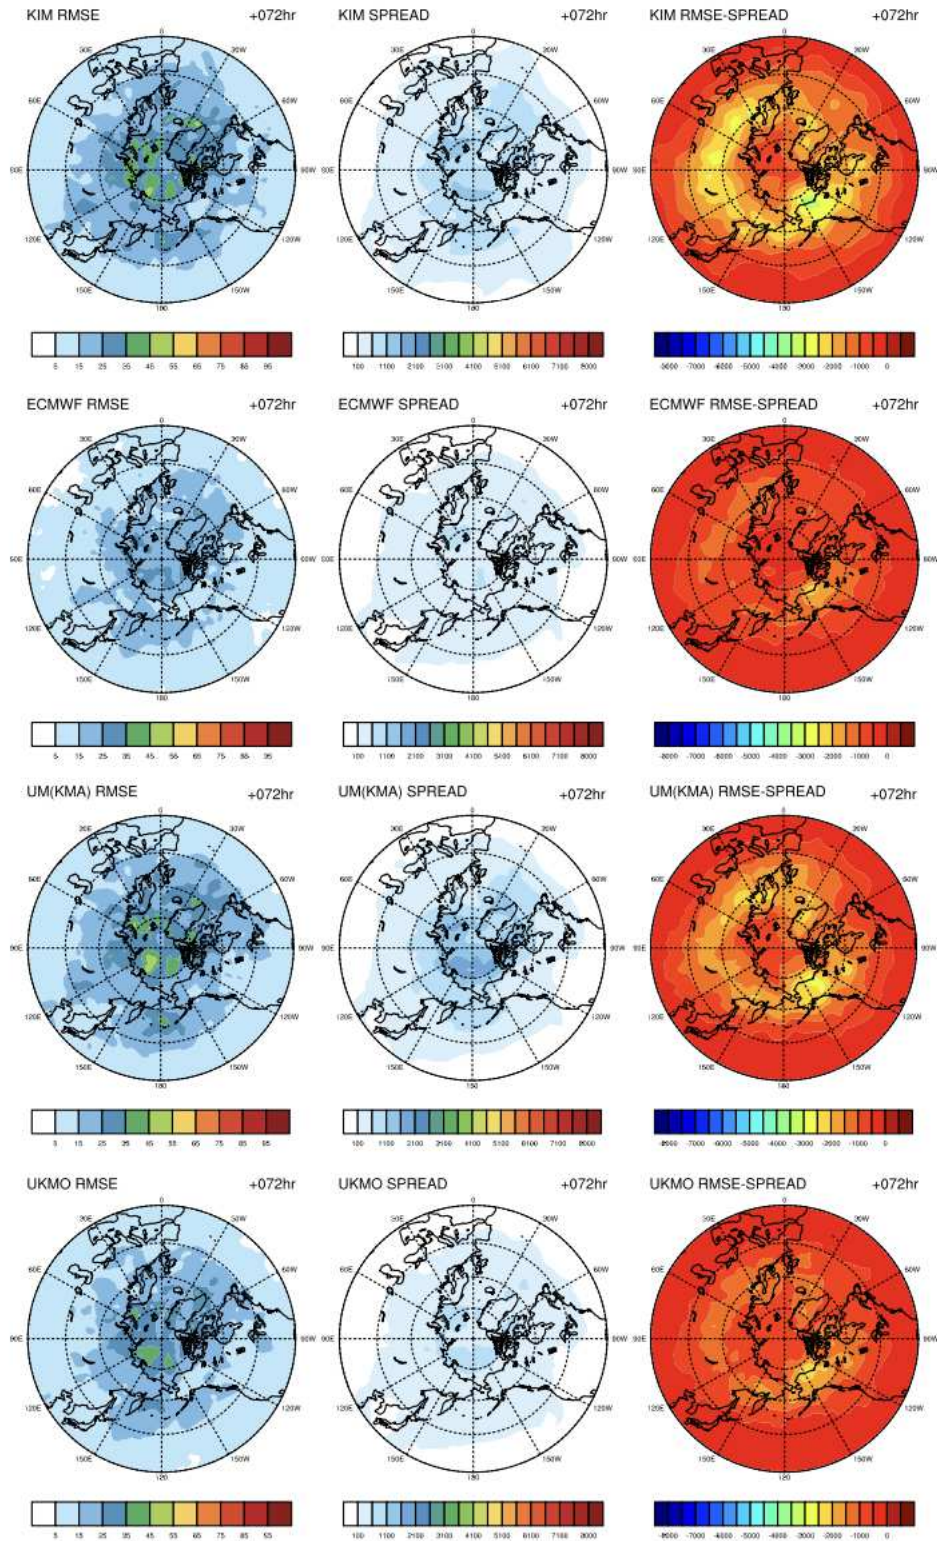


그림 1.1.71 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 12UTC T850 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형 앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

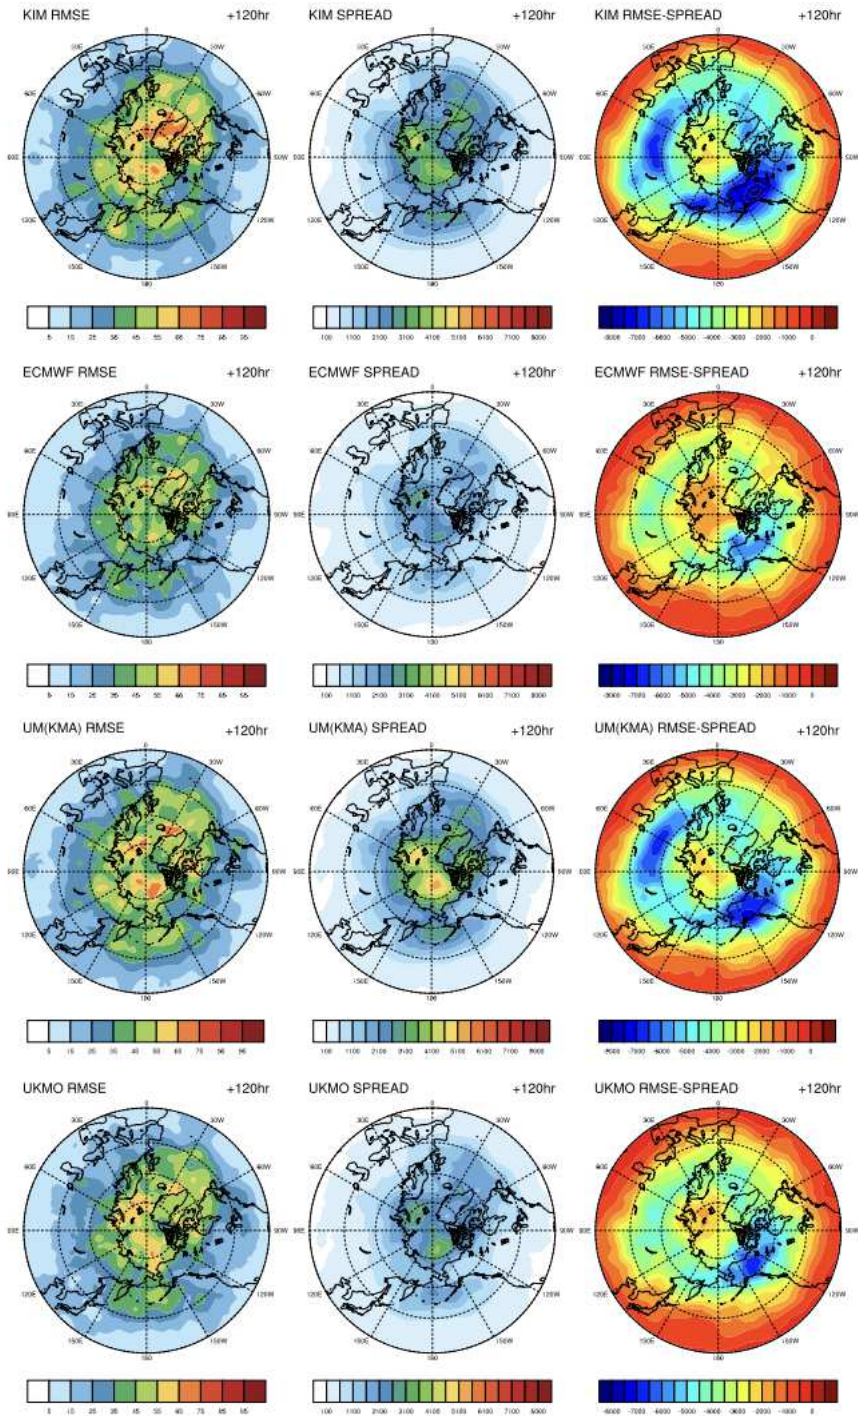
- 북반구 T850 12UTC RMSE, Spread 분포 예측 성능을 살펴보면, 겨울철의 경우 여름철에 비해 북반구 대륙 중 특히 북미 지역에서 큰 차이가 나타남을 확인할 수 있으며, 이는 RMSE 뿐만 아니라, Spread 에서도 비슷한 패턴을 보임을 확인할 수 있다 (그림 1.1.71).

- 2021년 7월(여름철) 00, 12UTC Z500 분석 결과

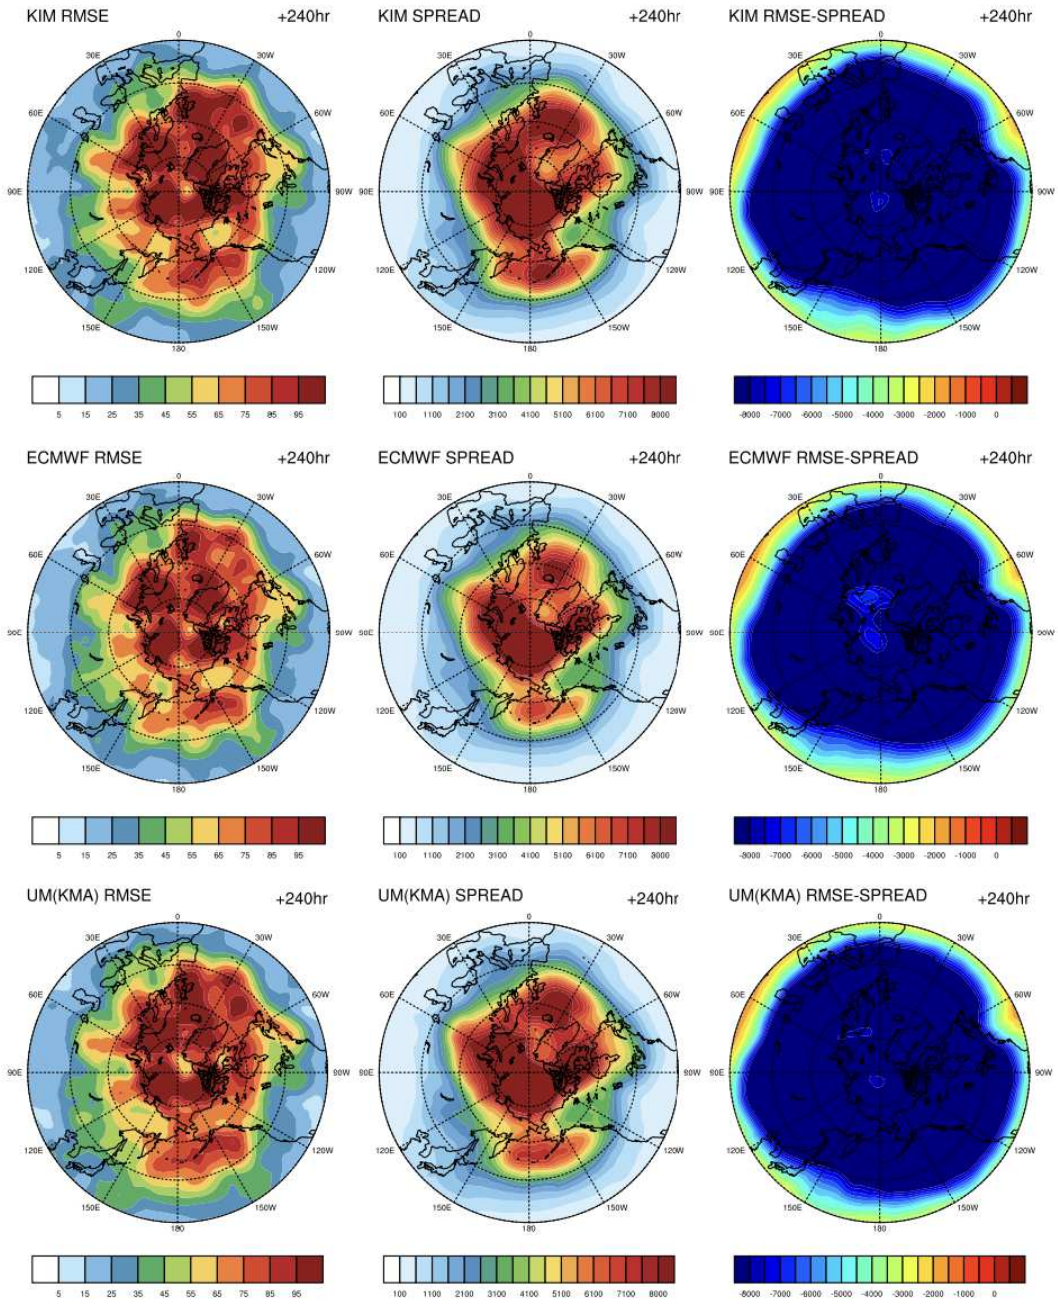
2021 JULY 00UTC Z500 RMSE & SPREAD



2021 JULY 00UTC Z500 RMSE & SPREAD



2021 JULY 00UTC Z500 RMSE & SPREAD



2021 JULY 00UTC Z500 RMSE & SPREAD

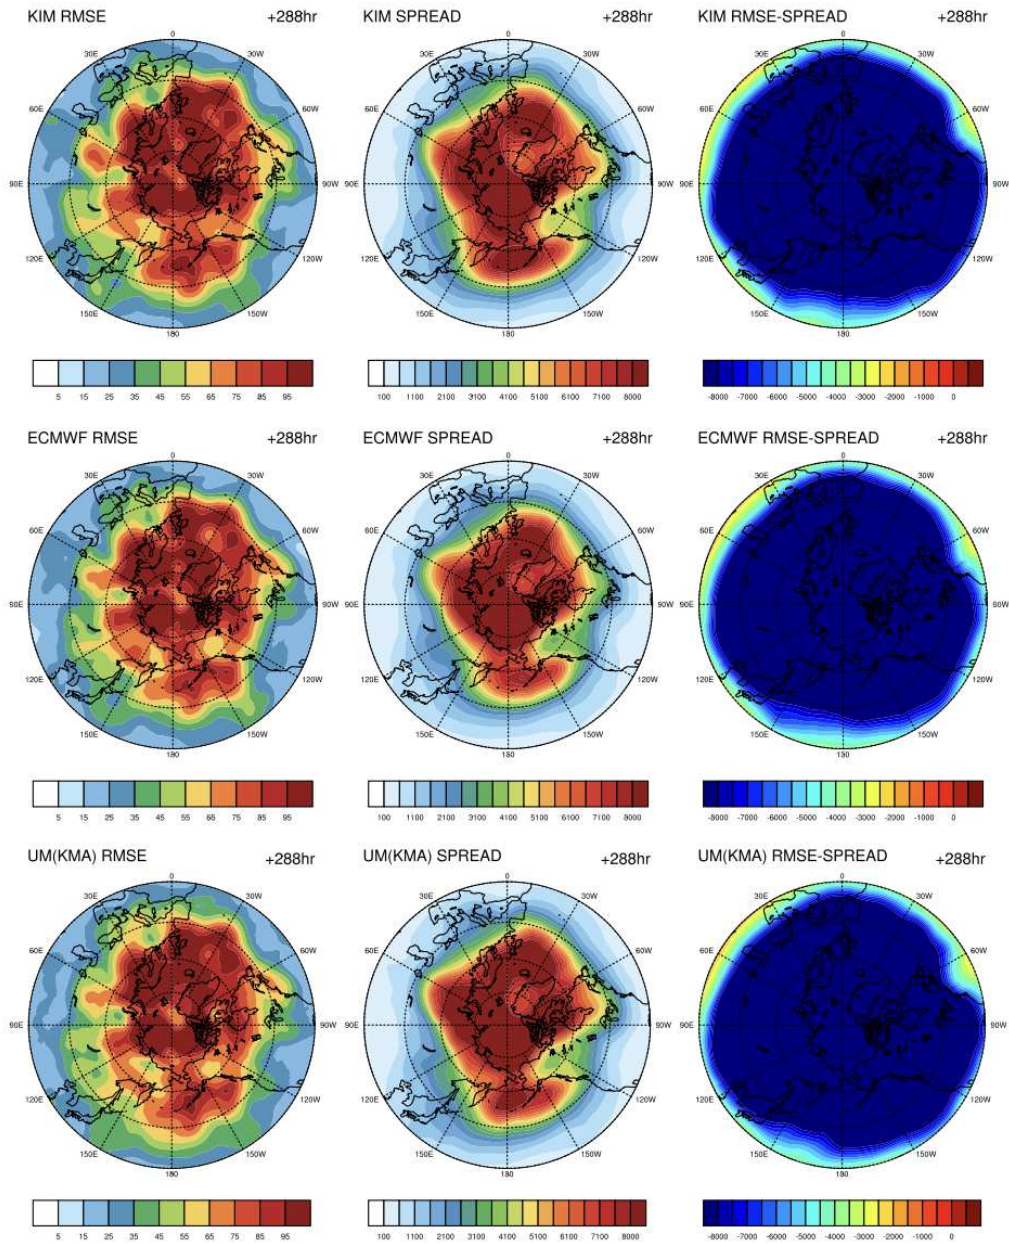
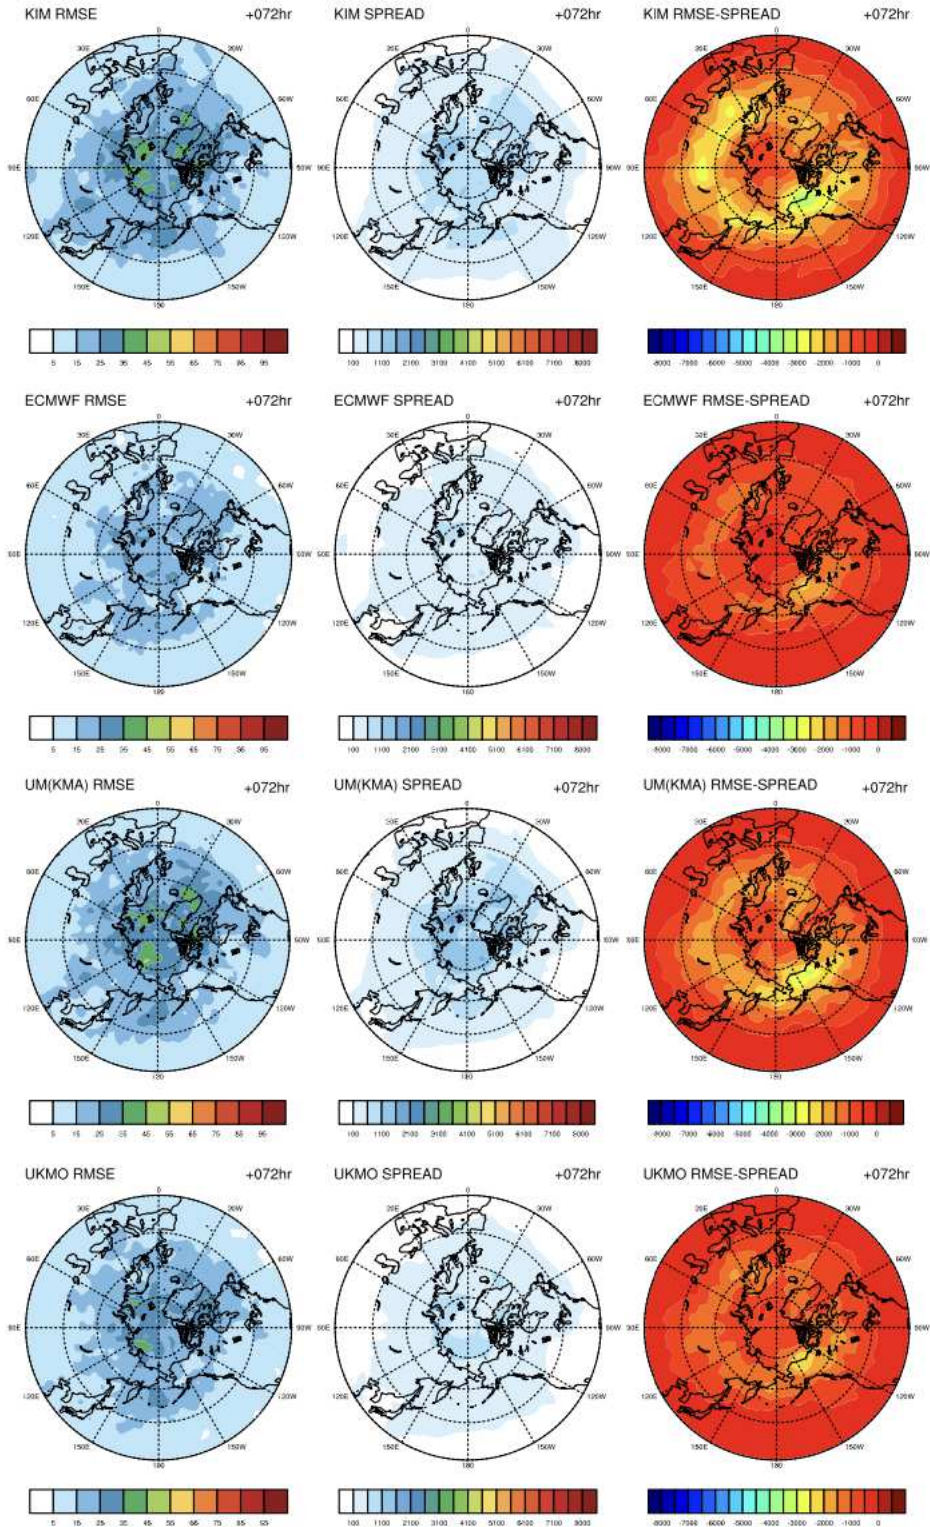


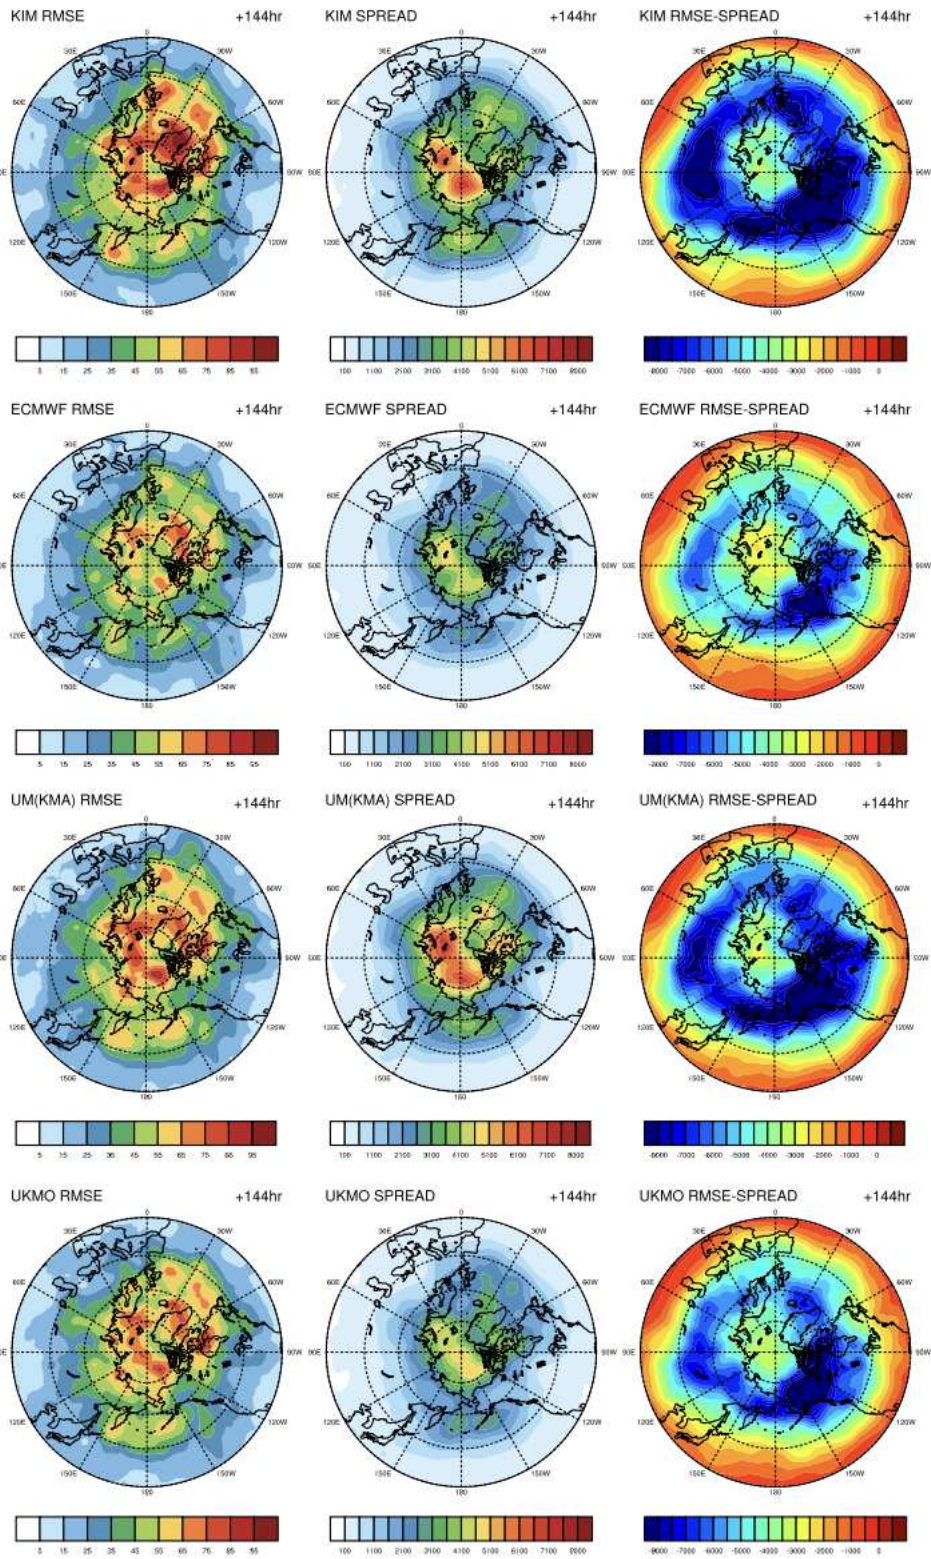
그림 1.1.72 양상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 00UTC Z500 (위-아래: Forecast Time 00, 120, 240, 288hr, 오른쪽-왼쪽: 한국형양상블모델 (KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 Z500 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 북반구 고위도 지역에서 대부분 RMSE가 크게 나타남을 확인할 수 있다. 특히 북극에서의 차이가 매우 크게 나타남을 확인할 수 있다 (그림 1.1.72).

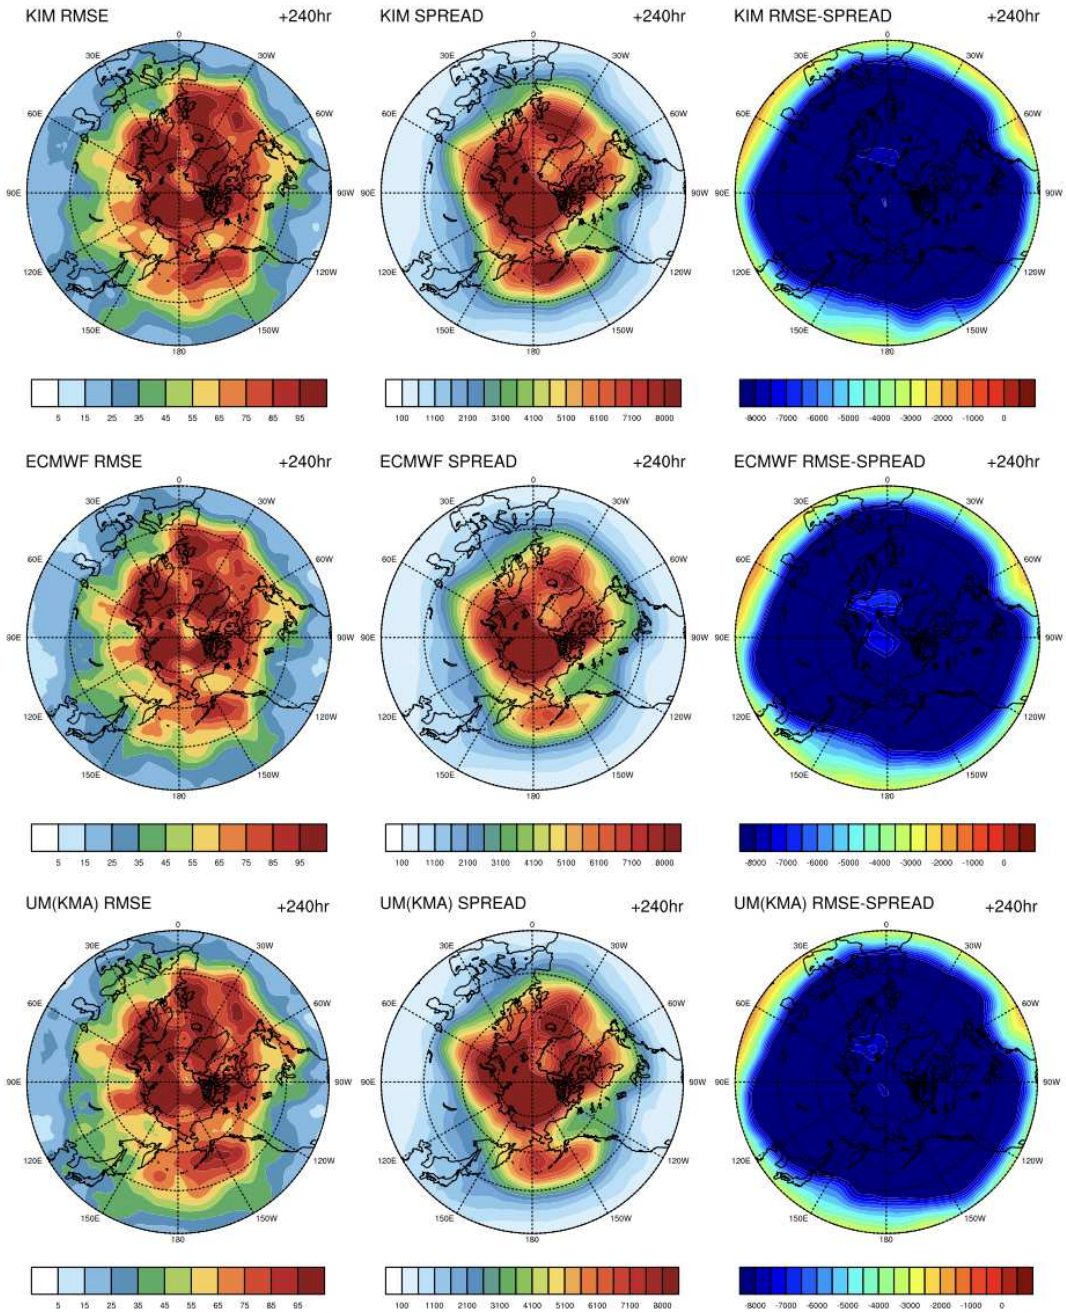
2021 JULY 12UTC Z500 RMSE & SPREAD



2021 JULY 12UTC Z500 RMSE & SPREAD



2021 JULY 12UTC Z500 RMSE & SPREAD



2021 JULY 12UTC Z500 RMSE & SPREAD

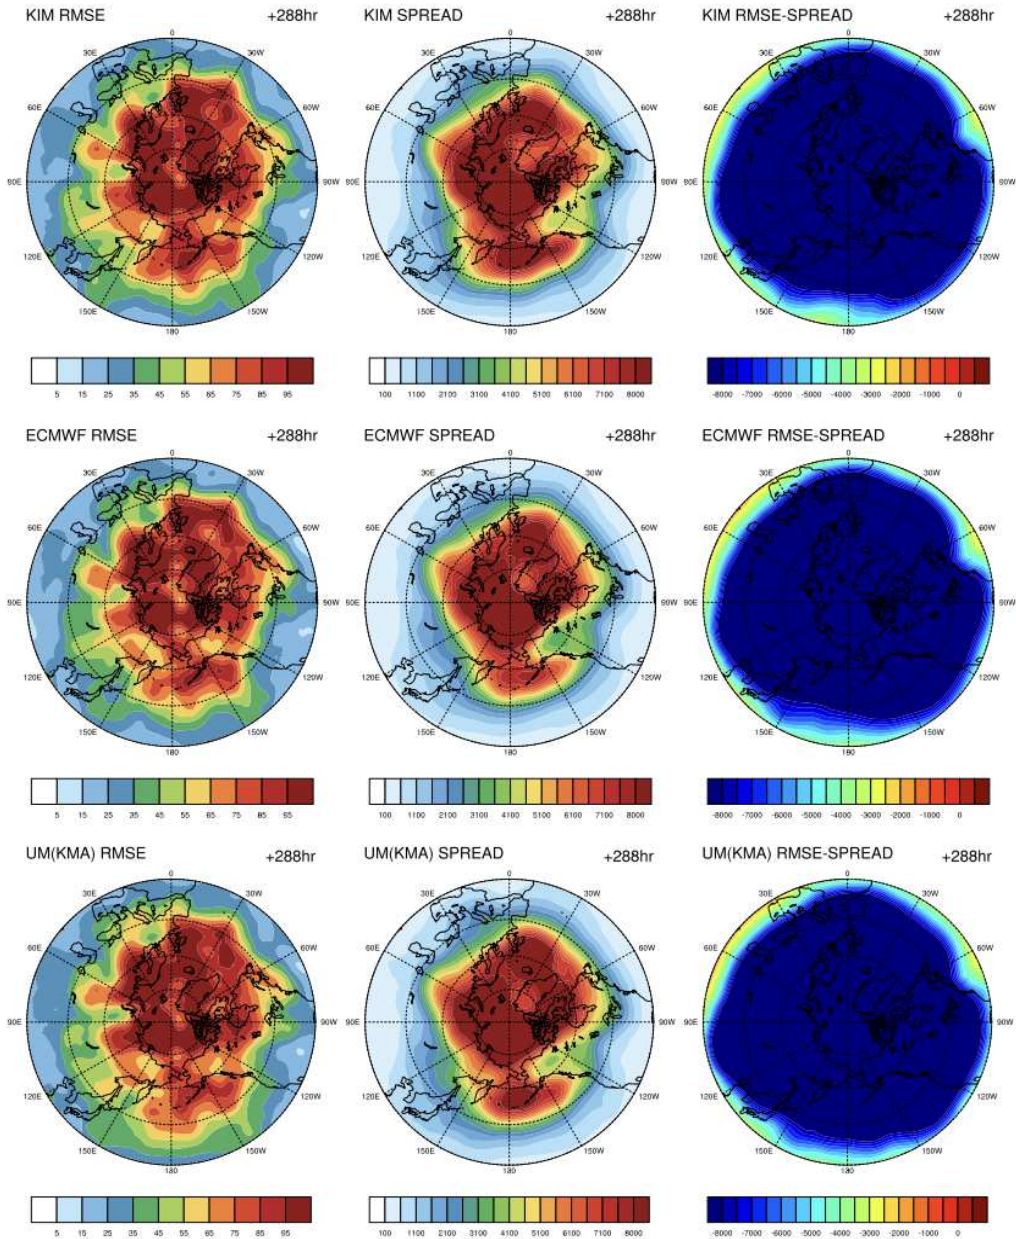
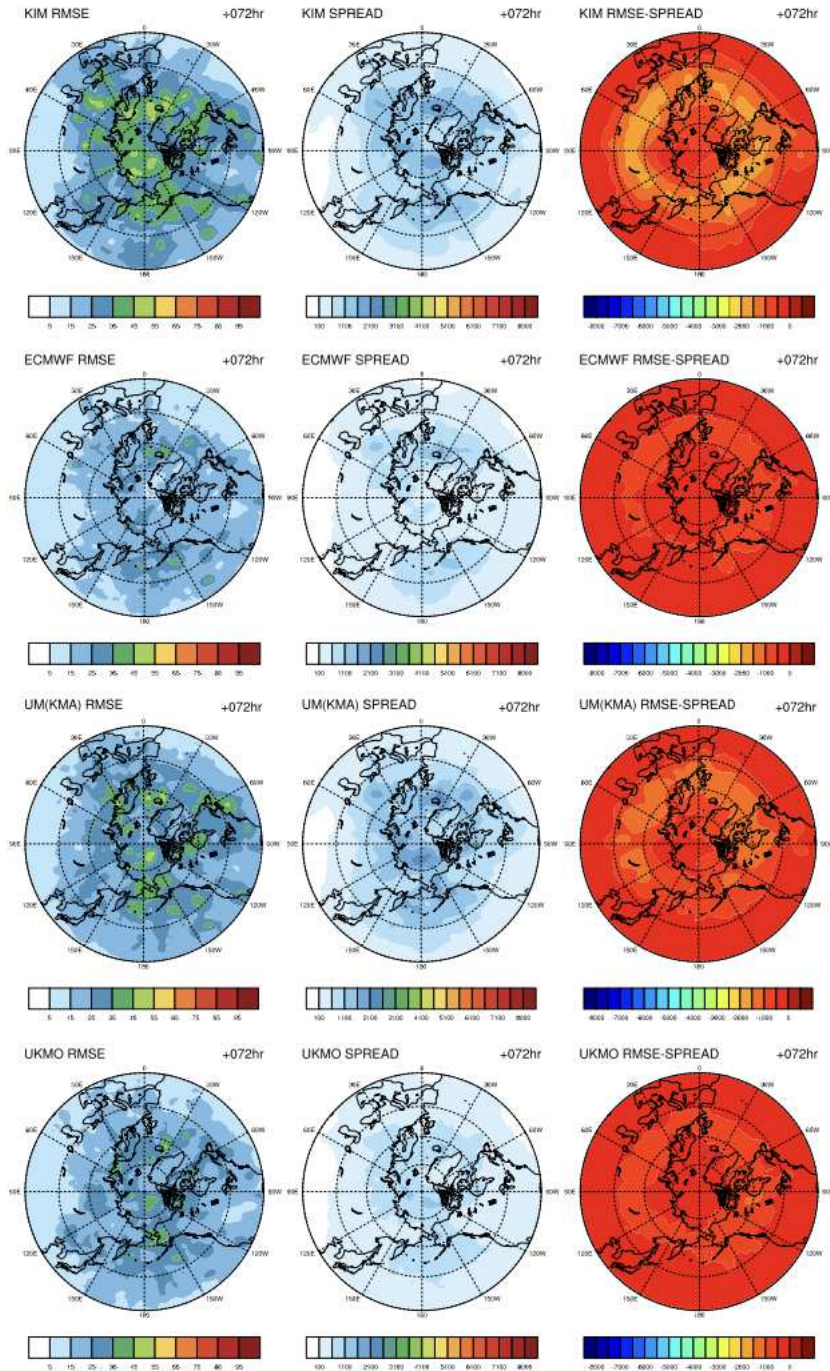


그림 1.1.73 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2021 JULY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: KIM, ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

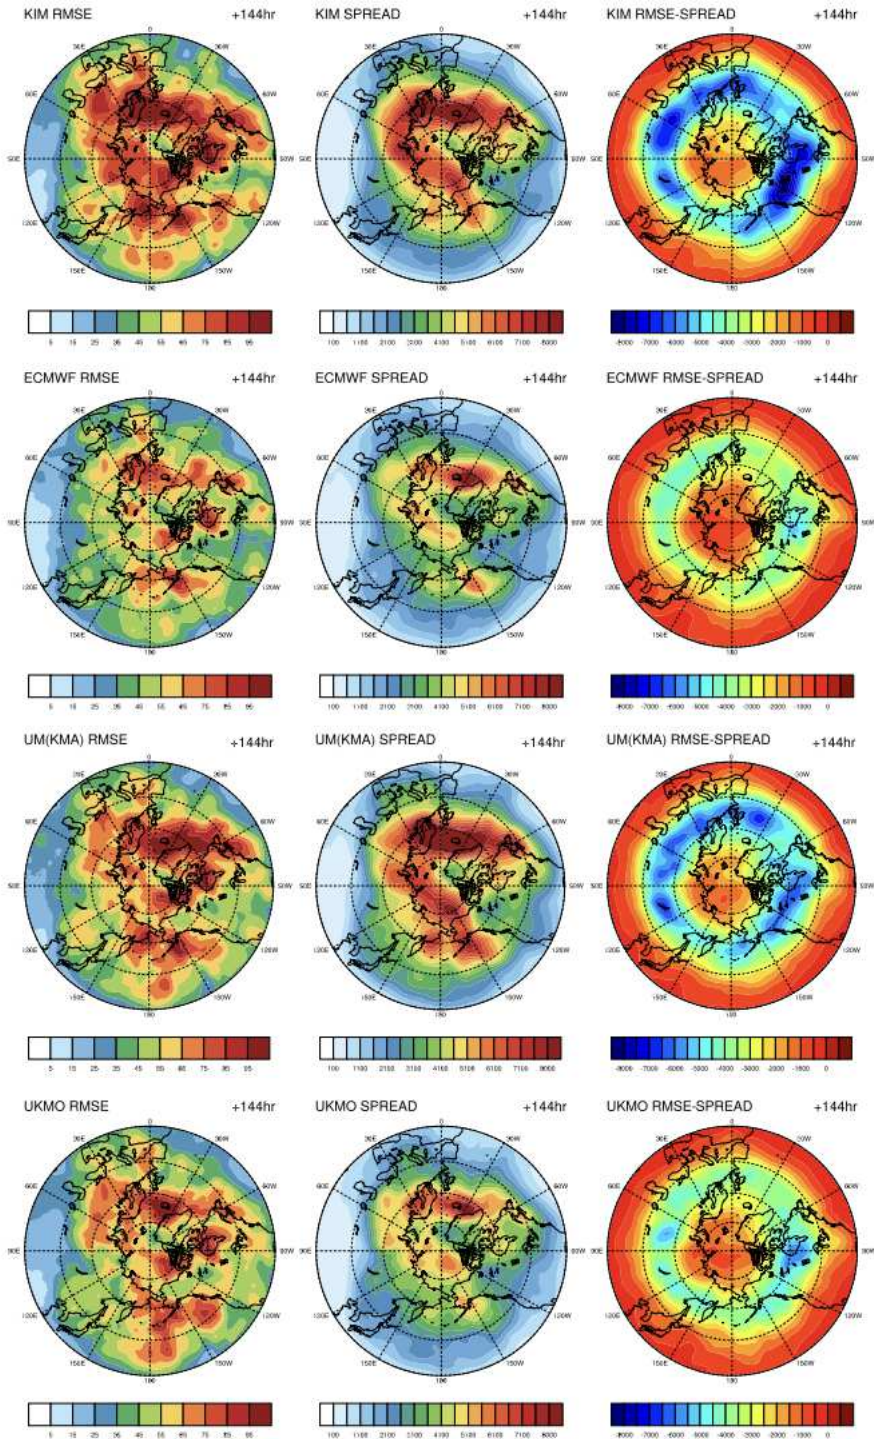
- 북반구 Z500 12UTC RMSE, Spread 분포 예측 성능을 살펴보면, 북반구 고위도 지역에서 대부분 RMSE가 크게 나타남을 확인할 수 있다. 특히 북극에서의 차이가 매우 크게 나타남을 확인할 수 있다 (그림 1.1.73).

- 2022년 1월(겨울철) 00, 12UTC Z500 분석 결과

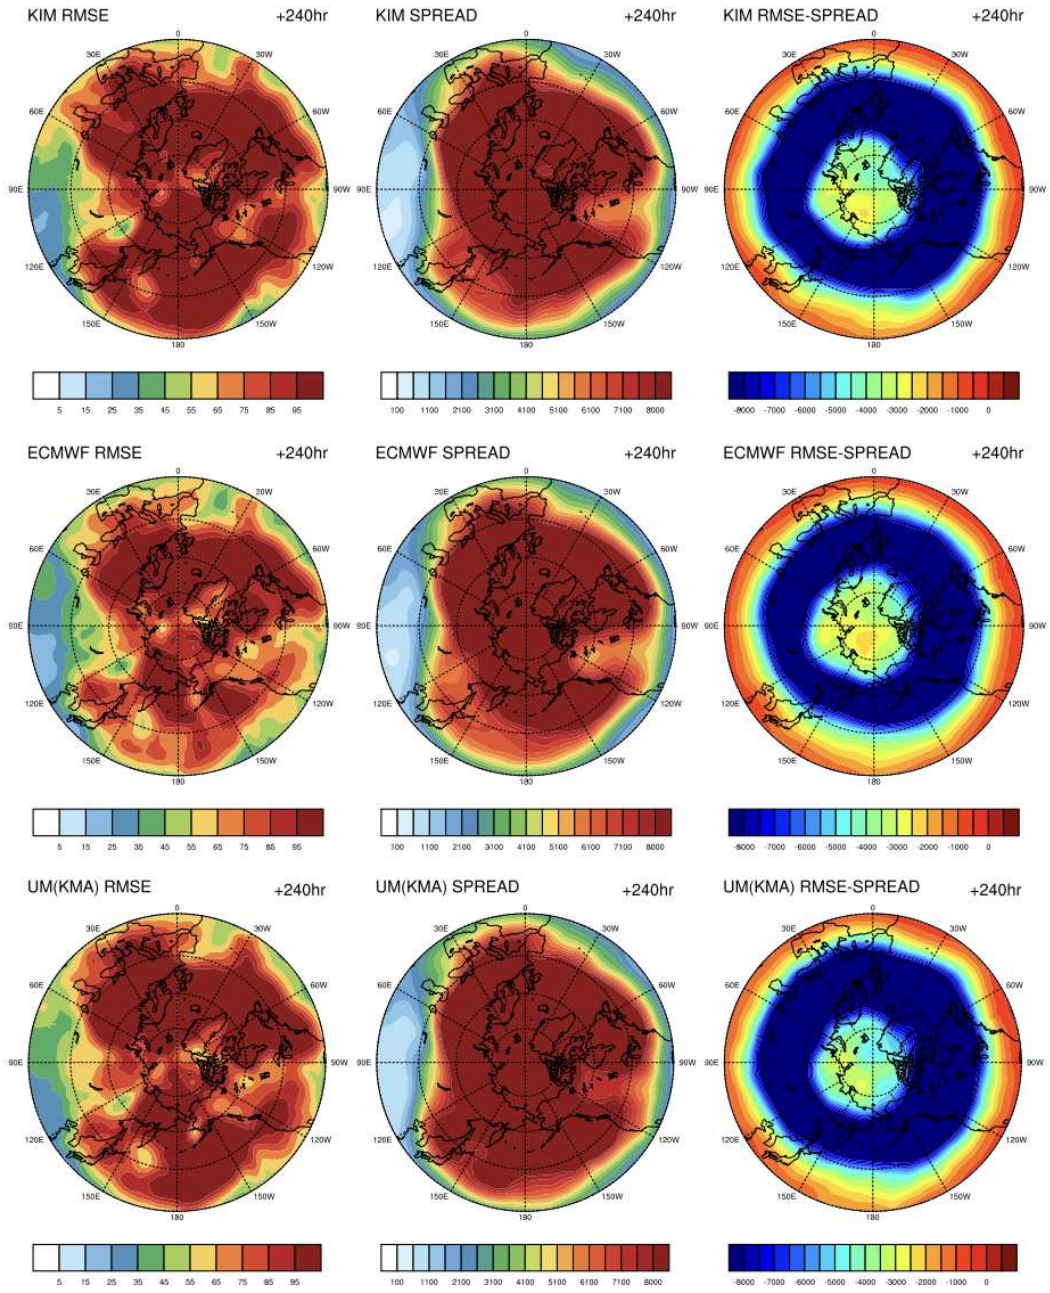
2022 JANUARY 00UTC Z500 RMSE & SPREAD



2022 JANUARY 00UTC Z500 RMSE & SPREAD



2022 JANUARY 00UTC Z500 RMSE & SPREAD



2022 JANUARY 00UTC Z500 RMSE & SPREAD

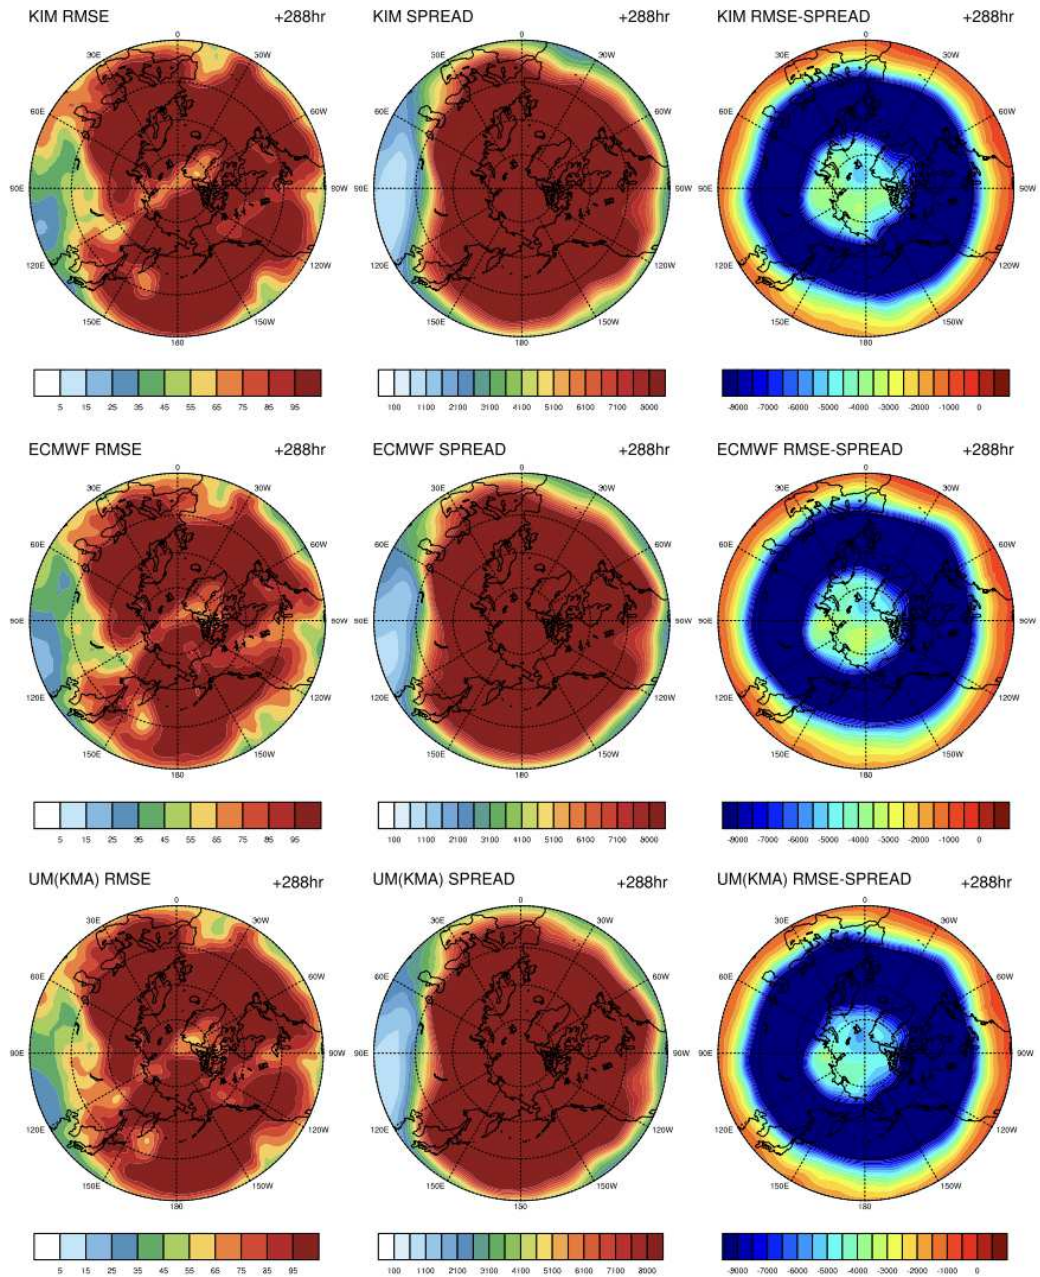
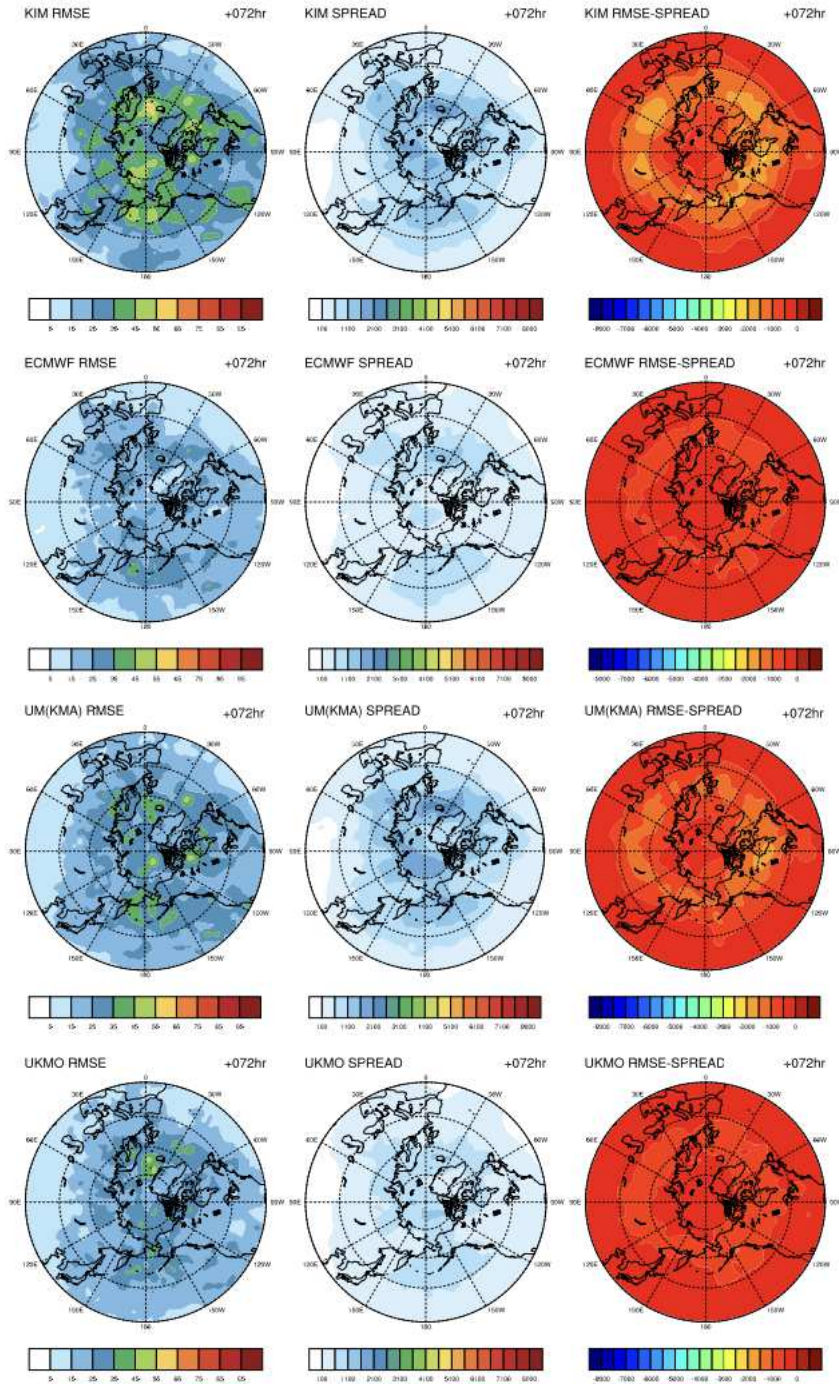


그림 1.1.74 양상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 00UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형양상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

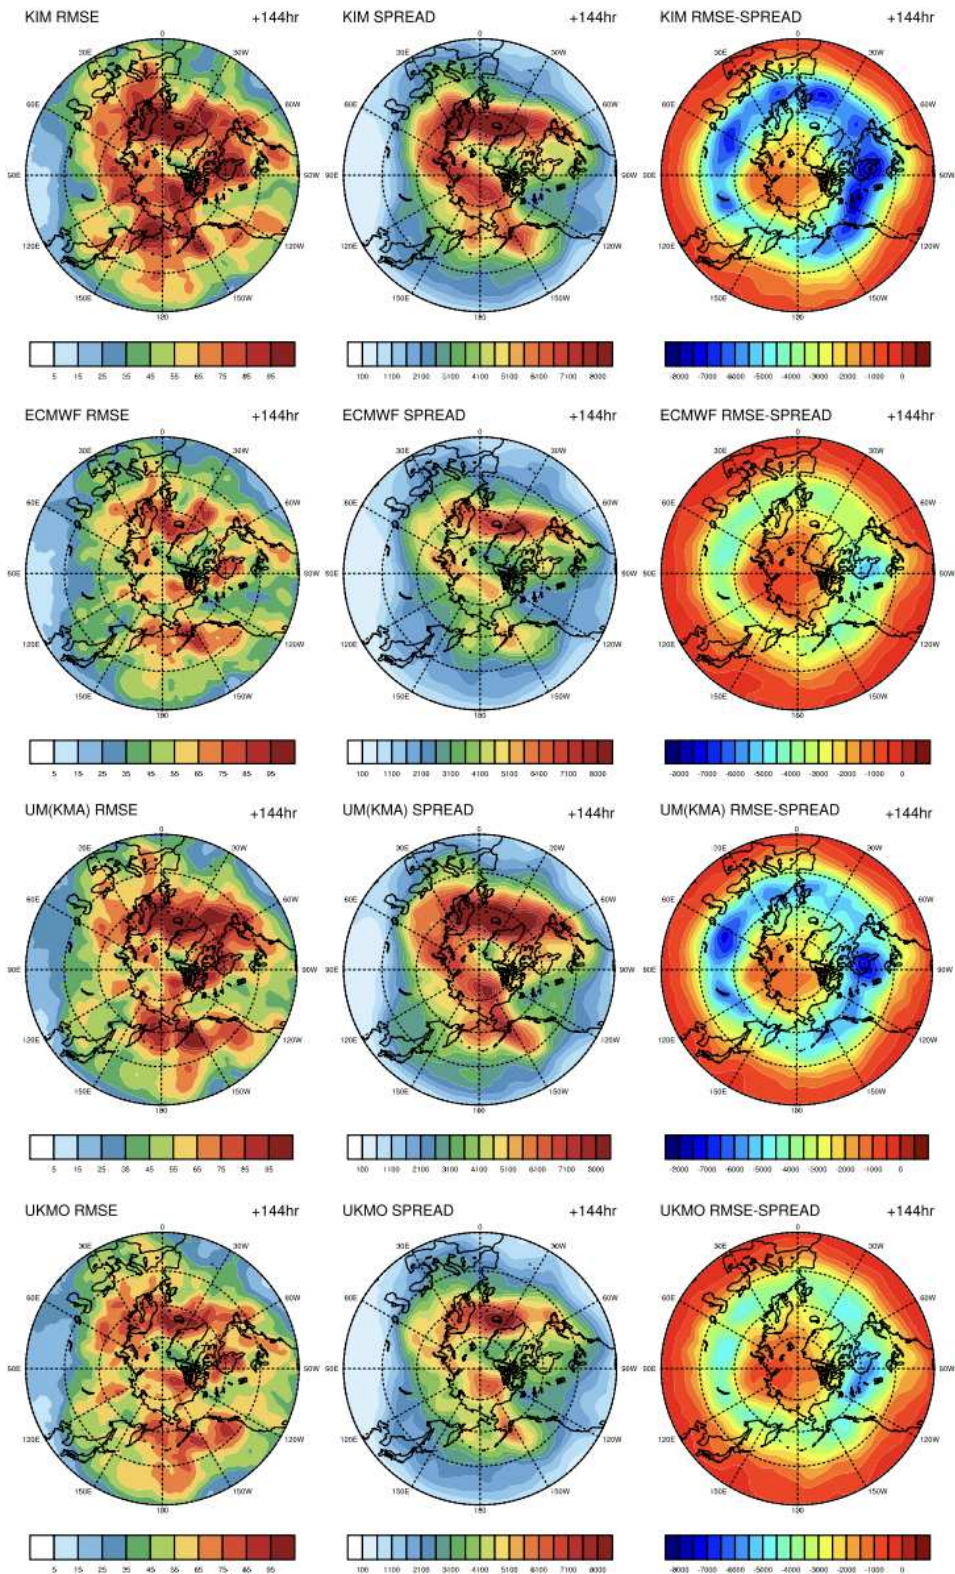
- 북반구 Z500 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 북반구 고위도 지역에서 대부분 RMSE가 크게 나타남을 확인할 수 있다. 특히

북극에서의 차이가 매우 크게 나타남을 확인할 수 있다 (그림 1.1.74).

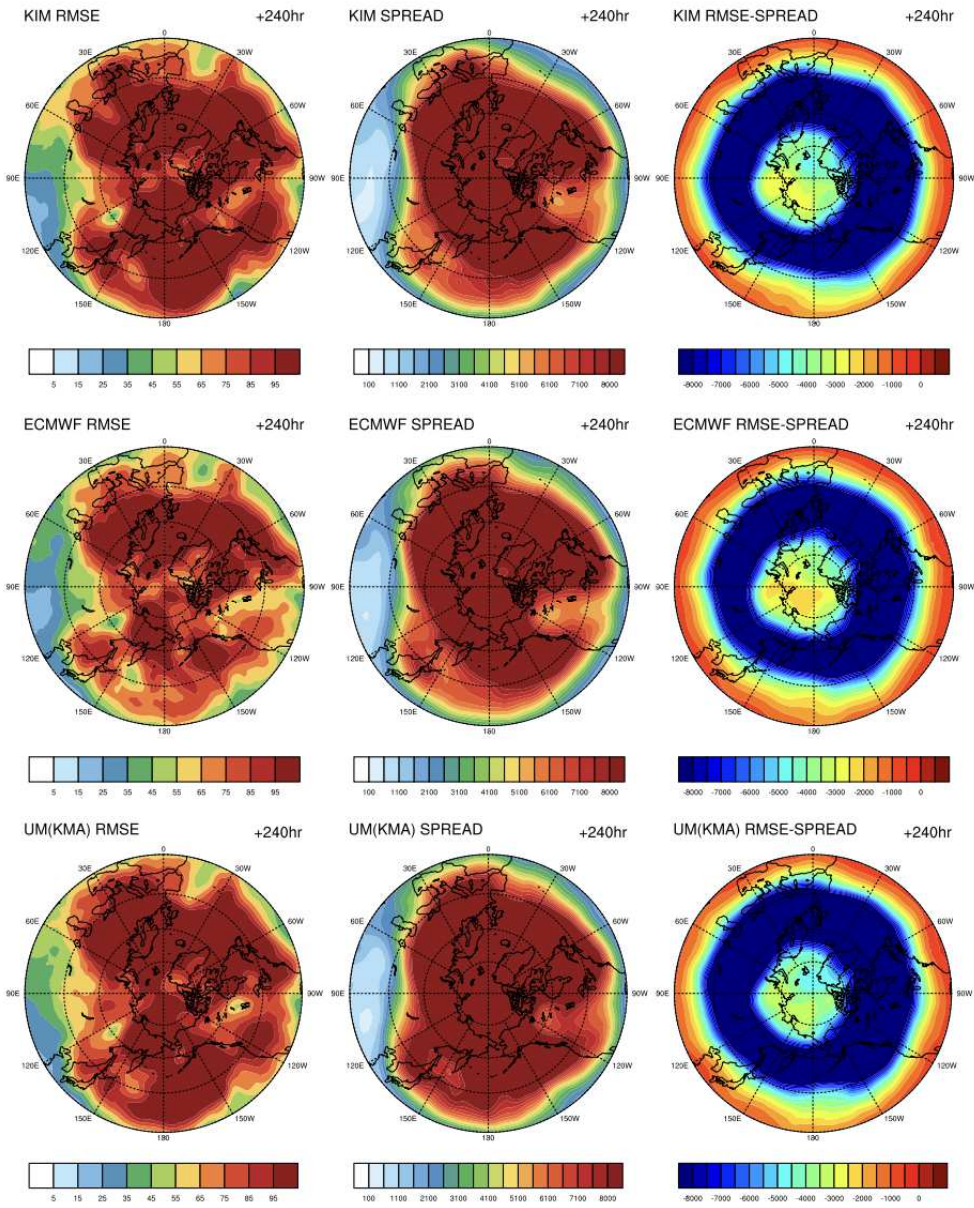
2022 JANUARY 12UTC Z500 RMSE & SPREAD



2022 JANUARY 12UTC Z500 RMSE & SPREAD



2022 JANUARY 12UTC Z500 RMSE & SPREAD



2022 JANUARY 12UTC Z500 RMSE & SPREAD

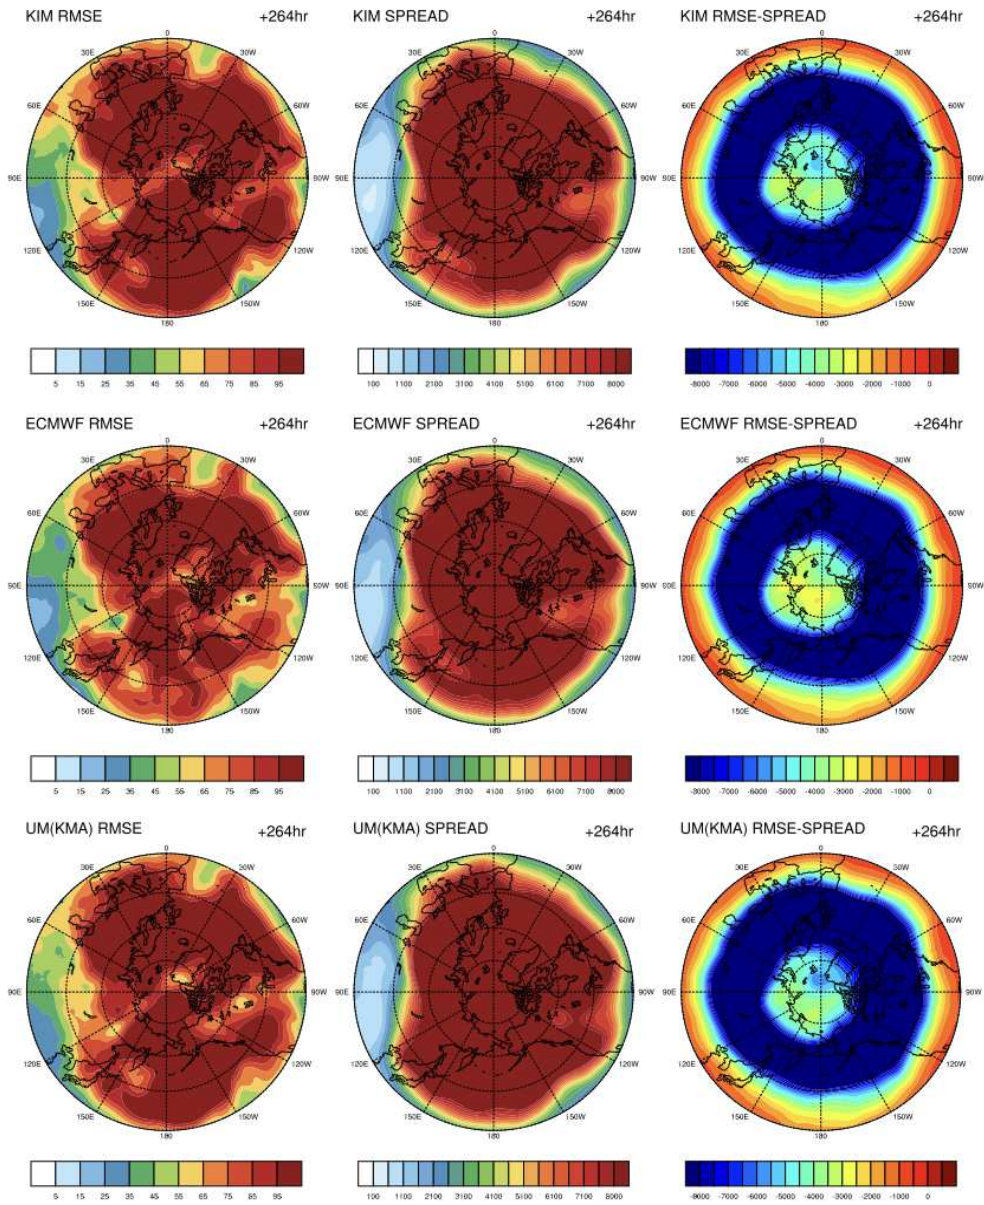



그림 1.1.75 앙상블 평균 RMSE, Spread, RMSE-Spread 분포 예측성 진단 평가: 2022 JANUARY 12UTC Z500 (위-아래: Forecast Time 000, 120, 240, 288hr, 오른쪽-왼쪽: 한국형앙상블모델(KIM), ECMWF, UM(KMA), UKMO 모델, 168hr Forecast Time 이후 UKMO 모델 자료 없음)

- 북반구 Z500 00UTC RMSE, Spread 분포 예측 성능을 살펴보면, 북반구 고위도 지역에서 대부분 RMSE가 크게 나타남을 확인할 수 있다. 특히 북극에서의 차이가 매우 크게 나타남을 확인할 수 있다 (그림 1.1.75).


4) 앙상블 평균 월별 원격상관 예측 성능 평가: AO&PNA Index

- 2021년 7월(여름철) 00, 12UTC AO Index


2021 JULY 00UTC AO Index Correlation



2021 JULY 00UTC AO Index Correlation



2021 JULY 00UTC AO Index Correlation








그림 1.1.76 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY AO Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)

- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 AO Index를 활용하여 예측 성능을 평가하였다. 상관계수가 약 0.6 이상일 경우 현업에서 활용할 수 있는 정보로 평가할 수 있는데 네 모델 모두 매우 높은 상관 계수를 보이며 한국형앙상블모델을 제외한 나머지 모델들의 경우 전체 Forecast Time에 대해 0.6 이상의 상관계수를 유지하는 반면, 한국형앙상블모델은 240hr Forecast Time 이후로는 AO Index 예측 성능이 낮게 나타나 활용에 안정적이지 못함을 확인할 수 있다 (그림 1.1.76).


2021 JULY 12UTC AO Index Correlation



2021 JULY 12UTC AO Index Correlation



2021 JULY 12UTC AO Index Correlation







그림 1.1.77 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY AO Index 12UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)


- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 AO Index를 활용하여 예측 성능을 평가하였다. 00UTC와 비교하였을 때 12UTC는 전반적으로 높은 AO Index 예측 성능을 보이지만, UM(KMA) 모델과 한국형앙상블모델이 264hr Forecast Time 이후로 0.6 이하의 예측 성능을 보임을 확인할 수 있다. ECMWF 모델의 경우 전체적으로 약 0.7 이상의 높은 AO Index 예측 성능을 보인다. 00UTC와 12UTC의 예측 성능의 차이가 보인다는 점에서 AO Index 예측에 있어 초기장 정보가 중요하다는 것을 확인할 수 있다 (그림 1.1.77).

- 2022년 1월(겨울철) 00, 12UTC AO Index


2022 JANUARY 00UTC AO Index Correlation



2022 JANUARY 00UTC AO Index Correlation



2022 JANUARY 00UTC AO Index Correlation








그림 1.1.78 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY AO Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)

- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 AO Index를 활용하여 예측 성능을 평가하였다. 여름철과 비교했을 때 겨울철의 AO Index는 음의 지수와 양의 지수의 변화가 빈번하게 발생하는 것을 확인할 수 있다. 예측 측면에 있어 이러한 빈번한 변화가 가져오는 Transition은 예측에 큰 어려움을 가져오는데도 불구하고 모델들의 초기 AO Index 예측 성능은 높은 편에 속한다. 전반적으로 ECMWF는 전체 Forecast Time에서 높은 상관계수를 유지하는 반면 168hr Forecast Time 이후로 나머지 모델들의 예측 성능이 현저히 감소하는 것을 확인할 수 있다 (그림 1.1.78).


2022 JANUARY 12UTC AO Index Correlation



2022 JANUARY 12UTC AO Index Correlation



2022 JANUARY 12UTC AO Index Correlation







그림 1.1.79 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY AO Index 12UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)


- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 AO Index를 활용하여 예측 성능을 평가하였다. 앞선 00UTC와 비교하였을 때, 12UTC의 예측 성능은 전체 모델에서 144hr Forecast Time 이후로 감소하는 추세를 보임을 확인할 수 있으며, 특이한 점은 240hr Forecast Time 이후 감소했던 상관계수가 증가하는 것을 한국형앙상블모델과 UM(KMA) 두 모델에서 모두 확인할 수 있다. 이러한 부분은 AO 지수의 예측 변동을 살펴봤을 때, 그 추세가 비슷한 형태로 lagged된 예측 성능을 보이기 때문으로 확인된다 (그림 1.1.79).

- 2021년 7월(여름철) 00, 12UTC PNA Index


2021 JULY 00UTC PNA Index: Reanalysis & Forecasts



2021 JULY 00UTC PNA Index: Reanalysis & Forecasts



2021 JULY 00UTC PNA Index: Reanalysis & Forecasts








그림 1.1.80 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY PNA Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)

- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 PNA Index를 활용하여 예측 성능을 평가하였다. PNA 패턴을 활용한 분석을 살펴보면, 초기 분석장에서부터 매우 높은 예측 성능을 보이며 모델 모두에서 120hr Forecast Time까지 상관계수가 약 0,9 이상의 매우 높은 성능을 보임을 확인할 수 있다. 192hr Forecast Time 이후로 예측 성능이 현저히 감소하는 것을 확인할 수 있다. 특히, 한국형앙상블모델의 경우 매우 높은 예측 성능을 유지하다가 급격히 감소하는 것을 확인할 수 있다 (그림 1.1.80).


2021 JULY 12UTC PNA Index: Reanalysis & Forecasts



2021 JULY 12UTC PNA Index: Reanalysis & Forecasts



2021 JULY 12UTC PNA Index: Reanalysis & Forecasts



2021 JULY 12UTC PNA Index Correlation





그림 1.1.81 앙상블 평균 월별 원격상관 예측 성능 평가: 2021 JULY PNA Index 12UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)


- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 PNA Index를 활용하여 예측 성능을 평가하였다. PNA 패턴을 활용한 분석을 살펴보면, 앞선 00UTC와 동일하게 초기 분석장에서 약 120hr Forecast Time까지 매우 높은 예측 성능을 보이다가 144hr부터 급격하게 예측 성능이 떨어지는 것을 확인할 수 있다. 특히, 한국형앙상블모델의 경우 급격히 감소하는 예측 성능을 보이며, 약 216hr 이후로는 0.6 이하의 상관계수를 보이며 예측 성능으로서는 안정적이지 않은 결과를 보이고 있다 (그림 1.1.81).

- 2022년 1월(겨울철) 00, 12UTC PNA Index


2022 JANUARY 00UTC PNA Index: Reanalysis & Forecasts



2022 JANUARY 00UTC PNA Index: Reanalysis & Forecasts



2022 JANUARY 00UTC PNA Index: Reanalysis & Forecasts








그림 1.1.82 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY PNA Index 00UTC
(위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)

- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 PNA Index를 활용하여 예측 성능을 평가하였다. 여름철과 달리 겨울철 PNA Index 예측 성능은 매우 높게 유지되며 감소하는 형태 또한 모델 모두 비슷한 양상을 보인다. 특히 240hr Forecast Time까지 0.6 이상의 예측 성능을 보임을 확인할 수 있다. 이는 앞선 Forecast Time 별 지수 분석 형태를 보았을 때는 지수 자체가 매우 다른 형태를 보이는 것이 아니라 비슷한 형태를 보이거나 Lagged 된 형태를 보임으로써 상관계수를 활용하여 계산했을 때 이러한 점이 반영되어 높은 상관성을 유지하는 것을 알 수 있다. 이를 통하여 예측에 PNA Index를 활용할 때 Lagged analysis, 지연 분석을 통해 더 다양한 정보를 얻을 수 있음을 알 수 있다 (그림 1.1.82).


2022 JANUARY 12UTC PNA Index: Reanalysis & Forecasts



2022 JANUARY 12UTC PNA Index: Reanalysis & Forecasts



2022 JANUARY 12UTC PNA Index: Reanalysis & Forecasts







그림 1.1.83 앙상블 평균 월별 원격상관 예측 성능 평가: 2022 JANUARY PNA Index 00UTC (위-아래: 000hr, 120hr, 288hr Forecast Time, Correlation Plots for 0~288hr Forecast Time)

- 앙상블 평균 월별 원격상관 예측 성능 평가를 위해 PNA Index를 활용하여 예측 성능을 평가하였다. 겨울철 00UTC와 유사하게 12UTC 또한 매우 높은 예측 성능을 유지하고 있다. 약 120hr Forecast Time까지 한국형앙상블모델을 포함한 모든 앙상블 모델들의 상관계수가 약 0.9 이상으로 매우 높게 유지하고 있다가 그 이후로 성능이 감소하는 것을 확인할 수 있으며 한국형앙상블모델의 경우 약 240hr Forecast Time 이후로 0.6 이하로 예측 성능이 감소하는 것을 확인할 수 있다. 그럼에도 불구하고 7일 이상의 예측 성능을 유지하는 결과는 PNA Index 및 앙상블 모델의 원격상관 예측 활용에 있어 매우 유의미한 결과로 보인다 (그림 1.1.83).


5) 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: Blocking Frequency

- 2021년 7월(여름철) 00, 12UTC


2021 JULY 00UTC Blocking Frequency: Reanalysis & Forecasts



2021 JULY 00UTC Blocking Frequency: Reanalysis & Forecasts



2021 JULY 00UTC Blocking Frequency: Reanalysis & Forecasts



2021 JULY 00UTC Blocking Frequency Correlation






그림 1.1.84 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2021 JULY 00UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0-288hr Forecast Time)

- 앙상블 평균 월별 블로킹 빈도 예측 성능 결과를 살펴보면, 여름철의 경우 일반적으로 블로킹이 많이 탐지되지 않는다. 영역별로 살펴보면 우랄 블로킹 영역과 북대서양 블로킹 영역에서 상대적으로 탐지가 많이 되는데, 우랄 블로킹 영역에서의 블로킹 탐지는 앙상블 모델 모두 초기 분석장부터 높은 탐지 성능을 보이지만, 오호츠크 영역과 북태평양 영역에서의 블로킹은 대부분 초기 분석장에서 부터 탐지 성능이 낮음을 확인할 수 있다. 이는 탐지 방법으로 활용되는 TM90 방법이 우랄 영역과, 북대서양 영역에서의 블로킹 탐지에 더 용이하기 때문일 수도 있다 (그림 1.1.84).


2021 JULY 12UTC Blocking Frequency: Reanalysis & Forecasts



2021 JULY 12UTC Blocking Frequency: Reanalysis & Forecasts



2021 JULY 12UTC Blocking Frequency: Reanalysis & Forecasts



2021 JULY 12UTC Blocking Frequency Correlation





그림 1.1.85 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2021 JULY 12UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0-288hr Forecast Time)


- 앙상블 평균 월별 블로킹 빈도 예측 성능 결과를 살펴보면, 00UTC와 비교했을 때 12UTC에서 UM(KMA) 모델이 더 긴 Forecast Time에서 예측 성능이 유지되는 것을 확인할 수 있다. 전체적으로 UM(KMA) 모델과 한국형앙상블모델의 탐지 능력은 144hr Forecast Time까지 0.6 이상을 유지하며, UKMO와 ECMWF는 그 이후까지는 유지되나 192hr 까지 탐지 성능을 보이지 않는다. 영역 별로 살펴보면 00UTC와 마찬가지로 우랄 영역과 북대서양 블로킹에서의 탐지는 잘 수행되나, 오호츠크와 북태평양 영역의 탐지는 상대적으로 예측 성능이 낮음을 확인할 수 있다 (그림 1.1.85).

- 2022년 1월(겨울철) 00, 12UTC


2022 JANUARY 00UTC Blocking Frequency: Reanalysis & Forecasts



2022 JANUARY 00UTC Blocking Frequency: Reanalysis & Forecasts



2022 JANUARY 00UTC Blocking Frequency: Reanalysis & Forecasts



2022 JANUARY 00UTC Blocking Frequency Correlation






그림 1.1.86 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2022 JANUARY 00UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0-288hr Forecast Time)

- 앙상블 평균 월별 블로킹 빈도 예측 성능 결과를 살펴보면, 겨울철의 블로킹이 더 의미있는 결과로 해석할 수 있는데 특히, 오호츠크와 북태평양 블로킹이 많이 발생하는 것을 확인할 수 있으며, 초기 분석장에서 앙상블 모델 모두 이 영역에서의 블로킹 탐지 능력이 매우 높은 것을 확인할 수 있다. 또한 여름철에는 168hr Forecast Time 이후로는 탐지되지 않았던 블로킹들이 겨울철에는 더 오랜 Forecast Time 까지 탐지가 가능한 것을 확인할 수 있다. 한국형앙상블모델또한 216hr Forecast Time 까지 0.6 이상의 높은 블로킹 탐지 성능을 보임을 확인할 수 있다 (그림 1.1.86).


2022 JANUARY 12UTC Blocking Frequency: Reanalysis & Forecasts



2022 JANUARY 12UTC Blocking Frequency: Reanalysis & Forecasts



2022 JANUARY 12UTC Blocking Frequency: Reanalysis & Forecasts



2022 JANUARY 12UTC Blocking Frequency Correlation




그림 1.1.87 앙상블 평균 월별 블로킹 빈도 예측 성능 평가: 2022 JANUARY 12UTC (위-아래: 000hr, 120hr, 168hr Forecast Time, Correlation Plots for 0-288hr Forecast Time)

- 앙상블 평균 월별 블로킹 빈도 예측 성능 결과를 살펴보면, 00UTC와 비교하였을 때, 12UTC에서 더 높은 블로킹 탐지 능력을 보임을 확인할 수 있다. 약 240hr Forecast Time까지 앙상블 모델 모두 0.6 이상의 높은 블로킹 탐지 능력을 보이며, 120hr Forecast Time까지 오호츠크, 북태평양 블로킹 영역 뿐만 아니라 우랄, 북대서양 블로킹 영역까지 블로킹이 잘 탐지되는 것을 확인할 수 있다. 또한 ECMWF와 함께 한국형앙상블모델의 겨울철 블로킹 탐지 능력도 매우 안정적이며 높은 탐지 예측 성능을 보임을 확인할 수 있다 (그림 1.1.87).

5) 추가 분석: 한국형양상블모델의 온도, 지위 고도장 수직 분포(Vertical Structure) 분석

한국형양상블모델의 월별 양상블 자료를 활용하여 수평 분포 뿐만 아니라, 수직 분포 분석을 진행하였다. 예측 성능을 평가하는데 있어 가장 중요한 온도(Temperature)와 지위 고도장(Geopotential Height) 변수를 중심으로 2021년 7월 여름철과, 2022년 1월 겨울철을 중심으로 예측 성능 분석 결과를 기술하였다. 수직 분포 분석에 활용된 기압은 1000hPa, 925hPa, 850hPa, 700hPa, 500hPa, 200hPa 까지 총 6개 층을 활용하였으며, 하층부터 중층, 상층까지 전체적으로 분석을 진행하였다. 본 분석에는 TIGGE Project 자료의 부족으로 한국형양상블모델과 ECMWF ERA5 재분석 자료와의 비교 분석을 진행하여, 재분석 자료 대비 한국형양상블모델의 성능을 평가하였으며, 수직 분포의 편차(Bias), 평균제곱근오차(RMSE), 양상블의 분산(SPREAD), 평균제곱근오차와 양상블 분산의 차이(RMSE-SPREAD)를 보았으며, 이를 통해 양상블 모델의 구조적 오차 파악 및 성능을 살펴보았다.

- 2021년 7월(여름철) 00/12UTC 온도(Temperature) 편차(Bias)

2021 JULY 00UTC Temperature BIAS




그림 1.1.88 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2021 JULY 00UTC Temperature

2021 JULY 12UTC Temperature BIAS




그림 1.1.89 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2021 JULY 12UTC Temperature

- 한국형앙상블모델의 2021년 7월 00UTC 온도 수직 분포의 경우 남반구 특히, 남극 영역 하층에 음의 편차가 분석 초기장부터 나타나며 Forecast Time이 증가할수록 더 커지는 양상을 보이며, 북반구의 경우 하층과 중층에 약 0.5-0.8 사이의 양의 편차가 보이는 것을 확인할 수 있으나 대체적으로 두드러지는 편차는 남반구에서 보임을 확인할 수 있다 (그림 1.1.88)
- 2021년 7월 12UTC의 경우 00UTC와 유사한 편차를 보이나 남반구 하층에서 두드러지는 차이를 보이는 것과, 북반구 하층과 중층 특히 북극지역의 음의 편차와 중층의 양의 편차가 00UTC 때 보다 더 두드러지게 나타나는 것을 확인할 수 있으며, 이 편차는 Forecast Time이 증가할수록 함께 커지는 것을 확인할 수 있다 (그림 1.1.89)
- 전체적으로 온도의 수직 분포의 차이는 하층-중층의 편차 양상이 00UTC와 12UTC가 유사하게 나타나는 것을 확인할 수 있으며, 상층(200hPa)에서의 차이는 음의 편차가 보이지만 큰 차이는 나타나지 않는다.
- 특히 수평 분포에서 보였던 00UTC와 12UTC의 지표 온도 차이는 수직 분포에서는 경도 평균을 통해서 나타나지 않는 것으로 확인되기 때문에 수평 분포와 수직 분포를 함께 살펴볼 필요가 있다.

- 2022년 1월(겨울철) 00/12UTC 온도(Temperature) 편차(Bias)

2022 JANUARY 00UTC Temperature BIAS

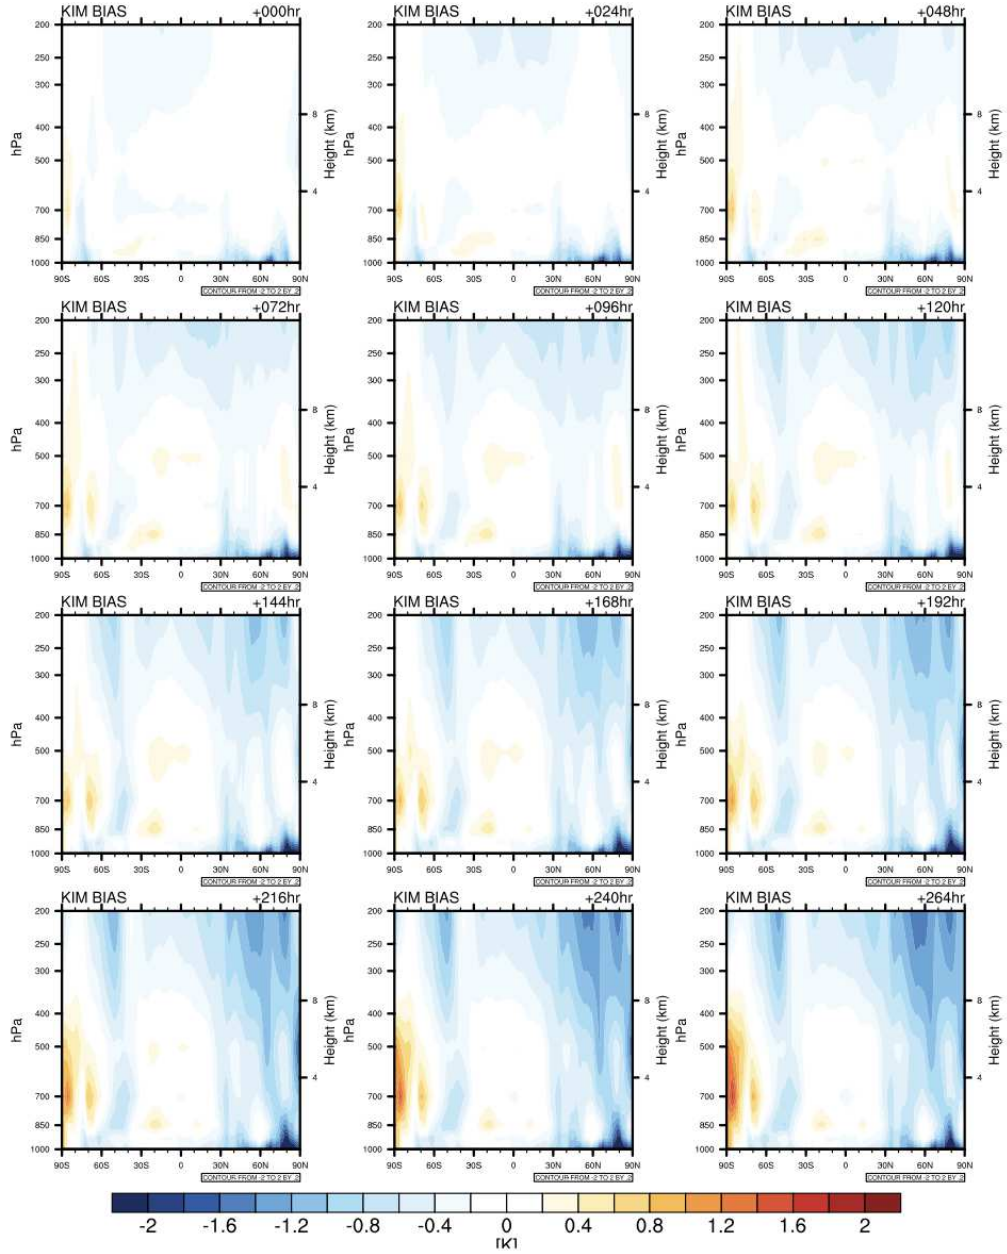


그림 1.1.90 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2022 JANUARY 00UTC Temperature

2022 JANUARY 12UTC Temperature BIAS




그림 1.1.91 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 편차(Bias) 분석: 2022 JANUARY 12UTC Temperature

- 한국형앙상블모델의 2022년 1월 00UTC 온도 수직 분포의 경우 남반구 특히, 남극 영역 하층-중층에서 양의 편차가 나타나는 것을 확인할 수 있으며, 북반구 표층에서는 양의 편차가 나타나는 것을 확인할 수 있다. 이러한 편차의 특징들은 분석 초기장(000hr)부터 나타나며, Forecast Time이 증가함에 따라 그 편차도 크게 나타난다.
- 또한, Forecast Time이 증가하면서 분석 초기장에서는 두드러지지 않았던 상층의 음의 편차들이 커지는 것을 확인할 수 있다. 적도와 중위도 영역 일부에서는 그러한 특징이 크게 나타나지 않으며, 양 극 지역에서의 편차가 커지는 것을 확인할 수 있다 (그림 1.1.90).
- 이러한 편차의 특징들은 앞선 여름철 편차 분석과 동일하게 00UTC와 12UTC 모두 비슷한 패턴을 보이는 것을 확인할 수 있으며, 이러한 원인 또한 앞서 언급했던 경도 평균으로 인해 표층 차이가 평활화(Smoothing) 된 값으로 표출된 것으로 보인다 (그림 1.1.91).

- 2021년 7월(여름철) 00/12UTC 지위 고도장(Geopotential) 편차(Bias)

2021 JULY 00UTC Geopotential BIAS




그림 1.1.92 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2021 JULY 00UTC Geopotential

2021 JULY 12UTC Geopotential BIAS




그림 1.1.93 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2021 JULY 12UTC Geopotential

- 한국형앙상블모델의 2021년 7월 00UTC 지위 고도장 수직 분포의 경우 초기 분석장에서 남극 지역의 양의 편차가 보이며, 상층에 음의 편차가 나타난다. Forecast Time이 증가할수록 남극지역의 상층의 음의 편차는 하층까지 이어져서 나타나며 하층의 양의 편차는 음의 편차 형태로 변환되는 것을 볼 수 있다. 또한 북반구의 경우 대륙 지역보다는 북극 지역에서 하층부터 상층까지 큰 양의 편차가 나타나는 것을 확인할 수 있다 (그림 1.1.92).
- 12UTC 또한, 00UTC와 동일한 형태의 편차를 보이며 북반구와 남반구 각각의 극에서 음의 편차와 양의 편차가 두드러지게 나타나는 것을 확인할 수 있다 (그림 1.1.93).

- 2022년 1월(겨울철) 00/12UTC 지위 고도장(Geopotential) 편차(Bias)

2022 JANUARY 00UTC Geopotential BIAS




그림 1.1.94 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2022 JANUARY 00UTC Geopotential

2022 JANUARY 12UTC Geopotential BIAS




그림 1.1.95 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 편차(Bias) 분석: 2022 JANUARY 12UTC Geopotential

- 한국형앙상블모델의 2022년 1월 00UTC 지위 고도장 수직 분포의 경우 초기 분석장에서 하층의 편차는 크게 나타나지 않으며, 상층의 음의 편차를 확인할 수 있다. 이 음의 편차는 Forecast Time이 증가할수록 같이 증가하며, 하층보다는 상층에 지속적으로 음의 편차가 나타나는 것을 확인할 수 있다. 겨울철의 경우 전반적으로 00UTC 뿐만 아니라, 12UTC 또한 하층의 편차 보다는 상층의 편차가 두드러지게 나타난다 (그림 1.1.94).
- Forecast Time이 증가할수록 북반구의 경우 하층의 양의 편차가 보이기는 하지만 그 차이는 크게 나타나지 않으며, 남반구의 경우 또한 중층에 양의 편차가 나타나지만 그 편차가 크게 나타나지는 않고, 두 초기장 모두 상층의 음의 편차에 주목할 필요가 있다 (그림 1.1.95).

- 2021년 7월(여름철) 00/12UTC 온도(Temperature) 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석

2021 JULY 00UTC Temperature RMSE & SPREAD

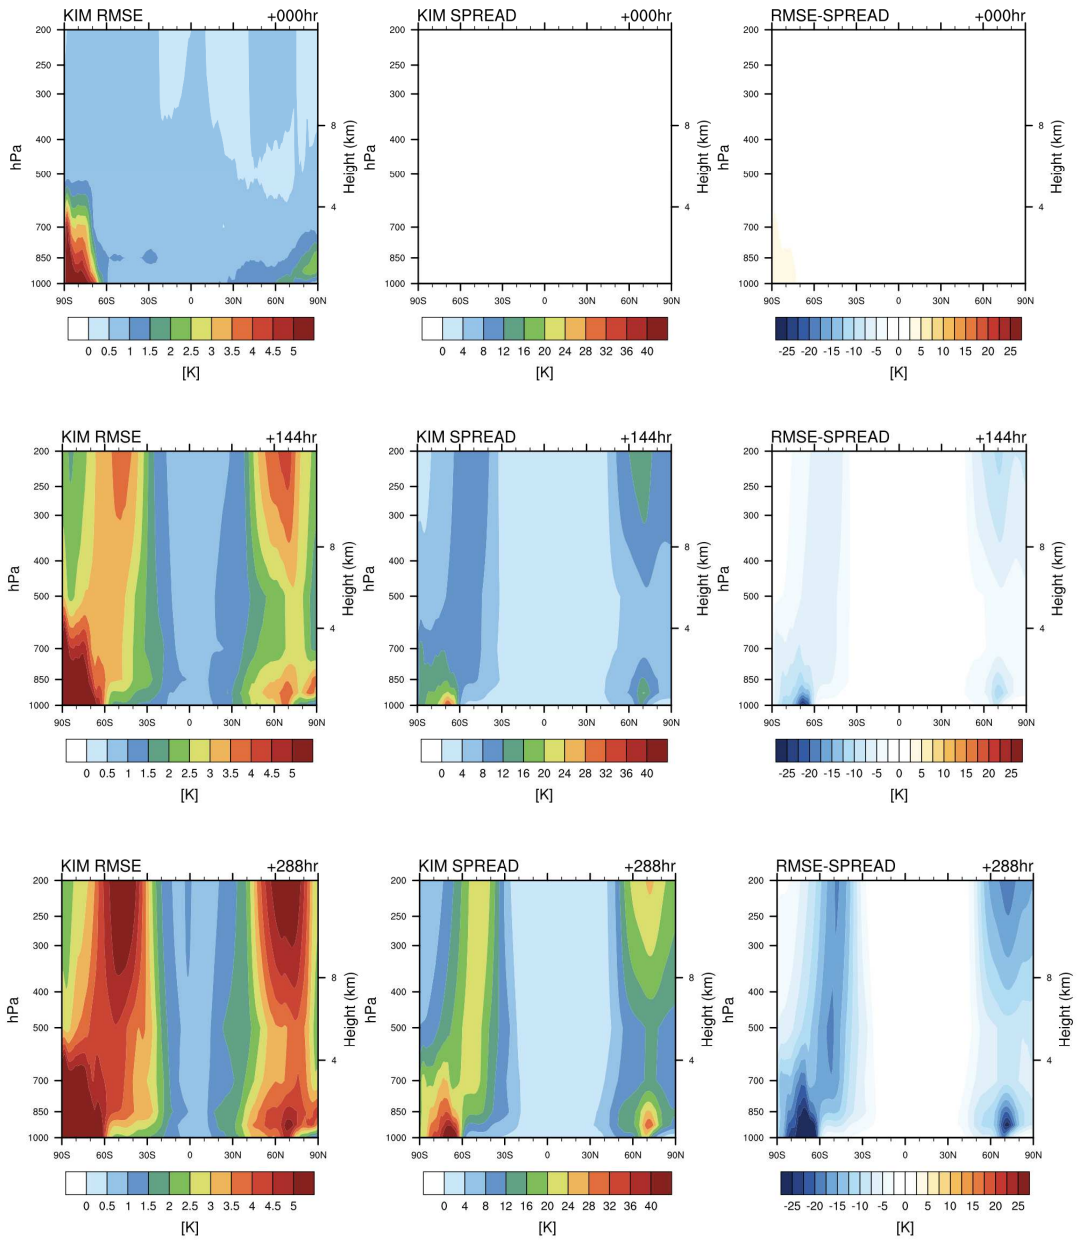


그림 1.1.96 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY 00UTC Temperature

2021 JULY 12UTC Temperature RMSE & SPREAD

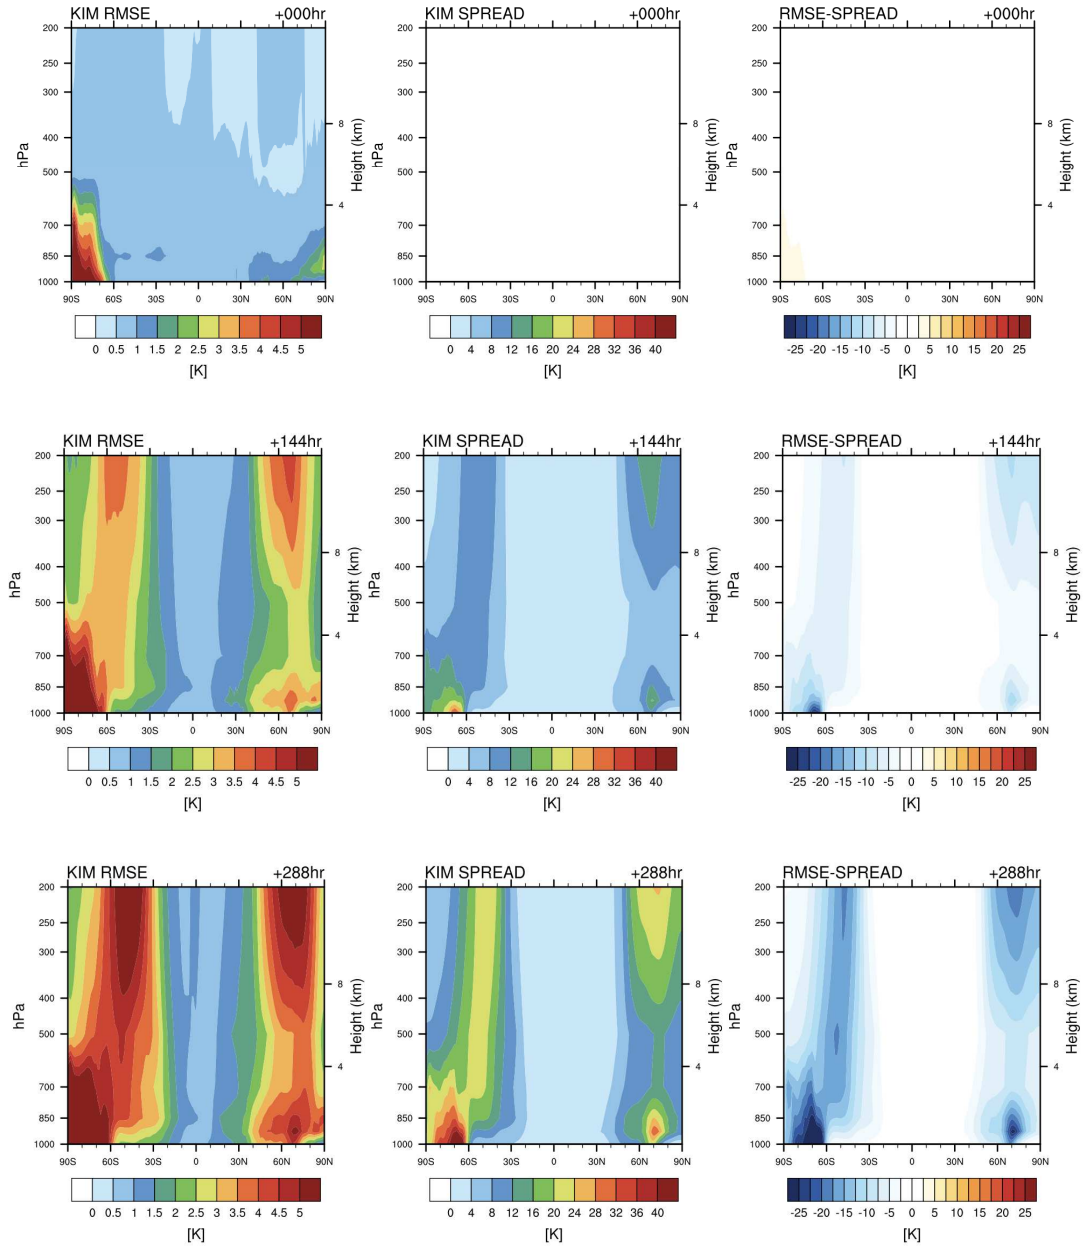


그림 1.1.97 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY 12UTC Temperature

- 한국형앙상블모델의 2021년 7월 00UTC의 경우 000hr, 144hr, 288hr Forecast Time에 대해서 온도 변수는 초기 분석장에서 양 극 지역에서 평균제곱근편차가 나타나는 것을 확인할 수 있으며, 이 편차는 하층에서 상층으로 Forecast Time이 증가함에 따라 증가하는 것을 살펴볼 수 있다 (그림 1.1.96).
- 00UTC와 동일하게 12UTC에서도 동일한 특징이 나타나며, 앙상블 분산의 경우 SPREAD가 초기 분석장에서는 두드러지게 나타나지는 않으나 Forecast Time이 증가함에 따라 양 극지역에서 크게 증가하는 것을 확인할 수 있으며, 이 차이는 그림 1.1.97에서도 볼 수 있듯이 양 극 지역에서 음의 편차를 확인할 수 있다 (그림 1.1.97).

- 2022년 1월(겨울철) 00/12UTC 온도(Temperature) 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석

2022 JANUARY 00UTC Temperature RMSE & SPREAD

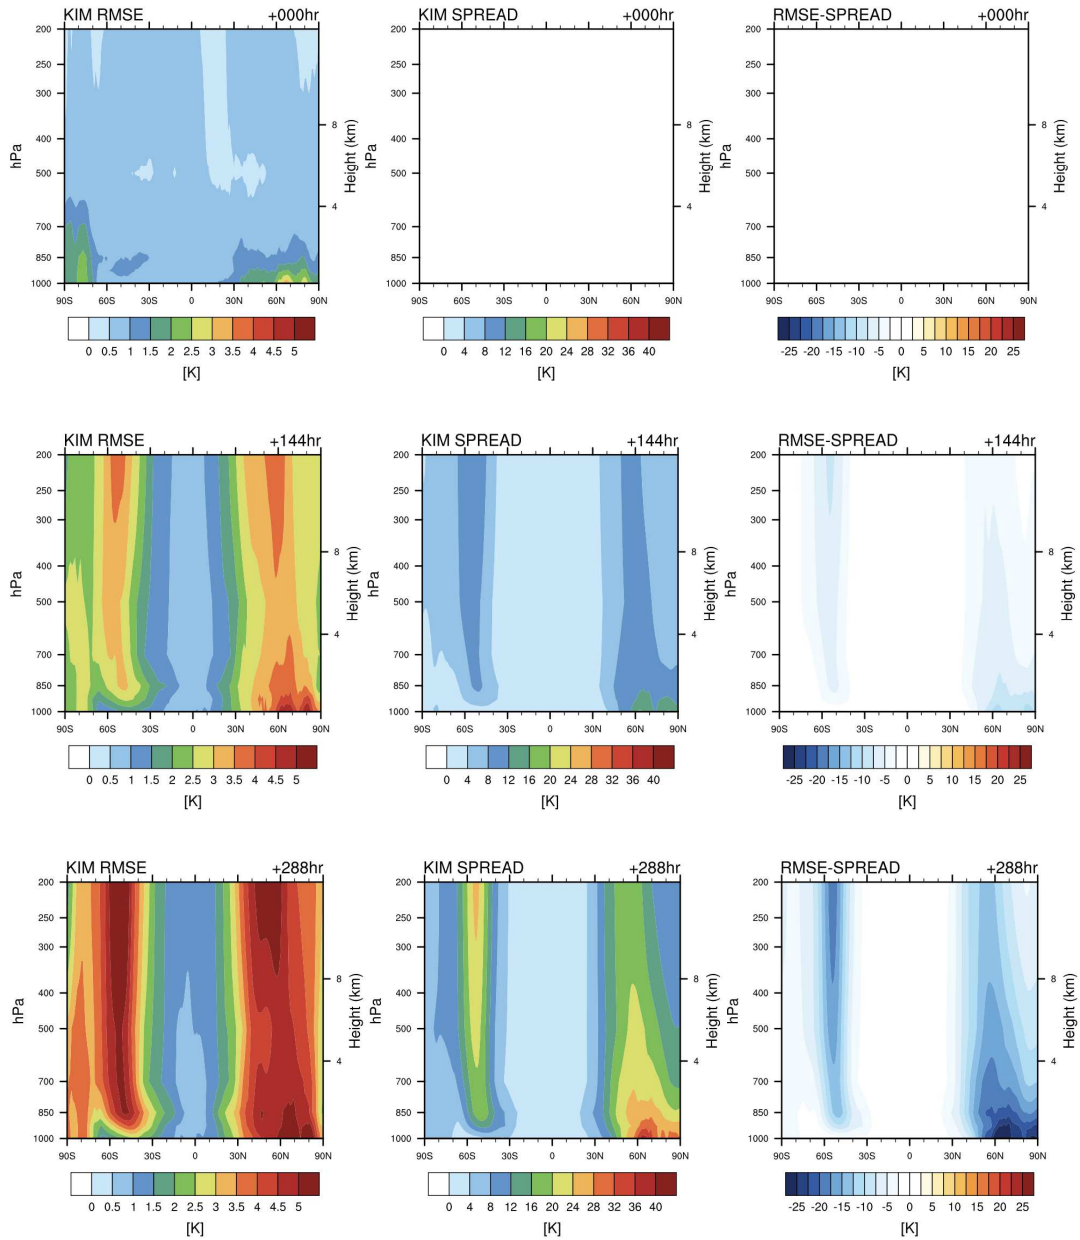


그림 1.1.98 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 00UTC Temperature

2022 JANUARY 12UTC Temperature RMSE & SPREAD

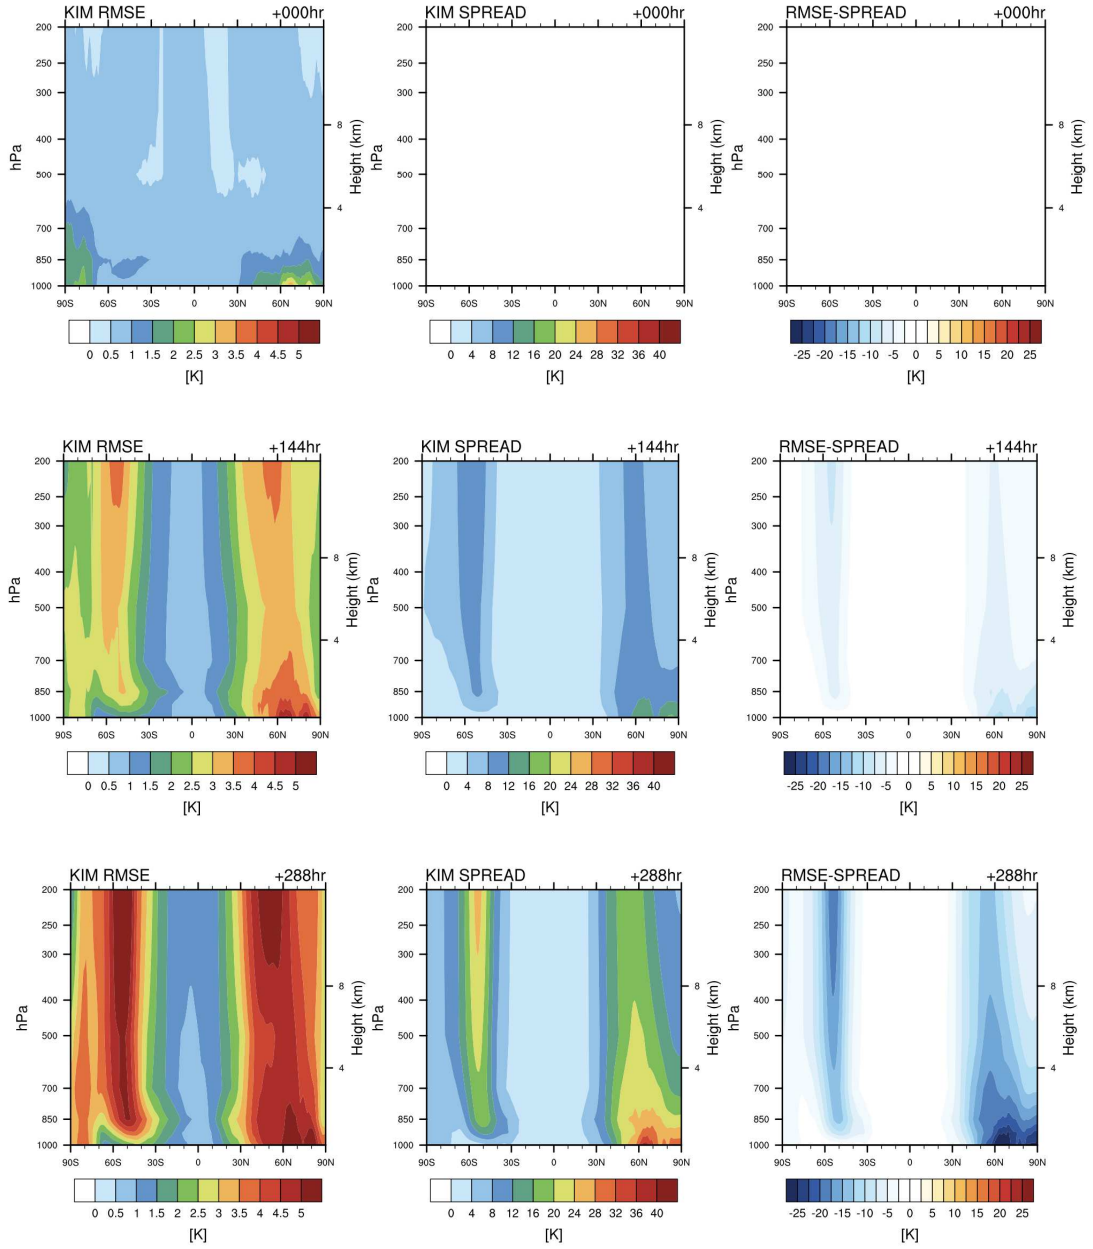


그림 1.1.99 한국형앙상블모델(KIM)의 평균 월별 온도 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 12UTC Temperature

- 한국형양상블모델의 2022년 1월 00UTC의 경우 000hr, 144hr, 288hr Forecast Time에 대해서 온도 변수는 초기 분석장에서 상대적으로 여름철 보다는 양 극 지역에서 나타나는 평균제곱근편차가 낮게 나타나는 것을 확인할 수 있다. 하지만, Forecast Time이 증가할수록 양 극 지역에서의 편차는 양의 편차를 보이며 크게 나타나는 것을 확인할 수 있으며, 288hr에서는 적도를 제외하고는 전반적으로 중위도와 고위도 모두에서 편차가 크게 나타남을 확인할 수 있다 (그림 1.1.98).
- 00UTC와 동일하게 12UTC 또한 비슷한 양상을 보이며, RMSE가 커지는 양상보다는 낮게 양상블 분산 SPREAD는 천천히 증가하는 것을 확인할 수 있다. 이 분산의 경우 북반구 중위도-고위도 지역에서 점점 커지는 것을 확인할 수 있으며, 남반구의 경우 하층보다는 상층에서 그 값이 커지는 것을 확인할 수 있다 (그림 1.1.99). 이러한 양상을 기반으로 평균제곱근편차와 양상블 분산의 차이는 남반구에서는 중층-상층에서의 음의 편차, 북반구에서는 하층에서의 큰 음의 편차가 두드러지게 나타나는 것을 확인할 수 있다.

- 2021년 7월(여름철) 00/12UTC 지위 고도장(Geopotential) 평균 제곱근 편차(RMSE), 앙상블 분산(SPREAD) 분석

2021 JULY 00UTC Geopotential RMSE & SPREAD




그림 1.1.100 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2021 JULY 00UTC Geopotential

2021 JULY 12UTC Geopotential RMSE & SPREAD

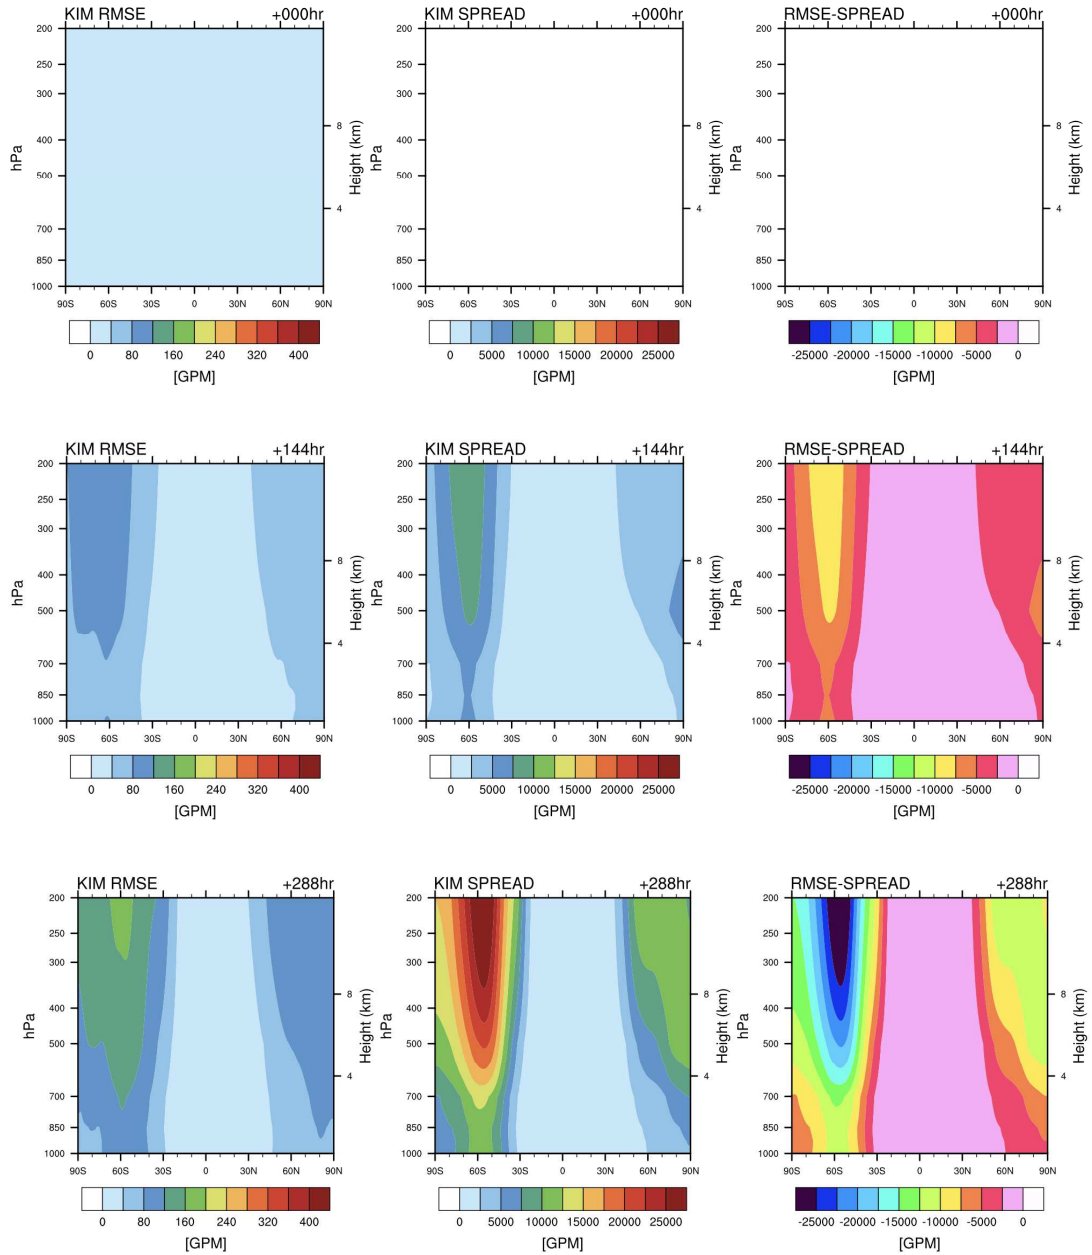


그림 1.1.101 한국형양상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 양상블 분산(SPREAD) 분석: 2021 JULY12UTC Geopotential

- 한국형양상블모델의 2021년 7월 00UTC의 경우 000hr, 144hr, 288hr Forecast Time에 대해서 지위고도장 변수는 초기 분석장에서는 상대적으로 두드러지는 편차 및 분산을 보이지 않지만, 144hr 이후 상층에서 그 편차 및 분산이 증가하는 것을 확인할 수 있다. 특히 남반구 상층에서 그 분산이 커지며 시간이 증가할수록 남반구의 경우 상층에서 그 값이 더 두드러지게 증가하는 것을 볼 수 있으며, 반면 북반구는 그 증가 추세가 그렇게 크지는 않음을 확인할 수 있다 (그림 1.1.100).
- 평균제곱근편차와 양상블 분산의 차이는 앞서 본 것과 동일하게 00UTC와 12UTC가 비슷한 편차 패턴을 보이는 것을 알 수 있으며, 차이의 경우 남반구에서 음의 편차가 가장 두드러지게 나타나는 것을 확인할 수 있다. 특히, 하층 보다는 중층과 상층에서 그 차이가 두드러진다 (그림 1.1.101).

- 2022년 1월(겨울철) 00/12UTC 지위 고도장(Geopotential) 평균 제곱근 편차(RMSE), 앙상블 분산(SPREAD) 분석

2022 JANUARY 00UTC Geopotential RMSE & SPREAD

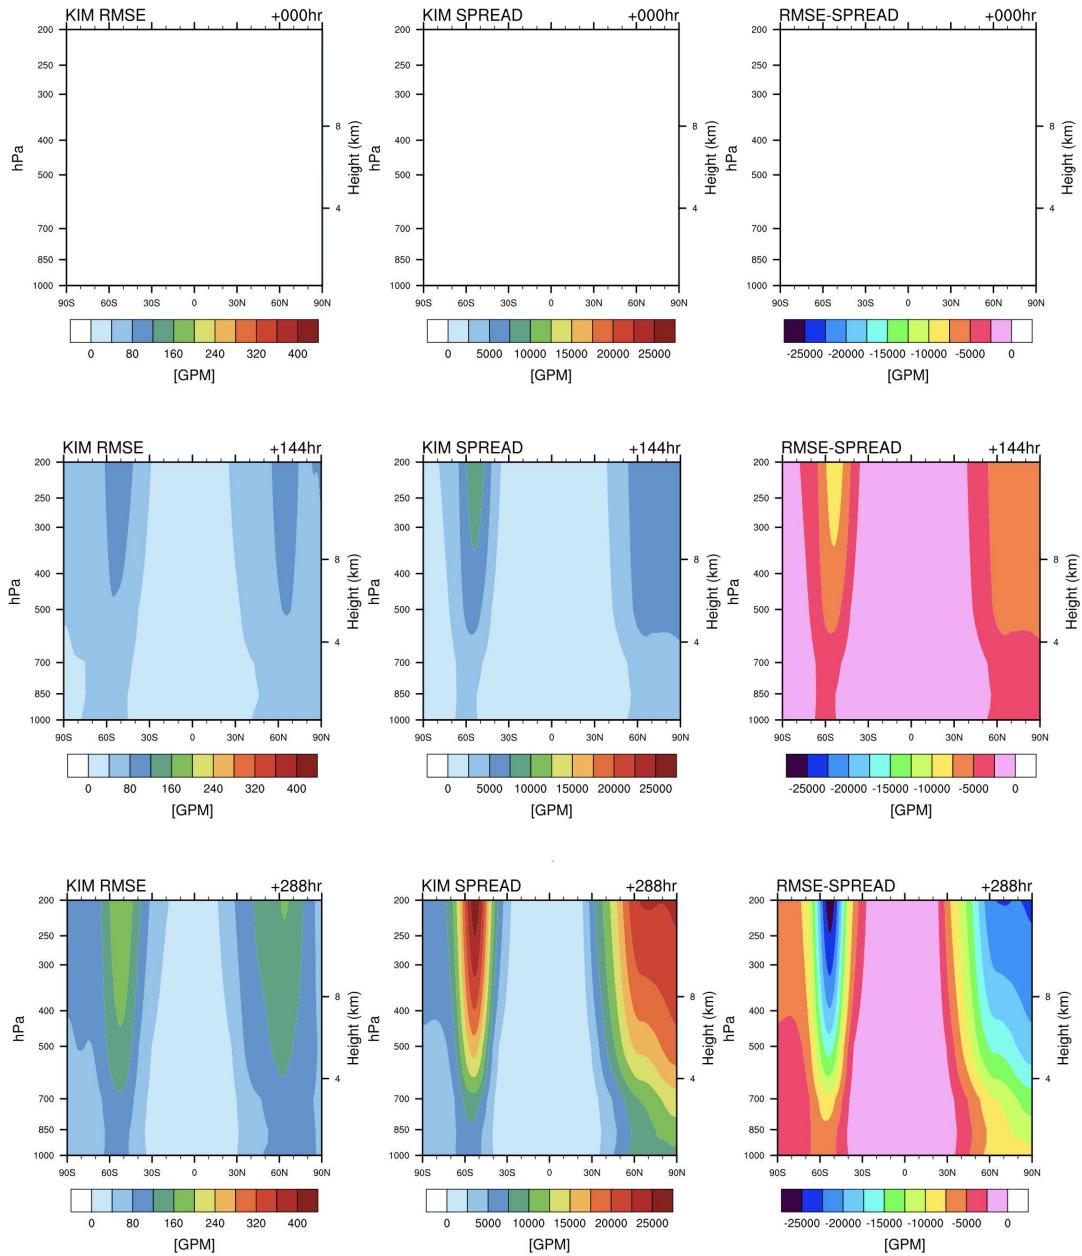


그림 1.1.102 한국형앙상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 앙상블 분산(SPREAD) 분석: 2022 JANUARY 00UTC Geopotential

2022 JANUARY 12UTC Geopotential RMSE & SPREAD

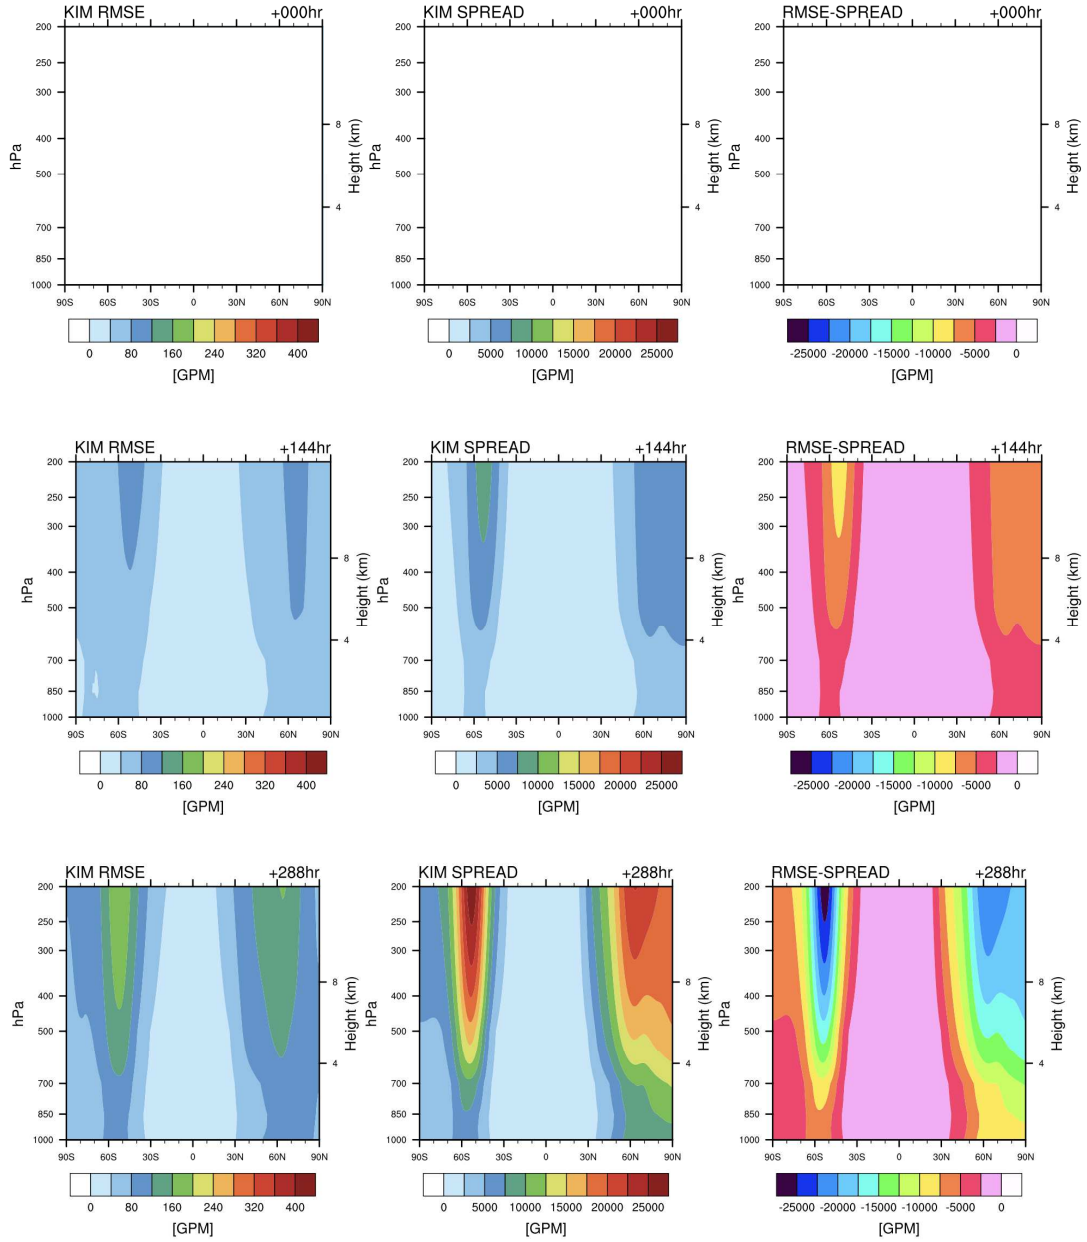


그림 1.1.103 한국형양상블모델(KIM)의 평균 월별 지위고도장 수직 분포 평균제곱근편차(RMSE), 양상블 분산(SPREAD) 분석: 2022 JANUARY 12UTC Geopotential

- 한국형양상블모델의 2022년 1월 00UTC의 경우 000hr, 144hr, 288hr Forecast Time에 대해서 지위고도장 변수는 초기 분석장에서는 상대적으로 두드러지는 편차 및 분산을 보이지 않지만, 144hr 이후 상층에서 그 값이 커짐을 알 수 있다. 여름철과는 다르게 겨울철에는 남반구 상층보다는 북반구 상층에서 그 차이가 크게 나타난다. 또한 평균제곱근편차 뿐만 아니라 양상블 분산의 경우도 북반구 상층에서 양상블 분산이 크게 나타나는 것을 확인할 수 있다 (그림 1.1.102).
- 이러한 편차와 분산의 차이는 00UTC와 12UTC가 비슷한 양상을 보이며 전반적으로 남반구 상층과 북반구 상층에서 음의 편차가 두드러지게 나타나며, 평균제곱근편차가 증가하는 양상에 비해 양상블 분산이 증가하는 양상이 더 두드러짐을 알 수 있다 (그림 1.1.103).

요약문

양상블 모델의 월별 예측 성능 결과 전반적으로 한국형양상블모델은 ECMWF 모델과 매우 유사한 패턴을 예측 성능 및 오차 분포를 갖고 있음을 확인하였다. 하지만, 하층 변수의 경우(T1000) 00UTC와 12UTC에서 예측 성능 차이가 크게 나타나는데, 이는 모델 초기 분석장 및 구조적 오차로 인해 예측 성능의 오류가 발생한 것으로 판단된다. 이와 함께 살펴본 850hPa에서의 온도(T850) 예측 성능은 00UTC와 12UTC가 매우 비슷한 패턴으로 예측 성능을 모의하는 것을 확인하였다. 이를 통해 다시 한국형양상블모델의 하층 변수에 대한 자료 동화 및 초기 분석장 문제가 있음을 확인할 수 있었다.

기본적으로 한국형양상블모델은 ECMWF 모델과 유사한 예측 분포를 가지고 있으나 (예측 성능의 차이가 있음에도 불구하고) 이는 하층 변수에서 나타나며, 특이하게도 상층에서는 한국형양상블모델과 UM(KMA) 모델과의 예측 성능 및 편차 분포가 유사함을 확인할 수 있었다. 모델의 상층 모의 능력에 영향을 미치는 부분이 한국형양상블과 UM(KMA) 모델이 유사한 것으로 판단된다.

또한 원격상관 및 블로킹 탐지 예측 성능에 있어 한국형양상블모델은 매우 안정적인 예측 성능을 보이나 원격상관에 활용된 변수 중 해면 기압 변수 또한 하층 변수이기 때문에 변수의 특성상 모의하는 능력에 차이가 있음을 확인할 수 있었다. 이 외에 상층 변수인 500hPa 지위 고도장을 활용한 PNA Index와 블로킹 탐지의 경우 매우 안정적인 예측 성능을 보임을 확인할 수 있었다. 특히, 블로킹 탐지에 있어 여름철과 겨울철 모두 주요 영역에서의 탐지가 매우 높은 예측 성능을 보이며 이뤄지고 있으며, 그 중에서도 겨울철 블로킹 탐지 능력은 한국형양상블모델이 ECMWF 모델과 함께 높은 예측 성능을 보임을 확인할 수 있었다.

결과적으로, 예측에 활용된 한국형양상블모델의 하층 변수에 대한 진단이 필요함을 확인할 수 있었으며, 이를 보완하여 한국형양상블모델의 양상블 예측

성능의 향상을 기대할 수 있을 것으로 생각된다.

추가 분석을 통해, 수평 분포 뿐만 아니라 수직 분포 분석을 진행하였으며 이를 통해 수직 분포에서 앞선 하층에서 나타나는 지위 고도장과 온도 변수의 문제점이 평활화 되어 두드러지게 나타나지는 않음을 확인할 수 있다. 하지만 하층부터 상층까지의 전체적인 수직 분포 분석을 통해 하층 보다 상층에서의 평균제곱근편차의 차이 및 앙상블 분산의 차이가 두드러지게 나타남을 두 변수 및 두 계절 모두에서 확인할 수 있었다. 뿐만 아니라, 두 변수 모두 북극 지역과 남극 지역에서 두드러진 차이를 보임을 확인할 수 있었으며, 적도 및 중위도는 상대적으로 그 차이가 하층에서 상층까지 두드러지지 않는 않았다. 결과적으로 온도 변수의 경우 양 극지역의 하층에서 상층까지의 편차, 지위 고도장의 경우 양 극지역의 중층-상층의 편차를 확인할 수 있었으며, 이 분석을 통해 모델의 구조적 오차 파악 및 예측 성능을 평가 할 수 있었다.

2.2 한국형앙상블모델의 앙상블 예측 특성 평가를 위한 진단기술 활용 분석 및 평가

(1) 북아메리카 서부 폭염 사례 분석

- 북미 폭염 발생 개요
 - 2021년 6월 25일부터 7월 1일까지 북아메리카 서부지역에 발생한 폭염 현상은 워싱턴, 오리건, 캐나다 서부 등 폭염으로 인한 사망자가 180여명에 달하는 피해를 주었다.
 - 특히 2021년 6월 29일에 캐나다의 브리티시컬럼비아주 리튼의 기온이 49.6°C를 기록하면서 캐나다 역사상 최고 온도를 기록하였다 (그림 1.2.1 (좌)). 또한 1950년 이후 가장 높은 기온인 39.5°C (45-52°N, 119-123°W 평균 기준) 기록하였고 확률분포의 가장 가장자리에 위치하여 발생빈도가 매우 낮은 기상 현상이었다 (그림 1.2.1(우); Thomson et al., 2022).

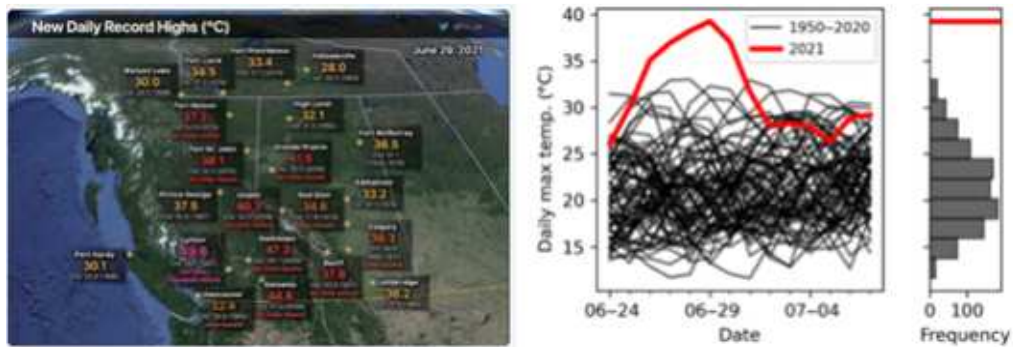


그림 1.2.1 2021년 6월 29일 발생한 북미 폭염 현상
(출처: (좌) Patrick Duplessis of Dalhousie University
(우) Thomson et al. 2022)

- 기상청의 ‘2021 이상 기후보고서’에 의하면 폭염 발생 주요 원인으로는 두 가지 요인이 제시되고 있다. 첫 번째, 양의 북대서양 진동(NAO; North Atlantic Oscillation)의 발달로 인해 북미지역에서 고기압성 순환 발달하였고, 두 번째, 라니냐의 영향으로 인한 아열대 중태평양 지역의 대류 활동이 강화되었고 이로 인해 북태평양-북미 파동 전파 구조가 발달하여 북미의 고기압성 순환이 더욱 강화되었다. 이러한 요인으로 강화된 북미지역의 고기압성 순환과 북미 서부의 강한 저기압성 흐름으로 인해 북미지역에 유례없는 폭염이 발생하였다 (그림 1.2.2).

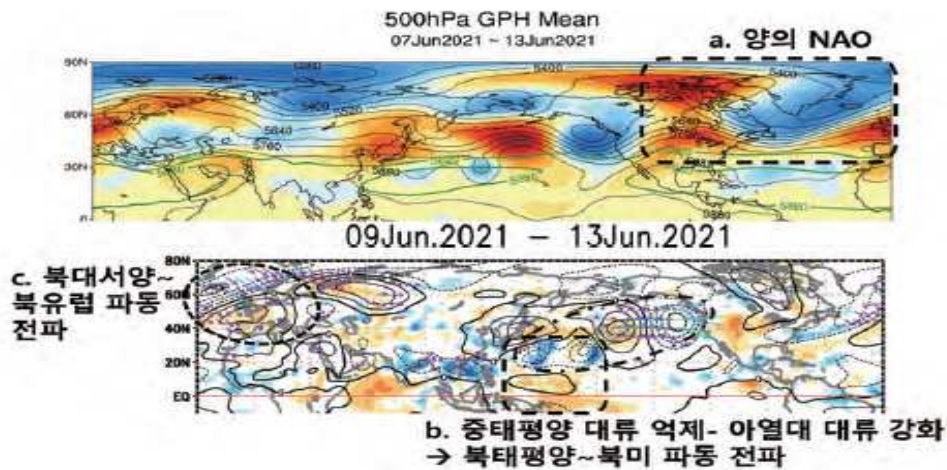


그림 1.2.2 (상) 6월 7~13일 500hPa 지위고도 편차 (하) 850hPa stream function, wave activity flux, outgoing longwave radiation(OLR)

(출처: Tokyo Climate Center; TCC)

(2) 한국형앙상블모델을 활용한 폭염 사례 분석 방법

- 앙상블모델 및 앙상블 구성 방법
 - 한국형앙상블모델의 폭염 사례에 대한 예측성능 비교, 분석을 위해 TIGGE의 ECMWF 앙상블모델을 활용하였다. ECMWF 앙상블모델의 경우, 앙상블 개수가 총 100개로 초기시간 00UTC와 12UTC에 각각 50개의 앙상블로 구성되어있고, 각 초기시간별로 24시간 간격으로 288시간까지의 예측자료를 활용하였다.
 - 24시간 간격의 예측시간을 가진 ECMWF 앙상블모델과 한국형앙상블모델을 비교, 분석하기 위해 초기시간 00UTC, 12UTC의 앙상블을 따로 구성하여 분석하였다 (표 1.2.1).

표 1.2.1 앙상블 모델 분석 방법 예시

Example		Valid Time					
		7/1 00	7/1 12	7/2 00	7/2 12	7/3 00	7/3 12
Init Time	7/1 00UTC	+00h		+24h		+48h	
	7/1 12UTC		+00h		+024h		+048h

- 앙상블모델의 아노말리(Anomaly) 분석 방법
 - 폭염과 같은 극한기상분석을 효과적으로 분석하기 위해서는 기후값 대비 현재 기상현상을 파악할 수 있는 아노말리(Anomaly) 분석이 필수적이다. 하지만 한국형앙상블모델은 과거재현실험(Hindcast) 자료가 없어, 모델 기후값이 존재하지 않는다. 따라서 본 연구에서는 모델 기후값을 대체하여

ERA5 재분석자료(관측)의 1991-2020년 기후값을 활용하여 모델 아노말리를 산출하여 분석하였다. 한국형앙상블모델과 ECMWF 앙상블 모델을 동일한 방법으로 아노말리를 계산하여 예측성능을 비교하였다.

ex) 관측 아노말리 = 관측자료 - 관측 기후값

모델 아노말리 = 모델자료 - 관측 기후값

- 앙상블모델의 앙상블 멤버 확률분포 분석 방법
 - Domeisen, Daniela IV, et al., 2022에서는 앙상블모델의 앙상블별 예측 결과를 확률분포로 나타내어 초기시간별로 앙상블 멤버의 극한 기상현상 예측 가능성을 확률로써 분석하였다. 그림 1.2.3은 2018년 7월 23일에 대해서 각각 초기시간 2018년 7월 2일, 7월 9일, 7월 16일 예측자료의 확률분포를 나타낸 것이다. 초기시간이 목표시간(7월 23일)에 가까워질수록 관측자료(보라색 점선)를 모의할 확률이 높아지는 것을 확인할 수 있다. 앙상블 멤버 확률분포 분석을 통해 모델별 앙상블 멤버들의 극한기상 예측 가능성을 평가하였다.
 - 본 연구에서는 선행연구에서 활용한 앙상블 확률분포 분석 방법을 폭염 사례에 적용하여 한국형앙상블모델과 ECMWF 앙상블모델에 대해 분석하였다.

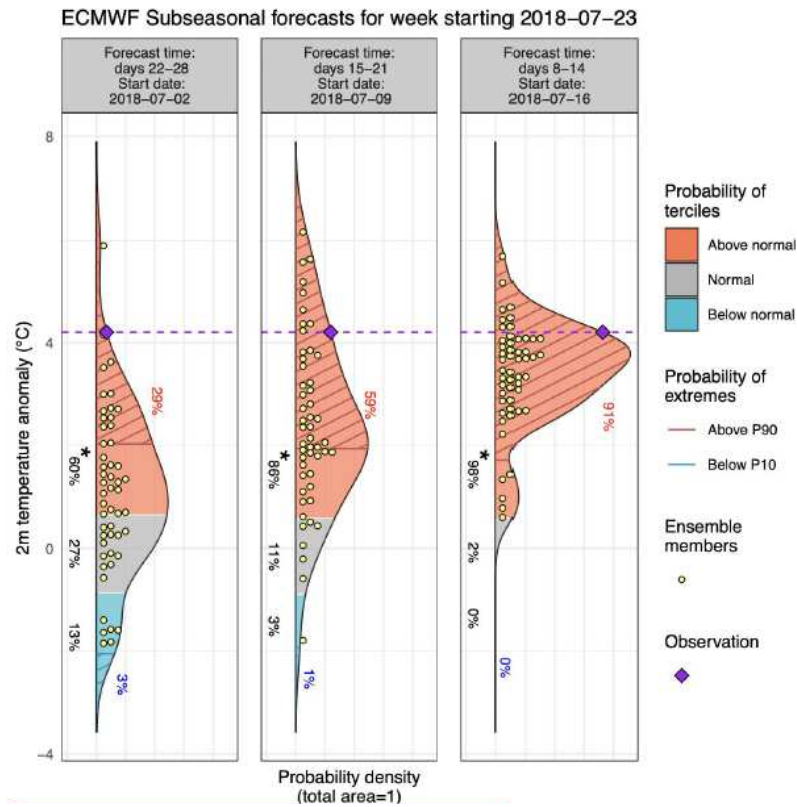


그림 1.2.3 European heat wave 2018 사례에 대한 ECMWF 예측 모델의 앙상블 확률분포와 관측자료 (Domeisen, Daniela IV, et al., 2022)

- 평균제곱근오차 및 박스플롯 분석 방법
 - 앙상블모델 예측 결과를 재분석자료와 비교하기 위해 평균제곱근오차 (RMSE; Root Mean Square Error) 분석 방법을 활용하였다. 또한 앙상블 멤버별로 평균제곱근오차를 산출하여 박스플롯 분석을 하였다. 박스플롯 분석은 자료로부터 얻어낸 통계량인 5가지 요약 수치를 통해 분석하는 방법으로써 최솟값, 제 1사분위(Q1), 제 2사분위(Q2), 제 3사분위(Q3), 최대값으로 구성되어있다. 이상치의 정의는 Q3와 Q1차의 1.5배에 해당하는 경우이다.
 - 본 연구에서는 앙상블 멤버별 평균제곱근오차를 박스플롯을 통해 분석함으로써 앙상블의 스프레드를 분석하였다.

$$RMSE = \sqrt{\frac{\sum(\hat{y} - y)^2}{n}}$$

(3) 앙상블 모델 예측 결과 분석

- 재분석자료 분석 결과
 - 앙상블모델의 북미 폭염 예측 결과 분석에 앞서 ERA5 재분석자료의 1000hPa 기온 아노말리 분포를 분석하였다. 북미 서부지역(빨간 네모 영역) 폭염은 6월 26일 00UTC부터 시작하여 7월 1일 12UTC까지 지속되었으며, 가장 높은 양의 아노말리를 보인 날짜는 6월 29일이다(그림 1.2.4-1.2.5).
 - 추후 모델 분석에서는 폭염이 가장 심했던 지역(빨간 네모 영역)에 대해 평균제곱근오차를 계산하여 분석하였고, 또한 가장 높은 양의 아노말리를 보인 6월 29일 00UTC와 12UTC를 목표날짜로 지정하고 분석하였다.

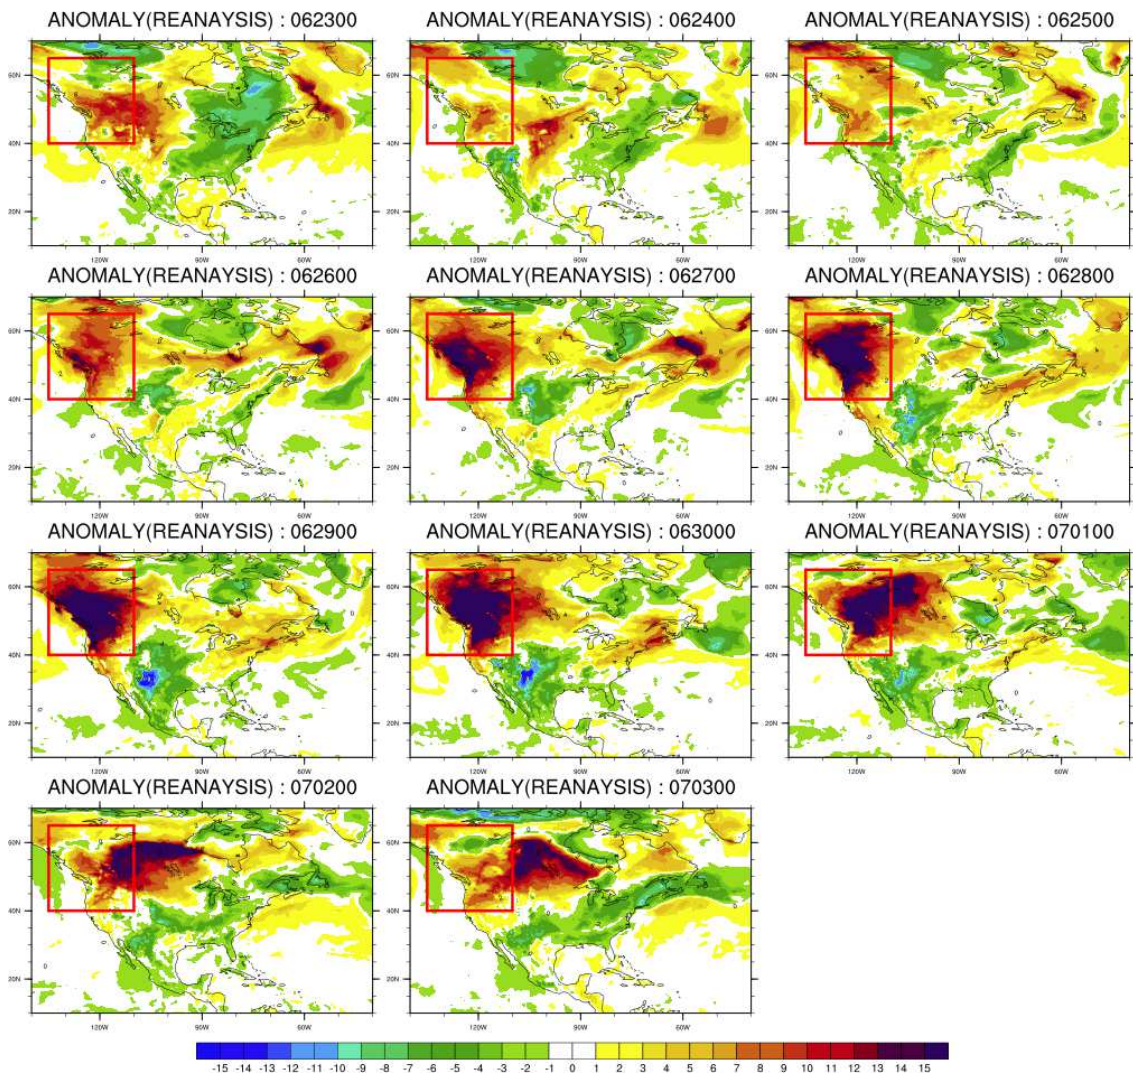


그림 1.2.4 초기시간 00UTC 모델 예측자료 분석을 위한
2021년 6월 23일 00UTC부터 7월 3일 00UTC까지 재분석자료 1000hPa 기온 분포

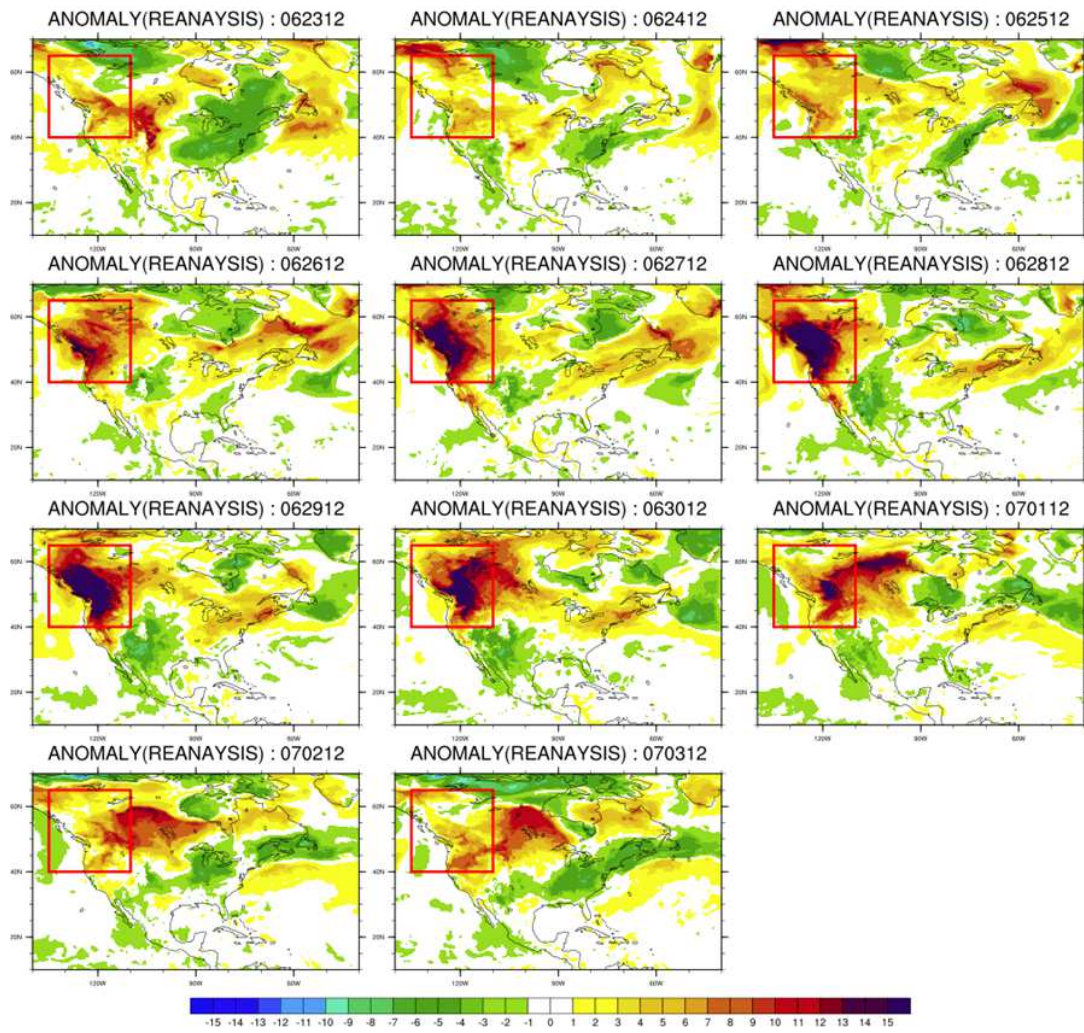


그림 1.2.5 초기시간 12UTC 모델 예측자료 분석을 위한
2021년 6월 23일 12UTC부터 7월 3일 12UTC까지 재분석자료 1000hPa 기온 분포

- 앙상블모델의 앙상블 평균 분석 결과
 - 한국형앙상블모델의 초기시간별 앙상블 평균 분석 결과(그림 1.2.6)를 보면, 초기시간 6월 19일 00UTC 예측자료로는 폭염을 전혀 예측하지 못하는 것을 확인할 수 있다. 초기시간 6월 21일 00UTC부터는 유효시간(Valid Time) 6월 27일 00UTC에 대해 일부지역에서 15°C 이상의 양의 아노말리를 예측하였지만 관측에 비해서는 과소모의하였다. 초기시간 6월 23일 00UTC의 예측자료를 보면 전체 유효시간에서 관측자료와 유사한 값의 아노말리 분포를 확인할 수 있다. 따라서 한국형앙상블모델의 경우 폭염 발생 6일 전 폭염 예측 가능성을 보였다.

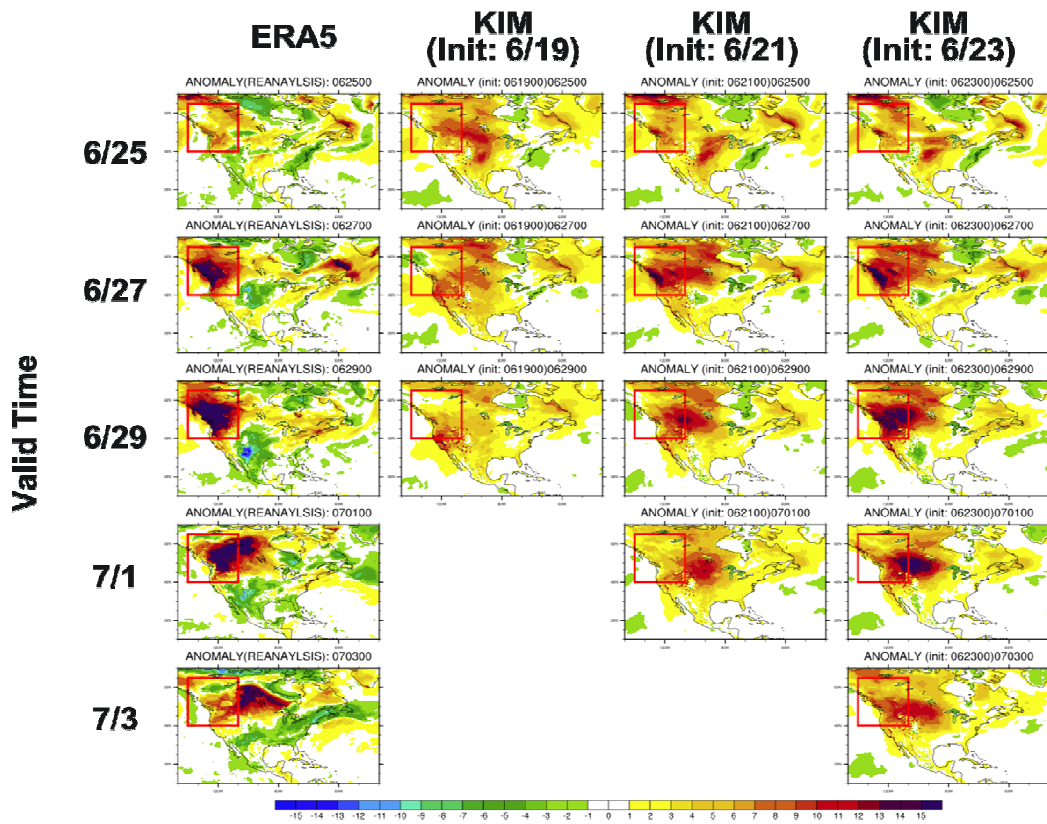


그림 1.2.6 한국형앙상블모델 초기시간별 앙상블 평균 분석 결과 (00UTC)

- ECMWF 앙상블모델 결과를 보면(그림 1.2.7), 한국형앙상블모델과 동일하게 초기시간 6월 19일 00UTC 예측자료에서는 폭염을 과소모의하는 경향이 있었다. 또한 초기시간 6월 21일 00UTC의 유효시간 6월 27일 00UTC 예측자료는 한국형앙상블 모델에 비해 관측과 더욱 유사한 분포를 보였다. 초기시간 6월 23일 00UTC의 예측자료의 경우 전체 분석기간에서 한국형앙상블모델에 비해 폭염 강도측면에서 높은 예측성능을 보였다.

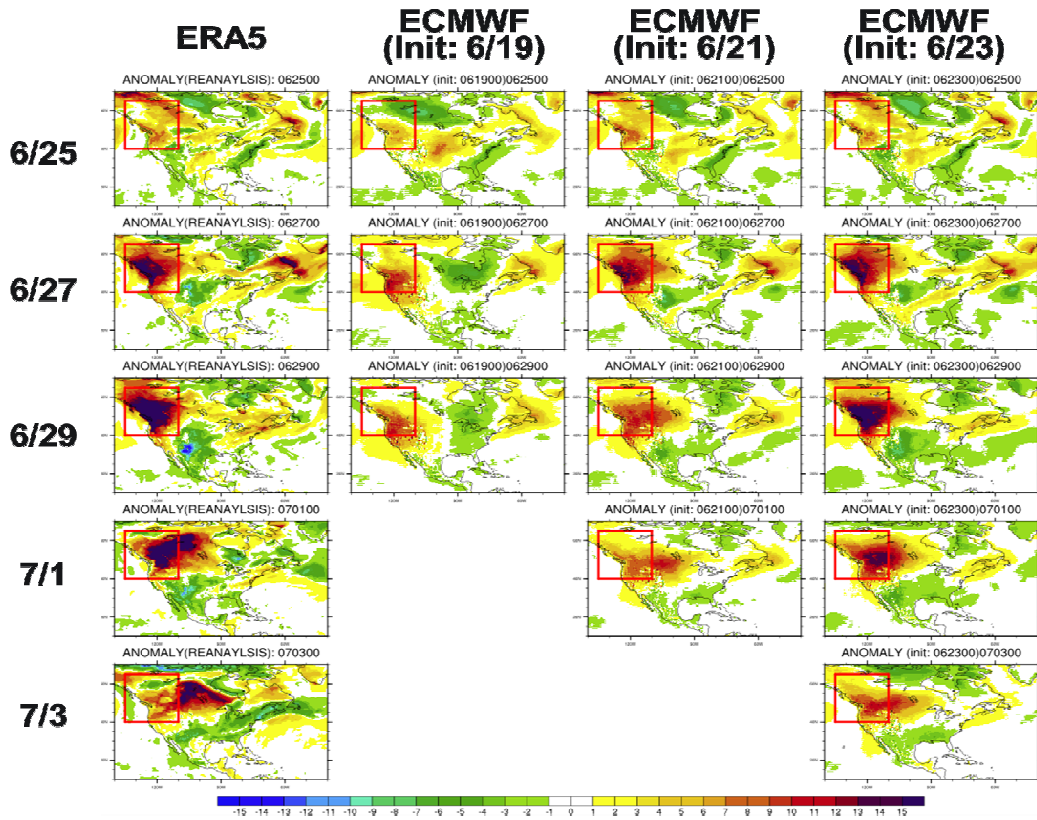


그림 1.2.7 ECMWF 앙상블모델 초기시간별 앙상블 평균 분석 결과 (00UTC)

- 한국형양상블모델의 초기시간 12UTC 예측자료 분석 결과를 보면(그림 1.2.8), 폭염 발생 6일전 높은 예측성능을 보인 한국형양상블모델의 초기시간 00UTC 예측 결과(그림 1.2.6)에 비해, 전체 분석기간에 대해 아노말리가 관측에 비해 매우 낮게 나타났다.

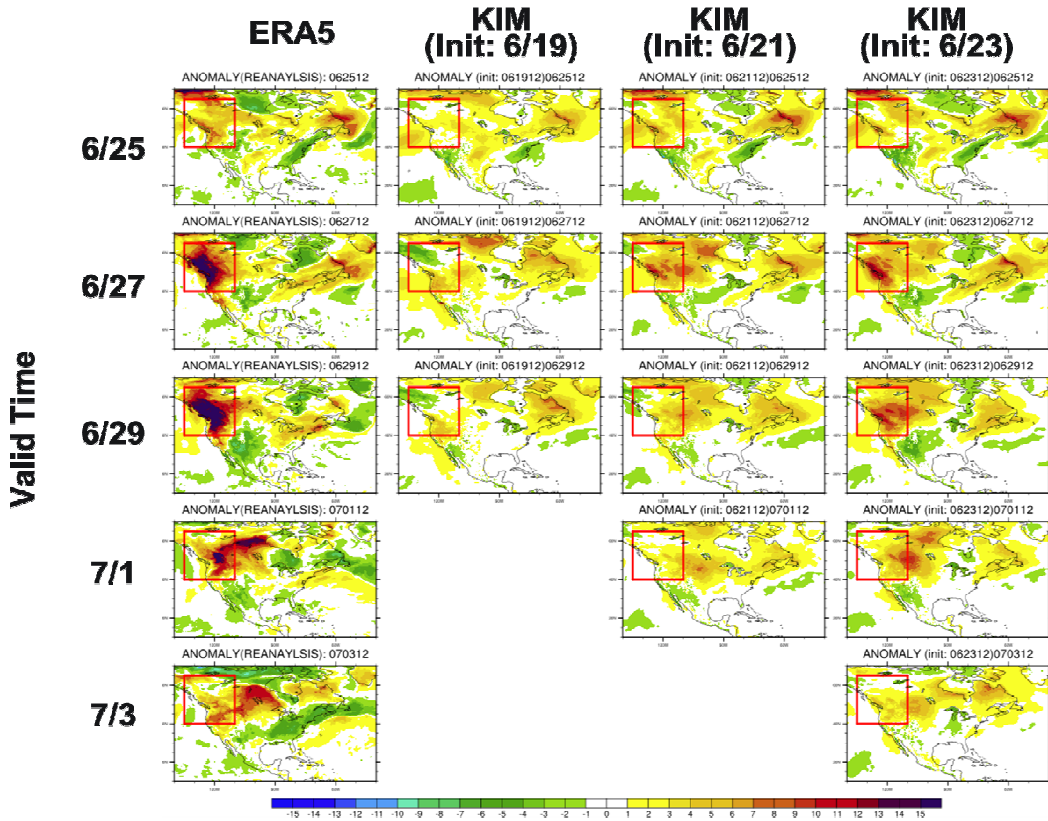


그림 1.2.8 한국형양상블모델 초기시간별 양상블 평균 분석 결과 (12UTC)

- ECMWF 앙상블모델의 초기시간 12UTC 예측 결과를 보면(그림 1.2.9), 한국형앙상블모델의 12UTC 과소모의 경향은 ECMWF 앙상블 모델에서는 나타나지 않았다. 또한 ECMWF 앙상블 모델은 초기시간 12UTC 예측 결과와 초기시간 00UTC 예측 결과가 유사하여 한국형앙상블모델에 비해 높은 안정성을 보였다.

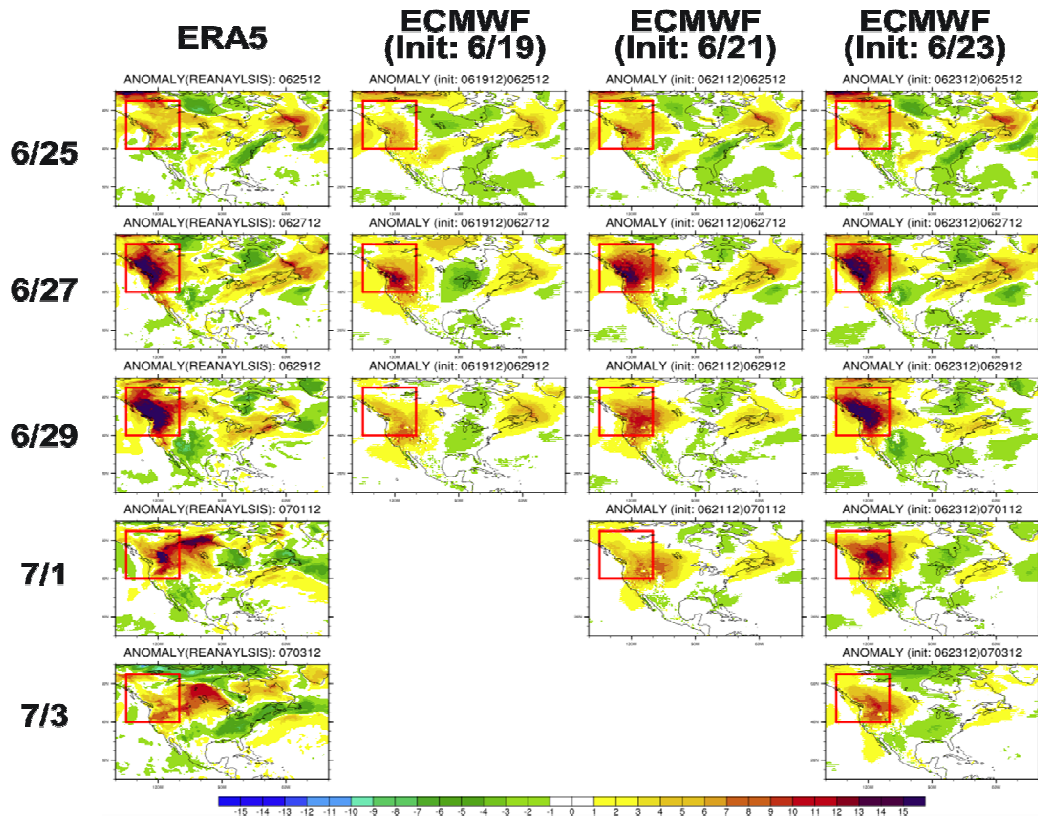


그림 1.2.9 ECMWF 앙상블모델 초기시간별 앙상블 평균 분석 결과 (12UTC)

- 앙상블모델의 박스플롯 분석 결과
 - 앙상블모델의 스프레드 분석을 위해 북미 서부 지역(빨간색 네모 박스)에 대해 앙상블 멤버 별로 평균제곱근오차를 산출하여 박스플롯 분석을 진행하였다. 앙상블 스프레드는 평균제곱근오차 최댓값과 최솟값의 차로 평가하였다. 그림 1.2.10은 한국형앙상블모델(회색 박스플롯)과 ECMWF 앙상블모델(노란 박스플롯)의 앙상블멤버의 평균제곱근오차를 박스플롯을 통해 나타내었고 이때 각 모델의 앙상블 평균의 평균제곱근오차를 동시에 표시하였다(회색실선: 한국형앙상블모델 앙상블평균, 노란실선: ECMWF 앙상블모델 앙상블평균).
 - 초기시간 00UTC 분석의 앙상블 평균 결과를 보면, 초기시간 6월 21일 00UTC까지 한국형앙상블모델과 ECMWF 앙상블모델의 예측성능이 유사하게 분포하였지만, 이후 두 모델간 앙상블 평균차이가 1°C 이상 차이가 나타났다.
 - 같은 초기시간에 앙상블 스프레드를 보면 두 모델 모두 초기시간이 목표시간(6월 29일)에 가까워질수록 스프레드가 작아지고 예측성도 높아지는 경향을 보였다. 또한 전반적으로 한국형앙상블모델이 ECMWF 앙상블 모델에 비해 스프레드가 크게 나타났다.
 - 초기시간 12UTC의 앙상블 평균 분석 결과는 00UTC 예측 결과와 다르게 초기시간 6월 19일 12UTC부터 두 모델간 평균제곱근오차가 약 2.3°C 차이로 매우 크게 나타났다. 이러한 경향은 24시간 예측 결과인 초기시간 6월 28일 12UTC 예측결과에서도 마찬가지로 나타났다.




그림 1.2.10 앙상블 모델 초기시간별 평균제곱근오차(°C) 박스플롯 분석 (Target time: 6/29, 초기시간 00UTC(위)/12UTC(아래), 회색박스플롯: 한국형앙상블모델, 노란박스플롯: ECMWF 앙상블모델, 회색실선: 한국형앙상블모델 앙상블평균, 노란실선: ECMWF 앙상블평균)

- 앙상블모델의 앙상블 확률분포 분석 결과
 - 앙상블모델의 앙상블 멤버들의 폭염에 대한 예측확률 분석을 위해 확률 밀도함수를 나타내었다. 그림 1.2.11의 확률분포를 구성하는 점은 앙상블의 각 멤버를 의미하고 파란 점은 초기시간 00UTC, 빨간 점은 12UTC를 의미한다. 파란 점선은 재분석자료의 00UTC 기온이고, 빨간 점선은 12UTC의 기온, 검은 점선은 00UTC와 12UTC 기온의 평균이다.
 - 한국형앙상블모델의 초기시간 6월 19일부터 6월 28일까지 목표시간 6월 29일에 대한 1000hPa 기온 아노말리의 확률분포분석 결과, 초기시간 6월 19일의 경우 00UTC와 12UTC 모두 예측 확률이 없었지만, 초기시간 6월 21일부터 00UTC에 대한 예측확률이 증가하였다. 하지만 초기시간 6월 25일부터 6월 28일까지 결과를 보면 00UTC 기온에 대해 약 1°C 이상 과대 모의하는 경향이 있었고, 12UTC는 약 2°C 정도의 과소모의 경향이 나타났다.

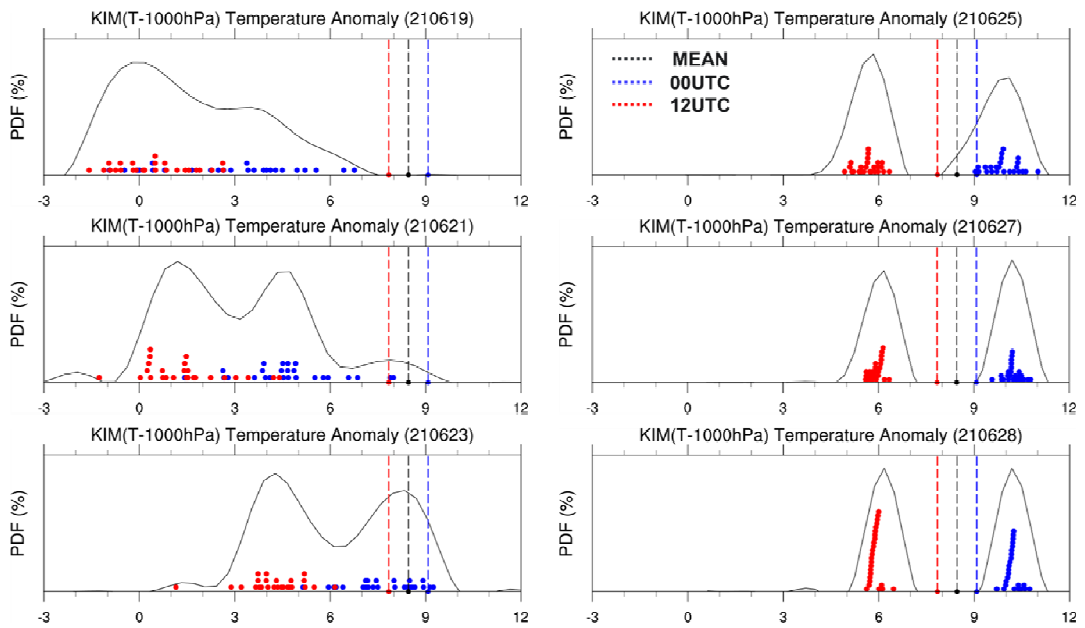


그림 1.2.11 KIM, ECMWF 모델의 초기시간별 확률분포 분석 결과 (점선은 관측자료를 의미, 검은 점선: 00/12UTC 평균, 파란 점선: 00UTC, 빨간 점선: 12UTC)

- ECMWF 앙상블모델의 앙상블 멤버의 확률분포 분석 결과는 초기시간 6월 21일부터 00UTC와 12UTC에서 폭염 예측 확률이 발생하였고, 6월 23일부터 관측과 가까운 확률분포를 보였다. 또한 한국형앙상블모델의 경우 00UTC와 12UTC 각각 과대, 과소 모의하는 경향으로 인해 양봉형 확률 분포를 보인 반면, ECMWF 앙상블모델은 단봉형 확률분포를 보여 상대적으로 안정성 있는 예측성을 보였다.

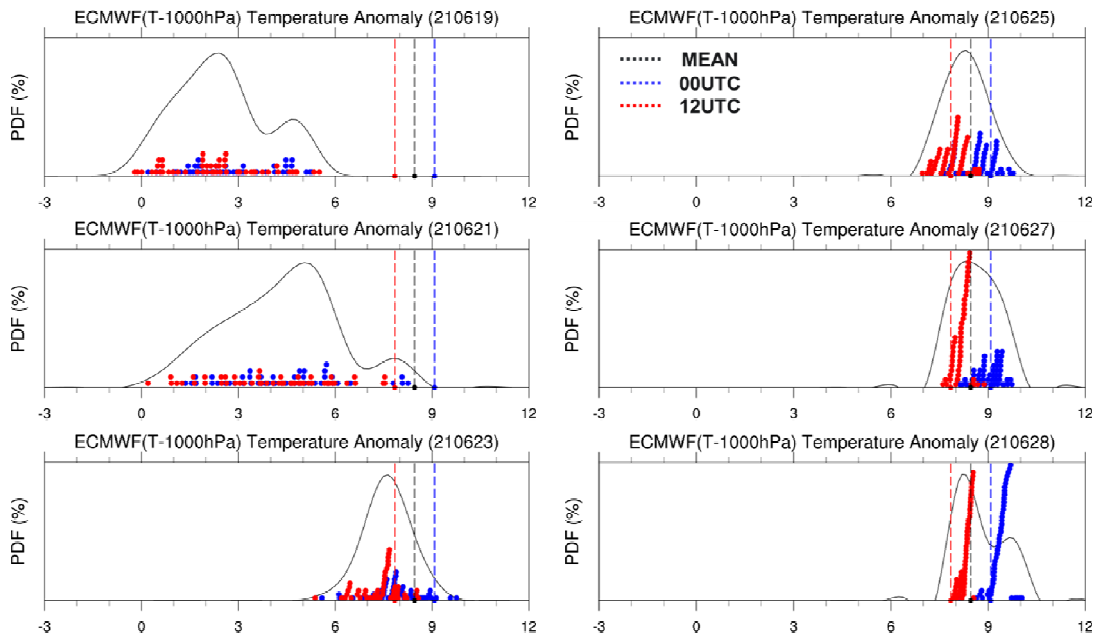


그림 1.2.12 KIM, ECMWF 모델의 초기시간별 확률분포 분석 결과 (점선은 관측자료를 의미, 검은 점선: 00/12UTC 평균, 파란 점선: 00UTC, 빨간 점선: 12UTC)

- 폭염사례를 통한 한국형앙상블모델의 모의특성 분석
 - 앞장의 분석을 통해 한국형앙상블모델의 초기시간 12UTC에서의 큰 오차를 확인하였다. 본 연구진은 12UTC에서의 오차 발생 원인을 파악하고자 먼저 분석장(+00h, 초기예측장)의 재분석자료와의 편차에 대해 분석하였다 (그림 1.2.13).
 - 초기시간 00UTC의 분석장과 24시간 예측장을 보면 재분석자료와의 오차가 크지 않은 것을 확인할 수 있다. 하지만 12UTC에서 큰 음의 편차 (약 -7°C)를 보였고 이러한 문제는 예측장 뿐만 아니라 분석장에서도 강한 음의 편차를 보였다.

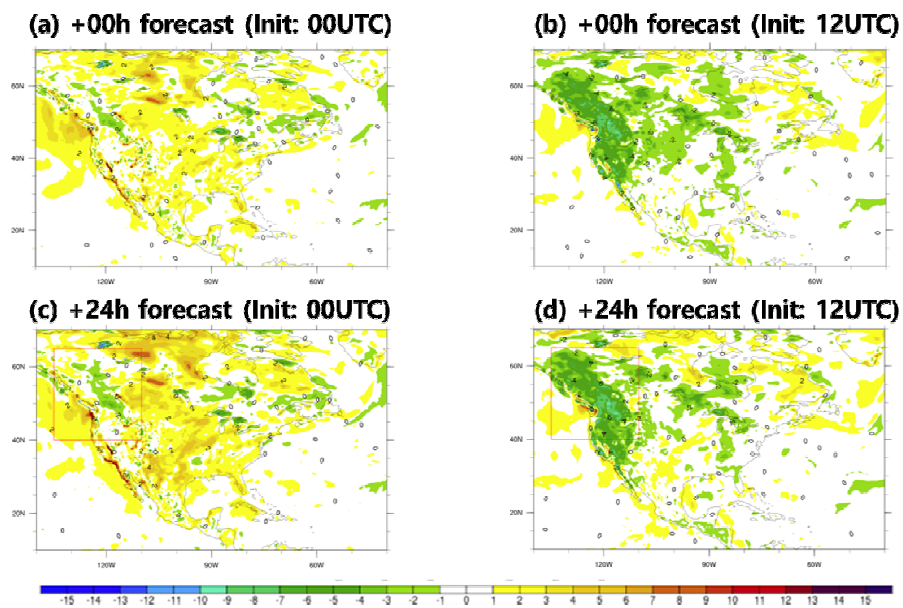


그림 1.2.13 한국형앙상블모델의 초기시간 00/12UTC의 1000hPa 기온 바이어스 분석장 (a-b) 및 24시간 예측장 (c-d) (Target Time: 2021.06.29)

- 분석장에서도 나타나는 강한 음의 편차의 원인으로서는 자료동화 문제, 1000hPa 등압면에서 육지 보간 문제가 있을 수 있다. 이러한 문제를 확인하기 위해 한국형앙상블모델의 2m 기온 편차를 분석하였다 (그림 1.2.14).
- 2m 기온의 분석장에서는 초기시간 00UTC에 약 -5°C 의 음의 편차가 나타났고 초기시간 12UTC에는 약 6°C 의 양의 편차가 나타났다.
- 분석 결과를 요약하면, 한국형앙상블모델에는 분석장에서부터 큰 편차가 있음을 확인하였고, 이는 1000hPa 기온 뿐만아니라 2m 기온에서도 확인되었다. 이러한 문제를 개선하기 위해서는 육지보간 문제와 자료동화 문제 등을 해결해야 할 것으로 사료 된다.

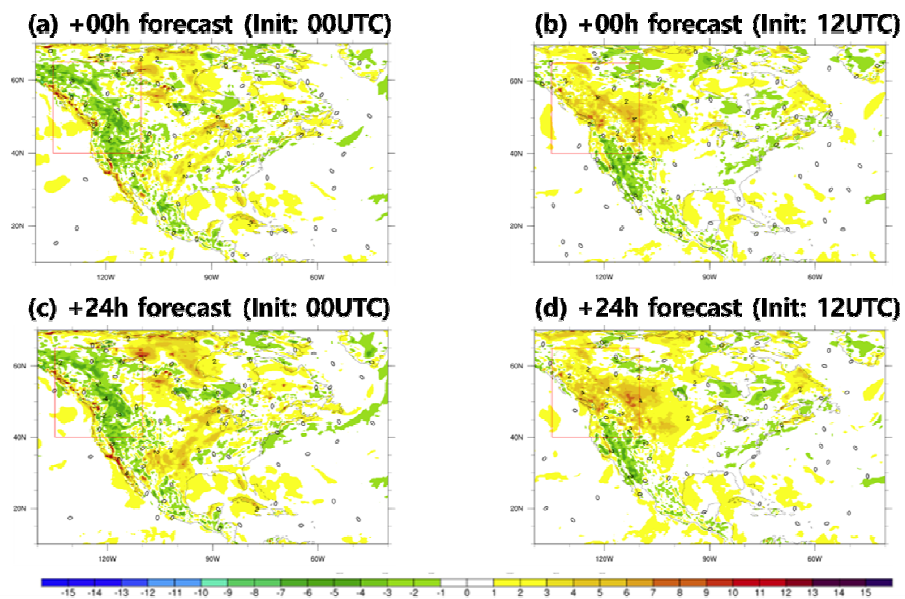


그림 1.2.14 한국형앙상블모델의 초기시간 00/12UTC의 2m 기온 바이어스 분석장 (a-b) 및 24시간 예측장 (c-d) (Target Time: 2021.06.29)

(4) 우리나라 짧은 장마 사례 분석

- 우리나라 짧은 장마 발생 개요
 - 2021년 장마철은 1982년 이후 가장 늦은(제주 기준) 7월 3일에 시작하고, 7월 19일에 종료하였다 (그림 1.2.15; 표 1.2.2). 이는 중부·제주 기준으로 역대 3번째로 짧은 장마철이었다. 장마가 짧아짐에 따라 전국 강수량 또한 227.5mm로 평년의 64.5%에 해당하였고, 강수일수는 9.9일로 평년의 57.4%를 기록하였다.




그림 1.2.15 2021년 7~8월 강수량 일별 시계열 (출처: 2021년 이상 기후보고서, 기상청)

표 1.2.2 2021년과 평년(1991~2020년)의 장마철 시작일과 종료일 및 기간

(출처: 2021년 이상 기후보고서, 기상청)

	2021년			평년		
	시작	종료	기간(일)	시작	종료	기간(일)
중부	7.3.	7.19.	17	6.25.	7.26.	31.5
남부	7.3.	7.19.	17	6.23.	7.24.	31.4
제주	7.3.	7.19.	17	6.19.	7.20.	32.4

※ 1973년 이후 연속적으로 관측자료가 존재하는 중부 26개, 남부 36개, 제주 4개 지점 관측값 사용

- 2021년 장마철이 짧았던 이유는 장마철이 늦게 시작되고 일찍 종료되었기 때문인데, 장마철이 늦게 시작된 원인으로는 6월 하순 우리나라 북쪽에 차고 건조한 기압골이 자주 통과하였고, 인도양과 열대 서태평양에서 평년 대비 하강기류가 형성되면서 북태평양고기압의 확장과 정체전선의 북상이 지연되었기 때문이다. 이로 인해 장마가 평년 대비 약 14일 늦게 시작하였다. 이와 더불어 북태평양고기압도 평년보다 이르게 북쪽으로 확장하면서 장마철이 일찍 종료되었다 (그림 1.2.16).

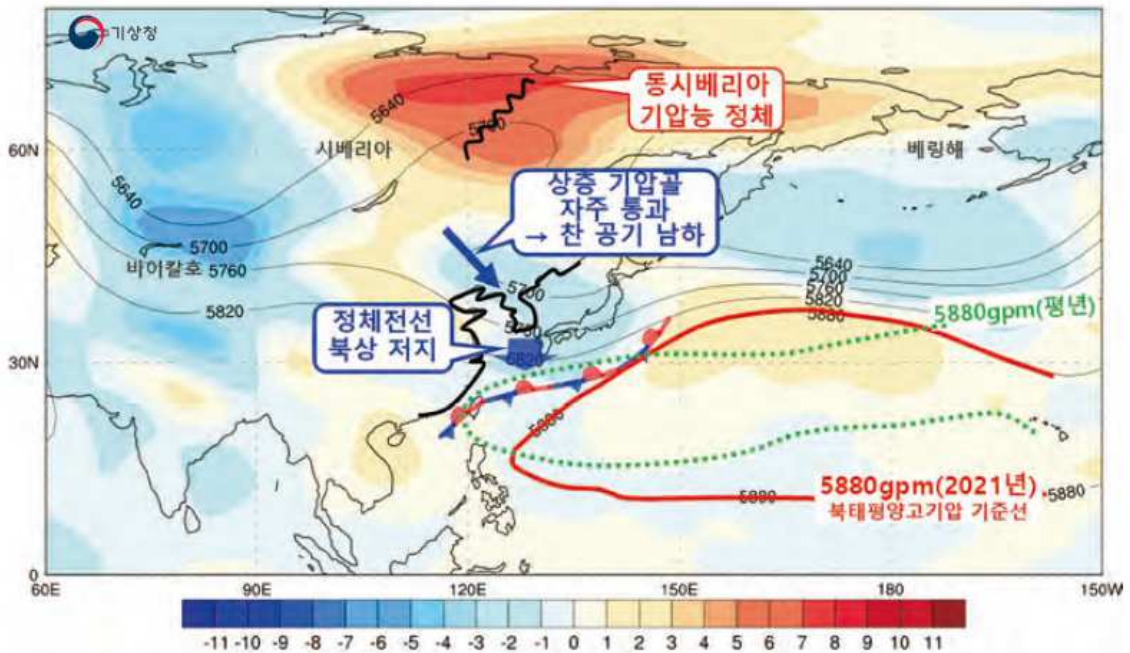


그림 1.2.16 6월 19~30일 500hPa 지위고도 분포 (빨강/파랑 채색: 평년보다 높/낮은 지위고도)
(출처: 2021년 이상 기후보고서, 기상청)

(5) 한국형앙상블모델을 활용한 짧은 장마 사례 분석 방법

- 패턴상관계수 분석 방법

- 폭염 분석과는 다르게 강수량은 연속성이 없고, 장마전선의 위치가 중요하기 때문에 평균제곱근오차 분석 방법이 아닌 패턴상관계수(PCC; Pattern Correlation Coefficient) 분석 방법을 통해 한국형앙상블모델의 짧은 장마 사례를 분석하였다. 패턴상관계수는 두 개의 서로 다른 지도의 각 위치에서 두 변수간의 선형 상관관계의 Pearson 계수이다. 패턴상관계수는 1에 가까울수록 높은 예측성을 의미한다.

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

- 장마 지수 분석 방법

- 한국형앙상블모델의 장마 사례에 대한 예측성능 분석을 위해 기상청 ‘손에 잡히는 예보 기술, 2012년 6월 장마 전선 편’에서 제시하는 장마 지수를 활용하여 장마사례를 분석하였다. 장마 지수는 우리나라의 위/경도를 고려하여 장마의 시작과 종료 지점을 분석한다. 장마지수는 상층 200hPa 고도의

장마철 특징을 반영하며, 경도 122.5~132.5E 사이의 평균값을 아래 수식과 같이 산출한다. 처음 두 항은 장마의 시작을, 마지막 항은 장마의 종료를 반영하며, 장마의 시작 시 이론적 값은 100%이다.

▶장마지수 = Value1 + Value2 + Value3		
Value1 = ((GPH36-12000)*0.2)	if GPH36 < 12350	
= 75	if GPH36 ≥ 12350	
Value2 = 25.0	if V27 < 10m/s	
= 0.0	if V27 > 35 m/s	
= 35.0 - V27	if 10 ≤ V27 ≤ 35m/s	
Value3 = GPH45-12300	if GPH45 ≥ 12300	
= 0.0	if GPH45 < 12300	
여기서, GPH36 = 200 hPa의 36.25N 동서고도 평균값		
V27 = 200 hPa의 27.5N 동서바람 평균값		
GPH45 = 200 hPa의 45N 동서고도 평균값		

그림 1.2.17 '손에 잡히는 예보 기술'에 적힌 잘못된 장마 지수

- 본 연구진이 '손에 잡히는 예보 기술'이 제시하는 장마 지수 수식을 활용하여 적용해보았을 때, 장마지수 값이 이상치가 나타났다. 이를 해결하기 위해 여러 시도를 해보았고 장마 지수 수식의 마지막 항을 더하는 것이 아닌 뺀을 때 정확한 값이 나오는 것을 확인하였다. 이렇게 수정된 장마지수 수식은 기상청과의 교차검증을 통해 올바른 식임을 확인하였다 (그림 1.2.18).

▶장마지수 = Value1 + Value2 - Value3		
Value1 = ((GPH36 - 12000) × 0.2)	if GPH36 < 12350 m	
= 75.0	if GPH36 ≥ 12350 m	
Value2 = 25.0	if V27 < 10 m/s	
= 0.0	if V27 > 35 m/s	
= 35.0 - V27	if 10 ≤ V27 ≤ 35 m/s	
Value3 = GPH45 - 12300	if GPH45 ≥ 12300m	
= 0.0	if GPH45 < 12300m	
		200hPa 기준
		GPH36 : 36.25N 동서고도 평균값
		V27 : 27.50N 동서바람 평균값
		GPH45 : 45.00N 동서고도 평균값

그림 1.2.18 잘못된 장마 지수를 수정한 수식

- 장마지수를 활용한 장마기간 정의
 - 재분석자료를 장마지수 수식에 적용하여 분석한 결과 (그림 1.2.19), 기상청 공식 장마 시작일과 종료일이 각각 7월 3일과 7월 19일임에 반해, 공식 장마 시작일 보다 하루 앞선 7월 2일에 장마지수가 100%를 기록하였고, 공식 종료일보다 한참 앞선 7월 9일을 마지막으로 100% 미만으로 장마지수가 감소하였다. 기상청의 공식 종료 기간과 재분석자료를 이용한 장마지수의 종료기간은 장마의 정의가 다르기 때문에 확연한 차이를 보이는 것을 확인할 수 있다.

- 본 연구에서는 앙상블 멤버별 장마 예측성능을 분석하기 위해 재분석자료 장마지수를 기준으로 장마지수가 처음 100%가 된 7월 2일을 장마시작일, 장마지수가 마지막으로 90% 이하로 떨어진 날짜인 7월 11일을 장마종료일로 정의하였다.

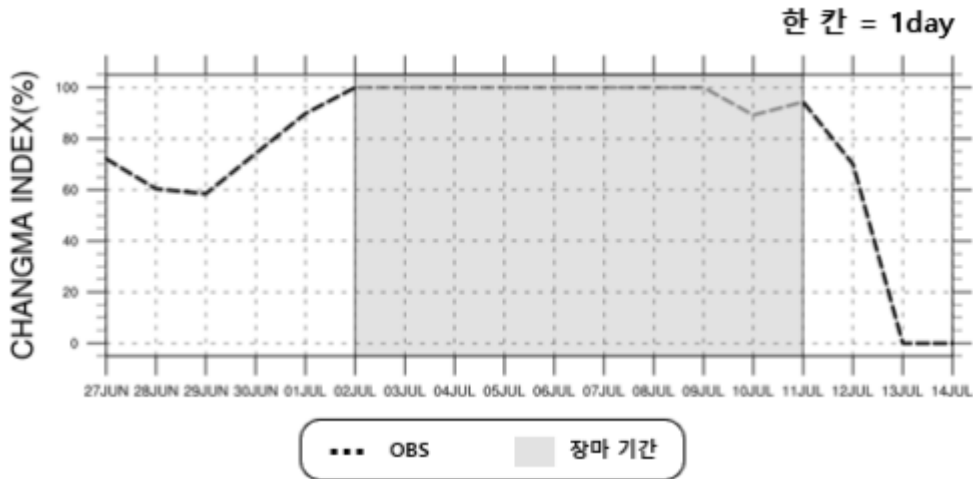


그림 1.2.19 2021년 6월 27일부터 7월 14일까지의 장마 지수
(00UTC 기준, 검은 점선: 관측값, 회색 칸: 선정된 장마 기간)

(6) 앙상블 모델 예측 결과 분석

- 관측자료 분석 결과
 - 한국형앙상블모델의 짧은 장마사례 예측 결과 분석에 앞서 NASA의 GPM (Global Precipitation Measurement Mission) 관측자료의 일 누적 강수량으로 동아시아 지역의 강수량 분포 및 장마 위치를 분석하였음 (그림 1.2.20). 재분석자료 장마지수를 통해 새로 정의한 장마기간인 7월 2일부터 7월 11일까지 강수량 분포를 보면 해당기간에 한반도에 강수량이 분포하고 이후에는 한반도에 강수가 없는 것을 확인할 수 있었고, 강수량이 가장 많은 일자는 7월 5일과 6일이었다.

GPM RAW DATA20210701-20210721

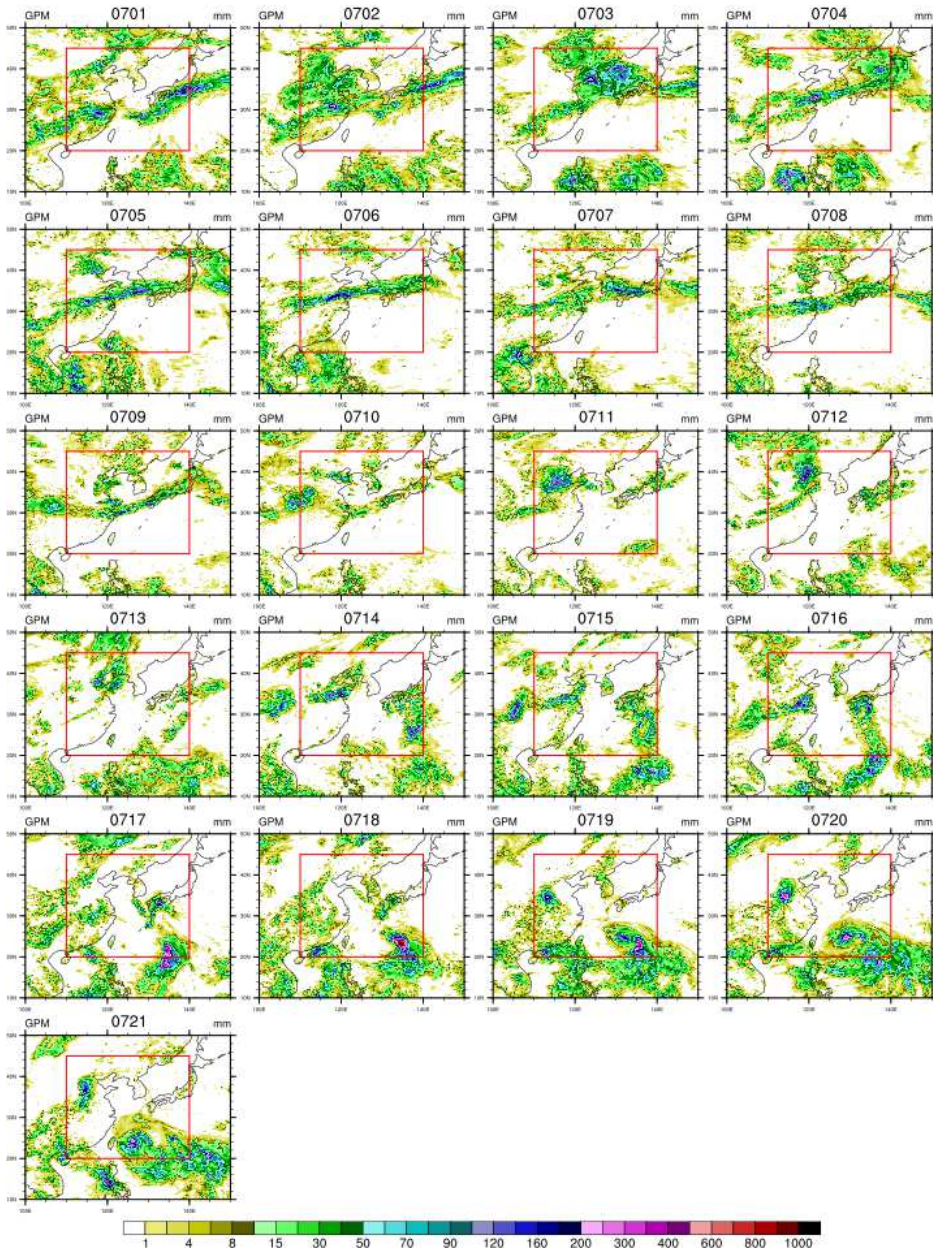


그림 1.2.20 2021년 7월 1일부터 7월 21일까지 동아시아 지역 1일 누적 강수량 분포(00UTC 기준)

- 앙상블 모델의 앙상블 박스플롯 분석 결과
 - 장마의 시작일과 종료일에 대한 한국형앙상블모델의 예측성능 평가를 위해 한반도를 포함한 지역(빨간색 네모 영역)에 대해 앙상블 멤버별로 각각 패턴상관계수를 산출하고, 앙상블 멤버의 박스플롯 분석을 진행하였다 (그림 1.2.21-1.2.22).
 - 먼저 장마 시작일일 때, 초기시간 00/12UTC의 앙상블 평균을 보면 전반적으로 앙상블 멤버들의 패턴상관계수에 비해 앙상블 평균이 높은 패턴상관계수를 확인할 수 있다. 장마시작일에 대한 예측성 향상은 초기시간 6월 28일까지 변동이 컸지만, 이후 지속적으로 향상되었고 장마 발생 2일전(00UTC)/3일전(12UTC)부터 상관계수 0.5 이상을 기록하였다.




그림 1.2.21 예측일 2021년 7월 2일 기준 6월 21일부터 7월 2일의 강수량 패턴상관계수 박스플롯 분석 (회색 실선: 앙상블 멤버 평균)

- 장마 종료일에 대한 앙상블 평균 분석을 보면(그림 1.2.22), 장마 종료 9일 전부터 패턴상관계수가 0.5 이상으로 높은 예측성을 보임을 확인할 수 있다. 이는 장마 시작일에 대한 예측보다 종료일에 대한 예측성이 매우 높은 것을 확인하였다.
- 앙상블 스프레드의 경우 장마 종료일에 대한 스프레드가 시작일 스프레드에 비해 넓은 것을 확인하였고 이는 멤버별로 예측성 차이가 크게 나타남을 의미한다.

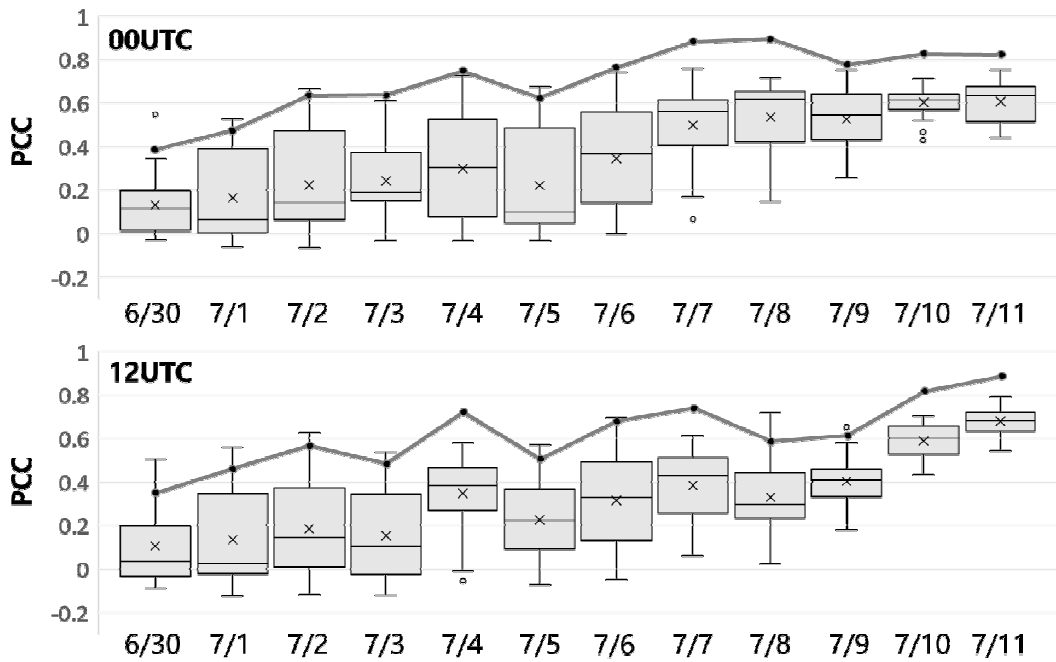


그림 1.2.22 예측일 2021년 7월 11일 기준 6월 30일부터 7월 11일의 강수량 패턴상관계수 박스플롯 분석(회색 실선: 앙상블멤버 평균)

- 앙상블모델의 장마지수 분석 결과

- 한국형앙상블모델의 앙상블 멤버별 장마지수 분석을 위해 6월 27일부터 7월 14일까지를 고정하고 모델의 초기시간 별로 장마지수 시계열을 재분석 자료와 비교하였다 (그림 1.2.23). 본 연구에서 정의한 장마기간은 회색으로 표시하였고, 재분석자료의 장마지수는 검은 점선, 앙상블 평균은 빨간 실선, 앙상블 멤버의 장마지수는 얇은 빨간 실선으로 구성하였다.
- 한국형앙상블모델의 앙상블 멤버의 장마지수 분석 결과, 예측시간이 길어짐에 따라 장마지수의 스프레드가 커지는 것을 확인하였다. 하지만 앙상블 평균의 장마지수의 경우 매우 높은 장마 예측성을 보여주는데, 장마 시작일에 대한 초기시간 6월 21일 00UTC 장마지수 예측성을 보면 장마시작일 11일 전부터 장마시작일을 예측한 것을 확인할 수 있다. 패턴상관계수가 0.5 이상일 때가 2일 전임을 감안 한다면 매우 높은 예측성을 보였다.

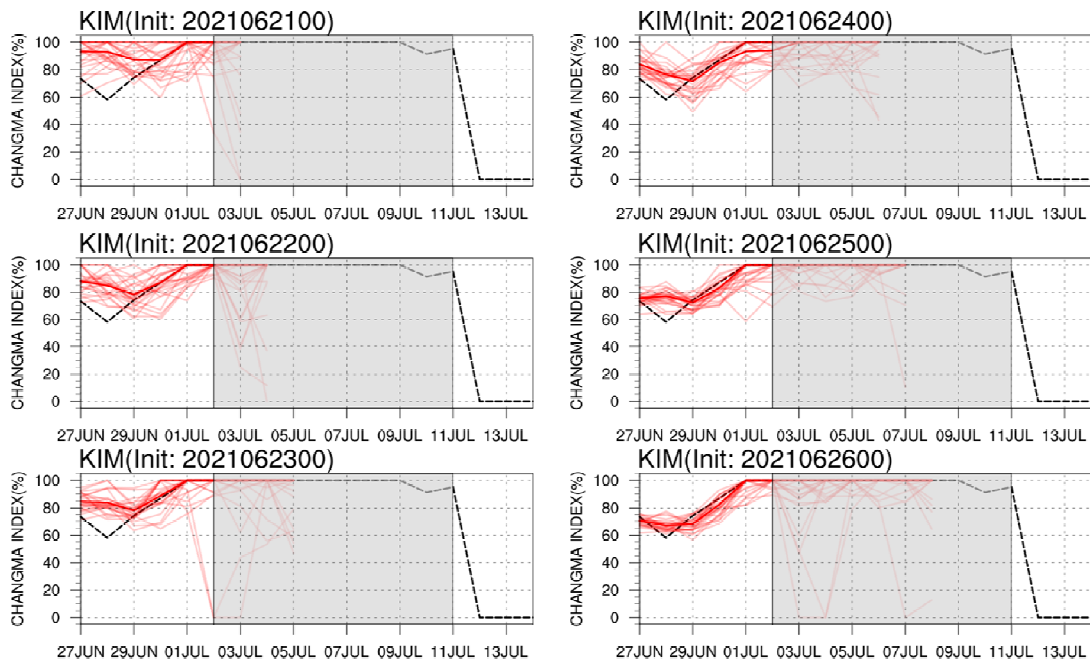


그림 1.2.23 2021년 6월 27일부터 7월 14일까지의 장마 지수, 초기시간 6/21~6/26

(검은 점선: 관측, 회색 칸: 장마 기간, 진한 빨간 선: 앙상블 평균, 얇은 빨간 선: 앙상블 멤버)

- 장마종료일에 대한 장마지수는 초기시간 6월 30일 00UTC의 예측 장마지수를 보면 양상블 평균의 장마지수가 장마종료일을 정확하게 모의한 것을 확인할 수 있다. 이는 장마 종료일 약 11일 전 예측자료를 통해 장마종료일을 예측한 것이다.
- 따라서 장마지수를 활용한 장마 시종 예측이 강수패턴 예측에 비해 높은 예측성을 보임을 확인하였다.

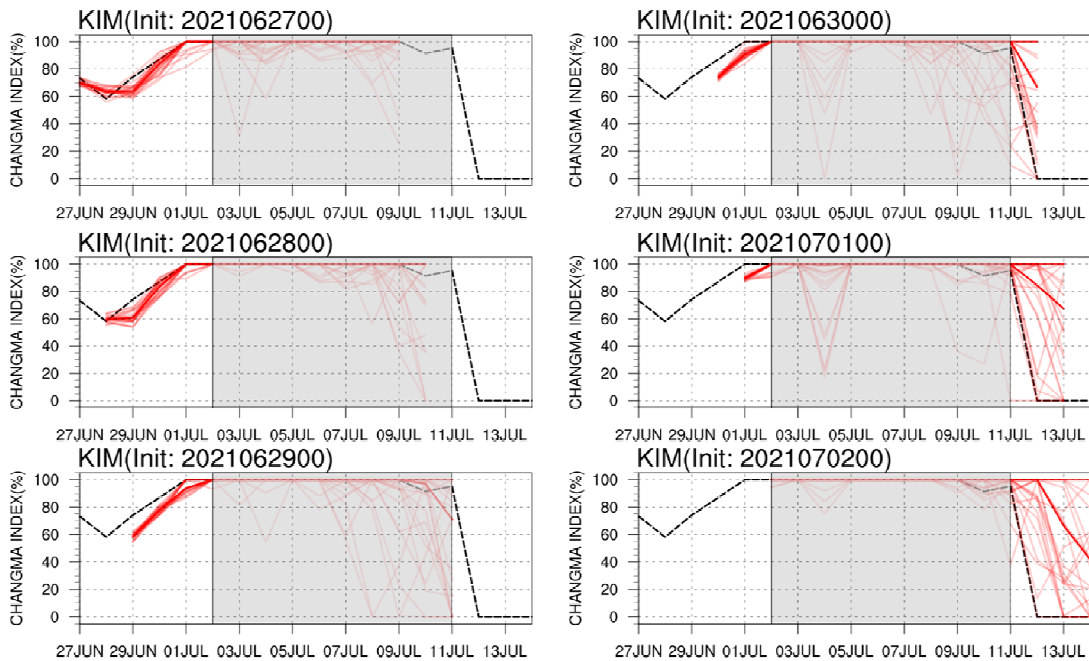


그림 1.2.24 2021년 6월 27일부터 7월 14일까지의 장마 지수, 초기시간 6/27~7/2

(검은 점선: 관측, 회색 칸: 장마 기간, 진한 빨간 선: 양상블 평균, 얇은 빨간 선: 양상블 멤버)

- 짧은 장마사례를 통한 한국형양상블모델의 모의특성 분석
 - 2021년 7월 짧은 장마사례 분석을 통해 장마시작일에 대한 패턴상관계수 예측성은 최소 2일 전에 예측가능성을 보였고, 장마종료일에 대한 예측성은 9일전으로 시작일에 비해서 높은 예측성을 확인하였다.
 - 장마에 대한 예측성은 장마지수 분석을 통해 항상 가능성을 보였는데, 장마종료일에 대한 장마 지수 예측성은 11일 전에 예측 가능성을 보였다. 이는 장마지수 수식을 구성하는 요소들이 200hPa의 변수들로 구성되어, 지상 강수량의 예측성능보다 비교적 높은 예측성을 보이는 상층 변수들로 구성되어 있어 장마지수에 대한 예측성이 향상된 것으로 판단된다.

요약문

극한기상현상에 대한 한국형앙상블모델의 예측성능을 평가하기 위해 2021년 6월 북미 서부지역의 폭염 사례와 2021년 7월 우리나라 짧은 장마 사례에 대해 분석하였다. 한국형앙상블모델의 폭염사례에 대한 예측성은 ECMWF 앙상블 모델과 앙상블 스프레드는 유사하였지만, 앙상블 평균에 대한 예측성이 ECMWF 앙상블 모델과의 평균제곱근오차 차이가 초기시간 00UTC에는 약 1°C , 12UTC에서는 약 2.3°C 로 낮은 예측성능을 보였다. 특히 초기시간 12UTC에는 강한 음의 편차를 보였는데 이는 분석장 분석 및 지면 변수(2m 기온) 분석을 통해 자료동화에 문제가 있을 수 있음을 제시하였다.

한국형앙상블 모델의 짧은 장마 사례에 대한 예측성은 장마 시작일과 종료일에 따라 매우 큰 예측성 차이를 보였다. 장마시작일에 대한 장마패턴의 예측성은 2일 전으로 낮은 예측성을 보인 반면, 장마종료일에 대한 예측성은 패턴상관계수가 약 9일 전에 0.5 이상으로 나타나 높은 예측성능을 보였다. 장마시작일에 대한 낮은 장마패턴 예측성은 장마지수를 통해 보완될 수 있음을 보였고 장마 시작일은 11일전 예측자료를 통해 장마시작일을 정확하게 모의하였다.

2.3 한국형앙상블모델의 Spread 특성 분석

(1) 분석 개요

국외 앙상블모델과의 섭동기법 비교 분석

- UM 예보 모델 결과의 확보: 다양한 분석을 위해 활용 가능한 예보 모델의 결과를 확보하고자 하며, UM 예보 모델 외에도 ECMWF 등 다양한 예보 모델과 비교를 위해 자료 확보를 진행하였다. 이러한 자료는 한국형앙상블모델 결과의 기간과 일치하고 가능한 많은 앙상블 자료 확보를 진행하여 수행하였다.

앙상블 spread와 앙상블 에러의 상관성 분석

- 앙상블 멤버 분포 기반의 정량적·통계적 분석을 수행하기 위해 기본적인 RMSE와 상관성(Correlation) 분석을 수행하였다. 이러한 분석의 결과는 그림 1.3.1과 같이 단일 모델에 다른 자료동화기법들을 활용한 결과로 직접적인 비교에는 한계가 존재하나, 특정 지역에서 정량적인 자료동화기법에 대한 차이를 확인할 수 있다.

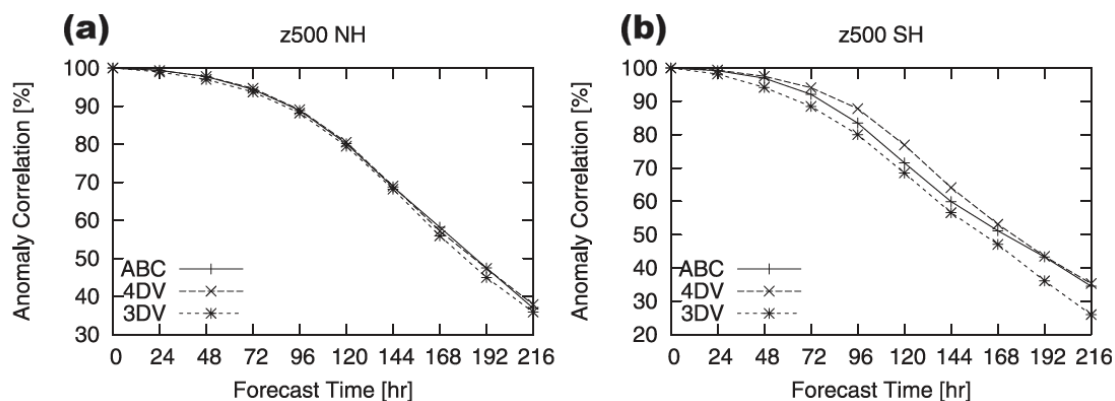


그림 1.3.1 Fig.11 of Miyoshi et al. 2010 [Miyoshi, T., Y. Sato, and T. Kadowaki, 2010: Ensemble Kalman filter and 4D-Var intercomparison with the Japanese operational global analysis and prediction system, Mon. Wea. Rev.]

정량적인 분석 외에도 앙상블 spread의 예측 성능을 분석 및 평가하기 위해 앙상블 spread와 에러 분석 기법을 조사하여 상관성 분석을 진행하고자 하였다.

앙상블 spread 분석은 특정 지역 및 지점에 대한 앙상블 spread를 예보 시간에 따라 계산하였고, 이와 앙상블 에러와의 관계 분석도 함께 진행 하였다. 더불어

한국형양상블모델의 팽창기법에 따른 상관성 분석도 함께 진행하였으며, 이러한 분석은 각 모델 별, 월별 시간 규모를 바탕으로 수행되었다.

(2) 국외 앙상블모델과의 섭동기법 비교 분석

		한국형앙상블모델	UM 앙상블모델
수평해상도		32 km (ne090np3)	32km (N400)
연직층		91층	70층
초기 섭동	방법	LETKF (50개)	ETKF(48개)
	Inflation	AdditiveInflation, RTPS inflation	Multiplicative Inflation
	Localilization	모든 격자	수평 80 지점, 연직 4층
초기 지면 섭동		SST	SST, SMC, Tsoil
통계 물리		SPPT, SPDT, SSST	RP2, SKEB2
Analysis Recentering		u, v, t, q (50%) ps(100%)	u, v, t, q, π (100%)
중기예측		이른분석 00/12UTC (컨트롤+25 개 섭동) 26개 멤버	이른분석 00/12UTC (컨트롤+시간차24개 섭동)

그림 1.3.2 한국형앙상블모델과 기상청 UM앙상블모델의 비교 (수치모델링센터 제공)

한국형앙상블 모델의 경우, LETKF를 사용하고 있으며 기상청 현업에서 운용중인 UM 앙상블모델의 경우 ENTF 방법을 사용하고 있다. 본 연구과제에서의 분석은 모두 TIGGE 사이트에서 수집한 현업 예보모델결과를 사용했다. 영국기상청의 자료도 확보하여, 모델과 앙상블 방법으로 인한 차이점도 파악하고자 하였다.

(3) 앙상블 spread와 앙상블 에러의 상관성 분석

앙상블 스프레드와 앙상블 평균장 에러의 관계 분석

- 앙상블 평균 오차와 스프레드의 관계는 서로 비례하는 것으로 알려져 있다. 아래 그림을 보면 유럽중기예보센터에서 검증한 850hPa 북반구 중위도 온도에 대한 앙상블 평균 오차와 스프레드의 관계를 보여주는 것으로 예보 선행시간이 늘어날수록 두 값 모두 증가하는 것을 보여주고 있다.
- 본 연구에서도 한국형앙상블모델의 앙상블 평균 오차와 스프레드를 예보선행시간에 따라 계산한 결과 아래와 같은 그림을 얻을 수 있었다. 여기에는 영국기상청과 유럽중기예보센터 예보모델 결과와 한국 기상청 현업 모델의 결과 역시 함께 표출하였다.




그림 1.3.3 앙상블 평균에러와 스프레드의 관계에 대한 예
 (Courtesy of confluence.ecmwf.int)

- 크게, 세 가지 지역 전지구 평균, 적도지역을 제외한 북반구, 그리고 열대 지역으로 구분하여 결과를 산출하였다. 2021년 7월 예보자료와 2022년 1월 예보자료를 확보하여 이를 위와 같은 앙상블 평균장의 절대 오차와 앙상블 스프레드를 계산하였다.

결과들의 특징은 아래처럼 요약할 수 있다.

1) 전지구 평균에서는 영국기상청, 유럽중기예보센터의 결과는 앙상블평균에러와 스프레드가 예보선행시간에 따라 증가하는 결과를 보여준다. 이는 통상적인 예보모델의 형태임에 반해, 한국형앙상블모델의 경우는 초기 굉장히 큰 앙상블 에러가 오히려 계속 유지되고 앙상블 스프레드 역시 초기의 큰 값이 아주 서서히 증가하는 형태를 보여준다. 한편, UM(KMA)의 경우는 초기에 앙상블평균에러와 스프레드가 이틀째 급격히 감소하고 그 이후로는 통상적인 예보모델의 형태에 가깝게 증가함을 보여준다.

2) 북반구 평균은 한국형앙상블모델과 한국 기상청 현업 모델에서 보여주는 초기 에러와 스프레드가 큰 특징은 그대로 유지하고 있는 반면에, 상대적으로 이러한 에러가 예보선행시간에 따라 천천히 증가하면서 예보선행시간이 4-5일을 넘어서면 절대오차는 다른 모델에 비해 나은 결과를 보여주고 있다. 하지만 앙상블 스프레드는 타 모델들과 비슷하게 증가하는 양상을 띄고 있다.

3) 적도 지역은 남위 30도에서 북위 30도 지역의 평균한 값을 사용하였다. 적도지역에서도 북반구 결과와 비슷한 형태를 보여주고 있다. 즉, 초기 상대적으로 큰 앙상블 에러가 예보선행시간에 따라 천천히 증가하면서 예보선행시간이 4-5일이 지나면 제일 우수한 성능을 보여주고 있다. 그럼에도 불구하고 앙상블 스프레드는 타 모델들과 유사하거나 오히려 빠르게 증가하는 형태를 보여주고 있다.

요약하면, 영국기상청과 유럽중기예보센터의 결과는 예보선행시간이 길어지면서 앙상블 평균장의 절대오차와 앙상블 스프레드 모두 비례하면서 증가하는 형태를 보여준다. 반면에 UM(KMA)의 경우 초기 오차가 크다는 점이 특이한 것으로 판단되며, 한국형앙상블모델의 경우 절대오차와 앙상블 스프레드가 서로 비례하지 않는 결과를 보여준다. 이는 모델 예측결과에 대한 안정성에 영향을 끼칠 수 있다고 판단되며 향후 지속적인 분석과 성능개선이 필요하다고 볼 수 있다.

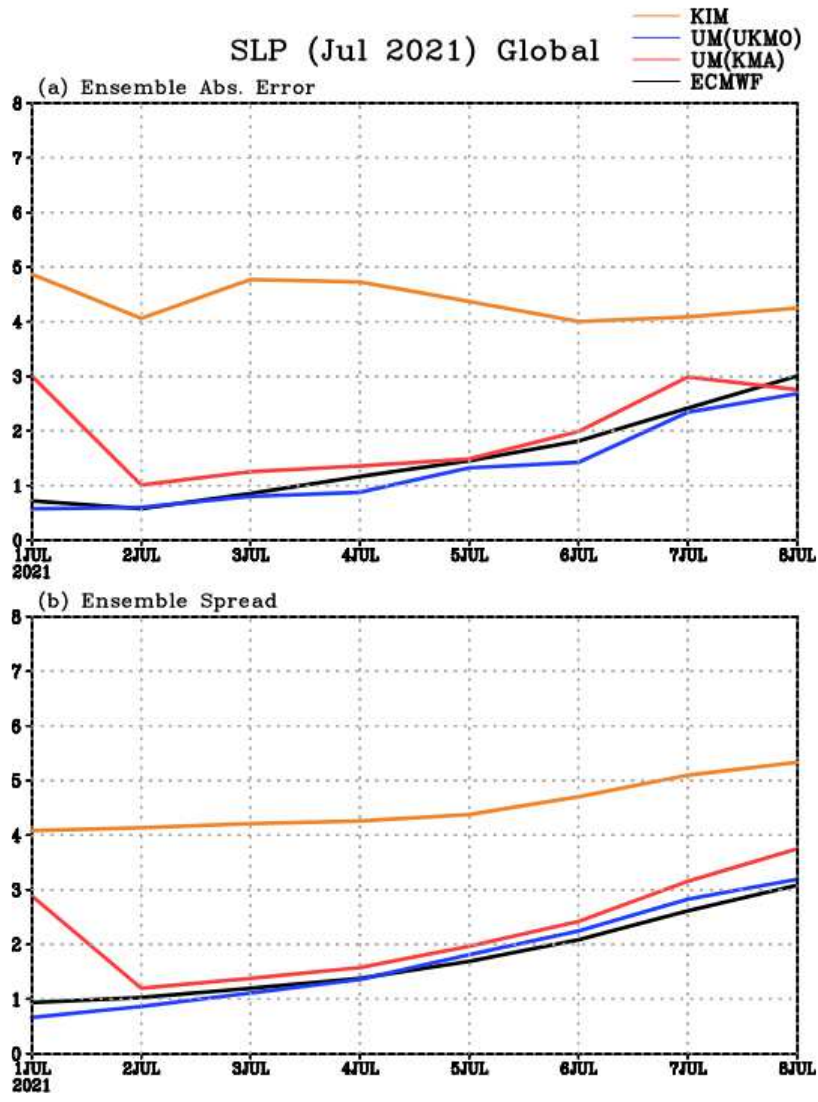


그림 1.3.4 해면기압의 전지구평균에 대한 앙상블 평균의 절대 오차 (a), 앙상블 스프레드의 예보선행시간에 따른 변화 2021년 7월 1일부터 7월 22일 예보결과를 사용하였음




그림 1.3.5 위 그림과 같으나 2022년 1월 예보결과를 사용함.




그림 1.3.6 해면기압의 북반구(북위20도-90도)평균에 대한 앙상블 평균의 절대 오차 (a), 앙상블 스프레드의 예보선행시간에 따른 변화 2021년 7월 1일부터 7월 22일 예보결과를 사용하였음.




그림 1.3.7 위의 그림과 같으나 2022년 1월 예보결과를 사용한 결과임.




그림 1.3.8 해면기압의 열대(남위30도-북위30도)평균에 대한 앙상블 평균의 절대 오차 (a), 앙상블 스프레드의 예보선행시간에 따른 변화 2021년 7월 1일부터 7월 22일 예보결과를 사용하였음.




그림 1.3.9 위의 그림과 같으나 2022년 1월 예보결과를 사용한 결과임.

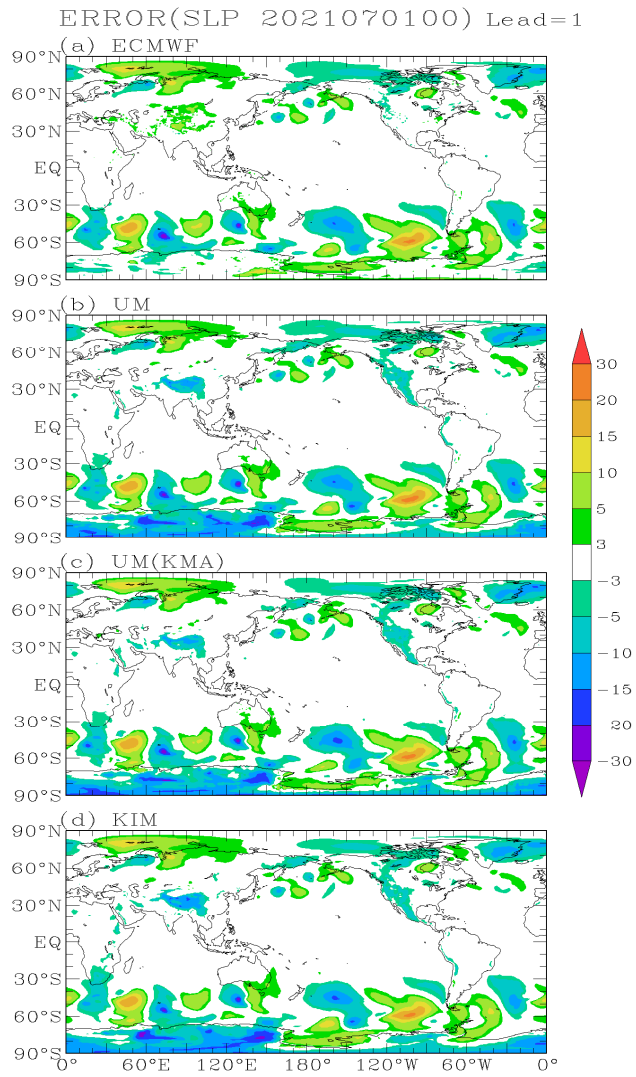


그림 1.3.10 2021년 7월 1일 00Z 초기조건으로 한 예보의 선행시간 1일 짜 해면기압의 오차

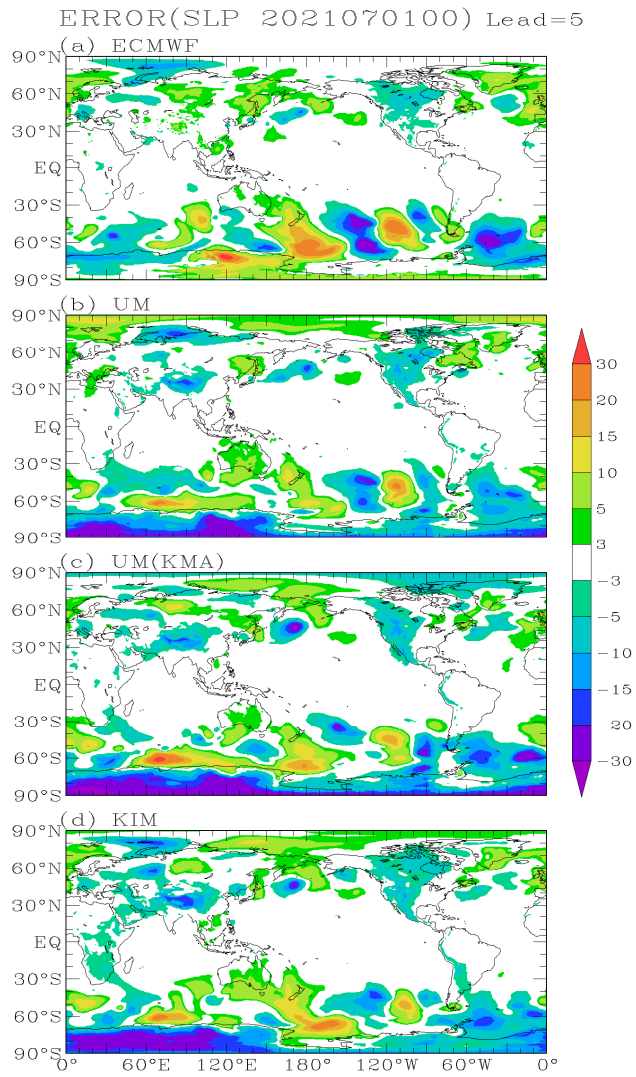


그림 1.3.11 위 그림과 같으나 예보선행시간 5일

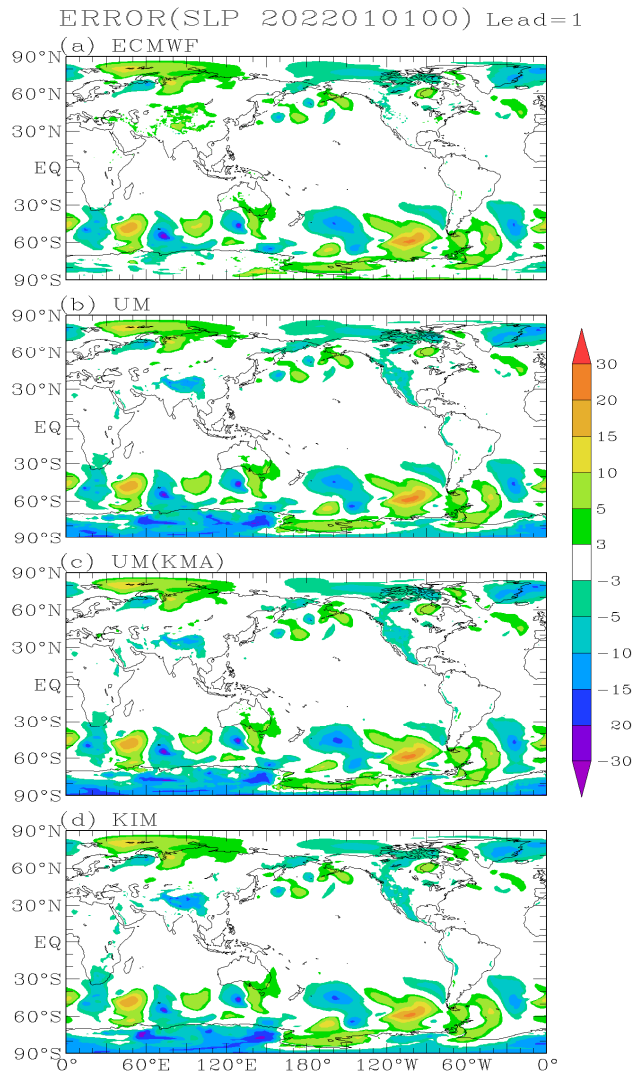


그림 1.3.12 2022년 1월 1일 00Z 초기조건으로 한 예보의 선행시간 1일 짜 해면기압의 오차

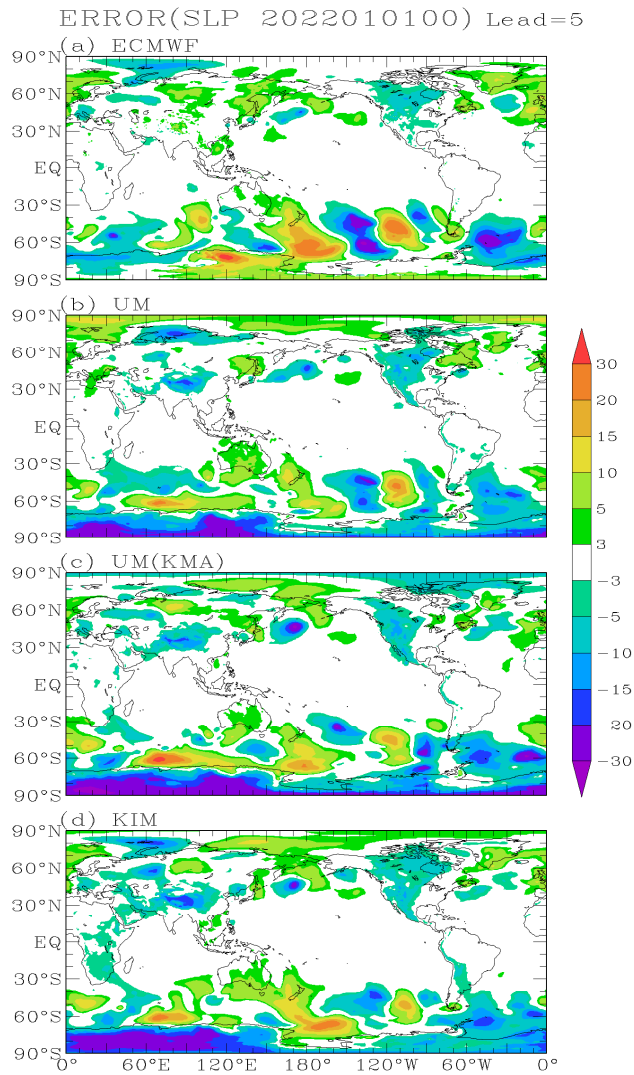


그림 1.3.13 위 그림과 같으나 예보선행시간 5일

- 마지막으로 오차의 근원을 파악하기 위하여 2021년 7월 1일 00Z, 2022년 1월 1일 00Z 초기조건 예보의 오차를 분석하였다. 비록 하나의 앙상블 멤버로 수행한 분석이지만 예보 오차가 남극 주위에서 매우 강함을 확인하였다.

(4) 한국형양상블모델 양상블자료동화(LETKF*)와 양상블 spread와의 상관성 분석

한국형양상블모델 양상블자료동화와 양상블 스프레드에 대한 분석은 한국형양상블모델 자료를 가지고 각 예보선행시간에 대한 양상블 표준편차를 계산하여 추정하였다.

아래에 보여주고 있는 결과는 2021년 7월과 2022년 1월 예보장을 활용하여 양상블 표준편차를 각 선행시간마다 계산하고 이를 평균한 결과이다. 예보선행시간의 증가에 따라 양상블 표준편차는 증가하고 있으며 이는 변수에 큰 상관없이 나타나는 현상이다.

한국형 양상블의 경우, 앞서 언급한 초기장에서의 특징이 예보선행시간이 7일이 되도록 유지되는 것을 확인할 수 있다.

ENSSTD(SLP Jul2021) KIM

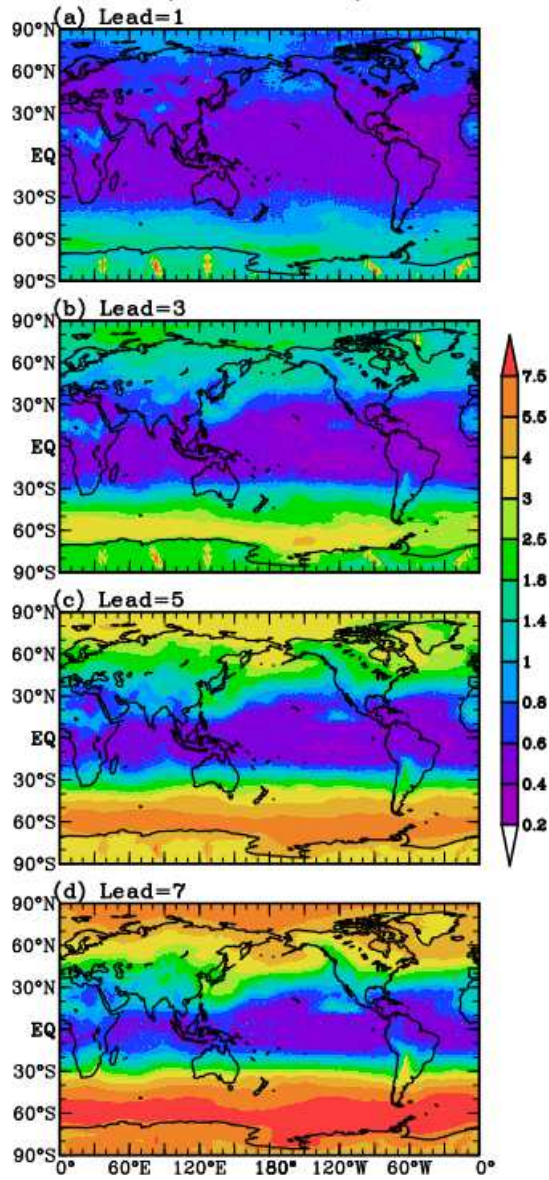


그림 1.3.14 해수면 기압에 대한 앙상블 표준편차로 추정된 앙상블 스프레드, 2021년 7월 예보에 대한 결과로 선행시간 1, 3, 5, 7일에 대한 분석임

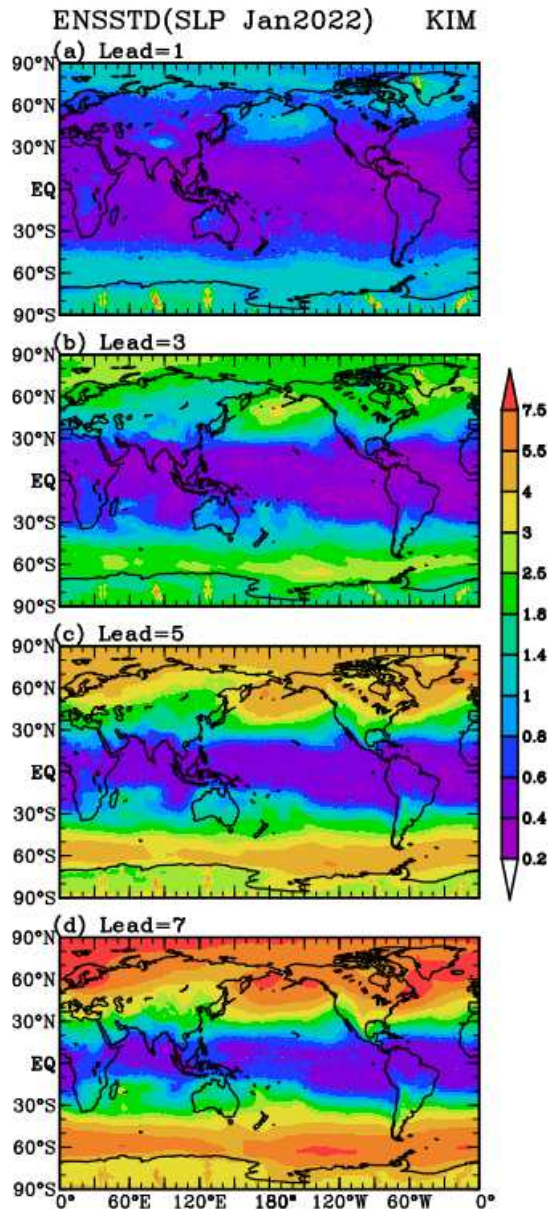


그림 1.3.15 옆의 그림과 같으나 2022년 1월
예보자료에 대한 결과임

ENSSTD(H200 Jul2021) KIM

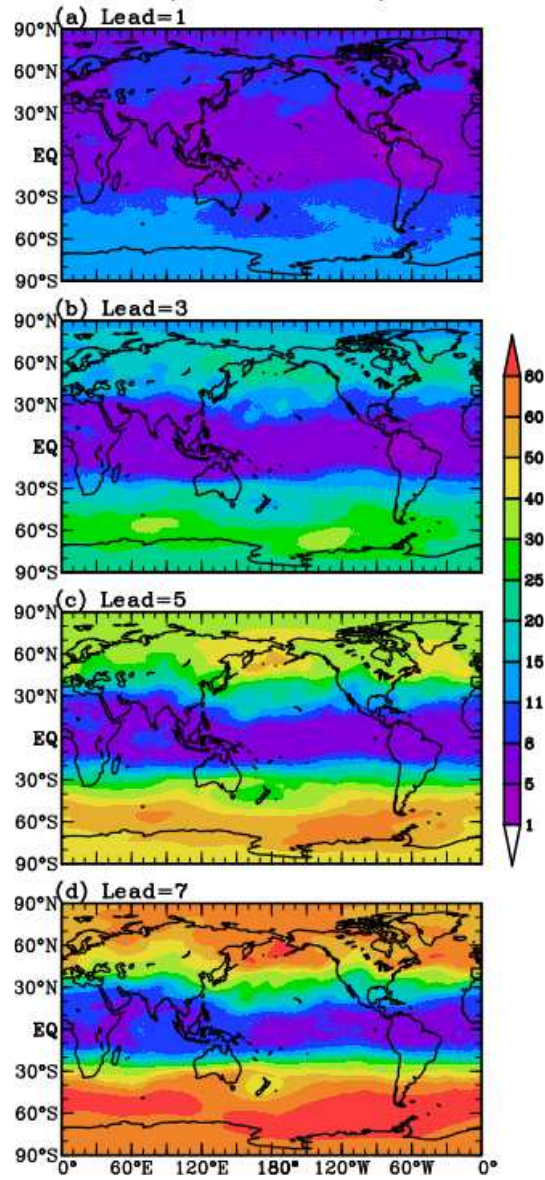


그림 1.3.16 앞의 그림과 같으나 지위고도장
200hPa

ENSSTD(H200 Jan2022) KIM

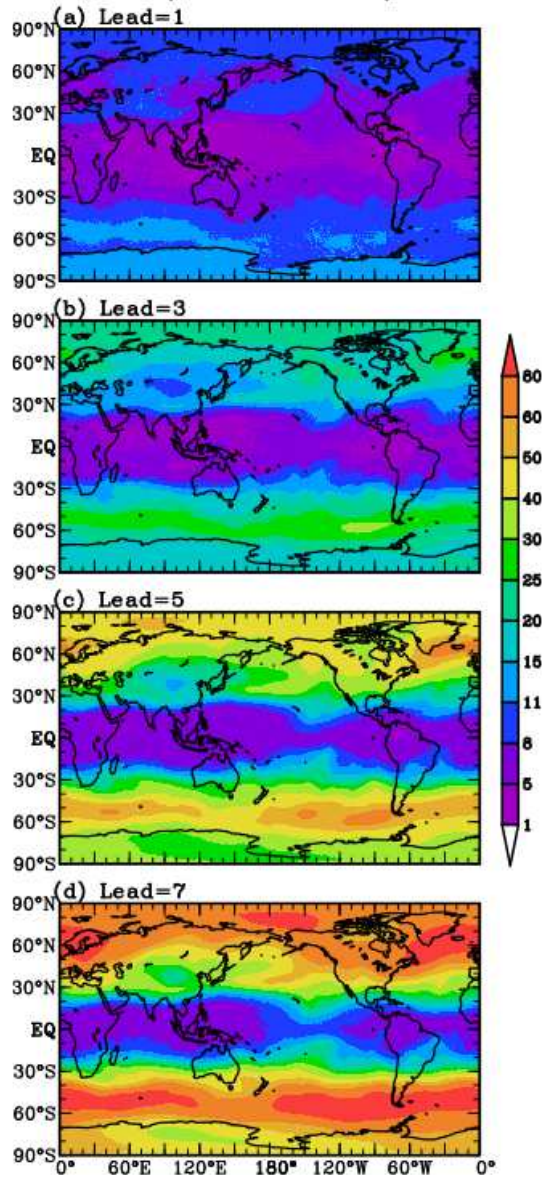


그림 1.3.17 옆의 그림과 같으나 2022년 1월 자료 분석한 결과임

ENSSTD(T1000 Jul2021) KIM

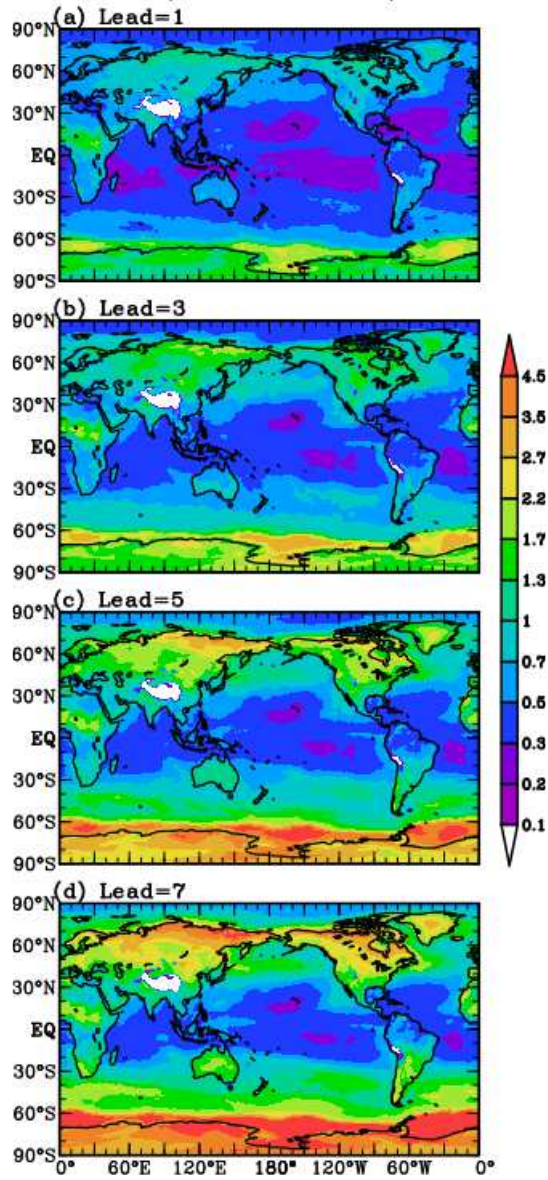


그림 1.3.18 앞의 그림과 같으나 1,000hPa 온도

ENSSTD(T1000 Jan2022) KIM

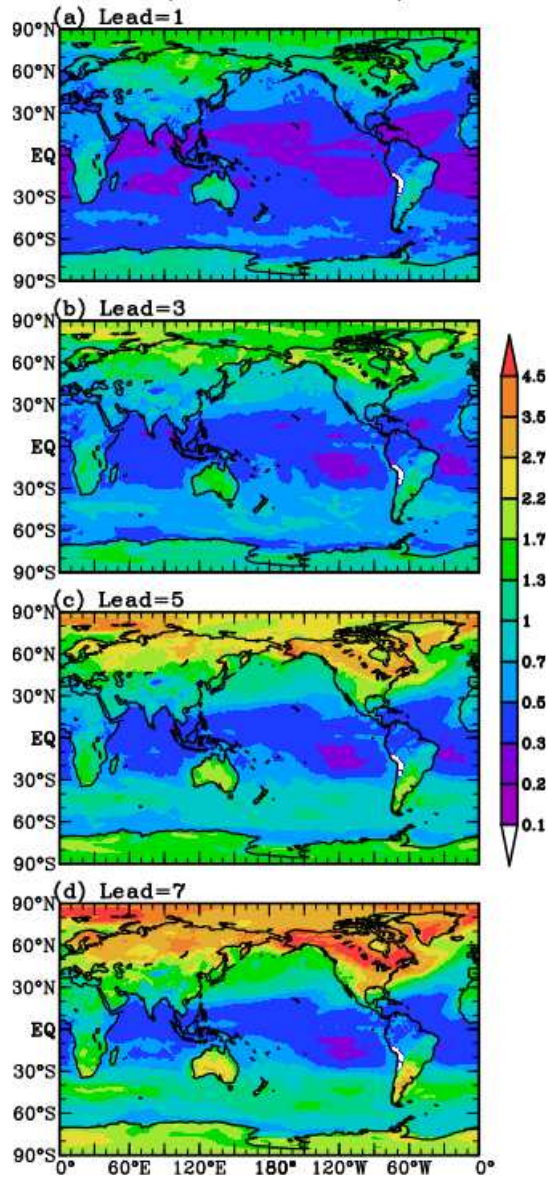


그림 1.3.19 옆의 그림과 같으나 2022년 1월 자료 분석한 결과임

ENSSTD(T500 Jul2021) KIM

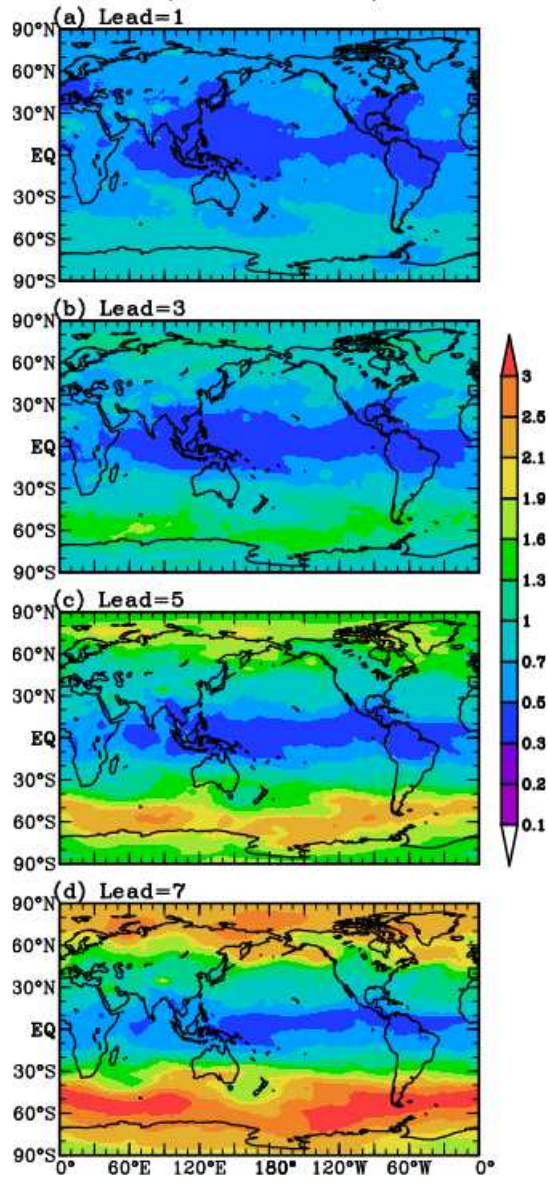


그림 1.3.20 앞의 그림과 같으나 500hPa 온도

ENSSTD(T500 Jan2022) KIM

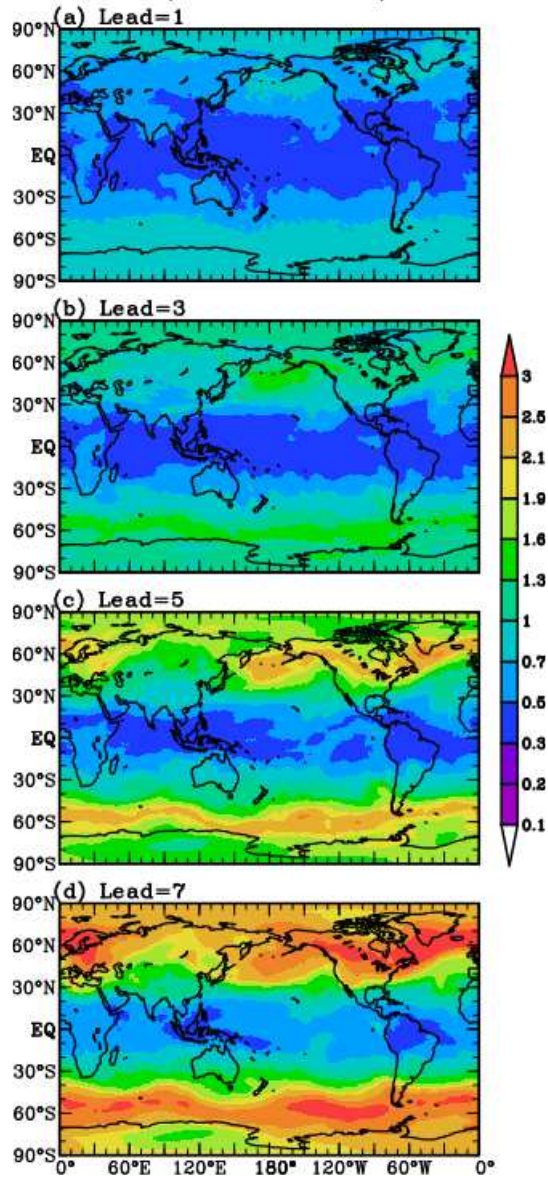


그림 1.3.21 옆의 그림과 같으나 2022년 1월 자료 분석한 결과임

(5) 한국형양상블모델 팽창기법(inflation)과 양상블 spread와의 상관성 분석

한국형양상블모델 팽창기법과 양상블 spread 와의 관계를 분석하기 위해서 두 개의 국외모델 - 영국기상청, 유럽중기예보센터 - 그리고 UM(KMA)의 예보자료를 확보하여 상대 비교하였다.

먼저, 양상블 평균장에 대한 분석을 진행하였다. 양상블 평균장은 아래 보여주듯이 네 개의 예보자료 모두 유사하게 모의하고 있으며 특별한 특이사항은 찾아볼 수 없었다. 따라서 양상블 평균장은 예보선행시간 1일과 7일에 대해서 앞서와 같이 2021년 7월과 2022년 1월 예보자료에 대한 결과만을 요약적으로 보여주고 있다.

다음은 양상블 스프레드 - 양상블 표준편차에 대한 분석을 진행하였다. 앞서 언급한대로 양상블 표준편차는 예보선행시간에 따라 증가하는게 통상적인 예보모델의 결과이며, 네 개 예보모델 모두 이러한 통상적인 결과를 따라가고 있다.

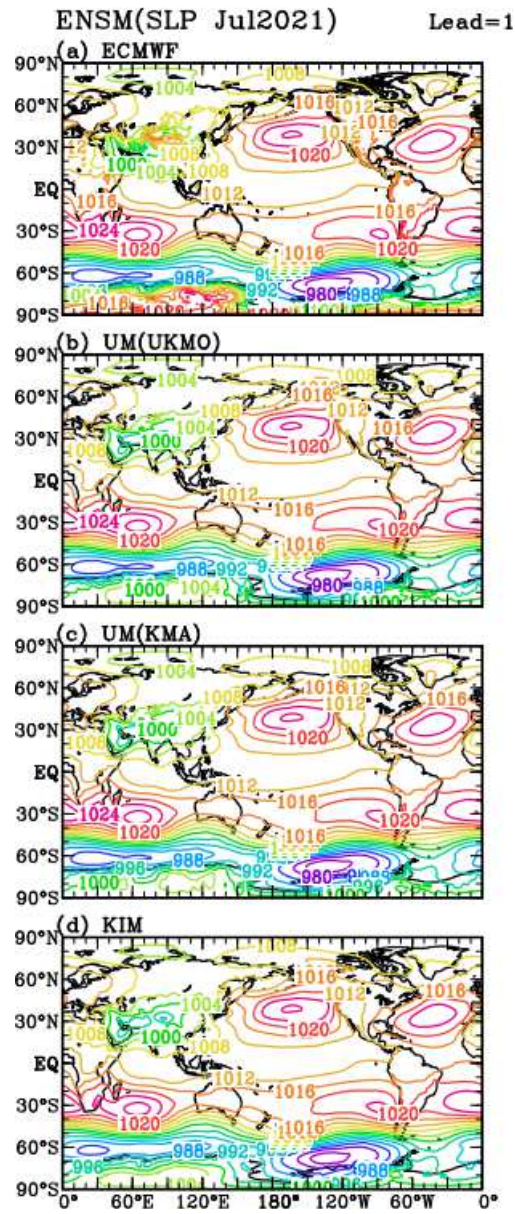


그림 1.3.22 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형 앙상블모델의 해수면기압 2021년 7월 평균장, 예보선행시간 1일에 대한 결과임

ENSM(SLP Jul2021) Lead=7

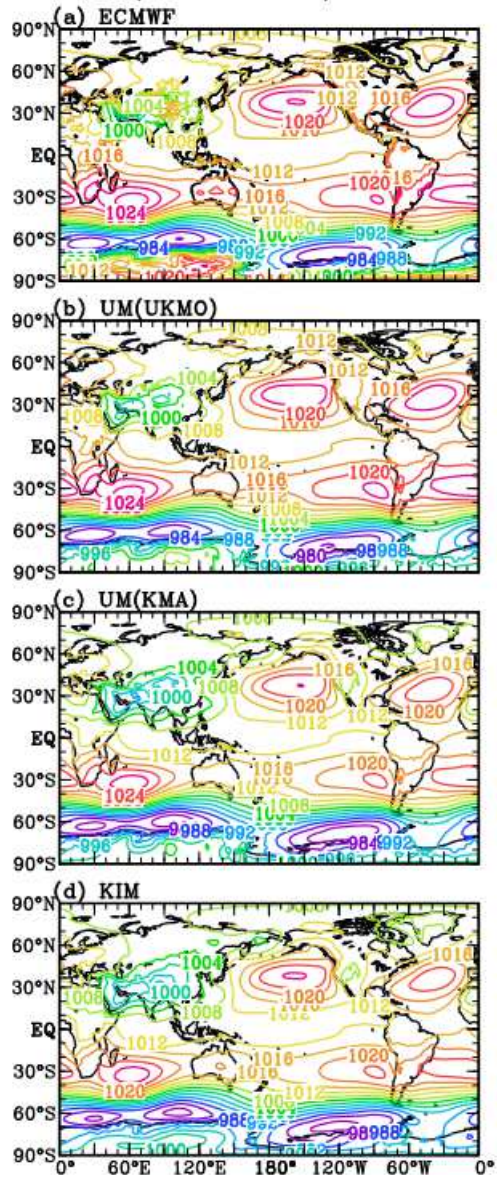


그림 1.3.23 왼쪽그림과 같으나 예보선행시간 7일에 대한 결과임

ENSM(SLP Jan2022) Lead=1

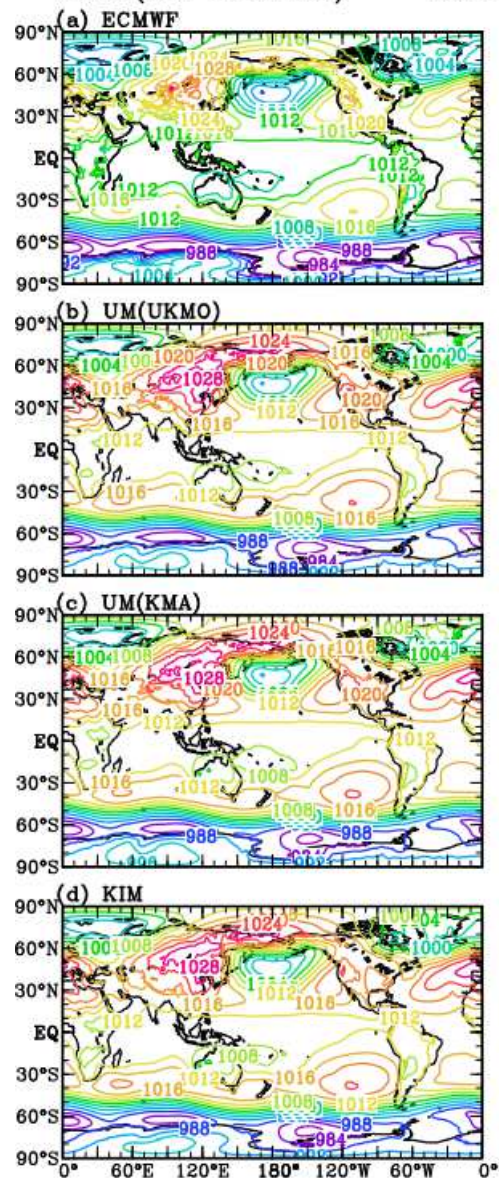


그림 1.3.24 위 그림과 같으나 2022년 1월에 대한 결과임

ENSM(SLP Jan2022) Lead=7

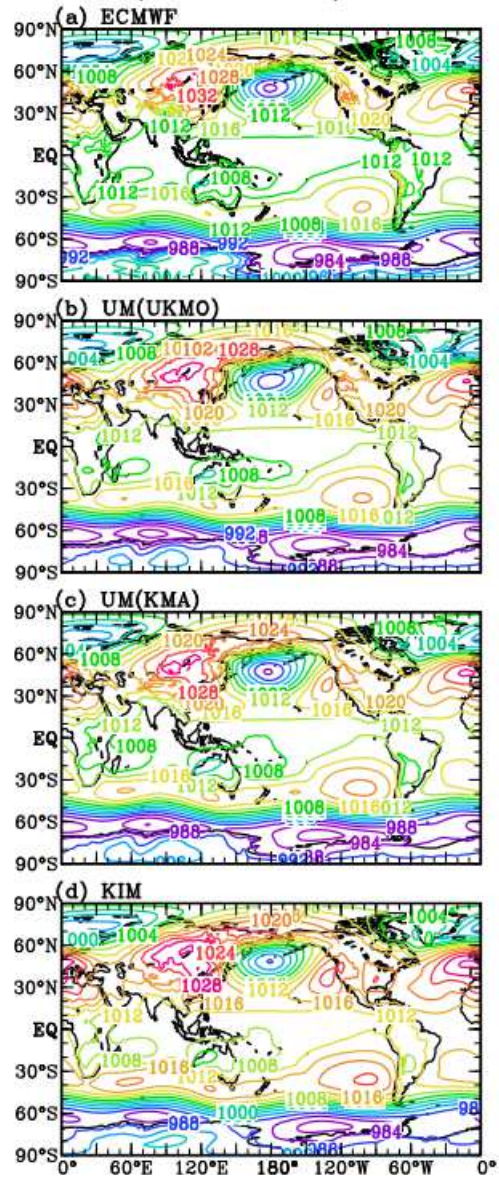


그림 1.3.25 왼쪽그림과 같으나 예보선행시간 7일에 대한 결과임

- 하지만, 주목할만한 특이사항이 발견되었다. 한국형양상블모델의 경우, 예보 초기에 확인되는 스프레드가 다른 어떤 모델에 비해서 큰 것을 확인할 수 있다. 이는 계절에 관계 없이 나타나는 현상으로 파악된다.

- 초기장에 나타나는 스프레더는 양상블 스프레드 - 표준편차에 반영되어 예보선행시간 내내 지속적으로 나타나는 것으로 확인하였다.

TIGGE에서 확보한 한국 기상청의 현업 모델결과에도 초기에 다소 과하게 모의되는 양상블 표준편차 - 스프레드가 있음을 확인하였다. 물론 이 값은 앞서 보여준 결과처럼 한국형양상블모델보다는 다소 작으나 영국기상청, 유럽중기예보센터의 결과보다는 확연히 큰 결과를 보여주고 있다. 이러한 특징은, 해수면기압, 상층 지위고도장, 온도장 등 모든 변수에서 공통적으로 나타나는 특징이다.

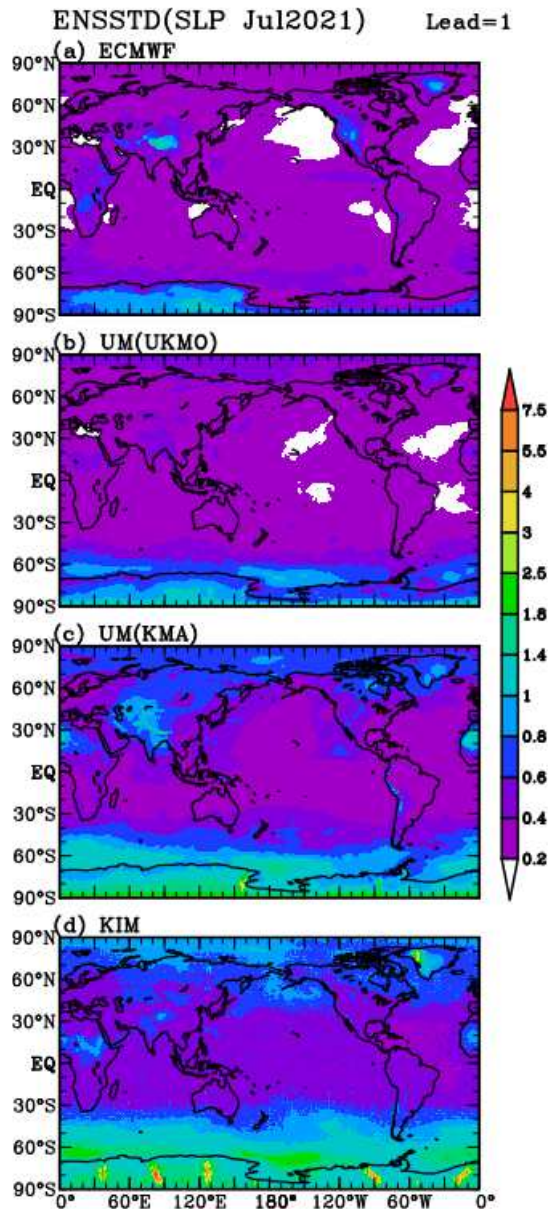


그림 1.3.26 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 해수면기압 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

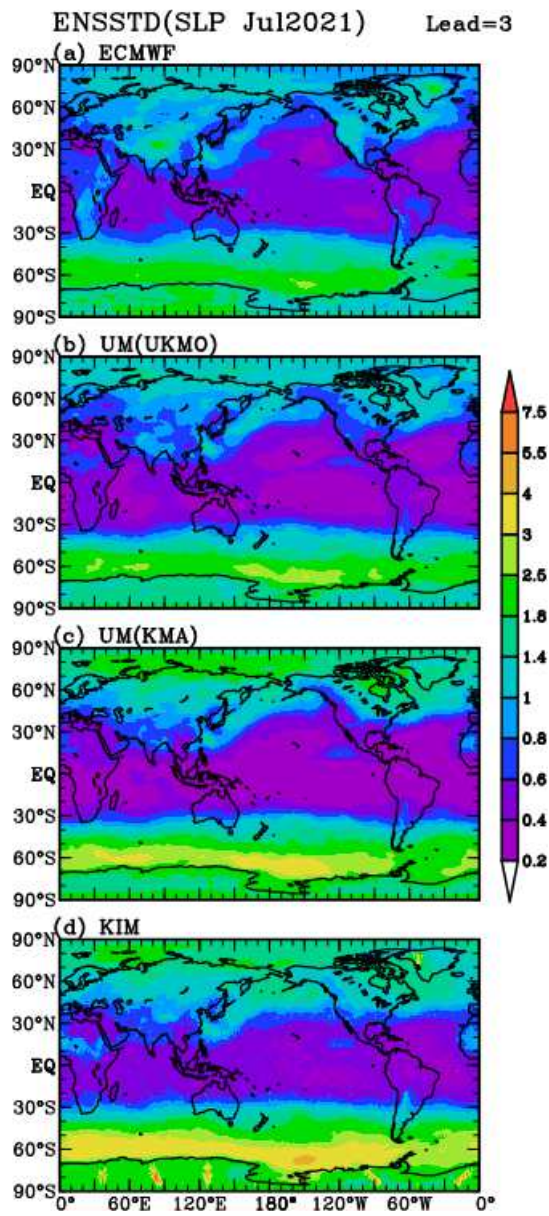


그림 1.3.27 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

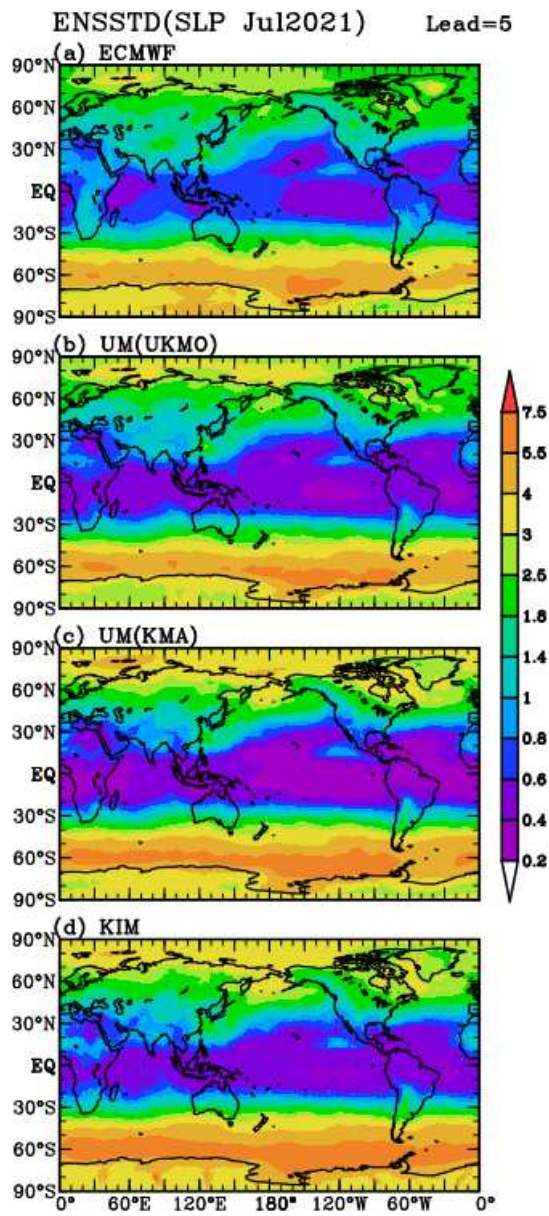


그림 1.3.28 앞의 그림과 같으나 예보선행시간 5일

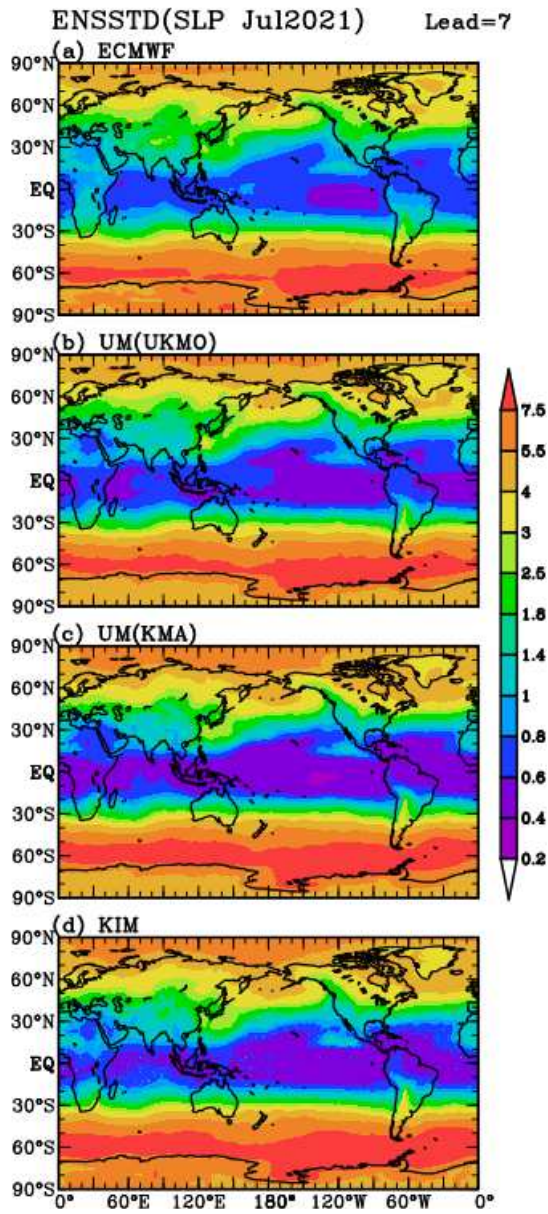


그림 1.3.29 왼쪽과 같으나 예보선행시간 7일

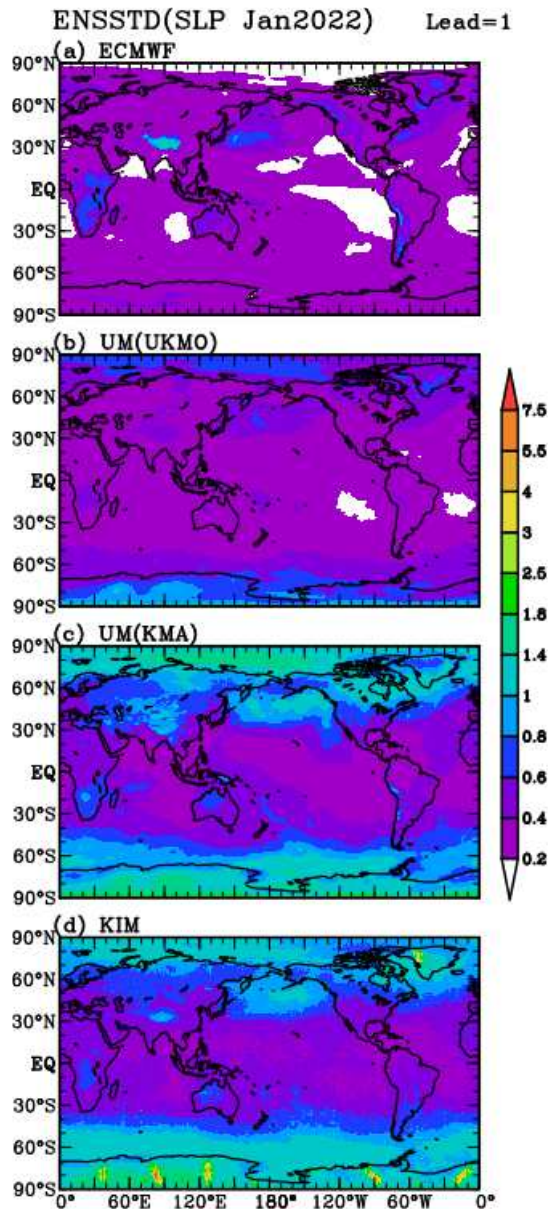


그림 1.3.30 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 해수면기압 2022년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

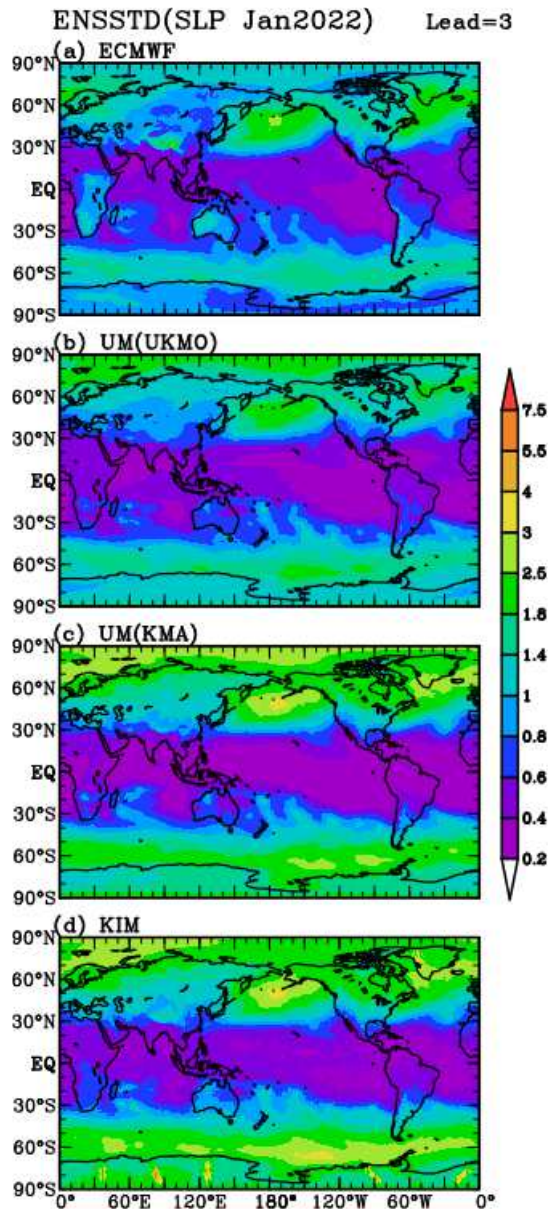


그림 1.3.31 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

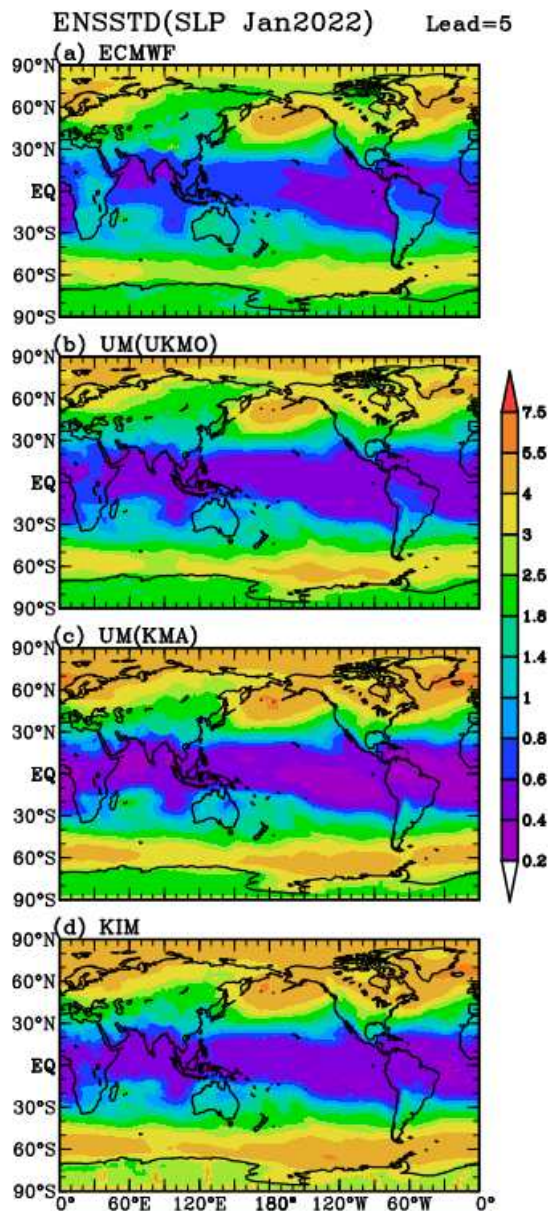


그림 1.3.32 앞의 그림과 같으나 예보선행시간 5일에 대한 결과임

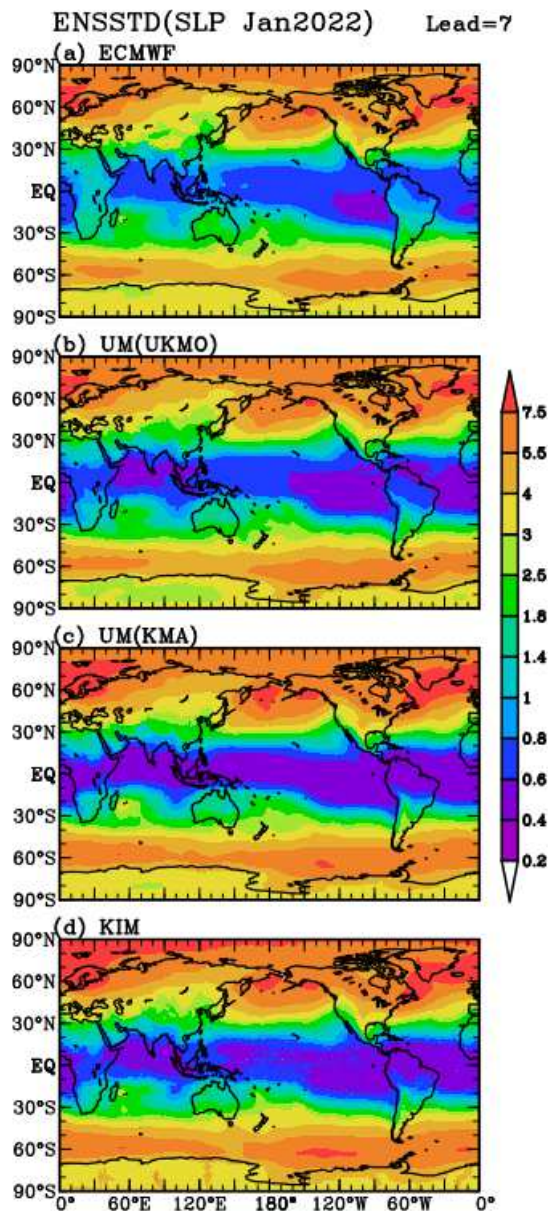


그림 1.3.33 왼쪽과 같으나 예보선행시간 7일에 대한 결과임

ENSSTD(H200 Jul2021) Lead=1

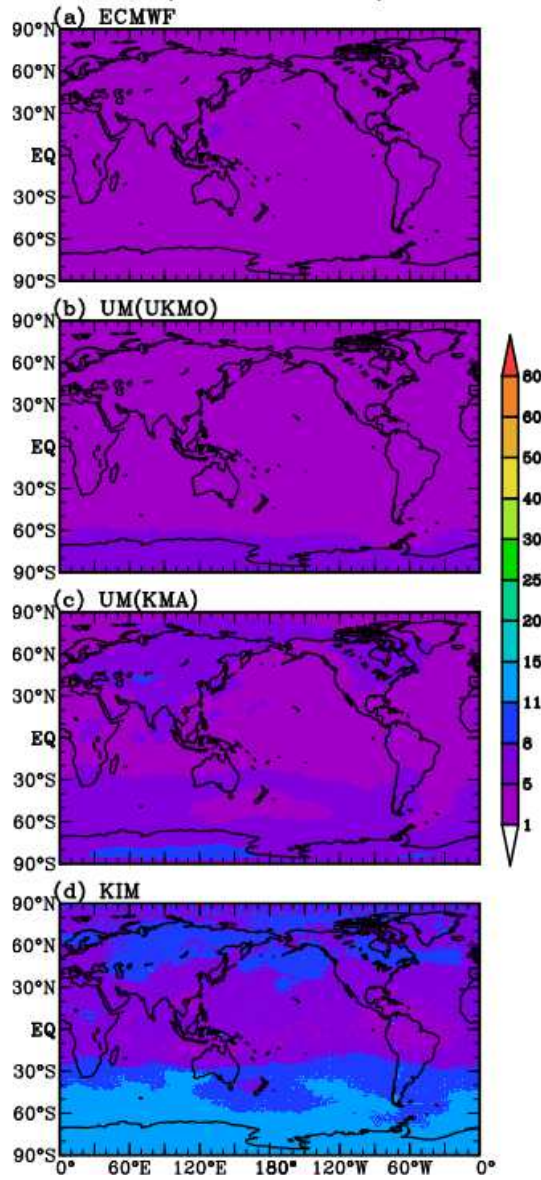


그림 1.3.34 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 200hPa 지위고도장 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

ENSSTD(H200 Jul2021) Lead=3

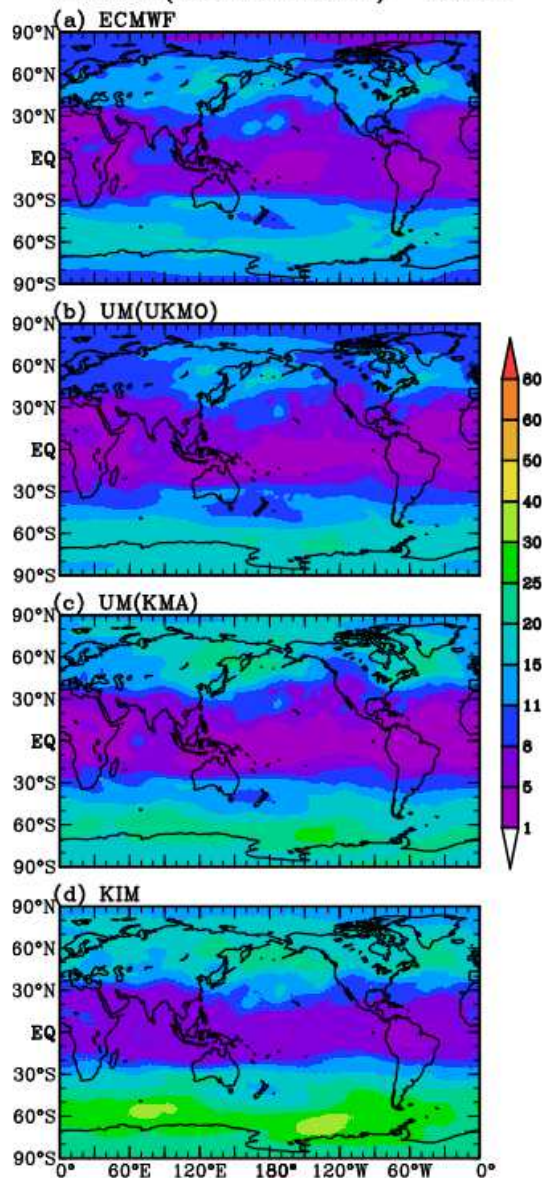


그림 1.3.35 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

ENSSTD(H200 Jul2021) Lead=5

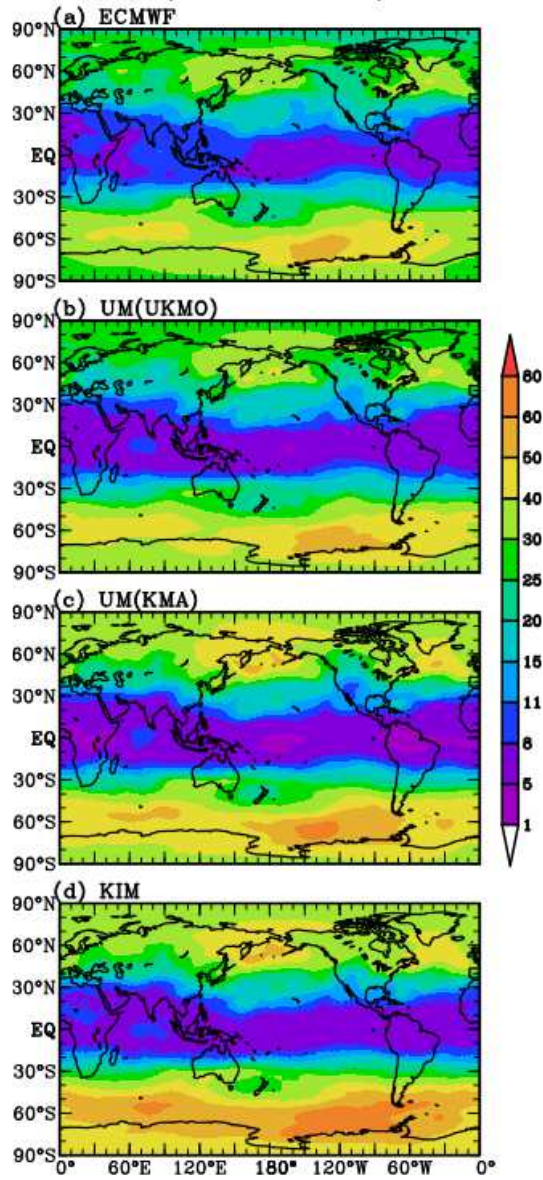


그림 1.3.36 앞의 그림과 같으나 예보선행시간 5일에 대한 결과임

ENSSTD(H200 Jul2021) Lead=7

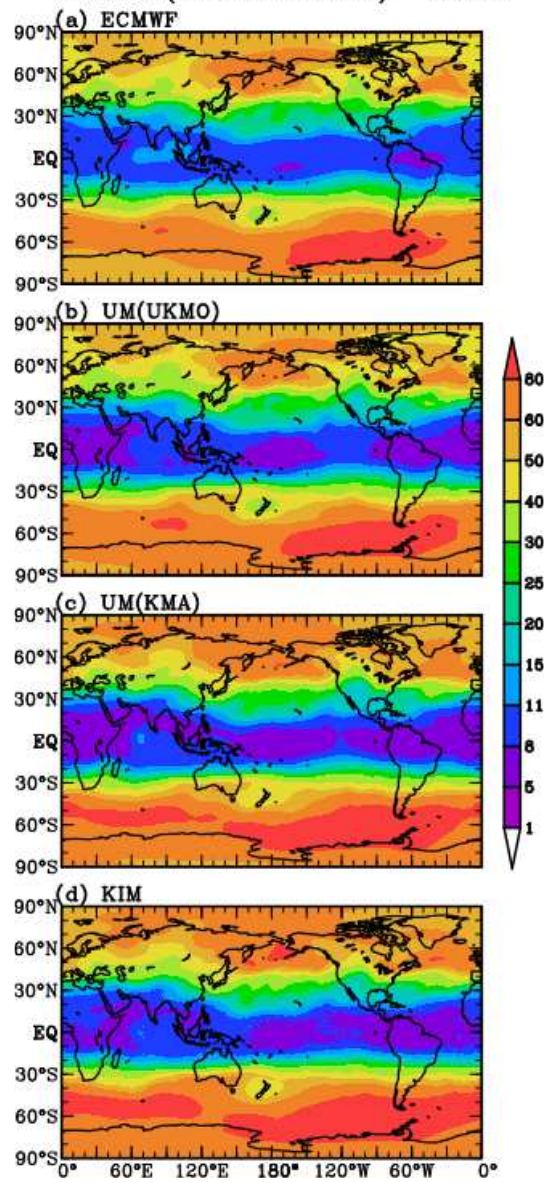


그림 1.3.37 왼쪽과 같으나 예보선행시간 7일에 대한 결과임

ENSSTD(H200 Jan2022) Lead=1

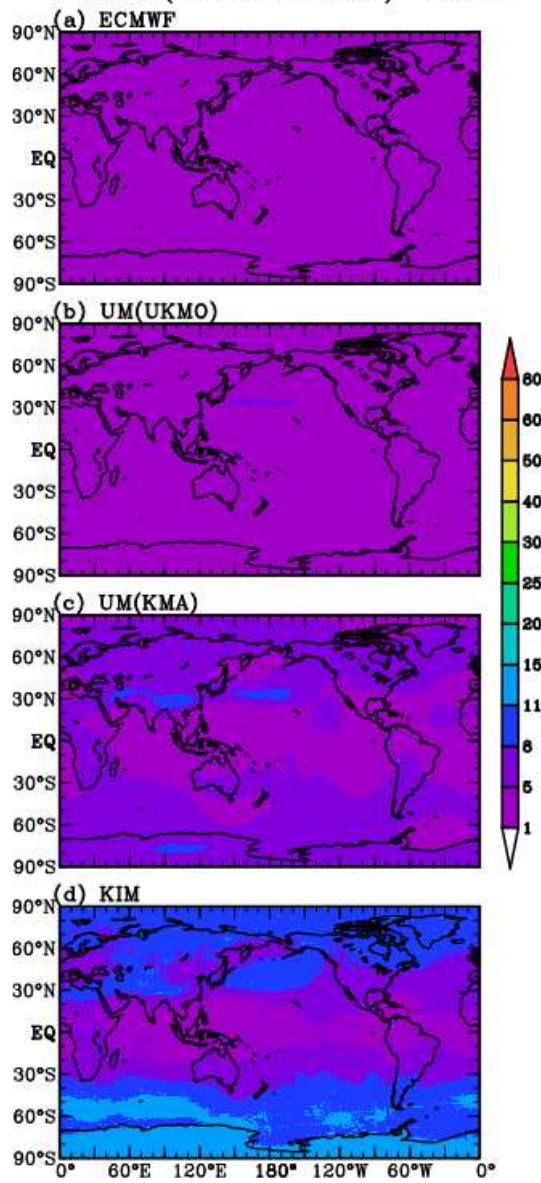


그림 1.3.38 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 200hPa 지위고도장 2022년 1월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

ENSSTD(H200 Jan2022) Lead=3

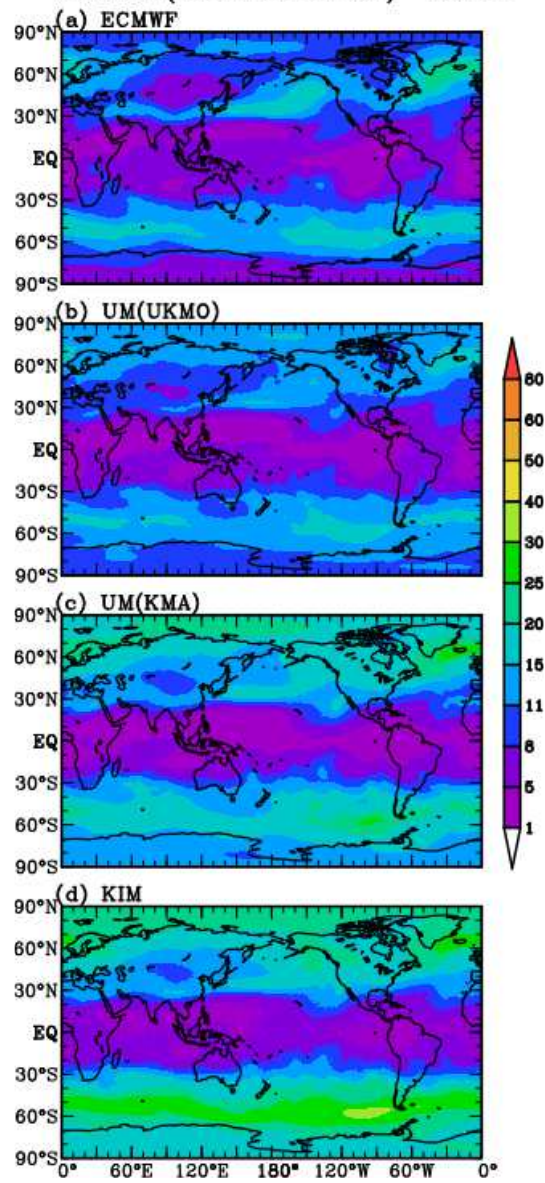


그림 1.3.39 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

ENSSTD(T1000 Jul2021) Lead=1

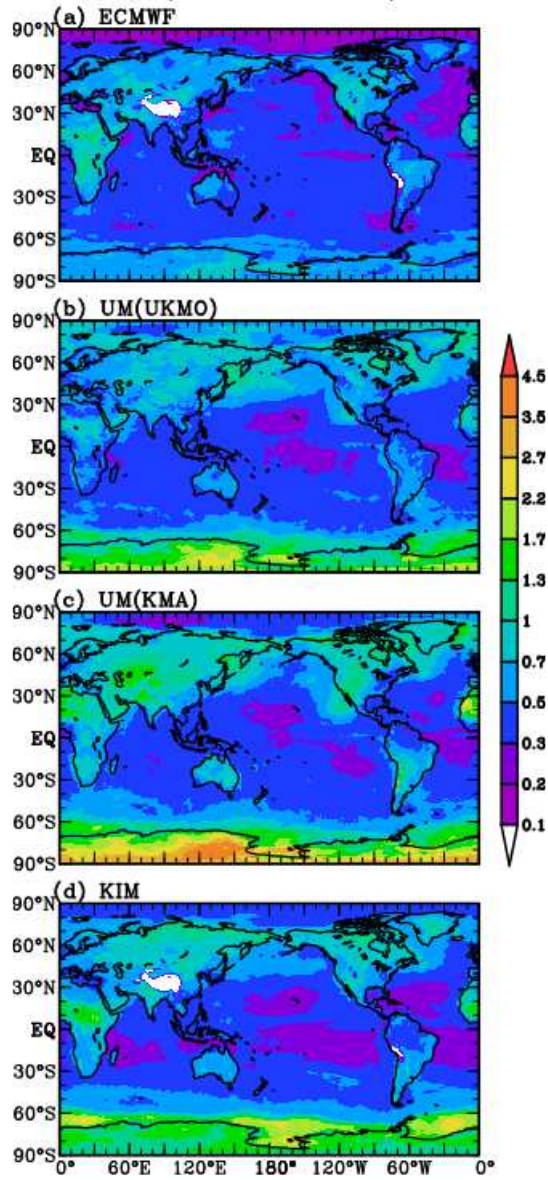


그림 1.3.40 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 1,000hPa 온도 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

ENSSTD(T1000 Jul2021) Lead=3

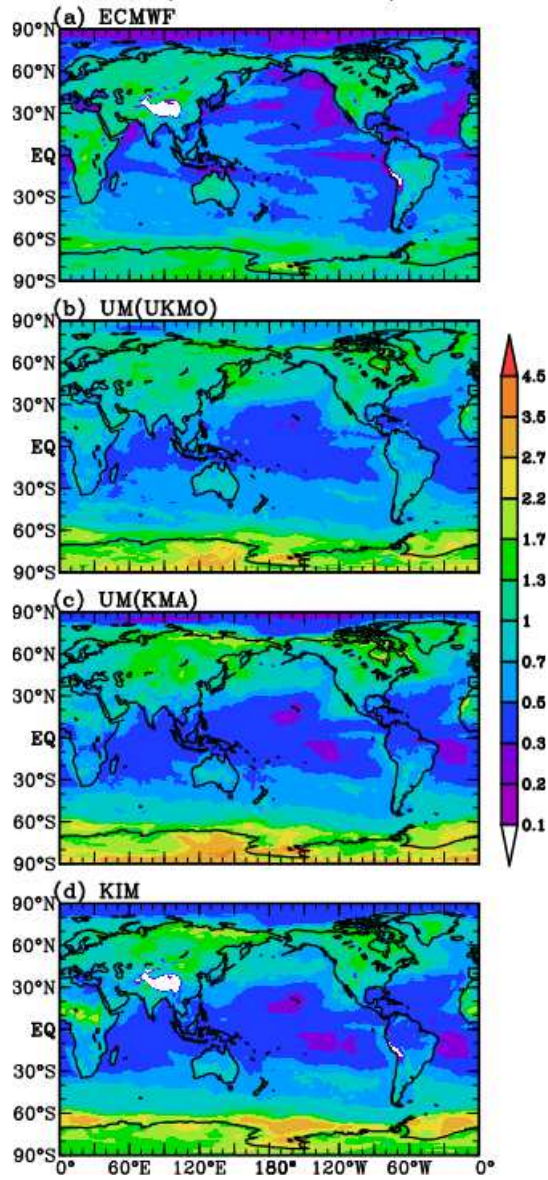


그림 1.3.41 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

ENSSTD(T1000 Jul2021) Lead=5

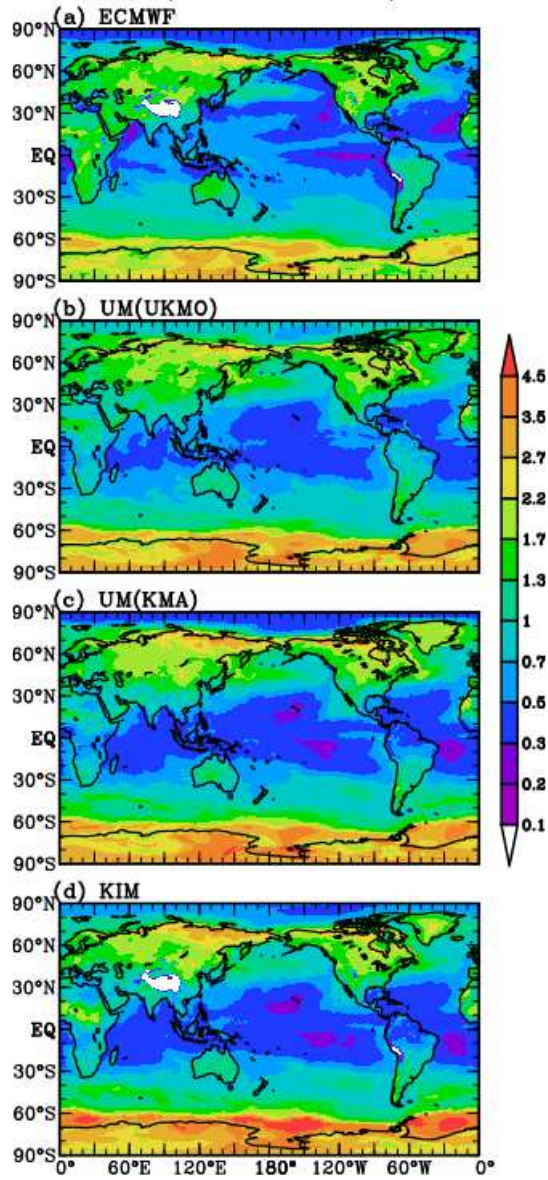


그림 1.3.42 앞의 결과와 같으나 예보선행시간 5일에 대한 결과임

ENSSTD(T1000 Jul2021) Lead=7

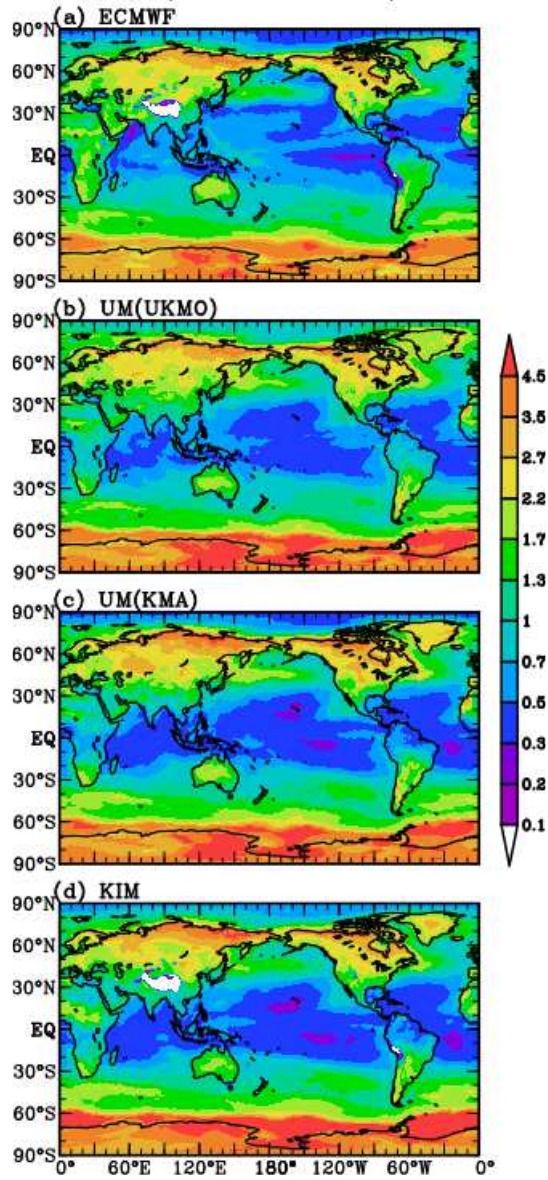


그림 1.3.43 왼쪽과 같으나 예보선행시간 7일에 대한 결과임

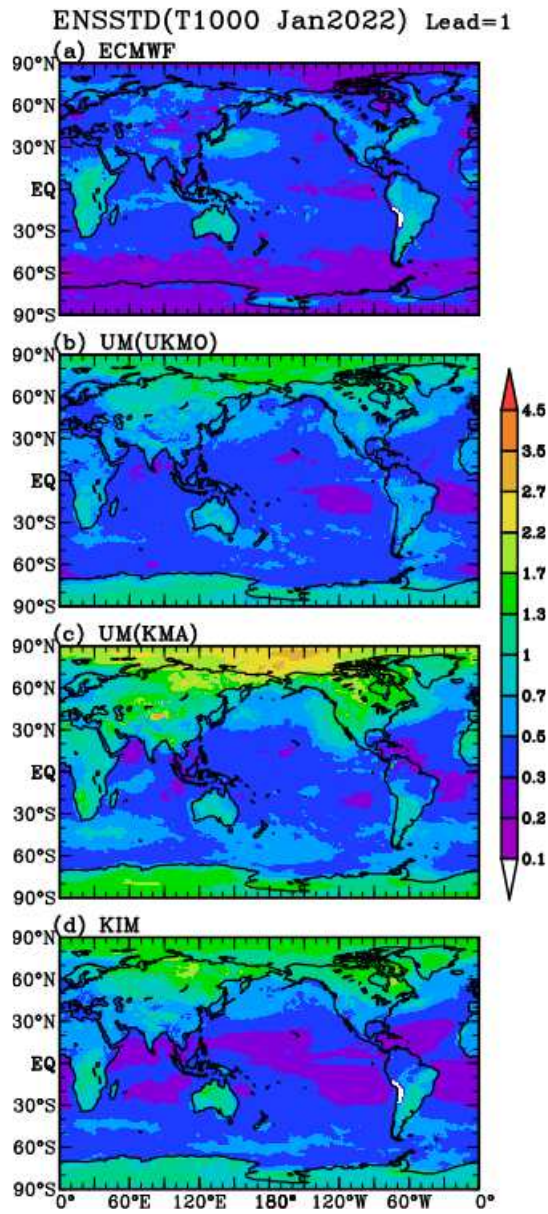


그림 1.3.44 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 1,000hPa 온도 2022년 1월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

ENSSTD(T1000 Jan2022) Lead=3

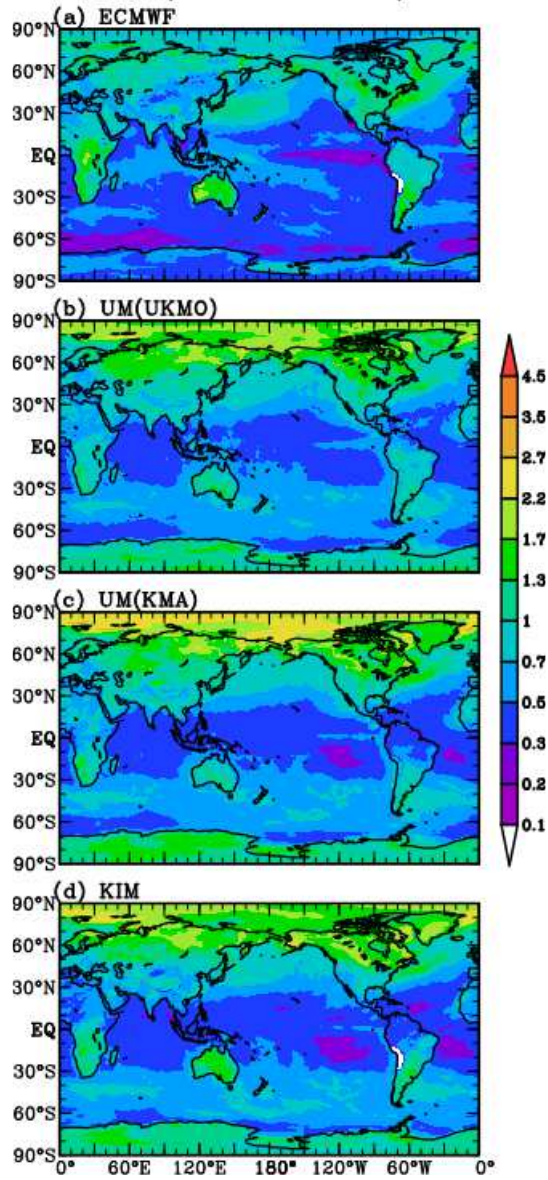


그림 1.3.45 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

ENSSTD(T1000 Jan2022) Lead=5

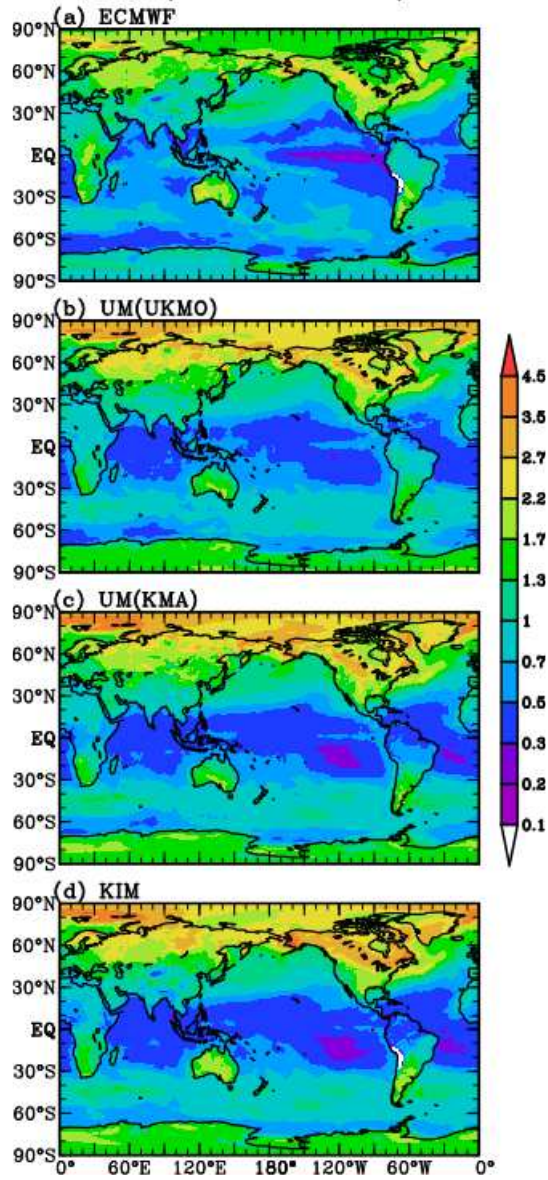


그림 1.3.46 앞의 그림과 같으나 예보선행시간 5일에 대한 결과임

ENSSTD(T1000 Jan2022) Lead=7

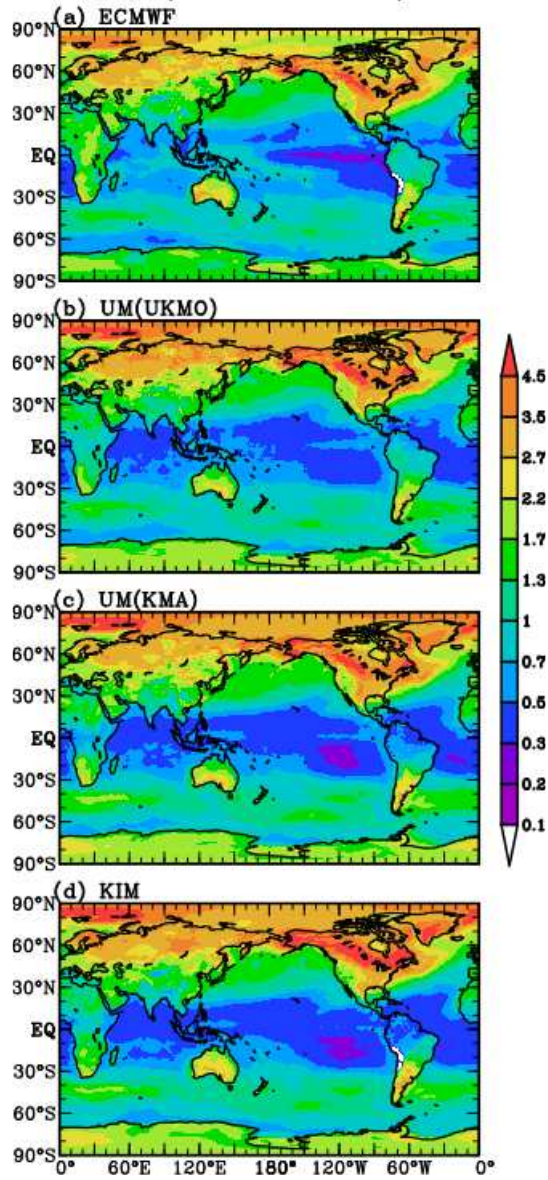


그림 1.3.47 왼쪽과 같으나 예보선행시간 7일에 대한 결과임

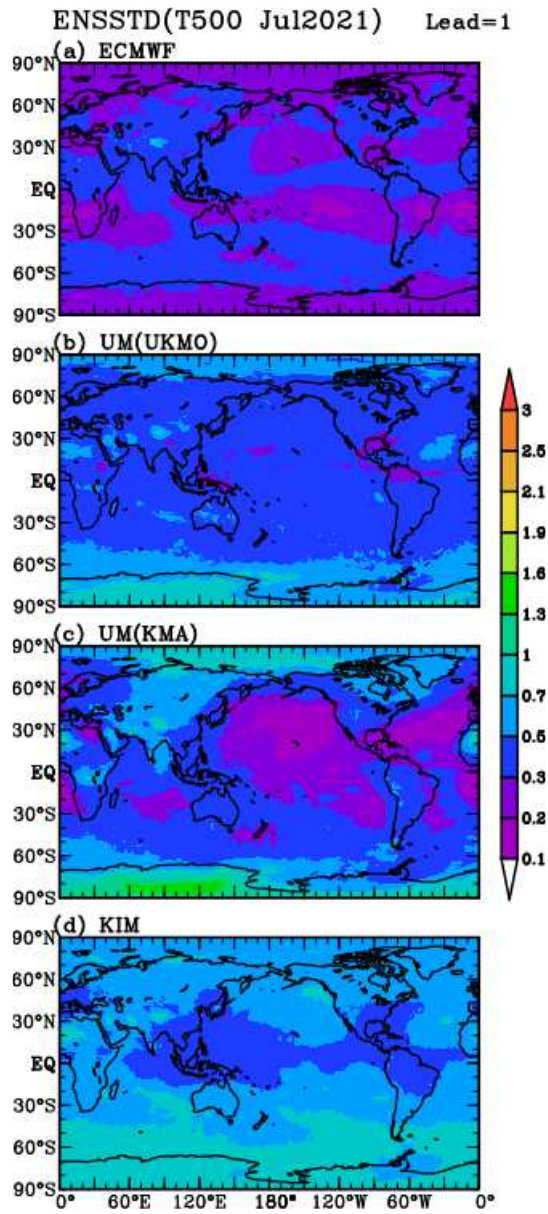


그림 1.3.48 ECMWF-유럽중기예보센터, UM(UKMO)-영국기상청, UM(KMA), 한국형앙상블모델의 500hPa 온도 2021년 7월 앙상블 표준편차, 예보선행시간 1일에 대한 결과임

ENSSTD(T500 Jul2021) Lead=3

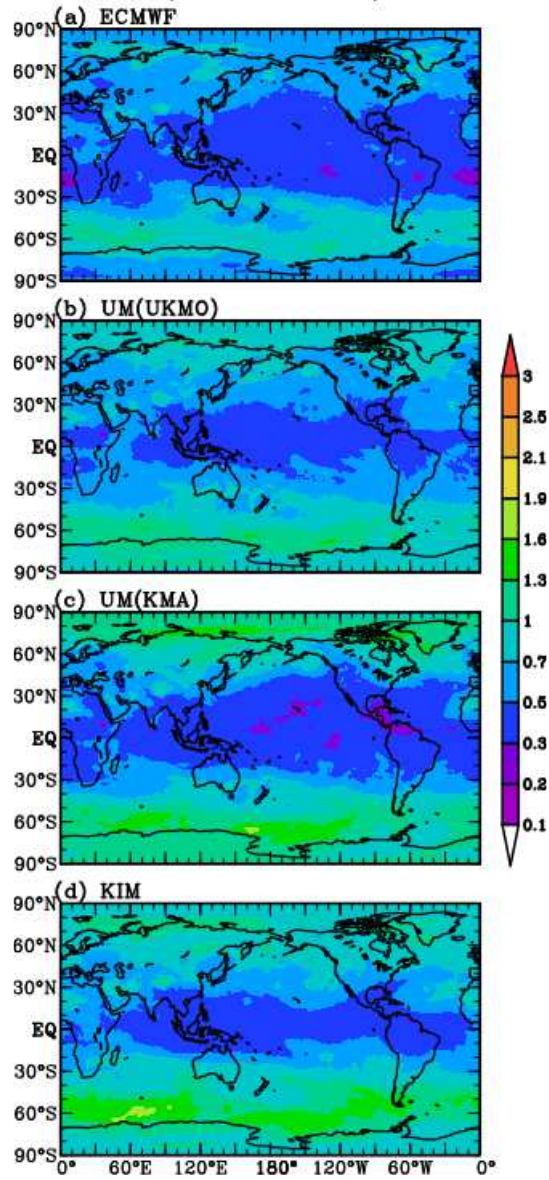


그림 1.3.49 왼쪽과 같으나 예보선행시간 3일에 대한 결과임

ENSSTD(T500 Jul2021) Lead=5

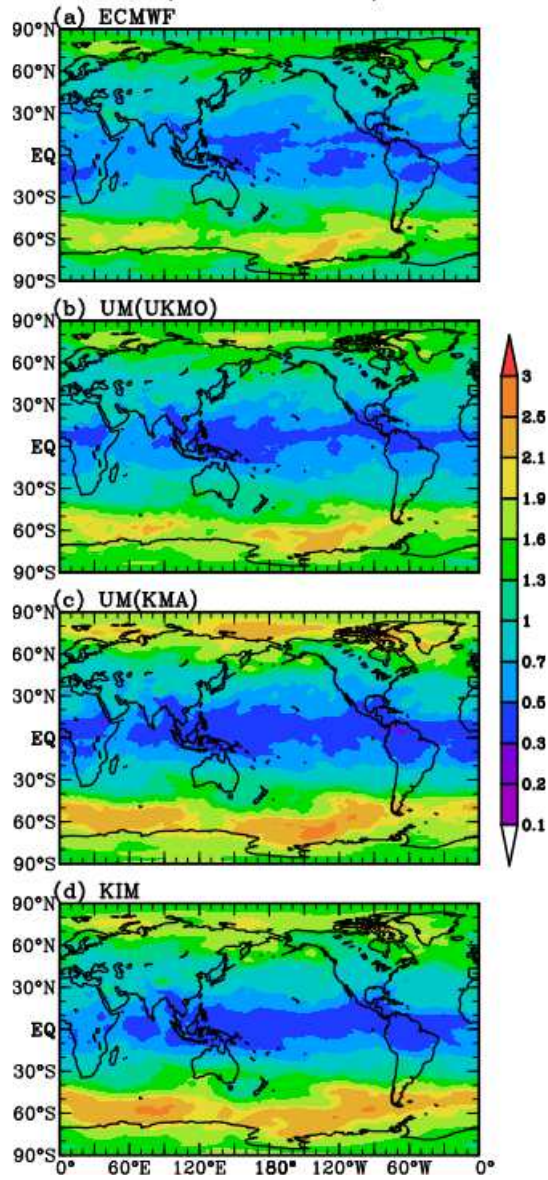


그림 1.3.50 위 그림과 같으나 예보선행시간 5 일에 대한 결과임

ENSSTD(T500 Jul2021) Lead=7

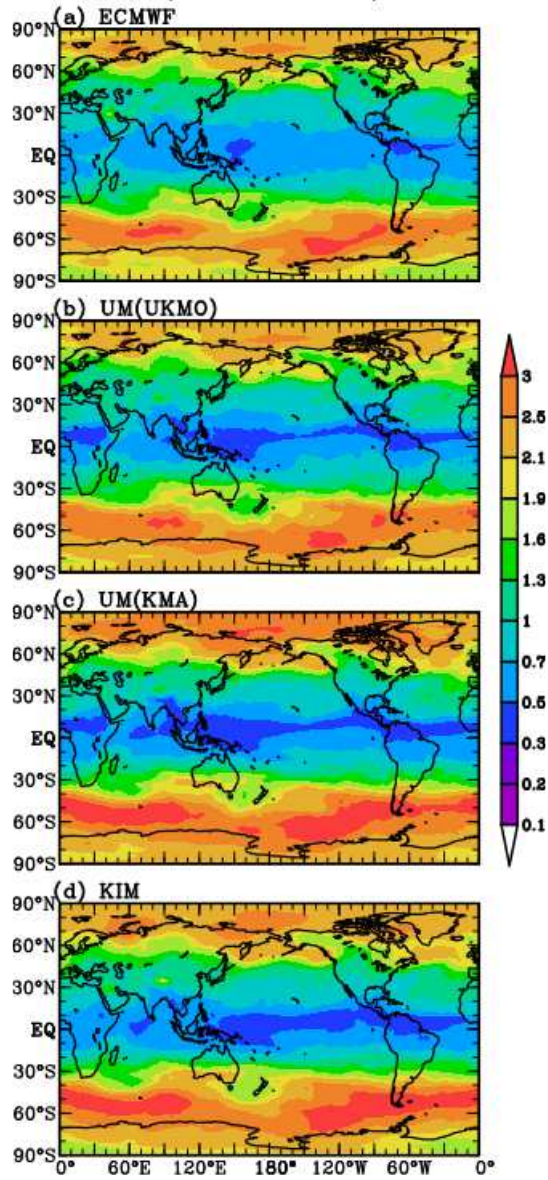


그림 1.3.51 왼쪽과 같으나 예보선행시간 7일에 대한 결과임

ENSSTD(T500 Jan2022) Lead=5

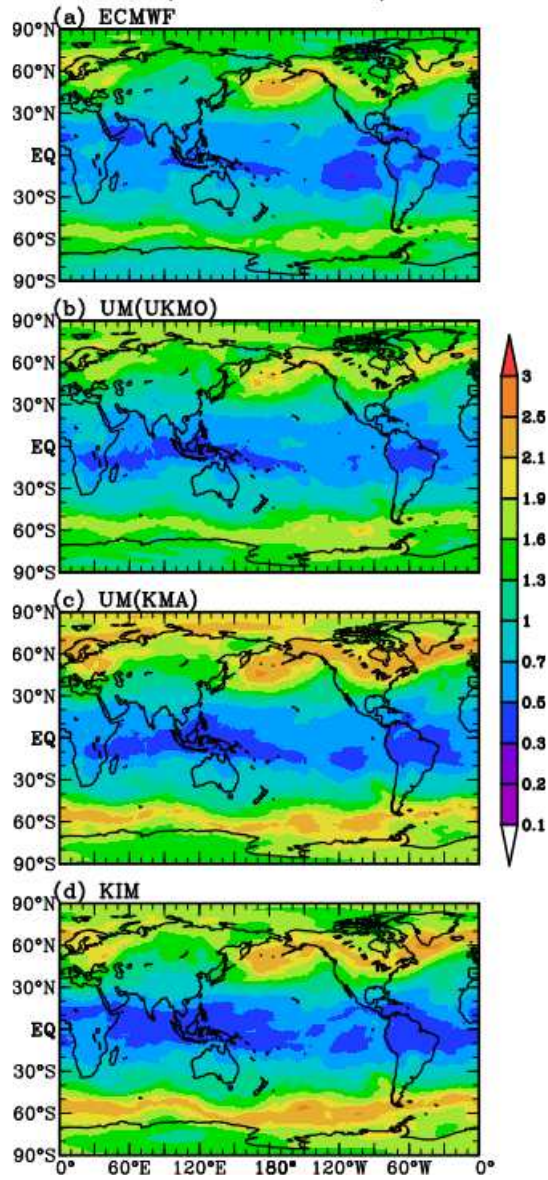


그림 1.3.52 위의 그림과 같으나 예보선행시간 5일에 대한 결과임

ENSSTD(T500 Jan2022) Lead=7

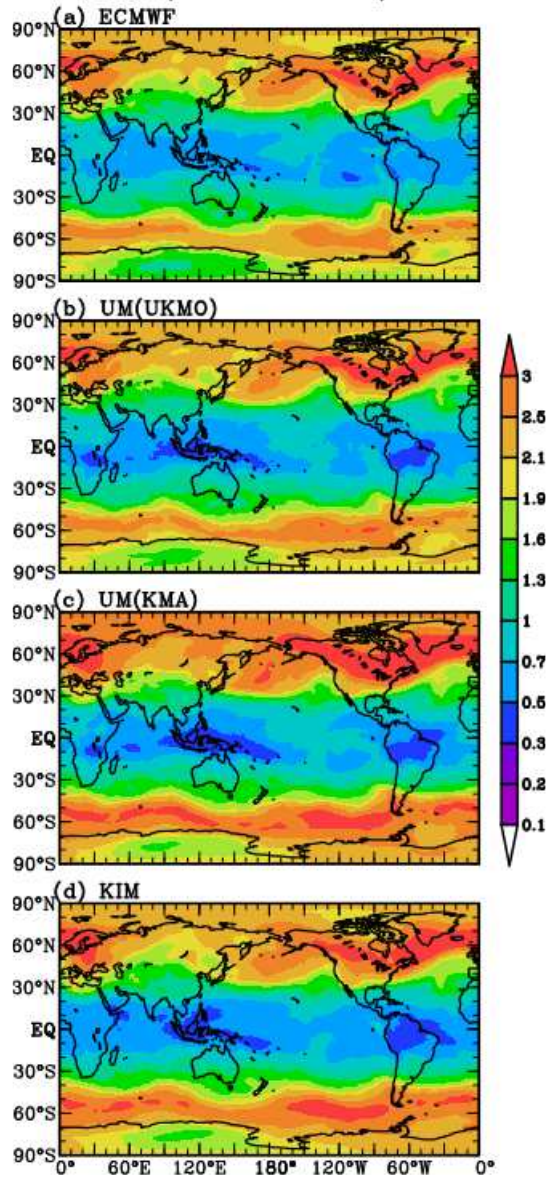


그림 1.3.53 위의 그림과 같으나 예보선행시간 7일에 대한 결과임

제 5 장 사업수행결과의 활용 계획

- 한국형양상블모델의 양상블 평균 예측 성능 및 모델 오차 분석을 통해 현재 단계에서의 모델의 예측 성능을 정량적으로 판단하고 모델의 구조적 오차를 객관적으로 진단하는데 활용할 수 있다. 특히, 예측 성능 진단을 통해 모델의 초기 분석장, 양상블 생산, 섭동 방법 등에 관한 보완점을 파악하여 앞으로 현업에 운용할 한국형양상블모델을 개선하는데 도움을 줄 수 있다.
- 극한기상사례에 대한 한국형양상블모델의 예측성 평가를 통해 추후 극한기상현상 발생시 참고자료로써 활용이 가능하다. 또한 한국형양상블모델의 극한기상 사례분석을 통해 제시한 개선사항을 한국형양상블모델 개발에 반영할 수 있다.
- 한국형양상블모델에서 보여주는 양상블 오차와 양상블 스프레드의 관계는 지속적으로 확인하고 개선해야 할 사항으로 이는 초기장에서 보이는 스플랜더의 존재와도 관련이 있을 것으로 추정할 수 있다. 특히, 스플랜더의 제거 그리고 제거 후에 모의되는 양상블에러 - 스프레드의 관계는 반드시 다시 확인하여 보완해야 한다.
- 더하여, 한국형양상블모델 그리고 UM(KMA)에서 나타나는 초기장에 대한 좀 더 세밀한 분석이 필요하며 이를 통하여 향후 개선점을 찾아나가야 할 필요성이 있으며, 스플랜더의 제거, 섭동의 방법에 대한 고민 등 다양한 분석과 검증이 지속적으로 이루어져야할 것으로 판단된다.

제 6 장 참고문헌

- Lorenz, E. N. (1963a). Deterministic nonperiodic flow. *Journal of atmospheric sciences*, 20(2), 130–141.
- Domeisen, D. I., White, C. J., Afargan–Gerstman, H., Muñoz, Á. G., Janiga, M. A., Vitart, F., ... & Tian, D. (2022). Advances in the subseasonal prediction of extreme events: Relevant case studies across the globe. *Bulletin of the American Meteorological Society*.
- Lorenz, E. N. (1963b). The mechanics of vacillation. *Journal of Atmospheric Sciences*, 20(5), 448–465.
- Palmer, T. N., & Räisänen, J. (2002). Quantifying the risk of extreme seasonal precipitation events in a changing climate. *Nature*, 415(6871), 512–514.
- Kalnay, E. (2003). *Atmospheric modeling, data assimilation and predictability*. Cambridge university press.
- Kalnay, E., & Yang, S. C. (2010). Accelerating the spin-up of ensemble Kalman filtering. *Quarterly Journal of the Royal Meteorological Society*, 136(651), 1644–1651.
- Marsigli, C., Montani, A., Nerozzi, F., Paccagnella, T., Tibaldi, S., Molteni, F., & Buizza, R. (2001). A strategy for high-resolution ensemble prediction. II: Limited-area experiments in four Alpine flood events. *Quarterly Journal of the Royal Meteorological Society*, 127(576), 2095–2115.
- van Oldenborgh, G. J., Doblas-Reyes, F. J., Wouters, B., & Hazeleger, W. (2012). Decadal prediction skill in a multi-model ensemble. *Climate dynamics*, 38(7), 1263–1280.
- Vitart, F., Ardilouze, C., Bonet, A., Brookshaw, A., Chen, M., Codorean, C., ... & Zhang, L. (2017). The subseasonal to seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, 98(1), 163–173.
- Thompson, V., Kennedy-Asser, A. T., Vosper, E., Lo, Y. E., Huntingford, C., Andrews, O., ... & Mitchell, D. (2022). The 2021 western North America heat wave among the most extreme events ever recorded globally. *Science advances*, 8(18), eabm6860.
- Kug, J. S., Lee, J. Y., Kang, I. S., Wang, B., & Park, C. K. (2008). Optimal multi-model ensemble method in seasonal climate prediction. *Asia-Pacific journal of atmospheric sciences*, 44(3), 259–267.
- Hurrell, J., Meehl, G. A., Bader, D., Delworth, T. L., Kirtman, B., & Wielicki, B. (2009). A unified modeling approach to climate system prediction. *Bulletin of the American Meteorological Society*, 90(12), 1819–1832.
- Kim, H. M., Webster, P. J., & Curry, J. A. (2012). Evaluation of short-term climate change prediction in multi-model CMIP5 decadal hindcasts. *Geophysical Research Letters*, 39(10).
- Kim, H. M., Webster, P. J., Toma, V. E., & Kim, D. (2014). Predictability and prediction skill of the MJO in two operational forecasting systems. *Journal of Climate*, 27(14), 5364–5378.
- Sperati, S., Alessandrini, S., & Delle Monache, L. (2016). An application of the ECMWF Ensemble Prediction System for short-term solar power forecasting. *Solar Energy*, 133, 437–450.
- Pegion, K., Kirtman, B. P., Becker, E., Collins, D. C., LaJoie, E., Burgman, R., ... & Kim, H. (2019). The Subseasonal Experiment (SubX): A multimodel subseasonal prediction experiment. *Bulletin of the American Meteorological Society*, 100(10), 2043–2060.
- Weyn, J. A., Durran, D. R., Caruana, R., & Cresswell-Clay, N. (2021). Sub-seasonal forecasting with a large ensemble of deep-learning weather prediction models. *Journal of Advances in Modeling Earth Systems*, 13(7), e2021MS002502.
- White, C. J., Carlsen, H., Robertson, A. W., Klein, R. J., Lazo, J. K., Kumar, A., ... & Zebiak, S. E. (2017). Potential applications of subseasonal-to-seasonal (S2S) predictions. *Meteorological applications*, 24(3), 315–325.
- Lee, S., Purushwalkam Shiva Prakash, S., Cogswell, M., Ranjan, V., Crandall, D., & Batra, D. (2016). Stochastic multiple choice learning for training diverse deep ensembles. *Advances in Neural Information Processing Systems*, 29.
- Ham, Y. G., Kim, J. H., & Luo, J. J. (2019). Deep learning for multi-year ENSO forecasts. *Nature*, 573(7775), 568–572.

- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., ... & Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999–2049.
- Hong, H., Liu, J., Bui, D. T., Pradhan, B., Acharya, T. D., Pham, B. T., ... & Ahmad, B. B. (2018). Landslide susceptibility mapping using J48 Decision Tree with AdaBoost, Bagging and Rotation Forest ensembles in the Guangchang area (China). *Catena*, 163, 399–413.
- Haiden, T., Janousek, M., Vitart, F., Bouallegue, Z. B., Ferranti, L., Prates, F., & Richardson, D. (2019). Technical Memo.
- Park, S., Kim, D. J., Lee, S. W., Lee, K. W., Kim, J., Song, E. J., & Seo, K. H. (2017). Comparison of extended medium-range forecast skill between KMA ensemble, ocean coupled ensemble, and GloSea5. *Asia-Pacific Journal of Atmospheric Sciences*, 53(3), 393–401.
- Choi, J., Son, S. W., Ham, Y. G., Lee, J. Y., & Kim, H. M. (2016). Seasonal-to-interannual prediction skills of near-surface air temperature in the CMIP5 decadal hindcast experiments. *Journal of Climate*, 29(4), 1511–1527.
- Jung, M. I., Son, S. W., Choi, J., & Kang, H. S. (2015). Assessment of 6-month lead prediction skill of the GloSea5 hindcast experiment. *Atmosphere*, 25(2), 323–337.
- Goddard, L., Kumar, A., Solomon, A., Smith, D., Boer, G., Gonzalez, P., ... & Delworth, T. (2013). A verification framework for interannual-to-decadal predictions experiments. *Climate Dynamics*, 40(1), 245–272.
- Matsueda, M., Endo, H., & Mizuta, R. (2010). Future change in Southern Hemisphere summertime and wintertime atmospheric blockings simulated using a 20-km-mesh AGCM. *Geophysical Research Letters*, 37(2).
- Martínez-Alvarado, O., Gray, S. L., Hart, N. C., Clark, P. A., Hodges, K., & Roberts, M. J. (2018). Increased wind risk from sting-jet windstorms with climate change. *Environmental research letters*, 13(4), 044002.
- Miyoshi, T., Sato, Y., & Kadowaki, T. (2010). Ensemble Kalman filter and 4D-Var intercomparison with the Japanese operational global analysis and prediction system. *Monthly Weather Review*, 138(7), 2846–2866.
- Hyun, Y. K., Park, J., Lee, J., Lim, S., Heo, S. I., Ham, H., ... & Kim, Y. (2020). Reliability assessment of temperature and precipitation seasonal probability in current climate prediction systems. *Atmosphere*, 30(2), 141–154.
- Whitaker, J. S., Hamill, T. M., Wei, X., Song, Y., & Toth, Z. (2008). Ensemble data assimilation with the NCEP global forecast system. *Monthly Weather Review*, 136(2), 463–482.
- Houtekamer, P. L., Mitchell, H. L., & Deng, X. (2009). Model error representation in an operational ensemble Kalman filter. *Monthly Weather Review*, 137(7), 2126–2143.
- Whitaker, J. S., & Hamill, T. M. (2012). Evaluating methods to account for system errors in ensemble data assimilation. *Monthly Weather Review*, 140(9), 3078–3089.
- 기상청 (2021). 이상기후보고서.
- 기상청 (2012). 손에 잡히는 예보기술. 제 15호.

제 2 세부과제

“양상블모델의 섭동 및 팽창기법 개선방안 제시”

연구기관
상명대학교

요 약 문

제 2 세부과제는 앙상블모델 성능개선을 위한 섭동 및 팽창 기법 최적화 방안 제시를 목표로 하였다. 이 목표를 달성하기 위해, 앙상블 자료동화시스템을 위한 새로운 팽창 기법을 고안하였으며 현업 적용 방안을 제시하였다. 새롭게 고안된 팽창 기법의 성능을 분석하기 위해 동아시아 주변에서 NCEP 분석장 대비 기존의 LETKF와 새로운 팽창기법이 적용된 LETKF의 배경장[동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)]의 자료동화 성능을 분석하였다. 세부적인 내용은 아래와 같다.

1). 앙상블 자료동화시스템을 위한 섭동 및 팽창 기법 분석

- 앙상블모델 성능개선을 위한 섭동 및 팽창 기법 최적화 방안 제시
- 최적화된 섭동 및 팽창 기법의 성능 검증 및 현업 적용 방안 제시
- 동아시아 지역에서 고안된 팽창 기법의 자료동화 성능 분석

차 례

제 1 장 사업의 필요성	1
제 2 장 사업 목적	2
제 3 장 사업 개요	2
제 4 장 사업 수행 내용 및 결과	4
제 1 절. 앙상블 자료동화시스템을 위한 개선된 팽창 기법 제시	4
1-1) LUTKF 알고리즘 소개	4
1-2) 비선형 시스템 모델	5
1-3) UT (unscented transform)	6
1-4) 초기장 생성	7
1-5) Forecast model을 이용한 상태 예측(배경장 생성)	7
1-6) Observation model을 이용한 관측 공간에서의 배경장 추정	9
1-7) KF를 이용한 상태 추정(분석장 생성)	10
1-8) 앙상블 모델의 섭동 관점에서 LETKF 대비 LUTKF의 장점	12
1-9) 현업 코드 내의 LUTKF와의 차이점	12
제 2 절. 개선된 팽창 기법의 현업 적용 방안 제시	13
2-1) 배경장 앙상블 공분산 계산	13
2-2) 관측공간에서의 배경장 공분산 계산	14
2-3) cross 에러 공분산 계산	14
2-4) 칼만 게인 계산	15
2-5) 분석장 앙상블 평균 계산	15
2-6) 분석장 앙상블 공분산 계산	16
2-7) Sigma point 선택(앙상블 멤버 샘플링)	16
제 3 절. 개선된 팽창 기법의 성능 검증	18
3-1) 시계열 검증	18
3-2) 수평 검증	20
3-3) 연직 검증	24
제 5 장 사업수행결과의 활용 계획	27
제 6 장 참고 문헌	28

표 차례

표 2.1.1 Bayesian filter 비교	4
표 2.1.2 현업 코드 내의 LUTKF과 개선된 LUTKF의 비교	12

그림 차례

그림 2.1.1 LUTKF(Bayesian filter)의 개념	5
그림 2.1.2 UT (unscented transform)의 개념	7
그림 2.1.3 배경장(prediction), 관측장(observation), 분석장(analysis)의 확률밀도 함수(pdf)	12
그림 2.2.1 lutkf_core내의 LUTKF 실행 순서도	13
그림 2.3.1 2008년 9월 3일 18 UTC부터 2008년 9월 19일 18 UTC까지 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 풍속(W), 온도(T), 습도(Q), 해수면 기압(SLP)]에 대한 시계열 RMSD	19
그림 2.3.2 2008년 9월 3일 18 UTC부터 2008년 9월 19일 18 UTC까지 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 풍속(W), 온도(T), 습도(Q), 해수면 기압(SLP)]에 대한 시계열 표준편차(standard deviation)	20
그림 2.3.3 2008년 9월 12일 12UTC에 LETKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)]	21
그림 2.3.4 2008년 9월 12일 12UTC에 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)]	22
그림 2.3.5 2008년 9월 12일 12UTC에 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)] RMSD reduction	23
그림 2.3.6 2008년 9월 12일 12UTC에 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)] RMSD의	

vertical profile	25
그림 2.3.7 2008년 9월 12일 12UTC에 850hPa에서 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)] RMSD reduction의 vertical profile	26

제 1 장 사업의 필요성

LETKF에서 제한적인 개수의 관측과 앙상블 멤버의 사용, 그리고 모델 오차 등이 존재할 때 배경장 공분산이 과소 추정되어 배경장을 과대 신뢰하고 관측장을 과소 신뢰하여 분석장에서 관측장이 무시됨에 따라 부정확한 분석결과를 초래할 수 있다. 이러한 LETKF의 문제를 해결하기 위해 곱셈팽창기법(multiplicative inflation method), 덧셈팽창기법(additive inflation method), RTPS (Relaxation to Prior Spread) 등과 같이 배경장 공분산 또는 분석장 공분산을 팽창시키는 기법들이 제안되었다.

현재 기상청(KMA)의 한국형앙상블모델 앙상블자료동화 시스템에 장착되어 현업 운영되고 있는 LETKF에서는 덧셈팽창기법(Whitaker et al., 2008; Houtekamer et al., 2009)과 RTPS 기법(Whitaker and Hamil, 2012)을 사용한다. 자료동화 사이클에서 RTPS를 사용하여 팽창된 분석장 표준편차는 배경장 표준편차에 가까워졌지만 분석장 표준편차와 배경장 표준편차 모두 동화 사이클이 경과될수록 현저하게 감소하는 것을 발견할 수 있다. 이러한 표준편차 값의 현저한 감소는 KIM 모델 예측 결과에 대한 신뢰도를 높이고 관측 정보에 대한 신뢰도를 상대적으로 낮춤으로써 LETKF의 자료동화 성능을 저하시킬 수 있다. 따라서 이러한 문제를 해결하기 LETKF에서는 RTPS에서 계산된 배경장과 분석장의 표준편차를 증가시키기 위해 덧셈팽창기법을 사용한다. 덧셈팽창기법은 임의의 섭동을 분석장 앙상블 멤버에 더해 분석장 공분산을 팽창시킨다. 그런데 덧셈팽창기법은 LETKF 분석장에 KIM 모델 에러를 반영하는 임의의 노이즈(random noise) 형태로 더해주기 위해 수일에 걸쳐 수천 개에 이르는 임의의 에러 샘플 데이터를 생성할 필요가 있다. 이러한 방법은 에러 샘플 데이터가 생성된 시기에 영향을 받으며 KIM 모델에 크게 의존하기 때문에 KIM 모델의 해상도가 변하거나 기법상 큰 변화가 있으면 에러 샘플 데이터를 재생성해야 하는 불편이 있다. 또한 덧셈팽창기법은 이 기법 내에서 사용되는 파라미터를 생성된 샘플에 맞게 적절하게 설정할 필요가 있으므로 여러 번의 민감도 실험이 요구된다. 상당한 에러 샘플 데이터를 요구하는 덧셈팽창기법으로 인한 많은 수고와 불편을 초래하지 않고 만족스러운 자료동화 성능을 제공하기 위해 덧셈팽창기법을 요구하지 않으며 앙상블 spread가 모델의 불확실성을 보다 정확히 추정할 수 있는 공분산팽창기법을 제시하는 연구는 필요하다.

제 2 장 사업 목적

제 2 세부과제는 앙상블 자료동화시스템을 위한 새로운 팽창 기법을 제시하고 현업 적용 방안을 제시하고자 하였다. 새롭게 고안된 팽창 기법의 성능을 분석하기 위해 동아시아 주변에서 NCEP 분석장 대비 기존의 LETKF와 새로운 팽창기법이 적용된 LETKF의 배경장[동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)]의 자료동화 성능을 분석하였다. 세부적인 내용은 아래와 같다.

■ 앙상블 자료동화시스템을 위한 섭동 및 팽창 기법 분석

- 1) 앙상블 자료동화시스템을 위한 개선된 팽창 기법 제시
- 2) 개선된 팽창 기법의 현업 적용 방안 제시
- 3) 기존의 LETKF와 개선된 팽창 기법이 적용된 LETKF간의 성능 검증

제 3 장 사업 개요

제 2 세부과제는 앙상블 자료동화시스템을 위한 새로운 팽창 기법을 고안하였으며 현업 적용 방안을 제시하였다. 새롭게 고안된 팽창 기법의 성능을 분석하기 위해 동아시아 주변에서 NCEP 분석장 대비 기존의 LETKF와 새로운 팽창기법이 적용된 LETKF의 배경장[동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)]의 자료동화 성능을 분석하였다.

■ 앙상블 자료동화시스템을 위한 개선된 팽창 기법 제시

- 1) 개선된 팽창 기법에서 사용된 LUTKF 알고리즘 소개
- 2) LUTKF 알고리즘의 UT (unscented transform) 소개
- 3) LUTKF 알고리즘의 Forecast model을 이용한 상태 예측(배경장 생성)
- 4) LUTKF 알고리즘의 Observation model을 이용한 관측 공간에서의 배경장 추정
- 5) LUTKF 알고리즘의 KF를 이용한 상태 추정(분석장 생성)
- 6) LUTKF 알고리즘의 앙상블 모델의 섭동 관점에서 LETKF과 LUTKF의 비교

■ 개선된 팽창 기법의 현업 적용 방안 제시

- 1) 배경장 앙상블 공분산 계산
- 2) 관측공간에서의 배경장 공분산 계산
- 3) cross 에러 공분산 계산
- 4) 칼만 게인 계산
- 5) 분석장 앙상블 평균 계산
- 6) 분석장 앙상블 공분산 계산
- 7) Sigma point 선택(앙상블 멤버 샘플링)

■ 개선된 팽창 기법의 성능 검증

- 1) 시계열 검증
- 2) 수평 검증
- 3) 연직 검증

제 4 장 사업 수행 내용 및 결과

제 1 절. 앙상블 자료동화시스템을 위한 개선된 팽창 기법 제시

1-1) LUTKF 알고리즘 소개

LUTKF(local unscented transform Kalman filter)는 LETKF와 같이 샘플(sample) 기반의 칼만 필터로서 모델에 대한 선형화를 가정으로 했던 LETKF와 달리 UT(unscented transform)를 사용하여 선형화하지 않은 process model(KIM 등)과 observation model(KPOP 등)을 통해 샘플들을 propagation한 다음 샘플들의 평균과 공분산을 통해 알고자 하는 상태를 추정하는 방식이다.

표 2.1.1은 Bayesian filter들의 주요 특징을 비교할 수 있도록 표로 정리한 것이다. KF(Kalman filter)의 변형 알고리즘인 LETKF와 LUTKF는 모두 process model noise과 observation model noise가 정규분포를 따라야 한다. 일반적인 KF는 process model과 observation model 모두 선형 모델이어야 한다. 그러나 샘플기반의 KF인 LETKF와 LUTKF에서 process model과 observation model은 선형화를 하지 않는다. 다만 LETKF에서 observation model은 선형화가 되어 있다고 가정한다. 수많은 샘플을 사용하는 몬테칼로 방식인 PF(particle filter)는 LETKF와 LUTKF와 마찬가지로 process model과 observation model이 선형화하지 않는다. 상대적으로 LETKF와 LUTKF 보다 많은 샘플을 사용하여 계산비용이 높지만 LETKF와 LUTKF 보다 정확한 성능을 보장한다. 그러나 높은 계산 비용으로 인해 현업에서는 실제로 쓰이지 않고 있다.

표 2.1.1 Bayesian filter 비교

종류	Process model	Process model noise	Observation model	Observation model noise	State estimation accuracy
KF	Linear	Gaussian	Linear	Gaussian	Poor
LETKF	Linear/nonlinear	Gaussian	Linearization 가정	Gaussian	Good
LUTKF	Linear/nonlinear	Gaussian	Linear/nonlinear	Gaussian	Good
PF	Linear/nonlinear	Non-Gaussian	Linear/nonlinear	Non-Gaussian	Best

Hidden Markov model (HMM)으로 모델링된 dynamic system은 그림 2.1.1의 회색 부분과 같이 나타낼 수 있다. 시스템 상태는 hidden되어 있으므로 실제로 어떤 값을 가지는지 알 수 없다. 따라서 KIM과 같은 예측 모델을 통해 시스템의 상태를 추정할 수 있다. 하지만 hidden 상태를 예측 모델이 제대로 추정할 수 없기 때문에 시간이 지남에 따라 에러가 누적되서 예측 모델이 오작동 할 수 있다. 위성이나 존데 등과 같은 센서를 관측기로 사용하면 hidden 상태를 외부에서 파악할 수 있다. 그러나 관측기에도 관측 오차로 인해 정확한 시스템 상태를 추정하기 어려울 수 있다. 이러한 문제를 해결하기 위해 그림 2.1.1과 같이 Bayesian filter는 관측값이 측정된 시점마다 예측 모델이 예측한 상태와 관측기의 관측값을 융합하여 보다 정확하게 hidden 상태를 추정할 수 있도록 하는 recursive state estimate을 제공한다.

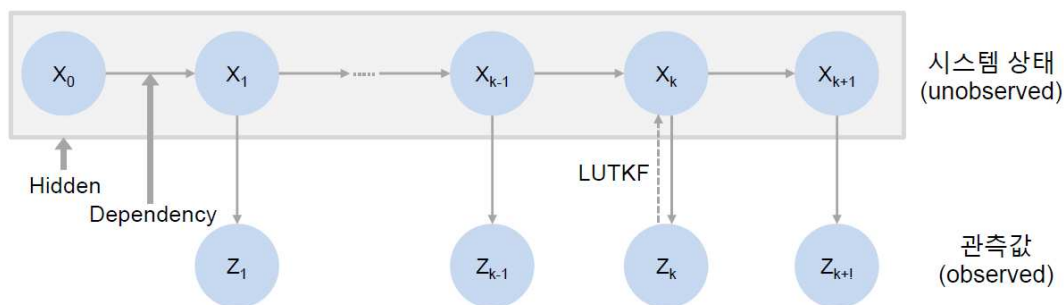


그림 2.1.1 LUTKF(Bayesian filter)의 개념

1-2) 비선형 시스템 모델

LUTKF에서 사용되는 비선형 시스템 모델은 다음과 같이 나타낼 수 있다.

$$x_k = f_{k-1}(x_{k-1}) \quad (1)$$

$$z_k = h_k(x_k) + v_k \quad (2)$$

식 (2)는 시간 $k-1$ 에서 k 로 예측하고자 하는 상태 x 를 propagation하는 process model $f_{k-1}(\cdot)$ 이며 KIM이 이 모델에 해당된다. 식 (2)는 시간 k 에서 상태 x 에 대한 관측값을 구하는 observation model $h_k(\cdot)$ 이며 KPOP에 이 모델에 해당

된다. v_k 은 observation model noise이며 $v_k \sim \mathcal{N}(0, R)$ 와 같이 평균이 0이고 공분산이 R 인 정규분포를 따르는 white noise이다. x_k 는 시스템 상태를 나타낸다. 상태변수의 noise w_k 는 white noise이므로 서로 독립되어 있다고 가정한다. 따라서 공분산 Q 는 아래와 같은 대각행렬의 형태를 띈다. 마찬가지로 공분산 R 은 l 개의 관측값의 noise v_k 는 white noise이므로 서로 독립되어 있다고 가정하여 대각행렬을 형태를 띈다.

1-3) UT (unscented transform)

LUTKF (local unscented transform Kalman filter)는 LETKF와 같이 샘플 (sample) 기반의 칼만 필터로써 LUTKF에서는 샘플을 시그마 포인트(sigma point)라고 부른다. 상태 변수의 수를 n 이라고 하면 시그마 포인트의 수는 $2n$ 이다. UT(unscented transform)는 임의의 비선형 함수에 근사(approximation)하도록 선형화하는 것보다 시그마 포인트들을 통해 확률 분포에 근사하는 것이 더 쉽다는 직관에 근거하는 것이다 (Nambiar et al. 2021, Deng et al. 2014, Julier et al. 1997, Julier and Uhlmann 2004, Van Der Merwe et al. 2004, Van Der Merwe and Rudolph 2004, Wan and Van Der Merwe 2000). LUTKF는 그림 2.1.2과 같이 UT를 사용하여 비선형 모델의 확률분포를 시그마 포인트들로 표현한 다음 해당 비선형 모델을 통해 nonlinear transformation한 뒤 시그마 포인트들의 평균 $\hat{x}_{k|k}$ 과 공분산 $P_{k|k}$ 을 계산하여 비선형 모델의 상태를 추정한다.




그림 2.1.2 UT (unscented transform)의 개념

1-4) 초기장 생성

LUTKF의 초기장은 다음과 같이 시간 $k=0$ 에서 비선형 모델 상태의 평균값 $\hat{x}_{0|0}$ 과 공분산 $P_{0|0}$ 이다.

$$\hat{x}_{0|0} = E[x_0] \quad (3)$$

$$P_{0|0} = E[(x_0 - \hat{x}_{0|0})(x_0 - \hat{x}_{0|0})^T] \quad (4)$$

LUTKF의 초기장은 LETKF의 초기장을 생성하는데 사용된 앙상블으로부터 식 (3) 과 식 (4)을 사용하여 생성될 수 있다. 참고로 $x_{k|k-1}$ 은 시간 $k-1$ 에서 시간 k 의 상태를 예측한 a priori 상태를 나타내고, $x_{k|k}$ 은 시간 k 에서 상태 x 를 관측한 관측값 z 과 $x_{k|k-1}$ 를 통해 상태 x 를 추정된 a posteriori 상태를 나타낸다.

1-5) Forecast model을 이용한 상태 예측(배경장 생성)

UT를 이용하여 모델의 상태를 추정하기 위해 먼저 $2n$ 개의 시그마 포인트 $\{x_{k-1|k-1}^i\}_{i=1}^{2n}$ 를 선택한다. 아래의 식은 시그마 포인트들이 시스템 모델 상태의 확률분포(정규분포)에 근사할 수 있도록 한다.

$$x_{k-1|k-1}^i = \hat{x}_{k-1|k-1} + (\sqrt{nP_{k-1|k-1}})_i, \text{ where } i = 1, \dots, n \quad (5)$$

$$x_{k-1|k-1}^i = \hat{x}_{k-1|k-1} - (\sqrt{nP_{k-1|k-1}})_i, \text{ where } i = n+1, \dots, 2n \quad (6)$$

$\sqrt{nP_{k-1|k-1}}$ 는 $nP_{k-1|k-1}$ 의 square root matrix로써 여러 방법으로 계산될 수 있지만 LUTKF에서는 안정적인 결과를 제공하는 Cholesky decomposition을 통해 구한다 (Van Der Merwe et al. 2004). $(\sqrt{nP_{k-1|k-1}})_i$ 은 $nP_{k-1|k-1}$ 에 대한 Cholesky decomposition의 low triangular matrix $\sqrt{nP_{k-1|k-1}}$ 의 i 번째 column을 나타낸다.

그 다음 식 (7)의 forecast model $f_k(\cdot)$ 을 이용하여 선택된 시그마 포인트들을 nonlinear transformation한다.

$$x_{k|k-1}^i = f_k(x_{k-1|k-1}^i) \quad (7)$$

nonlinear transformation된 시그마 포인트들을 통해 시간 k 에서의 a priori 상태의 평균 $\hat{x}_{k|k-1}$ 과 공분산 $P_{k|k-1}$ 을 다음과 같이 구할 수 있다.

$$\hat{x}_{k|k-1} = \frac{1}{2n} \sum_{i=1}^{2n} x_{k|k-1}^i \quad (8)$$

추정된 a priori 상태 $\hat{x}_{k|k-1}$ 의 에러 $e_{k|k-1}^i$ 는 다음과 같이 표현할 수 있으며 $e_{k|k-1}^i$ 는 $e_{k|k-1}^i \sim N(0, P_{k|k-1})$ 을 만족하는 white noise이다.

$$e_{k|k-1}^i = x_{k|k-1}^i - \hat{x}_{k|k-1} \quad (9)$$

$e_{k|k-1}^i$ 의 공분산 $P_{k|k-1}$ 은 다음과 같이 계산할 수 있다.

$$\begin{aligned} P_{k|k-1} &= \frac{1}{2n} \sum_{i=1}^{2n} e_{k|k-1}^i e_{k|k-1}^{i T} \\ &= \frac{1}{2n} X X^T \end{aligned} \quad (10)$$

식 (10)에서 X 는 i 번째 column이 a priori 상태 에러 벡터 $e_{k|k-1}^i$ 인 행렬이다.

1-6) Observation model을 이용한 관측 공간에서의 배경장 추정

Observation model $h_k(\cdot)$ 을 이용하여 시그마 포인트들을 식 (11)과 같이 nonlinear transformation한다.

$$z_k^i = h_k(x_{k|k-1}^i) \quad (11)$$

그 다음 $h_k(\cdot)$ 를 이용하여 nonlinear transformation된 시그마 포인트들을 통해 시간 k 에서의 관측값 평균 \hat{z}_k 는 다음과 같이 추정할 수 있다.

$$\hat{z}_k = \frac{1}{2n} \sum_{i=1}^{2n} z_k^i \quad (12)$$

관측값의 오차가 아니라 관측값의 residual (innovation) \tilde{z}_k^i 은 다음과 같이 계산할 수 있으며, \tilde{z}_k^i 는 $\tilde{z}_k^i \sim N(0, S_k)$ 을 만족하는 white noise이다.

$$\tilde{z}_k^i = z_k^i - \hat{z}_k \quad (13)$$

관측값의 residual (innovation) \tilde{z}_k^i 의 공분산 S_k 은 다음과 같이 계산할 수 있다. 공분산 R_k 의 대각행렬원소는 각 관측값의 분산값이다.

$$\begin{aligned} S_k &= \frac{1}{2n} \sum_{i=1}^{2n} \tilde{z}_k^i \tilde{z}_k^{iT} + R_k \\ &= \frac{1}{2n} Z Z^T + R_k \end{aligned} \quad (14)$$

식 (14)에서 Z 는 i 번째 column이 관측값의 residual (innovation) 벡터 \tilde{z}_k^i 인 행렬이다.

1-7) KF를 이용한 상태 추정(분석장 생성)

LUTKF를 사용하여 a posteriori 상태를 추정하려면 먼저 아래의 식과 같이 식 (10)의 x 와 식 (14)의 Z 를 사용하여 cross error 공분산을 구할 수 있다.

$$\begin{aligned} P_{xz} &= Cov(e_{k|k-1}^i, \tilde{z}_k^i) \\ &= E[e_{k|k-1}^i \tilde{z}_k^{iT}] \end{aligned} \quad (15)$$

$$\begin{aligned}
&= \frac{1}{2n} \sum_{i=1}^{2n} e_{k|k-1}^i \tilde{z}_k^{iT} \\
&= \frac{1}{2n} XZ^T
\end{aligned}$$

Kalman gain K_k 은 다음과 같이 유도된다.

$$\begin{aligned}
P_{k|k} &= E[e_{k|k} e_{k|k}^T] & (16) \\
&= E[(x_k - \hat{x}_{k|k})(x_k - \hat{x}_{k|k})^T] \\
&= E[(x_k - (\hat{x}_{k|k-1} + K_k \tilde{z}_k))(x_k - (\hat{x}_{k|k-1} + K_k \tilde{z}_k))^T] \\
&= E[(e_{k|k-1} - K_k \tilde{z}_k)(e_{k|k-1} - K_k \tilde{z}_k)^T] \\
&= E[(e_{k|k-1} - K_k \tilde{z}_k)(e_{k|k-1}^T - \tilde{z}_k^T K_k^T)] \\
&= E[e_{k|k-1} e_{k|k-1}^T - e_{k|k-1} \tilde{z}_k^T K_k^T - K_k \tilde{z}_k e_{k|k-1}^T + K_k \tilde{z}_k \tilde{z}_k^T K_k^T] \\
&= E[e_{k|k-1} e_{k|k-1}^T] - E[e_{k|k-1} \tilde{z}_k^T] K_k^T - K_k E[\tilde{z}_k e_{k|k-1}^T] + K_k E[\tilde{z}_k \tilde{z}_k^T] K_k^T \\
&= P_{k|k-1} - P_{xz, k|k-1} K_k^T - K_k P_{zx, k|k-1} + K_k S_k K_k^T
\end{aligned}$$

식 (16)을 통해 최적의 Kalman gain K_k 을 구하기 위해 $Tr(P_{k|k})$ 를 최소화하는

$\frac{Tr(P_{k|k})}{\partial K_k} = 0$ 을 만족시키는 최적의 K_k 를 구하면 아래와 같다.

$$\frac{Tr(P_{k|k})}{\partial K_k} = -P_{xz, k|k-1} - P_{zx, k|k-1} + 2K_k S_k \quad (17)$$

$$= -2P_{zx, k|k-1} + 2K_k S_k = 0$$

$$K_k = P_{zx, k|k-1} S_k^{-1} \quad (18)$$

따라서 LUTKF에서 사용되는 최적의 Kalman gain K_k 은 식 (15)의 P_{xz} 과 식 (14)의 S_k 를 통해 구할 수 있다.

$$K_k = P_{xz} S_k^{-1} \quad (19)$$

시간 k 에서 Kalman gain K_k 와 KPOP에서 제공되는 관측값 z_k 을 통해 a priori 상태 $\hat{x}_{k|k-1}$ 와 $P_{k|k-1}$ 를 update한 a posteriori 상태 $\hat{x}_{k|k}$ 와 $P_{k|k}$ 은 다음과 같이 추정할 수 있다.

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - \hat{z}_k) \quad (20)$$

$$P_{k|k} = P_{k|k-1} - K_k S_k K_k^T \quad (21)$$

a priori 상태의 확률밀도함수 $P(x_k|z_{1:k-1})$ 와 관측값의 확률밀도함수 $P(z_k|x_k)$ 와 자료동화된 a posteriori 상태의 확률밀도함수 $P(x_k|z_{1:k})$ 는 아래의 그림 2.1.3으로 나타낼 수 있다. 이 그림을 통해 동적 모델의 실제 상태값은 그림 2.1.1에서와 같이 hidden되어 있으므로 정확히 알 수 없지만 예측모델을 통한 예측값(a priori 상태)과 관측기로부터 얻은 관측값을 이용한 자료동화를 통해 분석값(a posteriori 상태)을 얻어 보다 정확한 상태 추정을 할 수 있다는 것을 보여준다.




그림 2.1.3 배경장(prediction), 관측장(observation), 분석장(analysis)의 확률밀도함수(pdf)

1-8) 앙상블 모델의 섭동 관점에서 LETKF 대비 LUTKF의 장점

LETKF는 analysis ensemble 평균 $\hat{x}_{k|k}$ 을 중심으로 analysis ensemble perturbation X 을 사용하여 analysis ensemble member들을 샘플링한다. 그런데 칼만 필터(Kalman filter)가 제대로 된 성능을 발휘하려면 process와 observation model의 noise는 정규분포를 따라야 한다. 그러므로 Kalman gain을 이용하여 상태를 추정하는 칼만 필터의 고유한 기능을 물려받은 LETKF도 또한 정상적인 성능을 얻기 위해 process와 observation model의 noise는 정규분포를 따라야 한다. 즉, LETKF에서 샘플링되는 analysis ensemble member는 정규분포를 따라야 한다. 그러나 LETKF에서 샘플링되는 analysis ensemble member는 정규분포를 따르지 않을 수 있으며 공분산이 과소 추정 될 수 있다. 따라서 최적의 성능을 얻기 위해서는 정규분포를 따르고 공분산이 과소 추정되지 않도록 공분산 팽창기법이 필요하다. 이에 반해, LUTKF는 매 사이클에서 sigma-point selection 이라는 샘플링 방법을 사용하여 시스템 모델 상태의 확률분포(정규분포)에 근사하도록 analysis ensemble을 샘플링하고 공분산을 팽창시킬 수 있다.

1-9) 현업 코드 내의 LUTKF와의 차이점

표 2.1.2 현업 코드 내의 LUTKF과 개선된 LUTKF의 비교

구분	현업 코드 내의 LUTKF	개선된 LUTKF
자료동화 방법 (Kalman gain 계산 방법)	관측 공간에서 자료동화 수행	양상불 공간에서 자료동화 수행
계산 비용	동화되는 관측장의 수에 따라 계산 비용이 지수적으로 증가함	계산 비용을 LETKF와 비슷하게 최적화 함
CPU core 사용량	LETKF와 동일한 계산 시간에 자료동화를 수행하려면 LETKF보다 10배 이상의 CPU core를 요구함	LETKF와 동일한 계산 시간에 자료동화를 수행하려면 LETKF와 동일한 CPU core를 요구함
메모리 사용	동화되는 관측장의 수에 따라 역행렬 계산에 요구되는 메모리 크기가 증가함	요구되는 메모리 크기를 LETKF와 비슷하게 최적화 함
초기장생성	LUTKF의 양상불 평균과 공분산을 이용하여 생성해야 함	LETKF의 배경장또는 분석장양상불로부터 초기장생성 가능
sigma point selection	LETKF 초기장들을 통해 생성해야 함	LETKF의 배경장또는 분석장양상불로부터 초기장생성 가능
현업에서 사용 가능성	LETKF보다 현저히 많은 CPU core와 메모리를 사용하기 때문에 현업 자료동화 시스템에서 사용하기 힘들	LETKF과 비슷한 CPU core 수와 메모리 크기를 요구하므로 현업 자료동화 시스템에서 사용 가능

제 2 절. 개선된 팽창 기법의 현업 적용 방안 제시

현재 자료동화를 위해 사용중인 LETKF와 새롭게 고안된 LUTKF를 선택적으로 실행하기 위해 LUTKF 알고리즘을 서브루틴 lutkf_core()으로 작성하였다. LETKF를 실행시키기 위해 서브루틴 letkf_core()을 호출하면 되고 LUTKF를 실행시키려면 서브루틴 lutkf_core()을 호출하면 된다. 그림 2.2.1는 서브루틴 lutkf_core()내의 LUTKF의 실행 순서를 보여준다. 관측값이 존재(nobs \neq 0)하면 배경장 앙상블 공분산 $P_{k|k-1}$, 관측공간에서의 배경장 공분산 S_k , cross 에러 공분산 P_{xz} , 칼만 게인 K_k , 분석장 앙상블 평균 $\hat{x}_{k|k}$, 분석장 앙상블 공분산 $P_{k|k}$, sigma point 선택 순으로 실행되며 관측값이 미존재(nobs == 0)하면 $P_{k|k-1}$, sigma point 선택(앙상블 멤버 샘플링) 순으로 실행된다.

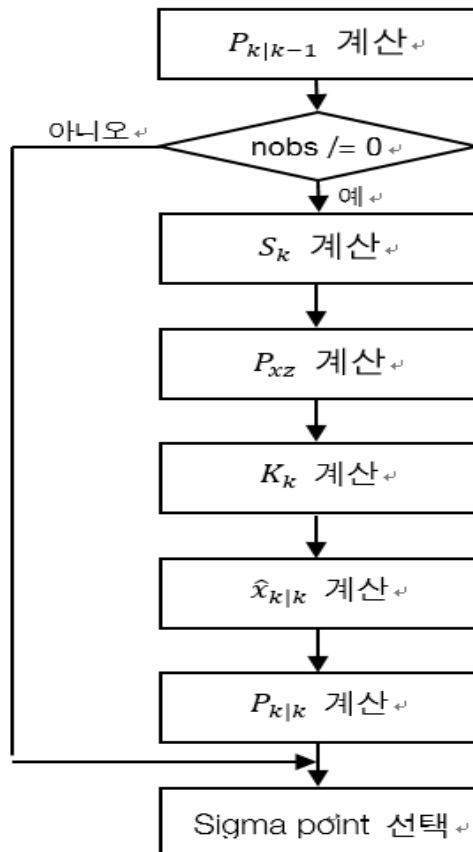


그림 2.2.1 lutkf_core()내의 LUTKF 실행 순서도

2-1) 배경장 앙상블 공분산 $P_{k|k-1}$ 계산

식 (10)의 $P_{k|k-1}$ 는 i 번째 column이 a priori 상태 에러 $e_{k|k-1}^i$ 인 행렬 X 를 통해 아래의 소스코드를 사용하여 계산될 수 있다. 소스코드에서 dgemm는 행렬곱을 수행하는 함수이고, n은 상태 변수의 수, np는 시그마포인트의 수, x_ptbs는 행렬 X , p는 행렬 $P_{k|k-1}$ 를 각각 나타낸다.

```
call dgemm('n','t',n,n,np,1.0d0/real(np,r_size),x_ptb,n,x_ptb,n,0.0d0,p,n)

do i = 1,n
  p(i,i) = p(i,i) + covq3d(i)
end do
```

2-2) 관측공간에서의 배경장 공분산 S_k 계산

식 (14)의 S_k 는 i 번째 column이 관측값의 residual (innovation) \tilde{z}_k^i 인 행렬 Z 를 통해 아래의 소스코드로 계산될 수 있다. 소스코드에서 dgemm는 행렬곱을 수행하는 함수, nobs은 관측값 z_k 의 수, np는 시그마포인트의 수, z_ptb는 행렬 Z , s는 행렬 S_k , r은 관측값 z_k 의 분산, rw는 관측값 z_k 의 가중치를 각각 나타낸다.

```
call dgemm('n','t',nobs,nobs,np,1.0d0/real(np,r_size),z_ptb,nobs,z_ptb,nobs,0.0d0,s,nobs)

do i = 1,nobs
  s(i,i) = s(i,i) + r(i)/rw(i)
end do
```

2-3) cross 에러 공분산 P_{xz} 계산

식 (15)의 P_{xz} 는 i 번째 column이 a priori 상태 에러 벡터 $e_{k|k-1}^i$ 인 행렬 X 와 i 번째 column이 관측값의 residual (innovation) 벡터 \tilde{z}_k^i 인 행렬 Z 를 통해 아래의 소스코드를 사용하여 계산될 수 있다. 소스코드에서 dgemm는 행렬곱을 수행하는 함수, n은 상태 변수의 수, nobs은 관측값 z_k 의 수, np는 시그마포인트의 수, x_ptbs는

행렬 X , z_ptb 는 행렬 Z , pxz 는 행렬 P_{xz} 를 각각 나타낸다.

```
call dgemm('n','t',n,nobs,np,1.0d0/real(np,r_size),x_ptb,n,z_ptb,nobs,0.0d0,pxz,n)
```

2-4) 칼만 게인 K_k 계산

식 (19)의 K_k 는 앞서 계산한 P_{xz} 과 S_k 의 역행렬을 통해 아래의 소스코드를 사용하여 계산될 수 있다. S_k 의 역행렬을 계산하기 위해 먼저 함수 `dgetrf`를 통해 S_k 의 LU factorization을 수행한 다음 함수 `dgetri`를 사용하여 S_k 의 역행렬을 구할 수 있다. 소스코드에서 `dgetrf`는 LU factorization을 수행하는 함수, `dgetri`는 역행렬을 계산하는 함수, `n`은 상태 변수의 수, `nobs`은 관측값 z_k 의 수, `pxz`는 행렬 P_{xz} , `k`는 행렬 K_k 를 각각 나타낸다.

그런데 현업 자료동화에서 어떤 한 UP point에 대한 관측종의 수가 수천에서 수만개에 이를 수 있기 때문에 관측종의 수를 나타내는 변수 `nobs`의 크기가 커져서 역행렬을 계산하는 함수 `dgetrf`와 `dgetri`의 계산비용은 상당히 증가한다.

```
s_inv = s  
  
call dgetrf(nobs,nobs,s_inv,nobs,pivot,errorHandler)  
call dgetri(nobs,s_inv,nobs,pivot,work,nobs*nobs,errorHandler)  
call dgemm('n','n',n,nobs,nobs,1.0d0,pxz,n,s_inv,nobs,0.0d0,k,n)
```

따라서 함수 `dgetrf`와 `dgetri`의 계산 성능을 높이기 위해 인텔에서 제공되는 고성능 수학 라이브러리인 MKL(math kernel library)을 사용하였다. MKL는 수학함수를 실행할 때 여러 계산 노드와 다중 스레드를 사용하여 병렬처리가 가능하도록 설계되어 있다. 그러므로 MKL 수학함수를 사용하면 별도의 병렬화나 최적화 없이 함수 계산에 사용되는 노드나 스레드 개수를 설정하고 실행하면 이전보다 향상된 계산 성능을 얻을 수 있다.

2-5) 분석장 앙상블 평균 $\hat{x}_{k|k}$ 계산

식 (20)의 $\hat{x}_{k|k}$ 는 배경장 앙상블 평균 $\hat{x}_{k|k-1}$, 앞에서 계산된 K_k , 관측값 z_k 와 시그마 포인트를 이용하여 추정된 관측값 \hat{z}_k 을 통해 아래의 소스코드와 같이 계산될 수 있다. 소스코드에서 x는 $\hat{x}_{k|k}$ 와 $\hat{x}_{k|k-1}$, n은 상태 변수의 수, nobs은 관측값 z_k 의 수, k는 Kalman gain K_k , z_rsd는 관측값 residual $z_k - \hat{z}_k$ 를 각각 나타낸다. 또한 상태변수 q(moisture)에 대해서는 qlev이하의 연직레벨에서만 자료동화가 이뤄지도록 구현하였다.

```
do j = 1,nobs
  do i = 1,n ! u, v, t, q (q is assimilated below qlev)
    if(ilev <= qlev .or. j /= iv3d_q) then
      x(i) = x(i) + k(i,j) * z_rsd(j)
    end if
  end do
end do
```

2-6) 분석장 앙상블 공분산 $P_{k|k}$ 계산

식 (21)의 공분산 $P_{k|k}$ 는 $P_{k|k-1}$ 와 앞에서 계산된 K_k , S_k 을 통해 아래의 소스코드와 같이 계산될 수 있다. 소스코드에서 p는 $P_{k|k}$ 와 $P_{k|k-1}$, n은 상태 변수의 수, nobs은 관측값 z_k 의 수, k는 Kalman gain K_k , p_tmp1는 $K_k S_k$, p_tmp1는 $K_k S_k K^T$ 를 각각 나타낸다.

```
call dgemm('n','n',n,nobs,nobs,1.0d0,k,n,s,nobs,0.0d0,p_tmp1,n)
call dgemm('n','t',n,n,nobs,1.0d0,p_tmp1,n,k,n,0.0d0,p_tmp2,n)
p = p - p_tmp2
```

2-7) Sigma point 선택(앙상블 멤버 샘플링)

식 (5)와 식 (6)의 시그마 포인트 $x_{k-1|k-1}^i$ 는 $\hat{x}_{k|k}$ 와 $P_{k|k}$ 을 통해 다음의 소스코드를 사용하여 구할 수 있다. 먼저 $\sqrt{nP_{k-1|k-1}}$ 은 여러 방법으로 계산될 수 있지만 LUTKF에서는 안정적인 결과를 제공하는 Cholesky decomposition을 통해 구한다 (Van Der Merwe et al. 2004). 함수 dpotrf는 Cholesky decomposition를 수행하는 인텔 MKL 함수이며 함수의 결과는 행렬 sigma_mtx에 저장된다. 상태변수 q(moisture)에 대해서는 qlév이하의 연속레벨에서만 자료동화가 이뤄지도록 구현하였다. 소스코드에서 p는 식 (21)의 분석장 공분산 $P_{k|k}$, n은 상태 변수의 수, x는 식 (20)의 $\hat{x}_{k|k}$, xi는 식 (5)과 식 (6)의 시그마포인트 $x_{k-1|k-1}^i$, np는 시그마포인트의 수를 각각 나타낸다.

```

! cholesky decomposition in lapack (sigma_mtx: lower triangular matrix)
sigma_mtx = real(n,r_sngl) * p

call dpotrf('L', n, sigma_mtx, n, errorHandler) ! cholesky decomposition

do j = 2, n
  do i = j-1, 1, -1
    sigma_mtx(i,j) = 0.0e0 ! in order to become a lower triangular matrix
  end do
end do

! Sigma point selection
do j = 1,n ! u, v, t, q (q is assimilated below qlév)
  if(ilev <= qlév .or. j /= iv3d_q) then
    do i = 1,n
      xi(i,j) = real(x(j) + sigma_mtx(j,i),r_size)
      xi(n+i,j) = real(x(j) - sigma_mtx(j,i),r_size)
    end do
  else
    do i = 1,np
      xi(i,j) = real(x(j),r_size)
    end do
  end if
end do

```

제 3 절. 개선된 팽창 기법의 성능 검증

3-1) 시계열 검증

그림 2.3.1는 2008년 9월 3일 18 UTC부터 2008년 9월 19일 18 UTC까지 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)]에 대한 시계열 RMSD을 보여준다. 이 그림을 통해 LUTKF는 LETKF보다 동서바람(U), 남북바람(V), 풍속(WS)에 대한 자

료동화 성능이 좋다는 것을 알 수 있다. 또한, 이 그림은 온도(T), 해수면 기압(SLP)에 대해 LUTKF와 LETKF의 자료동화 성능은 비슷하고 습도(Q)는 LETKF는 LUTKF보다 자료동화 성능이 좋다는 것을 보여준다. U, V에 비해 Q의 관측값이 적는데 LUTKF는 LETKF보다 크게 분석장 공분산 팽창이 되므로 오히려 동화성능이 좋지 않다.




그림 2.3.1 2008년 9월 3일 18 UTC부터 2008년 9월 19일 18 UTC까지 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)]에 대한 시계열 RMSD

그림 2.3.2은 2008년 9월 3일 18 UTC부터 2008년 9월 19일 18 UTC까지 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)]에 대한 시계열 표준편차(spread)를 보여준다. 이 그림은 동서바람(U), 남북바람(V), 풍속(WS), 온도(T), 습도(Q), 해수면 기압(SLP)에 대해 LUTKF는 LETKF보다 큰 spread를 가진다는 것을 보여준다. 동서바람(U), 남북바람(V)에 대해 큰 spread를 가진 LUTKF는 그림 2.3.1에서 보이는 것처럼 LETKF보다 작은 RMSD를 가진다. 즉, LUTKF는 LETKF와 비교하여 동서바람(U), 남북바람(V)에 대해 공분산이 과소 추정되는 것을 막을 수 있으므로 LETKF보다 좋은 자료동화 성능을 제공한다. 그러나 습도(Q)에 대해 지나치게 큰 spread를 가진 LUTKF는 그림 2.3.1에서 보이는 것처럼 오히려 LETKF보다 큰 RMSD를 가진다.



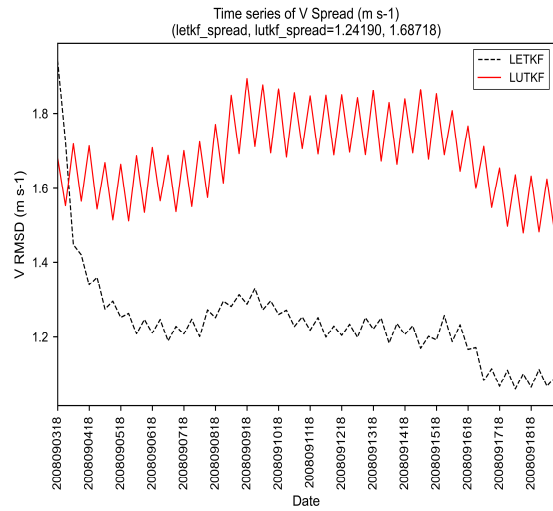



그림 2.3.2 2008년 9월 3일 18 UTC부터 2008년 9월 19일 18 UTC까지 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 풍속(W), 온도(T), 습도(Q), 해수면 기압(SLP)]에 대한 시계열 표준편차(spread)

3-2) 수평 검증

그림 2.3.3은 2008년 9월 12일 12UTC에 LETKF의 배경장[동서바람(U), 남북바

람(V), 가강수량(PW), 해수면 기압(SLP)]을 나타낸다. 해수면 기압(SLP)을 통해 대만 부근에는 태풍이 있고 일본 동북쪽으로 고기압이 있다는 것을 확인할 수 있다.

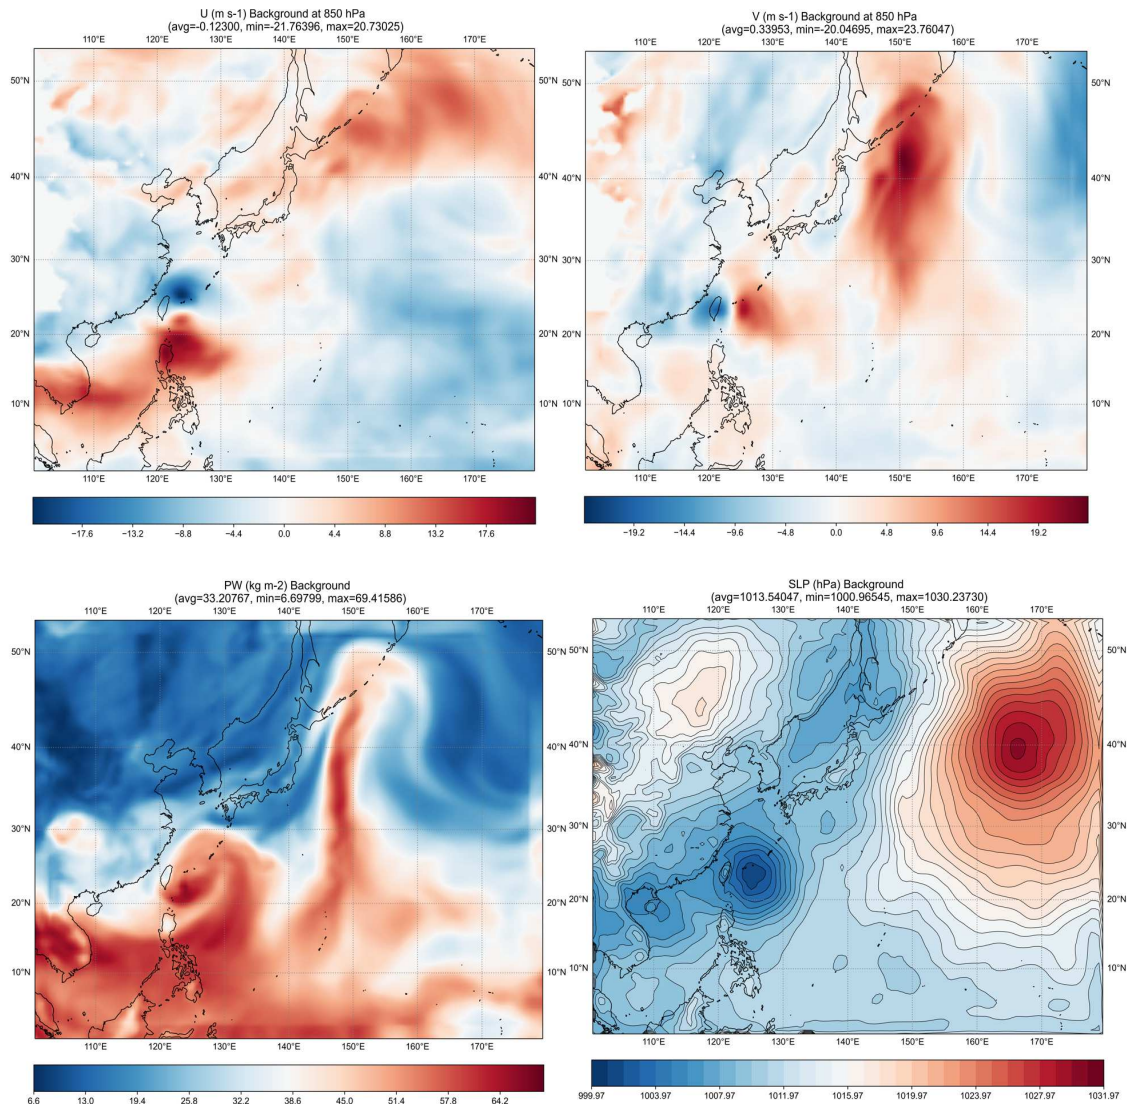


그림 2.3.3 2008년 9월 12일 12UTC에 LETKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)]

그림 2.3.4은 2008년 9월 12일 12UTC에 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)]을 나타낸다. 해수면 기압(SLP)을 통해 대만 부근에는 태풍이 있고 일본 동북쪽으로 고기압이 있다는 것을 확인할 수 있다.

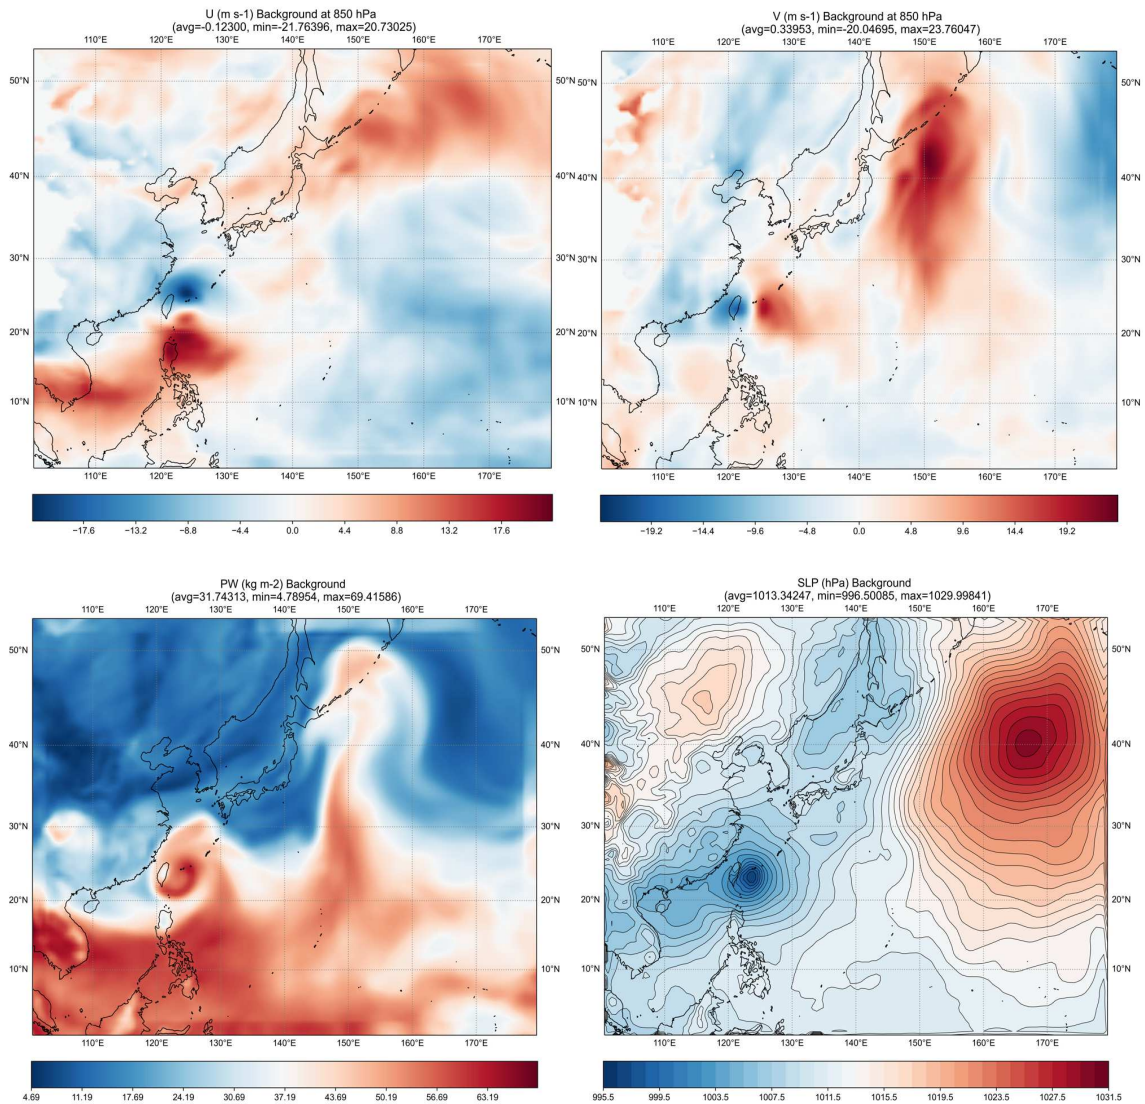


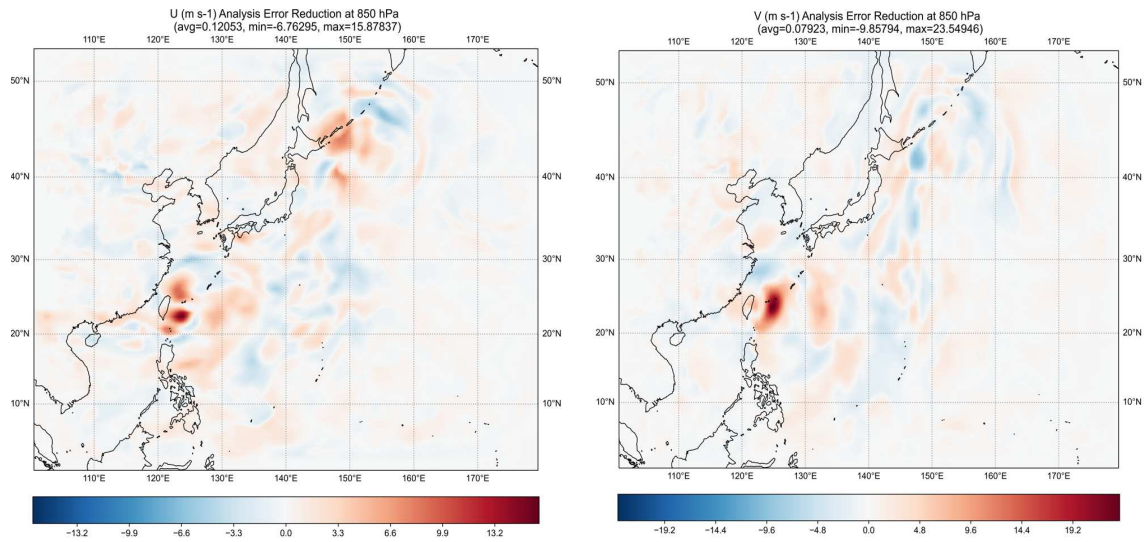
그림 2.3.4 2008년 9월 12일 12UTC에 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)]

그림 2.3.5는 2008년 9월 12일 12UTC에 LETKF와 LUTKF의 배경장 RMSD reduction을 보여준다. 배경장 RMSD reduction은 식(22)와 같이 LETKF 배경장(LETKF_{background})과 NCEP 분석장(NCEP_{analysis})의 차에 대한 절대값과 LUTKF 배경장(LUTKF_{background})과 NCEP 분석장(NCEP_{analysis})의 차에 대한 절대값을 비교하여 LUTKF가 LETKF 대비 배경장의 정확도가 얼마나 개선되었는지 보여준다. 예를 들어, 그림 2.3.5에서 빨간색으로 표시된 부분은 LUTKF가 LETKF보다 더 정확히 배

경장을 추정한다는 것을 나타낸다. 이와 반대로 파란색으로 가까질수록 LETKF가 LUTKF보다 배경장 추정 정확도가 높다는 것을 나타낸다.

$$| \text{LETKF}_{\text{background}} - \text{NCEP}_{\text{analysis}} | - | \text{LUTKF}_{\text{background}} - \text{NCEP}_{\text{analysis}} | \quad (22)$$

그림 2.3.5를 통해 대만 부근의 태풍을 추정하는 자료동화 성능은 LUTKF가 LETKF보다 좋은 성능을 제공(나은 배경장 추정 정확도를 제공)한다는 것을 알 수 있다. 특히 동서바람(U), 남북바람(V), 해수면 기압(SLP)에 대해 LUTKF가 LETKF보다 높은 배경장 추정 정확도를 제공한다.



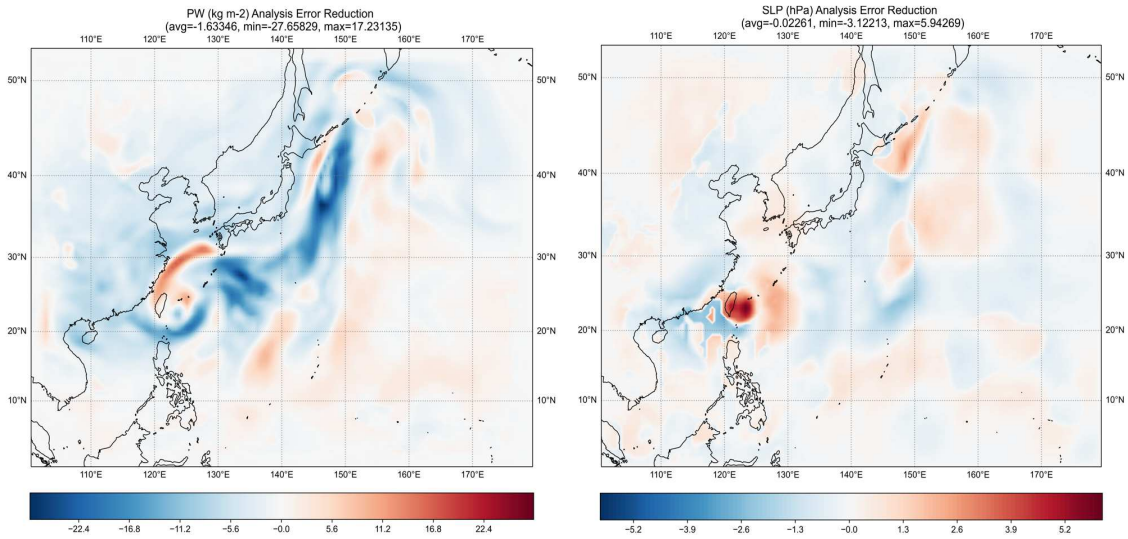



그림 2.3.5 2008년 9월 12일 12UTC에 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)] RMSD reduction

3-3) 연직 검증

그림 2.3.6은 2008년 9월 12일 12UTC에 동서바람(U), 남북바람(V), 온도(T)과 습도(Q) 변수에 대해 LETKF와 LUTKF의 배경장에 대한 NCEP 분석장 대비 RMSD의 vertical profile을 나타낸다. 그림 2.3.6을 통해 확인할 수 있듯이 동서바람(U), 남북바람(V) 변수에 LUTKF는 LETKF보다 낮은 RMSD를 보인다. 이에 반해 온도(T)과 습도(Q) 변수에 대해 LETKF와 LUTKF는 550hPa ~ 950hPa 영역을 제외하고 대체로 비슷한 RMSD를 보인다. 동서바람(U), 남북바람(V) 변수에 비해 관측장의 수가 현저히 적은 온도(T)과 습도(Q) 변수에 대해 LUTKF의 자료동화 성능을 개선하기 위해서 향후 LUTKF의 자료동화 관련 파라미터를 적절히 조정할 계획이다.

그림 2.3.7은 2008년 9월 12일 12UTC에 LETKF와 LUTKF의 배경장 RMSD reduction의 vertical profile을 보여준다. 배경장 RMSD reduction은 식(22)와 같이 LETKF 배경장(LETKF_{background})과 NCEP 분석장(NCEP_{analysis})의 차에 대한 절대값과 LUTKF 배경장(LUTKF_{background})과 NCEP 분석장(NCEP_{analysis})의 차에 대한 절대값을 비교하여 LUTKF가 LETKF 대비 배경장의 정확도가 얼마나 개선되었는지 보여준다. 예를 들어, 그림 2.3.7에서 빨간색으로 표시된 부분은 LUTKF가 LETKF보다 더 정확히 배경장을 추정한다는 것을 나타낸다. 이와 반대로 파란색으로 가까질수록 LETKF가 LUTKF보다 배경장 추정 정확도가 높다는 것을 나타낸다.

그림 2.3.7를 통해 동서바람(U), 남북바람(V)에 대해 대만 부근(20N~30N)의 태풍을 추정하는 자료동화 성능은 LUTKF가 LETKF보다 높은 배경장 추정 정확도를 제공한다는 것을 알 수 있다. 550hPa ~ 1000hPa 영역에서 동서바람(U), 남북바람(V) 변수에 비해 관측장의 수가 현저히 적은 온도(T)과 습도(Q) 변수에 대해 LUTKF의 자료동화 성능을 개선하기 위해서 향후 LUTKF의 자료동화 관련 파라미터를 적절히 조정할 계획이다.






그림 2.3.6 2008년 9월 12일 12UTC에 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)] RMSD의 vertical profile

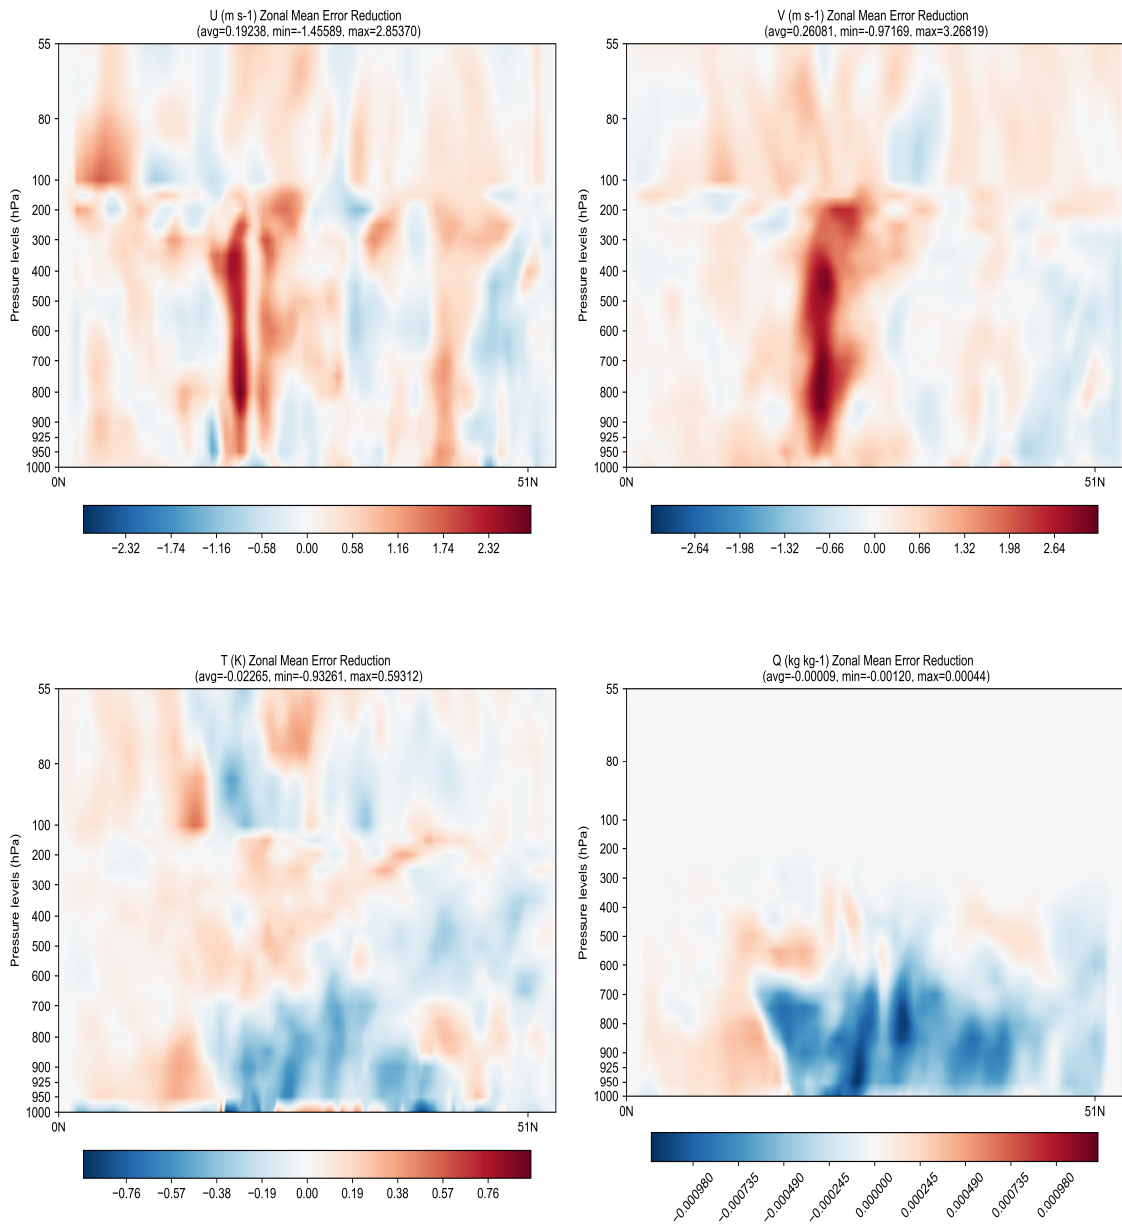


그림 2.3.7 2008년 9월 12일 12UTC에 850hPa에서 NCEP 분석장 대비 LETKF와 LUTKF의 배경장[동서바람(U), 남북바람(V), 가강수량(PW), 해수면 기압(SLP)] RMSD reduction의 vertical profile

제 5 장 사업수행결과의 활용 계획

- 앙상블 자료동화시스템에서 높은 정확도를 가진 앙상블 분석 공분산 추정 가능
- 앙상블 자료동화시스템에서 실제 상태의 오차 분포에 근사하는 오차 평균과 공분산을 추정하는데 기여

제 6 장 참고 문헌

Deng, Ziwang & Nambiar, Manoj & Chen, Dake. (2014). A practical scheme of the sigma-point Kalman filter for high-dimensional systems. *Journal of Advances in Modeling Earth Systems*. 6. 10.1002/2013MS000255.

Houtekamer, P.L., H.L. Mitchell, and X. Deng, 2009: Model Error Representation in an Operational Ensemble Kalman Filter. *Mon. Wea. Rev.*, 137, 2126–2143, doi:10.1175/2008MWR2737.1.

Julier, Simon J., and Jeffrey K. Uhlmann. "A new extension of the Kalman filter to nonlinear systems." *Int. symp. aerospace/defense sensing, simul. and controls*. Vol. 3. No. 26. 1997.

Nambiar, Manoj & Deng, Ziwang. (2021). A local sigma-point unscented Kalman filter for geophysical data assimilation. *Physica D: Nonlinear Phenomena*. 425. 132979. 10.1016/j.physd.2021.132979.

S. J. Julier and J. K. Uhlmann, "Unscented filtering and nonlinear estimation," in *Proceedings of the IEEE*, vol. 92, no. 3, pp. 401–422, Mar 2004.

Van Der Merwe, Rudolph, Eric A. Wan, and Simon Julier. "Sigma-point Kalman filters for nonlinear estimation and sensor-fusion: Applications to integrated navigation." *Proceedings of the AIAA Guidance, Navigation & Control Conference*. 2004

Van Der Merwe, Rudolph. "Sigma-point Kalman filters for probabilistic inference in dynamic state-space models." (2004).

Wan, Eric A., and Rudolph Van Der Merwe. "The unscented Kalman filter for nonlinear estimation." *Adaptive Systems for Signal Processing, Communications, and Control Symposium 2000. AS-SPCC. The IEEE 2000*. Ieee, 2000.

Whitaker, J.S. and T.M. Hamill, 2012: Evaluating Methods to Account for System Errors in Ensemble Data Assimilation. *Mon. Wea. Rev.*, 140, 3078–3089, doi:10.1175/MWR-D-11-00276.1.

Whitaker, J.S., T.M. Hamill, X. Wei, Y. Song, and Z. Toth, 2008: Ensemble Data Assimilation with the NCEP Global Forecast System. *Mon. Wea. Rev.*, 136, 463–482, doi:10.1175/2007MWR2018.1.

제 3 세부과제

“양상블모델 예측특성 진단결과 표출 방안 연구”

연구기관

(주)투씨솔루션

요 약 문

제3세부과제는 한국형양상블모델의 예측특성을 진단하고 성능개선을 효과적으로 제시하기 위한 다양한 시각화 방안에 대하여 연구를 진행하였다.

현업 한국형양상블모델과 실험용 한국형양상블모델의 성능을 비교 분석하기 위하여 양상블 멤버별 강수 예측성향 및 공간적 특징을 효율적으로 분석할 수 있는 가시화 가이드선스 체계를 구축하였다. 또한 현업 한국형양상블모델과 실험용 한국형양상블모델을 이용하여 양상블멤버별 강수 예측성향 및 공간적 특징을 효율적으로 분석할 수 있는 웹 기반 가시화 시스템을 구축하였다.

차 례

제 1 장 사업의 필요성	1
제 2 장 사업 목적	2
제 3 장 사업 개요	3
제 4 장 사업 수행 내용 및 결과	4
제 1 절. 웹 기반 앙상블모델의 예측 특성을 효과적으로 진단할 수 있는 시각화 방안 연구	4
1-1) 현업 및 실험용 한국형앙상블모델 가시화 가이드스 체계 구축	4
1-2) 웹기반 앙상블모델 가시화 시스템 구축	8
제 5 장 사업수행결과의 활용 계획	13

표 차례

표 3.1.1 다중모델 예측결과 가시화 가이드스 프로그램 및 파일명	5
---	---

그림 차례

그림 3.1.1 현업 및 실험용 한국형양상블모델 가시화 가이드스 체계	4
그림 3.1.2 한국형양상블모델을 이용한 2022년 6월 27일 12UTC +006h의 전지구 영역의 시간강수량 stampmap 일기도	6
그림 3.1.3 한국형양상블모델을 이용한 2022년 6월 27일 12UTC +006h의 한반도 영역의 시간강수량 stampmap 일기도	7
그림 3.2.1 양상블 예상/진단 시스템 웹 시스템 구성	8
그림 3.2.2 예상시각 선택 UI 구현 내역	9
그림 3.2.3 현업, 실험 결과 예측 stampmap 비교 (위: 전지구, 아래:한반도)	10
그림 3.2.4 양상블 예상 웹 페이지 기본 메뉴 UI	10
그림 3.2.5 양상블 진단 웹 페이지 진단 요소별 메뉴 구성	11
그림 3.2.6 진단 요소별 사용자 선택 시각의 분석 정보 제공 예	12
그림 3.2.7 날짜 및 시각 입력과 시점 이동 버튼 UI 구현 내역	12

제 1 장 사업의 필요성

기상청은 예보 생산 지원 강화를 위해 2021년부터 현업 운영 중인 한국형앙상블 모델을 개선하고 있다. 따라서 개선된 한국형앙상블모델자료의 활용을 위한 분석 도구인 수치일기도 생산체계 구축과 같은 후속작업이 필요하다. 또한 예보관 및 내부사용자, 수치예보모델 개발자들에게 손쉬운 가시화 도구를 제공함으로써 보다 정확한 예보 향상을 도모한다.

제 2 장 사업 목적

기상청은 2020년부터 한국형수치예보모델을 현업에 활용하고 있으며, 2021년 10월부터는 한국형수치예보모델 기반 앙상블예측시스템(이하 한국형앙상블모델)을 현업 운영 중에 있다.

단일 수치예보모델로부터 산출되는 결정적인 예보는 하나의 예측결과만을 산출하기 때문에, 모델예측이 실황과 다르게 전개될 경우 나타날 수 있는 다양한 가능성들에 대한 정보를 얻기 어렵다. 반면 앙상블모델을 통해 산출되는 확률론적 예보는 여러개의 가능한 예상 시나리오를 제공해주기 때문에, 앞으로 발생할 다양한 위험 가능성에 대해 대비할 수 있는 기회를 제공해준다.

본 사업에서는 2021년부터 현업 운영 중인 한국형앙상블모델의 예측특성을 진단하고 성능개선을 위해 더 개선되어야 할 부분이 무엇인지 분석하고자 한다. 이에 따라 제3세부과제에서는 한국형앙상블모델의 예측특성을 진단하고 성능개선을 효과적으로 제시하기 위한 다양한 시각화 방안에 대하여 연구를 진행하고자 한다.

제 3 장 사업 개요

1) 웹 기반 앙상블모델의 예측 특성을 효과적으로 진단할 수 있는 시각화 방안 연구

- 현업 및 실험용 한국형앙상블모델 가시화 가이드스 체계 구축
- 웹기반 앙상블모델 가시화 시스템 구축

2) 추진일정

구분		추진일정 (월)								
대분류	중분류	3	4	5	6	7	8	9	10	11
업무 분석	프로젝트 수행계획 수립									
	자료 확보 및 분석									
	사용자 요구사항 분석									
	사용자 요구사항 정의									
설계 구현	앙상블모델 예측특성									
	진단결과 표출 방안 연구									
시험	단위 테스트									
	통합테스트									
전개	교육계획 및 보고서									
	착수보고	★								
	중간보고						★			
	최종보고									★

제 4 장 사업 수행 내용 및 결과

제 1 절. 웹 기반 앙상블모델의 예측 특성을 효과적으로 진단할 수 있는 시각화 방안 연구

1-1) 현업 및 실험용 한국형앙상블모델 가시화 가이드스 체계 구축

현업 한국형앙상블모델은 여름철 한반도 강수에 대하여 과소모의하는 경향이 있다. 이에따라 대류성 강수의 작용을 악화시켜 상대적으로 large scale precipitation 을 크게 유도하여, 중위도 지역에 속하는 강수량을 증대시키는 앙상블 멤버를 구성하고, 강한 강수를 모의하는 실험용 한국형앙상블모델을 생산하였다.

본 과제에서는 현업 한국형앙상블모델과 실험용 한국형앙상블모델의 성능을 비교 분석하기 위하여 앙상블 멤버별 강수 예측성향 및 공간적 특징을 효율적으로 분석할 수 있는 가시화 가이드스 체계를 구축하였다. 그림 3.1.1은 현업 및 실험용 한국형앙상블모델 가시화 가이드스 체계 모식도이다.

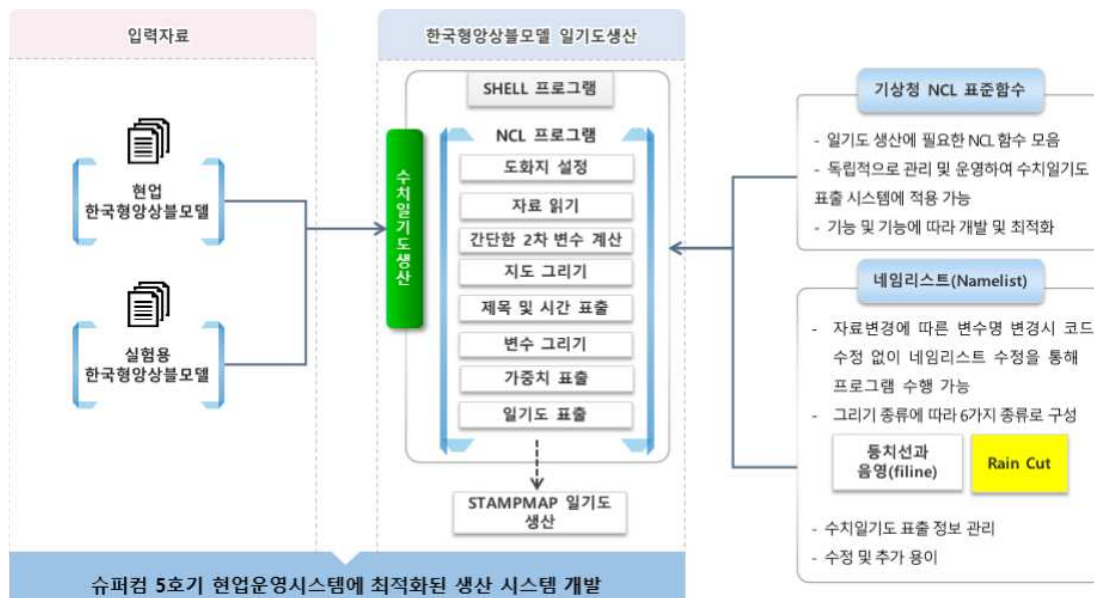


그림 3.1.1 현업 및 실험용 한국형앙상블모델 가시화 가이드스 체계

현업 및 실험용 한국형앙상블모델 가시화 가이드스에서는 전지구 및 한반도 영역

에 대하여 시간강수량 stampmap 일기도를 생산한다. 가시화 가이드는 C-Shell 과 NCL 언어를 이용하여 개발하였으며, 기상청 NCL 표준함수를 이용하였다. 또한 기상청 현업 일기도 형식과 동일한 형태로 표출하도록 프로그램을 개발하였다.

일기도 생산시 별도의 네임리스트를 관리하여 스무딩 횟수, shading의 최솟값 및 최댓값, 선 색깔 등의 수정시 일기도 코드 수정없이 네임리스트에서 수정하여 일기도를 표출 할 수 있도록 구현하였다. 또한 앙상블모델의 예보시간 간격 및 예보시간 변경 등의 확장성을 고려하여 프로그램 변경을 최소화 할 수 있도록 프로그램을 구축하였다.

현업 및 실험용 한국형앙상블모델 가시화 가이드 개발 프로그램과 일기도 파일명은 표 3.1.1과 같다.

표 3.1.1 다중모델 예측결과 가시화 가이드 프로그램 및 파일명

구분			프로그램명
stampmap (전지구)	프로그램	현업용	epsg_draw_global_stamp_oper.csh
		실험용	epsg_draw_global_stamp_test.csh
	네임리스트		epsg_global_fillne.dat
	파일명	현업용	epsg_global_stmslp_oper_s\$FTIM_\$ANLTIM.png
		실험용	epsg_global_stmslp_test_s\$FTIM_\$ANLTIM.png
	stampmap (한반도)	프로그램	현업용
실험용			epsg_draw_hkorl_stamp_test.csh
네임리스트		epsg_hkorl_fillne.dat	
파일명		현업용	epsg_hkor_stmslp_oper_s\$FTIM_\$ANLTIM.png
		실험용	epsg_hkor_stmslp_test_s\$FTIM_\$ANLTIM.png
<ul style="list-style-type: none"> • FTIM : 모델 예측시간(0시부터 96시까지 6시간 간격, 96시부터 240시까지 12시간 간격) • ANLTIM : 모델 예보초기시각 			

한국형앙상블모델의 멤버는 1개의 컨트롤 멤버와 25개의 멤버로 구성되어 있다. stampmap 일기도 표출시 현업 한국형앙상블모델은 1개의 컨트롤 멤버와 25개의

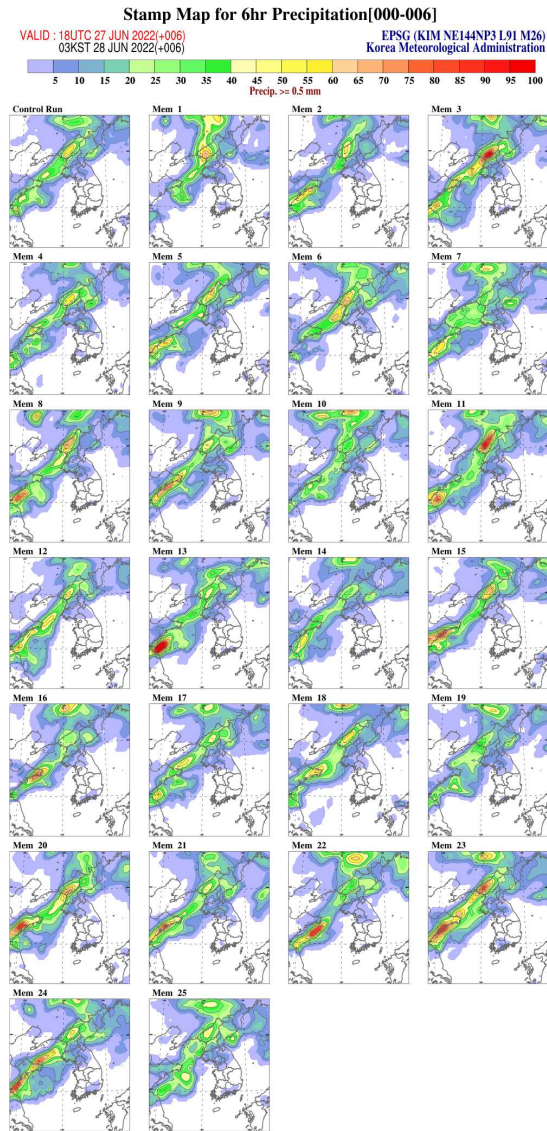
멤버를 패널형식으로 표출하며, 실험용 한국형앙상블모델은 1개의 컨트롤 멤버와 00UTC의 경우 짝수 멤버 12개(2, 4, 6, ... , 22, 24번 멤버)를 출하였으며, 12UTC의 경우 홀수 멤버 12개(26, 28, 30, ... , 48, 50번 멤버)를 표출하였다.

그림 3.1.2는 현업 및 실험용 한국형앙상블모델을 이용한 전지구 영역의 2022년 6월 27일 12UTC +006h의 시간강수량 stampmap 일기도이며, 그림 3.1.3은 현업 및 실험용 한국형앙상블모델을 이용한 한반도 영역의 2022년 6월 27일 12UTC +006h의 시간강수량 stampmap 일기도이다.



그림 3.1.2 한국형앙상블모델을 이용한 2022년 6월 27일 12UTC +006h의 전지구 영역의 시간강수량 stampmap 일기도

a) 현업(한반도 영역)



b) 실험용(한반도 영역)

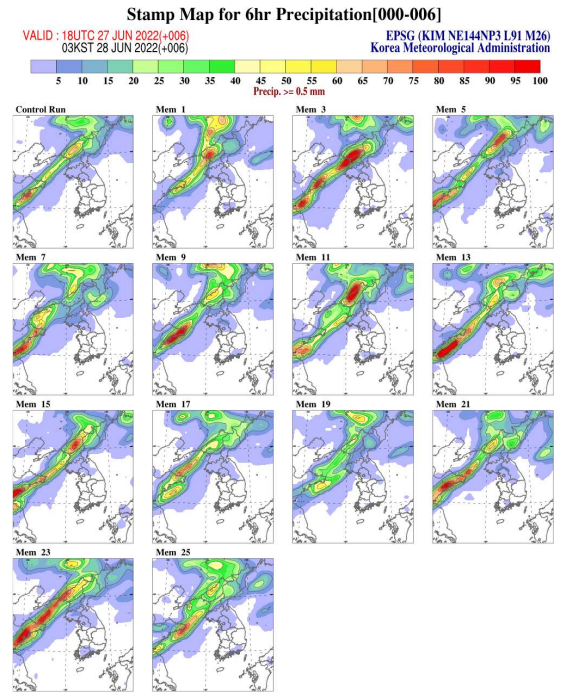


그림 3.1.3 한국형앙상블모델을 이용한 2022년 6월 27일 12UTC +006h의 한반도 영역의 시간강수량 stampmap 일기도

1-2) 웹기반 앙상블모델 가시화 시스템 구축

본 과제에서는 현업 한국형앙상블모델과 실험용 한국형앙상블모델을 이용하여 앙상블멤버별 강수 예측성향 및 공간적 특징을 효율적으로 분석할 수 있는 웹 기반 가시화 시스템을 구축하였다. 구축된 웹 기반 가시화 시스템은 기상청 슈퍼컴 환경에서 수행되는 점을 고려하여 기본적인 웹 언어인 html, javascript, php, jquery 만을 사용하도록 하였다. 웹 프로그램은 앙상블 실험 사용자의 개인 디렉터리에서 수행되는 환경을 고려하여 일기도 등 표출이 필요한 자료는 웹 프로그램이 설치되는 ~<username>/public_html 디렉터리 밑에 symbolic link로 연동되도록 구성하였다. 또한 앙상블 진단 페이지와 예상 페이지를 분리하여 향후 시스템 운영 환경이 변화될 때를 대비하도록 구현하였다.

구현된 웹 시스템의 구성은 아래 그림과 같다.

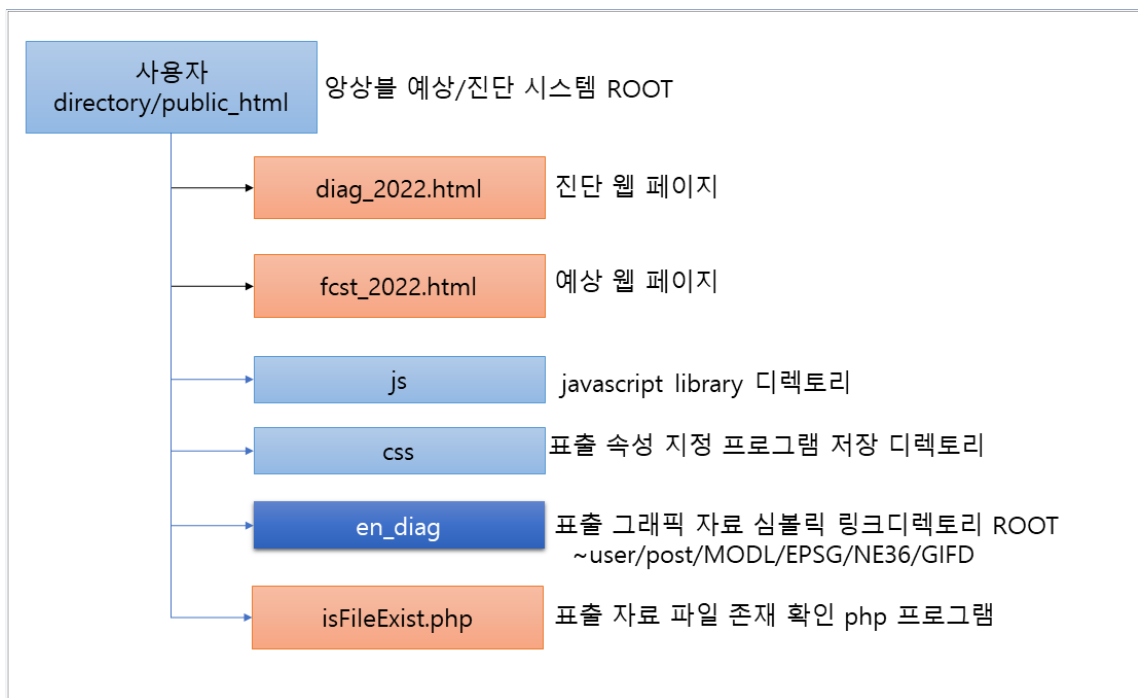


그림 3.2.1 앙상블 예상/진단 시스템 웹 시스템 구성

해당 웹 페이지는 기상청의 COMIS 시스템 기본 일기도 웹 표출 웹 페이지의 구성을 차용하여 사용자가 기존의 경험을 바탕으로 별도의 교육이 없이도 쉽게 사용할 수 있도록 하였으며 사용자가 선택한 진단 요소 또는 예상 영역에 따라 관련 메

뉴가 자동으로 적용되도록 구현하였다. 또한 html 프로그램 내부의 공역 변수로 웹 ROOT 디렉터리와 자료 위치를 지정할 수 있도록 구현하여 향후 해당 내용이 변경 될 때 쉽게 수정하여 사용될 수 있도록 하였다.

a) 앙상블 예상 자료 표출 시스템

앙상블 예상 자료 표출 시스템은 현업 및 실험용 한국형앙상블모델 가시화 가이던스로 생산한 전지구 및 한반도 영역에 대한 시간강수량 stampmap 일기도를 예보 시각별로 보여 주는 기능을 제공한다. 앙상블 예측 시각은 0 ~ +240h (10일)이므로 사용자가 예상 시각을 step 박스를 통해 예상시각을 선택할 수 있도록 구현하였다.



그림 3.2.2 예상시각 선택 UI 구현 내역

위의 그림에서 보여 주듯이 시각 선택 step 박스 상에 마우스 커서를 위치시키면 해당 예상 시각값이 tooltip 형태로 화면에 표출되며, 시각선택 step박스 우측의 play 버튼으로 이전 시각 또는 이후 시각, 자동 시각 이동 Play 기능 등을 사용하여 예상시각 변화에 따른 모델별 강수량 변화를 쉽게 관찰할 수 있도록 구현하였다.

예상 웹 시스템에서는 아래 그림과 같이 사용자가 선택한 예상 시각별 6시간 강수량 stampmap을 현업과 실험 결과 일기도를 좌우로 동시에 배치하여 보여 주도록 구현하였다.

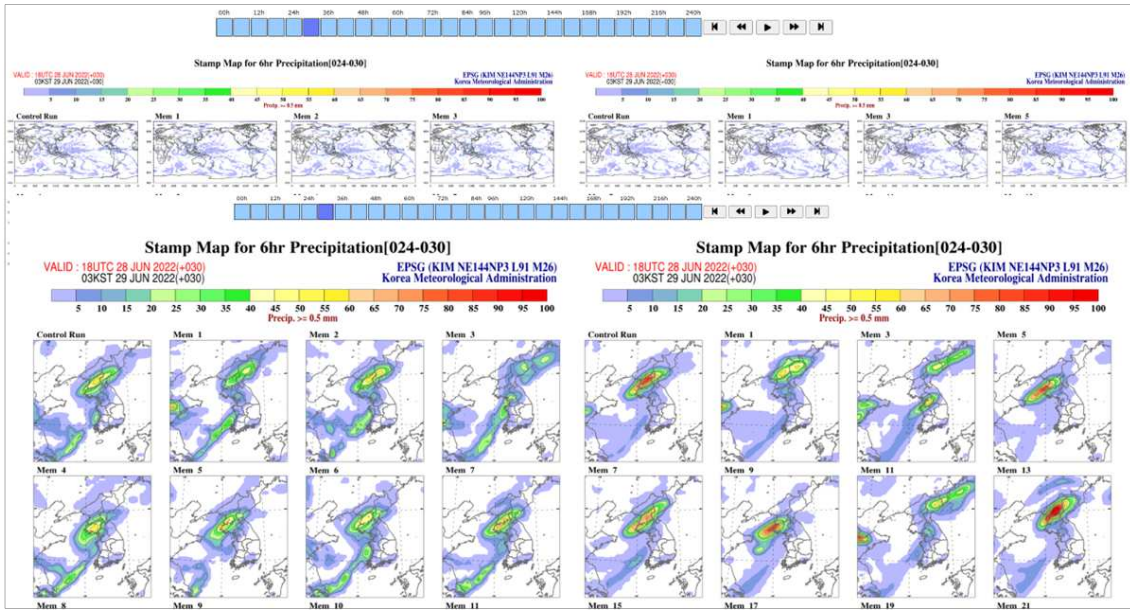


그림 3.2.3 현업, 실험 결과 예측 stampmap 비교 (위: 전지구, 아래:한반도)

양상불 예상 웹 시스템의 기본 메뉴는 아래 그림에서 나타난 바와 같이 영역을 선택할 수 있는 선택 메뉴와 예보 일자 및 시각을 선택할 수 있는 입력 상자, 그리고 현재 선택된 일시에서 -7일, -1일, -12시 또는 +12시, +1일, +7일 이후로 이동할 수 있는 버튼으로 구성되어 있다. 이 메뉴는 기존의 타 일기도 표출 웹 시스템의 메뉴와 유사하게 구현된 내용으로 사용자가 쉽게 이해하고 사용할 수 있도록 하였다.

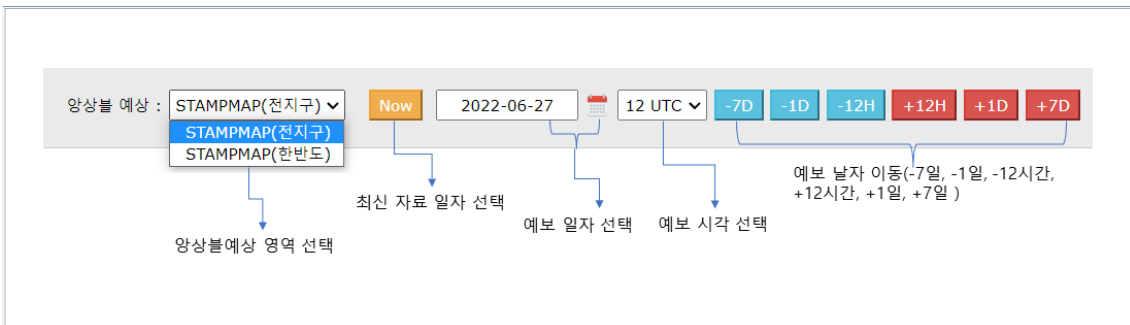


그림 3.2.4 양상불 예상 웹 페이지 기본 메뉴 UI

b) 앙상블 진단 결과 표출 시스템

앙상블 진단 결과 표출 웹 시스템은 진단 요소별 진단 결과를 예보 기간별로 보여 주는 시스템이다. 해당 시스템은 각 진단 요소별 분석 결과를 사용자가 선택한 등압면, 영역 등에 따라 보여 주는 메뉴로 구현되었다.

각 진단 요소별 세부 메뉴는 아래 그림과 같다.

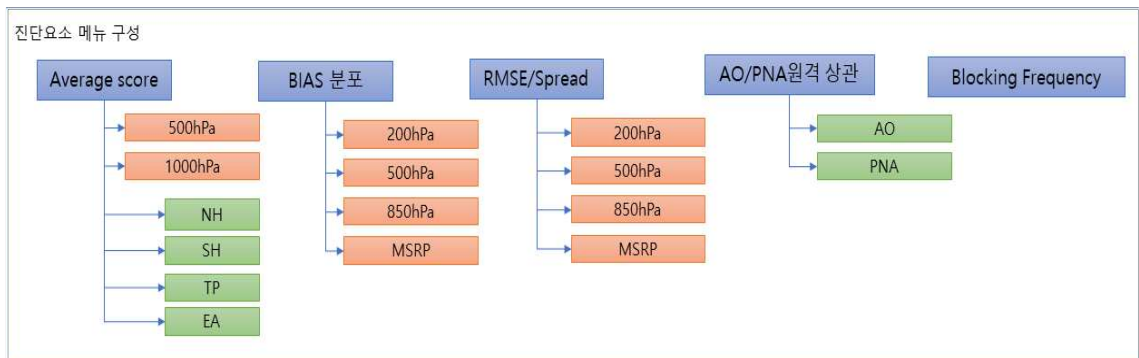


그림 3.2.5 앙상블 진단 웹 페이지 진단 요소별 메뉴 구성

진단 웹 페이지도 예상 웹페이지와 동일하게 예상 시각별 진단 분석 내용을 선택할 수 있는 시각 선택 step 박스와 play 버튼 메뉴를 제공하며 진단의 경우는 00시 ~ +288시 까지 24시간 간격의 예상 시각 선택 기능이 제공된다. 시각 선택 step 박스의 경우는 매 박스 위에 예상 시각 정보가 표시되고 해당 시각을 선택하면 사용자가 선택한 진단요소에 대한 해당 예보 시각의 분석 정보가 표출되도록 구현되었다.




그림 3.2.6 진단 요소별 사용자 선택 시각의 분석 정보 제공 예

날짜 및 시각 선택 입력의 경우는 입력 상자를 통해 입력을 받을 수 있도록 구현하였고 진단 시스템의 특성상 월 단위로 날짜를 선택하고 예보 시각은 UTC로 00, 12 시간을 선택할 수 있도록 구현하였다. 기간 이동 버튼의 경우는 -12개월, -3개월, -1개월 등 월 단위로 쉽게 이동하여 이전 자료 또는 이후 자료를 비교할 수 있는 기능도 추가하였다.



그림 3.2.7 날짜 및 시각 입력과 시점 이동 버튼 UI 구현 내역

분석된 파일들은 이미지 형태이며, 해당 진단요소별 명명 규칙을 가지고 있어 해당 규칙을 분석하여 사용자가 선택한 일시의 자료를 화면에 표출하는 로직 및 해당 자료가 존재하는지 확인하는 프로그램을 구현하였다. 해당 로직은 향후 변경이 발생할 시에도 수정이 용이하도록 각 진단요소별로 프로그램 모듈을 구성하였다.

제 5 장 사업수행결과의 활용 계획

- 한국형앙상블모델의 가시화 가이드선 체계 구축에 따른 성능파악 가시화 도구 활용 증대
- 예보관 및 내부사용자, 수치예보모델 개발자들에게 손쉬운 가시화 도구를 제공함으로써 보다 정확한 예보 향상 도모

비매품/무료

95450



9 791192 755205

ISBN 979-11-92755-20-5 (PDF)