

안전한 항공기 운항을 위한 현업 전지구예보모델 기반 깊은 대류 예측 지수: Part 2. 계절별 최적화 및 사례 분석

박이준 · 김정훈*

서울대학교 지구환경과학부

(접수일: 2023년 9월 12일, 수정일: 2023년 10월 25일, 게재확정일: 2023년 11월 3일)

Aviation Convective Index for Deep Convective Area using the Global Unified Model of the Korean Meteorological Administration, Korea: Part 2. Seasonal Optimization and Case Studies

Yi-June Park and Jung-Hoon Kim*

School of Earth and Environmental Sciences, Seoul National University, Seoul, Korea

(Manuscript received 12 September 2023; revised 25 October 2023; accepted 3 November 2023)

Abstract We developed the Aviation Convective Index (ACI) for predicting deep convective area using the operational global Numerical Weather Prediction model of the Korea Meteorological Administration. Seasonally optimized ACI (ACI_{SnOpt}) was developed to consider seasonal variabilities on deep convections in Korea. Yearly optimized ACI (ACI_{YrOpt}) in Part 1 showed that seasonally averaged values of Area Under the ROC Curve (AUC) and True Skill Statistics (TSS) were decreased by 0.420% and 5.797%, respectively, due to the significant degradation in winter season. In Part 2, we developed new membership function (MF) and weight combination of input variables in the ACI algorithm, which were optimized in each season. Finally, the seasonally optimized ACI (ACI_{SnOpt}) showed better performance skills with the significant improvements in AUC and TSS by 0.983% and 25.641% respectively, compared with those from the ACI_{YrOpt} . To confirm the improvements in new algorithm, we also conducted two case studies in winter and spring with observed Convectively-Induced Turbulence (CIT) events from the aircraft data. In these cases, the ACI_{SnOpt} predicted a better spatial distribution and intensity of deep convection. Enhancements in the forecast fields from the ACI_{YrOpt} to ACI_{SnOpt} in the selected cases explained well the changes in overall performance skills of the probability of detection for both “yes” and “no” occurrences of deep convection during 1-yr period of the data. These results imply that the ACI forecast should be optimized seasonally to take into account the variabilities in the background conditions for deep convections in Korea.

Key words: Deep Convection, Aviation Convective Index (ACI), Seasonal variability, Seasonal optimization

*Corresponding Author: Jung-Hoon Kim, School of Earth and Environmental Sciences, Seoul National University, 1 Gwanak-ro, Gwanak-gu, Seoul 08826, Korea.
Phone: +82-2-880-6718, Fax: +82-2-883-4972
E-mail: jhkim99@snu.ac.kr

1. 서 론

대류 현상은 단순히 강수를 발생시킬 뿐만 아니라, 대류로 인한 난류(Convectively-Induced Turbulence, CIT), 다운버스트, 착빙 등 다양한 악기상을 발생시킨다. 그러므로 항공기 운항 계획을 수립하는 데 있어서 깊은 대류에 대한 단기 또는 중기 예측은 필수적이다. 이를 위해, 전-지구 규모부터 지역 규모까지 다중 규모에 대한 뇌우 및 이와 관련된 악기상을 예측하는 연구가 많이 진행되어 왔다. 대표적으로 내륙 뿐만 아니라 해양성, 그리고 대륙간에 발생하는 깊은 대류를 예측하기 위해 World Area Forecast System Cumulonimbus (WAFS Cb; ICAO, 2012)와 Ensemble Prediction of Oceanic Convection Hazards (EPOCH) (Melling et al., 2019)이 개발되었다. 두 예측 시스템은 전-지구 예보모델을 사용하여 각각 결정론적 그리고 확률론적 예측 결과를 제공하기 때문에 넓은 공역 예보에 효과적이다. 뿐만 아니라, 국지적으로 발생하는 대류 시스템을 예측하기 위해, High-Resolution Rapid Refresh (HRRR) 또는 Weather Research and Forecasting (WRF)와 같은 고해상도의 Convection-Allowing Models (CAMs)가 적극적으로 활용되고 있다. 해당 모델들은 수평 해상도가 4 km 이하이기 때문에 적은 모수화 방안을 사용할 필요가 없어 이로 인한 불확실성을 없앨 수 있다는 장점이 있다. 해당 모델들은 국지적인 기상 현상을 예측하는 데 있어서 해상도가 섬진 전구 모델보다 더 높은 예측 성능을 갖기 때문에, 뇌우 뿐만 아니라 우박, 그리고 중규모 이하의 토네이도를 예측하는데 적극적으로 활용되고 있다(Sobash et al., 2011; Sobash et al., 2016; Wendt et al., 2016).

대류 현상을 예측하기 위해서는 대류와 관련된 지수 및 변수들을 활용해야 한다. 이를 위해, 깊은 대류의 물리적 특성을 잘 대변할 수 있는 다양한 지수들이 개발되어 왔으며, 앞서 언급한 선행 연구를 포함하여 다양한 연구에서 이들을 활용하고 있다. 대표적으로 활용되는 지수는 K-Index (George, 1960; Charba, 1977), Showalter Index (Showalter, 1953), Lifted Index (Galway, 1956), Total Totals (Miller, 1967) 등이 있으며, 해당 지수들은 기본적으로 대기의 불안정도를 의미한다. 뿐만 아니라, 역학적 이론을 바탕으로 오메가 방정식을 활용하여 상층 바람 시어 및 온도 이류를 추가로 고려한 Severe Weather Threat Index (Miller, 1975)도 개발되었다. Haklander and Delden (2003)에서는 해당 지수들을 포함하여 총 32개의 뇌우 관련 지수들의 예측 성능을 비교하였다. 뿐만 아니라, 이러한 지수들은 통계 모델 기반 확률 예측 기술 개발에도 활용된 바 있다(Reap and Foster, 1979; Schmeits

et al., 2008; Slangen and Schmeits, 2009; Simon et al., 2018).

대류 현상은 지형으로 인한 강제 상승, 비-단열 과정, 그리고 불안정도 해소와 같은 복합적인 요인으로 인해 발생한다. 그러므로, 특정 지역이 갖는 고유의 특성은 대류의 발생 및 발달 과정에 중요한 역할을 한다. 그러므로 한반도 주변에 발생하는 깊은 대류를 효과적으로 예측하기 위해서는 한반도 지역을 중심으로 개발되고 최적화된 예측 기술이 필요하다. 이를 위해, 본 연구의 파트 1에서는 한반도를 포함한 공항 및 공역 지역에 대한 깊은 대류 예측에 활용될 수 있는 새로운 예측 지수인 Aviation Convective Index (ACI)를 제시하였으며, 1년 장기간에 대한 최적화 과정을 설명하였다. 해당 지수는 국내 현업 수치예보모델 중 하나인 통합 모델(Unified Model) 기반의 전지구 예보모델(Global Data Assimilation and Prediction System, GDAPS)를 사용하여 개발되었으며, 예측 성능은 레이더 관측 자료에서 산출된 15 dBZ 에코 정상고도(15 dBZ Echo Top Height, 이하 15 dBZ ETH)를 통해 검증되었다. ACI는 퍼지-로직(Fuzzy-logic) 알고리즘을 통해 서로 다른 3개의 변수를 하나의 연속적인 값으로 변환되어 산출된다. 여기서 입력 변수로는 깊은 대류의 물리적인 특성을 잘 대변하는 대류 가용 잠재에너지(Convective Available Potential Energy, CAPE), 누적 강수량(Accumulated Precipitation, APCP), 그리고 상향 장파 복사량(Outgoing Longwave Radiation, OLR)이 사용되었다. 이러한 변수들은 각각의 멤버십 함수(Membership Function, MF)를 통해 0과 1 사이의 일반화된 값으로 변환된 후, 특정 상수 조합(α (CAPE), β (APCP), γ (OLR))를 통해 가중 평균 되어 ACI로 계산된다. 앞서 간단히 설명한 입력 및 검증 자료와 ACI 계산 방법론에 대한 자세한 설명은 파트 1에서 다루고 있다.

ACI 산출 과정에서 사용되는 가중 상수는 각 변수의 중요도를 의미하기 때문에, 가중치 조합은 변수들의 대류 예측 성능을 고려하여 결정되어야 한다. 파트 1에서는 수신자 조작 특성 곡선(Receiver Operating Characteristics curve, ROC curve) 분석을 통해 Area Under the Curve (AUC)의 최댓값을 기준으로 2021년, 1년 기간에 대한 최적의 가중치 조합($\alpha=0.45$, $\beta=0.05$, $\gamma=0.50$)을 결정하였다. 여기서, ROC 곡선을 이루는 Probability Of Detection (PODY)와 Probability Of False Detection (POFD)는 두 통계치에 사용되는 격자수를 유사하게 맞추기 위해 15 dBZ ETH가 비행고도(Flight Level, FL) 0을 넘는 지역에 대해서 계산되었다. 1년 기간에 대한 최적의 가중치 조합을 통해 계산된 ACI (ACI_{YrOpt})는 동일한 가중치를 적용한 ACI (ACI_{NoOpt})보다 통계적으로 더 높은 예측 성능을 보였

다. 전체 예측 기간 평균 AUC는 기존의 0.717에서 최적화 이후 0.729로 1.67% 향상되었다. 뿐만 아니라, 평균 True Skill Statistics (TSS)는 최적화 과정을 통해 0.238에서 0.248로, 기존 대비 4.20%의 향상된 결과를 보였다.

대류 현상뿐만 아니라 이와 관련된 변수들의 발생 강도 및 빈도는 계절에 따라 매우 다르게 나타난다 (Chuda and Niino, 2005; K. Riemann-Campe et al., 2009; Poręba et al., 2022; Hu et al., 2023). 그러므로 모든 계절에서 예측 성능을 향상시키기 위해서는 이러한 계절 변동성을 고려해야 한다. 특히, 본 연구를 통해 개발된 ACI는 입력 변수들의 통계적 특성을 기반으로 정의된 MF들로 계산되기 때문에, 계절에 맞는 MF와 가중치 조합을 적용할 필요가 있다. 본 연구의 파트 2에서는 앞서 수행한 1년간 자료 기반 최

적화의 대한 한계점을 제시하고, 계절별 최적화에 대한 필요성과 방법을 담고 있다. 또한, 계절별 최적화된 ACI의 예측 성능을 파악하기 위해 통계적 방법을 통한 정량적인 검증뿐만 아니라, 사례 분석을 통한 정성적인 검증을 수행하였다.

2. 최적화 방법론

2.1 1년간 자료 기반 최적화의 한계

앞서 언급한 것처럼 1년 기간에 대한 최적화가 AU와 TSS를 동시에 증가시키면서 예측 성능을 향상시켰다. 하지만 대류 현상은 계절별로 예측 성능을 파악할 필요가 있다. 이를 위해, 예측 기간에 따른 ACI_{NoOpt} 와 ACI_{YrOpt} 의 ROC curve를 장기간이 아닌 계절별로 나누어 살펴보았다(Fig. 1). 여기서 겨울철은 12월, 1

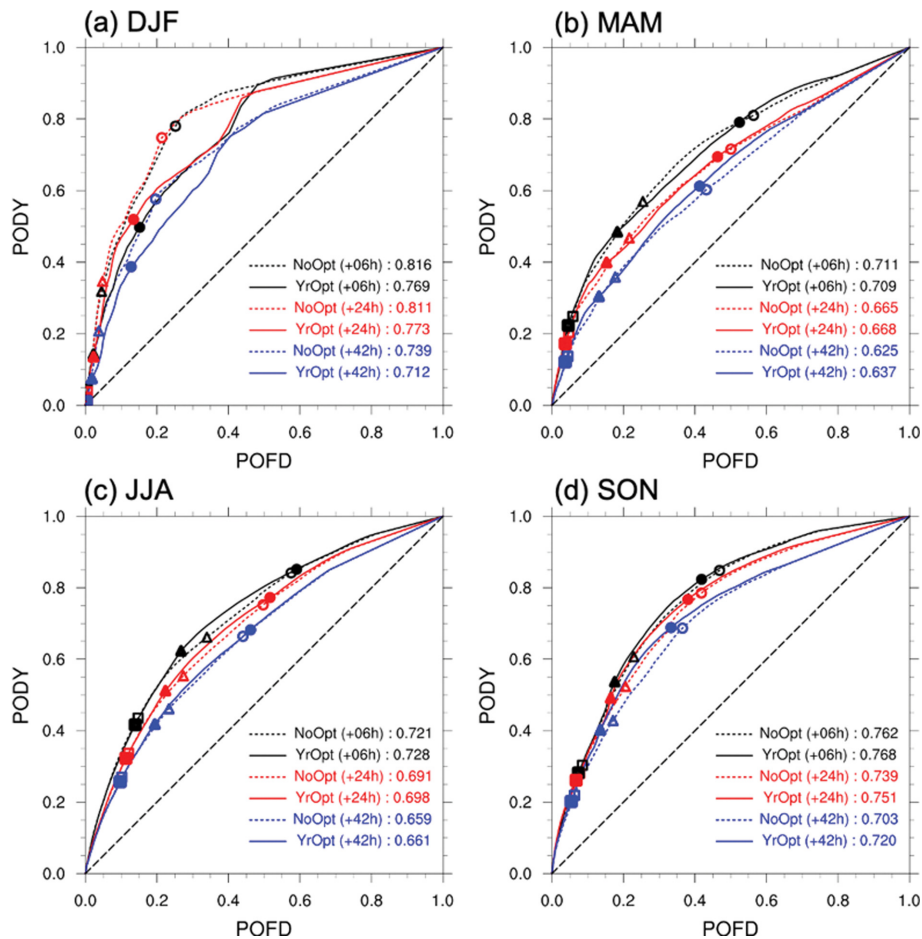


Fig. 1. ROC curves of ACI_{NoOpt} (dashed line) and ACI_{YrOpt} (solid line) of 6-hour (black), 24-hour (red), and 42-hour (blue) forecast in (a) DJF, (b) MAM, (c) JJA, and (d) SON. The circle, triangle, and square marker indicate the ACI of 0.25, 0.50, and 0.75, respectively.

Table 1. Total number of grids where convection with reflectivity over 15 dBZ is observed in radar.

	DJF	MAM	JJA	SON	Total
Observation (n)	181,797	324,186	423,795	306,471	1,236,249
Percentage (%)	14.71	26.22	34.228	24.79	-

Table 2. Forecast period averaged AUC and TSS of ACI_{NoOpt} and ACI_{YrOpt} with rate of change in each season.

Seasons		DJF	MAM	JJA	SON	Average
AUC	ACI_{NoOpt}	0.780	0.662	0.684	0.732	0.715
	ACI_{YrOpt}	0.746	0.668	0.690	0.744	0.712
	Percentage	-4.359%	+0.906%	+0.877%	+1.639%	-0.420%
TSS	ACI_{NoOpt}	0.212	0.164	0.209	0.245	0.207
	ACI_{YrOpt}	0.145	0.167	0.211	0.256	0.195
	Percentage	-31.604%	+1.829%	+0.957%	+4.490%	-5.797%

월, 그리고 2월(DJF), 봄철은 3~5월(MAM), 여름철은 6~8월(JJA), 그리고 가을철은 9~11월(SON)로 정의되었다. 겨울을 제외한 대부분의 계절에서는 기존의 ACI_{NoOpt} 보다 ACI_{YrOpt} 의 곡선이 상대적으로 더 좌측 상단으로 확장되어 성능이 향상된 모습을 보여준다. 하지만 여기서 중요한 점은 DJF 기간에서 ACI_{YrOpt} 의 예측 성능이 오히려 현저하게 저하되었다는 것이다. ACI_{NoOpt} 의 6시간, 24시간, 42시간 예측 기간에 대한 AUC는 0.816, 0.811, 그리고 0.739인 반면, ACI_{YrOpt} 의 AUC는 각각 0.769, 0.733, 그리고 0.712로 매우 크게 감소하였다.

DJF 기간에서만 1년 자료 최적화의 결과가 다른 양상을 보인 이유는 해당 시기의 관측된 대류 발생 빈도와 큰 관련이 있다. 장기간에 대한 최적의 기중치 조합은 계절과 상관 없이 전체 기간에 대한 대류를 예측하는 데 유리하도록 설정된다. 그러므로 설정된 깊은 대류 발생 빈도가 작은 특정 계절에서는 최적화의 효과가 작을 수 밖에 없다. 검증에 사용된 ETH 관측장에서 15 dBZ 이상의 대류가 관측된 전체 격자수를 계절별로 비교해 보았다(Table 1). DJF, MAM, JJA, 그리고 SON 기간에 대류가 발생한 격자수는 181,797개, 324,186개, 423,795개, 306,471개로, 다른 계절과 비교했을 때 DJF 시기의 관측 수는 다른 계절 대비 대략 절반 정도였으며 전체 격자 수의 고작 14.71%였다. 물론 계절에 따라 사용된 수치 예보모델의 예측 성능도 달라지기 때문에, 단순히 대류 발생 빈도에 따라 선형적으로 최적화의 효과가 증가하는 것은 아니다. 하지만 특정 계절의 매우 낮은 대류 발생 빈도는 이와 관련된 입력 변수의 강도 및 빈도 또한 낮다는 것을 의미하기 때문에 1년 기간을 대상으로 기중치를 최적화하거나 MF를 구축하는 과정에서 이러한 계절적 특성이 고려되는 데 한계가 있다.

DJF를 제외한 모든 계절에서 ACI_{YrOpt} 의 전체 예측 기간에 대한 평균 AUC는 기존의 ACI_{NoOpt} 와 비교하여 모두 증가하였다(Table 2). MAM과 JJA 기간에는 기존 대비 0.906%, 그리고 0.877% 향상되었으며, 특히 SON의 경우 1.639%가 향상되었다. TSS 값도 해당 계절에서 각각 1.829%, 0.957%, 그리고 4.490%의 향상을 보였다. 하지만 DJF 기간의 경우, 평균 AUC와 TSS의 변화율은 각각 -4.359%와 -31.604%로 모두 매우 크게 감소한 것을 알 수 있다. 이로 인해 전체 계절에 대한 평균 AUC와 TSS들을 비교해 보면 오히려 1년 기간 최적화 이후 감소하는 결과를 보였다. 즉, 대부분의 계절에서는 예측 성능이 향상되었지만, DJF 기간에 큰 폭의 성능 저하로 인해 전체 계절 평균 예측 성능은 오히려 감소하였다. 이것이 계절에 따라 발생 빈도 및 강도의 특성이 크게 달라지는 대류 현상을 예측하는데 있어서 예측 지수를 1년 단위 기간에 대해 최적화했을 때 나타나는 한계이며, 계절 변동성을 고려하여 ACI를 개발하고 계절에 따라 검증해야 하는 이유이다.

2.2 계절별 최적화

한반도의 경우 여름철에는 북태평양 고기압이 세력을 확장하면서 그 가장자리를 따라 많은 양의 수증기가 빈번하게 유입된다. 또한, 고기압의 확장으로 인한 지면 가열에 더불어 발해만에서 발달하여 동진하는 상층 기압골 시스템은 종종 찬공기를 남하 시켜 대기를 열적으로 불안정한 상태로 만들기도 한다. 뿐만 아니라, 여름철에 대륙 고기압과 북태평양 고기압과 대치하여 한반도를 중심으로 강한 온위 경도를 이루어 전선을 발달시킬 수 있다. 이러한 수증기, 불안정도, 그리고 강제 상승과 같은 기상학적 요인들은 여름철을 중심으로 강한 대류를 발생시키는 원인이 된다

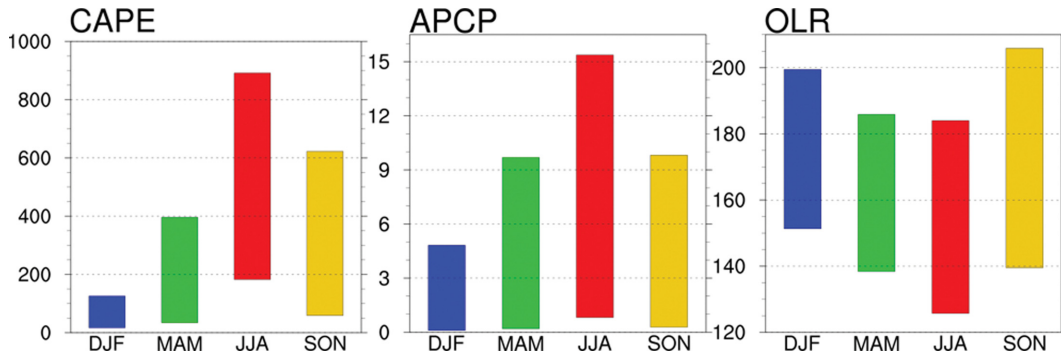


Fig. 2. Variability on seasonal MF (CAPE, ACP; 1σ~99%, OLR; 1%~−1σ).

Table 3. Coefficients of MF coefficients in each season.

Seasons	Variables	Coefficients of Membership Function, $MF(x) = a + bx + cx^2 + dx^3 + ex^4 + fx^5 + gx^6 + hx^7$							
		a	b	c	d	e	f	g	h
DJF	CAPE	-0.903	0.084	-0.002	3.2×10^{-5}	-3.0×10^{-7}	1.5×10^{-9}	-3.0×10^{-12}	-
	ACP	-0.020	2.298	-3.050	2.311	-1.003	0.247	-0.032	0.002
	OLR	-523.7	15.05	-0.17	0.001	-2.6×10^{-6}	2.6×10^{-9}	7.2×10^{-13}	-
MAM	CAPE	-0.646	0.030	-2.9×10^{-4}	1.6×10^{-6}	-5.2×10^{-9}	8.9×10^{-12}	-6.1×10^{-15}	-
	ACP	0.018	0.709	-0.324	0.087	-0.013	0.001	-3.0×10^{-5}	-
	OLR	1164	-44.41	0.701	-0.006	2.7×10^{-5}	-6.8×10^{-8}	7.0×10^{-11}	-
JJA	CAPE	-0.765	0.006	-1.2×10^{-5}	1.8×10^{-8}	-2.0×10^{-11}	1.2×10^{-14}	-3.1×10^{-18}	-
	ACP	-0.296	0.574	-0.143	0.021	-0.002	8.0×10^{-5}	-1.5×10^{-6}	-
	OLR	166.2	-5.62	0.08	-0.001	1.8×10^{-6}	-2.8×10^{-9}	9.9×10^{-13}	-
SON	CAPE	-0.813	0.022	-1.0×10^{-3}	5.2×10^{-7}	-1.1×10^{-9}	1.1×10^{-12}	-4.8×10^{-16}	-
	ACP	-0.069	0.842	-0.382	0.100	-0.014	0.001	-3.1×10^{-5}	-
	OLR	323.9	-11.70	0.175	-0.001	6.0×10^{-6}	-1.4×10^{-8}	1.4×10^{-11}	-

(Doswell, 1987; Schultz and Schumacher, 1999). 이러한 대류의 계절적 특성은 ACI의 입력 변수들의 계절별 확률 누적 분포에서도 잘 나타난다(Fig. 2). 해당 그림은 각 MF이 정의되는 위험 범위를 나타낸다. CAPE와 ACP의 위험 범위는 JJA 기간에 특히 넓고 높게 나타났다. 이는 대류 특성에 따라 두 변수 모두 여름철에는 강도가 크고 빈번하게 발생하기 때문이다. 반면에 DJF 기간에는 다른 기간에 비해 전반적으로 매우 낮은 값을 보였다. OLR의 경우, 계절별로 위험 범위는 비슷한 폭으로 나타났지만, 강한 대류가 빈번한 JJA 때의 범위는 가장 낮은 구간에 위치해 있다. 이처럼 대류 뿐만 아니라 이와 관련된 입력 변수들도 계절에 따른 강도 및 빈도의 차이는 크게 나타난다. 본 연구에서는 이러한 입력 변수들의 계절적 변동성을 고려하여 ACI 산출에 사용되는 MF를 각 계절별로 구축하였다(Table 3). MF를 정의하는 방법은 파트 1에 자세히 설명되어 있다. 이전의 ACI_{NoOpt} 와 ACI_{YrOpt} 에 사용된 선형 MF들은 모두 6차 방정식으로 이루어

져 있다. 하지만 DJF 기간에 대한 ACP의 MF은 6차 방정식으로 정의하였을 때, 위험 범위 내의 높은 구간에서 CDF와 잘 맞지 않는 것을 확인하였다(Fig. 3). 본 연구에서는 더 정교한 7차 회기방정식과의 비교를 통해 겨울철 MF_{ACP} 는 정성적으로 잘 맞으면서 상대적으로 평균 제곱근 오차(Root Mean Square Error, RMSE)도 낮았던 7차 방정식으로 정의하였다.

계절별로 구축된 각 변수의 MF는 범위가 다르기 때문에, 모든 기간에 동일한 가중치를 적용시킬 수 없다. 이를 해결하기 위해, 계절별로 모든 가중치 조합에 대한 AUC 값을 비교하여 그 시기에 맞는 최적의 가중치 조합을 선정하였다(Table 4). 자세히 말하면, 파트 1에서 전체 1년 기간에 대한 최적화 과정과 동일한 방식을 사용하여, 특정 기간 마다 모든 가중치 조합에 대한 AUC 값들을 비교하여 최대 값을 갖는 조합을 최적의 가중치 조합으로 정의하였다. 흥미롭게도 계절마다 최대 AUC를 갖는 상수 조합은 다르게 나타났다. DJF 시기에는 CAPE와 OLR의 가중치

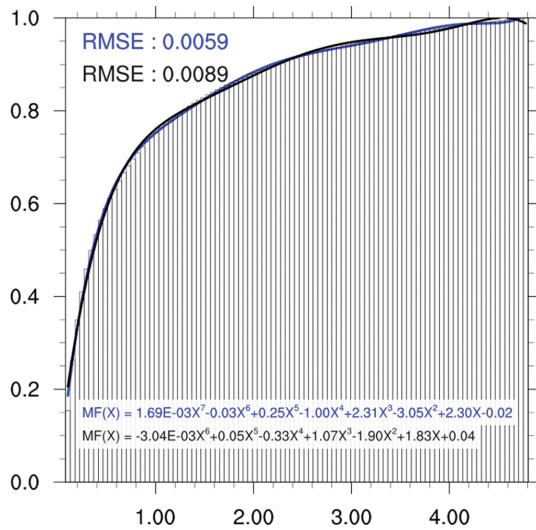


Fig. 3. Cumulative distribution of Accumulated Precipitation (APCP) between +1 standard deviation and 99th percentile value in DJF. The blue and black line indicate the 7th and 6th-order polynomial function with formula below. The Root Mean Square Error (RMSE) of each polynomial function is also noted.

Table 4. Optimized weighting coefficients in each season.

	Weighting coefficient		
	α	β	γ
DJF	0.20	0.70	0.10
MAM	0.50	0.15	0.35
JJA	0.25	0.20	0.55
SON	0.15	0.25	0.60

가 작고 APCP은 매우 높은 가중치를 갖는다. 반면, MAM 때는 CAPE의 비중이 더 높았으며, JJA와 SON 시기에는 OLR에 더 높은 가중치가 할당되었다. 이러한 결과는 AUC라는 통계치의 특성 및 사용된 모델이 모사한 강수 및 대류운 모수화의 계절 변동성과 관련이 깊다. 앞서 설명한 것처럼, 본 연구에서는 가중치를 최적화하는 과정에서 최종적인 AUC 값만 비교하여 그 조합을 선정하였다. 여기서 AUC는 고려하는 계절마다 큰 차이를 보일 뿐만 아니라 최적화 과정에서 다양한 요인에 따라 증가될 수 있다. 실제로, 파트 1의 1년 기간에서 보았을 때는 APCP를 거의 고려하지 않고 CAPE와 OLR을 주로 고려한 조합이 장기간 전체에 대한 PODY는 감소시켰지만 POFD를 더 감소시켜 줌으로써 AUC를 증가시킬 수 있었다. 하지만 뒤에서 다룰 계절별로 보이는 AUC가 증가되는 방식은 다양하다. 예를 들면, POFD가 증가하더라도

PODY가 더 큰 폭으로 증가할 때 AUC가 증가할 수 있다. 이렇듯 본 연구에서 사용하는 모델에서는 특정 시기마다 AUC가 증가되는 방식이 달라질 뿐만 아니라, AUC를 증가시키는 데 기여하는 변수들과 기여하는 정도 또한 달라진다. 그러므로 특정 계절에 대한 최적화 이후 가중치가 높게 할당된 변수는 해당 계절에서 보여진 AUC가 증가되는 방식에 더 많이 기여한 변수라고 이해할 수 있다. 이렇게 구축된 계절별 MF와 최적의 가중치 조합을 통해 각 계절에 맞는 ACI를 계산할 수 있으며, 이를 계절별 최적화된 ACI (Seasonal Optimized ACI, ACI_{SnOpt})라고 정의하였다 (Eq. 1).

$$ACI_{SnOpt} = \begin{cases} \alpha_{DJF}M_{DJF, CAPE} + \beta_{DJF}M_{DJF, APCP} + \gamma_{DJF}M_{DJF, OLR} \\ \alpha_{MAM}M_{MAM, CAPE} + \beta_{MAM}M_{MAM, APCP} + \gamma_{MAM}M_{MAM, OLR} \\ \alpha_{JJA}M_{JJA, CAPE} + \beta_{JJA}M_{JJA, APCP} + \gamma_{JJA}M_{JJA, OLR} \\ \alpha_{SON}M_{SON, CAPE} + \beta_{SON}M_{SON, APCP} + \gamma_{SON}M_{SON, OLR} \end{cases} \quad (1)$$

3. 예측 성능 검증

3.1 ACI_{SnOpt} 와 ACI_{YrOpt} 의 예측 성능 비교

본 연구에서는 관측자료의 15 dBZ ETH와 비교를 통해 ACI_{YrOpt} 와 ACI_{SnOpt} 의 예측 성능을 계절별로 검증하였다. 즉, ACI_{SnOpt} 을 이루는 계절별 ACI는 최적화 과정에서 정의된 계절별 기간에 대해 검증이 수행되었으며, ACI_{YrOpt} 는 1년 전체 기간에 대해 최적화가 이루어졌지만, 마찬가지로 계절별로 예측 성능이 검증되었다. 각 계절마다 6시간, 24시간, 그리고 42시간 예측에 대한 ACI_{YrOpt} 와 ACI_{SnOpt} 의 ROC curve를 비교해보았다(Fig. 4). 먼저, 1년 기간 최적화로 인해 예측 성능이 가장 감소했던 DJF기간을 보면, 계절에 맞는 최적화를 진행했을 때 각 예측 기간의 AUC가 0.809, 0.803, 그리고 0.728로 기준과 대비하여 큰 폭으로 증가한 것을 알 수 있다. 또한, MAM의 경우, 전반적으로 ACI_{SnOpt} 의 곡선이 기준보다 좌측 상단으로 약간 넓어지는 결과를 보였다. 6시간과 24시간 예측에서는 AUC가 각각 0.716과 0.675로 기준보다 약간 증가하였지만, 장기간인 42시간 예측에서는 0.636으로 기준의 0.637과 비교하여 약간 감소 또는 비슷한 결과를 보여준다. 즉, 단기(short-term)에 대한 예측 성능이 계절 최적화를 통해 상대적으로 더 크게 향상되었다. JJA 기간에는 단기(6, 24시간) 예측은 비슷하지만 42시간 예측에서 성능이 소폭 감소하였다. 6시간 예측 기간에 대한 AUC는 증가하였지만, 24시간부터 오히려 AUC가 감소하는 모습을 보여준다. 마지막으로 SON 기간의 ROC curve 변화는 MAM 기간과 비슷

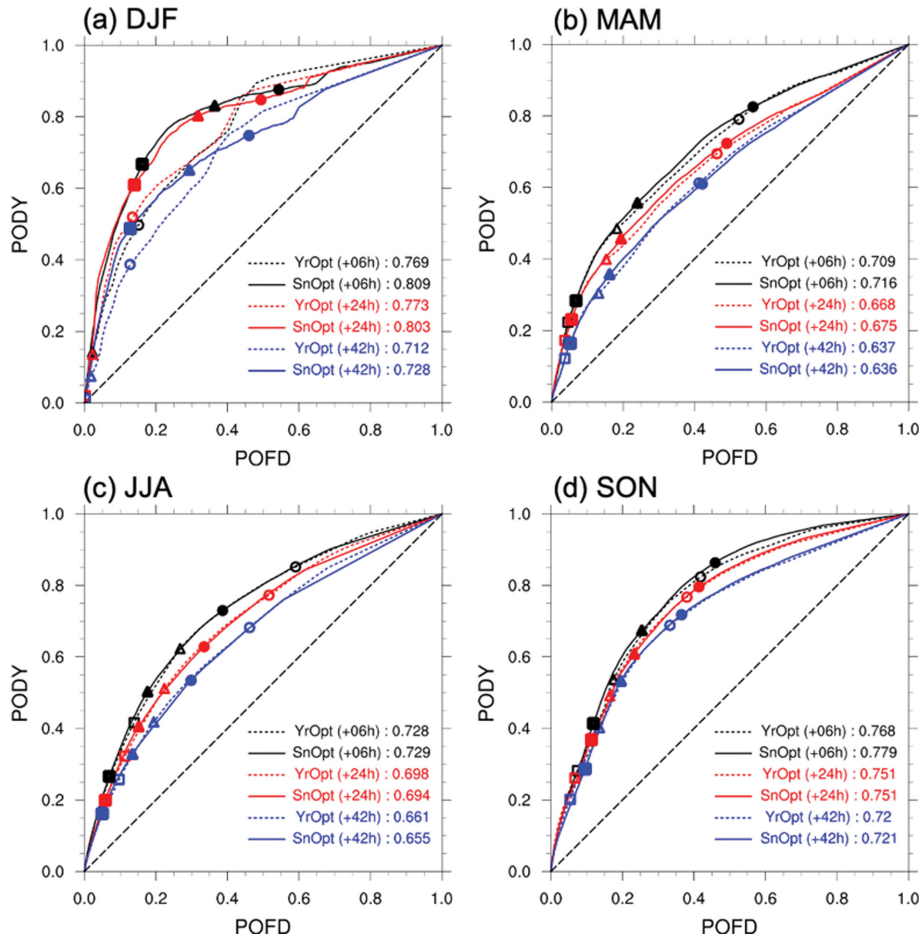


Fig. 4. ROC curves of ACI_{YrOpt} (dashed line) and ACI_{SnOpt} (solid line) of 6-hour (black), 24-hour (red), and 42-hour (blue) forecast in (a) DJF, (b) MAM, (c) JJA, and (d) SON. The circle, triangle, and square marker indicate the ACI of 0.25, 0.50, and 0.75, respectively.

한 결과를 보여준다. 대부분의 예측 기간에서 곡선은 좌측 상단으로 넓어지며 AUC가 소폭 증가하였으며, 중기(medium range)보다 단기(short-term) 예측에 있어서 계절별 최적화를 통한 성능 향상이 뚜렷하였다.

3.2 계절별 예측 기간에 따른 ACI_{SnOpt} 와 ACI_{YrOpt} 의 AUC와 TSS 비교

예측 기간에 따른 ACI_{YrOpt} 와 ACI_{SnOpt} 의 AUC와 TSS 값을 보면, DJF 때는 모든 예측 기간에서 두 통계치 모두 증가한 것을 알 수 있다(Fig. 5a). 여기서 TSS는 모든 예측 기간에 대해 동일한 증가폭을 보여주고 있으며, AUC는 상대적으로 짧은 예측 기간에서 더 큰 폭으로 증가하였다. 전체 예측 기간에 대한 평균 AUC는 기존의 0.746에서 0.772로 3.485% 증가하였고, TSS는 최적화 이후 0.321로 기존 대비 121.379%나 증가

하였다(Table 5). 또한, MAM 기간의 최적화를 통해 TSS는 모든 예측 기간에서 증가하였다(Fig. 5b). 하지만 증가폭은 중기예측보다는 단기예측에서 크게 나타났다. 뿐만 아니라, 앞서 ROC curve를 통해 분석한 것처럼 AUC 또한 단기 예측에서는 증가하지만 36시간 이상 예측 기간에서는 소폭 감소하였다. 해당 기간 ACI_{SnOpt} 의 평균 AUC와 TSS는 각각 0.670, 그리고 0.180으로 기존 대비 0.299%와 7.784%의 향상을 보였다. 계절별 최적화 이후, JJA 기간에는 대부분의 예측 시간대에서 예측 성능이 다소 감소하였다(Fig. 5c). 특히, 짧은 예측 시간대에서는 큰 차이가 없지만, 예측 시간이 길어지면서 AUC와 TSS 모두 감소하는 모습을 보여준다. 기존 ACI_{YrOpt} 의 평균 AUC와 TSS는 0.690과 0.211인 반면 ACI_{SnOpt} 는 0.686과 0.196으로 각각 0.580%, 그리고 7.109% 예측 성능이 저하되는 결

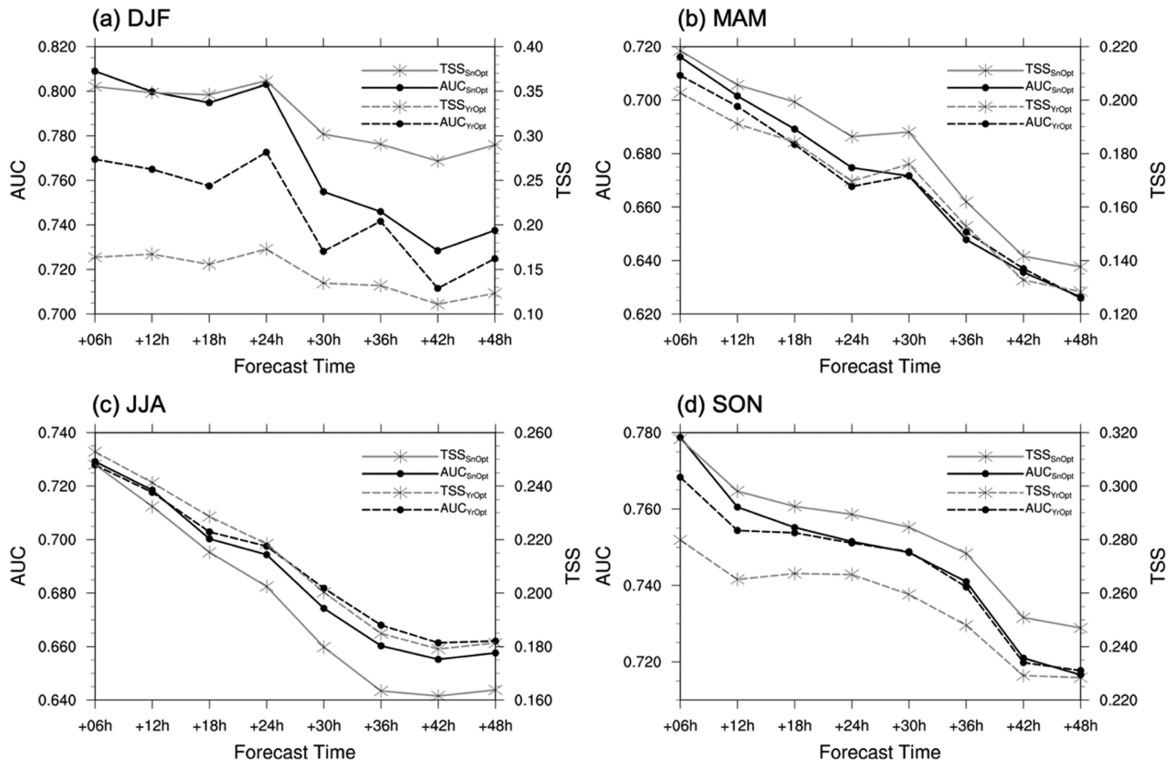


Fig. 5. AUC (black) and TSS (grey) values of ACI_{YrOpt} (dashed line) and ACI_{SnOpt} (solid line) for each forecast time in (a) DJF, (b) MAM, (c) JJA, and (d) SON.

Table 5. Seasonal averaged AUC and TSS of ACI_{NoOpt} , ACI_{YrOpt} , and ACI_{SnOpt} .

Seasons		DJF	MAM	JJA	SON	Averaged
AUC	ACI_{NoOpt}	0.780	0.662	0.684	0.732	0.715
	ACI_{YrOpt}	0.746	0.668	0.690	0.744	0.712
	ACI_{SnOpt}	0.772	0.670	0.686	0.747	0.719
TSS	ACI_{NoOpt}	0.212	0.164	0.209	0.245	0.207
	ACI_{YrOpt}	0.145	0.167	0.211	0.245	0.195
	ACI_{SnOpt}	0.321	0.180	0.196	0.282	0.245

과를 보였다. SON의 경우, 대부분의 예측 시간에서 성능이 향상되었다(Fig. 5d). 특히, MAM 기간과 마찬가지로 단기예측 결과에서 AUC와 TSS 모두 큰 폭으로 증가하였으며, 중기예측에 대한 성능은 상대적으로 증가폭이 작았다. 전체 예측 시간에 대해 AUC와 TSS는 0.403%, 그리고 15.102% 향상되었다. 정리하면, 입력 변수의 계절적 변동성을 고려하여 MF와 가중치를 최적한 이후, JJA를 제외한 모든 계절에서 전반적으로 예측 성능이 향상되었다. 특히, 1년 기간 자료기반 최적화 과정에서 큰 성능 저하를 보였던 DJF 시기에서는 성능이 큰 폭으로 향상되었다. 또한, MAM

과 SON 기간의 경우 긴 시간 예측보다 짧은 시간의 예측 결과에서 성능이 상대적으로 크게 향상되었다. 반면에, JJA 시기에는 오히려 계절에 따른 최적화 이후 예측 성능이 전반적으로 감소하였으며, 이러한 성능 저하는 예측 시간이 증가하면서 커지는 경향이 나타났다.

3.3 계절별 ACI_{YrOpt} 와 ACI_{SnOpt} 사이의 PODY와 POFD 변화 분석

최적화 이후 각 계절에서 나타난 AUC의 변화는 ACI_{SnOpt} 와 ACI_{YrOpt} 의 PODY와 POFD의 차이로 설명

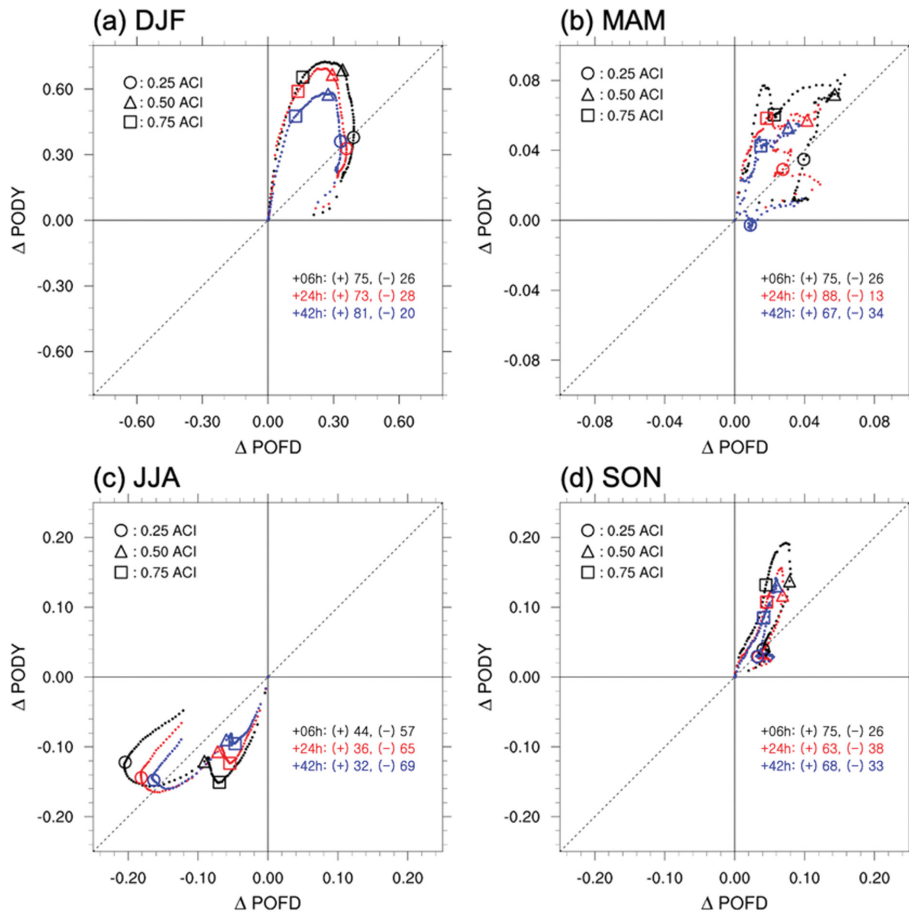


Fig. 6. Scatter plot of change of PODY and POFD between ACI_{YrOpt} and ACI_{SnOpt} ($ACI_{SnOpt} - ACI_{YrOpt}$) for 06-hour (black), 24-hour (red), 42-hour (blue) forecast time in (a) DJF, (b) MAM, (c) JJA, and (d) SON. And circle, triangle, square marker indicates the ACI of 0.25, 0.50, and 0.75 for each forecast time.

될 수 있다. 본 연구에서는 ACI를 0.01 단위로 나누어 각각에 대응되는 PODY와 POFD로 ROC 곡선을 분석하였기 때문에 특정 예측 기간 마다 총 101개의 점들이 존재한다. 또한 해당 점들은 ACI_{SnOpt} 와 ACI_{YrOpt} 의 ROC 곡선에서 각 ACI 값의 PODY와 POFD의 변화와 동일하기 때문에, Fig. 6에서 각 점들의 y-축 값은 ACI_{SnOpt} 의 PODY 값과 ACI_{YrOpt} 의 PODY 값의 차이와 동일하고 x-축은 두 ACI의 POFD 값의 차이와 동일하다. 그러므로 점들이 분포하는 방향은 곧 계절별 최적화 이후 ROC 곡선이 움직이는 방향으로 이해할 수 있다. 해당 그림에서 점선 상단에 위치한 점들이 많다는 의미는 ROC 곡선이 주로 좌측 상단으로 이동하여 곡선이 이루는 면적, 즉 AUC가 증가할 수 있다는 것을 의미한다. 본 연구에서는 편의를 위해 점선 상단을 (+)로 표현하였다. 그러므로 곡선의 하단 영역을 의미하는 (-)영역의 점보다 (+)영역의 점

이 더 많을수록, 그리고 그 거리가 멀수록 AUC 증가에 기여할 수 있다. 해당 그림에 대한 해석 방법은 파트 1에도 자세히 설명되어 있다.

먼저, 계절별 최적화를 통해 예측 성능이 가장 뚜렷하게 향상되었던 DJF 기간에는 대부분의 점이 1사분면에 위치한 것을 알 수 있다. 이는 PODY와 POFD가 모두 최적화를 통해 증가하였다는 의미이다. 그럼에도 불구하고 AUC가 크게 증가할 수 있었던 이유는 PODY의 증가폭이 더 컸기 때문이다. 실제로 6시간 예측 결과에서 ROC curve를 좌측 상단으로 옮기는 (+)점은 75개, 그리고 우측 하단으로 옮기는 (-)구역의 점은 26개로, 그 차이가 49개였다. 이러한 결과는 24시간과 42시간 예측 시간에서도 유사했다. 하지만 예측 기간이 짧을수록 점들의 위치는 원점으로부터 멀리 위치하여, 단기간 예측 결과에서 PODY의 증가폭이 더 큰 것을 보여준다. 이것이 42시간 예측 결

과에서 (+)점과 (-)점의 개수 차이가 짧은 예측 기간 때보다 컸음에도 불구하고 오히려 단기간 예측에서 AUC가 더 크게 증가했던 이유이다(Fig. 4a과 Fig. 5a). 겨울을 중심으로 최적화한 이후, 전반적으로 POFD가 증가했기 때문에, 기존의 ACI_{YrOpt} 보다 ACI_{SnOpt} 가 더 넓은 영역을 예보한다는 것을 알 수 있다. 이러한 통계적 특징은 뒤에 이어질 사례 분석을 통해 다시 확인할 수 있다.

MAM기간에도 PODY와 POFD 모두 증가하였다. 하지만, AUC를 증가시킬 수 있는 (+)지역에 더 많은 점들이 위치해 있다(Fig. 6b). 즉, 적중률과 오탐률이 모두 증가하였지만 전반적으로 적중률이 더 크게 증가하여 예측 성능이 향상된 경우이다. 예측 기간이 짧을수록 원점을 중심으로 더 멀리 위치해 있기 때문에, 단 기간 예측에서 PODY가 더 크게 증가한 것을 알 수 있다. 뿐만 아니라, 6시간 예측 결과에서 (+)점과 (-)점의 개수 차이는 42시간 예측 결과보다 더 크다. 이러한 요인들로 인해 Fig. 4b와 Fig. 5b에서 본 것처럼 장기간 보다 단기간 예측에서 예측 성능이 더 향상될 수 있었다. DJF시기와 마찬가지로 최적화 이후 기존보다 POFD가 증가하였기 때문에 ACI_{SnOpt} 가 ACI_{YrOpt} 보다 더 넓은 영역을 예측하는 것을 알 수 있다.

계절별 최적화 과정에서 유일하게 AUC가 감소하였던 JJA 때는 다른 계절과 달리 PODY와 POFD가 모두 감소하였다(Fig. 6c). 특히, 3사분면의 상단의 (+)점보다 하단의 (-)점이 더 많이 존재했으며, 이는 전반적으로 오탐률이 감소하는 정도보다 적중률의 감소 폭이 더 컸다는 의미이다. 예측 기간별 차이를 살펴보면, PODY의 감소폭은 전반적으로 비슷하였지만, POFD는 42시간 예측에서 더 적게 감소하였다. 실제로 (+)와 (-)점의 개수 차이는 6시간 예측 기간 때는 13개였지만, 42시간 예측에서는 37개로 급격하게 증가하였다. 이로 인해 예측 기간이 길어질수록 AUC는 더 크게 감소하였다(Fig. 4b와 Fig. 5b).

SON 시기의 최적화 결과는 DJF와 MAM 때의 결과와 유사했다. 마찬가지로 대부분의 ACI점들은 1사분면에 위치해 있었으며, PODY가 POFD보다 더 큰 폭으로 증가하면서 AUC가 증가하였다. 또한, 짧은 예측 기간에서 적중률이 더 많이 증가하였다. 1사분면 상단의 (+)점과 하단의 (-)점의 개수 차이도 단기간 예측에서 제일 높았다. 이것이 가을 시기의 최적화 과정에서 예측 기간이 짧을수록 AUC가 더 많이 증가할 수 있었던 이유이다(Fig. 4d와 Fig. 5d).

앞서 설명한 것처럼 계절별 최적화를 통해 대부분의 계절에서 예측 성능이 향상된 것을 확인하였다. 하지만 여름철의 특성을 고려한 이후, 기존과 대비하여 ACI_{SnOpt} 가 과소 예측하면서 오히려 성능이 소폭 감소하는 결과가 발생했다. 이는 위험 범위를 기반으로 구

측된 MF와 관련이 깊다. 여름철의 경우 대류의 발생 강도와 빈도가 매우 높기 때문에, 다른 계절에 비해 CAPE와 APCP의 위험 범위는 매우 높고 OLR은 매우 낮은 값의 구간에서 설정되었다(Fig. 2) 특히, JJA 기간의 위험 범위는 파트 1에서 설명된 1년 기간에 대한 위험 범위와 차이가 크기 때문에, 같은 입력 변수의 값이라도 1년 기간의 MF보다 여름철을 중심으로 설정된 MF에서 더 낮은 잠재도 값이 산출될 수밖에 없다. 이러한 요인으로 인해 ACI_{SnOpt} 는 기존의 ACI_{YrOpt} 와 비교하여 과소 예보하면서 AUC가 소폭 감소하였다. 그럼에도 불구하고 다른 계절에서는 모두 예측 성능이 향상되면서 전체 계절 평균 AUC는 0.719로 가장 높았다(Table 5). 평균 TSS도 유사한 결과를 보였다. ACI_{NoOpt} 의 계절 전체 평균 TSS는 0.207이지만, ACI_{YrOpt} 는 0.195로 오히려 감소하였다. 이는 마찬가지로 다른 계절 평균값은 증가하였지만, 겨울철의 급격한 감소가 원인이었다. 이후, 계절 변동성을 고려하면서 DJF 시기의 TSS는 급격히 증가하였고 MAM과 SON 시기에 TSS는 각각 0.180와 0.282로 ACI_{NoOpt} 와 ACI_{YrOpt} 에 비교하여 예측 성능이 꾸준히 향상되었다. 여름철에는 TSS 또한 소폭 감소함에도 불구하고 다른 계절의 큰 향상으로 인해 전체 계절 평균 TSS는 0.245로 가장 높은 결과를 보여주었다. 즉, 정리하면 계절 평균 AUC와 TSS를 비교하였을 때, 본 연구를 통해 개발된 다양한 형태의 ACI 중에서 계절 변동성을 고려한 ACI_{SnOpt} 가 가장 높은 예측 성능을 보였다. 특히, ACI_{SnOpt} 의 AUC와 TSS는 기존의 ACI_{YrOpt} 와 대비하여 각각 0.983%, 그리고 25.641% 향상되었다.

4. 사례 분석

본 연구에서는 지금까지 개발된 다양한 형태의 ACI의 예측 성능을 정량적으로 검증하기 위해 레이더 자료와 함께 비교하여 ROC curve 분석을 수행하였다. 앞서 분석한 통계적 특징이 실제 깊은 대류 사례에서 나타나는지 판단하고, ACI_{YrOpt} 와 ACI_{SnOpt} 의 예측 성능을 정성적으로 검증하기 위해 본 연구에서는 사례 분석을 추가로 수행하였다. ACI는 서로 다른 변수들을 결합하여 산출한 지수로 0과 1 사이의 값으로 이루어져 있다. 그러므로 무차원 수의 ACI 예측 결과는 관측에서 산출된 15 dBZ ETH와 정성적으로 비교하기 힘들다는 한계가 있다. 이러한 한계를 극복하기 위해, 0과 1 사이의 값으로 이루어진 ACI 값을 본 연구에서 최종적으로 예측하고자 하는 15 dBZ ETH의 단위와 동일한 비행고도(Flight Level, FL)로 변환하고자 하였다. 여기서 1 FL은 100 ft와 동일하다. 이를 위해, 먼저 각 계절별로 레이더 관측장에서 15 dBZ ETH의 고도에 대한 발생 빈도와 예측장에서 ACI 값에 따른

발생 빈도를 분석하였다. 이후 ETH와 ACI의 발생 빈도를 누적분포함수(Cumulative Distribution Function, CDF)로 표현하여 이들을 비교하였다. 특정 ETH 고도에 대한 CDF 값을 기준으로 같은 CDF 값을 갖는 ACI 값을 대응시켰다. 예를 들면, ETH의 CDF에서 FL250 (= 25,000 ft)의 CDF 값은 0.8이고 ACI에 대한 CDF에서도 ACI가 0.61 일 때 CDF가 동일하게 0.8이라고 한다면, 0.61 ACI와 FL250를 대응시켜 변환해 줄 수 있다. 본 연구에서는 각 계절별로 FLO부터 FL350까지 FL25 간격마다 나누어 특정 15 dBZ ETH 고도마다 같은 CDF 값을 갖는 ACI 값들을 대응시켰다. 이를 통해, 무차원 수의 ACI 예측 결과를 비행 고도로 변환하여 정성적인 검증을 수행하였다.

4.1 사례1 - 2021.12.16.0000 UTC

첫 번째 사례는 2021년 12월 16일 0000 UTC에 제

주도 및 남부 지역을 중심으로 발생한 집중호우 사례이다. 당시 종관 기압장을 보면, 한반도를 중심으로 서해에는 저기압, 그리고 남동쪽에는 고기압이 위치해 있다(Fig. 7a). 이러한 기압 배치에서 남해 부근에는 남서풍 기류가 발달하면서, 동중국해에 위치한 지상 저기압이 빠르게 한반도를 향해 이동하였다. 이로 인해 제주도를 포함한 남부 내륙에는 넓은 지역에 강수가 발생한 것을 시간당 강수량에 대한 레이더 Plan Position Indicator (PPI) 영상에서도 확인할 수 있다(Fig. 7b). 또한, 한반도로 이동하는 지상 저기압과 고기압 사이로 강한 기압 경도력이 발생하여 저기압 전면에는 강한 하층 제트가 발달하였다. 이 강한 남풍으로 인해 많은 양의 수증기가 한반도 남해안으로 유입되었다(Fig. 7c). 이 하층제트 뿐만 아니라 서해의 저기압성 흐름으로 인한 북풍, 그리고 내륙의 지형적 요인으로 인해 한반도 남해안에는 국지적으로 강한

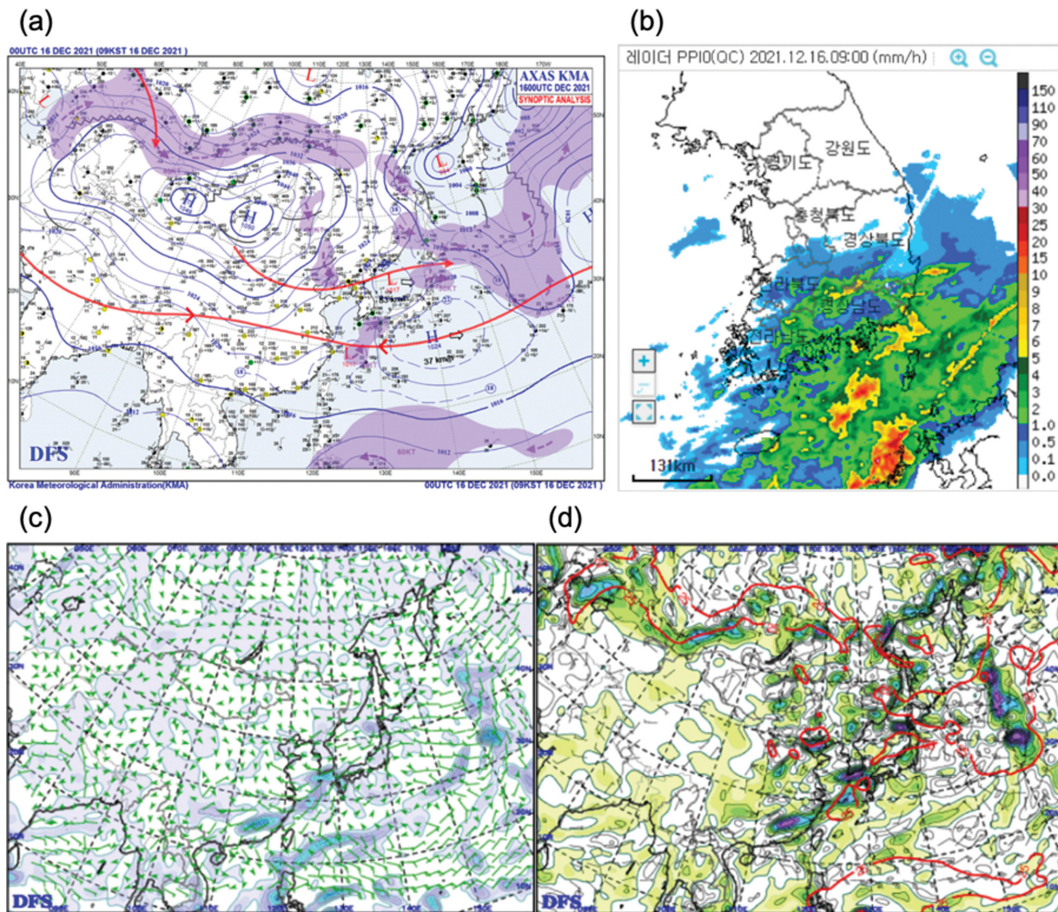


Fig. 7. (a) Analysis synoptic map at the surface, (b) Hourly precipitation of radar Plan Position Indicator (PPI) image, KIM-GDAPS Auxiliary analysis chart of (c) 850 hPa Moisture flux, and (d) 850 hPa Convergence at 0000 UTC 16 December 2021 from the Korea Meteorological Administration.

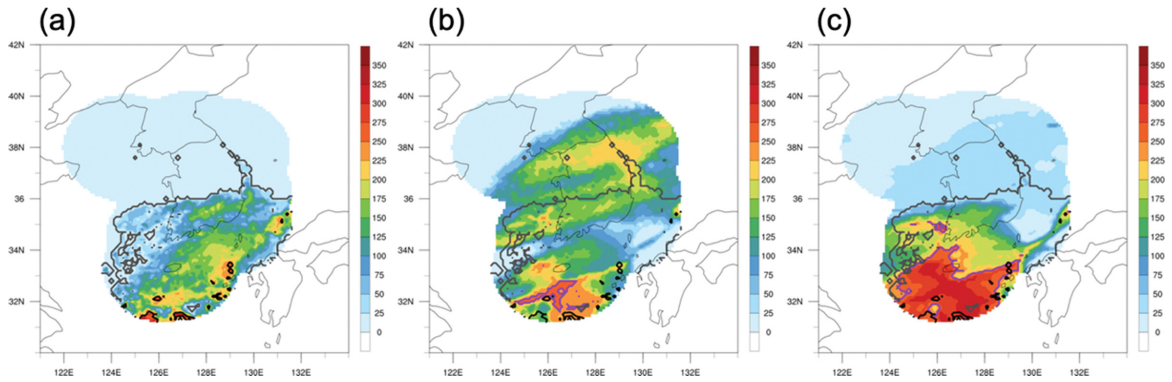


Fig. 8. (a) 15 dBZ ETH, 24-hour forecast of (b) ACI_{YrOpt} and (c) ACI_{SnOpt} at 0000 UTC 16 December 2021. Grey and black line indicate the area of 15 dBZ ETH over FL0 and the deep convective area (15 dBZ ETH \geq FL250) in (a), that is also expressed in (b) and (c). Purple line indicates the deep convective area (\geq FL250) in forecast field of (b) and (c).

하층 수렴대가 형성되었다(Fig. 7d).

해당 사례에서 15 dBZ ETH를 보면, 강수가 발생한 남해 및 남부 일부 지역에 대류가 존재하는 것을 알 수 있다(Fig. 8a). 내륙의 ETH는 FL200까지 나타났으며, 강수량이 높았던 남해 일부 지역에서는 FL250까지 대류가 발생하였다. 본 연구에서 최종적으로 예측하고자 하는 FL250 이상의 15 dBZ ETH 영역을 그림에서 검은색 선으로 표현하였고, 이를 깊은 대류 영역(deep convective area)으로 정의하였다. 반대로 예측장에서 설명하는 깊은 대류 영역은 그림에서 보라색으로 표현하였다. ACI_{YrOpt} 의 24시간 예측 결과에서는 깊은 대류의 공간 분포가 관측과 매우 다르게 나타났다. 남해에는 FL250 이상의 강한 대류를 예측하였지만, 실제로 관측되지 않았던 한반도 내륙의 중부 지역에도 FL200 정도의 추가적인 대류를 예측하였다(Fig. 8b). 이로 인해 전반적인 대류의 분포에서 관측과 많은 차이가 나타났다. 하지만 계절 변동성이 고려된 ACI_{SnOpt} 의 24시간 예측 결과에서는 관측장과 유사하게 남해 및 남해안에 중심을 둔 강한 대류 시스템만 예측하면서, 중부 지역의 큰 오차를 상당히 개선시켰다(Fig. 8c). 하지만 남해 지역을 중심으로 보면, ACI_{SnOpt} 가 오히려 ACI_{YrOpt} 보다 대류를 더욱 과대 예측하는 것을 알 수 있다. ACI_{SnOpt} 의 예측 결과에서는 FL300 이상 고도까지 발달한 대류가 관측보다 더 넓은 지역에 발달하였다. 이렇게 관측과 더불어 기존의 ACI_{YrOpt} 보다 과대 모의하는 특징은 앞서 Fig. 6a 통해 이해한 통계적 특성과 동일하다. 앞선 통계적 분석 결과에 따르면, DJF 기간에 맞는 MF와 가중치 조합을 적용시키면서 전반적인 예측 성능은 크게 향상되었다. 이 과정에서 PODY 뿐만 아니라 POFD도 증가하였다. 본 사례에서도 마찬가지로 ACI_{SnOpt} 예측장에서는 보라색으로 표현된 예측된 깊은 대류 영역이 검은색의

관측장에서의 깊은 대류 영역을 모두 설명하고 있다. 반면에 ACI_{YrOpt} 에서는 거의 설명이 되지 못했다. 이를 통해 PODY의 증가를 알 수 있다. 하지만, ACI_{SnOpt} 에 측정의 보라색 영역이 실제 깊은 대류 영역보다 넓은 영역을 예측하며 POFD 또한 증가한 것을 보여준다.

앞서 언급한 것처럼 본 연구에서 ROC 곡선을 사용한 최적화 및 검증은 15 dBZ ETH가 FL0을 넘는 영역에 대해서 수행되었다. 해당 영역은 Fig. 8에서 회색으로 표현되었다. 본 사례에서 나타난 중요한 특징 중 하나는 최적화 활용된 FL0을 넘는 영역뿐만 아니라 그 바깥 지역에서도 공간 분포의 개선이 뚜렷하게 나타났다는 것이다. 이러한 대류 공간 분포에 대한 개선 과정을 자세히 살펴보기 위해, 입력 변수로부터 산출된 최종 잠재도를 비교해보았다. 여기서 최종 잠재도는 MF로부터 산출된 값에 가중 상수가 곱해진 값을 의미하며, 그 합이 최종적인 ACI 결과와 동일하다. ACI_{YrOpt} 와 ACI_{SnOpt} 에서 산출된 CAPE의 최종 잠재도를 비교해보면, 전반적인 공간 분포는 유사하지만 ACI_{YrOpt} 에서 잠재도가 더 좁은 영역에서 높은 값을 보인다(Figs. 9a, d). 이러한 차이는 가중치 조합과 멤버십 함수가 모두 다르기 때문이다. 각각의 MF_{CAPE} 범위만 고려해본다면, ACI_{SnOpt} 에서 설정된 범위가 상대적으로 더 낮은 값에서 정의되었기 때문에 계산 과정에서 산출되는 CAPE의 최종 잠재도는 더 높아야 한다. 그럼에도 불구하고 ACI_{YrOpt} 가 높은 이유는 장기간에 대한 최적의 가중 상수가 0.45로, 계절에 맞는 가중치보다 더 높게 설정되었기 때문이다. APCP의 경우, ACI_{YrOpt} 계산 과정에서 가중치가 0.05로 매우 낮게 설정되면서 최종 잠재도가 매우 낮게 산출되었다(Fig. 9b). 하지만 계절 변동성을 고려한 ACI_{SnOpt} 에서는 상대적으로 작은 값에서 MF가 구축되었을 뿐만 아니라, 가중치가 0.7로 조정되었기 때문에, ACI_{SnOpt}

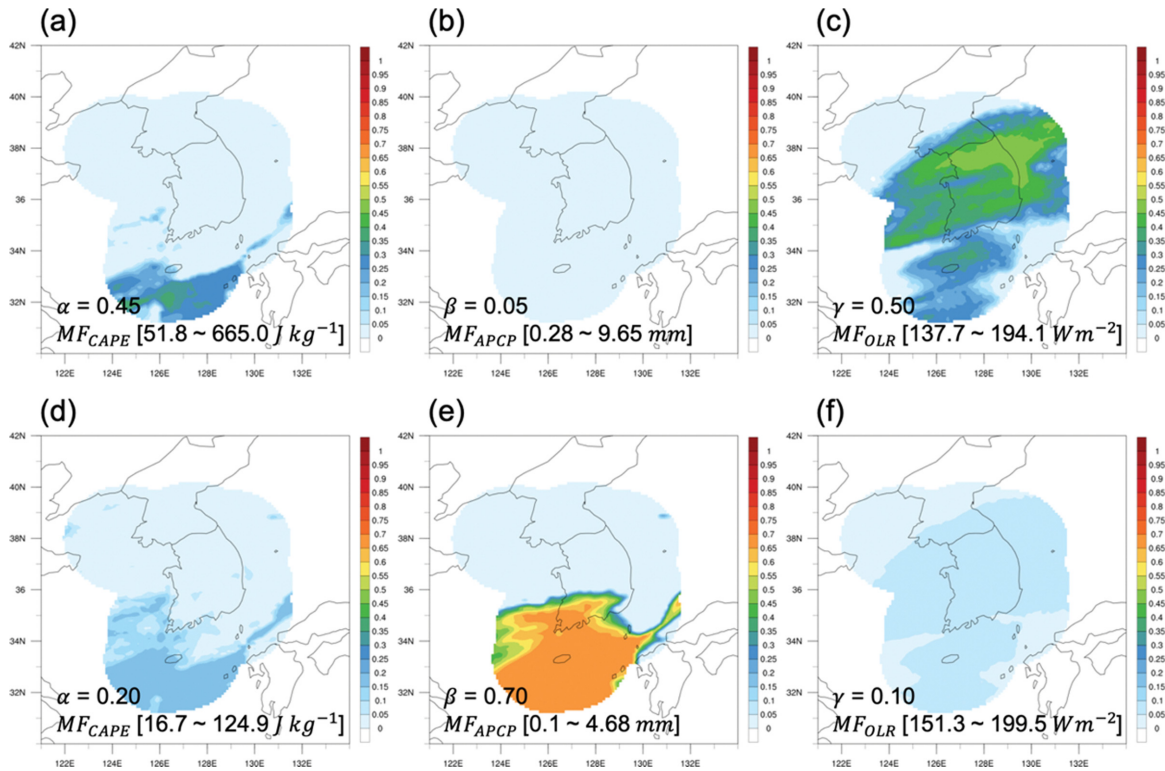


Fig. 9. (a) αM_{CAPE} , (b) βM_{APCP} , (c) γM_{OLR} of ACI_{YrOpt} , and (d) αM_{CAPE} , (e) βM_{APCP} , (f) γM_{OLR} of ACI_{SnOpt} . Bracket refers to the range of MFs.

의 예측 결과에서 0.65 이상의 잠재도가 남해의 넓은 지역에 예측되었다(Fig. 9e). ACI_{SnOpt} 의 예측 결과에서 대류의 공간 분포가 크게 개선된 이유는 OLR의 최종 잠재도의 변화 때문이다(Figs. 9c, d). 먼저, ACI_{YrOpt} 계산 과정에서 산출된 OLR 예측장을 보면 기본적으로 깊은 대류의 발생 위치를 잘 설명하지 못하는 것을 알 수 있다. 하지만 장기간에 대한 최적의 가중치는 0.5로 설정되었기 때문에 이러한 잘못된 예측 결과가 많이 반영되었다. 이로 인해 최종적인 ACI_{YrOpt} 예측 결과에서 관측에는 발생하지 않았던 한반도 중부 지역의 대류를 잘못 예측하였다. 하지만 계절별 최적화 이후, MF 범위는 유사하지만 가중치는 0.1로 조정되면서 OLR의 최종 잠재도는 ACI_{SnOpt} 계산 과정에서 거의 나타나지 않았다. 이를 통해 중부 지역에 잘못 예측된 대류 분포를 상당히 보정할 수 있었다.

4.2 사례2 - 2021.05.28.0300 UTC

해당 사례는 중국의 산둥 지역에 지면 가열로 인해 발생한 저기압이 발달과 동시에 동진하며 한반도를 관통하여 집중호우를 발생시킨 사례이다. 집중호우 발생 시간 기준 3시간 이전의 지상 분석 일기도에서는

상층의 뚜렷한 기압골과 강한 제트 기류가 존재한다 (Fig. 10a). 하지만 지상 저기압의 중심은 기압골의 우측, 혹은 제트 기류 입구의 우측에 위치하지 않기에, 상층 시스템으로 인한 비-지균 상승의 직접적인 영향은 있다고 보기 어렵다. 실제로 보조 분석도의 상층 발산에서는 상층 기압골과 제트 기류로 인한 넓은 발산 구역과 서해안에 지상 저기압으로 인한 국지적인 발산 구역은 뚜렷하게 구분된다(Fig. 10c). 서해안에 위치한 저기압은 한반도로 동진하며, 주변에는 강한 하층 제트가 발달하였다. 이로 인해 저기압 전면에는 선형 형태의 강한 강수대가 발달하였으며, 시간이 지나면서 더욱 발달하여 위성 영상에서는 뚜렷한 콤파 형태의 구름 구조로 강화되었다(Fig. 10b). 또한, 해당 사례가 발생한 시기에는 서해안에는 국지적으로 높은 불안정도가 존재한 것이 특징이었으며, 이는 쇼월터 안정도 지수(Shoewalter Stability Index)에 대한 보조 분석도에서 확인할 수 있다(Fig. 10d).

해당 사례는 선형 강수대가 한반도를 지나는 과정에서 항공기가 대류를 피하지 못하고 관통하였던 사례이다. 이로 인해, 항공기는 CIT를 조우하였다. 항공기 관측 자료인 Aircraft Meteorological Data Relay

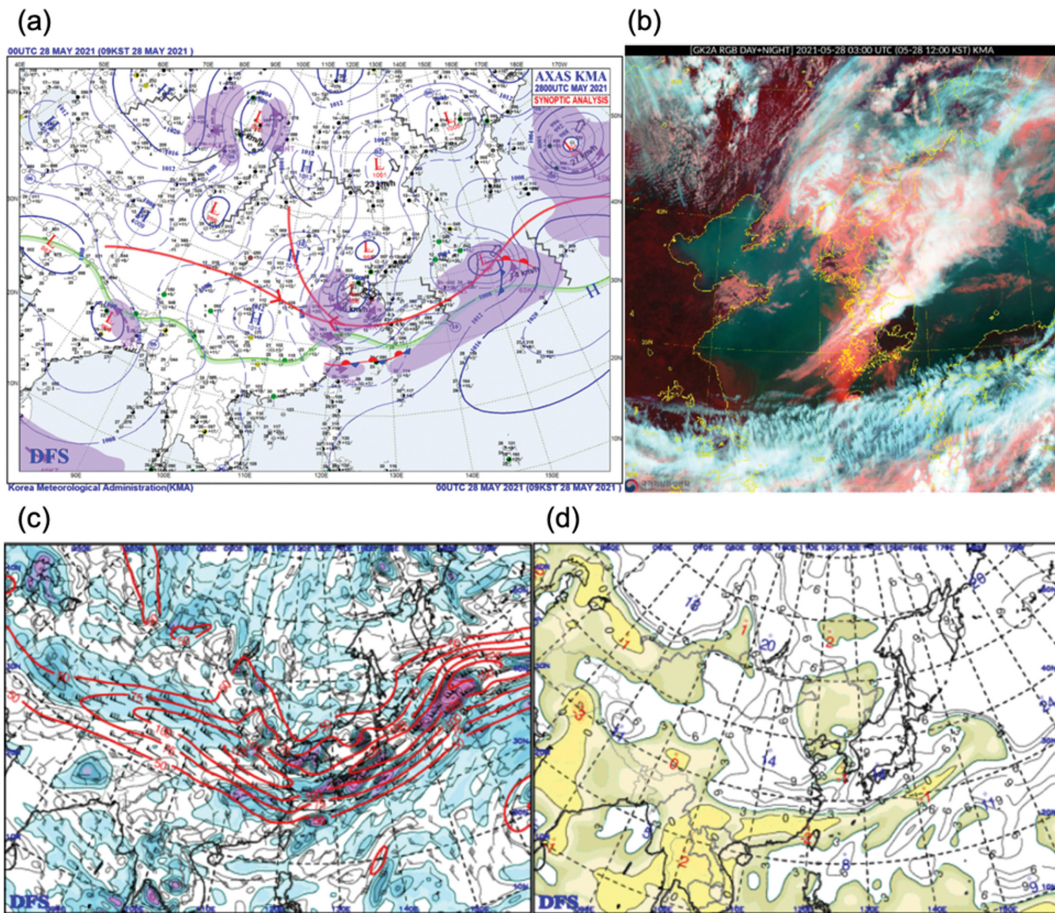


Fig. 10. (a) Analysis synoptic map at the surface, (b) GK2A RGB image, KIM-GDAPS Auxiliary analysis chart of (c) 300 hPa Divergence and wind, and (d) 850-500 hPa Showalter Stability Index at 0000 UTC 28 May 2021 from the Korea Meteorological Administration.

(AMDAR)에 기록된 순간 최대 난류 강도는 $0.21 \text{ m}^2 \text{ s}^{-1}$ 였으며 난류강도는 중간 강도로써 상공 약 6.28 km에서 관측되었다. 발생 당시인 2021년 5월 28일 0300 UTC 때의 15 dBZ ETH를 보면 FL250 이상으로 깊은 대류의 중심에서 파란색 점으로 표시된 CIT가 발생한 것을 알 수 있다(Fig. 11a). 앞선 사례와 마찬가지로 관측장에서 FL250 이상의 깊은 대류 영역은 검은색 선으로 표현되었으며, 예측된 깊은 대류 영역은 예측장에서 보라색으로 표현되었다. ACI_{YrOpt} 와 ACI_{SnOpt} 의 21 시간 예측 결과에서는 관측에서 나타난 대류의 전반적인 공간 분포가 잘 설명되었다(Figs. 11b와 c). 하지만 CIT 발생 지점을 중심으로 보면, ACI_{YrOpt} 은 관측과 비교하여 대류 강도를 약하게 예측한 반면에 ACI_{SnOpt} 예측 결과에서는 ETH를 FL250 이상으로 대류의 강도를 관측과 유사하게 예측되었다. 뿐만 아니라, ACI_{YrOpt}

예측장에서 보라색으로 표시된 깊은 대류 영역은 검은색으로 표시된 관측 자료의 깊은 대류 영역을 모두 설명하지 못하였지만, ACI_{SnOpt} 를 통해 예측된 깊은 대류 영역은 실제 영역을 모두 설명하였다. 이는 곧 PODY의 증가를 의미하며, 앞서 Fig. 6b를 통해 분석한 MAM 기간의 최적화 과정에서 보인 통계적 특성과 동일하다. DJF와 마찬가지로 해당 계절에는 POFD와 PODY가 모두 증가하였지만 PODY의 증가폭이 더욱 크면서 예측 성능이 향상되었다. 본 사례에서도 기존의 ACI_{YrOpt} 보다 과대 예측하면서 관측된 대류영역을 모두 예측하긴 했지만, 관측되지 않은 영역 또한 더 많이 예측하면서 POFD도 증가하는 것을 보여준다.

앞서 해당 사례의 쇼월터 안정도 지수에 대한 보조 분석도에서 확인한 것처럼 대류 발달 당시 불안정도가 높은 환경이었다(Fig. 10d). 마찬가지로 ACI_{YrOpt} 와

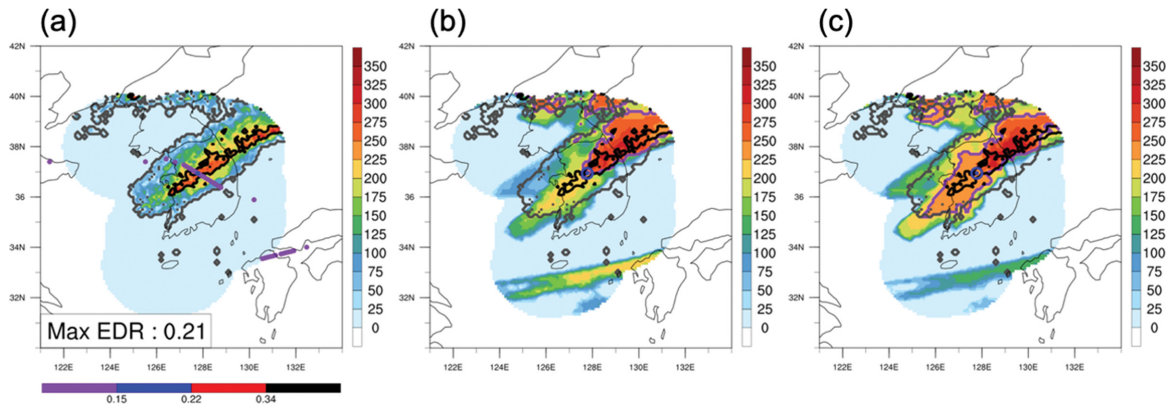


Fig. 11. (a) 15 dBZ ETH, 21-hour forecast of (b) ACI_{YrOpt} and (c) ACI_{SnOpt} at 0300 UTC 28 May 2021. Grey and black line indicate the area of 15 dBZ ETH over FL0 and the deep convective area (15 dBZ ETH \geq FL250) in (a), that is also expressed in (b) and (c). Purple line indicates the deep convective area (\geq FL250) in forecast field of (b) and (c). Here, the intensity of Convectively-Induced Turbulence is indicated by the dots with colors in (a). And the location of CIT encounter is indicated by the blue circle in (b) and (c).

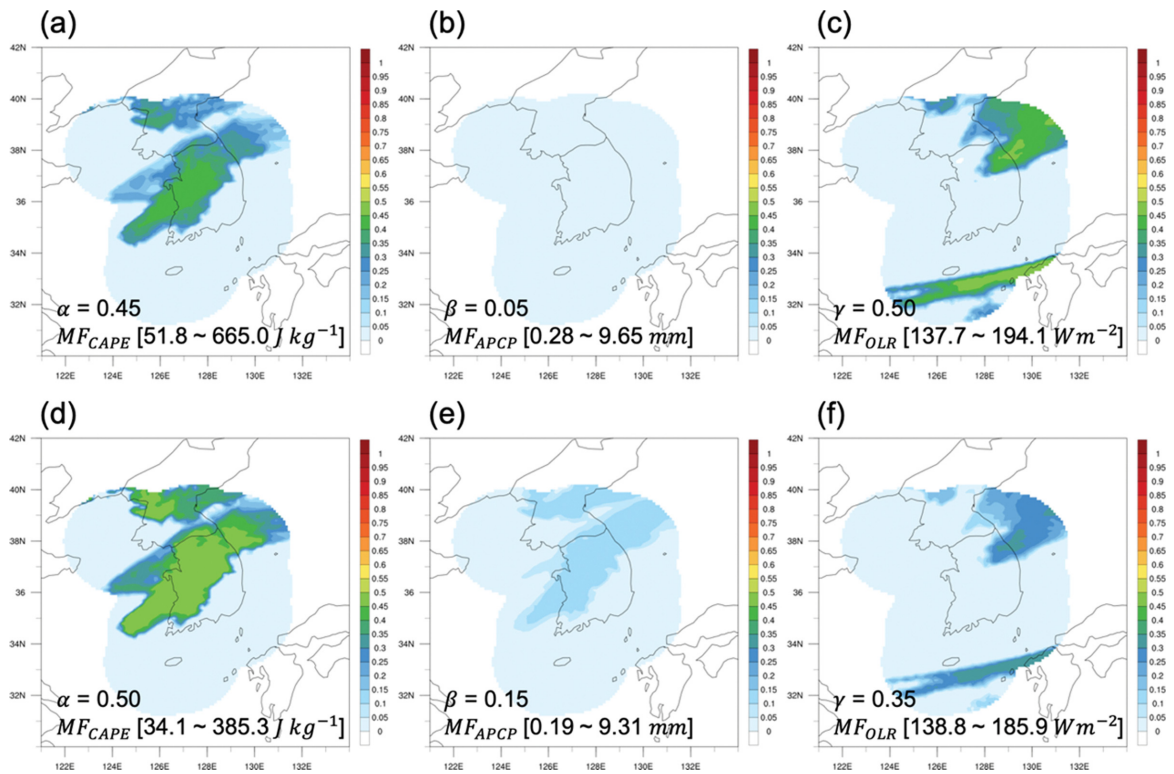


Fig. 12. (a) $\alpha_{M_{CAPE}}$, (b) $\beta_{M_{APCP}}$, (c) $\gamma_{M_{OLR}}$ of ACI_{YrOpt} , and (d) $\alpha_{M_{CAPE}}$, (e) $\beta_{M_{APCP}}$, (f) $\gamma_{M_{OLR}}$ of ACI_{SnOpt} . Bracket refers to the range of MFs.

ACI_{SnOpt} 에서 계산된 CAPE의 잠재도 모두 대류가 존재하였던 한반도 내륙에서 매우 강하게 나타났으며,

다른 변수와 비교하여 최종적인 ACI에 가장 많은 기여를 한 것을 알 수 있다(Figs. 12a, d). 계절별 최적

화 이후 CAPE의 가중 상수는 크게 조정되지 않았다. 하지만 MF의 범위가 더 낮게 설정되면서 ACI_{SnOpt} 에서 CAPE의 최종 잠재도는 기존의 ACI_{YrOpt} 보다 높게 나타났다. 이러한 변화는 해당 사례에서 PODY를 증가시키는 데 직접적인 기여를 하였다. APCP의 예측 장에서도 선형 형태의 대류가 잘 나타났다. 하지만 ACI_{YrOpt} 계산 과정에서는 APCP의 최종 잠재도가 매우 낮게 고려되었다(Fig. 12b). 즉, 해당 변수의 좋은 예측 결과가 거의 반영되지 못했다. 이러한 이유는 장기간에 대한 최적화 과정을 거치면서 강수량에 대한 가중 상수는 0.05로 매우 낮게 설정되었기 때문이다. 하지만 계절적 특성이 고려되면서, 가중치가 0.15로 증가하였다. 이를 통해 ACI_{SnOpt} 계산 과정에서는 APCP의 잠재도가 더 높게 산출되면서, 좋은 예측 결과가 최종적인 ACI 결과에 더 많이 반영될 수 있었다(Fig. 12e). 이것이 ACI_{SnOpt} 가 ACI_{YrOpt} 보다 더 강한 대류를 예측하여 실제 관측과 더 유사해 질 수 있었던 원인이었다. 반면에 ACI_{SnOpt} 와 ACI_{YrOpt} 에서 OLR은 전반적으로 깊은 대류에 대한 공간 분포를 잘 설명하지 못하였다(Figs. 12c, f). 영동 지역을 포함한 동해안 일부와 긴 형태의 상층운이 존재했던 남해 일부 지역에서 대류를 예측하였지만, CIT를 발생시킨 한반도 중부 지역의 깊은 대류를 전혀 예측하지 못하였다. 그러므로 깊은 대류를 예측하는 데 있어서 OLR은 적게 고려될수록 유리하다. 두 가지의 ACI를 비교해보면, ACI_{SnOpt} 에서 더 작게 산출된 것을 알 수 있다. 계절별 최적화 이후 MF 범위의 차이는 크지 않지만, 기존 ACI_{YrOpt} 의 OLR 가중 상수는 0.5인 반면 ACI_{SnOpt} 에서는 0.35로 더 낮게 설정되었다. 이를 통해 불필요한 예측 결과를 더 적게 고려할 수 있었다.

5. 결 론

본 연구에서는 다양한 항공 위험 기상을 발생시키는 깊은 대류로 인한 직, 간접적 영향을 최소화하고 안전한 항공기 운항에 기여하기 위해 국내 공항 및 공역 지역에 활용 가능한 새로운 대류 예측 지수, ACI를 개발하였다. ACI는 기상청의 현업 예보 모델 중 하나인 UM-GDAPS를 기반으로 구축되었으며, 국내 레이더 관측 자료를 통해 검증되었다. 해당 지수는 CAPE, APCP, 그리고 OLR의 예측장으로부터 퍼지-로직 알고리즘을 통해 결합시켜 산출되며, 이 과정에서 사용된 MF와 가중치 조합은 특정 시기에 맞추어 최적화할 수 있다는 장점이 있다. 본 연구의 Part 1에서는 1년 기간에 대한 최적의 가중치 조합을 적용시킨 ACI_{YrOpt} 와 균일한 가중치를 사용한 기존의 ACI_{NoOpt} 의 예측 성능을 ROC curve 분석을 통해 정량적으로 검증하였다. 그 결과 1년 전체 기간에 대한 AUC 값

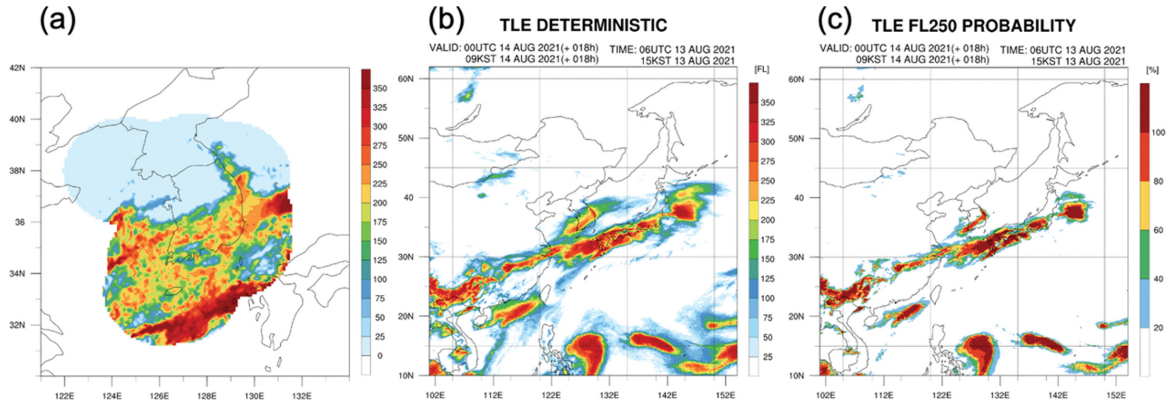
은 향상되었지만, 계절별 대류 발생 빈도가 가장 낮은 DJF 기간에 대한 AUC는 급격하게 감소하는 것을 본 연구(Part 2)에서 확인하였다. 겨울철 급격한 성능 저하로 인해, 전체 계절 평균 AUC와 TSS는 오히려 Part 1의 1년 기간 자료 최적화 이후 감소하였다.

Part 2에서는 이러한 장기간 최적화 방식이 갖는 한계점을 극복하기 위해 대류와 관련된 입력 변수들의 계절 변동성을 고려하였다. 이 과정에서 계절에 따라 MF와 최적의 가중치 조합을 구축하여 계절에 최적화된 ACI_{SnOpt} 를 개발하였다. 그 결과 대부분의 계절에서 예측 성능이 향상되었다. 특히, 장기간 최적화로 인해 성능이 저하되었던 DJF 시기에는 PODY가 POFD보다 더 큰 폭으로 증가하면서 AUC도 증가하였다. 전체 계절 평균 AUC와 TSS는 지금까지 개발된 ACI 중 ACI_{SnOpt} 가 가장 높았다. 추가로, 본 연구에서는 계절별 최적화를 통한 예측 성능 향상을 정성적으로 검증하기 위해 사례 분석을 수행하였다. 선정된 사례에서도 앞서 분석한 통계적 특성이 잘 나타났으며, ACI_{SnOpt} 가 기존의 ACI_{YrOpt} 보다 대류의 공간 분포와 강도 측면에서 정성적으로 더 좋은 예측 결과를 보였다. 또한, 각 변수의 최종 잠재도를 비교하여 MF와 가중치 조합의 최적화를 통한 성능 개선 과정을 확인하였다.

본 연구에서는 몇 가지 한계점이 존재한다. 특정 기간에 대한 가중치 조합과 지수 산출에 쓰이는 MF를 구축하는 과정뿐만 아니라 이렇게 최적화된 지수의 예측 성능을 검증하는 과정에서 동일하게 2021년 기간에 대한 자료를 활용하였다. 최적화와 평가 데이터가 같기 때문에, 본 연구에서는 과적합(Overfitting)의 가능성이 존재한다. 그러므로 향후 최적화에 고려된 기간이 아닌 다른 해의 자료를 통해 검증할 필요가 있다. 또한, 본 연구에서는 입력 변수들의 강도 및 빈도에 대한 계절별 변동성을 고려하기 위해 임의로 특정 월들을 묶어 계절로 정의하였다. 그리고 해당 기간에 대한 통계적 특성을 기반으로 MF와 가중치를 개발하였기 때문에, 계절과 계절 사이의 불연속성이 분명 존재한다. 예를 들어, DJF 기간의 마지막 시간대와 MAM 기간의 첫 시간대는 분명 연속되지만 서로 다른 MF와 가중치 조합을 토대로 예측 결과가 산출된다. 이를 해결하기 위해서는, 서로 다른 계절에 대한 ACI의 예측 결과를 섞어 주는 과정(Blending, 블렌딩)이 필요하다. 예를 들어, 두 예측 결과를 단순히 평균을 취하거나 기간에 따라 가중치를 할당하여 가중 평균 취해줄 수 있다. 하지만 이 과정에서도 블렌딩하는 기간을 설정해주어야 하기 때문에 이 부분에 대한 임의성도 존재할 수 밖에 없다는 한계점이 있다. 그러므로 계절 사이에 존재하는 불연속성을 줄이기 위해서는, 다양한 블렌딩 방식과 기준에 따른 민감도를 파악하여 적절한 방법을 고려해야 한다.

Table 6. Time-lagged ensemble members of each forecast time.

Forecast time	Ensemble members				
6-hour forecast	+06 h	+12 h	+18 h	+24 h	+30 h
12-hour forecast	+12 h	+18 h	+24 h	+30 h	+36 h
18-hour forecast	+18 h	+24 h	+30 h	+36 h	+42 h
24-hour forecast	+24 h	+30 h	+36 h	+42 h	+48 h

**Fig. 13.** (a) 15 dBZ ETH, 18-hour Time-lagged ensemble-based (b) deterministic and (c) probabilistic forecast of ACI_{SnOpI} at 0000 UTC 16 August 2021.

또한, 수치예보모델을 기반으로 산출되는 ACI를 예보에 활용하기 위해서는 초기장, 예측 기간, 모수화 방안 등 다양한 요인들로 인한 수치모델이 갖는 불확실성을 고려해야한다. 이러한 불확실성을 줄이기 위해 다중-모델, 다중-지수 등 다양한 앙상블 기법을 활용할 수 있다. 현재 본 연구를 통해 개발된 ACI는 단일 수치예보모델의 예측장을 통해 산출되기 때문에 이러한 앙상블 기법은 사용하지 못한다. 하지만 서로 다른 예측 기간에 대한 결과를 활용한 앙상블(Time-lagged Ensemble, TLE) 방식을 ACI에 활용하여 깊은 대류에 대한 확률 예측장을 생산할 수 있다. 본 연구에서는 TLE 기반 확률 예측을 위해 개발 및 검증에 활용하였던 6시간 단위의 예측장을 앙상블 멤버로 사용하였다(Table 6). 총 5개의 앙상블 멤버를 통해 특정 고도에 대한 확률을 산출할 수 있을 뿐만 아니라 앙상블 멤버간 평균을 취해 결정론적 예보에도 활용할 수 있다. Figure 13은 TLE 방식을 기반으로 계산된 결정론적 예측 결과와 FL250에 대한 확률론적 예측 결과를 예시로 보여준다. 하지만 확률 예측 결과에서는 여전히 앙상블 멤버의 수가 제한적이라는 한계가 있다. 더욱 상세한 확률 예측 결과를 예보에 활용하기 위해서는 2개 이상의 수치 모델 자료와 ACI를 구성하는 지수들을 포함한 다양한 지수를 활용하여 다중-모델 및 다중-지수 앙상블 기반 확률 예측 기

술을 개발할 필요가 있다.

감사의 글

본 논문의 질적 향상을 위해 좋은 의견들을 제시해주신 두 심사위원 분들께 감사의 말씀을 전합니다. 이 연구는 기상·지진 See-At 기술개발연구사업(KMI2020-01910)의 지원과 기상청 「차세대 항공교통 지원 항공기상 기술개발(NARAE-Weather)」(KMI2022-00310과 KMI2022-00410)의 지원으로 수행되었습니다.

REFERENCES

- Charba, J. P., 1977: Operational system for predicting thunderstorms two to six hours in advance. *NOAA* [Available online at https://repository.library.noaa.gov/view/noaa/13628/noaa_13628_DS1.pdf].
- Chuda, T., and H. Niino, 2005: Climatology of environmental parameters for mesoscale convections in Japan. *J. Meteor. Soc. Japan. Ser. II*, **83**, 391-408, doi:10.2151/jmsj.83.391.
- Doswell III, C. A., 1987: The distinction between large-scale and mesoscale contribution to severe convection: A case study example. *Wea. Forecasting*, **2**, 3-16,

- doi:10.1175/1520-0434(1987)002<0003:TDBLSA>2.0.CO;2.
- Galway, J. G., 1956: The lifted index as a predictor of latent instability. *Bull. Amer. Meteor. Soc.*, **37**, 528-529, doi:10.1175/1520-0477-37.10.528.
- George, J. J., 1960: *Weather forecasting for aeronautics*. Academic press, 684 pp.
- Haklander, A. J., and A. V. Delden, 2003: Thunderstorm predictors and their forecast skill for the Netherlands. *Atmos. Res.*, **67**, 273-299, doi:10.1016/S0169-8095(03)00056-5.
- Hu, S., S.-P. Xie, R. Seager, and M. A. Cane, 2023: Spatial and seasonal variations of sea surface temperature threshold for tropical convection. *J. Climate*, **36**, 4899-4912, doi:10.1175/JCLI-D-22-0545.1.
- ICAO, 2012: 'Seventh Meeting of the World Area Forecast System Operations Group (WAFSOPSG)' Lima, Peru, 59 pp [Available online at <https://www.icao.int/safety/meteorology/WAFSOPSG/WAFSOPSG%20Meetings%20Metadata/WAFSOPSG.7.Final.Report.pdf>].
- Melling, L. D., A. G. Laing, M. S. Wandishin, J. E. Hart, and M. A. Petty, 2019: Ensemble Prediction of Oceanic Convective Hazards (EPOCH) Assessment: Part II. *NOAA* [Available online at https://repository.library.noaa.gov/view/noaa/22921/noaa_22921_DS1.pdf].
- Miller, R. C., 1967: *Notes on analysis and severe-storm forecasting procedures of the Military Weather Warning Center*. Air Weather Service (MAC), United States Air Force, 2 pp.
- _____, 1975: *Notes on analysis and severe-storm forecasting procedures of the Air Force Global Weather Central*. AWS, 200 pp.
- Poręba, S., M. Tazarek, and Z. Ustrnul, 2022: Diurnal and seasonal variability of ERA5 convective parameters in relation to lightning flash rates in Poland. *Wea. Forecasting*, **37**, 1447-1470, doi:10.1175/WAF-D-21-0099.1.
- Reap, R. M., and D. S. Foster, 1979: Automated 12-36 hour probability forecasts of thunderstorms and severe local storms. *J. Appl. Meteor. Climatol.*, **18**, 1304-1315, doi:10.1175/1520-0450(1979)018<1304:AHPFOT>2.0.CO;2.
- Riemann-Campe, K., K. Fraedrich, and F. Lunkeit, 2009: Global climatology of convective available potential energy (CAPE) and convective inhibition (CIN) in ERA-40 reanalysis. *Atmos. Res.*, **93**, 534-545, doi:10.1016/j.atmosres.2008.09.037.
- Schmeits, M. J., K. J. Kok, D. H. P. Vogelesang, and R. M. van Westrhenen, 2008: Probabilistic forecasts of (severe) thunderstorms for the purpose of issuing a weather alarm in the Netherlands. *Wea. Forecasting*, **23**, 1253-1267, doi:10.1175/2008WAF2007102.1.
- Schultz, D. M., and P. N. Schumacher, 1999: The use and misuse of conditional symmetric instability. *Mon. Wea. Rev.*, **127**, 2709-2732, doi:10.1175/1520-0493(1999)127<2709:TUAMOC>2.0.CO;2.
- Showalter, A. K., 1953: A stability index for thunderstorm forecasting. *Bull. Amer. Meteor. Soc.*, **34**, 250-252, doi:10.1175/1520-0477-34.6.250.
- Simon, T., P. Fabsic, G. J. Mayr, N. Umlauf, and A. Zeileis, 2018: Probabilistic forecasting of thunderstorms in the Eastern Alps. *Mon. Wea. Rev.*, **146**, 2999-3009, doi:10.1175/MWR-D-17-0366.1.
- Slangen, A. B. A., and M. J. Schmeits, 2009: Probabilistic forecasts of winter thunderstorms around Amsterdam Airport Schiphol. *Adv. Sci. Res.*, **3**, 39-43, doi:10.5194/asr-3-39-2009.
- Sobash, R. A., J. S. Kain, D. R. Bright, A. R. Dean, M. C. Coniglio, and S. J. Weiss, 2011: Probabilistic forecast guidance for severe thunderstorms based on the identification of extreme phenomena in convection-allowing model forecasts. *Wea. Forecasting*, **26**, 714-728, doi:10.1175/WAF-D-10-05046.1.
- _____, G. S. Romine, C. S. Schwartz, D. J. Gagne, and M. L. Weisman, 2016: Explicit forecasts of low-level rotation from convection-allowing models for next-day tornado prediction. *Wea. Forecasting*, **31**, 1591-1614, doi:10.1175/WAF-D-16-0073.1.
- Wendt, N. A., I. L. Jirak, and C. J. Melick, 2016: *Verification of severe weather proxies from the NSSL-WRF for hail forecasting*. In 28th Conf. on Severe Local Storms, 15 pp.