

마이크로 유전알고리즘을 이용한 적운물리과정 모수 최적화에 따른 여름철 강수에측성능 개선

장지연* · 이용희 · 최현주

기상청 수치모델링센터 수치자료응용과

(접수일: 2020년 6월 28일, 수정일: 2020년 9월 25일, 게재확정일: 2020년 9월 25일)

The Improvement of Summer Season Precipitation Predictability by Optimizing the Parameters in Cumulus Parameterization Using Micro-Genetic Algorithm

Ji-Yeon Jang*, Yong Hee Lee, and Hyun-Joo Choi

Numerical Data Application Division, Numerical Modeling Center, KMA, Seoul, Korea

(Manuscript received 28 June 2020; revised 25 September 2020; accepted 25 September 2020)

Abstract Three free parameters included in a cumulus parameterization are optimized by using micro-genetic algorithm for three precipitation cases occurred in the Korea Peninsula during the summer season in order to reduce biases in a regional model associated with the uncertainties of the parameters and thus to improve the predictability of precipitation. The first parameter is the one that determines the threshold in convective trigger condition. The second parameter is the one that determines boundary layer forcing in convective closure. Finally, the third parameter is the one used in calculating conversion parameter determining the fraction of condensate converted to convective precipitation. Optimized parameters reduce the occurrence of convections by suppressing the trigger of convection. The reduced convection occurrence decreases light precipitation but increases heavy precipitation. The sensitivity experiments are conducted to examine the effects of the optimized parameters on the predictability of precipitation. The predictability of precipitation is the best when the three optimized parameters are applied to the parameterization at the same time. The first parameter most dominantly affects the predictability of precipitation. Short-range forecasts for July 2018 are also conducted to statistically assess the precipitation predictability. It is found that the predictability of precipitation is consistently improved with the optimized parameters.

Key words: Cumulus parameterization, micro-genetic algorithm, optimization, precipitation

1. 서 론

수치예보모델에서 격자 규모로 분해되지 않는 아격자 규모의 운동은 일반적으로 관측, 통계, 경험 식 등을 활용하여 모수화된다. 그 중 아격자 규모의 강수 현상은 적운물리과정을 통해 모수화되며, 적운물리과정

은 아격자규모의 연직 운동과 대류에 의해 발생하는 적운이 주위 대기에 미치는 영향을 모수화한다.

모수화에서 복잡하거나 중요하지 않은 과정은 생략되거나 수학적 가정을 통해 단순화된다. 또한 모수화에 사용되는 많은 모수 값들은 경험적으로 설정됨에 따라 모수화는 불확실성을 포함하게 되며, 모델의 오차를 유발하는 주된 원인이 된다(van Lier-Walqui et al., 2012; Shutts and Pallares, 2014). 이에 수치 모델의 불확실성과 오차를 줄이고자 적운물리과정 모수화는 지속적으로 개선되어 왔다. 첫째로, 적운물리과정의 모수화 방법론을 보다 현실적인 방향으로 고도화

*Corresponding Author: Ji-Yeon Jang, Numerical Data Application Division, Numerical Modeling Center, KMA, 61 16-Gil Yeouidaebang-ro, Dongjak-gu, Seoul 07062, Korea.
Phone: +82-2-2181-0562, Fax: +82-2-833-0365
E-mail: jyjang415@gmail.com

하여 개선하였다. Ma and Tan (2009)은 Kain-Fritsch (1993) 질량 속 적운물리과정의 대류 발생 조건에 수분 비유 효과를 고려하여 열대저기압의 대류 강도와 강수 분포의 예측 성능을 개선시켰다. 그리고 Wang et al. (2016)은 Groenemeijer and Craig (2012)가 사용한 방법을 기반으로 한 Plant-Craig (PC) 확률론적 적운물리과정을 결정론적 적운물리과정(Zhang and McFarlane, 1995)과 결합하여 미국 국립 대기연구센터(National Center for Atmospheric Research, NCAR)의 CAM5 (Community Atmosphere Model version 5) 모델에 적용하였다. 이를 통해 강수 강도의 확률밀도함수를 개선하여 CAM5에서 이슬비 과대 모의를 감소시켜 강수예측성능을 개선하였다.

둘째로, 적운물리과정의 경험적, 근사적으로 추정된 모수를 자료동화 방법과 인공지능 기법을 활용하여 개선하였다. Li et al. (2018)은 앙상블 접합 자료동화 방법을 이용하여 접합대순환모형(Coupled General Circulation Model, CGCM)의 Relaxed Arakawa-Schubert 적운물리과정(Moorthi and Suarez, 1992)을 최적화하였다. 적운물리과정의 흡기율, 대류 조절 시간 규모와 관련된 완화 계수, cloud work function의 임계 비율, 깊은 대류와 얇은 대류 과정의 강수 효율에 영향을 미치는 모수에 대해 최적화하였다. 해양과 기후 모의에 대한 최적 적운물리과정 모수 값의 차이를 줄이는데 앙상블 접합 자료동화 방법이 효과적이었고 최적 모수는 대기, 해양의 예측 성능을 모두 개선하였다. Zou et al. (2014)은 MVFSA (multiple very fast simulated annealing) 방법을 이용하여 MIT-Emanuel (Emanuel, 1991; Emanuel and Zivkovic-Rothman, 1999) 적운물리과정을 최적화하였다. 대류 발생의 상대습도 임계값, 운저에서 상승하는 질량 속의 완화율, 구름 물에서 강수로 전환되는 임계값, 육지와 해양에서의 자동전환 규모 인자, 육지와 해양에서의 격자 내의 구름 양에 대한 상대습도 임계값을 최적화하였다. 이를 통해 강수의 공간적 분포, 일 강우 강도의 확률밀도함수를 개선하였다. Lee et al. (2006)은 유전알고리즘을 이용하여 적운물리과정의 대류 가용 잠재 에너지 감소율과 수치적 안정도 과정의 Asselin 필터 모수를 추정하였다. 이를 통해 2005년 한국의 집중호우 사례에 대해 강수 검증 지수인 ETS (Equivalent Threat Score)를 약 0.4에서 약 0.6으로 개선하였다. 그리고 Yu et al. (2013)은 마이크로 유전알고리즘을 이용하여 적운물리과정의 대류성 시간 규모와 대류과정에서 미세물리적 피드백을 제어하는 자동전환률을 최적화하였다. 이는 2002년 태풍 루사(Rusa)가 동반한 한반도 집중호우 사례에 대해서 강수예측성능 향상에 긍정적인 영향을 미쳤다.

현재 한국형 수치예보모델(Korean Integrated Model,

KIM)의 적운물리과정은 질량 속 방법인 Simplified Arakawa and Schubert (SAS)에 기반을 둔 KIAPS SAS (KSAS) 방법(Han et al., 2016, 2020; Kwon and Hong, 2017)이다. SAS는 Arakawa and Schubert (1974) 방법을 단순화 한 것으로 한 격자에 하나의 상승, 하강 운동만을 고려한 방법이다. Han and Hong (2018)은 그레이존 해상도 영역에서 Kwon and Hong (2017)이 제안한 격자 적응 SAS 방법이 강수예측성능에 미치는 영향을 살펴보았다. 격자 적응 SAS 방법을 적용하면 약한 강수에 대한 예측 성능이 높아지고 적용하지 않으면 강한 강수에 대한 예측 성능이 높아지는 것을 확인하여 격자 적응 SAS 방법의 적용 유무에 따른 계통 오차를 확인하였다. Han and Hong (2018)은 정량 강수 예보를 개선하기 위한 방법으로 앙상블 방법, 인공지능 기법을 이용한 후처리 등을 제안하였다.

이 연구에서는 인공지능 기법의 일종인 유전알고리즘을 이용하여 KSAS 방법에서 불확실성을 내포한 모수를 최적화함으로써 여름철 강수예측성능을 개선하고자 한다. 유전알고리즘은 유전적 계승과 생존 경쟁이라는 자연현상을 알고리즘화 한 모델로 불확실성과 비연속성, 비선형적 관계를 고려하여 최적의 모수 조합을 탐색하는 장점을 가졌다(Holland, 1975; Goldberg, 1989). 이때, 기존 선행 연구들(Lee et al., 2006 ; Hong et al., 2014)에서 사용한 유전알고리즘의 계산 비용 측면을 개선하여 수치예보모델에 더 적합한 마이크로 유전알고리즘을 이용하고자 한다.

2장에서는 이 연구에서 사용한 모델과 적운물리과정 모수, 모수 최적화 방법인 마이크로 유전알고리즘에 대해 설명한다. 3장에서는 모수 최적화 과정과 모수 최적화에 따른 강수예측성능에 대한 민감도 실험 결과, 한달 간의 강수 모의를 통한 최적 모수의 영향을 살펴보았다. 마지막으로 4장에서는 요약 및 결론에 대해 기술한다.

2. 자료 및 실험 설계

2.1 모델 설명 및 적운물리과정 모수

이 연구에서 사용한 모델은 WRF (Weather Research and Forecasting Model) 3.9.1.1버전이다. 미세물리과정은 WRF Double-Moment 7-class (WDM7; Bae et al., 2019), 단파와 장파 복사과정은 RRTMG-K (Beak, 2017), 대기경계층 물리과정은 Shin-Hong 방법(Shin and Hong, 2013, 2015), 적운물리과정은 KSAS 방법(Han et al., 2016, 2020; Kwon and Hong, 2017)을 적용하였다. 설정한 모델의 영역은 한반도를 중심으로 한 5 km 해상도로 격자 수는 234×282 이다. 적운물리과정에서 5 km 해상도는 그레이존에 해당하기 때문

에 격자 적응(Kwon and Hong, 2017)을 고려하고 있는 KSAS 방법을 적용하였다.

KSAS 방법은 질량 속 방법인 SAS를 기반으로 적운형 구름이 대기의 비단열 가열, 건조 효과, 수분 유입 및 유출 과정 등을 통해 대규모 운동에 미치는 영향을 모수화 한다. SAS의 원형인 Arakawa and Schubert (1974) 방안은 다양한 규모의 적운형 구름들과 대규모 운동 사이의 상호 작용을 바탕으로 개발되었고 한 격자에 여러 개의 구름 유형을 고려한다. 이후 Grell (1993)은 한 격자에 하나의 상승, 하강 운동만을 고려하도록 단순화하여 SAS를 제안하였다. 적운물리과정은 일반적으로 그레이존 해상도에서 부분적으로 분해되며 그 정도가 역학 과정의 종류, 사용하는 적운물리과정의 유형에 따라 다르기 때문에 그레이존에서는 모수화의 사용 및 적용 유무 결정에 주의가 필요하다 (Hong and Dudhia, 2012). 이에 Kwon and Hong (2017)은 SAS를 그레이존 해상도에서 사용할 수 있도록 적운 대류 구름 비율을 수평해상도에 대한 함수로 정의하여 KSAS에 반영하였다. KSAS 방법은 SAS를 기반으로 격자 적응을 고려할 뿐만 아니라 대류 발생 조건, 흡기율, 대류종결, 대류미세물리(Han et al., 2016, 2020) 등이 수정되었다.

이 연구에서는 KSAS 방법에서 강수예측성능에 민감하게 영향을 미치면서 물리적으로 단일 모수 값으로 설정하는데 있어 불확실성 및 자유도가 큰 모수 중 세 가지 모수를 선정하여 강수예측성능을 향상시키도록 모수 값을 최적화하였다. 각각의 모수는 KSAS 방법의 대류 발생, 구름 모형, 대류종결과정에 포함된다. KSAS 방법은 이 연구에서 고려한 모수 외에도 경험적으로 설정된 모수들을 포함하며 이러한 모수들의 강수예측성능 민감도는 모델의 특성 및 오차 등에 의존한다. 이에 선행 연구들에서는 모델의 오차 특성 및 모델에서의 각각의 모수 민감도 등을 고려하여 최적화할 물리과정 모수를 경험적으로 선정하여 최적화하고 있다(Lee et al., 2006; Yu et al., 2013; Zou et al., 2014). 향후에는 적운물리과정 모수 뿐 아니라 타 물리과정의 서로 다른 경험적 모수 사이의 상호 작용 및 균형을 고려하여 보다 종합적으로 물리과정 내 모수를 최적화하는 것이 필요하다.

KSAS 방법은 대류가 발생하기 위한 조건으로 5가지 조건을 사용한다. 그 중 첫 번째 조건은 식(1)과 같이 상승 시작 고도와 자유대류고도의 기압 차이가 임계값(Δp_{cr})보다 작아야 하는 것이다(Han et al., 2020). 여기서 임계값은 식(2)로 계산된다.

$$P_{parcel_start} - P_{LFC} < thre \times \Delta p_{cr} \quad (1)$$

$$\Delta p_{cr} = \left(p_{min} + \frac{P_{max} - P_{min}}{2} \right) RH_{low} \times (1 - \sigma) \quad (2)$$

여기에서 P_{max} 와 p_{min} 은 각각 240 hPa, 120 hPa이고 RH_{low} 은 하층 상대습도를 의미한다. σ 는 적운 대류 구름 비율로 수평해상도에 따라 값이 변하고 이 연구에서 실험한 5 km 수평 해상도에서는 0.5이다. 이 연구에서는 대류 발생 조건 중 첫 번째 조건의 임계값에 모수(이하 $thre$)를 곱하여 임계값에 따른 강수예측성능 민감도를 살펴보고 최적화하였다.

KSAS의 대류종결과정은 적운물리과정에 의해 안정해지는 정도와 대규모 대기 운동 과정에 의해 불안정해지는 정도가 균형을 이루고 있다고 가정하는 Arakawa and Schubert (1974)의 준평형가정을 기반으로 한다.

대규모 불안정성은 $\left(\frac{dA}{dt} \right)_{LS} = A / \tau_c$ 를 기반으로 Bechtold et al. (2014)에서 경계층-대류 과정의 평형 이론에 따라 경계층의 강제력 효과를 고려한 식(3)으로 계산된다(Han et al., 2020).

$$\left(\frac{dA}{dt} \right)_{LS} = \frac{A - apbl \times A_{BL}}{\tau_c} \quad (3)$$

$$A_{BL} = \max \left(g \Delta h_{BL} \frac{\tau_{BL}}{\Delta t}, 0 \right) \quad (4)$$

$$\tau_c = \frac{H}{\bar{w}_u} \quad (5)$$

$$\tau_{BL} = \tau_c \quad \text{over land} \quad (6a)$$

$$\tau_{BL} = \frac{z_b}{\bar{u}_{BL}} \quad \text{over water} \quad (6b)$$

여기에서 A는 cloud work function, LS는 대규모 과정, BL은 대기경계층 과정, τ_c 는 대류 조절 시간 규모, g 는 중력가속도, Δh_{BL} 은 지금 시간과 이전 시간의 경계층 높이 차이, τ_{BL} 은 경계층 시간 규모, Δt 는 모델 적분 시간 간격, H는 대류의 깊이, \bar{w}_u 는 자유대류고도와 부력이 0이되는 고도 사이의 평균 상승기류 연직 속도이고 \bar{u}_{BL} 은 상승 시작 고도와 운저 고도 사이의 평균 수평바람속도를 의미한다. 이 연구에서는 경계층 강제력에 모수(이하 $apbl$)를 곱하여 적용 비율에 대한 강수예측성능의 민감도를 확인하고 최적화하였다.

KSAS에서는 응결물을 대류성 강수 또는 격자 규모의 구름물로 전환한다. 그 중 응결물이 대류성 강수로 전환되는 비율을 결정하는 모수(C_0)는 구름분해모델 결과를 기반으로 수정되었으며 식(7a)-(7b)와 같이 계산된다(Han et al., 2016).

$$C_0(z) = a \exp \{ \beta [T(z) - T_0] \} \quad \text{for } T \leq T_0 \quad (7a)$$

$$C_0(z) = a \quad \text{for } T > T_0 \quad (7b)$$

여기에서 a 는 $2.0 \times 10^{-3} \text{ m}^{-1}$ 으로 일정한 값이고 β 는

0.07°C⁻¹로 지수감소율이다. 그리고 T_0 는 어느점온도로 0°C를 의미한다. C_0 는 어느점 이상에서는 일정한 값을 가지고 어느점 이하에서는 온도에 따라 지수함수적으로 감소한다. 이 연구에서는 구름분해모델 결과를 기반으로 결정된 β (이하 beta)에 따른 강수예측 성능 민감도를 살펴보고 최적화하였다.

2.2 마이크로 유전알고리즘을 이용한 모수 최적화 실험 설계

2.2.1 마이크로 유전알고리즘

마이크로 유전알고리즘(micro genetic algorithm, 이하 micro-GA)은 고전적인 유전알고리즘(Holland, 1975)을 개선한 최적화 기법의 일종으로 자연세계의 생물 진화 과정과 다윈의 적자생존 원리를 기본 개념으로 하여 알고리즘화한 것이다. Micro-GA는 Fig. 1의 흐름도로 작동되며 micro-GA의 연산자는 초기화, 적합도 평가, 선택, 교배, 재생산 등이다. 초기화 과정에서는 주어진 문제에 대해 유전적 형식을 정의하고, 세대별 개체들의 수렴여부를 판단한 뒤 최적화 목적에 기반한 적합도 평가를 수행한다. 적합도 평가 결과에 따라 유전자들을 선택하고 교배 과정을 통해 유전자들을 서로 교체하고 재생산 과정에서 부모 세대의 유전자의 일부를 선택하여 새로운 세대의 해를 만들어낸다. 이 과정에서 적합도가 높은, 우수한 해들을 선택하여 교배하면 새로운 해는 우수한 해들이 가지는 특성을 이어받을 가능성이 높아진다. 적합도 평가, 선택, 교배, 재생산 과정은 수렴 조건이 만족할 때까지 반복적으로 수행하게 된다. Micro-GA는 유전알고리즘의 돌연변이 연산자가 없는 대신에 재시작을 반복하는 접근방법을 기초로 매우 작은 수의 개체로도 다양한 해 집단 탐색이 가능하기 때문에 계산 비용이 적은 장점이 있다(Krishnakumar, 1989).

Micro-GA를 이용하여 최적화할 때, 개체 수와 세대 수를 지정하여 개체들을 유지하면서 세대를 거쳐 진화한다. 여기에서 개체 수는 일반적으로 2의 승수로 결정하는데 이 연구의 추정 모수는 세 가지이기 때문에 세대 당 개체 수는 8로 하였고 세대 수는 총 30세대를 수행하였다. Micro-GA를 이용하여 추정하고자 한 모수는 Table 1에 정리하였다. Table 1의 최솟값과 최댓값을 이용하여 각 모수에 대해 기본 값을 포함하

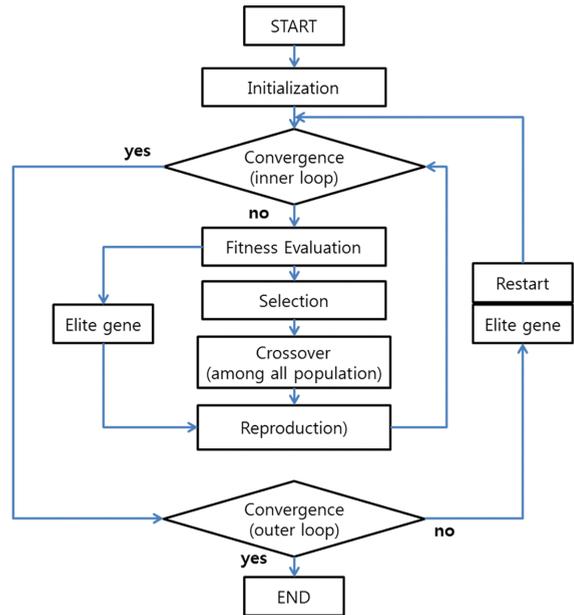


Fig. 1. Flow chart of micro-Genetic Algorithm (micro-GA) (Lee et al., 2016).

는 범위 내에서 최적 모수를 탐색하도록 하였다. 여기서 최솟값과 최댓값은 각 모수에 대한 사전 민감도 실험을 통해 경험적으로 정하였다. 교배 방법은 균등 교배를 사용하고 교배율은 0.5로 설정하였다. 이는 부모 세대 사이에 고정된 혼합 비율을 사용하는 방법이고 0.5의 교배율은 자손 세대의 유전자는 부모 세대의 절반을 이어 받게 된다는 의미이다.

2.2.2 사례 선정 및 적합도 함수

이 연구에서는 여름철 강수예측성능을 개선하는 것을 목표로 한다. Han and Hong (2018)은 격자 적응 SAS 적용 시 약한 강수의 예측 성능은 높지만 강한 강수의 예측 성능이 낮음을 확인하였다. 2018년 여름철 한반도에서 발생한 세 가지 집중호우 사례를 선정하여 강한 강수의 예측 성능을 개선하고자 하였다. 첫 번째는 6월 27일 장마 전선에 의해 남부지방을 중심으로 시간당 최고 70 mm 이상의 강수가 발생한 사례

Table 1. Summary of optimized parameters. Min and Max are the ranges used in the optimization process. Default is the parameter used in the KIM.

Parameter	Min/Default/Max	Optimized parameter
Trigger Threshold (thre)	0.0/1.0/1.2	0.391
Boundary layer forcing (apbl)	0.0/1.0/1.2	0.029
Exponential decaying rate (beta)	0.02/0.07/0.1	0.066

이다. 두 번째는 6월 30일 장마전선으로 인해 남부지방에서 강수가 시작되어 전국적으로 강수가 발생하고 시간당 최고 40 mm 이상의 강수가 발생한 사례이다. 그리고 세 번째는 7월 1일 두 번째 사례와 연속하여 중부지방을 중심으로 강수가 발생하고 점점 강수가 소강되면서 국지적인 강수가 발생한 사례이다.

Micro-GA가 강수예측성능이 개선되는 방향으로 모수를 최적화하기 위해 강수 검증 지수인 CSI (Critical Successive Index)와 BIAS를 기반으로 적합도함수를 구성하였다. CSI와 BIAS는 식(8), (9)로 정의된다.

$$CSI = \frac{hits}{hits + misses + false} \tag{8}$$

$$BIAS = \frac{hits + false}{hits + misses} \tag{9}$$

여기서 hits는 강수가 발생하였을 때 강수를 예측한 경우를 의미하고 misses는 강수가 발생하였을 때 강수를 예측하지 못한 경우, false는 강수가 발생하지 않았을 때 강수를 예측한 경우를 의미한다. 따라서 BIAS는 1 미만은 과소 모의, 1 초과는 과대 모의를 의미하며 CSI는 1에 가까울수록 완벽한 예보를 의미한다.

Micro-GA를 통해 추정된 모수로 각 사례별 24시간 강수 예측을 수행하고, 예측된 1시간 누적 강수에 대해 기상청 자동기상관측망(Automatic Weather Station, AWS) 관측자료를 이용하여 예측 성능을 검증하였다. 각 사례별 초기 시간은 2018년 6월 27일 1200 UTC, 2018년 6월 30일 1200 UTC, 2018년 7월 1일 0600 UTC이다.

적합도 함수는 세 사례를 모두 포함하도록 Lee et al. (2016)에서와 같이 식(10)로 정의하였다.

$$FITNESS = \sum_{j=1}^3 \sum_{i=1}^{16} \left(\frac{2}{2(|1 - BIAS_i| + 1)} + CSI_i \right) \tag{10}$$

여기서, i 는 강수 임계값(mm)을 나타내는 것으로 0.5 mm부터 70 mm까지 총 16개의 값이고, j 는 사례를 의미한다. 적합도가 높은 값을 가질수록 강수예측성능이 향상됨을 의미한다.

3. 결 과

3.1 마이크로 유전알고리즘을 이용한 모수 최적화 과정

Micro-GA를 이용한 적운물리과정 모수 최적화 과정의 적합도 변화를 살펴보았다. Figure 2는 micro-GA가 30세대까지 수행되는 동안 세대에 따른 적합도 변화를 나타낸 것이다. Figure 2에 최소, 평균, 최대 적합도와 적운물리과정의 기본 값을 적용했을 때의 적

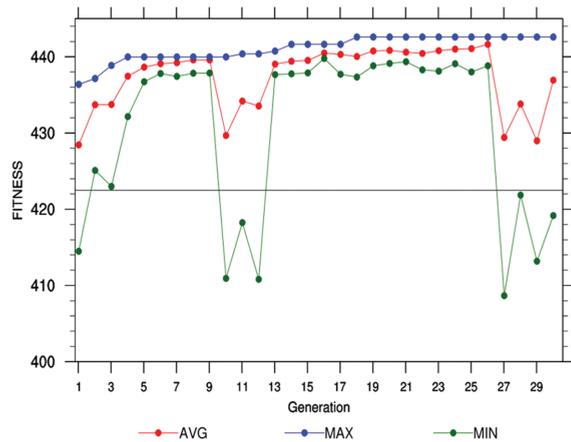


Fig. 2. The fitness for generations during the processes of optimization. The red, blue, and green lines indicate the average, maximum, and minimum value of fitness, respectively. The black line indicates the fitness value of CNTL.

합도를 나타냈다. 30세대까지 수행되는 동안 계산되는 적합도의 수렴 및 발산 여부를 살펴보았을 때, 10, 27세대에 재 시작이 있었고 18세대에 적합도가 가장 높은 모수 값이 산출되었다. 최대 적합도는 442.59로 기본 모수를 이용했을 때의 적합도인 422.50 보다 높았고 1세대의 최대 적합도도 기본 모수를 이용했을 때의 적합도 보다 높았다. 적합도가 가장 높았을 때의 모수, 즉 최적 모수로 산출된 값은 Table 1에서처럼 *thre*와 *apbl*은 기본 값보다 작은 0.391, 0.029로 추정되었고 *beta*는 기본값과 유사한 0.066로 추정되었다.

모수 최적화에 사용한 세 가지 모수에 대한 적합도 분포를 Fig. 3에 나타내었다. 세 가지 모수 사이의 강수예측성능에 대한 민감도 비교를 위해 적합도에 대한 상대 분포를 나타내었다. Figure 3a는 *thre*와 *apbl*, Fig. 3b는 *thre*와 *beta*, 그리고 Fig. 3c는 *apbl*과 *beta*의 적합도에 대한 상대 분포를 나타내고 기본 값은 검은 실선으로 표현하였다.

Figure 3a에서 *thre*는 기본 값인 1.0 보다 작은 약 0.3에서 0.5 사이에 적합도가 높은 것을 알 수 있고 *apbl*은 기본 값인 1.0 보다 작을수록 적합도가 높아지는 것을 알 수 있다. Figure 3b에서 *thre*는 Fig. 3a에서와 마찬가지로 약 0.3에서 0.5 사이, 특히 약 0.4에서 적합도가 뚜렷하게 높은 것을 볼 수 있다. *Beta*는 적합도가 산발적으로 분포되어 있는 것으로 보아 *thre*보다 강수예측성능에 대한 민감도가 작은 것으로 보인다. Figure 3c에서 *apbl*은 Fig. 3a와 마찬가지로 약 0.1에서 적합도가 높은 것을 알 수 있고 *beta*는 Fig. 3b와 마찬가지로 적합도가 산발적으로 분포되어 세 가지 모수 중 강수예측성능에 대한 민감도가 가장 낮

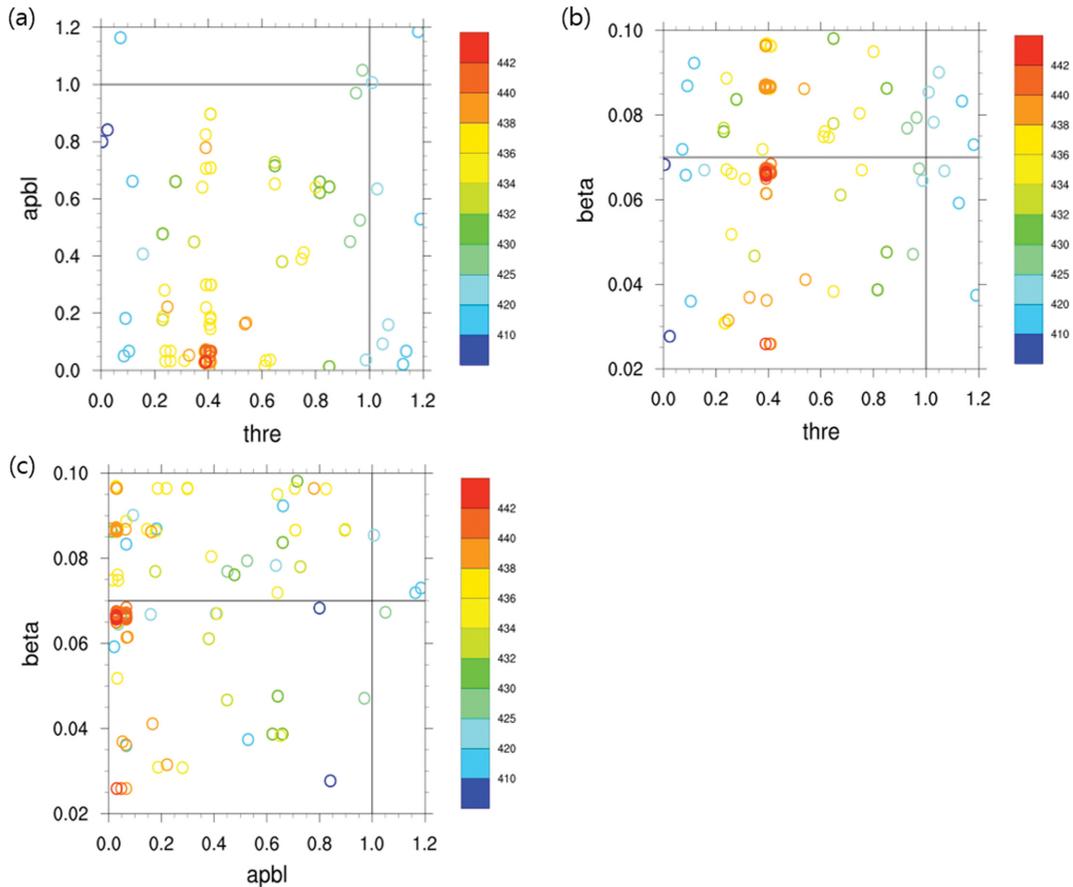


Fig. 3. The distribution of fitness according to (a) thre and apbl, (b) thre and beta, and (c) apbl and beta.

은 것을 알 수 있다.

3.2 최적 모수 별 강수 예측 민감도 실험

최적화한 모수에 따른 강수예측성능에 대한 민감도를 확인하기 위해 Table 2와 같이 여섯 가지의 실험을 추가로 수행하였다. Figure 4는 최적화에 적용한 세 가지 사례에 대해 기본 값을 사용한 실험(CNTL)과 적합

Table 2. Summary of sensitivity experiments.

Experiment	Description
CNTL	Use default parameter
GA_BEST	Use optimized parameter
EXP1	Use optimized parameter (thre)
EXP2	Use optimized parameter (apbl)
EXP3	Use optimized parameter (beta)
EXP4	Use optimized parameter (thre, apbl)
EXP5	Use optimized parameter (thre, beta)
EXP6	Use optimized parameter (apbl, beta)

도가 가장 높은 최적 모수를 사용한 실험(GA_BEST)을 추가 민감도 실험들과 6시간 예보에 대한 강수예측성능을 비교한 것이다. Figure 4a는 2018년 6월 27일 1200 UTC 사례, Fig. 4b는 2018년 6월 30일 1200 UTC 사례, Fig. 4c는 2018년 7월 1일 0600 UTC 사례에 대한 강수예측성능을 성능 도표(performance diagram)로 나타내었다. 성능 도표는 POD (Probability of Detection), SR (Success Ratio), BIAS, CSI의 관계를 이용하여 예측 성능을 도표로 나타낸 것으로 오른쪽 상단에 위치할수록 예측 성능이 높은 것을 의미한다(Roebber, 2009). 여기에서 POD는 강수가 발생한 경우 예보가 적중한 경우의 비율이며 SR은 강수를 예보한 경우 실제로 강수가 발생하여 예보가 적중한 경우의 비율이다. POD와 SR은 모두 1에 가까울수록 예측 성능이 높은 것을 의미한다. Figure 4a에서 CNTL, GA_BEST와 추가 민감도 실험의 예측 성능을 비교해보면 GA_BEST가 POD, SR, CSI가 가장 높고 BIAS가 1에 가까워 예측 성능이 가장 높았다. 최적 thre를

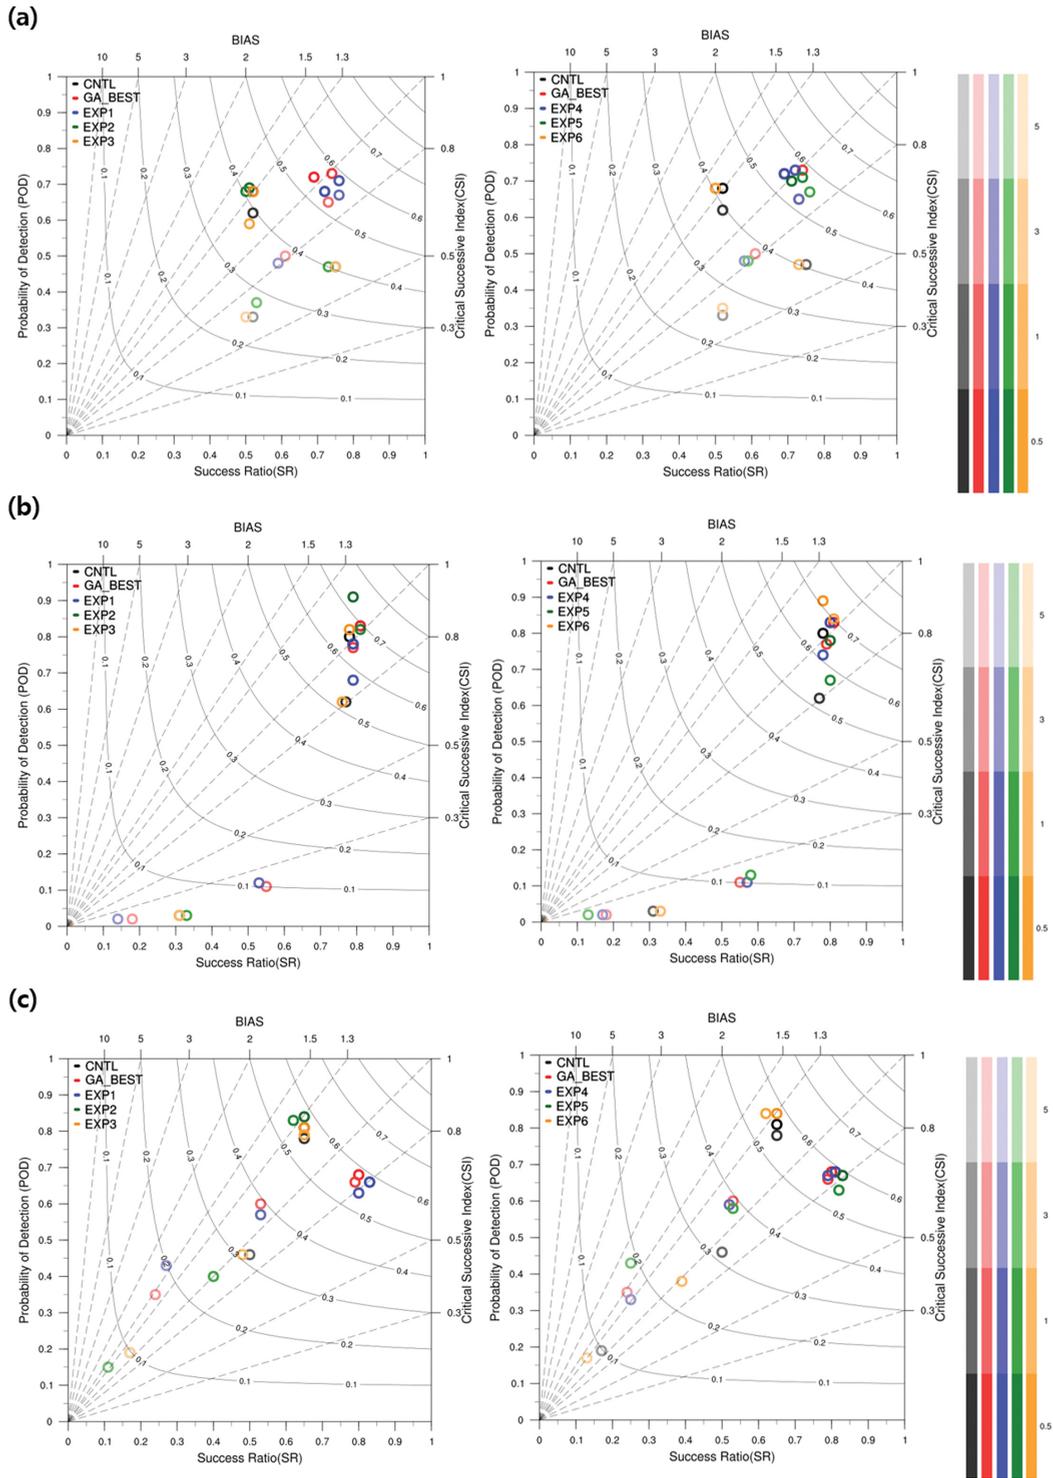


Fig. 4. Performance Diagram summarizing the SR, POD, BIAS, and CSI. Dashed lines represent BIAS score, solid contours are CSI. Markers indicate precipitation verification for CNTL, GA_BEST, EXP1, EXP2, EXP3, EXP4, EXP5, and EXP6 at 6 hour forecast (a) 1200 UTC 27 June 2018 case (b) 1200 UTC 30 June 2018 case and (c) 0600 UTC 1 July 2018 case.

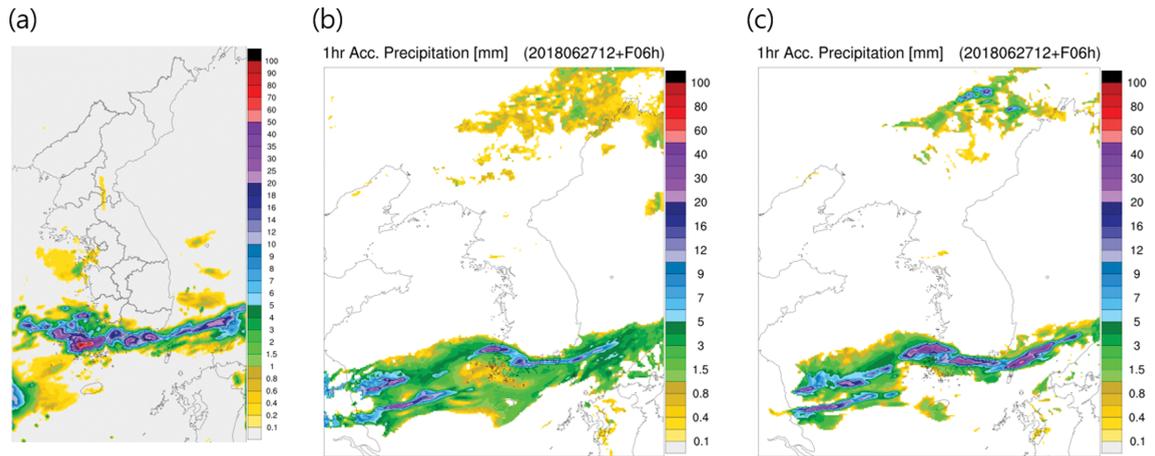


Fig. 5. The 1hr accumulated precipitation of (a) Reanalysis, and 6 hour forecasted by (b) CNTL, and (c) GA_BEST at 1200 UTC 27 June 2018.

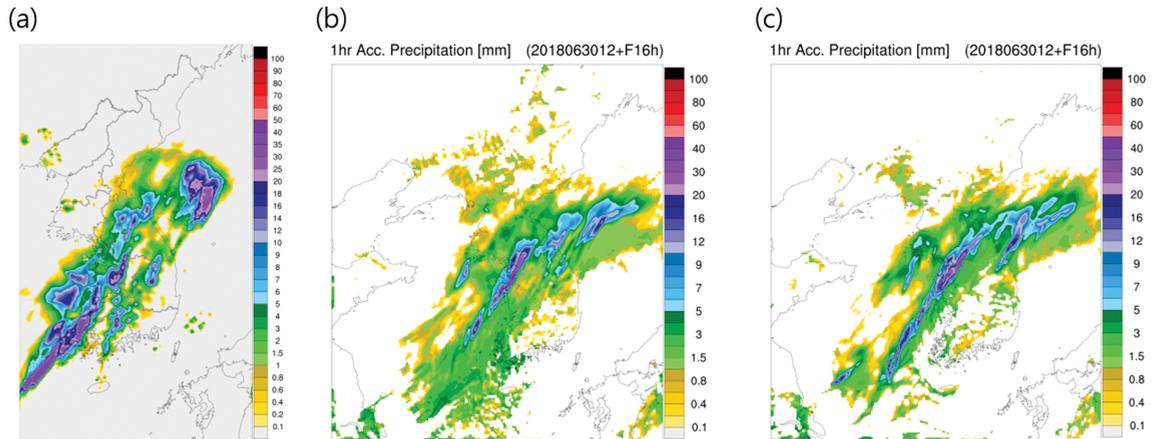


Fig. 6. Same as Fig. 5 but for 16 hour forecasted at 1200 UTC 30 June 2018.

이용한 EXP1, EXP4, EXP5는 GA_BEST와 유사한 예측 성능을 보였고, 최적 thre를 적용하지 않은 EXP2, EXP3, EXP6은 CNTL과 유사한 성능을 보였다. Figure 4b에서 모든 실험의 SR은 유사하였으나 최적 apbl을 사용한 EXP2, EXP6이 0.5 mm 강수에 대해 POD와 CSI가 가장 높았지만 BIAS가 1 이상으로 과대 모의하는 경향을 보였다. Figure 4a와 마찬가지로 최적 thre를 이용한 EXP1, EXP4, EXP5는 GA_BEST와 유사한 예측 성능을 보였고 GA_BEST가 SR, POD, CSI가 가장 높고 BIAS도 1에 가장 가까워 예측 성능이 가장 높았다. Figure 4c는 최적 thre를 사용한 GA_BEST, EXP1, EXP4, EXP5는 0.5 mm, 1 mm 강수 임계값의 예측 성능이 BIAS가 1보다 작아 과소 모의하는 경향을 보이고 SR이 높았다. 반면, 최적 thre를 사용하지

않은 CNTL, EXP2, EXP3, EXP6은 0.5 mm, 1 mm 강수 임계값의 예측 성능이 BIAS가 1 이상으로 과대 모의하는 경향을 보이고 POD가 높았다. Thre의 최적 값이 기본 값보다 감소하면서 대류가 발생하기 위한 조건이 강화되어 대류가 억제되는 효과로 인해 대류성 강수에서 발생하는 약한 강수가 감소하고 비대류성 강수에서 발생하는 강한 강수가 증가하였다. 이로 인해 CNTL보다 BIAS는 1에 가까워지고 CSI는 높아진 것을 알 수 있다. 최적 apbl은 기본 값보다 감소하면서 대기경계층의 강제력 효과가 감소하고 대규모 불안정성이 증가하여 적운물리과정에 의해 안정해지는 정도가 증가하였다. 최적 apbl의 효과는 최적 thre를 적용한 실험보다 작았다. 최적 beta는 기본 값과 유사한 값으로 최적화되어 CNTL과의 차이가 미미했다.

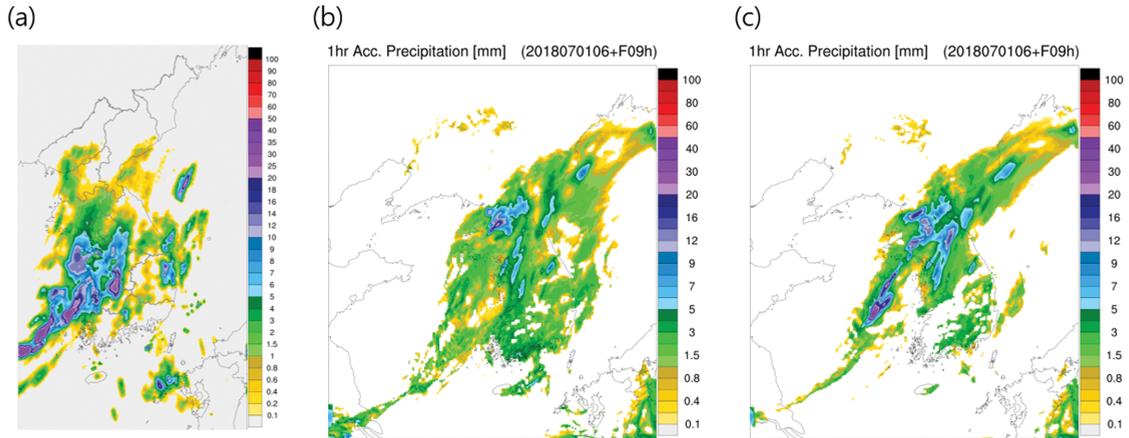


Fig. 7. Same as Fig. 5 but for 9 hour forecasted at 0600 UTC 1 July 2018.

3.3 최적 모수에 따른 강수예측성능 분석

이 연구에서 선정한 세 가지 강수 사례에 대해 CNTL과 GA_BEST에서 예측한 1시간 강수량과 한반도 강수재분석자료의 1시간 강수량을 비교하였다. 여기에서 사용한 한반도 강수재분석자료는 AWS와 1 km, 3 km 해상도의 레이더 반사도 자료를 이용해 합성강수자료로 생산한 후 후처리 과정을 거쳐 생산한 자료이고 1시간 누적 강수량에 대해 한반도 중심으로 5 km 수평해상도를 가진 자료이다(Nam et al., 2012). Figures 5-7은 한반도 강수재분석자료와 CNTL, GA_BEST의 1시간 누적 강수량이고 Fig. 5는 2018년 6월 27일 1200 UTC 사례의 6시간 예측 결과, Fig. 6은 2018년 6월 30일 1200 UTC 사례의 16시간 예측 결과, Fig. 7은 2018년 7월 1일 0600 UTC의 9시간 예측결과이다. Figure 5의 CNTL은 약한 강수가 넓게 분포하여 강수재분석자료보다 강수 구역이 넓고 전라남도 지역에서 발생한 강수에 대해 과소 모의한다. 반면 GA_BEST는 CNTL에서 발생한 시간당 3 mm 이하의 약한 강수가 감소하고 강수재분석자료와 유사한 강수 영역이 모의되었다. 또한 전라남도 지역에 발생한 강수를 CNTL보다 관측과 더 유사하게 모의하였다. Figure 6은 강한 강수의 위치가 관측보다 실험들이 모두 북쪽에 위치하고 있다. CNTL은 20 mm 이상의 강한 강수 구역 주변에 5 mm 이하의 약한 강수가 넓게 분포하고 GA_BEST는 CNTL보다 약한 강수가 감소하고 강한 강수는 증가하였다. GA_BEST의 서해안 강수가 관측과 유사하게 모의되었다. Figure 7의 CNTL은 우리나라 전역에 5 mm 이하의 약한 강수가 넓게 과대하게 모의되는 것을 볼 수 있다. GA_BEST는 CNTL보다 약한 강수가 감소하고 8 mm 이상의 강수가 증가하였다. 또한 우리나라 서쪽의 강수 구역에 대해 관측과 유사하게 모의하였다. Figures 5-7의 세 가지 사

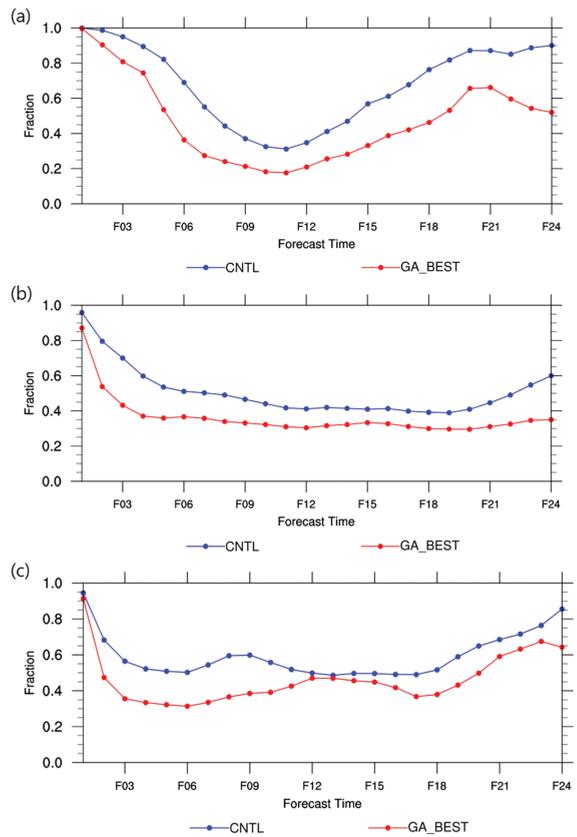


Fig. 8. Convective rain ratio of CNTL (blue line) and GA_BEST (red line) (a) 1200 UTC 27 June 2018 case (b) 1200 UTC 30 June 2018 case and (c) 0600 UTC 1 July 2018 case.

례에서 모두 GA_BEST가 CNTL 보다 약한 강수가 감소하고 강한 강수가 증가하여 관측과 더 유사해 지

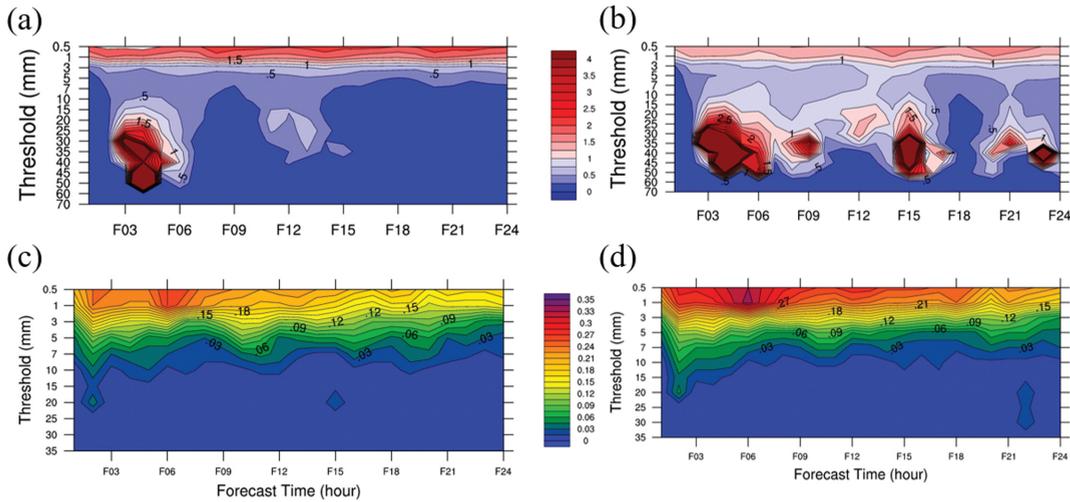


Fig. 9. The results of monthly verification. Left Panels are CNTL and Right panels are GA_BEST. (a) (b) BIAS, (c) (d) CSI.

는 것을 확인하였다.

Figure 8은 24시간 예측 자료에 대한 도메인 전체 영역에 대한 대류 강수 비율을 나타낸 것이다. Figure 8a는 2018년 6월 27일 1200 UTC 사례이고 Fig. 8b는 2018년 6월 30일 1200 UTC 사례, Fig. 8c는 2018년 7월 1일 0600 UTC 사례이다. Figure 8의 대류 강수 비율은 세 가지 사례 모두 CNTL보다 GA_BEST에서 감소한 것을 볼 수 있다. 이는 GA_BEST에서 대류 발생 임계값 조절 모수가 감소함에 따라 대류가 발생 되는 경우가 줄어들어 대류가 억제되었기 때문이다.

3.4 2018년 7월 적용 결과

기본 모수와 최적 모수를 이용하여 2018년 7월 한 달 동안 0000 UTC 부터 6시간 간격의 초기 자료를 이용하여 24시간 강수를 예측하고 강수예측성능을 비교하였다. Figure 9은 CNTL과 GA_BEST의 BIAS, CSI를 비교한 것이다. CNTL은 시간당 1 mm 이하의 약한 강수를 과대 모의하는 경향을 보이며 6시간 예측까지 시간당 10 mm 이상의 강한 강수를 모의하지만 15시간 예측 이후에는 강한 강수를 모의하지 못하는 것을 볼 수 있다. 반면 GA_BEST는 시간당 30 mm 이상의 강한 강수를 과대 모의 하는 경향이 있지만 CNTL 보다 시간당 1 mm 이하의 약한 강수에 대해 과대 모의 하는 경향이 감소했다. CSI는 GA_BEST가 CNTL보다 값이 높아져 전반적으로 GA_BEST의 강수예측성능이 CNTL보다 향상됨을 알 수 있다.

4. 요약 및 결론

이 연구에서는 micro-GA를 이용하여 적운물리과정

의 세 모수를 최적화하고 강수예측성능에 대한 민감도를 살펴보았다. 대류 발생 조건에 사용되는 임계값 조절 모수(thre), 대류종결과정의 경계층 강제력 효과 모수(apbl), 응결물이 대류성 강수로의 전환 조절 모수(beta)를 선택하여, 2018년 여름철 한반도에 발생한 세 가지 집중호우 사례에 대해 강수예측성능을 개선하도록 모수를 최적화하였다. Micro-GA를 18세대 수행하였을 때 최대 적합도의 모수가 추정되었고 thre와 apbl은 기본 값보다 작게, beta는 기본 값과 유사하게 최적화되었다. 추가적인 민감도 실험을 통해 최적화된 세 모수 중 강수예측성능에 thre가 가장 민감하게 반응하는 것을 알 수 있었으며 최적 모수는 대류 발생을 억제하여 대류성 강수에 대한 과대 모의 경향이 감소하고 비대류성 강수가 증가하여 강수예측성능이 향상됨을 보였다. 또한 2018년 7월 한 달 간의 예측 실험 수행 결과를 검증했을 때에도 사례에서 나타난 강수예측성능 개선 효과가 일관되게 나타나는 것을 확인하였다. 이는 이 연구에서 최적화한 모수가 우리나라 여름철 강수예측성능에 긍정적으로 영향을 미치는 것을 의미한다.

이 연구에서 마이크로 유전알고리즘을 통해 도출된 모수의 최적 값은 최적화 실험에 적용된 사례 및 계절과 모델의 오차 특성에 따라 다소 다른 값으로도 출될 수 있다. 그러나 이러한 경험 모수들이 모수화 과정에서 단일 상수 값으로 근사되거나 불확실성을 가지고 설정되었다는 모수화의 기본적인 한계를 고려할 때 물리적으로 타당한 범위 안에서 모수 값의 유연한 설정은 가능하다. 향후에는 보다 다양한 사례에서 적운물리과정뿐만 아니라 타 물리과정의 서로 다른 경험적 모수 사이의 상호 작용과 균형을 고려하여

보다 종합적으로 모수를 최적화하는 것이 필요하며, 궁극적으로는 물리 모수를 검증할 수 있는 관측자료 등을 활용하여 보다 물리적으로 타당하게 모수 값을 결정하는 것이 필요하다.

감사의 글

이 논문의 개선을 위해 좋은 의견을 제시해 주신 심사위원께 감사를 드립니다. 이 연구는 수치모델링 센터 ‘수치예보 및 자료응용 기술개발(KMA2018-00721)’ 과제의 일환으로 수행되었습니다.

REFERENCES

- Arakawa, A., and W. H. Schubert, 1974: Interaction of a cumulus cloud ensemble with the large-scale environment, Part I. *J. Atmos. Sci.*, **31**, 674-701.
- Bechtold, P., N. Semane, P. Lepez, J.-P. Chaboureau, A. Beljaars, and N. Bormann, 2014: Representing equilibrium and nonequilibrium convection in large-scale models. *J. Atmos. Sci.*, **71**, 734-753, doi:10.1175/JAS-D-13-0163.1.
- Bae, S. Y., S.-Y. Hong, and W.-K. Tao, 2019: Development of a single-moment cloud microphysics scheme with prognostic hail for the weather research and forecasting (WRF) model. *Asia-Pac. J. Atmos. Sci.*, **55**, 233-245, doi:10.1007/s13143-018-0066-3.
- Beak, S., 2017: A revised radiation package of G-packed McICA and two-stream approximation: Performance evaluation in a global weather forecasting model. *J. Adv. Model. Earth Syst.*, **9**, 1628-1640, doi:10.1002/2017MS000994.
- Emanuel, K. A., 1991: A scheme for representing cumulus convection in large-scale models. *J. Atmos. Sci.*, **48**, 2313-2329.
- _____, and M. Zivkovic-Rothman, 1999: Development and evaluation of a convection scheme for use in climate models. *J. Atmos. Sci.*, **56**, 1766-1782.
- Goldberg, D. E., 1989: *Genetic algorithms in search, optimization and machine learning*. Addison-Wesley Professional, 432 pp.
- Grell, G. A., 1993: Prognostic evaluation of assumptions used by cumulus parameterizations. *Mon. Wea. Rev.*, **121**, 764-787.
- Groenemeijer, P., and G. C. Craig, 2012: Ensemble forecasting with a stochastic convective parametrization based on equilibrium statistics. *Atmos. Chem. Phys.*, **12**, 4555-4565, doi:10.5194/acp-12-4555-2012.
- Han, J.-Y., and S. Y. Hong, 2018: Precipitation forecast experiments using the weather research and forecasting (WRF) model at gray-zone resolutions. *Wea. Forecasting*, **33**, 1605-1616, doi:10.1175/WAF-D-18-0026.1.
- _____, _____, K.-S. Sunny Lim, and J. Han, 2016: Sensitivity of a cumulus parameterization scheme to precipitation production representation and its impact on a heavy rain event over Korea. *Mon. Wea. Rev.*, **144**, 2125-2135, doi:10.1175/MWR-D-15-0255.1.
- _____, _____, and Y. C. Kwon, 2020: The performance of a revised simplified Arakawa-Schubert (SAS) convection scheme in the medium-range forecasts of the Korean Integrated Model (KIM). *Wea. Forecasting*, **35**, 1113-1128, doi:10.1175/WAF-D-19-0219.1.
- Holland, J. H., 1975: *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. University of Michigan Press, 183 pp.
- Hong, S., X. Yu, S. K. Park, Y.-S. Choi, and B. Myong, 2014: Assessing optimal set of implemented physical parameterization schemes in a multi-physics land surface model using genetic algorithm. *Geosci. Model Dev.*, **7**, 2517-2529, doi:10.5194/gmd-7-2517-2014.
- Hong, S. Y., and J. Dudhia, 2012: Next-generation numerical weather prediction: Bridging parameterization, explicit clouds, and large eddies. *Bull. Amer. Meteor. Soc.*, **93**, ES6-ES9, doi:10.1175/2011BAMS3224.1.
- Kain, J. S., and J. M. Fritsch, 1993: Convective parameterization for mesoscale models: the Kain-Fritsch scheme. In K. A. Emanuel et al. Eds., *The Representation of Cumulus Convection in Numerical Models*. Amer. Meteor. Soc., 165-170.
- Krishnakumar, K., 1989: Micro-genetic Algorithms for Stationary and Non-stationary Function Optimization. *Proc. SPIE Intelligent Control and Adaptive System*, 1196, Philadelphia, PA, United States, SPIE, 289-296.
- Kwon, Y. C., and S.-Y. Hong, 2017: A mass-flux cumulus parameterization scheme across gray-zone resolutions. *Mon. Wea. Rev.*, **145**, 583-598, doi:10.1175/MWR-D-16-0034.1.
- Lee, Y. H., S. K. Park, and D.-E. Chang, 2006: Parameter estimation using the genetic algorithm and its impact on quantitative precipitation forecast. *Ann. Geophys.*, **24**, 3185-3189.
- _____, J.-E. Nam, and S. Joo, 2016: A optimization of Z-R relationship in the summer of 2014 using the micro-genetic algorithm. *Journal of Korean Institute of Intelligent Systems*, **26**, 1-8 (in Korean with English abstract).

- Li, S., and Coauthors, 2018: Estimating convection parameters in the GFDL CM2.1 Model using ensemble data assimilation. *J. Adv. Model. Earth Syst.*, **10**, 989-1010, doi:10.1002/2017MS001222.
- Ma, L.-M., and Z.-M. Tan, 2009: Improving the behavior of the cumulus parameterization for tropical cyclone prediction: Convection trigger. *Atmos. Res.*, **92**, 190-211.
- Moorthi, S. A., and M. J. Suarez, 1992: Relaxed Arakawa-Schubert. A parameterization of moist convection for general circulation models. *Mon. Wea. Rev.*, **120**, 978-1002.
- Nam, J. E., Y. H. Lee, J. C. Ha, and K. Y. Jung, 2012: Production of rainfall reanalysis data through development of synthetic precipitation production technique on the Korea peninsula. *Proc. The Spring Meeting of KMS*, Korean Meteorological Society, 136-137 (in Korean).
- Roebber, P. J., 2009: Visualizing multiple measures of forecast quality. *Wea. Forecasting*, **24**, 601-608.
- Shin, H. H., and S.-Y. Hong, 2013: Analysis of resolved and parameterized vertical transports in convective boundary layers at gray-zone resolutions. *J. Atmos. Sci.*, **70**, 3248-3261, doi:10.1175/JAS-D-12-0290.1.
- _____, and _____, 2015: Representation of the subgrid-scale turbulent transport in convective boundary layers at gray-zone resolutions. *Mon. Wea. Rev.*, **143**, 250-271, doi:10.1175/MWR-D-14-00116.1.
- Shutts, G., and A. C. Pallares, 2014: Assessing parameterization uncertainty associated with horizontal resolution in numerical weather prediction model. *Phil. Trans. R. Soc. A.*, **372**, 20130284, doi:10.1098/rsta.2013.0284.
- van Lier-Walqui, M., T. Vukicevic, and D. J. Posselt, 2012: Quantification of cloud microphysical parameterization uncertainty using radar reflectivity. *Mon. Wea. Rev.*, **140**, 3442-3466, doi:10.1175/MWR-D-11-00216.1.
- Wang, Y., G. J. Zhang, and G. C. Craig, 2016: Stochastic convective parameterization improving the simulation of tropical precipitation variability in the NCAR CAM5. *Geophys. Res. Lett.*, **43**, 6612-6619, doi:10.1002/2016GL069818.
- Yu, X., S. K. Park, Y. H. Lee, and Y. S. Choi, 2013: Quantitative precipitation forecast of a tropical cyclone through optimal parameter estimation in a convective parameterization. *SOLA*, **9**, 36-39, doi:10.2151/sola.2013-009.
- Zhang, G. J., and N. A. McFarlane, 1995: Sensitivity of climate simulations to the parameterization of cumulus convection in the Canadian climate centre general circulation model. *Atmos. Ocean*, **33**, 407-446.
- Zou, L., Y. Qian, T. Zhou, and B. Yang, 2014: Parameter tuning and calibration of RegCM3 with MIT-Emanuel cumulus parameterization scheme over CORDEX East Asia domain. *J. Climate*, **27**, 7687-7701, doi:10.1175/JCLI-D-14-00229.1.