

Article

위성고도자료와 유전자 알고리즘을 이용한 남한의 겨울철 기온의 1 km 격자형 계절예측자료 생산 기법 연구

이준리*, 안중배*†, 정명표**, 심교문**

*부산대학교 지구환경시스템학부, **농촌진흥청 국립농업과학원 농업환경부 기후변화생태과

A Study on the Method of Producing the 1 km Resolution Seasonal Prediction of Temperature Over South Korea for Boreal Winter Using Genetic Algorithm and Global Elevation Data Based on Remote Sensing

Joonlee Lee*, Joong-Bae Ahn*†, Myung-Pyo Jung**, and Kyo-Moon Shim**

*Division of Earth Environmental System, Pusan National University, Busan, Korea

**Climate Change and Agroecology Division, Department of Agricultural Environment, National Institute of Agricultural Science, Rural Development

Abstract : This study suggests a new method not only to produce the 1 km-resolution seasonal prediction but also to improve the seasonal prediction skill of temperature over South Korea. This method consists of four stages of experiments. The first stage, EXP1, is a low-resolution seasonal prediction of temperature obtained from Pusan National University Coupled General Circulation Model, and EXP2 is to produce 1 km-resolution seasonal prediction of temperature over South Korea by applying statistical downscaling to the results of EXP1. EXP3 is a seasonal prediction which considers the effect of temperature changes according to the altitude on the result of EXP2. Here, we use altitude information from ASTER GDEM, satellite observation. EXP4 is a bias corrected seasonal prediction using genetic algorithm in EXP3. EXP1 and EXP2 show poorer prediction skill than other experiments because the topographical characteristic of South Korea is not considered at all. Especially, the prediction skills of two experiments are lower at the high altitude observation site. On the other hand, EXP3 and EXP4 applying the high resolution elevation data based on remote sensing have higher prediction skill than other experiments by effectively reflecting the topographical characteristics such as temperature decrease as altitude increases. In addition, EXP4 reduced the systematic bias of seasonal prediction using genetic algorithm shows the superior performance for temporal variability such as temporal correlation, normalized standard deviation, hit rate and false alarm rate. It means that the method proposed in this study can produce high-resolution and high-quality seasonal prediction effectively.

Key Words : Remote sensing, Statistical downscaling, Seasonal prediction, CGCM, Genetic Algorithm, Temperature

Received August 25, 2017; Revised September 17, 2017; Accepted September 20, 2017; Published online October 17, 2017.

† Corresponding Author: Joong-Bae Ahn (jbahn@pusan.ac.kr)

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

요약: 본 연구에서는 남한영역에 대하여 1 km 고해상도의 계절예측 기온자료를 생산하고, 생산된 예측자료의 성능을 높이는 새로운 방법을 제안하였다. 이 새로운 방법은 총 4가지 단계의 실험으로 구성되어 있다. 첫 번째 단계인 EXP1은 PNU CGCM에서 생산된 저해상도 계절예측 기온자료이며, EXP2는 EXP1의 결과에 역거리 가중법을 적용하여 생산된 남한영역의 1 km 고해상도 계절예측 기온자료이다. EXP3는 EXP2의 결과에서 위성고도자료인 ASTER GDEM을 이용하여 고도에 따른 기온변화를 추정된 후 이를 적용한 계절예측 기온자료이다. 마지막으로 EXP4는 EXP3의 결과에 유전자 알고리즘을 적용하여 모형의 예측결과 내 존재하는 계통적 오차를 보정한 결과이다. EXP1과 EXP2는 남한의 지형적 특성이 전혀 고려되지 않아 다른 실험에 비해 낮은 예측성을 보였으며, 특히 고도가 높은 관측지점에서 두 실험의 예측 성능이 더욱 낮았다. 반면, 위성에서 관측된 고해상도 고도자료가 적용된 EXP3와 EXP4는 고도가 증가함에 따라 기온이 감소하는 특징 등 지형적 특성을 효과적으로 표현하면서 높은 예측성능을 보였다. 특히, 유전자 알고리즘으로 예측값의 계통적 오차가 감소된 EXP4는 다른 실험과 비교하여 시간상관성, 관측으로 정규화된 표준편차, 정답률, 오답률 등 시간에 따른 변동성에 대해서 가장 높은 예측성능을 보였다. 이는 본 연구에서 제안한 새로운 방법을 통해 고해상도 격자의 질 높은 실시간 계절예보 자료를 효과적으로 생산할 수 있음을 의미한다.

1. 서론

기후는 작물의 성장에 중요한 요소 중 하나로, 작물의 성장단계에 미치는 영향이 크다. 만약 작물의 생육에 적합한 기후조건이 충족되지 못할 경우 생육이 정지되거나 비정상적으로 성장할 수 있다. 따라서 기후변화는 작물의 성장뿐만 아니라 농업생산 및 농업생태의 변화에 큰 영향을 미치게 된다(Lee *et al.*, 2008). 특히, 작물 성장에 영향을 미치는 기후요소들 중 기온의 변화는 작물의 성장에 직접적으로 영향을 줄 뿐만 아니라 재배지의 변화 및 병해충과 같은 유해생물군에 의한 식물의 피해에도 영향을 준다(Yoon, 2005). 또한, 기온의 변화는 폭염, 냉해 등 극한농업기상 이변의 발생빈도와 강도를 변화 시켜서, 농업 및 인문·사회 분야 등 전반적인 인간활동에 영향을 준다(Stocker *et al.*, 2013). 그렇기 때문에 기온을 정확하게 예측하는 것은 농업 및 기상분야에 있어서 매우 중요한 과제 중 하나이다.

접합대순환모형(Coupled general circulation model, CGCM)은 기온을 예측하기 위한 가장 주요한 수단으로, 세계 여러 현업기관들(operation centers)에서도 접합대순환모형을 이용하여 계절예보를 수행하고 있다(Wang *et al.*, 2001; Molteni, *et al.*, 2011; Saha *et al.*, 2014). 하지만 접합대순환모형에서 생산된 예측자료의 수평격자 해상도는 대략 50~320 km로(Min *et al.*, 2014), 접합대순환모형을 통해 상세격자규모의 기상예측정보를 제

공하기에 한계가 있다(Ahn *et al.*, 2012; Ahn *et al.*, 2014). 그럼에도 불구하고 농업을 포함한 수문, 경제 등 기상산업 발전과 더불어 다양한 분야에서 상세한 예측정보가 요구되고 있다. 이에 많은 선행연구들은 역학적 및 통계적 규모축소법(downscaling)을 이용하여 이를 극복하고자 하였다. Ahn *et al.* (2012)에서는 WRF (Weather Research and Forecast)와 같은 지역기후모형을 이용하여 역학적 규모축소법으로 남한의 상세한 기온분포를 나타낼 수 있음을 보였다. 이처럼 역학적 규모축소법은 지형적효과와 같은 역학적·물리적요소에 대한 대기과정을 현실적으로 모의할 수 있는 장점이 있다. 하지만, 1 km 이하의 고해상도규모의 예측자료를 생산하기 위해서는 모델의 적분시간이 장시간 소요될 뿐만 아니라 상당한 컴퓨팅 계산자원이 필요하기 때문에 역학적 규모축소법 또한 한계가 존재한다. 반면 통계적 규모축소법은 주어진 기상정보만으로 원하는 격자형태의 기후정보를 생산하므로, 상대적으로 적은 컴퓨팅 계산자원을 이용하여 효과적으로 상세한규모의 예측자료를 생산할 수 있다(Brunetti *et al.*, 2014). 통계적 방법에는 거리만의 함수로 계산하는 Cressman 기법(Cressman, 1959), Barnes 기법(Barnes, 1964), 역거리 가중법(Inverse Distance Weighting, IDW) (Szolgay *et al.*, 2009) 등이 있으며, 거리뿐만 아니라 지형학적 특성까지 고려하는 Hypsometric 기법(Ahrens, 2012), 베이시안 공간선형모형(Bayesian spatial linear model), PRISM (Parameter-elevation Regressions on

Independent Slope Model; Daly *et al.*, 1994; Kim *et al.*, 2012; Ahn *et al.*, 2014) 등이 있다. 이 외에도 일반선형모형(Jeong *et al.*, 2012), 특이값 분해(Park *et al.*, 2008), 정준상관분석(Skourkease *et al.*, 2010) 등의 통계적 모형이 고해상도의 기상정보를 생성함에 있어서 활용되었다.

대부분의 선형연구들은 관측자료를 이용하여 남한 영역의 고해상도 격자형 기온자료를 생산에 집중되어 있다(Kim *et al.*, 2012; Ahn *et al.*, 2014). 그렇기 때문에 실시간 예측자료를 이용하여 고해상도 기온예측자료를 생산하는 연구가 필요하다. 이에 본 연구에서는 남한영역에 대하여 1 km 고해상도의 계절예측 기온자료를 생산함과 동시에 예측된 기온자료의 성능을 높이기 위하여 새로운 방법을 제안하고자 하였다. 먼저, 이 새로운 방법은 집합대순환모형에서 생산된 저해상도의 계절예측 기온자료를 바탕으로, 통계적 규모축소법을 이용하여 남한지역에 대해 1 km 고해상도의 계절예측 기온자료를 생산한다. 그 다음 과정으로 위성에서 관측된 고해상도 고도자료와 유전자알고리즘을 이용하여 모형의 예측결과 내에 존재하는 오차를 보정한다. 이 새로운 방법은 관측지점과 예측지점간의 거리, 예측지점의 고도, 지향면, 해양도 중에서 기온에게 영향을 가장 크게 주는 고도와 거리를 이용할 뿐만 아니라 유전자 알고리즘을 이용하여 모형이 가지는 계통적 오차(systematic bias)를 줄여서 보다 정확한 고해상도의 계절예측 기온자료를 만드는 방법이다. 각 통계적 방법에 대한 자세한 설명은 2장에서 언급하였으며, 3장에서는 실험설계를, 4장에서는 실험들간의 예측성능을 평가하였다. 마지막으로 5장에서는 요약 및 결론을 제시하였다.

2. 자료 및 연구방법

1) 자료

본 연구에서는 PNU (Pusan National University) CGCM에서 생산된 계절예측자료를 사용하였다. PNU CGCM은 APCC (Asia-Pacific Economic Cooperation Climate Center)의 장기예측을 위한 다중 모형 앙상블 시스템(Multi-model ensemble system)에 참여하고 있으며, 매 분기별 기상청에서 개최하는 기후예측전문가회의에도 계절예측 자료를 제공하고 있는 모형이다(Sun and Ahn, 2011; Sun and Ahn, 2015; Kim and Ahn, 2015). 이모형은 대기대순환모형(atmospheric general circulation model, AGCM)인 CCM3 (Community Climate Model version 3, kiehl *et al.*, 1996)와 해양대순환모형(oceanic general circulation model, OGCM)인 MOM3 (Modular Ocean Model version 3, Pacanowski and Griffies, 1998), 지면모형인 LSM (land surface model, Bonan, 1998), 해빙모형인 EVP (Elastic-Viscous-Plastic Model, Ahn *et al.*, 2001)로 구성되어 있다(Ahn and Lee, 2015; Kim and Ahn, 2015). PNU CGCM에 대한 자세한 설명은 Table 1에 나타내었다.

본 연구에서는 초기조건에서 발생하는 예측의 불확실성을 줄이기 위하여 시간지연방법(time-lag method)에서 생성된 앙상블예보 결과를 사용하였다(Kharin *et al.*, 2001; Kim and Ahn, 2015). 초기조건의 시간을 다르게 하여 앙상블 멤버를 만드는 시간지연방법은 간단하면서도 효과적으로 초기조건의 불확실성을 줄이는 방법이다(Blanković *et al.*, 1990). 본 연구에서 사용된 초기조건은 11월 6일부터 15일까지 총 10개이며, 1980년부터 2015년

Table 1. Description of PNU-CGCM

Component model	Resolution		Reference
Atmosphere	Horizontal	Spectral truncation T42	Community Climate Model (CCM3, Kiehl <i>et al.</i> , 1996)
	Vertical	18 hybrid sigma-pressure levels (top : 2.917mb)	
Land	Horizontal	Spectral truncation T42	Land Surface Model (LSM, Bonan, 1998)
	Vertical	6 levels	
Ocean	Horizontal	2.8125° longitude, ~0.7° (low lat.), ~1.4° (mid lat) and ~2.8° (high lat) latitude	Modular Ocean Model (MOM3, Pacanowski and Griffies, 1998)
	Vertical	40 levels (top : 10m, bottom : 5258m)	
Sea-ice	Horizontal	2.8125° longitude, ~0.7° (low lat.), ~1.4° (mid lat) and ~2.8° (high lat) latitude	Elastic-Viscous-Plastic Model (EVP, Ahn <i>et al.</i> , 2001)
	Vertical	3 levels	

까지 총 36년 동안 매년 각각의 초기조건 날짜에서 적분을 수행하였다. 그래서 최종적으로 10개의 앙상블 멤버를 생산하였으며, 각 앙상블멤버들의 결과를 SCM (simple composite method)를 이용하여 평균한 후 그 예측결과를 이용하였다(Jo and Ahn, 2014; Ahn and Lee, 2016). 모형의 적분 lead time은 3.5개월(November to February)이며, 분석은 북반구 겨울철(DJF, 1.5~3.5 month lead time) 기온예측에 초점을 맞췄다.

본 연구에서는 기상청의 지상기상관측(Automated Surface Observing System, ASOS)과 자동기상관측(Automated Weather Station, AWS) 기온자료를 보정 및 검증을 위해 사용하였다. 여기서 AWS는 1990년 후반부터 구축이 되었기 때문에 긴 기간 관측이 진행된 ASOS와 사용 가능한 자료의 기간이 다르다. 이에 본 연구에서는 ASOS는 56개 지점에 대하여 1980년부터 2015년까지 총 36년간의 자료를 사용하였으며, AWS는 291개 지점에 대하여 2001년부터 2015년까지 14년간의 자료를 사용하였다. 각 자료의 지점에 대한 위치는 Fig. 1에 나타나 있다. ASOS의 관측지점이 대부분 고도가 낮은 곳에 위치하기 때문에, 본 연구에서는 상대적으로 짧은 기간 동안 관측되었음에도 불구하고 남한의 전반에 위치한 AWS 지점 자료를 분석에 함께 사용하였다.

2) 방법

관측과 모형 자료는 섭동법(perturbation method)을 이용하여 기후값(\bar{M})과 아노말리(M') 부분으로 나눌 수

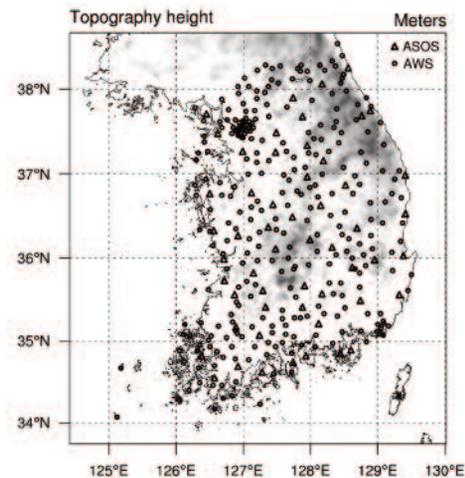


Fig. 1. Topography height (shaded, m) and location of ASOS and AWS used in analysis of observation data.

있다(Ahn *et al.*, 2012; Ahn and Lee, 2016).

$$M = \bar{M} + M' \tag{1}$$

본 연구에서는 1 km 고해상도의 계절예측 기온자료를 생산하기 위하여 역거리가중법을 이용한 통계적 규모축소법을 수행하였으며, 위성에서 관측된 고해상도 고도자료와 유전자 알고리즘을 활용하여 모형의 예측결과에 존재하는 계통적 오차를 보정하였다. 각 방법에 대한 기본적인 설명은 아래에 소개되어 있다.

(1) 역거리 가중법(Inverse Distance Weighting, IDW)

본 연구에서 사용된 역거리 가중법은 기온의 동질성을 거리만의 함수로 계산하는 공간 보간법(geographic information system interpolation, GIS)으로, 이미 알고 있는 위치정보를 이용하여 가까이 있는 실측값에 더 큰 가중치를 주어 보간하는 방법이다. 이 방법은 공간 보간법 중에서도 가장 단순하면서 효과적이기 때문에 널리 사용되는 방법이다(Szolgay *et al.*, 2009; Ahn *et al.*, 2014; Lee *et al.*, 2016). 역거리 가중법의 수식은 다음과 같다.

$$M_p = \frac{\sum_{i=1}^N M_i W_i}{\sum_{i=1}^N W_i}, W_i = \frac{1}{d_i^2} \tag{2}$$

여기서 M_p 는 추정하고자 하는 예측지점의 기온이며, M_i 는 예측지점을 중심으로 영향반경 안에 포함된 N 개의 관측점 중 i 번째 관측지점의 기온을 의미한다. W_i 는 i 번째 관측지점의 가중치를 의미하며, d_i 는 예측지점과 i 번째 관측지점간의 거리를 의미한다. 이처럼 영향반경 내에 포함된 N 개의 관측지점의 가중치는 예측지점과 각 관측지점간의 거리의 제곱에 반비례로 계산된다. 본 연구에서는 PNU CGCM에서 예측된 기온의 수평격자간 거리가 약 314 km이기 때문에 최소 격자점을 2개 이상 사용하기 위해서 영향반경을 250 km로 설정하여 이용하였다.

(2) 위성고도자료 이용한 오차보정(bias correction)

본 연구에서는 고도에 따른 기온의 변화를 고려하기 위하여 고해상도의 격자형 위성고도자료인 ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) GDEM (Global Digital Elevation Map)을 사용하였다(Frey and Paul, 2012; Choi, 2013). ASTER는 1999년 12월에 시작된 미국항공우주국(National Aeronautics and

Space Administration, NASA)의 지구관측시스템(Earth observing system, EOS)의 주력 위성인 Terra에 탑재된 이미지 장비(imaging instrument)이다. ADEM GDEM에서는 30 m 해상도의 격자형 고도자료가 제공되기 때문에 본 연구에서는 최대 30 m 해상도의 기온예측자료를 생산할 수 있지만, 고해상도 기온자료 생산 방안을 개발하고 테스트하는데 초점을 맞추었기에 계산 자원의 효율성을 고려하여 1 km 격자로 재배열하여 사용하였다. 위성고도자료에서 제공되는 해상도만큼 상세화가 가능하기 때문에, 향후 30 m 해상도의 계절 예측자료를 생산한다면 도단위 또는 시군단위를 포함하여 작황을 평가하는데 더 유용하게 사용 될 것이라 생각된다. Figure 1의 색칠된 부분이 GDEM에서 제공되는 남한영역에 대한 1 km 해상도의 고도분포를 나타낸 그림이다. 본 연구에서는 단순선형회귀식(single linear regression)을 이용하여 각 해의 관측지점별 고도와 기온자료간의 회귀계수($\hat{\beta}$) 그리고 절편($\hat{\alpha}$)을 구한 후, 이들을 모든 해에 대해 평균하였다. 여기에서 사용된 단순선형회귀식은 다음과 같다.

$$\hat{\alpha} = \bar{O} - \hat{\beta}\bar{Z} \quad (3)$$

$$\hat{\beta} = \frac{\sum_{i=1}^N (z_i - \bar{z}) \sum_{i=1}^N (o_i - \bar{o})}{\sum_{i=1}^N (z_i - \bar{z})^2} \quad (4)$$

$$\bar{\alpha} = \frac{1}{T} \sum_{t=1}^T \hat{\alpha} \quad \bar{\beta} = \frac{1}{T} \sum_{t=1}^T \hat{\beta} \quad (5)$$

여기서 N 과 T 는 각각 관측지점 개수와 훈련기간에 사용된 관측기간을 나타내며, O 와 Z 는 각각 i 번째 관측지점의 기온과 고도를 나타낸다. 회귀계수와 절편을 얻기 위해 사용된 자료의 기간이 ASOS는 36년, AWS는 14년으로, 훈련기간(training period)과 검증기간(validating period)로 나누기에 자료의 기간이 짧기 때문에 leave-one-out 교차검증(cross-validation)을 사용하여 결과를 검증하였다. 즉, 예측하고자 하는 목표(target) 연도를 제외한 나머지 년도(ASOS는 35년, AWS는 13년)에 대하여 각 해마다 회귀계수와 절편을 구한 후, 이들을 각각 시간에 대하여 평균하였다. 이렇게 구한 시간평균 회귀계수($\bar{\beta}$)와 절편($\bar{\alpha}$)을 고해상도 격자형 위성고도자료에 적용하여 계절예측자료의 고도에 따른 기온변화의 공간분포(D_{ij})를 생산한다. 최종적으로 생산된 공간분포

(D_{ij})는 아래와 같이 1 km 고해상도 기온 예측자료에 적용되어 보정된다.

$$D_{ij} = \bar{\alpha} + \bar{\beta}Z_{ij} \quad (6)$$

$$NM_{ijt} = M_{ijt} + D_{ij} \quad (7)$$

여기서 i, j 는 공간격자점을 나타내며, t 는 목표연도를 의미한다. M_{ijt} 는 통계적 규모축소법으로 생산된 1 km 고해상도 기온자료이며, NM_{ijt} 는 위성고도자료에 의해 보정된 1 km 고해상도 기온자료이다.

(3) 유전자알고리즘(Genetic algorithm, GA)을 이용한 오차보정(bias correction)

아노말리의 계통적 오차는 기후값에 포함되어 있는 계통적 오차에 비하여 상대적으로 보정하기가 어렵다(Kug *et al.*, 2008; Ahn *et al.*, 2012; Ahn and Lee, 2016). 그림에도 불구하고 실시간 예보의 질을 향상시키기 위해서는 평년대비 그 해의 특징을 나타내는 아노말리 보정이 필요하다. 이에 본 연구에서는 유전자알고리즘을 이용하여 아노말리의 계통적 오차를 보정하여 예측성능을 향상시키고자 하였다. 유전자알고리즘은 생물의 진화과정을 기반으로 한 최적화 탐색방법으로, 생물진화의 과정을 모방함으로써 근사값에 가까운 해답을 찾아낼 수 있다(Holland, 1975; Ahn and Lee, 2016). 유전자 알고리즘의 주요 원리는 염색체(chromosome)이다. 염색체는 유전자(gene)로 구성되어 있으며, 여러 개의 염색체가 모여서 개체군(population)이 된다. 세대(Generation)는 개체군에 속해 있는 부모염색체(parent chromosome)가 자식염색체(offspring chromosome)를 생산하여 다음의 개체군으로 변화하는 과정을 의미한다. 유전자 알고리즘의 세대가 변화하는 과정에 사용되는 연산은 선택(selection), 교차(crossover), 변이(mutation), 대치(replacement)가 있다. 선택은 가장 핵심적인 연산으로 유전적으로 훌륭한 염색체를 우선적으로 선택하기 위한 과정이며, 교차는 부모 세대에서 자식 세대로 유전자를 넘겨주기 위해 사용된다. 변이는 단순한 유전적 대물림 이외에 자연발생적으로 유전자 변형이 일어나 부모에게서는 설명하기 힘든 변화를 담당한다. 그리고 대치는 다음 세대로 가기 위하여 개체군을 교체하는 것을 의미한다. 여기에서는 단순히 모든 개체군을 바꿀 수도 있고, 이전보다 우수한 개체만 교체할 수도 있다.

본 연구에서 사용된 인경신경망 프로그램은 PIKAIA 1.2라고 불리는 유전자 알고리즘 패키지 프로그램이다 (Charbonneau, 2002). 본 연구에서는 PNU CGCM에서 생산된 앙상블 멤버들 사이에 최적의 가중치를 찾아 모형의 예측결과 내에 계통적 오차를 줄이기 위한 목적으로 유전자 알고리즘을 사용하였다. 즉, 접합대순환모형에서 생산된 각 앙상블 멤버의 예측결과와 아노말리에서 관측지점과 가까운 위치에 있는 예측값을 이용하여 관측지점별 예측값을 추출한 후, 각 지점별 관측자료를 이용하여 추출한 앙상블 예측결과들 사이의 가중치를 유전자 알고리즘을 통해 생산하였다. 유전자알고리즘을 이용한 보정 역시 자료기간(ASOS는 36년, AWS는 14년)을 고려하여 leave-one-out 교차검증(cross-validation)을 사용하여 결과를 검증하였다. 다시 말해, 예측하고자 하는 목표(target) 연도를 제외한 나머지 년도를 유전자알고리즘에 넣어서 각 앙상블 멤버들간의 최적의 가중치를 구하고, 여기서 구한 가중치를 목표(target) 연도에 적용하여 최종적인 예측결과를 얻었다. 유전자 알고리즘을 통해 최종적으로 생산된 관측지점별 예측자료는 역거리 가중법에 의하여 1 km 고해상도격자로 생산되어 기온 예측자료의 아노말리 부분에 적용된다.

유전자알고리즘 내에는 각 각의 염색체가 주어진 환경에서 얼마나 살아남기에 적합한가를 판단하는 적합도 함수(fitness function)가 있다. 적합도 함수는 어떤 문제가 주어졌을 때 어떤 염색체가 최적의 해인지 판단해 주기 때문에, 사용자가 적합도 함수를 어떻게 설정하는가에 따라 진화의 방향이 설정된다(Lee *et al.*, 2006). 본 연구에서 사용한 적합도 함수는 관측과 모형의 예측결과와 아노말리 사이의 최소오차제곱근(minimum root mean square error, RMSE)로 정의하였다. 적합도 함수로 사용된 최소오차제곱근은 간단하면서도 효율적인 방법으로, 선행 연구에서도 자주 사용되었다(Lee *et al.*, 2006; Ahn and Lee, 2016). 오차제곱근(F)의 수식은 다음과 같다.

$$F = \frac{1}{T} \sum_{i=1}^T (k_i - O_i)^2 \quad (8)$$

$$k_j = \sum_{i=1}^T (M_{ij} \times x_j) \quad (9)$$

여기에서 M_{ij} 는 접합대순환모형에서 생산된 관측지점별 각 앙상블의 예측결과와 아노말리(anomaly)이며, x_j 는 유전자알고리즘에서 구해진 각 앙상블별 가중치이다.

O_i 와 k_i 는 각각 관측(ASOS and AWS)과 유전자알고리즘에서 구한 가중치가 적용된 앙상블평균 아노말리이다. 그리고 N 은 접합대순환모형의 앙상블 개수(10개)이며, T 는 시간으로, 목표(target) 연도를 제외한 ASOS의 경우 35년, AWS는 13년이다.

3. 실험설계

일반적으로 계절예측자료를 생산하기 위해 세계 현업기관에서는 접합대순환모형을 사용한다(Wang *et al.*, 2001; Saha *et al.*, 2014). 하지만 접합대순환 모형에서 생산된 계절예측결과는 저해상도이기 때문에 남한 전체 영역의 기온예측에는 사용이 가능하지만 지역별로 상세하게 예측함에 있어서는 사용이 힘들다. 이에 본 연구에서는 1 km 해상도의 격자형 기온 예측자료를 보다 정확하게 생산하는 방법을 살펴보기 위해, Fig. 2와 같이 4가지 단계로 나누어 순차적으로 실험을 수행하였다. EXP1은 PNU CGCM에서 생산된 저해상도 계절예측 기온을 나타내며, EXP2는 EXP1의 예측결과에 역거리 가중법을 사용한 통계적 규모축소법을 적용하여 생산된 남한지역의 1 km 고해상도 계절예측 기온자료를 나타낸다. EXP3는 EXP2의 결과에서 위성고도자료인 ASTER GDEM을 이용하여 생산된 고도에 따른 기온변화 분포를 적용하여 구한 1 km 고해상도 계절예측 기온자료를 나타낸다. EXP2는 관측지점과 예측지점간의 거리에 따른 기온변화만 고려되었지만 EXP3는 거리뿐만 아니라 고도에 따른 기온 변화도 포함하게 된다. 마지막으로 EXP4는 EXP3에서 유전자알고리즘을 이용하여 모형의 예측결과 내 존재하는 계통적 오차를 보정한 결과이다. EXP4는 EXP3의 장점뿐만 아니라 아노말리 부분에서 존재하는 오차를 줄였기 때문에 다른 실험들에 비해 가장 관측과 유사한 계절예측 기온자료가 생산될 것으로 기대된다. 본 연구에서는 저해상도의 접합대순환모형 예측결과(EXP1), 통계적 규모축소법을 통한 고해상도 예측결과(EXP2), 위성고도자료를 이용하여 보정 후에 예측결과(EXP3), 그리고 유전자 알고리즘을 이용하여 보정 후에 예측결과(EXP4) 등 순차적으로 진행되는 과정의 예측성능을 비교·평가함으로써, 각 단계별 과정이 최종 결과에 미치는 영향을 살펴보고자 하

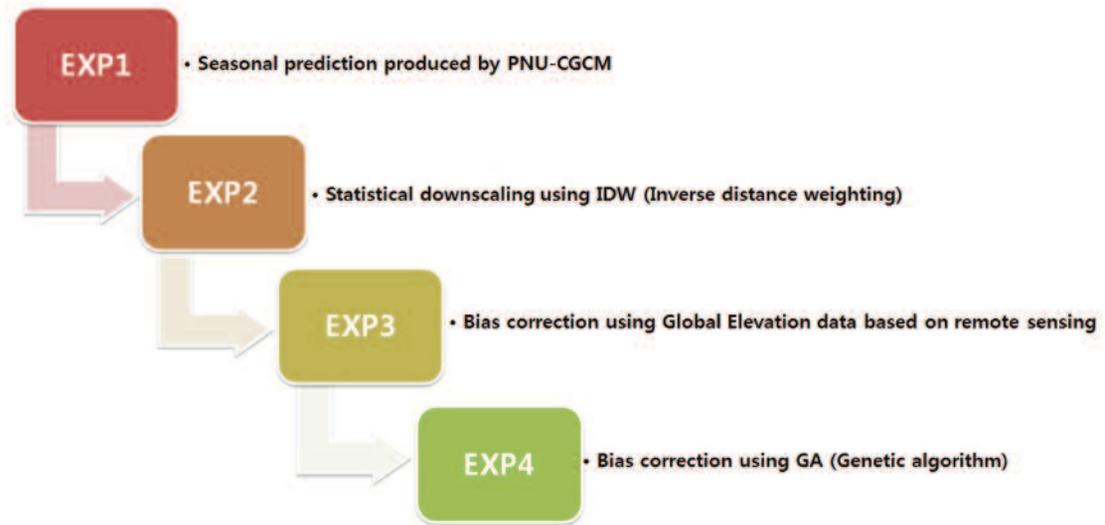


Fig. 2. Schematic diagram for the four experiments to produce the fine-resolution distribution of seasonal prediction for temperature.

였다.

모형의 성능은 분석방법에 따라 결정될 수 있기 때문에 다양한 측면의 분석이 필요하다(Wilks, 1995; Hagedorn *et al.*, 2005). 본 연구에서는 대표적인 결정적 분석방법(deterministic analysis)인 오차제곱근(root mean square error, RMSE)와 시간상관계수(temporal correlation coefficient, TCC), 관측자료를 이용하여 정규화된 표준편차(normalized standard deviation, NSTD)를 사용하였다(Jolliffe and Stephenson, 2003). 또한, 범주형 결정적 분석방법(categorical deterministic analysis)인 정답률(hit rates, HR)과 오답률(false alarm rates, FAR)도 분석에 사용하였다(Wilks, 1995). 여기서 HR과 FAR은 관측자료와 실험들의 아노말리의 분포에서 각각의 $\pm 0.43\sigma$ (standard deviation)을 기준으로 삼등분하여 구했다(Ahn and Lee, 2016).

4. 실험결과

본 연구에서는 1 km 고해상도의 계절예측 기온자료의 성능을 검증하기 위하여 기후값과 아노말리 부분으로 나눠서 분석을 하였다. 분석기간은 ASOS의 경우 36년(1980-2015)이며, AWS 또는 AWS+ASOS는 14년(2001-2015)이며, 북반구 겨울철에 분석의 초점을 맞추었다.

1) 기후값 분석

본 연구에서는 먼저 각 실험별 기후값 예측성능을 평가해 보고자 하였다. Figures 3과 4는 각 실험을 통해 생산된 기온예측자료의 기후값 공간분포이며, 각각 총 36년(1980-2015)과 14년(2001-2015)의 기후값을 나타낸다. 검증을 위하여 관측지점별 ASOS와 AWS의 기후값도 함께 나타내었다. Figures 3과 4의 관측을 살펴보면, ASOS와 AWS 모두 기후값의 기간은 다르지만 북쪽으로 갈수록 온도가 낮고, 남쪽으로 갈수록 온도가 높아지는 공통적인 특징을 보이고 있다. 하지만 ASOS의 남한영역의 면적평균 기온의 기후값이 0.2°C인 반면, AWS는 -0.3°C였다. 이는 AWS가 ASOS에 비하여 높은 고도까지 골고루 관측지점이 분포되어 고도에 따른 기온의 감소를 잘 반영함을 의미한다. EXP1은 PNU CGCM에서 생산된 저해상도 기온 예측자료이기 때문에 남한영역에 대하여 4개의 격자점에 대한 기온예측자료가 존재한다. EXP2는 역거리 가중법을 이용한 통계적 규모축소법 통해 1 km의 고해상도 기온예측자료를 만들었지만, EXP1의 4개 격자점에서의 예측자료만으로 만들었기 때문에 상세한 기온분포는 나타나지 않았다. 게다가 EXP2는 통계적 규모축소과정에서 관측지점과 예측지점간의 거리만 고려되었기 때문에 남한의 지형적 특성이 전혀 반영되지 않아 남한의 기후값이 매우 높게 나타났다(Figs. 3b과 4b). 반면, EXP3과 EXP4는 남한의 동쪽에 위치한

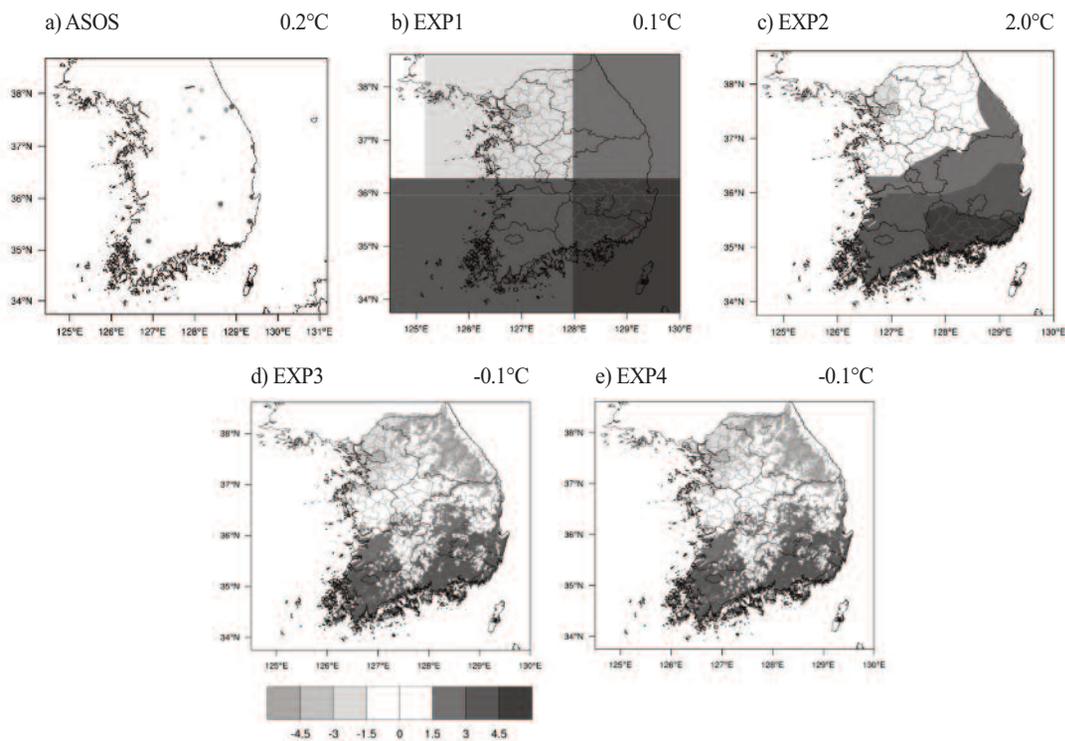


Fig. 3. Climatology distribution of temperature over South Korea for boreal winter, averaged over 36 years (1980-2015) derived from ASOS (a), EXP1 (b), EXP2 (c), EXP3 (d), and EXP4 (e).

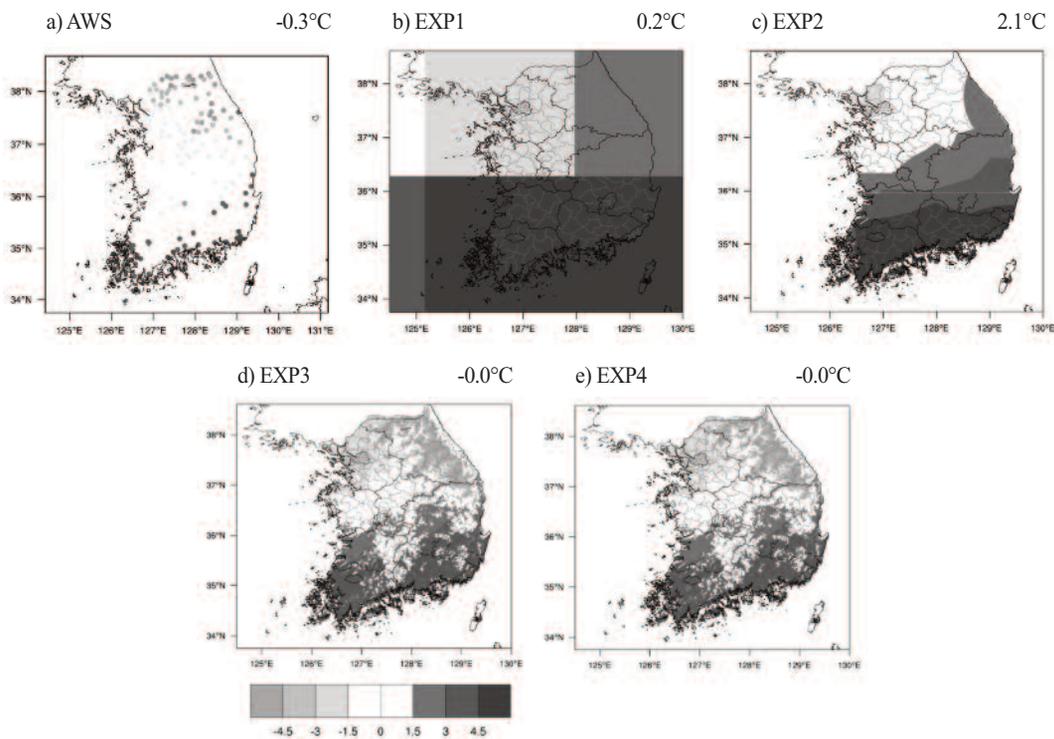


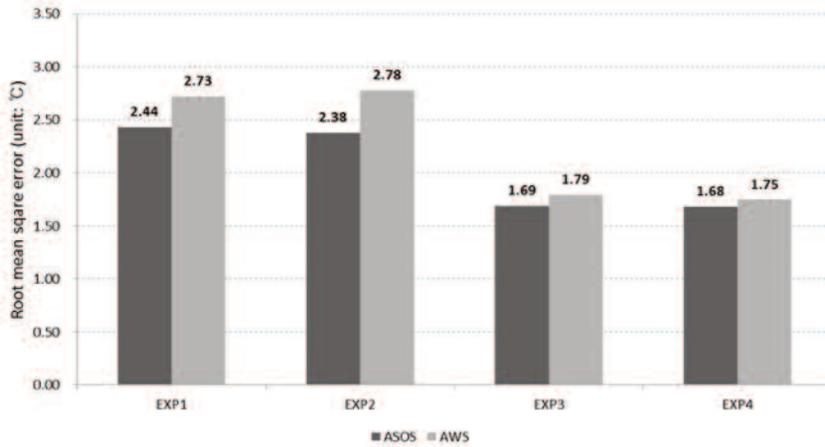
Fig. 4. Same with Fig. 3 but averaged over 14 years (2001-2015) derived from AWS (a), EXP1 (b), EXP2 (c), EXP3(d), and EXP4 (e).

남북으로 뺀 태백산맥과 동서로 뺀 소백산맥과 같이 고도가 높은 산맥지역에서 기온이 낮게 나타나는 등 위성고도자료를 이용하여 고도에 따른 기온변화를 잘 나타내고 있다. 이는 EXP3과 EXP4가 다른 실험에 비하여 1 km 고해상도의 기온예측자료를 실제 관측과 유사하게 잘 예측했음을 의미한다. EXP4는 유전자알고리즘을 이용하여 아노말리 부분의 오차를 보정하였기 때문에 기후값에 대해서는 EXP3와 유사한 결과를 보였다.

기후값의 예측성능을 평가하기 위하여 관측과 각 실험별 기후값의 RMSE를 Fig. 5에는 나타내었다. ASOS

의 경우 EXP1의 RMSE가 2.44°C로 가장 높은 반면, AWS에는 EXP2의 RMSE가 2.78°C로 가장 높았다. 이는 EXP2가 1 km 고해상도 기온예측자료로 만들어졌음에도 불구하고 고도에 따른 기온변화를 표현 못하기 때문에, 다양한 고도자료가 있는 AWS에서 EXP1보다 높은 RMSE를 가지게 된 것이다. 위성고도자료로 인하여 고도에 따른 기온변화가 고려된 EXP3와 EXP4의 RMSEs는 EXP1과 EXP2에 비하여 낮게 나타났다. 실험들 사이의 RMSE 차이는 고도가 높아짐에 따라 더 크게 나타났다(Fig. 5b). EXP1과 EXP2는 고도가 높아짐에 따라 RMSE가 점차적으로 커졌지만, EXP3와 EXP4는 고도

a) RMSE of ASOS and AWS



b) RMSE of ASOS+AWS according to altitude

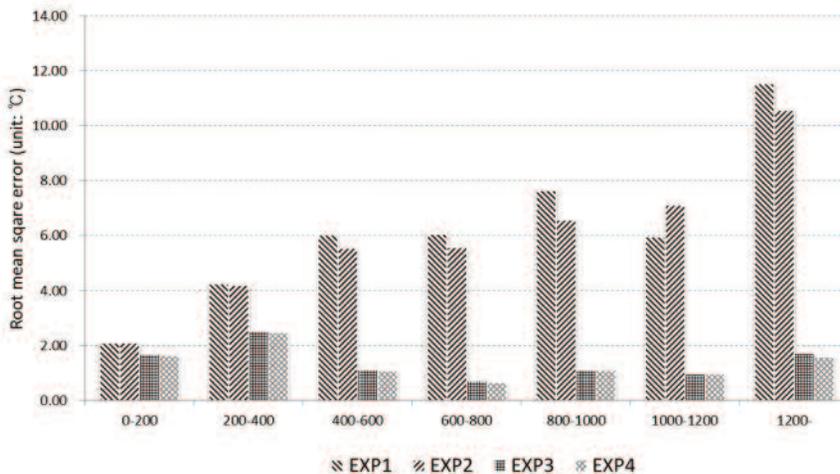


Fig. 5. Root mean square errors of temperature climatologies between observation and each experiment. The climatology periods of ASOS and AWS (ASOS+AWS) are 36 years (1980-2015) and 14 years (2001-2015), respectively (unit: °C).

가 높아짐에도 불구하고 RMSE는 감소하거나 일정수준을 유지하였다. 그렇기 때문에 고도가 높아짐에 따라 고도에 따른 기온변화가 포함될 실험들과 포함되지 않은 실험들 사이의 RMSE는 매우 커졌다. 관측지점의 고도가 200m이하에서는 고도에 따른 기온변화가 포함될 실험들(EXP3와 EXP4)과 포함되지 못한 실험들(EXP1과 EXP2)간의 RMSE 차이가 약 0.5°C정도 나지만, 1200m 이상 되는 지점에서의 EXP1과 EXP2의 RMSEs가 각각 11.5°C와 10.6°C임에 반해, EXP3와 EXP4의 RMSEs는 각각 1.7°C와 1.6로 약 10°C 이상의 RMSE 차이를 보였다. 고도에 따른 기온변화가 포함될 실험들 사이에서는 EXP4의 RMSE가 어떤 고도에서든 가장 낮은 값을 나타내었다. Figure 6은 각 실험들에 대하여 고도와 기온과의 산점도(scatter plot)를 그린 것으로, 이 그림은 고도의 변화에 따른 기온변화를 설명한다. 관측자료인 ASOS+AWS는 고도가 증가할수록 기온이 낮아지는 선형적 관계를 잘 나타내고 있다(Fig. 6a). 실험별로 살펴보면, EXP1과 EXP2에서는 고도에 따른 기온변화가

전혀 나타나지 않았다. 특히 EXP1은 4개의 점을 통해 생성되었기 때문에 온도의 값이 고도에 따라 큰 차이가 보이지 않는다. 이러한 결과는 EXP1과 같이 점합대순환 모형에서 생산된 저해상도 격자의 한계성을 보여주는 동시에 단순히 예측지점과 관측지점간의 거리의 함수만으로 1 km 고해상도 기온예측자료를 만들 때 남한의 지형적 특징이 전혀 고려되지 않아 야기되는 문제점을 보여준다. 반면 EXP3와 EXP4는 위성고도자료를 이용하여 관측지점과 예측지점의 거리뿐만 아니라 고도에 따른 변화도 고려하였기 때문에, 고도가 증가함에 따른 기온의 감소를 잘 표현하고 있다. 이는 본 연구에서 제안한 새로운 방법이 앞서 언급한 문제들을 극복하고 지형적 특성이 효과적으로 반영되어 보다 정확한 예측자료의 기후값을 생산할 수 있음을 의미한다.

2) 아노말리(anomaly) 분석

각 실험별 아노말리 예측성능을 평가해 보기 위하여, 관측과 각 실험간의 RMSE를 Fig. 7에 나타내었다. 아노말리에 대한 각 실험의 RMSE는 기후값에 비하여 크게

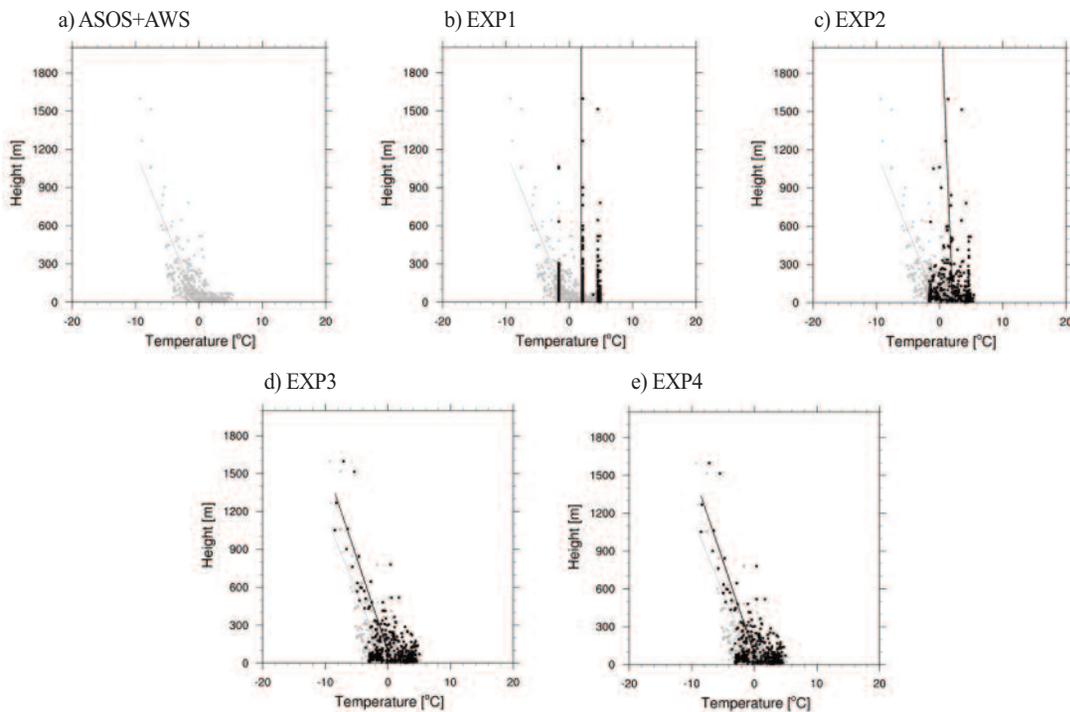
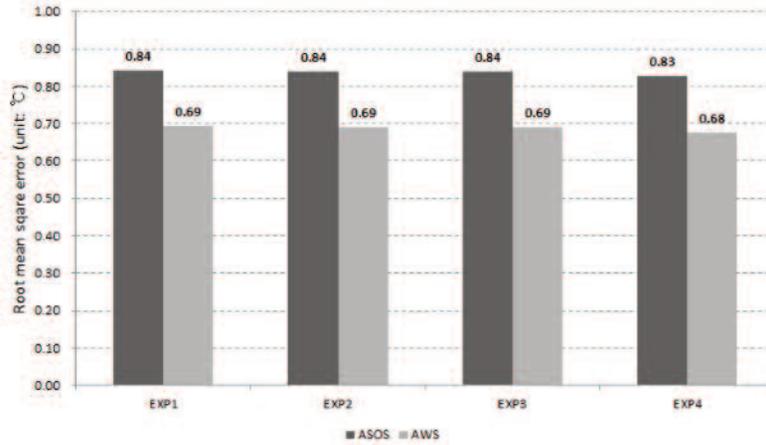


Fig. 6. Scatter plots of altitudes against temperature over South Korea for boreal winter, averaged over 14 years (2001-2015) derived from ASOS+AWS(a), EXP1(b), EXP2(c), EXP3(d), and EXP4(e). Here, all panels include the distribution of ASOS+AWS and its regression line for reference.

a) RMSE of ASOS and AWS



b) RMSE of ASOS+AWS according to altitude

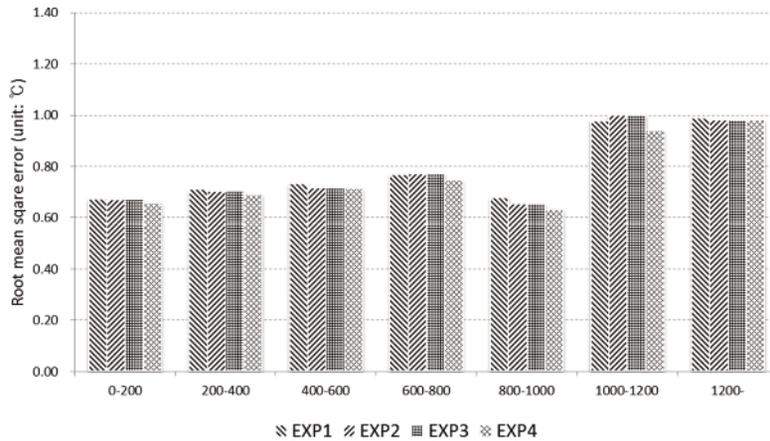


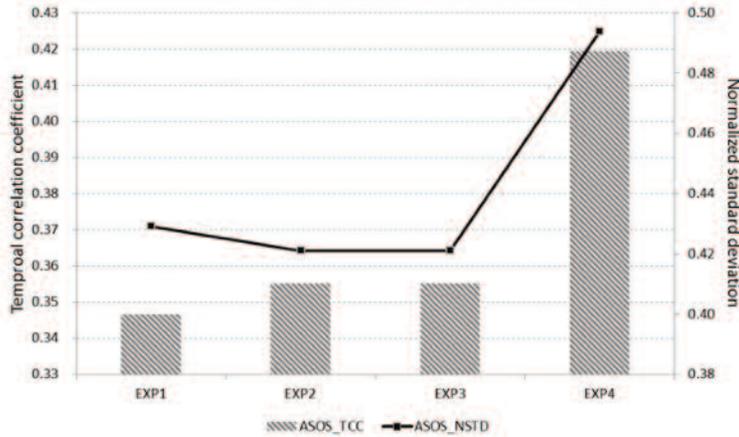
Fig. 7. Root mean square errors of temperature anomalies between observation and each experiment. The data period of ASOS and AWS (ASOS+AWS) are 36 years (1980-2015) and 14 years (2001-2015), respectively (unit: °C).

나타나지 않았다. 예를 들어 기후값의 경우 각 실험의 RMSE 범위가 1~3°C 였다면, 아노말리는 각 실험의 RMSE 범위가 0.6~0.9°C 이하로 작게 나타났다. 또한, 고도에 따라 실험간의 RMSE 차이가 매우 많이 나타난 기후값과는 달리 아노말리에서는 고도에 따라 큰 차이를 보이지 않았다(Fig. 7b). 이는 고도에 따른 기온변화는 대부분 기후값에 영향을 주며, 아노말리의 경우 고도에 따른 영향을 크게 받지 않음을 의미한다. 실험들간의 예측성능을 살펴보면, 관측지점과 예측지점의 거리와 고도뿐만 아니라 유전자 알고리즘으로 계통적 오차가 보정된 EXP4의 RMSE가 가장 낮게 나타났다. EXP4를 제외한 나머지 실험들의 RMSE는 큰 차이 없이 유사하게

나타났다.

RMSE가 관측과 모형 예측결과간의 정량적 차이를 나타내는 분석이었다면, 시간에 따른 변화와 변동성의 크기가 얼마나 관측과 유사한지 살펴보기 위해 TCC와 NSTD를 Fig. 8에 나타내었다. 여기서 Fig. 8a (8b)는 36년 (14년)기간에 대해 ASOS(AWS)의 관측지점별 기온값과 각 실험의 기온 예측값과의 TCC 및 NSTD를 구한 것이다. TCC의 경우 통계적으로 95% 신뢰구간에 유의한 범위부터 나타내도록 하였다. TCC가 “1”에 가까울수록 관측과 유사한 시간변동성을 가짐을 의미하며, NSTD는 관측을 이용하여 정규화 되었기 때문에 “1”에 가까울수록 관측과 변동성의 크기가 유사함을 의미한다. 먼저,

a) ASOS



b) AWS

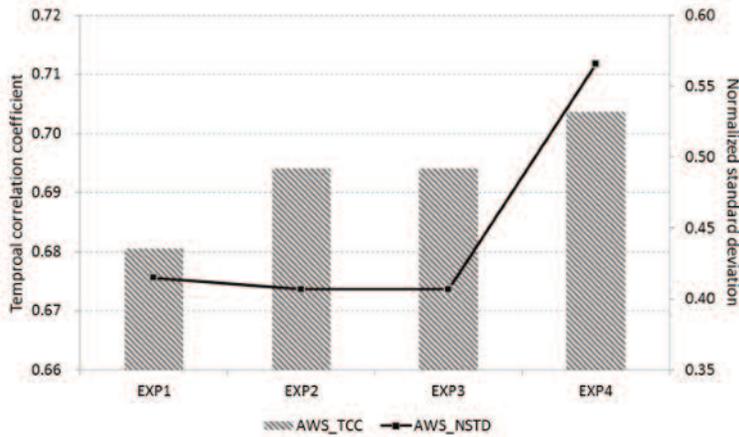


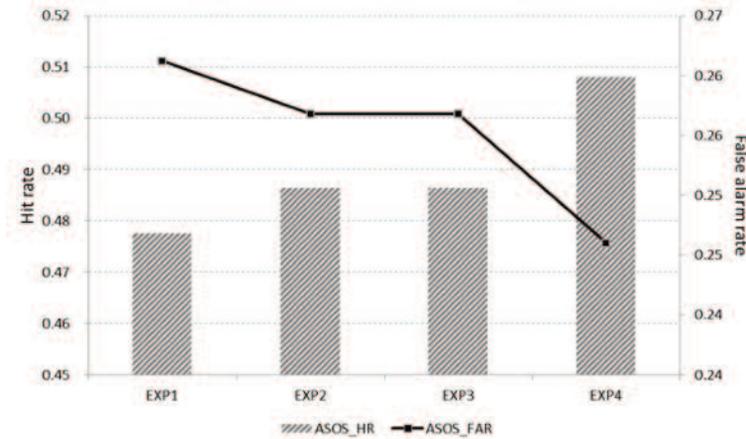
Fig. 8. Temporal correlation coefficient (TCC, left axis) and normalized standard deviation (NSTD, right axis) of temperature anomalies between observation and each experiment

ASOS(AWS)의 경우 EXP1의 TCC가 0.345(0.681)로 가장 낮으며, EXP4의 TCC가 0.418(0.705)로 가장 높았다. EXP2와 EXP3의 TCCs는 0.354(0.695)로 EXP1보다는 높았지만, EXP4보다는 낮았다. NSTD의 경우에도 EXP4의 예측결과가 다른 실험들에 비하여 가장 관측과 유사한 변동성을 가지고 있었다. EXP2와 EXP3의 TCC과 NSTD가 거의 유사하게 나타났는데, 이는 고도에 따른 기온변화의 효과가 아노말리에게 거의 영향을 주지 않음을 의미한다. 또한, EXP4의 TCC와 NSTD가 다른 실험들에 비하여 높는데, 이는 예측결과 내에 존재하는 계통적 오차가 유전자 알고리즘을 통해 잘 보정됨을 의미한다(Ahn and Lee, 2016).

Figure 9에는 각 실험의 아노말리의 예측성능을 살펴

보기 위해 범주형 결정적 분석방법인 HR과 FAR을 나타내었다. HR이 높으면서, FAR이 낮다는 의미는 예측된 기온의 결과가 평년과 비교하여 높거나, 낮거나, 동일하거나 등 삼등분으로 나누었을 때 평년대비 그해의 기온변동을 잘 예측한다는 의미이다. HR가 FAR에서도 앞서 분석 했던 TCC와 NSTD와 유사결과를 보였다(Fig. 9). 즉, 접합대순환모형에서 생산된 저해상도 예측결과인 EXP1에서 가장 낮은(높은) HR(FAR)을 보였으며, 유전자 알고리즘을 통해 계통적 오차가 보정된 EXP4에서 가장 높은(낮은) HR(FAR)을 보였다. 그리고 역거리가중법으로 생산된 1 km 고해상도 예측결과인 EXP2와 위성고도자료로 고도에 따른 기온변화가 추가된 EXP3의 결과들은 서로 유사하게 나타났다.

a) ASOS



b) AWS

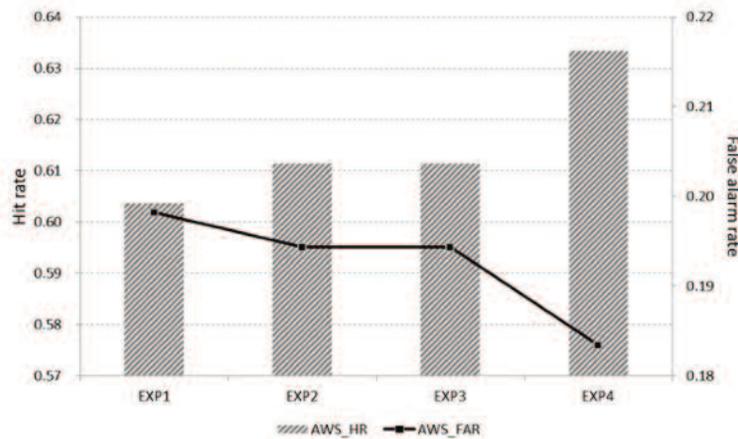


Fig. 9. Hit rate (HR, left axis) and False alarm rate (FAR, right axis) of temperature anomalies between observation and each experiment

아노말리의 경우 저해상도(EXP1) 보다는 고해상도(EXP2)에서 예측성능이 높았지만, 고해상도로 인해 향상되는 예측성의 크기는 매우 작았다. 또한, EXP2와 EXP3의 예측성능 비교를 통해 고도에 따른 기온의 변화는 아노말리에게는 크게 영향을 주지 않음을 알 수 있었다. 반면, 유전자 알고리즘으로 계통적 오차를 보정한 EXP4의 예측성능은 다른 실험들에 비해서 높게 나타났으며, 특히 시간에 따른 변동성에서 이러한 특징이 잘 나타났다. 이는 본 연구에서 제안한 새로운 방법을 통해 고해상도 격자의 질 높은 실시간 계절예보 자료를 생산할 수 있음을 의미한다.

5. 요약 및 결론

본 연구에서는 남한영역에 대하여 1 km 고해상도의 계절예측 기온자료를 생산할 뿐만 아니라 생산된 예측자료의 성능을 높이기 위하여 새로운 방법을 제안하였다. 이 새로운 방법은 역거리 가중법을 이용한 통계적 규모 축소법과 위성에서 관측된 고해상도 고도자료와 유전자 알고리즘을 이용하여 모형이 가지는 계통적 오차를 줄여서 보다 정확한 고해상도의 계절예측 기온자료를 만드는 방법이다. 이 방법은 총 4가지 단계의 실험으로 구성되어 있으며(Fig. 2), 순차적으로 진행되는 각 단계마다의 예측성능을 비교·평가하여 각 단계별 과정이 최종 결과에 미치는 영향을 살펴보았다. 첫 번째 단계인

EXP1은 PNU CGCM에서 생산된 저해상도 계절예측 기온자료이며, EXP2는 EXP1의 결과에 역거리 가중법을 적용하여 생산된 남한지역의 1 km 고해상도 계절예측 기온자료이다. EXP3는 EXP2의 결과에서 위성고도 자료인 ASTER GDEM을 이용하여 고도에 따른 기온변화를 추정된 후, 이를 적용한 계절예측 기온자료이다. 마지막으로 EXP4는 EXP3의 결과에서 유전자알고리즘을 이용하여 모형의 예측결과 내 존재하는 계통적 오차를 보정한 결과이다.

먼저 각 실험별 예측된 기후값을 살펴보면, EXP1과 EXP2에서는 고도에 따른 기온변화가 전혀 나타나지 않았다. 특히 EXP2는 1 km 고해상도 기온예측자료로 만들어졌음에도 불구하고 통계적 규모축소과정에서 관측지점과 예측지점의 거리만 고려되었기 때문에 남한의 지형적 특성이 전혀 나타나지 않았다. 반면 EXP3와 EXP4는 거리뿐만 아니라 위성고도자료를 이용하여 고도에 따른 변화도 고려하였기 때문에, 고도가 높은 산맥지역에서 기온이 낮게 나타나는 등 지형적 효과가 잘 나타났다. 이로 인하여 기온변화가 포함된 실험들(EXP3와 EXP4)은 포함되지 못한 실험들(EXP1과 EXP2)보다 낮은 RMSE를 보였으며, 고도가 높은 지점일수록 두 실험들 간에 RMSE 차이는 매우 크게 나타났다(Fig. 5b). 각 실험별 아노말리의 RMSE는 기후값의 RMSE와 비교하여 실험간의 차이가 작았으며, 기후값과는 달리 고도에 따른 영향을 크게 받지 않았다. 실험별 아노말리 예측성능을 비교하면, 거리와 고도가 함께 고려되었을 뿐만 아니라 유전자 알고리즘으로 계통적 오차가 보정된 EXP4의 RMSE가 가장 낮게 나타났으며, 그 외 다른 실험의 RMSE는 큰 차이 없이 유사하게 나타났다. TCC와 NSTD, HR, FAR에서도 유사한 결과를 보였다. EXP1이 가장 낮은 예측성능을 보였으며, 그 다음으로 EXP2와 EXP3의 예측성능이 거의 유사하게 나타났다. 그리고 시간 따른 변동성과 변동성크기, 관측과의 정량적 차이 등 EXP4의 예측성능이 모든 부분에서 가장 높았다. 이러한 결과는 새롭게 제안한 방법이 접합대순환 모형에서 생산된 저해상도 격자의 한계성을 극복하고 보다 정확한 기온 예측자료를 생산할 수 있음을 의미한다.

이처럼 본 연구에서 제안한 새로운 방법은 위성에서 관측된 고해상도 고도자료와 유전자 알고리즘을 이용

하여 전구모형에서 생산된 기온의 예측결과를 효율적으로 고해상도로 바꿈과 동시에 예측결과 내의 계통적 오차도 제거하여 고해상도 격자의 질 높은 실시간 계절예보 자료를 생산할 수 있기 때문에, 기상뿐만 아니라 농업·수문 등 다양한 분야에 사용 가능할 것으로 기대된다.

사사

이 논문은 농촌진흥청 국립농업과학원 농업과학기술 연구개발사업(과제번호: PJ009953)의 지원을 받았으며, 이에 감사드립니다.

References

- Ahn, J.B., and J.A. Lee, 2001. Numerical Study on the Role of Sea-ice Using Ocean General Circulation Model, *Atmosphere*, 6(4): 225-233 (in Korean with English abstract).
- Ahn, J.B., J.L. Lee, and E.S. Im, 2012. The reproducibility of surface air temperature over South Korea using dynamical downscaling and statistical correction, *Journal of Meteorological Society Japan*, 90(4): 493-507.
- Ahn, J.B., J. Hur, and A.Y. Lim, 2014. Estimation of fine-scale daily temperature with 30 m-resolution using PRISM, *Atmosphere*, 24(1): 101-110 (in Korean with English abstract).
- Ahn, J.B. and J.L. Lee, 2015. Comparative Study on the Seasonal Predictability Dependency of Boreal Winter 2m Temperature and Sea Surface Temperature on CGCM Initial Conditions, *Atmosphere*, 25(2): 353-366 (in Korean with English abstract).
- Ahn, J.B. and J.L. Lee, 2016. A new multimodel ensemble method using nonlinear genetic algorithm: An application to boreal winter surface air temperature and precipitation prediction,

- Journal of Geophysical Research*, 121(16): 9263-9277.
- Ahrens, C.D., 2012. *Meteorology today: An introduction to weather, climate, and the environment*, Cengage Learning, California, USA.
- Barnes, S.L., 1964. A technique for maximizing details in numerical weather map analysis, *Journal of Applied Meteorology and Climatology*, 3(4): 396-409.
- Bonan, G.B., 1998. The land surface climatology of the NCAR Land Surface Model (LSM 1.0) coupled to the NCAR Community Climate Model (CCM3), *Journal of Climate*, 11: 1307-1326.
- Branković, Č., T.N. Palmer, F. Molteni, S. Tibaldi, and U. Cubasch, 1990. Extended-range predictions with ECMWF models: Time-lagged ensemble forecasting, *Quarterly Journal of the Royal Meteorological Society*, 116(494): 867-912.
- Brunetti, M., M. Maugeri, T. Nanni, C. Simolo, and J. Spinoni, 2014. High-resolution temperature climatology for Italy: Interpolation method intercomparison, *International Journal of Climatology*, 34: 1278-1296.
- Charbonneau P., 2002. *An introduction to genetic algorithms for numerical optimization*, NCAR Technical Note TN-450 IA, National Center for Atmospheric Research, Boulder, Colo, USA.
- Choi, J.M., 2013. Spatial Accuracy of Medium Resolution ASTER GDEM Data, *The Korean Association of Professional Geographers*, 47(1): 61-69 (in Korean with English abstract).
- Cressman, G.P., 1959. An operational objective analysis system, *Monthly Weather Review*, 87: 367-374
- Daly, C., R.P. Neilson, and D.L. Phillips, 1994. A statistical-topographic model for mapping climatological precipitation over mountainous terrain, *Journal of Applied Meteorology and Climatology*, 33: 140-158.
- Frey, H., and F. Paul, 2012. On the suitability of the SRTM DEM and ASTER GDEM for the compilation of topographic parameters in glacier inventories, *International Journal of Applied Earth Observation and Geoinformation*, 18: 480-490.
- Hagedorn, R., J. Francisco, Doblus-reyes, and T. N. Palmer, 2005. *The rationale behind the success of multi-model ensembles in seasonal forecasting- I. Basic concept*. *Tellus*, 57A, 3, 219-233.
- Holland, J.H., 1975. *Adaption in Natural and Artificial Systems*. University of Michigan Press, p. 288.
- Stocker, T.F., D. Qin, G.K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, and P.M. Midgley (Eds.), IPCC, 2013. *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge Univ. Press, Cambridge, U.K.
- Kharin, V.V., F.W. Zwiers, and N. Gagnon, 2001. Skill of seasonal hindcasts as a function of the ensemble size, *Climate Dynamics*, 17: 835-843.
- Kiehl, J.T., J.J. Hack, G.B. Bonan, B.A. Boville, B.P. Briegleb, D.L. Williamson, and P.J. Rasch, 1996. *Description of the NCAR Community Climate Model (CCM3)*, NCAR Technical Note, p. 152.
- Kug, J.S., J.Y. Lee, I.S. Kang, B. Wang, and C.K. Park, 2008. Optimal Multi-model Ensemble Method in Seasonal Climate Prediction, *Journal of the Korean Meteorological Society*, 44: 259-267.
- Kim, M.K., M.S. Han, D.H. Jang, S.G. Baek, W.S. Lee, Y.H. Kim, and S. Kim, 2012. Production Technique of Observation Grid Data of 1 km Resolution, *Journal of climate research*, 7(1): 55-68 (in Korean with English abstract).
- Kim, H.J., and J.B. Ahn, 2015. Improvement in Prediction of the Arctic Oscillation with a Realistic Ocean Initial Condition in a CGCM, *Journal of Climate*, 28(22): 8951-8967.
- Lee, J.L, J.B. Ahn, and H.G. Jeong, 2016. A Study on

- the Method for Estimating the 30 m-Resolution Daily Temperature Extreme Value Using PRISM and GEV Method, *Atmosphere*, 26(4): 697-709 (in Korean with English abstract).
- Lee, S.H., I.H. Heo, K.M. Lee, S.Y. Kim, Y.S. Lee, and W.T. Kwon, 2008. Impacts of Climate Change on Phenology and Growth of Crops: In the Case of Naju, *Journal of the Korean Geographical Society*, 43(1): 20-35 (in Korean with English abstract).
- Lee, Y.H., S.K. Park, and D.E. Chang, 2006. Parameter estimation using the genetic algorithm and its impact on quantitative precipitation forecast. *Annales Geophysicae*, 24(12): 3185-3189.
- Jeong, D.I., A. St-Hilaire, T.B.M.J. Ouarda, and P. Gachon, 2012. Comparison of transfer functions in statistical downscaling models for daily temperature and precipitation over Canada, *Stochastic Environmental Research and Risk Assessment*, 26: 633-653.
- Jo, S., and J.B. Ahn, 2014. Improvement of CGCM prediction for wet season precipitation over Maritime Continent using a bias correction method, *International Journal of Climatology*, 35(13): 3721-3732.
- Jolliffe, I. T., and D.B. Stephenson, 2003. *Forecast verification: a practitioner's guide in atmospheric science*. p. 240, John Wiley, Chichester, U. K.
- Min, Y.M., V.N. Kryjov, and S.M. Oh, 2014. Assessment of APCC multimodel ensemble prediction in seasonal climate forecasting: Retrospective (1983-2003) and real-time forecasts (2008-2013), *Journal of Geophysical Research*, 119(21): 132-143
- Molteni, F., T. Stockdale, M.A. Balmaseda, G. Balsamo, R. Buizza, L. Ferranti, L. Magnusson, K. Mogensen, T. Palmer, and F. Vitart, 2011. *The new ECMWF seasonal forecast system (System 4)*. ECMWF Technical Memorandum 656, Reading, U.K.
- Pacanowski, R.C. and S.M. Griffies, 1998. *MOM 3.0 Manual*. NOAA/Geophysical Fluid Dynamics Laboratory, Princeton, USA.
- Park, C.K., W.S. Lee, and W.T. Yun, 2008. Statistical downscaling for multi-model ensemble prediction of summer monsoon rainfall in the Asia-Pacific region using geopotential height field, *Advances in Atmospheric Sciences*, 25: 867-884.
- Saha, S., and and Coauthors, 2014. The NCEP climate forecast system version 2, *Journal of Climate*, 27(6): 2185-2208.
- Skourkeas, A., F. Kolyva-Machera, and P. Maheras, 2010. Estimation of mean maximum summer and mean minimum winter temperatures over Greece in 2070-2100 using statistical downscaling methods, *Euro-Asian Journal of Sustainable Energy Development Policy*, 2: 33-44.
- Sun, J.Q., and J.B. Ahn, 2011. A GCM-based forecasting model for the landfall of tropical cyclones in China, *Advances in Atmospheric Sciences*, 28: 1049-1055.
- Sun, J.Q., and J.B. Ahn, 2015. Dynamical seasonal predictability of the arctic oscillation using a CGCM, *International Journal of Climatology*, 35(7): 1342-1353.
- Szolgay, J., J. Parajka, S. Kohnová, and K. Hlavčová, 2009. Comparison of mapping approaches of design annual maximum daily precipitation, *Atmospheric Research*, 92(3): 289-307.
- Wang, G., R. Kleeman, N. Smith, and F. Tseitkin, 2001. The BMRC coupled general circulation model ENSO forecast system, *Monthly Weather Review*, 130: 975-991.
- Wilks, D.S., 1995. *Statistical Methods in the Atmospheric Sciences*. Academic Press, p. 467.
- Yoon, S.T., 2005. Effect of Global Warming and Cropping with Vulnerability of Agricultural Production, *The Korean Society of International Agriculture*, 17(3): 199-207 (in Korean with English abstract).