

Weather Generator를 이용한 APCC 계절예측 상세화 방법 개발 - 계절확률예측 기반으로 -

Development of APCC Seasonal Prediction Downscaling Method Using
a Weather Generator - Based on Probabilistic Seasonal Forecast -

김무섭, 김원무 서비스개발팀

정여민 융합기술팀

발간사

APCC의 계절 기후 예측은 센터를 대표하는 기후정보입니다. 이 기후정보의 정확성과 정밀도를 높이기 위한 많은 연구를 수행해 왔고, 다양한 기후 인접분야에 쉽게 활용되도록 사용자 편의를 위한 관련 서비스를 개발해 왔습니다. 농업, 수자원, 보건 등에서 기후가 미치는 영향이 크고 그에 대한 적절하고 정밀한 영향평가가 중요한 시대인 만큼 APCC도 그 사회적 요구에 대해 최선을 다해 부응하는 것이 우리 사회의 기후관련 공공기관으로 해야 할 책무라고 생각합니다.

계절 기후 예측은 크게 두 가지 측면에서 높은 난이도를 보입니다. 우선, 계절 예측 자체의 어려움입니다. 우리나라를 포함한 동아시아 지역은 계절 예측성이 높지 않은 것으로 알려져 있습니다. 다른 측면에서의 어려움은 계절예측의 활용성에 있습니다. 계절예측의 시공간적인 해상도는 낮고, 계절예측 자체가 대규모 대기 순환을 중심으로 표현된 정보이기에 기후 인접분야에 직접적으로 쓰이기에 많은 난관이 있습니다. 이 연구는 활용성의 측면에서, 즉, 사용자가 더 쉽게 기후정보에 다가갈 수 있도록 노력한 결과물이라 할 수 있습니다. 기후정보에 적용되는 지역과 시간규모에 맞도록 계절예측의 시공간적 해상도를 높이고 사용자에게 친숙한 날씨관련변수를 제공함으로써 활용성을 높이하고자 하였습니다.

이 연구보고서가 발간되기까지 힘써 준 김무섭, 김원무 선임연구원, 그리고 정여민 연구원에게 큰 감사의 뜻을 전합니다. 앞으로도 APCC의 대표정보인 계절 기후 예측 성능 향상에 더 큰 노력을 기울이기를 바랍니다.

2019년 3월
APEC 기후센터
원장 권 원 태

ABSTRACT

The APEC Climate Center produces seasonal predictions of prominent climatological variables using a 2.5 degree grid system. However, agriculture and water resource management are concerned with a specific site or a narrow basin, which are only covered roughly with this grid system, and demand daily values for data such as relative humidity, solar radiation, and surface wind speed instead of large-scale circulation variables. These gaps mean that seasonal prediction data is too limited to be used widely and popularly. Therefore, we developed a statistical downscaling method to enhance the utility of the seasonal predictions. Our proposed downscaling method is based on a weather generator called “acidWG,” and it is divided mainly into precipitation and temperature models. The precipitation model consists of several parametric sub-models whose parameters are adjusted for seasonal prediction. The temperature model decomposes the daily variation in the temperature and introduces low-frequency oscillation terms that are simulated and downscaled according to seasonal predictions. Finally, we propose an algorithm for downscaling seasonal prediction based on those models. The proposed method is applied to the Nakdong river basin during MAM and SON to evaluate its performance in terms of reproducibility, validity, and predictability. Results show that the proposed method produces suitable seasonal prediction scenarios.

목 차

1. 서론	1
2. 연구자료와 대상지역	3
3. 계절예측 상세화 방법	5
3.1 APCC 계절확률예측과 관측기간 월강수/기온상태의 정의	5
3.2 acidWG 모형과 모의	7
3.2.1 강수모형과 모의	7
3.2.2 기온 모형과 모의	11
3.3 상세화 방법	16
4. 연구결과	17
4.1 재현성 평가	17
4.1.1 습윤일 강수량 분포	18
4.1.2 습윤일 강수량의 공간상관성	21
4.1.3 일최고/최저기온의 분포	24
4.1.4 기온의 공간상관성	26
4.1.5 시간적 자기상관 및 교차상관	28
4.2 계절확률예측 상세화 정보의 적절성과 예측성 평가	31

5. 결론 및 토론-----	35
5.1 결 론-----	35
5.2 토 론-----	36
Ⅱ REFERENCES-----	37

1. 서론

APEC기후센터(APCC)는 월마다 향후 6개월 동안의 계절예측(seasonal prediction)이라고 불리는 기후예측정보를 생산하여 공공에 제공한다. 그 예측정보는 다중모형앙상블(multi-model ensemble, MME) 기법으로 생산되어 안정적이고 신뢰할 수 있는 수준의 예측성을 보인다(Min et al. 2017). 계절예측은 월단위이고 위경도 2.5도 격자간격으로 강수와 기온, 지위고도(geopotential height), SST(sea surface temperature, 해수면온도), SLP(sea level pressure, 해면기압) 등 주요 기후변수들의 예측정보를 제공한다. 반면에, 계절예측의 주요 수요분야인 농업이나 수자원에서는 그 대상 지역이 특정 지점이나 작은 유역인 경우가 많고, 강수와 기온을 비롯해 상대습도, 일사량, 풍속 등의 일단위 변수가 필요하다. 그래서, 이러한 시공간적 규모와 변수의 차이로 인해, 현행의 계절예측은 농업과 수자원 분야에서 활용되는데 있어 큰 제한이 있다. 본 연구는 이러한 제한을 극복하고 계절예측 활용도를 제고하기 위해서 관련 상세화(downscaling) 기술을 개발하는 것을 목표로 한다.

김무섭(2017)은 동아시아몬순을 기반으로 계절예측상세화를 연구하였다. 한반도는 겨울과 여름에 각기 동아시아겨울/여름몬순의 영향권 아래에 있다는 점에 착안하여, 이 대규모 순환에 따른 한반도 유역기후의 반응을 통계모형으로 표현하는 통계적 상세화 방법을 제안하였다. 이 상세화 방식은 유역기후를 지배하는 뚜렷한 대규모 순환의 특징을 전제한다. 하지만, 한반도에 한해서도 봄과 가을 같이 그러한 대규모 순환을 특정할 수 없는 경우가 많아서, 적용을 확장하는데 있어 난관이 있다. 그래서, 본 연구에서는 현업적 기후서비스를 염두하며 APCC가 매월 제공하는 계절예측에 중점을 둔다. 특히, 계절예측은 크게 결정론적(deterministic) 예측과 확률적(probabilistic) 예측으로 구분되는데, 예측의 불확실성과 상세화의 용이성을 감안해서 확률예측을 기반으로 한 상세화 방법을 다룬다.

제안하고자 하는 상세화 방법은 통계적 방법으로 weather generator를 기반한다. 계절예측 상세화의 도구로서 weather generator 연구는 김무섭(2015)의 연구에서 비롯되었고, 후속연구인 김무섭(2017)과 본 연구를 통해 그 내용이 보완되었다. 특히, 본 연구에서 제안된 상세화 방법은 acidWG(APCC Climate Information Downscaling Weather Generator)라고 명명된 weather generator로 구현되었다. 현재, acidWG의

통계모형은 강수모형과 기온모형으로 구분된다. 강수모형은 여러 모수적(parametric) 하위모형으로 구성되는데, 계절예측 상세화의 핵심단계는 예측된 기후상황에 따라 그 하위모형의 모수(parameter)를 조정하는 것이다. 이는 그 모수가 강수의 일특성(daily characteristics)을 특징짓는다는 점에서 기후상황에 따라 일특성을 조정한다는 의미이다. 한편, 기온모형은 기온변동의 분해식에 기반하는데, 상세화를 위해 상대적으로 주기가 긴 저주파진동향을 도입한다. 기온 상세화는 계절예측에 따른 저주파진동향의 모의를 핵심으로 하는데, 이는 계절예측이 수개월 주기의 대규모순환의 변동을 대표하기에 저주파진동과 관련성이 클 것이라는 추측에 근거한다. 최종적으로 두 모형을 기반으로 한 계절예측 상세화 알고리즘을 제안하는데, 이를 통해 주어진 계절예측 상황 하에서 발생할 수 있는 다양한 일강수/기온 시나리오를 생산할 수 있다.

제안된 상세화 방법을 봄철과 가을철의 한반도 낙동강유역에 적용하여 그것의 성능을 평가한다. 평가 항목으로 재현성, 적절성, 예측성을 고려한다. 재현성 평가는 통상적인 weather generator의 평가 방식으로 관측자료의 특성이 시나리오 자료에서 잘 재현되는지를 확인한다. 한편, 제안된 상세화 방법이 유용한 계절예측의 상세화 정보를 생산하고 있는지에 대한 평가가 필요하다. 본 연구에서는 월누적강수량과 월평균기온과 같은 월특성을 기준으로 시나리오 자료에 의해 표현되는 월특성 분포의 적절성과 예측성을 평가한다.

이후 본 보고서의 구성은 다음과 같다: 2절에서는 본 연구에서 사용된 자료와 대상지역에 대해 기술하고, 이어 3절에서는 acidWG의 모형과 모의에 대해 설명하고 이를 기반으로 한 계절예측상세화 상세화 알고리즘을 제안한다. 4절에서는 제안된 상세화 방법을 봄철과 가을철 동안 대상지역에 적용한 평가 결과를 제시한다. 마지막 5절에서는 본 연구 보고서의 결론과 관련된 토론 내용을 언급한다.

2. 연구자료와 대상지역

본 연구에서 쓰인 자료는 크게 기상관측자료와 계절예측자료로 구분된다. 기상관측자료로 기간이 충분히 긴 ASOS(automatic synoptic observation system) 자료를 사용한다. 본 연구의 대상지역은 낙동강 유역으로, 특히, Eum et al. (2010)에서처럼 그 주변에 위치한 14개 지점을 선정하여(그림 1), 해당 관측소의 일별자료를 쓰며 기간은 1988년 1월 1일부터 2013년 12월 31일까지이다. ASOS 자료는 다양한 기상관측변수를 제공하는데, 본 연구에서는 일누적강수(mm), 일최고/최저기온자료($^{\circ}\text{C}$)를 쓴다. 이 자료는 weather generator의 통계모형을 구축하는데 사용된다.

한편, APCC 계절확률예측(probabilistic seasonal prediction) hindcast 자료를 계절예측자료로 쓴다. 이 자료는 위경도 2.5° 간격의 각 격자지점에서 지상 2m 기온(t2m), 강수(prec), 850hPa 기온(t850), 500hPa 지위고도(z500), 해수면온도(sst)의 향후 6개월까지 월별예측정보가 확률분포로 제공되는데, 본 연구에서는 지상 2m 기온과 강수자료가 쓰인다. 특히, 본 연구에서는 낙동강유역을 대상지역으로 삼기 때문에, 그림 1에서 제시된 낙동강 관측소 인근 4개의 격자지점이 연구에서 다루어진다. 자료기간은 1983년부터 2005년까지이다.




그림 1. 낙동강 유역, ASOS 관측소(적색), APCC 계절예측 격자(청색). 상단: Eum et al. (2010), 하단좌측: 김무섭 (2017)에서 발췌.

3. 계절예측 상세화 방법

3.1 APCC 계절확률예측과 관측기간 월강수/기온상태의 정의

본 연구에서는 APCC 계절확률예측의 상세화를 고려한다. 계절확률예측에서는 강수/기온의 월단위 상태를 그 수준에 따라 삼등분한다. 삼등분된 범주를 수준의 순서대로 BN(Below Normal), NN(Near Normal), AN(Above Normal)이라고 부르는데, 각각은 평년보다 낮은 수준, 평년과 비슷한 수준, 평년보다 높은 수준의 월강수량/월평균기온을 의미한다. 계절확률예측은 월강수/기온의 상태를 확률분포로 나타낸다. 예를 들어, 강수의 확률예측이 BN:30%, NN:40%, AN:30%이라면, 해당 월의 월강수량이 평년보다 낮은 확률이 30%, 평년과 비슷한 확률이 40%, 평년보다 높을 확률이 30%라는 의미이다. APCC는 각 격자지점에 대해 매월 향후 6개월 기간의 이러한 확률예측을 제공한다. 앞서 2절에서 언급하였듯이 낙동강 유역 인근에 격자지점 4개가 있는데, 각자가 약간 상이한 예측결과를 보인다. 상세화를 위해서 유역의 대표계절예측이 필요한데, 이를 얻기 위해 상태별 지점평균을 취한다: $(p_{BN,s}, p_{NN,s}, p_{AN,s})$ 이 격자지점 $s \in \{1, \dots, 4\}$ 의 강수 또는 기온상태의 확률분포라고 할 때,

$$p_{BN} = \frac{1}{4} \sum_{s=1}^4 p_{BN,s}, \quad p_{NN} = \frac{1}{4} \sum_{s=1}^4 p_{NN,s}, \quad p_{AN} = \frac{1}{4} \sum_{s=1}^4 p_{AN,s}, \quad (1)$$

을 유역대표 예측정보로 간주한다. 예를 들어, 표 1은 이러한 방식으로 가공한 2018년 8월에 발표한 APCC 계절확률예측의 결과이다. 본 연구에 대상유역에 대해서는 각 격자점의 확률예측이 크게 상이하지 않아 단순평균이 충분한 대표성을 지닌다고 볼 수 있으나, 일반적으로는 격자점과 관측지점 간 거리를 감안한 가중평균을 고려해야 대표성을 확보할 수 있을 것이다.

한편, weather generator 통계모형의 추정을 위해서 APCC 계절예측에 상응하는 관측기간 동안 유역의 월강수/기온상태도 정해야 한다. 월강수에 대해서 월누적강수량의 유역평균, 월기온에 대해서는 월평균기온의 유역평균을 대푯값으로 정하고, APCC 계절예측과 개념적 일치를 위해 관측기간 동안 월강수/기온의 분포를 삼등분하여 수준의 순

서에 따라 각 범주를 BN, NN, AN라고 정의한다. 표 2는 관측기간의 가을철 월강수/기온 상태를 제시한다.

표 1. APCC SON 낙동강 유역 대표 계절확률예측 (2018년 8월 발표)

상태	강수			기온		
	9월	10월	11월	9월	10월	11월
AN	0.25	0.22	0.34	0.69	0.56	0.59
NN	0.33	0.35	0.33	0.21	0.27	0.28
BN	0.42	0.43	0.33	0.10	0.17	0.13

표 2. 가을철 관측기간의 강수/기온상태 관측값

년도	강수			기온		
	9월	10월	11월	9월	10월	11월
1988	BN	BN	BN	NN	NN	BN
1989	AN	BN	AN	BN	BN	NN
1990	AN	BN	AN	NN	NN	AN
1991	NN	BN	BN	NN	BN	BN
1992	NN	NN	BN	BN	BN	BN
1993	NN	AN	AN	BN	BN	AN
1994	BN	AN	NN	NN	NN	AN
1995	BN	NN	BN	BN	NN	BN
1996	BN	AN	AN	NN	AN	NN
1997	BN	BN	AN	BN	BN	AN
1998	AN	AN	NN	AN	AN	NN
1999	AN	AN	NN	AN	BN	NN
2000	AN	NN	NN	BN	NN	NN
2001	NN	AN	BN	BN	AN	BN
2002	NN	AN	BN	BN	BN	BN
2003	AN	BN	AN	NN	BN	AN
2004	NN	BN	AN	NN	NN	AN
2005	NN	BN	NN	AN	NN	AN
2006	BN	NN	NN	BN	AN	AN
2007	AN	NN	BN	AN	AN	NN
2008	BN	NN	BN	AN	AN	NN
2009	BN	BN	NN	AN	AN	NN
2010	AN	NN	BN	AN	AN	BN
2011	BN	AN	AN	AN	BN	AN
2012	AN	NN	NN	NN	NN	BN
2013	NN	AN	AN	AN	AN	BN

3.2 acidWG 모형과 모의

본 연구에서 제안하는 계절예측상세화방법은 acidWG(APCC Climate Information Downscaling Weather Generator)라고 명명된 weather generator를 이용한다. 이 weather generator는 김무섭(2015)에서 제안한 통계모형을 기반해 김무섭(2017)와 본 연구에서 행해진 수정 및 보완을 거쳐 개발되었다. 현재, acidWG는 통계모형은 크게 강수모형과 기온모형으로 구성된다. 아래에서 각 통계모형과 모의를 설명한다.

3.2.1 강수모형과 모의

건조기/습윤기 교대 알고리즘 (dry/wet-spell alternating algorithm)으로 강수모의를 수행하려면 건조기생성모형과 습윤기생성모형이 필요하다. 아래 소절에서 각 생성모형을 설명한다.

3.2.1.1 건조기 생성모형

건조기(dry-spell)는 모든 유역관측지점에서 비가 내리는 않는 날의 기간을 의미하므로, 건조기생성을 위해서는 기간의 길이를 생성하는 모형으로 충분하다. 기간의 길이에 대한 통계모형으로 음이항분포를 고려한다: L 이 건조기의 길이라고 할 때,

$$\Pr(L=m+1) = \frac{\Gamma(m+\theta^L)}{m!\Gamma(\theta^L)} \left(\frac{\mu^L-1}{\theta^L+\mu^L-1} \right)^m \left(\frac{\theta^L}{\theta^L+\mu^L-1} \right)^{\theta^L}, \quad m=0,1,2,\dots, \quad (2)$$

이며, 여기서 μ^L 는 길이의 평균, θ^L 는 분포의 형태를 결정하는 모수이다. 계절예측상세화를 위해서, 월강수상태에 따라 평균 μ^L 의 값이 조정되도록 한다, 즉,

$$\mu^L = \begin{cases} \mu_{BN}^L, & \text{월 강수량이 평년수준 미만;} \\ \mu_{NN}^L, & \text{월 강수량이 평년수준;} \\ \mu_{AN}^L, & \text{월 강수량이 평년수준 초과.} \end{cases} \quad (3)$$

$\mu^L = (\mu_{BN}^L, \mu_{NN}^L, \mu_{AN}^L)$ 와 θ^L 의 모수값은 일반화선형모형적합을 통해 최대우도법으로 월 단위로 추정한다.

3.2.1.2 습윤기 생성모형

습윤기(wet-spell)는 유역의 습윤일(wet-day, 어느 한 지점에서라도 비가 오는 날)의 기간으로 정의되기 때문에, 그 생성모형은 습윤기의 길이 뿐만 아니라 각 습윤일의 강수량을 모의해야 하므로 건조기 생성모형보다 훨씬 복잡하다. 습윤기 생성모형은 습윤기 동안의 습윤상태 일간변화를 모의하는 Markov 모형과 습윤일의 강수량을 모의하는 Gaussian copula 모형으로 이루어진다.

본 연구에서 고려하는 Markov 모형은 습윤상태를 Apipattanavis(2007)에서처럼 0, 1, 2로 구분한다. 상태 0은 모든 지점에서 비가 오지 않은 경우; 습윤일의 일강수량 유역평균의 중간값을 q 라고 했을 때, 상태 1은 습윤일이지만 강수량 유역평균이 q 를 넘지 않는 경우; 상태 2는 유역평균이 q 를 넘는 경우를 의미한다. 상태 1과 2는 강수세기가 비교적 약한 경우와 비교적 강한 경우에 대응한다. Markov 모형은 습윤상태의 일간 변화를 전이확률(transition probability)로써 모의한다: 구체적으로,

$$P = \{p_{k_1, k_2} : k_1, k_2 = 0, 1, 2\}, \quad p_{0,1} + p_{0,2} = 1, \quad (i.e., \quad p_{0,0} = 0), \quad (4)$$

즉, 상태 k_1 에서 상태 k_2 로의 전이확률로 이루어진 전이확률행렬에 대해, $\{S_l : l = 0, 1, 2, \dots\}$ 이

$$S_0 = 0, \quad \Pr(S_{l+1} = k_2 | S_l = k_1) = p_{k_1, k_2}, \quad l = 0, 1, 2, \dots, \quad (5)$$

을 만족하는 Markov 사슬이고 m 이

$$S_k \neq 0, \quad k = 1, \dots, m, \quad S_{m+1} = 0 \quad (6)$$

을 만족하는 정지시간이라고 했을 때, 습윤상태의 일간변화는 $S_1, \dots, S_m$ 으로 모의되며, 습윤기 길이는 m 이다.

Markov 모형으로 습윤상태의 일간변화가 모의되고 나면 각 습윤일의 강수량을 모의해야 한다. 여러 지점의 동시적 강수량을 모의해야 하기 때문에, 지점의 강수량분포 뿐만 아니라 지점 간의 강수량 연관성을 표현할 수 있는 모형이 필요하다. 그러한 모형으로 Gaussian copula 모형을 고려한다. 우선, 지점의 강수량분포에 대한 모형으로 감마분포

를 고려한다: $R(s_j)$ 가 지점 s_j 의 강수량을 나타낸다고 했을 때,

$$H_j(x) = \Pr(R(s_j) \leq x | R(s_j) > 0) = \left\{ (\mu_j / \alpha_j)^{\alpha_j} \Gamma(\alpha_j) \right\}^{-1} \int_0^x z^{\alpha_j-1} e^{-z\alpha_j/\mu_j} dz, \quad x > 0,$$

이고, $\alpha_j > 0$ 와 $\mu_j > 0$ 은 각각 분포의 형태와 평균을 나타낸다. 공간연관성을 표현하기 위해, 습윤일의 $R(s_1), \dots, R(s_d)$ 이 ($d \in \mathbb{N}$ 는 지점 수)가 각 지점의 강수량을 나타낸다고 할 때,

$$(Z_1, \dots, Z_d) \sim N(\mathbf{0}, \Sigma), \quad p_1, \dots, p_d \in (0, 1), \quad (7)$$

에 대해

$$R(s_j) = \begin{cases} 0, & \Phi(Z_j^\circ) \leq p_j; \\ H_j^\leftarrow((\Phi(Z_j^\circ) - p_j)/(1 - p_j)), & \Phi(Z_j^\circ) > p_j. \end{cases}$$

여기서, Φ 는 표준정규분포의 누적분포함수이고, $(Z_1^\circ, \dots, Z_d^\circ)$ 은 어떤 $j \in \{1, \dots, d\}$ 에 대해 $\Phi(Z_j) > p_j$ 일 때 $(Z_1, \dots, Z_d)$ 의 조건부 확률분포를 따르는 확률벡터이다. 공분산행렬 Σ 는 실질적으로 지점 간 강수량 연관성을 표현하고 모수 p_j 는 습윤일에 지점 s_j 에서 비가 올 확률에 관여한다.

Markov 모형의 모수를 $\theta_1 = (q, P)$, 지점강수량 분포의 모수를 $\theta_2 = (\alpha_1, \dots, \alpha_d, \mu_1, \dots, \mu_d)$, 공간연관성을 표현하는 모수를 $\theta_3 = (p_1, \dots, p_d, \Sigma)$ 로 요약하면, 습윤기 생성에 관여하는 모든 모수는 $\theta = (\theta_1, \theta_2, \theta_3)$ 로 정리된다. 계절예측상세화를 위해서, 음이항분포의 평균 μ^L 에서 처럼, θ 도 역시 월강수상태에 따라 조정되도록 한다, 즉,

$$\theta = \begin{cases} \theta_{\text{BN}}, & \text{월 강수량이 평년수준 미만;} \\ \theta_{\text{NN}}, & \text{월 강수량이 평년수준;} \\ \theta_{\text{AN}}, & \text{월 강수량이 평년수준 초과.} \end{cases} \quad (8)$$

$(\theta_{\text{BN}}, \theta_{\text{NN}}, \theta_{\text{AN}})$ 의 모수값은 각 월강수상태의 관측자료를 이용해 최대우도법으로 추정한다.

3.2.1.3 강수 모의 알고리즘

앞선 소절에서 설명한 모형을 기반으로 한 강수 모의 부속 알고리즘(Algorithm 1-2)과 주(主)알고리즘(Algorithm 3)을 제안한다. 거기서, $\mathbf{R}^*(t) = (R^*(s_1, t), \dots, R^*(s_d, t))$ 는 알고리즘으로 생성된 시점 t 의 강수량을 뜻한다.

Algorithm 1 (습윤일 강수량 생성)

아래에 등장하는 모든 변수의 값은 사전에 정해졌다고 전제한다. 습윤상태 S^* 가 주어졌을 때, 아래의 단계를 통해 그 상태에 해당하는 강수량 $R^*(s_1), \dots, R^*(s_d)$ 을 생성한다.

1. $(Z_1^*, \dots, Z_d^*) \sim N(\mathbf{0}, \Sigma)$ 생성한다.

2. $U_j^* = \Phi(Z_j^*)$, $j = 1, \dots, d$ 라고 했을 때,

$$R^*(s_j) = \begin{cases} 0, & U_j^* \leq p_j; \\ H_j^{-1}\left(\frac{U_j^* - p_j}{1 - p_j}\right), & U_j^* > p_j, \end{cases} \quad \text{그리고 } S^* = \begin{cases} 0, & A^* = 0; \\ 1, & 0 < A^* \leq q; \\ 2, & A^* > q. \end{cases}$$

$$\text{단, } A^* = d^{-1} \sum_{j=1}^d R^*(s_j).$$

3. 만약 $S^* = S^*$ 이면, $R^*(s_1), \dots, R^*(s_d)$ 를 각 지점의 강수량으로 정한다. 그렇지 않으면, 1단계로 돌아간다.

Algorithm 2 (습윤기 생성)

아래에 등장하는 모든 변수의 값은 사전에 정해졌다고 전제한다. 주어진 시점 t_0 바로 다음 날부터 시작하는 습윤기를 아래 단계로 생성한다:

1. $S_0^* = 0$ 라고 두면서, 전이확률행렬 P 로 Markov 사슬 $S_1^*, \dots, S_m^*$ 을 생성한다. 단, m 은 (6)와 같이 정의되는 정지시간이다.

2. $k = 1, \dots, m$ 에 대해서, $S^* = S_k^*$ 라고 두면서 Algorithm 1을 통해 강수량 $\mathbf{R}^*(t_0 + k)$ 를 생성한다. $\mathbf{R}^*(t_0 + 1), \dots, \mathbf{R}^*(t_0 + m)$ 이 생성된 습윤기를 나타낸다.

주알고리즘을 소개하기 앞서 부속 알고리즘에서 언급된 주어진 시점 t 에서 모수값을 정하는 방식을 설명하고자 한다. 강수와 관련된 모든 모수는 기본적으로 월단위로 추정되지만, 실제적으로는 모수값이 시간에 흐름에 따라 연속적으로 변한다고 보는 것이 합리적이다. 그래서, 이러한 점을 감안하여, 주알고리즘에서 모수값은 다음과 같은 방식으로 정한다: 알고리즘 수행 중 현시점이 t 라고 할 때, 어떤 달의 중심일 t_1 과 그 다음 달의 중심일 t_2 에 사이에 있다고 한다면 (즉, $t_1 \leq t \leq t_2$), 연속하는 두 달 중 한 달을 $(t_2 - t)/(t_2 - t_1)$ 과 $(t - t_1)/(t_2 - t_1)$ 의 확률로 선택한다. 그리고 선택된 달과 그 달의 강

수상태에 따라 모수값을 정한다. 예를 들어, t 가 3월 21일 가르킨다고 할 때, t_1 은 3월 15일, t_2 는 4월 15일이 되며, 3월은 25/31의 확률로, 4월 6/31의 확률로 선택된다. 만약 4월이 선택되었다면, 현시점이 3월이어도 모든 모수는 4월의 해당 강수상태의 모수값으로 정해진다.

Algorithm 3 (강수 모의)

$\{1, \dots, L\}$ 이 모의 기간이라고 하고 ($L \in \mathbb{N}$), 기간에 속한 각 월의 강수상태가 주어졌다고 하자. 변수 t^* 의 값을 0으로 두고 변수 s 의 값을 DRY와 WET 중 하나로 무작위로 정한다. 아래와 과정을 반복하면서 모의 기간의 강수를 모의한다.

1. $t^* \geq L$ 이면, 수행을 종료한다. 그렇지 않으면 다음 단계로 간다.
2. 만약 $s = \text{DRY}$ 라면,
 - 2-1. μ^L 과 θ^L 의 값을 t^* 과 주어진 월강수상태 기준으로 앞서 설명한 방식으로 정한다.
 - 2-2. 건조기 길이 L 를 음이항 분포 (2)로부터 생성한다.
 - 2-3. $t = t^* + 1, \dots, t^* + L$ 에 대해서 $R^*(t) = 0$ 로 둔다.
 - 2-4. t^* 의 값에 L 을 더하고 s 의 값을 WET로 바꾸어, 1 단계로 이동한다.
3. 만약 $s = \text{WET}$ 라면,
 - 3-1. 습윤기 생성에 관여하는 모든 모수의 값을 t^* 과 주어진 월강수상태를 기준으로 앞서 설명한 방식으로 정한다.
 - 3-2. $t_0 = t^*$ 로 두면서 Algorithm 2를 통해 습윤기 $R^*(t^* + 1), \dots, R^*(t^* + m)$ 를 생성한다. m 은 습윤기 길이를 의미한다.
 - 3-3. t^* 의 값에 m 을 더하고 s 의 값을 DRY로 바꾸어, 1 단계로 이동한다.

3.2.2 기온 모형과 모의

시점 t 에서 지점 s 의 일최고/최저기온 $T_{\diamond}(s, t)$, $\diamond = \max, \min$ 에 대해 아래와 같은 분해를 고려한다:

$$T_{\diamond}(s, t) = E\{T_{\diamond}(s, t)\} + \Lambda_{\diamond}(s, t) + \Delta_{\diamond}(s, t) + \sigma_{\diamond}(s, t)\epsilon_{\diamond}(s, t), \quad \diamond = \max, \min. \quad (9)$$

여기서, $E\{T_{\diamond}(s, t)\}$ 는 관측기간의 평균적 기온추세, $\Lambda_{\diamond}(s, t)$ 은 저주파 진동, $\Delta_{\diamond}(s, t)$ 은 강수효과인데, 이들의 합 $E\{T_{\diamond}(s, t)\} + \Lambda_{\diamond}(s, t) + \Delta_{\diamond}(s, t)$ 는 시점 t 의 기온평균을 의미하고, $\sigma_{\diamond}(s, t)$ 는 표준편차, $\epsilon_{\diamond}(s, t)$ 는 표준화된 anomaly를 뜻한다. 분해를 위한 각 요소의 구체적인 모형과 추정은 김무섭(2015, 2017)을 참고하기를 바란다. 그림 2는 안동지점의 2010년 MAM기간에서 안동지점의 일최고기온의 분해 결과를 보여 준다. 분해를 통해 적절히 저주파 진동을 얻은 것으로 판단된다. 또한, 그림 3은 저주파진동의 공간적 동질성과 경년변동성을 확인해 주고 있다.




그림 2. 2010년 MAM 기간 안동지점의 일최고기온(화색연결선)의 분해 (최상단): 기온추세(흑색파선), 기온추세+저주 파진동(적색실선), 기온추세+저주파진동+강수효과(청색연결선). 저주파 진동(중간)과 anomaly 시계열 그림 (최하단). 저주파진동이 주기가 긴 기온진동을 표현한다면 anomaly는 상대적으로 주기가 짧은 고주파수대의 진동을 나타낸다. 주기가 긴 저주파진동이 수개월단위 주기로 진행되는 대규모순환과 관련이 있을 것으로 추측 된다.




그림 3. 각 관측년도에서 모든 지점의 저주파 진동. 저주파 진동은 뚜렷한 공간동질성과 경년변동성을 드러낸다.

김무섭(2017)은 분해를 통해 얻어진 저주파 진동이 동아시아 몬순순환에 유의하게 반응함을 확인하고 이를 기반으로 상세화 기법을 제안하였다. 이는 저주파 진동이 수개월 주기로 진행되는 대규모 순환과 관련되었다는 추측에 기반하였다. 계절예측도 역시 월단 위의 대규모 순환 예측에 기반하기 때문에, 그 추측의 근간을 계절예측 상세화에도 적용하고자 한다. 그런데, 기온계절예측에서 예측대상변수는 지상 2m 일평균기온의 월평균인 반면에 acidWG는 강수와 더불어 일최고/최저기온만을 다룬다. 그래서, 본 연구에서는 $T_{avg} = (T_{max} + T_{min})/2$ 로 일평균기온을 대용한다. 앞서 언급한 근간에 기반한 계절예측상세화를 위해서, 주어진 계절예측에 상응하는 저주파 진동을 생성하는 기법이 필요하다. 아래에서 생성기법을 제안하는데,

$$\mathbf{A}_i(t) = (\mathbf{A}_{i,max}(s_1, t), \dots, \mathbf{A}_{i,max}(s_d, t), \mathbf{A}_{i,min}(s_1, t), \dots, \mathbf{A}_{i,min}(s_d, t)), \quad \mathbf{W}_i = (W_{i,1}, \dots, W_{i,M})$$

로서, 전자는 관측년도 i 에 지점 $s_1, \dots, s_d$ 의 일최고/최저기온 저주파진동으로 이루어

진 벡터이고, $W_{i,k}$, $k = 1, \dots, M$ (M 은 예측기간 길이)은 동일년도에 관측된 예측대상시기의 k 번째 월평균기온의 유역평균값을 나타낸다.

Algorithm 4 (저주파진동 생성)

$i = 1, \dots, n$ 이 총 관측년도를 나타내고, $\bar{W} = \frac{1}{n} \sum_{i=1}^n W_i$, $\bar{A}(t) = \frac{1}{n} \sum_{i=1}^n A_i(t)$ 라고 하자. 각 월 기온상태가 주어졌을 때, 다음의 단계로 저주파 진동을 생성한다:

1. 정규분포 $N(0, 1/n)$ 로부터 난수 $\eta_1, \dots, \eta_n$ 를 생성하여

$$(W_1^*, \dots, W_M^*) = \sum_{i=1}^n \eta_i (W_i - \bar{W}) + \bar{W} \quad (10)$$

를 얻는다.

2. 각 W_k^* ($k = 1, \dots, M$)로 정해지는 기온상태가 주어진 해당 월 기온상태와 동일인지 확인한다. 한 월에서도 일치하지 않으면 1 단계로 돌아간다.
3. 1 단계에서 생성된 $\eta_1, \dots, \eta_n$ 를 이용해, 저주파 진동

$$A^*(t) = \sum_{i=1}^n \eta_i \{A_i(t) - \bar{A}(t)\} + \bar{A}(t) \quad (11)$$

를 생성한다.

그림 4을 통해 Algorithm 4의 의미를 설명하고자 한다. 그림에서처럼 식 (11)을 통해 난수 $\eta_1, \dots, \eta_n$ 생성으로 과거기간의 통계적 특성을 유지하는 다양한 저주파 진동을 생성할 수 있다. 하지만, 알고리즘의 궁극의 목표는 주어진 계절예측의 상태에 맞는 저주파진동을 생성하는 때문에, 이를 위해 저주파진동과 더불어 월평균기온도 식 (10)를 통해 함께 생성하여 그림 4나 Algorithm 4의 2 단계에서처럼 각 월에서 월평균기온을 기준으로 기온상태를 확인한다. 위 알고리즘에서 주어진 계절예측과 동일한 기온상태가 나올 때까지 이 생성과 확인 과정을 반복한다.




그림 4. 난수 $\eta_1, \dots, \eta_n$ 에 따른 저주파진동(회색선)과 월평균기온의 편차(흑색실선). 적색파선은 각 월의 월평균기온의 NN과 AN 경계선, 청색파선은 BN과 NN의 경계선이고, 각 월의 월평균기온편차값에 따라 그 월의 기온상태가 정해진다. 각 그림 상단에 각 월의 상태가 제시되어 있다.

기온모의를 위한 알고리즘은 김무섭(2017)에서 제안된 기온시나리오 생성 알고리즘과 저주파 생성을 제외하면 나머지는 동일하다. 아래는 계절예측 상세화 기온모의 알고리즘이다:

Algorithm 5 (기온 모의)

강수 시나리오와 각 월의 기온상태가 주어졌다고 하자. 다음 단계를 시행해 기온 시나리오를 생성한다.

1. 주어진 월기온상태에 대해 Algorithm 4로 저주파진동 $\Delta_{\max}$, $\Delta_{\min}$ 을 생성한다.
2. 강수시나리오부터 강수효과 $\Delta_{\max}$, $\Delta_{\min}$ 와 표준편차 $\sigma_{\max}$, $\sigma_{\min}$ 를 김무섭(2017)의 식 (8)와 (10)에 따라 얻는다.
3. 김무섭(2017)의 부록에서 주어진 Anomaly 생성 알고리즘으로 $\epsilon_{\max}$, $\epsilon_{\min}$ 를 생성한다.
4. 식 (9)을 통해 일최고/최저기온 값을 얻는다.

3.3 상세화 방법

이제, 최종적인 계절예측 상세화 알고리즘을 제안하면서 본 절을 마무리 하고자 한다. 3.1절의 표 1처럼 유역을 대표하는 계절확률예측이 주어졌다고 전제한다.

Main Algorithm (계절확률예측 상세화)

유역대표 계절확률예측이 주어졌고, 상세화 시나리오 개수를 N 으로 정해졌다고 하자. 다음의 단계를 반복해 N 개 시나리오를 얻는다.

1. 계절예측의 확률분포로 각 월의 강수/기온상태를 결정한다.
2. 결정된 강수상태로 Algorithm 3를 통해 강수시나리오를 생성한다.
3. 결정된 기온상태와 2 단계에서 생성된 강수시나리오로 Algorithm 5를 통해 기온 시나리오를 생성하여, 하나의 계절예측상세화 강수/기온 시나리오를 만든다.

본 연구에서 Main Algorithm의 N 은 1000으로 정한다.

4. 연구결과

본 절에서는 3.3절에서 제안한 상세화방법을 낙동강 유역의 봄철(MAM)과 가을철(SON)에 적용한 결과를 제시한다.

4.1 재현성 평가

우선, 상세화방법의 재현성(reproducibility)을 평가한다. 즉, acidWG가 주어진 강수/기온의 월상태에 상응하는 동일변수의 일특성(daily characteristics)을 시나리오로 재현하고 있는지의 확인이 필요하다. 재현성 평가를 위한 참조자료(reference data)로 추정에 쓰인 관측자료를 쓴다. 또한, Main Algorithm를 통해 시나리오를 생성할 때, 그것의 1단계를 과거기간의 계절상태를 무작위로 선정하는 것으로 대신한다. 예를 들어, 가을철의 경우에 표 2에서 한 해를 무작위로 선정하여 강수/기온의 월상태를 결정한다. 이는 가능한 과거기간과 유사한 계절상황 하에서 시나리오를 생산하기 위함이다. 이 1단계가 변경된 알고리즘의 수행을 변수(강수/기온)와 월(봄철:3-5월, 가을철: 9-11월)의 모든 조합에 대해 각 상태 당 1000개의 시나리오 자료를 생성할 때까지 반복한다. 그 결과, 봄/가을 각 계절에 대해서, 변수(강수/기온)과 월(봄철:3-5월, 가을철:9-11월), 그리고 상태(BN/NN/AN)의 18개 각 조합에 대해 시나리오 1,000개, 총 18,000개의 시나리오를 생산하게 된다. 각 시나리오는 길이가 3개월로서 해당조합의 변수가 그 월에 그 상태인 경우에서 생산되었다. 예를 들어, (기온, 3월, BN)조합의 시나리오는 월기온상태가 3월에 BN인 경우에서 생산된 봄철 3개월 일강수/기온자료이다.

재현성 평가는 각 조합의 시나리오 자료와 동일조건의 과거기간 관측자료에 대해 동일한 통계량을 계산하고 비교하는 것으로 실시된다. 예를 들어, (기온, 9월, BN)조합에 대한 재현성 평가는 관측9월평균기온이 BN인 해인 1989, 1992, 1993, 1995, 1997, 2000, 2001, 2002, 2006년 표 2의 관측자료만을 참조자료로 사용하여 실시한다. 본 연구에서 비교할 통계량으로서, 습윤일 강수량 분포; 지점 간 강수량 상관계수; 일최고/최저기온 분포, 지점 간 기온 상관계수; 시간적 자기/교차상관계수이다.

4.1.1 습윤일 강수량 분포

습윤일 강수량 분포의 시나리오와 관측자료 간 일치성을 확인하기 위해서 양의 강수량에 대해서 카이제곱적합도 검정과 무강수확률에 대해서는 t-검정을 실시하였다. 통상적으로 분포일치성은 K-S(Kolmogorov-Smirnov) 검정법을 적용해 확인하지만, 강수량의 경우에 관측이 0.1mm 단위로 이루어져 0.0mm 인근 범위에서 동일한 관측값이 종종 발생한다. 이는 K-S 검정의 정확성을 저해한다. 그래서, K-S 검정 대신에, $(0, \infty)$ 를 시나리오 강수량의 20, 40, 60, 80%분위수로 구분하여 다섯 개의 범위를 만들고, 관측자료 강수량의 상대빈도를 계산한다. 만약 분포가 일치한다면, 상대빈도는 $(1/5, 1/5, 1/5, 1/5, 1/5)$ 와 유사하게 나타날 것이고, 우리는 이를 카이제곱 적합도 검정법으로 확인한다. 또한, 습윤일의 정의상, 특정 한 지점에서는 비가 오지 않을 가능성이 있는데, 무강수확률은 그 가능성을 의미한다. 무강수확률의 시나리오와 관측자료 간 일치성을 확인하기 위해 t-검정을 적용하였다. 그림 5은 3월 강수에 대한 습윤일 분포 일치성 검정 결과이다. 유의수준 5%에서 세 경우에서 유의한 차이가 보이고, 그림 6은 세부적인 확인을 위한 여러 분포비교그림을 제공하고 있다.

우리는 모든 월에 대해 동일한 방식으로 검정하였으나 지면관계상 결과 전부를 제시할 수 없다. 대신, 결과의 요약적인 제시를 위해 유의수준 5%에서 유의한 차이가 보이는 지점의 수를 표 3에서 제시한다. 그 결과, 10월의 BN 월강수상태에서 상대적으로 큰 차이를 보인다. 그림 7은 해당경우에 대한 분포비교그림을 제시하는데, acidWG가 강수량 분포를 과대모의하는 것으로 보인다.




그림 5. 3월 습윤일 강수량 분포에 대한 카이제곱검정과 t-검정결과. 각 칸의 상단값은 카이제곱검정, 하단값은 t-검정의 유의확률을 나타낸다. 적색으로 표시된 경우는 5% 유의수준에서 분포차이가 유의한 것으로 나타난다.




그림 6. 3월 습윤일 강수량 분포 검정에서 유의한 차이를 보이는 경우의 분포 비교 그림. 왼쪽 상단: 히스토그램(관측)과 밀도함수(시나리오, 파선) 비교, 오른쪽 상단: Q-Q plot, 왼쪽 하단: log-scale에서 Q-Q plot, 무강수확률값 비교. 이 그림들을 통해 어떤 점에서 분포차이가 있는지 확인한다.

표 3. 습윤일 강수량 분포 재현성 평가 결과: 유의수준 5%에서 차이는 보이는 자점의 수. 10월의 월강수상태가 BN인 경우에서 상대적으로 큰 차이를 보인다.

	봄철			가을철		
	3월	4월	5월	9월	10월	11월
BN	0/14	0/14	0/14	1/14	4/14	1/14
NN	2/14	2/14	1/14	1/14	2/14	1/14
AN	1/14	0/14	1/14	0/14	1/14	1/14




그림 7. 10월 BN 월강수상태의 습윤일 강수량 분포 검정에서 유의한 차이를 보였던 경우에 대한 분포비교그림. 왼쪽 상단: 히스토그램(관측)과 밀도함수(시나리오,파선) 비교, 오른쪽 상단: Q-Q plot, 왼쪽 하단: log-scale에서 Q-Q plot, 무강수확률값 비교. 전반적으로 강수량 분포가 과대모의되고 있다.

4.1.2 습윤일 강수량의 공간상관성

acidWG는 다지점 weather generator로서 공간상관성을 재현하는 것이 주요하게 요구된다. 여기서, 습윤일 강수의 지점 간 상관성이 잘 재현되는지를 확인하고자 한다. 지점 간 상관성의 측도로 크게 Pearson, Spearman의 상관계수와 log-odds ratio를 고려한다. Pearson 상관계수는 통상적으로 많이 쓰이는 상관계수로, 두 지점의 편차곱의 평균에 기반하는 반면에 Spearman 상관계수는 순위(rank)에 기반하기 때문에 자료의 비대칭성이나 이상점의 영향을 줄이기 위해 사용된다. 한편, log-odds ratio는 두 지점의 강수발생여부를 기준으로 상관성을 재는 계수로 두 지점에 동시에 강수가 발생하거나 발생하지 않은 빈도수와 그 반대 경우의 빈도수 간 비(比)의 log 함수값으로 정의된다.

그림 8은 3월의 모든 지점 간 (총 $91 = \binom{14}{2}$ 개) 상관관계를 비교한 결과이다. 그림에서 회색구간은 시나리오 자료를 기준으로 구해진 관측상관계수 분포의 95% 범위(2.5%-97.5%)

로서, 파선으로 표시된 기울기 1인 직선을 포함하고 있지 않으면 관측과 시나리오 간 상관계수가 5% 유의수준에서 차이가 있음을 뜻한다. 그림에서 확인할 수 있는 바와 같이 상관관계가 잘 모의되고 있는 것으로 판단된다. 요약적인 비교결과를 제시하기 위해서, 관측 상관계수와 시나리오 상관계수의 절대차(絶對差)의 평균과 5% 유의수준에서 차이가 나는 지점 쌍의 개수를 제시한다. 표 4-5에서 보여지듯이, 대체적으로 공간상관이 잘 모의되는 것으로 판단되지만, 10월 월강수상태가 BN인 경우에서 Pearson 상관계수의 큰 차이가 감지된다. 그림 9은 해당경우의 상관계수 비교그림을 제시하는데, Pearson 상관계수가 과대모의되고 있음을 알 수 있다. 반면에 Spearman 상관계수가 어느 정도 모의되고 있는 점을 감안할 때, 그 과대모의는 습윤일 강수량 분포의 과대모의에서 기인한 것으로 추측된다.




그림 8. 3월 습윤일 강수량 지점 간 상관계수의 비교. 회색구간은 관측상관계수의 95% 범위를 시나리오자료를 계산한 결과로, 기울기 1인 직선(파선)을 포함하고 있지 않으면 시나리오와 관측 간 상관계수 차이가 5% 수준에서 유의함을 의미한다.

표 4. 봄철 공간 상관성 재현성 평가결과. 유의성 검정 결과는 상관계수 차이가 5% 수준에서 유의한 지점 쌍의 전체 비율을 의미한다.

		Pearson			Spearman			log odds ratio		
		3월	4월	5월	3월	4월	5월	3월	4월	5월
절대차의 평균	BN	0.076	0.099	0.079	0.029	0.026	0.049	0.199	0.153	0.208
	NN	0.034	0.051	0.037	0.028	0.028	0.046	0.204	0.174	0.217
	AN	0.027	0.055	0.036	0.030	0.043	0.030	0.158	0.208	0.106
유의성 검정	BN	2/91	7/91	3/91	0/91	0/91	1/91	0/91	6/91	0/91
	NN	0/91	0/91	1/91	0/91	2/91	3/91	1/91	1/91	0/91
	AN	2/91	2/91	8/91	4/91	4/91	6/91	0/91	8/91	0/91

표 5. 가을철 공간 상관성 재현성 평가결과. 10월 월강수상태가 BN인 경우, Pearson 상관계수의 차이가 크다.

		Pearson			Spearman			log odds ratio		
		9월	10월	11월	9월	10월	11월	9월	10월	11월
절대차의 평균	BN	0.074	0.313	0.080	0.055	0.098	0.042	0.189	0.177	0.190
	NN	0.065	0.066	0.037	0.027	0.039	0.042	0.141	0.186	0.157
	AN	0.043	0.062	0.035	0.067	0.054	0.052	0.274	0.253	0.183
유의성 검정	BN	0/91	36/91	0/91	4/91	0/91	0/91	5/91	5/91	1/91
	NN	0/91	0/91	0/91	0/91	0/91	1/91	15/91	1/91	0/91
	AN	3/91	0/91	1/91	0/91	4/91	2/91	16/91	12/91	2/91




그림 9. 10월 습윤일 강수량 지점 간 상관계수의 비교. 회색구간은 관측상관계수의 95% 범위를 시나리오자료를 계산한 결과로, 기울기 1인 직선(파선)을 포함하고 있지 않으면 시나리오와 관측 간 상관계수 차이가 5% 수준에서 유의함을 의미한다. BN 월강수량상태의 Pearson 상관계수가 과대모의되고 있다.

4.1.3 일최고/최저기온의 분포

이제, 일최고/최저기온의 분포에 대한 재현성을 평가한다. 분포 일치성 검정은 K-S 검정법을 이용한다. 표 6은 앞서 습윤일 강수량 분포 검정에서처럼 K-S 검정에서 5% 유의수준에서 차이가 있는 것으로 나타나는 지점의 수를 제시한다. 그 결과, 대체적으로 기온분포가 잘 모의되지만, 9월 AN 기온상태의 일최고기온 분포가 모의가 잘 안되는 것으로 판단된다. 그림 10은 일최고기온 분포가 차이가 유의한 지점의 분포비교그림을 제시한다. 대략 중간값 이하의 범위에서 기온이 과대모의되는 것으로 보인다.

표 6. 일최고/최저기온 분포 재현성 평가 결과: 유의수준 5%에서 차이는 보이는 지점의 수. 9월 월기온상태가 AN인 경우에서 상대적으로 분포 차이가 심한 것으로 보인다.

		봄철			가을철		
		3월	4월	5월	9월	10월	11월
일최고기온	BN	2/14	0/14	0/14	0/14	0/14	0/14
	NN	0/14	0/14	0/14	0/14	0/14	0/14
	AN	0/14	0/14	0/14	5/14	0/14	0/14
일최저기온	BN	0/14	0/14	0/14	0/14	0/14	0/14
	NN	0/14	0/14	0/14	0/14	0/14	0/14
	AN	0/14	0/14	0/14	0/14	0/14	0/14




그림 10. 9월 AN 월기온상태의 경우에서 일최고기온분포가 유의하게 차이나는 지점의 분포비교그림: 대략 중간값 이하 범위에서 분포가 과대모의되고 있다.

4.1.4 기온의 공간상관성

기온에 대해서 공간상관성의 재현성을 평가한다. 강수와 달리 기온의 경우는 분포의 비대칭성이 심하지 않기 때문에 Pearson 상관계수만을 고려한다. 요약적으로 평가결과를 제시하기 위해서, 강수의 경우에서처럼 관측상관계수와 시나리오상관계수 간 절대차의 평균과 5%유의수준에서 차이가 나는 지점 쌍의 개수의 비율을 제시한다. 표 7-8를 그 결과는 제시하는데, 강수경우에 비해, 절대차의 평균(표 7)이 훨씬 더 작은 반면에 차이가 나타나는 지점 쌍의 개수(표 8)는 더 많다. 그림 11에서 나타나는 것처럼 기온의 공간상관은 강수보다 강한데, 상관계수값이 1에 가까울수록 상관계수 추정의 불확실성은 낮아진다. 또한, 강수의 경우에는 습윤일의 자료만 쓰는 있는 반면에 기온에 대해서는 기간의 모든 날의 자료를 사용해서 더 많은 표본수를 확보하기 때문에, 상관계수의 작은 차이를 더 잘 탐지해서 표 7과 8간 결과 차이가 나는 것으로 추측된다. 유의한 차이가 나는 지점쌍 수가 많기는 하지만 절대차 평균이 작은 것을 감안해서, 수용할 수 있는 수준에서 기온이 공간상관이 모의 되고 있는 것으로 결론짓는다.

표 7. 절대차 평균을 통한 기온 공간상관 재현성 평가: 강수의 경우와 비교할 때, 절대차 평균이 훨씬 작다.

		봄철			가을철		
		3월	4월	5월	9월	10월	11월
일최고기온	BN	0.008	0.019	0.034	0.043	0.049	0.021
	NN	0.021	0.019	0.013	0.021	0.015	0.028
	AN	0.007	0.016	0.021	0.053	0.015	0.011
일최저기온	BN	0.019	0.020	0.041	0.023	0.013	0.079
	NN	0.016	0.021	0.043	0.023	0.012	0.035
	AN	0.015	0.030	0.021	0.040	0.032	0.050

표 8. 유의성 검정을 통한 기온 공간상관 재현성 평가: 유의성 검정에서 차이가 있는 지점 쌍의 수. 강수의 경우와 비교할 때, 유의한 차이가 나타나는 지점 쌍 수가 더 많다.

		봄철			가을철		
		3월	4월	5월	9월	10월	11월
일최고기온	BN	4/91	16/91	48/91	46/91	74/91	10/91
	NN	25/91	12/91	2/91	0/91	0/91	28/91
	AN	3/91	11/91	18/91	56/91	2/91	2/91
일최저기온	BN	11/91	4/91	27/91	4/91	0/91	76/91
	NN	1/91	5/91	36/91	8/91	0/91	30/91
	AN	1/91	19/91	2/91	54/91	24/91	79/91




그림 11. 9월 기온의 상관계수 비교 그림. 관측상관계수 분포의 95% 범위가 상관계수가 1에 가까울수록 좁아진다. 그래서, 상관계수의 절대적 차이는 상대적으로 적으나 유의성 검정에서 더 자주 차이가 유의하게 나타난다.

4.1.5 시간적 자기상관 및 교차상관

재현성 평가의 마지막 일특성으로 기온의 시간적 자기상관과 교차상관의 재현성을 평가하고자 한다. 앞서 공간상관의 재현성 평가에서 보았듯이 기온은 강한 양의 공간상관성을 지니고 있기 때문에, 간략성을 위해 일최고/최저기온, 그리고 일강수량의 대푯값으로 그것의 유역평균에 대해서 재현성을 평가한다. 그림 12과 13은 각각 3월의 자기상관함수와 교차상관함수를 나타낸다. 그림에서 시나리오의 상관계수는 흑색, 관측은 적색으로 표시되었으며, 각 시차에서 구간은 시나리오 자료를 이용해 계산한 관측상관계수 분포의 95% 범위이다. 이를 통해 앞선 경우에서처럼 계수 간 차이 유의성 검정을 한다. 표 9-10은 각각 봄철 자기상관과 교차상관의 재현성 평가 결과를 절대차평균(관측계수와 시나리오 계수 간의 절대차의 시차에 대한 평균)과 유의성 검정에서 계수 간 차이가 유의한 시차의 개수로 제시한다. 한편 표 11-12은 동일한 방식의 평가를 가을철에 적용한 결과이다. 봄철의 경우, 일최저기온과 강수 간 교차상관이 일치도가 다른 경우의 교차상관보다 더 좋은 것으로 나타난다. 반면에, 가을철 11월에서 월기온상태가 AN인 경우에서 일최저기온의 자기상관이 잘 모의되지 않는데, 그림 14에서 드러나듯이, 관측에서 일최저기온의 지속성이 다른 월기온상태에서보다 더 강한 것으로 판단된다.




그림 12. 3월 일최고/최저기온 자기상관그림. 시나리오의 자기상관계수(흑색), 관측의 자기상관계수(적색). 각 시차(1~5일)에서 구간은 시나리오 자료를 이용해 구한 관측자기상관계수의 95% 범위이다. 구간이 관측값을 포함하고 있지 않으면 5%유의수준에서 계수 간 차이가 있음을 의미한다.




그림 13. 3월 일최고기온, 일최저기온, 그리고 유역평균 일강수량 간 교차상관그림. 시나리오의 교차상관계수(흑색), 관측의 교차상관계수(적색). 각 시차(-5~+5일)에서 구간은 시나리오 자료를 이용해 구한 관측자기상관계수의 95% 범위이다. 구간이 관측값을 포함하고 있지 않으면 5%유의수준에서 계수 간 차이가 있음을 의미한다.

표 9. 봄철 자기상관 재현성 평가결과. 유의성 검정 결과는 자기상관계수 간 차이가 유의한 시차의 전체비율을 나타낸다.

		일최고기온			일최저기온		
		3월	4월	5월	3월	4월	5월
절대차평균	BN	0.108	0.041	0.054	0.051	0.013	0.078
	NN	0.098	0.023	0.009	0.088	0.038	0.044
	AN	0.096	0.091	0.030	0.042	0.065	0.032
유의성 검정	BN	1/5	0/5	1/5	0/5	0/5	1/5
	NN	2/5	0/5	0/5	2/5	0/5	0/5
	AN	2/5	1/5	0/5	0/5	1/5	0/5

표 10. 봄철 교차상관 재현성 평가결과.

		TMAX-TMIN			TMAX-PRCP			TMIN-PRCP		
		3월	4월	5월	3월	4월	5월	3월	4월	5월
절대차 평균	BN	0.106	0.094	0.079	0.094	0.067	0.077	0.055	0.050	0.088
	NN	0.090	0.066	0.108	0.062	0.071	0.070	0.061	0.046	0.056
	AN	0.072	0.079	0.070	0.087	0.079	0.046	0.059	0.076	0.055
유의성 검정	BN	4/11	2/11	2/11	3/11	2/11	3/11	1/11	0/11	4/11
	NN	2/11	1/11	5/11	2/11	3/11	2/11	0/11	1/11	1/11
	AN	3/11	2/11	2/11	2/11	3/11	1/11	1/11	3/11	3/11

표 11. 가을철 자기상관 재현성 평가결과. 11월 월기온상태가 AN인 경우에서 자기상관계수 간 차이가 크다.

		일최고기온			일최저기온		
		9월	10월	11월	9월	10월	11월
절대차평균	BN	0.035	0.055	0.080	0.046	0.070	0.082
	NN	0.047	0.083	0.120	0.032	0.095	0.059
	AN	0.061	0.038	0.054	0.105	0.043	0.133
유의성 검정	BN	0/5	0/5	0/5	0/5	0/5	2/5
	NN	0/5	0/5	2/5	0/5	1/5	0/5
	AN	2/5	0/5	0/5	2/5	1/5	4/5

표 12. 가을철 교차상관 재현성 평가결과.

		TMAX-TMIN			TMAX-PRCP			TMIN-PRCP		
		9월	10월	11월	9월	10월	11월	9월	10월	11월
절대차 평균	BN	0.048	0.117	0.090	0.043	0.078	0.062	0.058	0.049	0.049
	NN	0.069	0.096	0.090	0.041	0.085	0.074	0.065	0.052	0.054
	AN	0.060	0.090	0.091	0.043	0.100	0.082	0.053	0.063	0.056
유의성 검정	BN	0/11	4/11	3/11	0/11	2/11	2/11	0/11	1/11	1/11
	NN	1/11	2/11	2/11	0/11	4/11	2/11	0/11	0/11	1/11
	AN	0/11	3/11	1/11	0/11	5/11	2/11	0/11	2/11	1/11




그림 14. 11월의 일최저기온의 자기상관함수: 월기온상태가 AN인 경우 자기상관함수 간에 차이가 비교적 크다. 관측의 지속성이 다른 월기온상태에서보다 강하다.

4.2 계절확률예측 상세화 정보의 적절성과 예측성 평가

본 절에서는, APCC 계절확률예측 hindcast 자료에 제안된 방법을 적용해 얻은 상세화 정보를 평가하고자 한다. 봄철(MAM)과 가을철(SON)의 계절시작 1달 선행 (봄철은 2월, 가을철은 8월에 생산) 계절확률예측으로 식(1)을 통해 표 1과 같은 유역대표 계절확률예측을 만들어 Main Algorithm을 적용한다. 그 결과, 각 계절에 대해 hindcast 기간 (1983-2005년)의 매해마다 $N=1000$ 개 시나리오를 얻는다. 여기서, 계절예측 상세화 시나리오 자료로부터 얻어진 주요 월특성(monthly characteristics) 정보의 적절성과 예측성을 평가한다. 본 연구에서는 월특성으로 월누적강수량과 월평균기온의 유역평균을 고려한다.

앞선 언급에서처럼 hindcast 기간 매해마다 1000개의 시나리오가 있기 때문에 월특성값도 같은 수만큼 확보할 수 있고, 그래서 사실상 월특성의 확률분포를 얻는다. 이 확률분포가 상세화 방법으로 얻어진 월특성의 정보에 해당한다. 반면에, 관측자료에 대해서는 관측의 일회성 때문에 관측기간의 해마다 월특성의 한 값이 주어진다. 예를 들어, 표 13는 hindcast 기간과 관측기간의 공통기간 동안 4월의 계절확률예측결과와 월평균기온 실관측값을 제시하고, 그림 15는 제안된 상세화 방법을 통해 얻어진 각 해의 월평균기온의 확률분포와 실관측값의 위치를 나타낸다.

상세화로 얻어진 월특성의 분포와 실관측값을 각각 F_i 와 x_i 라고 표현하자. 여기서, 첨자 i 는 hindcast 기간과 관측기간의 공통기간 $I = \{1, \dots, n\}$ 의 해를 나타낸다. 시나리오 자료의 적절성은 각 x_i 가 F_i 로부터 나온 표본점(sample point)으로 볼 수 있는지로 평가할 수 있다. 만약 그렇다면, $\{\Phi^{-1}(F_i(x_i)) : i \in I\}$ 는 표준정규분포를 따라 실수축 상에 분포한다, (Φ 는 표준정규분포의 누적분포함수). 그러므로, 적절성 평가는 $\{\Phi^{-1}(F_i(x_i)) : i \in I\}$ 에 대한 정규성 검정으로 실시할 수 있다. 한편, 상세화 방법으로 얻어진 F_i 가 x_i 를 예측하는데 있어 얼마나 유용한지를 확인할 필요가 있다. 이는 통상적인 예측성 척도인 MSE를 계산해 평가할 수 있다. 즉, X_i 가 F_i 를 따르는 확률변수라면, $MSE = E[(X_i - x_i)^2]$ 이다. 그런데, MSE 값은 해 i 에 따라 변동이 있으므로, 해에 대한 평균값

$$AMSE(\text{Average MSE}) = \frac{1}{n} \sum_{i=1}^n E[(X_i - x_i)^2]$$

을 취한다. 이 예측성의 하한으로서 계절확률예측정보가 없는 경우, 즉, $p_{BN} = p_{NN} = p_{AN} = 1/3$ 일 때, 상세화 방법의 월특성분포에 대한 AMSE를 $AMSE_b$ 이라고 한다면, 예측성 평가는 최종적으로 두 AMSE의 비 $AMSE/AMSE_b$ 로 실시한다. 비의 값이 1보다 작으면 계절예측이 유의미하다고 할 수 있다.

봄철과 가을철의 각 월에 대해서 앞서 설명한 평가방법을 적용한 결과를 표 14-15에 걸쳐 제시한다. 표 14에 따르면, 상세화로 얻어진 월특성분포는 유의수준 5%에서 대체적으로 적절한 것으로 판단되지만, 5월 월평균기온의 경우는 양의 방향으로 편이가 감지된다(그림 16). 한편, 표 15의 예측성 평가 결과에서는 강수의 경우에는 예측성이 낮거나 없지만, 기온의 경우는 상대적으로 높은 것으로 판단된다.

표 13. hindcast 기간과 관측기간의 공통기간(1988-2005) 동안 봄철 4월의 계절확률예측과 월평균기온(°C)의 관측값

연도	강수의 계절확률예측			기온의 계절확률예측			월평균기온 관측값
	AN	NN	BN	AN	NN	BN	
1988	31.8	33.5	34.7	31.9	36.6	31.5	11.5
1989	23.1	31.9	45.1	50.4	31.4	18.2	13.4
1990	31.5	35.9	32.7	36.8	35.4	27.8	11.1
1991	34.0	36.0	30.0	24.7	41.4	33.8	12.0
1992	37.6	35.2	27.1	41.2	38.0	20.8	11.9
1993	30.4	38.3	31.4	46.4	32.9	20.7	11.4
1994	24.8	38.2	37.0	17.5	37.0	45.5	13.4
1995	40.0	33.2	26.7	42.5	34.2	23.4	11.3
1996	28.7	33.6	37.7	29.5	33.2	37.3	10.2
1997	31.4	34.8	33.8	41.1	34.6	24.4	12.3
1998	41.9	32.2	25.9	48.7	34.0	17.3	15.3
1999	28.0	33.5	38.5	58.7	27.4	13.9	12.8
2000	23.1	33.3	43.6	50.4	34.6	15.0	11.7
2001	34.1	33.2	32.7	33.8	37.1	29.1	12.4
2002	36.6	35.2	28.2	45.7	33.4	20.9	13.0
2003	39.0	35.2	25.8	29.0	40.3	30.7	12.4
2004	33.2	36.3	30.6	39.9	37.2	22.9	13.1
2005	32.2	37.6	30.2	41.2	32.2	26.5	13.2




그림 15. hindcast 기간과 관측기간의 공통기간(1988-2005) 동안 봄철 4월의 월평균기온($^{\circ}\text{C}$)의 계절예측상세화를 통해 얻어진 분포 (상단: 확률밀도함수, 하단: 상자그림)와 실관측값(적색점)

표 14. 적절성 평가 결과: 표준정규분포에 대한 K-S 검정의 유의확률값. *유의수준 5%에서 5월평균기온의 상세화를 통해 얻어진 분포가 편의성(biasedness)이 있다.

	봄철			가을철		
	3월	4월	5월	9월	10월	11월
월누적강수	0.169	0.428	0.315	0.068	0.628	0.285
월평균기온	0.198	0.746	0.048*	0.364	0.127	0.937

표 15. 예측성 평가 결과: AMSE의 비. 대체적으로 월평균기온에 대해 예측성이 있다.

	봄철			가을철		
	3월	4월	5월	9월	10월	11월
월누적강수	0.97	0.99	0.95	0.92	1.05	0.98
월평균기온	0.90	0.85	1.00	0.85	0.82	0.97




그림 16. 좌측: hindcast 기간과 관측기간의 공통기간(1988-2005) 동안 봄철 5월의 월평균기온(°C)의 계절예측상세화를 통해 얻어진 분포 (상자그림)와 실관측값(적색점), 우측: $\{\Phi^{-1}(F_i(x_i)): i \in I\}$ 의 Q-Q 정규성 그림. 상세화로 얻어진 분포가 양의 방향으로 편이가 있다.

5. 결론 및 토론

5.1 결 론

본 연구에서는 acidWG라고 명명된 weather generator를 이용한 APCC 계절확률 예측의 상세화 방법을 제안하고, 봄/가을철 낙동강 유역에 적용하여 상세화 방법의 성능을 평가하였다. acidWG의 통계모형은 강수모형과 기온모형으로 이루어져 있다. 강수모형은 여러 모수적(parametric) 하위모형으로 구성되는데, 강수예측의 상세화는 월강수 상태에 따라 모수의 값을 조정하는 것으로서 행한다. 강수모형의 모수들은 강수의 일특성에 관여하기에, 제안된 방법은 월특성에 따라 달라지는 일특성을 상세화에 반영하는 것이라고 볼 수 있다. 한편, 기온모형은 시간적 기온변동의 분해식으로 표현되는데, 특히, 주기가 긴 저주파진동향이 기온예측 상세화를 위해 분해식에 도입된다. 기온모의는 각 분해식의 요소를 각기 모의하여 합하는 방식으로 실시되는데, 저주파진동향 모의에 기온예측을 반영하는 것으로 상세화가 행해진다. 계절예측은 그 특성상 대규모순환의 수개월 주기의 변동에 기반하는데, 기온의 상세화 방법은 기온의 저주파진동향이 그러한 변동과 밀접한 관련이 있을 것이라는 추측에 근거한다.

제안된 상세화 방법을 봄과 가을철 낙동강 유역에 적용하여 다량의 계절예측상세화 시나리오를 생산하고, 이를 분석함으로써 방법을 평가하였다. 분석은 크게 weather generator의 통상적인 평가방식인 재현성 평가와 계절확률예측에 적용하였을 때에 얻어지는 상세화 정보의 적절성과 예측성을 가늠하기 위한 계절확률예측 hindcast의 상세화 자료 평가로 구분하여 실시하였다. 전자는 시나리오 자료의 일특성에, 후자는 월특성에 평가의 초점을 두었다. 재현성 평가 결과, 관측의 여러 일특성을 몇몇의 경우를 제외하면 잘 재현하는 것으로 판단된다. 한편, 계절확률예측 hindcast의 상세화 자료 평가에서는 계절예측의 대상변수인 월누적강수량과 월평균기온을 월특성으로 고려하였는데, 상세화 방법이 대체적으로 적절한 상세화 정보를 생산하고 있음을 확인하였다. 한편, 계절예측에 대한 우리의 통념과 유사하게, 월기온에 대한 예측성이 월강수보다 높게 나왔다. 전반적으로 제안된 상세화 방법은 합리적 수준의 성능을 보인다.

5.2 토 론

상세화의 핵심인 acidWG는 지난 수년간의 연구를 통해 수정 및 보완이 이루어져 지금 단계까지 왔지만, 여전히 재현성이 미흡한 관측의 특성이 있다. 본 연구에서 드러나는 점은 다음과 같다: 앞서 기온의 시간적 지속성이 월특성에 따라 다르게 나타나는 경우가 있었다. 이는 anomaly의 모형을 월특성에 따라 다르게 잡는 것으로 대처해야 할 것으로 짐작된다. 한편, 일강수량분포로 감마분포모형을 썼는데, 월상태에 따라 잘 맞지 않는 경우가 있었다. 이를 대처하기 위해서 감마분포 대신 경험분포(empirical distribution)를 쓸 수 있겠다. 또한, 9월 월기온이 AN인 경우와 같이 월기온이 높을 때, 일최고기온분포의 왜곡이 발생하였고, 비슷한 사례가 김무섭(2017)의 그림 23에서도 발견된다. 현재 그 이유가 명확하지 않으나, 표준편차에 대한 경년변동성의 미비가 원인으로 의심된다. 후속 연구에서 개선 방법을 찾고자 한다. 더불어, 계절예측 상세화평가에서 1달 전 선행시간만 고려되었는데, 후속 연구에서는 그 이상의 예측선행시간도 고려할 것이다.

대다수의 weather generator처럼, acidWG의 모형도 역시 관측자료만을 사용해 추정된다. 하지만 기온과 강수의 관측자료만으로 건조/습윤상태를 정의하고 모의하는 것은 한계가 있다. 계절내예측정보와 같이 계절예측보다 더 상세화 예측정보가 가능하다면, 더 현실성있고 정확한 기상모의가 가능할 것으로 기대된다. 향후 연구에서 계절예측 외 예측 정보도 활용하는 방법을 연구하여 상세화에서 기후정보 활용의 폭을 넓히고자 한다.

Main Algorithm에서 기온과 강수의 월특성은 주어진 계절확률예측에 따라 독립적으로 결정된다. 하지만 월에 따라 두 특성이 독립적이지 않을 수 있다. 실제, 7월의 경우, 두 특성의 상관관계가 유의하게 나타난다. 본 연구에서 봄/가을철 낙동강 유역을 대상으로 삼았지만, acidWG는 다양한 지역과 시기에 적용될 것을 감안하여 개발되어 왔다. 그래서, 일반성을 감안해 근원적으로 계절확률예측이 변수별이 아닌 두 변수의 결합확률 분포(joint probability distribution)로 주어질 필요가 있다.

서론에서 언급하였듯이, 김무섭(2017)에서 동일 유역에서 겨울과 여름의 대규모 순환 기반의 계절예측 상세화를 고려하였다. 그래서, 두 계절에 대해서는 대규모 순환장 예측 기반과 계절예측 기반 방식 모두가 적용가능하다. 추후 연구에서 두 방식을 비교해 장단을 파악할 계획이다.

REFERENCES

- 김무섭 2015: *통계적 상세화를 위한 Weather Generator 개발* APEC 기후센터 연구보고서 2015-04 ISBN: 979-11-5698-094-0
- 김무섭 2017: *Weather Generator를 이용한 APCC 계절예측의 통계적 상세화-동아시아 겨울/여름몬순 기반으로-* APEC 기후센터 연구보고서 2017-05 ISBN: 979-11-5698-195-4
- Apipattanavis, S., G. Podestá, B. Rajagopalan, and R. W. Katz, 2007: A semiparametric multivariate and multisite weather generator. *Water Resour. Res.*, **43**, doi:10.1029/2006WR005714.
- Eum, H.-I., S. P. Simonovic, and Y.-O. Kim, 2010: Climate Change Impact Assessment Using K-Nearest Neighbor Weather Generator: Case Study of the Nakdong River Basin in Korea. *J. Hydrol. Eng.*, **15**, 772-785, doi:10.1061/(ASCE)HE.1943-5584.0000251.
- Min, Y. M., V. N. Kryjov, S. M. Oh, and H. J. Lee, 2017: Skill of real-time operational forecasts with the APCC multi-model ensemble prediction system during the period 2008-2015. *Clim. Dyn.*, **49**, 4141-4156, doi:10.1007/s00382-017-3576-2.

【연구자】

김무섭 선임연구원

김원무 선임연구원

정여민 연구원

연구보고서 2018-11

**Weather Generator를 이용한 APCC 계절예측 상세화 방법 개발
- 계절확률예측 기반으로 -**

I S B N 979-11-5698-243-2

발 행 2019년 3월

발 행 인 권 원 태

발 행 처 APEC기후센터
부산시 해운대구 센텀7로 12

제작·인쇄 경성문화사

이 보고서는 APEC기후센터 홈페이지(<http://www.apcc21.org/>)에서 이용하실 수 있습니다.
또한 보고서에 실린 내용은 출처를 명시하면 자유롭게 인용할 수 있습니다. 단, 무단 전재 및
복제를 금합니다.