

TRAVEL REPORT FORM

출장보고서

결 재	선임연구 원	과장	부서장	원장
	07/03	07/03	07/03	07/04
협 조	손수진	김형진	유진호	권원태

I. Travel Overview 출장개요

1. Traveler(s) 출장자

Department 소속	Position 직위(직급)	Name 성명	Note 비고
예측기술과	선임연구원	김무섭, 손수진	

2. Travel Period 출장기간

: 2019년 6월 23일(일) ~ 28일(일)

3. Occasion and destination 행사 및 출장지

■ 출장세부 내용

일시	출발지	도착지	업무수행내용	비고
6월 23일	대한민국 부산	프랑스 툴루즈	이동	
6월 24~28일	프랑스 툴루즈		2019년 국제통계기후학회 참석	<APCC 출장자 발표> • 6월 26일: 손수진 • 6월 27일: 김무섭
6월 29~30일	프랑스 툴루즈	대한민국 부산	이동	

II. Major Activities 주요업무 수행내용

1. Main Contents and Activities 주요내용 및 활동

○ APEC 기후센터 출장자 발표 세션 및 발표 제목

1. 손수진

- 발표 일시: 6월 26일
- 발표 세션: <세션 4> Space-timestatistics for modeling and analyzing climate variability
- 발표 제목: Statistical space-time diagnostics of ENSO diversity and associated tropical Pacific rainfall variability, and evaluation of their reproducibility in APCC MME seasonal prediction

- 발표 내용: 붙임 1 참조

2. 김무섭

- 발표 일시: 6월 27일
- 발표 세션: <세션 12> From global change to regional impacts, downscaling and bias correction
- 발표 제목: Statistical downscaling of EAWM into a Korean Local Basin Climate using a Weather Generator
- 발표 내용: 붙임 2 참조

○ 주요 연구 성과 및 연구 동향 파악

- 국제통계기후학회 (The 14th International Meeting on Statistical Climatology, IMSC)는 1979년부터 매 3년 마다 정기적으로 개최, 기후-통계 커뮤니티 간 정보환류, 기후 및 대기과학 분야에서 우수 통계적용 사례를 목표로 함. 본 학회는 제 14차 회의로 프랑스 툴루즈 기상청에서 2019년 6월 24-28 일(5일간) 개최되었으면, 220여명의 통계, 기후, 대기과학 분야의 명망 있는 전문가, 관련 연구 종사자 및 학계에서 참석. 국내에서는 과학위원회 (Scientific Committee) 멤버인 포항공과기술평과대학교 민승기 교수 외 2인, 부산대학교 서경환 교수, APCC 예측기술과 선임연구원 2인 참석
- 이번 회의에서는 총 200편의 발표가 있었으며, 126편은 구두 발표, 74편은 포스터 발표였음 (세부 프로그램은 붙임 3 참조). 구두 발표 중 23편은 전체 세션 (Plenary session)에서, 나머지 123편은 해당 주제별 세션에서 발표됨.
- 주제별로는 12개의 세션이 있었으며, 기후자료로부터 시-공간 통계 분석, 자료 동화 및 규모 축소 (downscaling)에 이르기까지 폭 넓은 주제를 다룸.

세션	주제	발표 (건)
1	Climate records: data homogenization, dataset creation, and uncertainty	19
2	Interactions of weather and climate with human and natural systems	8
3	Statistical issues working with large datasets and model outputs	3
4	Space-time statistics for modeling and analyzing climate variability	23
5	Weather/climate predictability and forecast evaluation	26
6	Statistics for climate models, ensemble design, uncertainty quantification, model tuning	8
7	Statistical and machine learning in climate science	15
8	Long-term D&A and emergent constraints on future climate projections	15
9	Attribution and analysis of single weather events	30
10	Changes in extremes including temperature, hydrologic, and multivariate compound events	25
11	Extreme value analysis for climate applications	29
12	From global change to regional impacts, downscaling and bias correction	24

1. 기후 자료 (Climate record) 관련 연구

- 관측 기반의 기후 자료는 기후 연구를 위한 다양한 분야에서 필요 불가결한 요소임. 이상적으로 완벽한 기후 자료는 정확하고, 시공간으로 인위적인 트랜트로부터 자유로우며, 전 지구적으로 누락된 자료가 없어야 함. 하지만 실제로는 자료의 노이즈, 관측지점의 이동, 관측 장비의 변경 및 노후화, 위성 궤도의 drift, 관측 지점 간 분포, 관측 빈도 등의 요인으로 인해 자료의 균일화, 관측자료 생성, 불확실성 추정에 대한 처리가 요구됨.
- 관측 장비 또는 시스템의 진보는 관측 자료에 직접적인 영향을 주는 요인으로, 이로 인해 발생 가능한 긴 시간 규모의(historical) 해수면기온 자료 내 bias의 새로운 추정 방법을 소개함.
- 전구 일평균 기온자료에 대한 분석 연구 등이 소개됨. 그 중 EUSTACE 사업

(www.eustaceproject.org)은 지상관측, 위성 관측 등 다양한 관측자료를 기반으로 한 전지구 규모의 일평균 기온자료 구축을 목표로 함. 통계적으로 구면상에서 정의된 국소기저함수(local base function)를 이용해 기온의 공간변동을 설명하는 모형을 구축함. 또한, 은닉변수(latent variable)-베이지안 방법으로 기온변동모형을 추정함.

- 전지구 기온자료를 다중 규모로 분리하는 방법에 대하여 소개함. 즉 기후변화, 대규모 변동, 일변화로 구분하여, 각 시간 규모에 영향을 주는 요소를 이용하여 기온 자료 생성함. 여기서 일변화 변동의 경우에 위성자료를 영향요소(다시 말해, 오차를 생성할 수 있는 인자)로 고려함.

2. 인간-자연계와 날씨/기후의 상호작용 관련 연구

- 사회적 관점에서, 기후과학은 상당한 중요성이 있음. 수자원 관리, 날씨관련 재해로부터 인프라구축에 이르기까지 위험 평가, 보건과 생태계에 대한 기후변화 영향 평가, 농업 정책 개발 및 식량안보, 재생에너지 자원 개발이 그 적용 분야임. 이러한 분야의 기획, 정책 개발자는 기후, 날씨 관련 이벤트에 대해 잘 알고 예보 및 기후변화를 활용한 정책 수립에 반영해야 함.
- 보건에 대한 날씨 영향을 감시하기 위한 지수에 대해 소개함. 이 지수는 constrained groupwise additive index 모형을 기반으로 설계됨. 이 모형은 보건과 관계된 기상 기반의 지수를 유도할 목적으로 개발된 것으로, 기존의 주관적이고 경험적인 지수선저에서 벗어나 보다 객관적인 방법을 제안하고자 함. 효과적인 보건관련 지수를 유도하기 위해 관련된 목적변수를 선정하고 이를 반응변수로 하는 회귀모형을 고려함. 아울러 관계의 비선형성을 감안해 일반화된 가법 모형(generalized additive model)을 씀.

3. 대규모 자료 및 모형 자료의 처리를 위한 통계적 이슈 관련 연구

- 원격탐지, 관측자료, 대규모 기후모형 앙상블로부터 지리학적 자료의 급속한 증가는 이에 걸 맞는 통계자료분석 방법을 요구함. 고용량의 자료는 실험적인 자료 분석, 자료 검수, 표준 방법을 사용하여 통계 모형으로 피팅(fitting)하는 것에 다소 어려움이 있음. 자료 처리 시 요구되는 계산 및 저장 요구사항은 공간 지리학적 분석 방법을 사용할 경우 컴퓨팅 자원의 제한을 쉽게 극복 가능한 방안임.
- 초대규모 공간자료를 위한 바이어스(bias)에 감점을 주는 모형에 대한 방법이 소개됨. 이는 기온공간변동을 설명하는 기저함수(basis function)를 기반으로 공간변동모형을 고려하는 방안으로, 기온의 공간변동 또는 그것의 분해에서 특정변동은 기저함수의 선형결합으로 표현된다고 가정, 선형계수에 대해 다변량 정규분포를 가정함. 여기에 다변량 정규분포의 정밀도 행렬(precision matrix, 공분산의 역행렬)을 희소행렬로 가정 함. 마지막으로 모형추정에 있어 penalized 기법을 적용함.
- 통계적으로 진보된 일평균 기온 자료 구축 시스템을 위한 building block이 소개됨. 기온변동을 시공간적 분석하여, 공간상의 기저함수와 시간상의 기저함수의 곱을 시공간상의 기저함수로 고려함.

4. 기후 변동 모델링 및 분석을 위한 시공간 통계 방법 관련 연구

- 기후시스템은 지면, 해양, 대기의 상호작용에 의한 복잡한 체계로, 이러한 과정의 자연 변동에 대한 이해는 기후 변동의 분석을 요구함. 다양한 기후 자료와 모델 아웃풋을 바탕으로 이러한 변동성을 더 잘 모의하고 이해할 수 있음. 계절 또는 여러 계절의 시공간 상의 변동 분석은 특히나 기후과정이 비정상성(nonstationary)을 가지거나 정규 분포가 아닐 (non-Gaussian) 경우 통계기술의 진보를 요구함.
- 다변수 모델을 선택하기 위한 새로운 임계치에 대해 소개함. 고차원 기후자료에 전준상관 분석을 적용할 경우 차원이 자료의 크기를 넘어서는 문제가 발생함. 기존의 방법으로는 정규화된(regularized) 정준상관분석과 경험직교함수(Empirical Orthogonal Function, EOF) 분석을 통한 차원축소가 있음. EOF 분석을 통한 차원 축소의 경우, 여전히 EOF 모드 선택하는 문제가 남음. EOF 모드 선택의 방법으로 AIC 기반의 변수선택법을 고려함. 흥미롭게도 유도된 기준량의 형태가 mutual

information criterion과 매우 닮음을 알 수 있음.

- APCC 다중모델앙상블(Multi-model ensemble, MME) 계절 예측자료를 바탕으로 엘니뇨-남방진동(El Nino-Southern Oscillation, ENSO)의 다양성을 정의하고, 이것이 계절예측 성능에 미치는 영향을 평가하고 그 요인을 도출하고자 분석한 결과를 발표함. 특히 연구 분석 과정에서 계절예측에서 가장 중요한 기후변동성인 ENSO를 EOF 분석을 통하여 정형성과 다양성으로 구분함, 이후 계절 기후 관점에서 ENSO 다양성과 적도 태평양 강수의 관련성을 특이치분해(Singular Value Decomposition) 방법을 적용하여 정량함 함. 이는 기후변동성의 시공간 특성을 분석하기 위하여 주로 사용되는 두 통계적 방법을 계절 기후 및 APCC MME 예측 자료에 적용한 사례로, 연구과를 통계-기후 간 Society와 Community에 공유함. ENSO 예측 결과를 보여주는 verification measure와 그 의미, 그리고 연구 결과에 대해서 주로 토론함.

5. 기후 과학에서의 통계 및 기계학습 관련 연구

- 고성능 컴퓨팅 기술의 진보로 시공간적으로 고해상도 및 재현성이 높은 대규모 기후 모형 자료의 생산이 가능해짐. 자료 내에는 표준 매뉴얼 기법으로 얻을 수 없는 상당한 정보가 있음. 초기 단계이지만 통계 및 기계학습은 이러한 자료 내 우리가 선형적으로 알고 있는 자료 뿐 만 아니라 비경험적 자료의 추출이 가능함. 예를 들어, 특징 감지(feature detection) 기술은 폭풍 같은 날씨 또는 기후의 패턴의 추출하는데 사용될 수 있음.
- 시공간 기후 자료의 패턴 감지를 위해서 위상수학적(topological) 자료 분석 및 기계학습 (deep learning)에 대한 기법을 이용하여 대기 블로킹과 atmospheric river에 적용함.

6. 규모축소 및 bias correction 관련 연구

- 기후 예측 및 변화는 종종 다소 성긴 전구모형 및 지역기후모형을 기반으로 함. 하지만, 많은 사용자들은 지역 또는 local scale의 고해상도 모형 결과를 바람. 특히 기후나 날씨관련 이상기후를 평가할 때 더욱 그러함. 이러한 공간적 규모 차이를 해소하기 위한 방안으로 통계적 규모축소가 하나의 수단으로 이용됨.
- Weather Generator(WG)를 사용하여 동아시아 겨울철 몬순 지수를 한반도 local basin으로 통계적 상세화 하는 연구를 발표함. 대부분의 기후 적용 분야에서, 기후 영향 연구는 작은 지역에서, 그리고 일변화에 대한 신뢰 있는 기후 자료를 요구함. 따라서 전구 모형 결과 같은 원시기후자료는 저해상도의 큰 규모의 순환변수는 잘 모의하므로, 이를 상세화 과정에 적용할 수 있음을 발표함. 겨울철 한반도 기후에 영향을 미치는 큰 규모 순환으로 지역 기후를 통계적으로 설명하는 상세화 방법에 대해서 제안함. 특별히, 동아시아 겨울 몬순 (East Asian Winter Monsoon, EAWM)은 한반도 기후에 영향을 미치므로, 몬순 강도에 따라 유역 기수의 반응을 설명하는 WG 모형을 설계함. 더욱이, EAWM 강도의 3분위 확률예측을 바탕으로 다양한 날씨 시나리오를 생산하는 방안에 대해 발표함. 또한, 이는 기후 영향의 불확실성을 추정하는 방안이 될 수 있음을 토론함.

2. Relevance to APEC Climate Center's Activities 결론 및 소감

3. Suggestions and Remarks 건의사항

- ▶ 본 학회는 일반적으로 통계적 처리와 분석에 대한 여러 주제를 다루고 있어, 크게 센터 업무와 상당한 관련이 있었음.
- ▶ 다양한 주제로 본 학회의 세션이 구성되어 있으며, 발표에 대한 저자 기여(contribution)가 주로 세션 4-5, 9-12에 집중되어 있음. 학회 참석자의 주요 관심 분야 및 기후 관련 통계 분야의 최근 연구 동향이 주로 기후변동의 시-공간 통계 분석, 날씨/기후 예측성 및 예측 성능 평가, 단일 날씨 이벤트에 대한 요인(attribution) 및 분석, 기후, 수문, 다변수 복합 이벤트를 포함한 극한에서의 변화 추정, 기

후 적용을 위한 극한값분석, 지구 변화 및 지역 영향까지의 규모축소 및 Bias 보정임을 알 수 있었음.

- ▶ 발제된 12개의 세션 중 세션 4-5, 12는 본 학회 참석자의 당해 연도 연구 주제와 밀접한 관련이 있어, 최근 연구 동향을 파악할 수 있었음.
- ▶ 최근 관측 장비 또는 시스템의 진보로 SST와 같은 지점 관측 자료에 직접적인 영향을 주는 요소도 개선되었으며, 이를 균일화하여 자료를 생성하고 이에 대한 불확실성을 추정하는 과정이 크게 개선됨. 이는 결국 ENSO와 같은 해양 변동성의 기작을 이해하고, 모델 내에서 역학을 이해하는데 크게 기여한 것으로 보임. 최근 APCC MME 참여 모형의 품질개선은 해양 초기화에서 한 가지 이유를 찾을 수 있으며, 이는 결국 MME 예측성의 향상에 기여한 것으로 보임.
- ▶ EUSTACE 사업의 전구 일평균 자료 구축 방법은 예측기술과의 상세화 관련 연구 과제 중 한반도 일평균 격자 자료 생산 방법과 유사, 추후 연구 확장 및 개선을 위해 적용 가능해 보임.
- ▶ 기후자료를 다중 규모로 분리하는 방법은 APCC의 계절 또는 계절내 기후 관련 연구 또는 예측자료 생산에 적용 가능해보임. 즉, 계절에서 경년 규모 내에서 기후 변동성을 크게 기후값, 경년변동성, 계절변동, 계절 내 변동 또는 계절 내에서 극한기후의 통계치로 분리하여, 각각의 규모 현상에 영향을 주는 요소를 분석하고, 이를 분석 및 활용하여 최종적으로 예보 자료를 만드는 데 활용할 수 있을 것으로 보임. 현재 S2S자료를 활용하여 단기간에 현업으로 예측하는 것은 아직은 시기적으로 다소 어려움이 있으며, 따라서 APCC MME 계절예측자료를 활용하여 계절 규모에서 아노말이나 3분위 예보값이 아닌 계절 내 극한기후의 빈도 예측으로 예측정보를 다양하게 확장할 필요가 있음 (이는 포항공대 민승기 교수님의 Comment이기도 함).
- ▶ 대규모 자료 및 모형 자료의 처리를 위한 공간 지리학적 분석 방법은 향후 APCC의 계절 예측 및 계절내 예측자료가 방대해질 경우 적용 가능한 방법으로 보임. 또한 초고용량 penalized bias model은 현재 APCC MME 계절예측에서 사용하는 Synthetic Super Ensemble과 매우 유사함. 반면에 APCC에서는 관측이나 모형 자료 내 자료 자체가 가진 시공간적 해석보다는 예측성능이 예측기법을 선택하는 기준이 되어 왔음. 즉, Synthetic Super Ensemble은 Simple Composite 보다 예측 성능면에서 낮게 평가되어, 현업적으로 그 중요성이 배제되어 있음.
- ▶ 주로 학회에서는 대규모 자료 내 공간 지리학적으로 의미 있는 자료를 어떻게 추출할 것인가에 초점이 맞추어져 있고, 시공간상의 의미에 더 주안점이 있음. 가령, 기온변동을 시공간적 분석하여, 공간상의 기저함수와 시간상의 기저함수의 곱을 시공간상의 기저함수로 고려하여 생산된 자료를 결측지에 대한 공간 보간된 실제 관측자료로 본다면, 현재기후에 대해서 생산된 기법을 미래기후변화 자료에 대해서 적용할 경우 overfitting 문제에 대한 고려는 없었음. 따라서, 실제로 이러한 유사 기법을 APCC 계절예측자료에 활용할 경우 overfitting 문제에 대한 해결 방안은 여전히 숙제로 남아있음. 단, 모형 평균 자료에 대해서 수행하던 이전의 방식에서 모든 앙상블로 확장해 볼 여지는 있는 것으로 보임.
- ▶ 기후변화 관련 연구에서는 비정상성(nonstationary)을 고려한 연구가 이미 진행되고 있으나, 계절 예측 분야에서는 아직 고려되고 있지 않음. 따라서 학습 기간에서 보여준 예측성능이 평가기간에 담보되지 않을 때 overfitting으로 간주함. 하지만, 비정상성을 고려하지 않은 차이에서 기인한 것으로 해석해 볼 여지가 있음. 즉 통계예측모형 내에서 비정상성을 고려하는 것이 시도 될 필요가 있음. 예를 들어, 기후변화에서는 long-term change를 0으로 만드는 방법으로 정상성을 고려하는 방법이 시도되고 있음. 하지만, 현재 APCC MME 기후예측에서는 단순히 기후값에 의한 평균 바이어스만 제거함으로써 비정상성에 대한 고려가 없고, 학습기간이나 평가기간이 동일한 변동을 한다고 가정함. 또한 trend에 대한 고려를 하지 않으므로, 현재 예측성능이 과거 10년에 비해 눈에 띄게 성능이 발전했는가에 대한 제고가 필요함. 또한 비정상성을 고려하지 않은 상황에서, 학습기간과 평가기간이 서로 상이하므로 그에 걸 맞는 검증 방법이 필요할 것으로 보임.
- ▶ 계절 내 또는 계절 규모에서 비정상성을 가지는 기후 현상에 대해서는 정규분포를 기반으로 모수화 방법을 쓰는 것에 대한 제고가 필요해 보임. 계절 또는 여러 계절 규모에서 대표적인 비정규 분포

현상으로는 엘니뇨-남방 진동 및 가뭄이 있으며, 이러한 변동성을 분석하고 예측하는 데는 비정규분포를 고려해야 할 것으로 보임. 특히 관측자료에서 이런 현상들이 비정규분포를 보이더라도 모형의 자료가 정규 분포를 보이면 단순히 정규 분포를 적용할 것이 아니라, 관측 대비 모형의 바이어스로 보고 예측을 수행하거나 quantile mapping 등을 통한 calibration을 수행해야 할 것으로 보임.

- ▶ 학회 특성 상 통계 위주의 해석 및 적용에 대한 발표 및 토론이 주류를 이룸. 즉 특정 통계 분석 방법 내에서 파라미터를 바꾸었을 때의 차이 등에 대한 토론이 많았으며, 이를 바탕으로 원인 분석 내지 물리적 해석, 예측성능의 검증에 대한 토론이 굉장히 한정되어 아쉬움이 남았음. 단 기후변화 중 특이기상과 관련된 attribution에 대한 연구는 물리적 해석 및 요인분석과 더불어 상당히 많은 발표와 토론이 있었음.
- ▶ 기후 변동 모델링 및 분석을 위해 시공간 통계 방법으로 널리 사용되는 방법 중에 하나인 EOF의 모드 선택을 위해, AIC를 기반으로 자료를 추출하는 방법은 APCC 내에서 EOF를 사용하는 기후 변동성 관련 연구 또는 예측 통계 모델링에 적용 가능해 보임. 즉, Synthetic Super Ensemble에서 현업에서 운영되는 모드의 추출이 타당한지 살펴볼 필요가 있음. 또한, 통계적 분석 내에서 사용하는 AIC 기반의 변수선택법이 물리적 해석과 연계될 때 더욱 의미가 있을 것으로 보임.
- ▶ 참석자의 대부분이 계절 이외의 분야에서 연구를 진행, 계절 예측 결과를 보여주는 Verification measure 자체에 대한 관심이 많았으며, 계절 예측에서 흔히 쓰는 방법이 기후 community 자체에서 통용된 것은 아니라는 것을 확인함. 계절 예측 커뮤니티에 다른 시간 규모 및 분야의 기후과학과 지속적인 토론 및 협업이 필요해보임. 또한 예측성능을 쉽게 직관적으로 이해할 수 있도록 시각화하는 것도 중요해 보임.
- ▶ 기후 과학에서 통계 및 기계학습 관련 연구는 격자점 위주에서 진행되고 있으나, 시공간 기후 자료의 패턴 감지 기술은 예측기술과 계절내 규모의 기후 예측 관련 연구 과제 중 S2S 기후예측 자료의 기계학습(deep learning)의 추후 연구 확장 및 개선을 위해 적용 가능해 보임.
- ▶ 본 학회의 상세화 세션은 주로 bias correction에 대한 발표 및 토론이 주를 이루었으며, 큰 규모의 순환장을 이용하는 상세화 방법에 대해 많은 관심을 받음. 다양한 분야 및 다학제간 통계-기후의 관심사 및 주 연구 방향을 고려할 때 상세화를 위한 다양한 방법과 gap이 존재함을 알 수 있었음. 기후변화나 응용 분야에서는 아직 QM 또는 bias correction이 주로 사용되며, 큰 규모 순환을 기후예측인자로 사용하는 연구는 아직까지는 제한적임을 알 수 있었음.

III. References (Presented and Collected Materials) 주요 수집자료

(with attachment of any information or report in case of attendance of conferences, workshops and meetings) 학술대회, 워크숍, 회의 등 참석 시 관련 정보 및 문서 첨부

IMSC 2019 – Scientific Program

	Monday 24	Tuesday 25	Wednesday 26	Thursday 27	Friday 28
09h00	Welcome coffee	Plenary	Plenary	Plenary	Plenary
10h00	Registration	3 + 11	2 + 4	6 + 12	5 + 9
10h30		Amphi	Amphi	Amphi	Amphi
11h00	Plenary	Break	Break	Break	Break
11h30	1 + 7	Plenary	Plenary	9 5 12	9 5 6
12h00	Amphi	10	4 + 8	(A) (P) (M)	(A) (P) (M)
12h30		Amphi	Amphi		
13h00	Lunch	Lunch	Lunch	Lunch	Lunch
14h00		Posters		Posters	
14h30	10 1 7	1, 2, 3, 4, 7, 10, 11	10/11 4 8	5, 6, 8, 9, 12	
15h00	(A) (P) (M)	Marquee	(A) (P) (M)	Marquee	
15h30					
16h00	Break	Break	Break	Break	
16h30	10 1 3+7	11 4 2	10 4 8	9 5 12	
17h00	(A) (P) (M)	(A) (P) (M)	(A) (P) (M)	(A) (P) (M)	
17h30					
18h00	Icebreaker	Conference diner Hotel Dieu		Wine tasting or Guided tour Downtown	Rooms: (A): Amphi (M): Megredichian (P): Prudhomme

List of sessions

- 1 Climate records: data homogenization, dataset creation, and uncertainty - John Kennedy, Xiaolan Wang
- 2 Interactions of weather and climate with human and natural systems - Bryson Bates, Richard Chandler
- 3 Statistical issues working with large datasets and model outputs - Erich Fischer, Doug Nychka
- 4 Space-time statistics for modeling and analyzing climate variability - Peter Craigmile, Tim Delsole
- 5 Weather/climate predictability and forecast evaluation - Matilde Rusticucci, Thordis Thorarinsdottir, David Stephenson
- 6 Statistics for climate models, ensemble design, uncertainty quantification, model tuning - Ben Sanderson
- 7 Statistical and machine learning in climate science - Philippe Naveau, Michael Wehner
- 8 Long-term D&A and emergent constraints on future climate projections - Dorit Hammerling, Reto Knutti
- 9 Attribution and analysis of single weather events - Chris Paciorek, Sarah Perkins-Kirkpatrick
- 10 Changes in extremes including temperature, hydrologic, and multivariate compound events - Jana Sillmann, Seung-Ki Min
- 11 Extreme value analysis for climate applications - Richard Smith, Xuebin Zhang
- 12 From global change to regional impacts, downscaling and bias correction - Alex Cannon, Mathieu Vrac

[IMSC 2019 출장자별 세부 일정]

1. 손수진 선임연구원

날 짜		세부 일정
6/24(월)	오전	• 등록 • Plenary session 참석: 1+7 1. Climate records: data homogenization, dataset creation, and uncertainty
	오후	• Oral session 참석: 10, 3+7 3. Statistical issues working with large datasets and model outputs 10. Changes in extremes including temperature, hydrologic, and multivariate compound events
6/25(화)	오전	• Plenary session 참석: 3+11, 10 3. Statistical issues working with large datasets and model outputs 10. Changes in extremes including temperature, hydrologic, and multivariate compound events
	오후	• Poster session 참석: 1-4, 7, 10, 11 • Oral session 참석: 4 4. Space-time statistics for modeling and analyzing climate variability
6/26(수)	오전	• Plenary session 참석: 2+4, 4+8 4. Space-time statistics for modeling and analyzing climate variability
	오후	• Oral session 참석: 4 4. Space-time statistics for modeling and analyzing climate variability
6/27(목)	오전	• Plenary session 참석: 6+12, 5 5. Weather/climate predictability and forecast evaluation 6. Statistics for climate models, ensemble design, uncertainty quantification, model tuning

	오후	• Poster session 참석: 5-6, 8-9, 12 • Oral session 참석: 5 5. Weather/climate predictability and forecast evaluation
6/28(금)	오전	• Plenary session 참석: 5+9 • Oral session 참석: 5 5. Weather/climate predictability and forecast evaluation

2. 김무섭 선임연구원

날 짜		세부 일정
6/24(월)	오전	• Oral session 참석: Statistical and machine learning in climate science
	오후	• Oral session 참석: Statistical and machine learning in climate science
6/25(화)	오전	• Oral session 참석: Extreme value analysis for climate applications
	오후	• Oral session 참석: Space-time statistics for modeling and analyzing climate variability
6/26(수)	오전	• Oral session 참석: Space-time statistics for modeling and analyzing climate variability
	오후	• Oral session 참석: Space-time statistics for modeling and analyzing climate variability
6/27(목)	오전	• Oral session 참석: Statistics for climate models, ensemble design, uncertainty quantification, model tuning + <u>From global change to regional impacts, downscaling and bias correction</u>
	오후	• Oral session 참석: From global change to regional impacts, downscaling and bias correction
6/27(금)	오전	• Oral session 참석: Weather/climate predictability and forecast evaluation
	오후	• Oral session 참석: Statistics for climate models, ensemble design, uncertainty quantification, model tuning

Statistical Downscaling of EAWM into a Korean Local Basin Climate using a Weather Generator

Moosup Kim

APEC Climate Center, Busan, Korea

(Coauthor: Seon Tae Kim, Yeomin Jeong)



Overview

1. Background
2. Weather Generator Model
3. The Result of EAWM Downscaling
4. Summary



Background

- Climate Prediction
 - Precipitation and Temperature,
 - Prediction skill is not good in mid-latitude regions.
 - Large-scale Circulation: EAWM, EASM, ENSO.
 - Relatively good skill,
 - connected with other predictable circulations.



Background

- Climate Application: Agriculture and Water Resource
 - Climate Impact Study,
 - Climate prediction with high-resolution,
 - TMAX, TMIN, daily precipitation, solar radiation, relative humidity.





Background

- Weather Generator (WG) Model
 - Weather simulation linked with large-scale circulations.
 - It produces daily scenario data of the required variables, which are used for evaluating climate impact.



Weather Generator Model

- Case study
 - Basin: the Nakdong River basin in Korea
 - Season: Boreal Winter
 - Large-scale Circulation : EAWM



Weather Generator Model

- Approach
 - *Constructing WG model describing the response of basin climate to EAWM.*
 - There are many existing EAWM indices.
 - They are related to basin climate,
 - Among them, one is selected based on their prediction skills.



Weather Generator Model

- EAWM indices

index	reference	index	reference
ChanLi04	Chan and Li (2004)	Shi96	Shi (1996)
Gong01	Gong et al. (2001)	WangChen14	Wang and Chen (2014)
Guo94	Guo (1994)	Wang09	Wang et al. (2009)
Kim17	Kim et al. (2017)	WuWang02	Wu and Wang (2002)
LiYang10	Li and Yang (2010)	XuJi65	Xu and Ji (1965)



Weather Generator Model

- Relevance to the basin climate

index	temperature	precipitation	index	temperature	precipitation
ChanLi04	-0.57(**)	-0.46(*)	Shi96	-0.57(**)	-0.54(**)
Gong01	-0.61(**)	-0.41(*)	WangChen14	-0.73(**)	-0.51(**)
Guo94	-0.57(**)	-0.43(*)	Wang09	-0.57(**)	-0.24
Kim17	+0.69(**)	+0.34	WuWang02	-0.61(**)	-0.40(*)
LiYang10	-0.69(**)	-0.49(*)	XuJi65	-0.31	-0.64(**)



Weather Generator Model

- Approach (continue)
 - Connecting the EAWM index with some components of WG model
 - Categorization of index: BN/NN/AN,
 - Components are adjusted/simulated by the category,
 - Which components are affected by EAWM?



Weather Generator Model


- WG model
 - Precipitation model
 - Fully parametric.
 - EAWM effect on precipitation is simulated by adjusting the parameter values according to its strength.
 - Temperature (TMAX/TMIN) model
 - Multi-site bivariate time series model with precipitation effect



Weather Generator Model

- Temperature model

TMIN DJF in 2008-2009





Temperature daily variation is decomposed into

- Annual cyclic mean trend, (---);
- Slow oscillation $\Lambda(s, t)$, (—);
- Precipitation effect $\Delta(s, t)$, (—);
- Anomaly.



Weather Generator Model

- Oscillation $\Lambda(s, t)$



Weather Generator Model

- The downscaling scheme for temperature
 - To simulate the oscillation $\Lambda(s, t)$ according to the EAWM strength!



Weather Generator Model

- Simulation of oscillation $\Lambda(s, t)$
 - $\Lambda^*(s, t)$ retains mean and covariance structure of $\Lambda_1(s, t), \dots, \Lambda_n(s, t)$.

$$Y_i(s, t) = \Lambda_i(s, t) - \frac{1}{n} \sum_{k=1}^n \Lambda_k(s, t),$$

$$Y^*(s, t) = \sum_{i=1}^n \eta_i Y_i(s, t), \quad \eta_i \sim N(0, 1/n),$$

$$\Lambda^*(s, t) = Y^*(s, t) + \frac{1}{n} \sum_{k=1}^n \Lambda_k(s, t).$$

$\Lambda_1(s, t), \dots, \Lambda_n(s, t)$ are historical oscillations in a category of EAWM strength.



Weather Generator Model

- Probabilistic Prediction
 - Multinomial logistic regression

$$\log \frac{p_{\text{BN}}}{p_{\text{AN}}} = \alpha_{\text{BN}} + \beta_{\text{BN}} X$$


$$\log \frac{p_{\text{NN}}}{p_{\text{AN}}} = \alpha_{\text{NN}} + \beta_{\text{NN}} X$$

$$p_{\text{BN}} + p_{\text{NN}} + p_{\text{AN}} = 1$$



Weather Generator Model

- Simulation scheme



EAWM Downscaling



- EAWM indices

index	reference	index	reference
ChanLi04	Chan and Li (2004)	Shi96	Shi (1996)
Gong01	Gong et al. (2001)	WangChen14	Wang and Chen (2014)
Guo94	Guo (1994)	Wang09	Wang et al. (2009)
Kim17	Kim et al. (2017)	WuWang02	Wu and Wang (2002)
LiYang10	Li and Yang (2010)	XuJi65	Xu and Ji (1965)



EAWM Downscaling

- Prediction skill: LiYang10 is the best.



EAWM Downscaling

- WG model Verification
 - Are climate characteristics well reproduced?
 - Daily distributions of precipitation, TMAX, TMIN;
 - Spatial correlation;
 - Temporal autocorrelation;
 - Cross correlation;
 - Seasonal average of TMAX/TMIN, total precipitation.



Table: KS-test result: the number of the sites that reveal significant difference at 5% level.

Category	Month	Precipitation	TMAX	TMIN
BN	12	1/14	0/14	0/14
	1	1/14	0/14	0/14
	2	4/14	0/14	0/14
NN	12	2/14	0/14	0/14
	1	0/14	0/14	0/14
	2	2/14	0/14	0/14
AN	12	1/14	1/14	0/14
	1	4/14	0/14	0/14
	2	0/14	1/14	0/14

Note: there are 14 stations in the basin.




Figure: spatial correlation comparison of TMAX (left) and TMIN (right). X-axis: simulation, Y-axis: observation. We have 91 pairs of stations: 91 points on each plot. As the points are close to the dashed line, spatial correlation is well reproduced.




Figure: Autocorrelation of TMAX (left) and TMIN (right). Black: simulation, red : Observation.






Figure: Cross-correlation of TMAX-PRCP (left) and TMIN-PRCP (right). Black: simulation, red : Observation.


Seasonal Total Precipitation BN




Seasonal Average TMAX BN




Seasonal Average TMIN BN




Seasonal Total Precipitation NN




Seasonal Average TMAX NN




Seasonal Average TMIN NN




Seasonal Total Precipitation AN



Seasonal Average TMAX AN



Seasonal Average TMIN AN



Summary

- Weather Generator Model
 - Categorization of monsoon strength,
 - Adjusting/simulating the components of the model according to the predicted category,
 - Multinomial logistic regression.
- Prediction skill evaluation
 - LiYang10
- Verification
 - Characteristics are reproduced well.



THANK YOU!

Welcome any Comments and Questions.




Weather Generator Model

- ASOS Data
 - 14 stations, 1988-2013, Daily data
- NCEP Reanalysis Data
 - 1979-2013, Monthly data
- APCC Seasonal Hindcast Data
 - 1983-2013, Monthly data
 - Lead time: 1-6 months
 - up to 3-month lead for EAWM prediction




Weather Generator Model

- Precipitation model
 - Wet/dry-spell alternation scheme




- Dry-spell model
 - Negative binomial
 - Parameters: mean and shape.
 - The mean is affected by EAWM



Weather Generator Model

- Wet-spell model
 - Markov model,
 - Gamma distribution,
 - Gaussian copula model.




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



Weather Generator Model

- Wet-spell model
 - Parameters:
 - Transition probabilities, mean of rainfall amount, Covariance matrix of Gaussian copula, etc.
 - They are assumed to be affected by EAWM.



Statistical space-time diagnostics of ENSO diversity and associated tropical Pacific rainfall variability, and evaluation of their reproducibility in APCC MME seasonal prediction

Soo-Jin Sohn¹, Chi-Yung Tam², and Jong-Seong Kug³

¹APEC Climate Center (APCC), Busan, Republic of Korea

²Chinese University of Hong Kong, Hong Kong, China

³Pohang University of Science and Technology, Pohang, Republic of Korea


June 26, 2019



Data

Country	Institute	Model	AGCM/resolution	OGCM/resolution	Ensemble Member	Hindcast Period	Reference
Australia	BOM	POAMA2.4	BAMv3.0d/T47L17	ACOM2/0.5-1.5°lat x 2°lon L25	33	1983-2011	Cottrill et al. (2013)
Canada	MSC	CCCma	AGCM3/T63L31	OGCM4 (1.41°lon x 0.94°lat L40)	10	1982-2010	Merryfield et al. (2013)
		CGCM3					
	MSC	CCCma	AGCM4/T63L31		10	1982-2010	
		CGCM4					
Italy	CMCC	CMCC-SPSv2	ECHAM5.3/T63L19	OPA8.2/ORCA2 grid_L31	9	1982-2005	Alessandri et al. (2010)
Korea	APCC	CCSM3	CAM3/T85L26	POP1.3/Gxlv3_L40	5	1983-2014	Jeong et al. (2008)
USA	NASA	GMAO	GEOS-5/288x181L72	MOM4/720 x 410 L40	11	1982-2011	Ham et al. (2012, 2014)
	NCEP	CFSv2	GFS/T126L64	MOM4/1/3°lat x 1°lon L40	17	1983-2005	Saha et al. (2014)

Prediction skill of tropical Pacific Precipitation




- Observed monthly mean Niño 3.4 index amplitude (*red dashed line*) and the anomaly pattern correlation (ACC) skill of the one-month lead MME mean tropical Pacific precipitation prediction (*blue dashed line*)
- Annual mean of ACC skills of the tropical Pacific precipitation prediction
- Total mean of ACC skills of the tropical Pacific precipitation prediction as a function of forecast lead time

- MME prediction skill is related to both the strength and flavor of ENSO.
- Amplitude of ENSO is highly correlated to the forecast skill of tropical Pacific precipitation
- Model forecasts of tropical Pacific precipitation were found to be most skillful during eastern Pacific (EP) El Niño.

Prediction skill of tropical Pacific Precipitation

Selected ENSO Events




- Models exhibit some difficulties in reproducing the anomalous rainfall during the CP El Niño event of 2004-2005
- >> **Skill of dynamical prediction systems in capturing tropical Pacific precipitation is strongly affected by ENSO occurrence and its diversity**

“Typical” ENSO


a

EOF Loading Vector



b

Combined Principal Component




>> SSTA data were stratified into those due to typical ENSO (1st EOF) and their residue

- 1st loading vector (which explains about 37 to 51% of the domain-integrated variance) can well represent anomalous warming over the eastern tropical Pacific Ocean up to the Peruvian coast
- The associated PC is highly correlated with the Niño 3

Typical ENSO


TCC Skills of 1st PC



- Models perform well in predicting typical ENSO, although there is a seasonal dependence in its predictability.

Typical ENSO

Regression onto 1st PC




- Warming is seen over the central to eastern tropical Pacific, with maxima over the eastern equatorial Pacific and the Peruvian coast → MME mean can replicate such geographical features with high fidelity, albeit with a slight westward shift of the overall pattern
- Precipitation signals show wetter-than-normal (drying) conditions from the central to eastern Pacific (western Pacific trailing to south Pacific) → MME mean can also mimic this pattern well

Typical ENSO

Time-averaged ACC skills


a

SST



b

Precipitation




- MME's skill is highly and significantly associated with the strength of typical ENSO through all lead times
- Tropical Pacific precipitation prediction skill is highly related with the strength of typical ENSO, especially during boreal winter

— Persistence — MME — Avg — Model Spread — γ (MME Skill, |Niño 3|) — 95% C.I.

Residual ENSO Signals


Variance



- For residual ENSO signals, its related SSTA variability pattern is captured in MME despite having much weaker amplitudes
- MME performs well in capturing precipitation variations related to typical ENSO, but not the residual variability which is large over the western Pacific in observations


Residual ENSO Signals

TCC Skills




- Typical ENSO is the major source of SST predictability
- Residual ENSO diversity is at least as important as typical ENSO for precipitation forecasts

Co-variability btwn residual SST & Rainfall



- 1st SVD mode gives an SST singular vector that greatly resembles the east-west shift from typical El Niño features to El Niño diverse patterns

SDs of typical ENSO & Diversity




- For typical ENSO, MME and individual models' results are close to observations
- All model predictions, and hence the MME mean, underestimate the amplitude of the residual ENSO SSTA.

Residual ENSO Signals

Time-averaged ACC skills


a

SST



b

Precipitation



- Compared to the total fields, MME's ability in predicting the residual SST and precipitation is more limited
- MME's skill for SST and precipitation predictions is highly related to the observed amplitude of residual ENSO signals


— Persistence — MME — Avg — Model Spread — γ (MME Skill, |Diversity|) — 95% C.I.

Skills


a Typical ENSO

b Residual ENSO signals

Lead 1



Lead 4




Models' representation of SST and precipitation in relation to ENSO diversity

- Compared with typical ENSO, results for residual ENSO signals present even larger spreads, especially for four-month lead predictions
- A model with poor performance in predicting residual ENSO SST also captures poorly the related tropical Pacific precipitation



Potential Predictability



- Typical ENSO is major source of tropical SST predictability
- Limiting factor in precipitation PP is actually due to residual ENSO signals, even though typical ENSO is the source of predictability for SST

Summary

- With a focus on ENSO and its diversity, we have investigated the prediction skill of tropical Pacific sea surface temperature (SST) and precipitation, based on retrospective forecasts from 1983 to 2005 of the APEC Climate Center (APCC) multimodel ensemble (MME) 6-month climate prediction.
- Two space-time statistical methods were used for diagnosing ENSO and associated tropical Pacific rainfall variability on a year-to-year basis.
- First of all, anomalous SST data were stratified into those due to canonical ENSO and their residue. The former is defined as the reconstruction of data based on the leading EOF of the Pacific SST itself. It was found that canonical ENSO and its impacts on tropical rainfall are well captured by dynamical seasonal prediction systems.
- Next, singular vector decomposition (SVD) analyses were carried out in order to identify climate modes related to the co-variability between residual SST signals and precipitation. Dynamical models have difficulties in reproducing the strength of this mode on the interannual scale. Their skill in predicting the temporal variation of this mode is also much lower than that for canonical ENSO.
- Finally, it is found that the statistical methods adopted here well represent the ENSO diversity and even its role in seasonal forecasting of tropical Pacific rainfall.



Thank You !!