

동아시아 대기의 강 탐지 알고리즘 비교

김규리 · 백승윤 · 권예은 · 손석우*

서울대학교 지구환경과학부

(접수일: 2023년 7월 6일, 수정일: 2023년 8월 3일, 게재확정일: 2023년 8월 8일)

Comparison of Atmospheric River Detection Algorithms in East Asia

Gyuri Kim, Seung-Yoon Back, Yeeun Kwon, and Seok-Woo Son*

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

(Manuscript received 6 July 2023; revised 3 August 2023; accepted 8 August 2023)

Abstract This study compares the three detection algorithms of East Asian summer atmospheric rivers (ARs). The algorithms developed by Guan and Waliser (GW15), Park et al. (P21), and Tian et al. (T23) are particularly compared in terms of the AR frequency, the number of AR events, and the AR duration for the period of 2016-2020. All three algorithms show similar spatio-temporal distributions of AR frequency, centered along the edge of the North Pacific high. The maximum AR frequency gradually shifts northward in early summer as the edge of the North Pacific High expands, and retreats in late summer. However, the detailed pattern and the maximum value differ among the algorithms. When the AR frequency is decomposed into the number of AR events and the AR duration, the AR frequencies detected by GW15 and P21 are equally explained by both factors. However, the number of AR events primarily determine the AR frequency in T23. This difference occurs as T23 utilizes the machine learning algorithm applied to moisture field while GW15 and P21 apply the threshold value to moisture transport field. When evaluating AR-related precipitation, the ARs detected by P21 show the closest relationship with total precipitation in East Asia by up to 60%. These results indicate that AR detection in the East Asian summer is sensitive to the choice of the detection algorithm and can be optimized for the target region.

Key words: Atmospheric Rivers, Detection Algorithm, East Asian Summer, AR Precipitation

1. 서 론

대기의 강(Atmospheric River, AR)은 가늘고 긴 띠의 형태로 이루어지는 수증기 수송 현상으로 전 지구 수문 순환에 있어 중요한 역할을 한다(Zhu and Newell, 1998; Newman et al., 2012; Gimeno et al., 2016). 특히 AR은 강수 혹은 극한 강수와 밀접한 관련이 있으며(Ralph et al., 2006; Neiman et al., 2011; Ralph and

Dettinger, 2012; Konrad and Dettinger, 2017), 특정 지역의 지속적인 가뭄을 종식시키거나(Dettinger, 2013) 수자원을 공급하기도 한다(Guan et al., 2010; Dettinger et al., 2011). 이와 같이 수문 순환과 지역 강수에 큰 영향을 미치는 AR의 중요성을 고려할 때, 정확한 AR 탐지의 중요성이 대두되고 있다.

일반적으로 AR을 탐지하기 위해서는 임계값 설정이 필요하다. 임계값으로는 주로 연직 적분된 수증기(Integrated Water Vapor, IWV) (e.g., Ralph et al., 2004; Bao et al., 2006; Wick et al., 2013; Goldenson et al., 2018) 혹은 연직 적분된 수증기 수송(Integrated water Vapor Transport, IVT)을 사용하는데 최근 연구는 주로 IVT를 이용하는 추세이다. 임계값으로 사용

*Corresponding Author: Seok-Woo Son, School of Earth and Environmental Sciences, Seoul National University, 1 Gwanak-ro, Gwanak-gu, Seoul 08826, Korea.
Phone: +82-2-880-8152, Fax: +82-2-883-4972
E-mail: seokwooson@snu.ac.kr

할 변수를 결정한 이후에는 임계값의 크기를 절대 임계(absolute threshold) (e.g., $IVT \geq 250 \text{ kg m}^{-1} \text{ s}^{-1}$) (e.g., Rutz et al., 2014) 혹은 상대 임계(relative threshold) (e.g., $IVT \geq IVT$ 기후 값의 85번째 백분율값) (Lavers et al., 2012)로 설정할 것인지를 결정한다. 이후 길이, 축, 방향, 비율 등의 기하학적 특성을 고려하여 AR을 탐지하며, 추가적으로 극 수송 수증기의 유무, AR의 중심이 위치한 위도 등의 조건을 고려하기도 한다.

임계값을 중심으로 AR을 탐지하는 방법과 달리, 머신러닝 혹은 딥러닝 기반 탐지 방법을 사용하여 특정한 임계값 없이 AR을 정의하기도 한다. Radić et al. (2015)에서는 머신러닝의 일종인 자기조직화지도(Self-Organizing Maps, SOM)를 이용하여 대규모의 IVT 특성을 파악해 AR의 미래변화에 대해 살펴보았고, Muszynski et al. (2019)에서는 Support Vector Machine (SVM) classifier를 이용해 사례를 AR 및 non-AR로 이진 분류(binary classification)하는 방법을 제안하였다. Higgins et al. (2023)에서는 CG (Context Guided) - Climate이라는 합성곱 신경망(Convolutional Neural Network, CNN)을 기반으로 이미지 내 AR 패턴의 존재 여부를 탐지하였다. 이처럼 연구 별로 각기 다른 과정을 통해 AR을 탐지하고 있기에 최근 AR 커뮤니티에서는 국제적인 협력(Atmospheric River Tracking Intercomparison Project, ARTMIP)을 통해 다양한 알고리즘이 가져올 불확실성에 대해 이해하고자 하는 연구가 진행되기도 했다(Shields et al., 2018; Rutz et al., 2019).

동아시아의 경우 비교적 최근에야 AR의 영향을 많이 받는 지역으로 주목 받기 시작했다. 동아시아 AR은 여름철에 가장 빈번하게 발생하며 여름철 강수 및 극한 강수와 밀접한 관련이 있음이 확인되었다(Guan and Waliser, 2015; Mundhenk et al., 2016; Kamae et al., 2017a, b; Pan and Lu, 2020; Kim et al., 2021; Park et al., 2021; Kwon et al., 2022). 그러나 다른 지역과 마찬가지로 사용한 알고리즘에 따라 AR 발생 빈도 및 강수에 미치는 영향의 차이가 나타난다. 일례로 Mundhenk et al. (2016) 알고리즘을 사용한 Kamae et al. (2017a)에서는 여름철 동아시아 AR의 빈도수가 13~16% 정도로 나타났고 PanLu2.0 알고리즘을 사용한 Pan and Lu (2020)에서는 6월 중순에서 7월 초의 AR의 빈도수가 최대 30% 정도까지 나타난다. 또한 Park et al. (2021)에서는 Guan and Waliser (2015) 알고리즘을 개선한 알고리즘을 이용하여 여름 몬순 시기의 동아시아 AR의 빈도수를 약 20% 정도로 보고하였다. 이와 같은 차이는 사용한 데이터와 AR탐지 알고리즘의 차이 때문으로 추정되지만, 아직까지 알고리즘간 직접적인 비교 분석은 수행되지 않았다.

본 연구는 다양한 AR 탐지 알고리즘을 비교하여,

동아시아 여름철 AR 탐지의 불확실성을 평가하고자 한다. 유사한 연구가 유럽과 미국 서부에 대해 진행된 바가 있으나(Shields et al., 2018; Rutz et al., 2019; O'Brien et al., 2022), 동아시아에 대해서는 보고된 바가 없다. 구체적으로 상대적인 임계값을 사용하는 Guan and Waliser (2015) 알고리즘(GW15), 절대적인 임계값을 사용하는 Park et al. (2021) 알고리즘(P21) 그리고 딥러닝 기반의 Tian et al. (2023) 알고리즘(T23)을 선택하여 동아시아에서 AR이 가장 빈번한 여름철에 대해 AR 탐지 특성을 비교하였다. 각기 다른 알고리즘을 활용하여, 각 알고리즘이 탐지하는 동아시아 여름철 AR의 특성을 이해할 수 있을 것으로 기대된다.

이후의 구성은 다음과 같다. 2장에서는 본 연구에서 사용한 자료와 세 가지 AR 탐지 알고리즘을 설명하였고, 3장에서는 각 알고리즘이 탐지한 동아시아 여름철 AR의 결과를 AR 빈도수로 비교하였다. 이를 AR 발생 횟수 및 AR 지속 시간으로 나누어 살펴보았으며 AR 강수 또한 비교하였다. 마지막으로 4장에서는 주요 결과를 요약하고 토의하였다.

2. 자료 및 방법

2.1 자료

유럽중기예보센터(European Center for Medium-range Weather Forecasts, ECMWF)에서 제공하는 ECMWF Reanalysis version 5 (ERA5, Hersbach et al., 2020) 재분석 자료를 사용하였다. 해당 자료는 6시간의 시간 해상도와 $1.5^\circ \times 1.5^\circ$ 의 수평해상도, 37개의 연직해상도를 가진다. 본 연구에서는 IVT를 계산하기 위해 ERA5 재분석 자료의 1000 hPa부터 300 hPa까지의 동서 방향, 남북 방향의 바람과 비습을 사용하였다. 마찬가지로 비습을 연직 적분하여 IWV를 정의하였다. 구체적으로 IVT와 IWV는 (식 1)과 같이 계산된다.

$$IVT = |IVT|, IVT = \left(-\frac{1}{g} \int_{1000 \text{ hPa}}^{300 \text{ hPa}} qudp \right) \vec{x} + \left(-\frac{1}{g} \int_{1000 \text{ hPa}}^{300 \text{ hPa}} qvdp \right) \vec{y}$$

$$IWV = -\frac{1}{g} \int_{1000 \text{ hPa}}^{300 \text{ hPa}} qdp \quad (1)$$

이때 \vec{x} , \vec{y} 는 각각 동서, 남북 방향의 단위 벡터, u , v 는 각각 동서방향과 남북방향의 바람, q 는 비습, g 는 중력가속도를 나타낸다. 연직 적분은 하부 대류권부터 상부 대류권에 속하는 1000 hPa에서 300 hPa까지를 고려하였다.

강수 분석을 위해 미국 해양대기청(National Oceanic

and Atmospheric Administration, NOAA)에서 제공하는 Global Precipitation Climatology Project (GPCP)의 $1^\circ \times 1^\circ$ 일별 강수 자료를 이용하였다(Adler et al., 2018). ERA5와 GPCP 모두 2016년부터 2020년의 6~8월 기간을 사용하였다.

2.2 AR 탐지 알고리즘

본 연구에서는 동아시아 지역의 AR 탐지를 비교하기 위해서 3가지의 서로 다른 알고리즘을 사용하였다. 해당 알고리즘은 IVT 상대 임계값을 활용한 GW15, IVT 절대 임계값을 활용한 P21, IWV를 학습시켜 AR을 탐지하는 딥러닝 알고리즘 T23이다. GW15는 IVT가 절대적 기준 값(상위 85% 이상 및 $100 \text{ kg m}^{-1} \text{ s}^{-1}$ 이상)을 만족하는 연속된 격자들의 집합을 AR 후보 객체로 선정한다. 가장 먼저 각 격자에서 5개월 이동창 내 IVT 중 상위 85%를 초과하는 지점을 해당 타임 스텝의 AR 후보로 선정한다. 수분 함량이 지속적으로 낮은 극지방의 경우, 상위 85%에 해당하는 IVT 값이 현저하게 작기 때문에 절대 임계값을 사용하여 $100 \text{ kg m}^{-1} \text{ s}^{-1}$ 을 넘는 객체만을 남긴다. 이 중 객체 IVT의 방향이 평균 IVT의 방향과 45° 이상 차이 나는 경우를 제외하여 AR의 방향과 실제 수증기 수송 방향의 차이가 크지 않은 객체들만을 포함한다. 또한, 객체 평균 IVT의 북향 성분이 $50 \text{ kg m}^{-1} \text{ s}^{-1}$ 이하이거나, 객체가 적도에 걸쳐 있는 경우 AR 후보 객체에서 제외한다. 이를 통해 북향 수증기 수송만을 고려한다. 마지막으로 AR의 기하학적 정의를 고려하여

길이가 2000 km 이상이고 길이와 너비의 비율이 2 이상인 객체만을 남긴다. 이 과정을 모든 기간에 대해 반복 수행한 후 남은 객체들을 AR로 정의한다(Guan and Waliser, 2015).

P21은 GW15를 동아시아의 실정에 맞게 변형한 것으로, 두 가지 주요 수정을 통해 동아시아 여름 몬순 수증기 수송(Park et al., 2021)의 특성을 반영한다. 첫 번째는 IVT 아노말리가 $150 \text{ kg m}^{-1} \text{ s}^{-1}$ 이상인 연속된 격자들의 집합을 AR 후보 객체로 선정한 것으로, IVT 아노말리는 동아시아 여름 몬순 시기에 극한 강수를 잘 포착한다고 알려져 있다(Liang and Yong, 2021). 또한, 북향에 대한 조건을 포함하지 않았다는 점에서 GW15와 차이점이 있다. 이는 동아시아 여름 몬순에 동반되어 발생하는 AR은 종종 동서방향으로 길게 늘어져 수증기를 공급하기 때문이다. 이 두 조건을 제외한 다른 조건들은 GW15와 동일하게 유지하여 AR을 정의한다(Park et al., 2021). 이처럼 P21은 GW15를 기반으로 한 탐지 알고리즘이지만 GW15는 상대적 임계값을, P21은 절대적 임계값을 사용하여 AR을 정의한다는 점에서 큰 차이를 보인다. Figure 1에서는 앞에서 설명한 GW15와 P21의 탐지 과정의 순서를 도식화하였다.

T23은 여러 개의 합성곱 신경망을 앙상블하여 구성한 딥러닝 알고리즘이다. 총 다섯 개의 알고리즘(CGNet, U-Net, DeepLabv3+, PSPNet, DUC-HDC)을 사용하며, ClimateNet (Kashinath et al., 2021)에서 제공하는 IWV와 850-hPa 바람장을 이용하여 학습한 버전이다(Tian

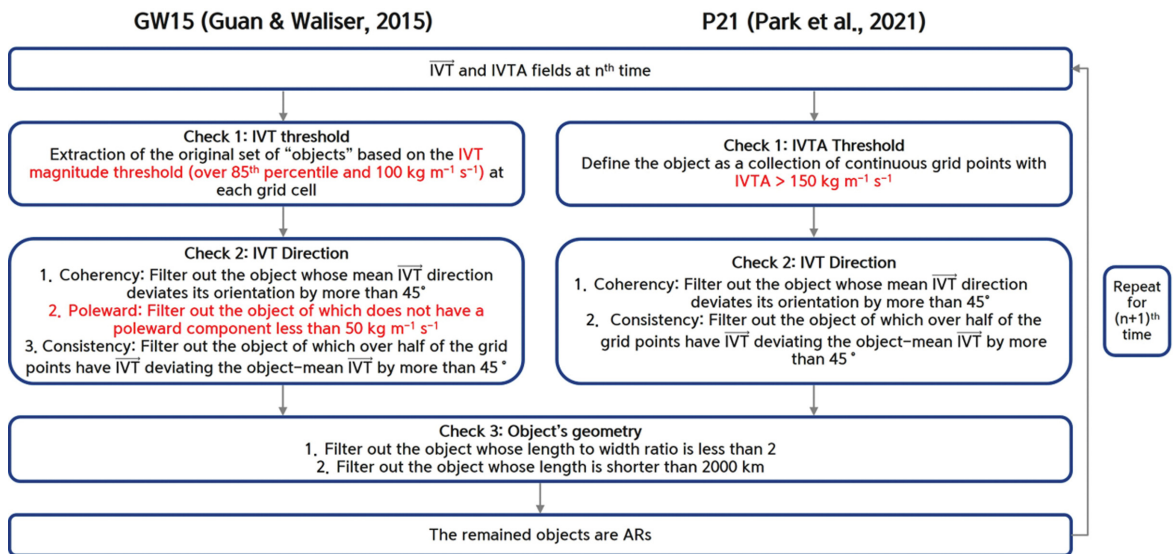


Fig. 1. AR detection procedures of Guan and Waliser (2015; GW15) and Park et al. (2021; P21) algorithms. The key differences between the two algorithms are highlighted in red.

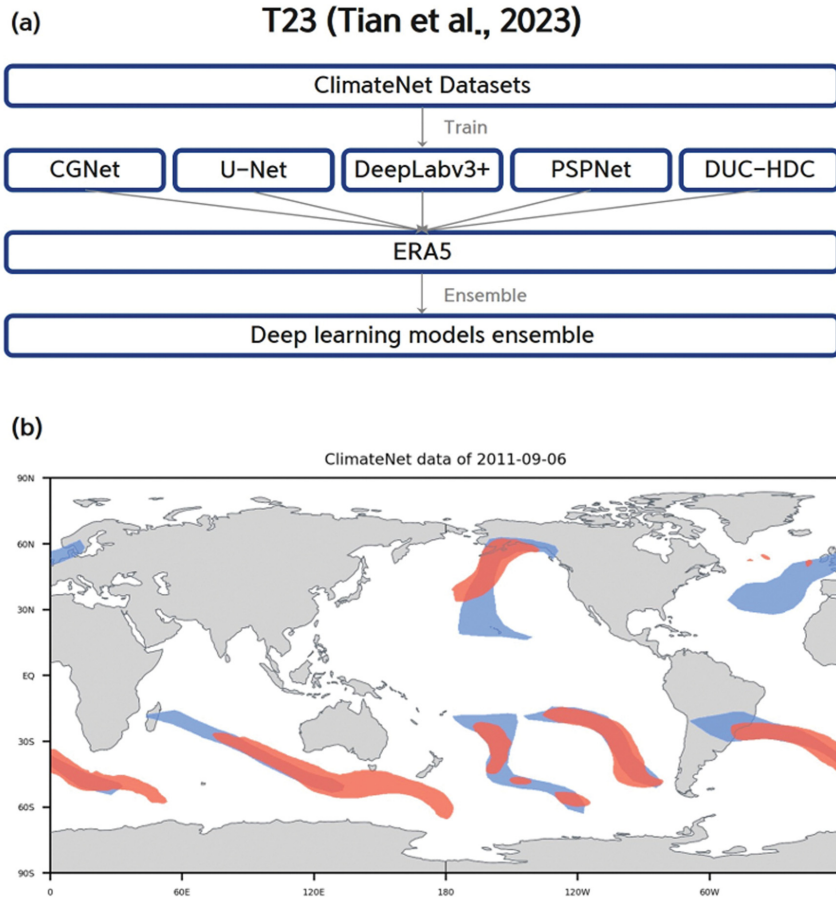


Fig. 2. (a) AR detection procedure using five deep learning algorithms, and (b) ARs labelled in ClimateNet on September 6, 2011 (blue shades) and ARs detected by deep learning algorithms (red shades). See Tian et al. (2023) for the details of each algorithm.

et al., 2023). 각 알고리즘으로 ERA5 자료를 개별 탐지한 후 다섯 알고리즘 모두가 AR로 탐지한 지점을 AR로 정의한다. T23의 경우 앞서 설명한 GW15와 P21과는 다르게 특정 임계값을 고려하지 않다는 차이점이 있다. 또한, IVT 값이 없는 자료에 대해서도 AR을 탐지할 수 있다는 장점이 있다. Figure 2a는 T23을 구성하는 과정들을 모식도로 나타낸 것이다. 앙상블에 사용된 개별 알고리즘은 부록에 간략히 설명하였다. Tian et al. (2023)에서 자세한 설명을 찾을 수 있다. Figure 2b는 ClimateNet 2011년 9월 6일 자료에서 AR로 라벨링한 지점을 파란색으로, T23으로 탐지한 결과를 빨간색으로 나타내 비교한 것이다.

2.3 AR 빈도수, AR 발생 횟수, AR 지속 시간, AR 강수의 정의

AR 빈도수는 각 격자점에서 전체 기간 중 AR이 존

재했던 기간의 비율을 나타낸다(Espinoza et al., 2018). 반면 각 격자점에서 불연속적으로 존재한 AR들 중 12시간 이상 지속된 것을 개별 AR로 정의하며 이것의 총 개수를 AR 발생 횟수로 정의하였다. 이 개별 AR들이 지속된 총 시간을 AR 발생 횟수로 나누어 평균적인 AR 지속 시간을 계산하였다. AR의 영향을 받은 강수(AR 강수)는 강수 자료에서 AR과 강수가 동시에 존재하는 것을 기준으로 판별하였다(e.g., Moon et al., 2019). 특히 각 격자점에서 하루 4번의 시간 간격 중 2번 이상 AR이 관측되었을 때 해당 격자에서의 일 누적 강수를 AR 강수로 정의하였다.

3. 결 과

3.1 AR 탐지 예시

Figure 3는 세 가지 다른 알고리즘으로 2020년 7월

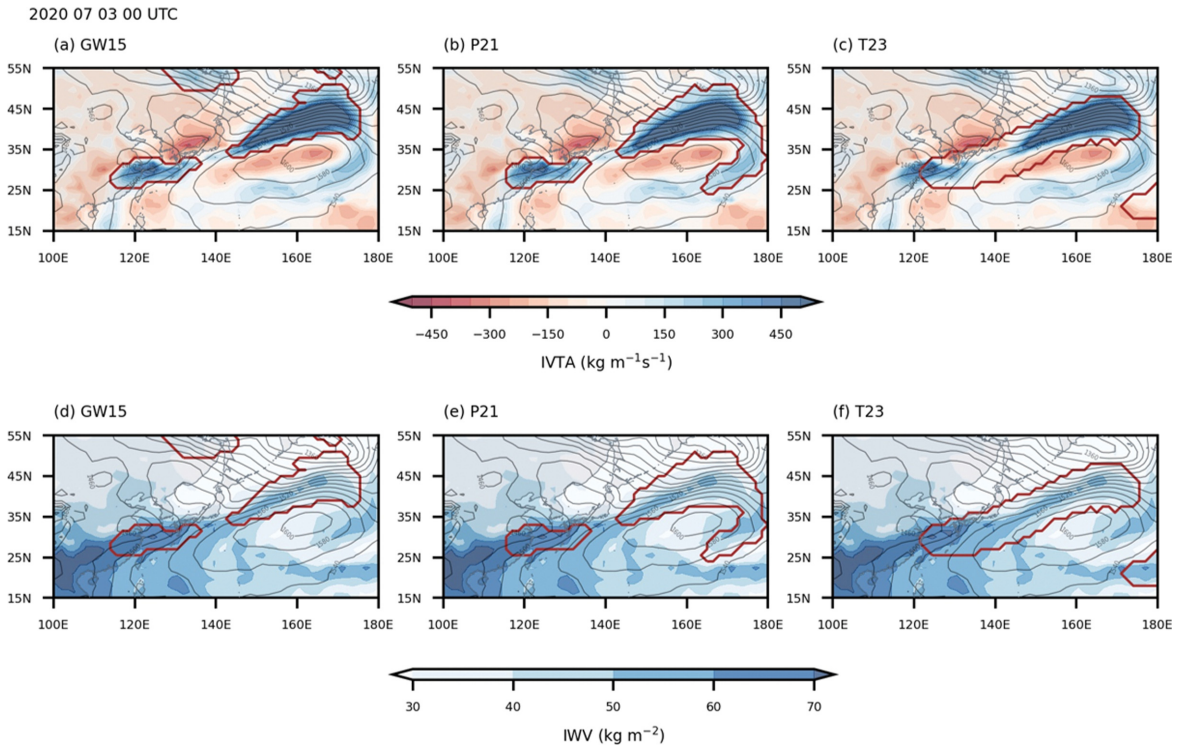


Fig. 3. Example of East Asian ARs on 00 UTC July 3, 2020. Figures (a)-(c) shows the 850-hPa geopotential height (gpm, contoured), IVTA ($\text{kg m}^{-1} \text{s}^{-1}$, shaded), and ARs (thick red line) detected by (a) GW15, (b) P21, (c) T23. Figures (d)-(f) are same as Fig. (a)-(c) but shows IWV (mm, shaded) instead of IVTA.

3일 00 UTC의 AR을 탐지한 결과를 나타낸다. IVTA는 동중국부터 한반도 남쪽에 양의 값을 보이며, 북서태평양 고기압의 북쪽 가장자리를 따라 강한 양의 값이 나타난다(Fig. 3a). IWV는 동중국부터 서일본 지역까지 높은 값을 보이며, IVTA가 강하게 나타나는 지역인 북태평양 고기압의 가장자리를 따라서도 40~60 kg m^{-2} 정도의 IWV 값이 나타났다(Fig. 3d).

GW15에서 탐지한 AR의 경우 동아시아 지역에서 3개의 AR을 탐지하였으며, IVTA의 최댓값을 중심으로 탐지되는 것을 확인할 수 있다(Fig. 3a). P21의 경우, GW15와 유사하게 AR을 탐지 하였으나 몇 가지 차이점을 보인다. P21은 GW15와 달리 러시아 극동 남쪽 지역의 양의 아노말리가 AR로 탐지되지 않았다(Fig. 3b). 이는 해당 지역의 IVT가 상위 85%에 해당했지만, IVTA가 $150 \text{ kg m}^{-1} \text{ s}^{-1}$ 를 넘지 않기 때문이다. 다른 차이점은 북서태평양 지역에서의 AR이 P21에서 GW15보다 더 넓게 탐지된 것이다(Figs. 3a, b). T23의 경우, AR 탐지 영역이 북서태평양 북쪽 가장자리를 따라 다른 알고리즘보다 넓고 길게 나타났다. IVTA 최댓값을 중심으로 AR이 탐지된 GW15와 P21과는 달리 T23은 IVTA 분포와 유사하게 나타나지는

않으며, IWV와 보다 유사하게 나타난다(Fig. 3f).

3.2 AR 빈도수

Figure 4는 세 알고리즘으로 탐지한 동아시아 지역의 여름철(6~8월, JJA) 및 월 별 AR 빈도수를 나타낸다. 세 알고리즘 모두 동아시아 지역의 여름철 평균 AR 빈도수는 북태평양 고기압의 가장자리를 따라 높게 나타나는 특징을 보인다(Figs. 4a-c). 하지만 각 알고리즘은 AR 빈도수의 집약적인 분포 정도와 그 최댓값에 있어서 차이를 보인다. GW15은 여름철 AR 빈도수를 동아시아 지역 전반적으로 넓은 영역에서 약 10~20%의 빈도를 보였다(Fig. 4a). P21로 탐지한 AR은 북서태평양 고기압의 가장자리인 기압경도가 큰 지역을 따라서 집약적으로 분포하며, 이 지역에서 GW15보다 빈도수를 약 5% 정도 더 빈번하게 탐지하였다(Fig. 4b). T23은 다른 두 알고리즘에 비해서 북서태평양 해양 지역의 AR 빈도수를 더 빈번하게 탐지하며, P21의 AR 빈도 최댓값이 약 160°E에 부근에 존재하는 것과 달리, 보다 더 동쪽(180°E)에서 AR 빈도의 최댓값이 나타났다.

이러한 알고리즘별 특징은 각 월별 AR 빈도에서도

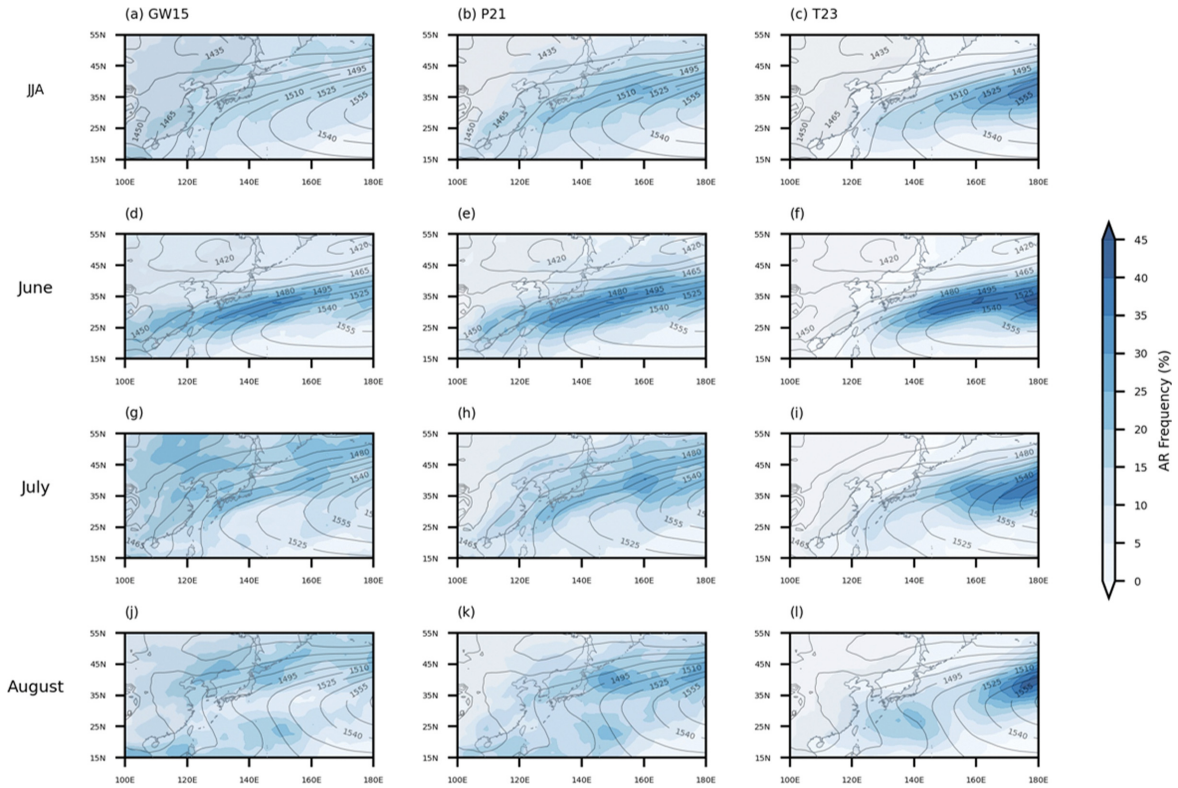


Fig. 4. (a)-(c) Seasonal-mean (JJA) and (d)-(l) monthly climatology of AR frequency (% , shaded) detected by GW15, P21, and T23 and 850-hPa geopotential height (gpm, contoured) in East Asia.

유사하게 나타난다. 세 AR 탐지 알고리즘 모두 북서태평양 고기압의 가장자리를 따라 AR 빈도수의 최대값이 점차 북상하고, 8월부터는 북서태평양 고기압이 동쪽으로 후퇴함에 따라 AR 빈도수가 상대적으로 감소하는 월별 변화를 보인다. 공통된 월별 변화에도 불구하고, 각 알고리즘에서 탐지한 AR의 월별 빈도수는 조금 다르게 분포한다. GW15의 경우 6월 AR 빈도수는 북태평양 고기압의 가장자리를 따라 길고 뚜렷하게 나타남에 비해, 7월과 8월에는 북서태평양 고기압의 가장자리를 중심으로 보다 더 넓은 영역에서 산발적으로 나타났다. GW15와는 달리 P21은 6월과 7월 모두 기압 경도가 큰 북서태평양 고기압의 가장자리에 집약적으로 AR이 분포하였으며, 기압 경도가 약해지는 8월에 넓은 영역에서 AR을 탐지하였다. T23의 경우 P21과 유사하게 AR이 북서태평양 고기압의 가장자리를 따라서 집약적으로 탐지된 것으로 보이나, 다른 알고리즘에 비해서 AR 빈도수의 최대값이 보다 더 동쪽에 나타나며 남북방향으로 이 최대값의 월별 변동이 제일 적게 나타났다. T23의 AR 빈도수의 최대값은 다른 알고리즘에 비해서 모든 월에 대해서 더

높게 나타났다. 반면 GW15와 P21은 빈도수의 최대값이 6월에는 거의 비슷하게 나타나나, 7월과 8월에 P21의 AR 빈도수의 최대값이 GW15보다 5% 정도 더 크게 나타났다.

이처럼 6월에는 세 AR 탐지 알고리즘의 AR 빈도수가 북태평양 고기압의 가장자리를 따라 큰 값을 보여 분포 및 강도 편차가 적었고, 북태평양 고기압이 점차 북상하는 7월과 8월에는 알고리즘 별 AR 빈도수 분포 및 강도 편차가 컸다. IVT를 기준 값으로 하는 GW15와 P21의 등지위고도선 간격이 좁고 수증기 수송량이 많은 곳에서 AR 빈도수가 크게 나타난 반면, IWV를 기반으로 학습된 T23의 경우 수증기량이 많은 곳 위주로 AR 빈도수가 크게 나타나는 것을 확인하였다. 이 결과를 통해 동아시아 여름철 AR 탐지는 알고리즘에 민감하다는 사실을 재확인할 수 있다.

3.3 AR 발생 횟수 및 AR 지속 시간

앞서 살펴 본 각 탐지 알고리즘의 AR 빈도수를 결정하는 요인 분석을 하기 위해 AR 발생 횟수와 AR 지속 시간으로 나누어 살펴보았다. 참고로 AR 지속

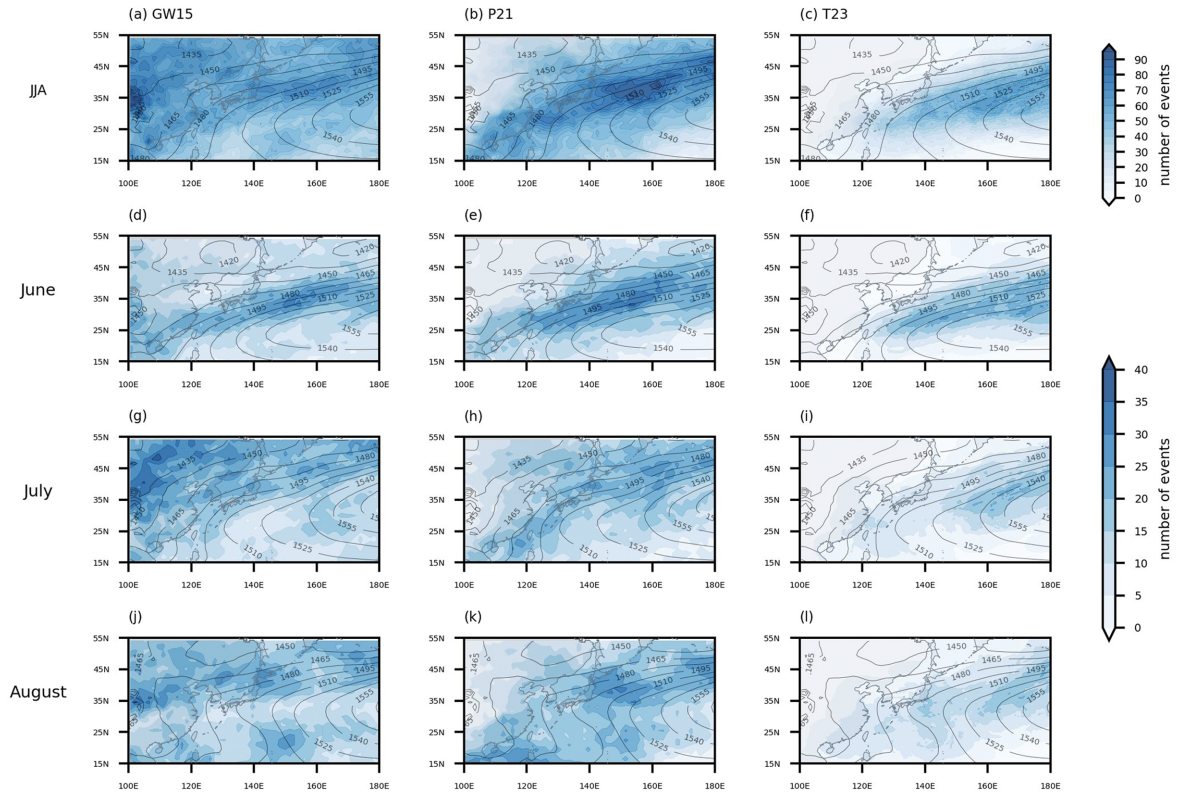


Fig. 5. (a)-(c) Seasonal-mean (JJA) and (d)-(l) monthly number of ARs (shaded) detected by GW15, P21, and T23 and 850-hPa geopotential height (gpm, contoured) in East Asia.

시간과 AR 발생 횟수의 곱을 전체 기간으로 나누면 AR 빈도수와 유사한 분포를 보인다. Figure 5는 세 알고리즘에서 나타난 여름철 및 월 별 AR 발생 횟수를 나타낸 것이다. 여름철 및 월 별 AR의 발생 횟수의 분포는 여름철 및 월 별 AR의 빈도수 분포와 거의 유사하게 나타난다(Fig. 5). 여름철 평균 및 6월의 AR 빈도수 분포는 세 알고리즘 모두 북서태평양 고기압의 가장자리를 따라 나타나며, 7월과 8월은 보다 넓은 영역에 산발적으로 분포한다. 눈에 띄는 점은 T23에서의 발생 횟수의 월별 변화는 빈도수의 변화와 달리 최대값의 남북 방향 변동이 보다 두드러지게 나타난다는 점이다. 세 알고리즘 간의 AR 발생 횟수의 차이는 알타이-사안 산맥 동쪽 지역에서 두드러지게 나타나는데, GW15에서는 AR의 발생 횟수가 빈번하게 나타나는 반면, P21과 T23에서는 적거나 거의 나타나지 않았다. 화북 지역을 제외한 북서태평양 가장자리에서의 발생 횟수는 P21에서 가장 많은 AR 발생 횟수를, T23에서 가장 적은 AR 발생 횟수를 보였다.

Figure 6은 세 알고리즘으로 탐지한 동아시아 지역의 여름철 및 월 별 AR 지속 시간을 나타낸다. 여름

철 평균 및 6월의 AR 지속 시간은 세 알고리즘 모두 스톱 트랙의 남쪽을 중심으로 지속 시간이 길게 나타나는 반면, 7월 및 8월의 AR 지속 시간은 어떤 뚜렷한 분포를 보이지는 않았다. 여름철 및 각 월별 AR의 지속시간은 AR 발생 횟수와는 달리 T23에서 가장 긴 AR 지속 시간을 보이고, P21에서 가장 짧은 지속시간을 보였다. AR 지속 시간의 분포는 6월, 7월에는 세 알고리즘 모두 비슷하게 나타나나, 8월에는 각 알고리즘 별로 다르게 나타났다. GW15는 필리핀 해역 부근에서 가장 긴 지속시간을 보인 반면 P21은 태평양 부근에서 가장 긴 지속시간을 보였다. 한편 T23은 이 두 지점 모두에서 긴 AR 지속 시간을 보였다.

세 알고리즘에서 AR 빈도수는 정성적으로 유사하게 나타났으나, 그 집약적 분포 정도와 최대값은 각 알고리즘 마다 상이하게 나타났다. GW15와 P21은 북서태평양 고기압의 가장자리에서의 AR 빈도수가 가장 크게 나타나고, P21에서 GW15보다 AR 빈도수가 크게 나타났다. 반면 T23의 경우 AR의 빈도수가 동쪽에 치우쳐 있는 경향이 있고, 다른 두 알고리즘에 비해서 값이 더 크게 나타났다. 여름철 결과에 대해

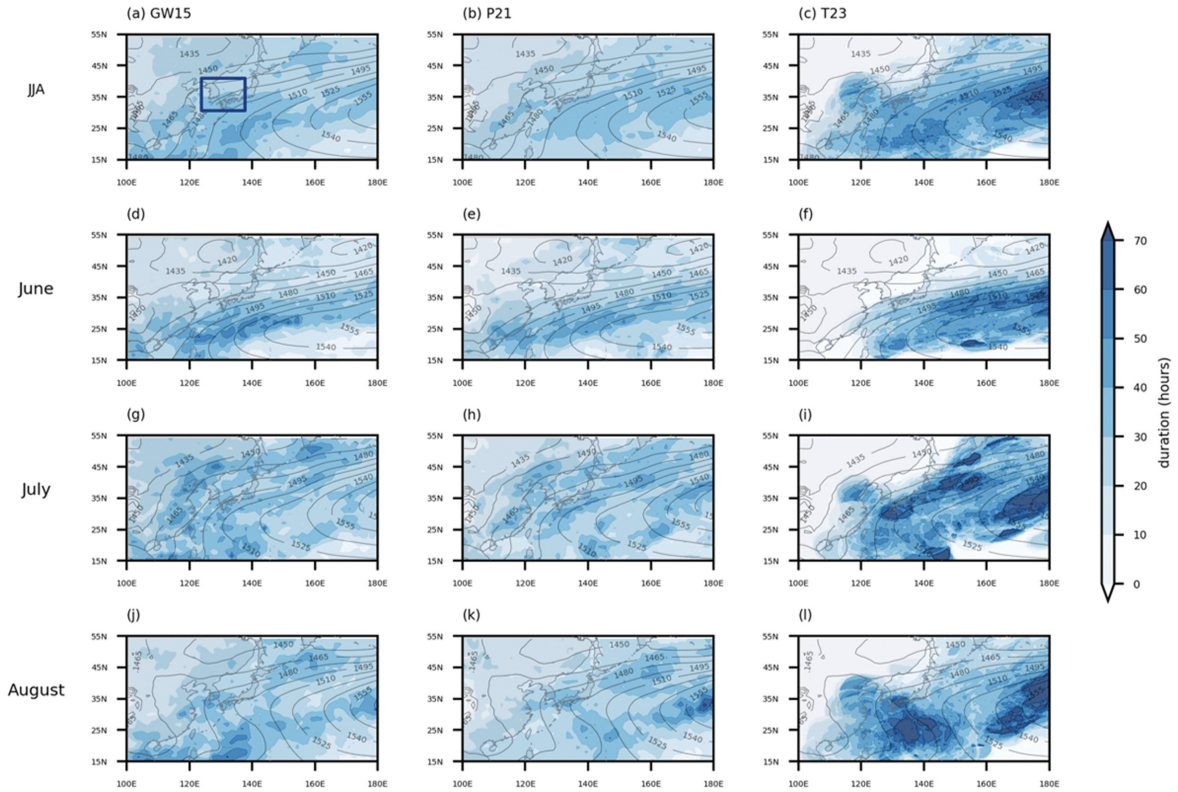


Fig. 6. (a)-(c) Seasonal-mean (JJA) and (d)-(l) monthly duration of ARs (hours, shaded) detected by GW15, P21, and T23 and 850-hPa geopotential height (gpm, contoured) in East Asia. The blue boxed region in (a) is the South Korea and Western Japan domain in this study (30~40.5°E, 124.5~138°E).

각 알고리즘 별로 피어슨 상관 분석을 한 결과 GW15의 AR 빈도수와 지속 시간의 상관 계수가 0.64이고 빈도수와 발생 횟수의 상관 계수는 0.50으로 유사한 분포를 보여 GW15의 빈도수 분포에 두 요인 모두가 중요한 것으로 나타났다. P21의 AR 빈도수와 지속 시간의 상관 계수는 0.86, 빈도수와 발생 횟수의 상관 계수는 0.95로 P21의 빈도수 분포 또한 두 요인 모두에 의해 결정되었다. 반면 T23의 AR 빈도수와 지속 시간의 상관 계수는 0.79이고 빈도수와 발생 횟수의 상관 계수는 0.96으로 AR 발생 횟수가 AR 빈도수 분포에 더 중요한 요인으로 작용하였다. 해당 분석은 통계적으로 유의하였다.

3.4 AR 강수

여름철 동아시아 지역에서 각 알고리즘이 탐지한 AR과 강수의 연관성을 확인하기 위해 순 별 AR의 빈도수와 한반도 및 서일본의 영역 평균(30~40.5°N, 124.5~138°E; Fig. 6c)의 과량 박스)된 순 별 강수를 분석하였다(Fig. 7). 한반도 및 서일본의 영역 평균된 강

수는 6월 초순부터 7월 초순까지 증가하다가, 7월 초순(약 12 mm day⁻¹)에 최대 지점이 나타나는 것을 확인할 수 있다. 이후 강수량이 감소하다 8월 말에 다시 강수량이 증가한다. 이러한 강수량의 순 별 변화는 해당 영역의 AR 빈도수의 변화와 비슷한 양상을 보인다.

세 알고리즘 모두 6월 초순부터 AR의 빈도수가 증가하여 7월 초순에 최댓값을 보이다, 7월 하순까지 감소하는 양상을 보였다. 세 알고리즘 간의 순 별 변화 양상의 차이는 8월 초순부터 나타나는데, GW15와 T23의 경우 8월 AR의 빈도수가 각각 약 13%와 7% 정도로 유지되는 것으로 나타났다. P21의 경우, 8월 초순부터 점차 AR의 빈도수가 증가하여 8월 말에 다시 높은 AR 빈도를 보인다(20%).

Figure 8는 여름철 순 별 영역 평균한 AR 탐지 알고리즘의 AR 강수와 전체 강수량 중 AR 강수의 비율(AR 강수 비율)을 나타낸다. 세 알고리즘에서의 AR 강수의 순 별 변화는 전체 강수의 순 별 변화와 유사한 양상을 보인다(Fig. 7과 Fig. 8의 막대). 세 알고리

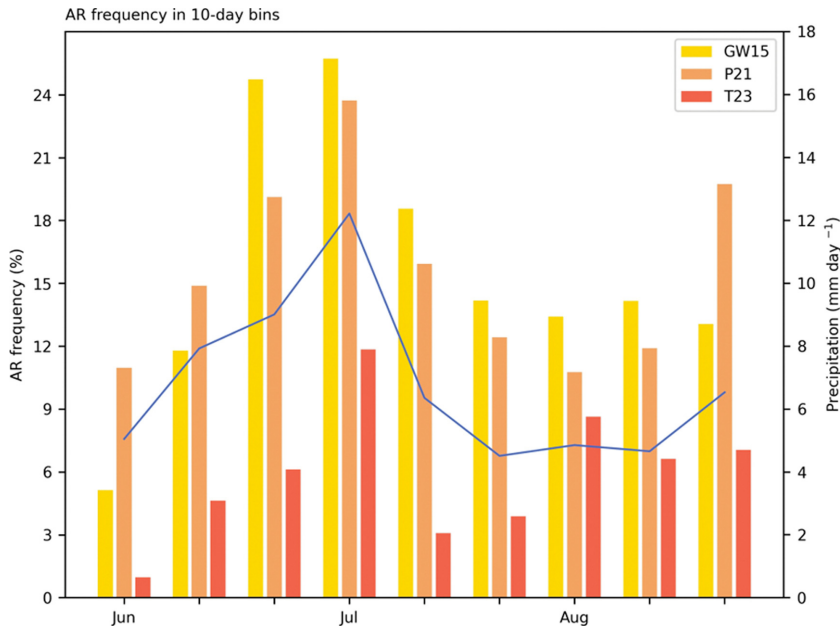


Fig. 7. AR frequency (%; bar) of GW15, P21, and T23 and total precipitation (mm day^{-1} , line) in 10-day bins in South Korea and Western Japan domain (blue boxed region in Fig. 6. (a); $30\sim 40.5^{\circ}\text{E}$, $124.5\sim 138^{\circ}\text{E}$).

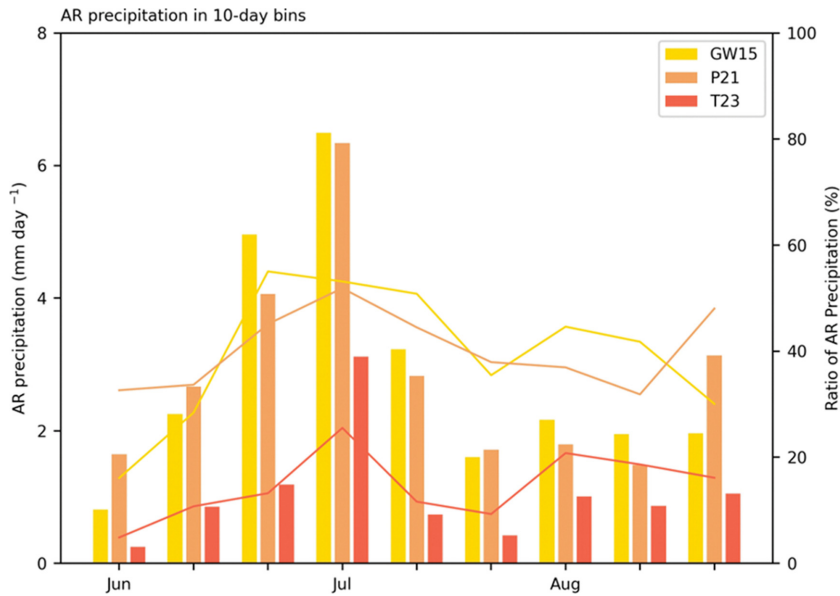


Fig. 8. AR precipitation (mm day^{-1} , bar) and ratio of AR precipitation (%; line) of GW15, P21, and T23 in 10-day bins in South Korea and Western Japan domain (blue boxed region in Fig. 6. (a); $30\sim 40.5^{\circ}\text{E}$, $124.5\sim 138^{\circ}\text{E}$).

즘 모두 6월 초순부터 7월 초순까지 AR 강수가 증가하다 7월 하순까지 감소하는 모습을 보인다. GW15와 T23은 8월에 전체 강수와 유사한 AR 강수량을 보이나 P21은 8월 하순까지 AR 강수가 증가하는 경향을

보인다. 전체 강수 대비 AR 강수의 비율은 GW15와 P21에서 약 30~60% 정도로 나타나며, T23은 약 30% 미만 정도로 낮게 나타났다. 전체 강수 대비 AR 강수 비율의 순 별 변화는 세 알고리즘 모두 두 개의

피크를 보이나, 그 시기가 알고리즘마다 상이하게 나타났다. GW15는 6월 말과 8월 초순에 두 개의 피크를 보이며, P21은 AR 강수의 순 별 변화와 유사하게 7월 초순과 8월 하순에 두 개의 피크를 보였다. 반면 T23의 경우 7월 하순과 8월 초순에 두 개의 피크를 보였다. 강수량과 AR 빈도수 간의 피어슨 상관 분석을 한 결과, GW15 AR과의 상관 계수는 0.75, P21 AR과는 0.89, T23 AR과는 0.59로 나타났다. 즉 P21 알고리즘에서 강수의 순 별 변화가 AR 빈도수와 밀접한 관련을 보였다. 특이한 점은 T23의 AR 빈도수가 다른 알고리즘에 비해서 확연히 적게 나타난 것이다. 이는 T23의 AR 빈도수가 북서태평양 고기압의 가장자리를 중심으로 집약적으로 분포하여 최댓값이 태평양 부근에서 나타나 한반도 및 서일본 지역에는 적게 AR을 모의하기 때문이다(Fig. 4).

4. 요약 및 토의

본 연구에서는 세 가지 AR 탐지 알고리즘으로 동아시아 여름철 AR을 탐지 및 비교 분석하였다. 먼저, 개별 AR 사례를 통해 AR 탐지 알고리즘 간 유의미한 차이가 존재한다는 것을 확인하였다. 보다 긴 기간에서 확인하기 위해 2016년부터 2020년 동아시아 여름철의 AR을 각 알고리즘으로 탐지 후 AR 빈도수를 여름철 평균 및 월 별로 논의하였다.

세 알고리즘 모두 북태평양 고기압의 가장자리를 따라 AR이 빈번하게 탐지되는 특징을 보이지만, 집약적인 분포 정도와 그 최댓값에서 차이를 나타냈다. 여름철에 GW15는 AR 빈도수가 전반적으로 넓은 영역에서 나타난 반면, P21은 기압경도가 큰 지역에 집약적으로 분포했으며 T23은 가장 동쪽에 집중된 분포를 보였다. 월 별 AR 빈도수의 경우 세 알고리즘 모두 북서태평양 고기압의 가장자리를 따라 최댓값을 보였으나 시간에 따라 점차 복잡하다 7월 및 8월부터 상대적으로 감소하는 경향을 보이며 알고리즘 별 편차가 두드러졌다. 이와 같은 결과는 임계 기준에 따라 AR 빈도수가 강조되는 지점이 달랐기 때문으로 확인하였다. AR 빈도수의 요인 분석을 하기 위해 알고리즘 별로 AR 발생 횟수와 AR 지속 시간과의 피어슨 상관 분석을 한 결과 GW15와 P21의 빈도수 분포는 AR 지속 시간과 발생 횟수 모두에 의해 결정됨을 알 수 있었다. 반면, T23은 AR 발생 횟수가 AR 빈도수의 더 주요한 요인이었다.

한반도 및 서일본에서 각 알고리즘이 탐지한 AR과 강수의 연관성을 보았을 때, 세 알고리즘 모두 7월 하순까지는 비슷한 양상을 보이다가 8월 초순부터 차이가 나타났다. 강수량과 AR 빈도수 간의 피어슨 상관 분석을 한 결과, P21 알고리즘에서 가장 밀접한 관련

이 있었다. 또한, 각 탐지 알고리즘의 AR 강수와 AR 강수 비율을 비교하였을 때 세 알고리즘에서 AR 강수의 순 별 변화는 전체 강수의 순 별 변화와 유사한 양상을 보였다. 다만 T23이 다른 두 알고리즘보다 낮은 AR 강수를 보였으며, 세 알고리즘 모두 두 개의 피크가 나타났지만 그 시기가 상이했다. 본 연구에서 사용한 T23은 ClimateNet을 학습한 것으로 이는 IWV를 기반으로 라벨링 된 자료이다. 이 알고리즘이 GW15와 P21과는 상대적으로 다른 결과를 보였는데 이는 ClimateNet의 라벨이 AR을 과장하는 경향이 있기 때문으로 보인다(Higgins et al., 2023). 또한 T23은 IWV를 기반으로 학습된 반면 GW15와 P21은 IVT를 기반으로 AR을 탐지하였다는 차이가 있어, 이 역시 탐지 결과에 영향을 미쳤을 수 있다. 따라서 IVT를 기반으로 라벨링 된 AR 학습 자료를 개발할 필요가 있으며, 개발될 경우 이 자료로 학습한 딥러닝 기반 알고리즘과 여타 IVT 기반 탐지 알고리즘을 비교하는 연구가 필요할 것으로 판단된다.

AR 탐지 알고리즘 비교는 본 연구에서 처음 시도된 것이 아니다. 이미 ARTMP를 통해 다양한 종류의 AR 탐지 알고리즘이 비교된 바 있다(Shields et al., 2018; Rutz et al., 2019). 그러나 비교 지역이 유럽 및 미국 서부에 국한되었으며, AR이 빈번한 겨울철로 제한되었다(Shields et al., 2018; Rutz et al., 2019; O'Brien et al., 2022). 동아시아는 유럽 및 미국 서부와 계절적 변동이 다르고 특히 여름 몬순이라는 특수한 시스템에 의해 AR이 큰 영향을 받기 때문에(Park et al., 2021), 별도의 AR 탐지 알고리즘 비교 분석이 추가적으로 수행될 필요가 있다. 본 연구에서는 GW15, P21, T23의 세 가지 알고리즘만을 이용하였으나, 동아시아 AR 연구에 활용되고 있는 다양한 알고리즘을 활용하여(Yang et al., 2018; Pan and Lu, 2019; Liang and Yong, 2021) 추가적인 분석을 수행할 필요가 있다. 이를 통해 동아시아 AR 탐지의 불확실성을 보다 정량적으로 이해할 수 있을 것으로 기대된다.

부 록

본 연구에 사용된 딥러닝 알고리즘은 다음과 같이 간략히 설명할 수 있다. CGNet (Wu et al., 2020)을 구성하는 CG block들은 결합 특성을 학습하여 이들이 공간 상 공유하는 특징들을 잘 학습하게 된다. 이에 따라 CGNet은 파라미터 수를 줄이고 메모리 공간을 절약해 경량화하면서도 기존 분할 모델보다 뛰어난 성능을 보인다. U-Net (Ronneberger et al., 2015)은 완전 합성곱 네트워크(Fully Convolutional Network, FCN)을 기반으로 하며, 수축 경로와 확장 경로를 다룬 샘플링과 업 샘플링을 반복하여 크기가 다양한 특

성 맵을 병합해 크기가 다양한 이미지의 객체를 분할할 수 있다는 특징이 있다. DeepLabv3+ (Chen et al., 2018)은 완전 연결층의 단점을 보완하기 위해 Atrous 합성곱을 사용하는 모델이다. 인코더와 디코더의 구조를 가지며, 일반적으로 인코더-디코더 구조에서는 불가능했던 인코더에서 추출된 특성 맵의 해상도 조절을 Atrous 합성곱을 도입하여 제어할 수 있도록 했다. PSPNet (Zhao et al., 2017) 또한 완전연결층의 한계를 극복하기 위해 피라미드 풀링 모듈을 추가했으며, 양선형 보간법을 사용하여 빈 화소에 값을 할당해 영상의 품질을 개선했다. DUC-HDC (Wang et al., 2018)는 FCN을 두 부분에서 변형한 것으로 FCN 마지막 층에 Dense Upsampling Convolution (DUC)을 추가하여 전체 라벨 맵을 여러 개의 채널을 가진 더 작은 라벨 맵으로 변환하였다. 또한, Hybrid dilated convolution (HDC)를 인코딩 과정에 사용하여 확장률을 적절하게 증가시켜 효과적으로 수용 영역을 늘리고 이는 보다 높은 정확도로 이어진다. 보다 구체적인 내용은 Tian et al. (2023)에서 찾을 수 있다.

감사의 글

이 논문은 기상청 국립기상과학원 「수도권 위험기상 입체관측 및 예보활용 기술 개발」 (KMA2018-00125)과 2023년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원으로 수행되었습니다 (2023R1A2C3005607).

REFERENCES

Adler, R. F., and Coauthors, 2018: The Global Precipitation Climatology Project (GPCP) monthly analysis (new version 2.3) and a review of 2017 global precipitation. *Atmosphere*, **9**, 138, doi:10.3390/atmos9040138.

Bao, J.-W., S. A. Michelson, P. J. Neiman, F. M. Ralph, and J. M. Wilczak, 2006: Interpretation of enhanced integrated water vapor bands associated with extratropical cyclones: Their formation and connection to tropical moisture. *Mon. Wea. Rev.*, **134**, 1063-1080, doi:10.1175/MWR3123.1.

Chen, L.-C., Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, 2018: Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)*, **15**, 801-818, doi:10.48550/arXiv.1802.02611.

Dettinger, M. D., F. M. Ralph, T. Das, P. J. Neiman, and D. R. Cayan, 2011: Atmospheric rivers, floods and the water resources of California. *Water*, **3**, 445-478,

doi:10.3390/w3020445.

_____, 2013: Atmospheric rivers as drought busters on the US West Coast. *J. Hydrometeor.*, **14**, 1721-1732, doi:10.1175/JHM-D-13-02.1.

Espinoza, V., D. E. Waliser, B. Guan, D. A. Lavers, and F. M. Ralph, 2018: Global analysis of climate change projection effects on atmospheric rivers. *Geophys. Res. Lett.*, **45**, 4299-4308, doi:10.1029/2017GL076968.

Gimeno, L., and Coauthors, 2016: Major mechanisms of atmospheric moisture transport and their role in extreme precipitation events. *Annu. Rev. Environ. Res.*, **41**, 117-141, doi:10.1146/annurev-environ-110615-085558.

Goldenson, N., L. R. Leung, C. M. Bitz, and E. Blanchard-Wrigglesworth, 2018: Influence of atmospheric rivers on mountain snowpack in the western United States. *J. Climate*, **31**, 9921-9940, doi:10.1175/JCLI-D-18-0268.1.

Guan, B., N. P. Molotch, D. E. Waliser, E. J. Fetzer, and P. J. Neiman, 2010: Extreme snowfall events linked to atmospheric rivers and surface air temperature via satellite measurements. *Geophys. Res. Lett.*, **37**, L20401, doi:10.1029/2010GL044696.

_____, and D. E. Waliser, 2015: Detection of atmospheric rivers: Evaluation and application of an algorithm for global studies. *J. Geophys. Res. Atmospheres*, **120**, 12514-12535, doi:10.1002/2015JD024257.

Hersbach, H., and Coauthors, 2020: The ERA5 global reanalysis. *Quart. J. Roy. Meteor. Soc.*, **146**, 1999-2049, doi:10.1002/qj.3803.

Higgins, T. B., and Coauthors, 2023: Using deep learning for an analysis of atmospheric rivers in a high-resolution large ensemble climate data set. *J. Adv. Modeling Earth Syst.*, **15**, e2022MS003495, doi:10.1029/2022MS003495.

Kamae, Y., W. Mei, and S.-P. Xie, 2017a: Climatological relationship between warm season atmospheric rivers and heavy rainfall over East Asia. *J. Meteor. Soc. Japan. Ser. II*, **95**, 411-431, doi:10.2151/jmsj.2017-027.

_____, W. Mei, S.-P. Xie, M. Naoi, and H. Ueda, 2017b: Atmospheric rivers over the northwestern Pacific: Climatology and interannual variability. *J. Climate*, **30**, 5605-5619, doi:10.1175/JCLI-D-16-0875.1.

Kashinath, K., and Coauthors, 2021: ClimateNet: An expert-labeled open dataset and deep learning architecture for enabling high-precision analyses of extreme weather. *Geoscientific Model Development*, **14**, 107-124, doi:10.5194/gmd-14-107-2021.

Kim, J., H. Moon, B. Guan, D. E. Waliser, J. Choi, T.-Y.

- Gu, and Y.-H. Byun, 2021: Precipitation characteristics related to atmospheric rivers in East Asia. *Int. J. Climatol.*, **41**, E2244-E2257, doi:10.1002/joc.6843.
- Konrad, C. P., and M. D. Dettinger, 2017: Flood runoff in relation to water vapor transport by atmospheric rivers over the western United States, 1949–2015. *Geophys. Res. Lett.*, **44**, 11456–11462, doi:10.1002/2017GL075399.
- Kwon, Y., C. Park, S.-Y. Back, S.-W. Son, J. Kim, and E. J. Cha, 2022: Influence of atmospheric rivers on regional precipitation in South Korea. *Atmosphere*, **32**, 135–148, doi:10.14191/Atmos.2022.32.2.135.
- Lavers, D. A., G. Villarini, R. P. Allan, E. F. Wood, and A. J. Wade, 2012: The detection of atmospheric rivers in atmospheric reanalyses and their links to British winter floods and the large-scale climatic circulation. *J. Geophys. Res. Atmospheres*, **117**, 13 pp doi: 10.1029/2012JD018027.
- Liang, J., and Y. Yong, 2021: Climatology of atmospheric rivers in the Asian monsoon region. *Int. J. Climatol.*, **41**, E801–E818, doi:10.1002/joc.6729.
- Moon, H., J. Kim, B. Guan, D. E. Waliser, J. Choi, T.-Y. Goo, Y. Kim, and Y.-H. Byun, 2019: The effects of atmospheric river landfalls on precipitation and temperature in Korea. *Atmosphere*, **29**, 343–353, doi: 10.14191/Atmos.2019.29.4.343.
- Mundhenk, B. D., E. A. Barnes, and E. D. Maloney, 2016: All-season climatology and variability of atmospheric river frequencies over the North Pacific. *J. Climate*, **29**, 4885–4903, doi:10.1175/JCLI-D-15-0655.1.
- Muszynski, G., K. Kashinath, V. Kurlin, M. Wehner, and Prabhat, 2019: Topological data analysis and machine learning for recognizing atmospheric river patterns in large climate datasets. *Geoscientific Model Development*, **12**, 613–628, doi:10.5194/gmd-12-613-2019.
- Neiman, P. J., L. J. Schick, F. M. Ralph, M. Hughes, and G. A. Wick, 2011: Flooding in western Washington: The connection to atmospheric rivers. *J. Hydrometeorol.*, **12**, 1337–1358, doi:10.1175/2011JHM1358.1.
- Newman, M., G. N. Kiladis, K. M. Weickmann, F. M. Ralph, and P. D. Sardeshmukh, 2012: Relative contributions of synoptic and low-frequency eddies to time-mean atmospheric moisture transport, including the role of atmospheric rivers. *J. climate*, **25**, 7341–7361, doi:10.1175/JCLI-D-11-00665.1.
- O'Brien, T. A., and Coauthors, 2022: Increases in future AR count and size: Overview of the ARTMIP Tier 2 CMIP5/6 experiment. *J. Geophys. Res. Atmospheres*, **127**, e2021JD036013, doi:10.1029/2021JD036013.
- Pan, M., and M. Lu, 2019: A novel atmospheric river identification algorithm. *Water Resour. Res.*, **55**, 6069–6087, doi:10.1029/2018WR024407.
- _____, and _____, 2020: East Asia atmospheric river catalog: Annual cycle, transition mechanism, and precipitation. *Geophys. Res. Lett.*, **47**, e2020GL089477, doi:10.1029/2020GL089477.
- Park, C., S.-W. Son, and H. Kim, 2021: Distinct features of atmospheric rivers in the early versus late East Asian summer monsoon and their impacts on monsoon rainfall. *J. Geophys. Res. Atmospheres*, **126**, e2020JD033537, doi:10.1029/2020JD033537.
- Radić, V., A. J. Cannon, B. Menounos, and N. Gi, 2015: Future changes in autumn atmospheric river events in British Columbia, Canada, as projected by CMIP5 global climate models. *J. Geophys. Res. Atmospheres*, **120**, 9279–9302, doi:10.1002/2015JD023279.
- Ralph, F. M., P. J. Neiman, and G. A. Wick, 2004: Satellite and CALJET aircraft observations of atmospheric rivers over the eastern North Pacific Ocean during the El Niño winter of 1997/98. *Mon. Wea. Rev.*, **132**, 1721–1745, doi:10.1175/1520-0493(2004)132<1721:SACAOO>2.0.CO;2.
- _____, _____, _____, S. I. Gutman, M. D. Dettinger, D. R. Cayan, and A. B. White, 2006: Flooding on California's Russian River: Role of atmospheric rivers. *Geophys. Res. Lett.*, **33**, doi:10.1029/2006GL026689.
- _____, and M. D. Dettinger, 2012: Historical and national perspectives on extreme West Coast precipitation associated with atmospheric rivers during December 2010. *Bulletin of the American Meteorological Society*, **93**, 783–790, doi:10.1175/BAMS-D-11-00188.1.
- Ronneberger, O., P. Fischer, and T. Brox, 2015: U-net: Convolutional networks for biomedical image segmentation. *In Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany*, **9351**, 234–241, doi:10.1007/978-3-319-24574-4_28.
- Rutz, J. J., W. J. Steenburgh, and F. M. Ralph, 2014: Climatological characteristics of atmospheric rivers and their inland penetration over the western United States. *Mon. Wea. Rev.*, **142**, 905–921, doi:10.1175/MWR-D-13-00168.1.
- _____, and Coauthors, 2019: The atmospheric river tracking method intercomparison project (ARTMIP): quantifying uncertainties in atmospheric river climatology. *J. Geophys. Res. Atmospheres*, **124**, 13777–13802, doi:10.1029/2019JD030936.
- Shields, C. A., and Coauthors, 2018: Atmospheric river

- tracking method intercomparison project (ARTMIP): project goals and experimental design. *Geoscientific Model Development*, **11**, 2455-2474, doi:10.5194/gmd-11-2455-2018.
- Tian, Y., Y. Zhao, S.-W. Son, J.-J. Luo, S.-G. Oh, and Y. Wang, 2023: A deep-learning ensemble method to detect atmospheric rivers and its application to projected changes in precipitation regime. *J. Geophys. Res. Atmospheres*, **128**, e2022JD037041, doi:10.1029/2022JD037041.
- Wang, P., P. Chen, Y. Yuan, D. Liu, Z. Huang, X. Hou, and G. Cottrell, 2018: Understanding convolution for semantic segmentation. In *2018 IEEE winter conference on applications of computer vision (WACV)*, 1451-1460, doi:10.1109/WACV.2018.00163.
- Wick, G. A., P. J. Neiman, F. M. Ralph, and T. M. Hamill, 2013: Evaluation of forecasts of the water vapor signature of atmospheric rivers in operational numerical weather prediction models. *Wea. Forecasting*, **28**, 1337-1352, doi:10.1175/WAF-D-13-00025.1.
- Wu, T., S. Tang, R. Zhang, J. Cao, and Y. Zhang, 2020: Cgnet: A light-weight context guided network for semantic segmentation. *IEEE Trans. Image Processing*, **30**, 1169-1179, doi:10.1109/TIP.2020.3042065.
- Yang, Y., T. Zhao, G. Ni, and T. Sun, 2018: Atmospheric rivers over the Bay of Bengal lead to northern Indian extreme rainfall. *Int. J. Climatol.*, **38**, 1010-1021, doi:10.1002/joc.5229.
- Zhao, H., J. Shi, X. Qi, X. Wang, and J. Jia, 2017: Pyramid scene parsing network. *Computer Vision and Pattern Recognition*, 2881-2890, doi:10.1109/cvpr.2017.660.
- Zhu, Y., and R. E. Newell, 1998: A proposed algorithm for moisture fluxes from atmospheric rivers. *Mon. Wea. Rev.*, **126**, 725-735, doi:10.1175/1520-0493(1998)126<0725:APAFMF>2.0.CO;2.