

논문

딥러닝 기법을 이용한 에어러솔 복사강제력 산출 Estimation of Aerosol Radiative Forcing Using Deep Learning Technique

표성훈^{1),3)}, 이권호^{2),3)}*

¹⁾강릉원주대학교 공간정보협동과정, ²⁾강릉원주대학교 대기환경과학과,

³⁾강릉원주대학교 복사-위성 연구소

Seong-Hun Pyo^{1),3)}, Kwon-Ho Lee^{2),3)}*

¹⁾Spatial Information Cooperative Program, Gangneung-Wonju National University, Gangneung, Republic of Korea

²⁾Department of Atmospheric & Environmental Sciences, Gangneung-Wonju National University, Gangneung, Republic of Korea

³⁾Research Institute for Radiation-Satellite, Gangneung-Wonju National University, Gangneung, Republic of Korea

접수일 2022년 8월 19일
수정일 2022년 9월 16일
채택일 2022년 9월 19일

Received 19 August 2022
Revised 16 September 2022
Accepted 19 September 2022

*Corresponding author
Tel : +82-(0)33-640-2319
E-mail : kwonho.lee@gmail.com

Abstract In this study, we propose a new method to determine aerosol radiation forcing (ARF) by building the Deep Learning based ARF (DL_ARF) model. For the best optimization of the deep learning structures used in the DL_ARF, performances with the different layers used in the deep neural network were evaluated. The DL_ARF uses only two input data of aerosol optical depth (AOD) and solar zenith angle (SZA) and it has a very fast calculation speed compared to the typical radiative transfer model's running time. In addition, accuracy of the DL_ARF was verified by comparing the ARF determined by DL_ARF and by the typical radiative transfer model based ARF (RTM_ARF) results. These comparisons showed very good correlation between DL_ARF and RTM_ARF (slope = 1.04~1.06, $r = 0.95 \sim 0.97$) and high accuracy (bias = 0.68~2.03 W/m², RMSE = 6.51~8.41 W/m²) was obtained. The ARF calculation time of DL_ARF was significantly shortened compared to the ARF calculation time of the radiative transfer model. The aerosol radiation forcing efficiency (ARFE) of Seoul and Gangneung was calculated and compared by applying the DL_ARF model developed in this study. As a result, ARFE in Gangneung and Seoul are $-1.22 \text{ W/m}^2\tau$, $-1.03 \text{ W/m}^2\tau$, respectively. Interestingly, ARFE in Gangneung is 18.4% lower than Seoul because aerosols in Gangneung have less single scattering albedo (SSA) values than Seoul indicating the more absorbing aerosols. DL_ARF can be effectively used to provide real-time data needed to study complex surface atmospheric motion and climate change.

Key words: Aerosol Optical Depth, Aerosol Radiation Forcing, Deep learning, Deep Neural Network

1. 서론

대기 에어러솔(aerosol)은 대기 중에 존재하는 다양한 종류의 입자상 물체이며, 인위적 또는 자연적 발생원에 의하여 분류된다(Hua *et al.*, 2016). 예를 들면, 모래 폭풍, 해염 입자, 화산, 산불 및 생물학적 배출과 같은 자연적 원인이거나 건설 및 시멘트 생산, 농업, 바이오매스 및 화석 연료의 연소와 같은 인간 활동에 의

하여 생성될 수 있다(Hoesly *et al.*, 2018). 특히 한반도는 편서풍에 의하여 동아시아 대륙에서 발생한 각종 대기 오염물질의 유입과 국내 배출량의 기여로 인해 에어러솔의 특성 연구가 중요하다(Shin and Lee, 2016; Lee and Kim, 2010).

에러러솔은 복사 순환 과정에 영향을 미칠 수 있으며, 태양 복사에너지를 직접 흡수하거나 산란하여 에어러솔 복사강제 효과를 유발한다(Bi *et al.*, 2014). 주

로 무기염 성분을 가지는 에어러솔은 광 산란 효과가 증가되어 대기를 냉각시키는 음(-)의 복사강제력을 유발하며, 화석 연료의 연소 등에 의해 생성되는 탄소 입자는 대기를 가열시켜 양(+)의 복사강제력을 유발한다(IPCC, 2022). 에어러솔에 의한 복사강제력(Aerosol Radiative Forcing; ARF)은 기후 시스템에서 가장 불확실한 요소이며(IPCC, 2022), 기후 및 대기환경 연구에서 중요하다(Field *et al.*, 2014; Krishnamurti *et al.*, 1998; Charlson *et al.*, 1991). 또한, ARF는 대기 중 에어러솔의 질량, 농도, 화학조성 및 성분이 시공간적으로 매우 다양하기 때문에 복잡한 특성을 지닌다(Bates *et al.*, 2006; Yoon *et al.*, 2005; Panner *et al.*, 1994).

ARF는 에어러솔의 광학 특성과 대기 중의 부하량에 의하여 결정되며, 주로 복사전달모델에 의하여 계산하거나 복사에너지를 관측하여 결정할 수 있다. 이중 복사전달모델을 사용하는 방법은 대기에 관한 정량적인 정보를 이용하여 모델의 계산 정확도 수준의 결과를 생산할 수 있으나, ARF 계산을 위한 자료구축에 대한 자원과 계산시간이 소요되는 단점이 있다. 관측 자료를 이용한 방법은 복사계를 이용하여 대기 조건이 매우 청명한 조건과 혼탁한 조건에 대한 상대적 비교를 통하여 복사강제 효과를 결정할 수 있으나, 관측 기기의 사용과 관측 자료의 유효성 등에 제한점이 발생할 수 있다. 대기 정보는 매우 다양하며 복잡한 요소들의 정보가 축적되고 있으므로, 이를 이용하여 기존의 관측 자료 수준의 정확도를 가지면서 보다 빠른 시간 내에 산출할 수 있는 방법론이 필요하다.

최근 빅데이터를 효율적으로 다루는 기법인 머신러닝 기법을 다양한 분야에서 사용하고 있으며, 클러스터링, 인공지능, 딥러닝 등 세부적으로 다양한 기법과 알고리즘이 개발되어 사용되고 있다(Lee, 2021; Murphy, 2012). 기존의 복잡하고 전문적인 과정을 통해 산출할 수 있었던 여러 가지 대기 물리량은 이러한 딥러닝 기법을 사용하여 정확하고 빠른 산출이 가능하게 되었다. 특히 딥러닝 기법은 기존 대기복사모델의 불확실성을 줄이고 대기운동의 복잡한 비선형 관

계를 산출하는 데 효과적이다(Ukkonen *et al.*, 2020). 최근에는 역전파 인공 신경망을 이용한 Aerosol Optical Depth (AOD) 산출 연구(Qin *et al.*, 2018)와 신경망 기법을 이용한 Global Solar Radiation (GSR) 산출 연구(Jiang *et al.*, 2019)가 진행되었다.

따라서 본 연구에서는 보다 효과적으로 에어러솔의 특성에 따른 ARF를 산출하기 위하여, 딥러닝 기반의 ARF 산출 모델인 Deep Learning based Aerosol Radiative Forcing (DL_ARF)을 구축하였다. DL_ARF 모델은 복사전달모델을 이용하여 산출된 학습데이터를 사용하였으며, 모델의 예측 정확도의 비교 평가는 DL_ARF 모델을 사용하여 산출한 ARF와 AERONET에서 제공되는 ARF를 비교하였다. 이러한 딥러닝 기법을 이용한 ARF 산출 연구는 지역별 관측 자료를 이용하여 실시간으로 ARF의 산출이 가능하며 기후 및 대기 연구에 관한 실시간 및 예측 데이터 제공의 수단으로 사용될 수 있다.

2. 자료 및 방법

2.1 연구 자료

연구 대상지역은 강릉과 서울로서, 두 도시는 유사한 위도를 가지는 도시 지역이지만 동서방향으로 직선거리 약 180 km 떨어져 있으며 배출원의 규모와 특성 및 환경이 서로 다르게 나타나는 지역이다(Kim *et al.*, 2020; Lee and Lee, 2020). 그림 1은 연구 지역의 위치와 고도 단면도이다. 서울은 약 605.2 km²의 면적으로 약 950만 명의 인구가 거주 중으로 교통량이 많고 다양한 배출 업체와 거주지에서 배출되거나, 서울 근교 지역과 중국에서 발생하여 서해를 통해 유입되는 대기오염물질의 영향을 크게 받는다(Choi *et al.*, 2016; Shin and Lee, 2016; Oh *et al.*, 2015). 강릉은 1,040 km² 면적으로 인구는 약 21만 명이며, 서쪽의 태백산맥과 동쪽의 동해바다를 마주하고 있으므로 산맥과 해양에 의한 복합적인 영향으로 인해 대기오염물질이 기상 조건의 영향을 크게 받는다(Lee and Lee, 2020). Pyo

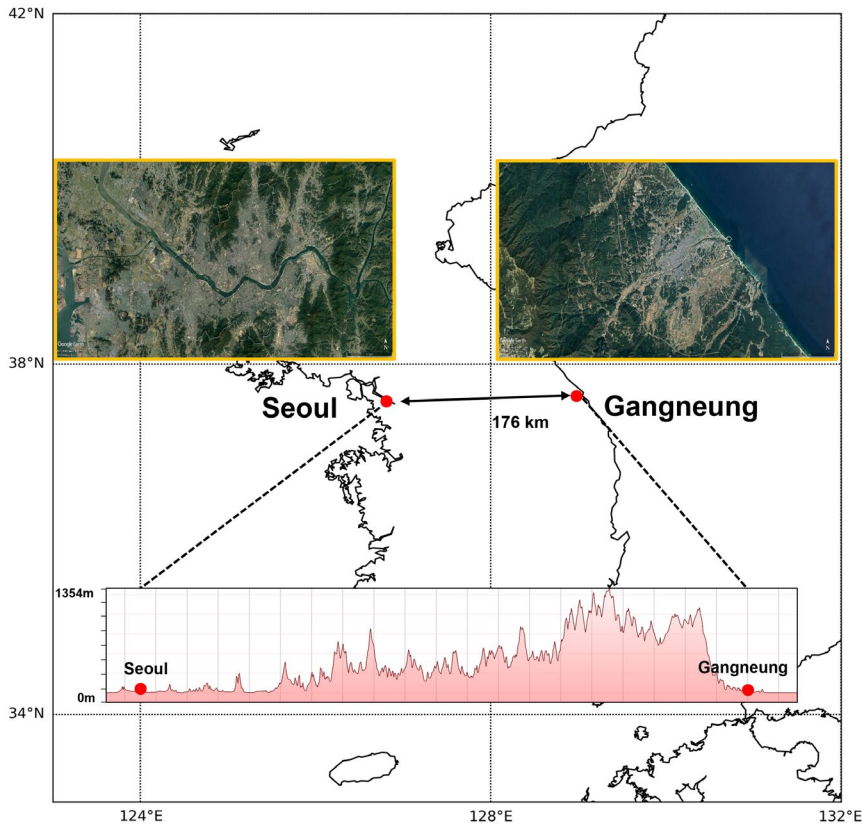


Fig. 1. Geographical locations of ground-based sun-skyradiometer measurement sites in Gangneung and Seoul used in this study. Distance and elevation profile between Gangneung (37.77°N, 128.86°E, 60 m) and Seoul (37.56°N, 126.93°E, 97 m) also shown.

et al. (2021)의 선행 연구에서는 강릉과 서울의 서풍의 빈도가 각각 83%, 67%로 주로 서풍 계열의 바람으로 인하여 외부에서 유입되는 에어러솔의 빈도가 높은 것으로 나타났으며, 두 지점의 에어러솔 부하량은 차이가 있지만 입자의 크기 분포 영역은 유사한 범위인 것으로 보고되었다.

표 1은 본 연구에서 사용된 자료 목록이며, 딥러닝 모델의 학습 구축에 필요한 복사전달모델 입력 파라미터인 파장 범위, 태양 천정각, 대기 프로파일, 에어러솔 타입, AOD, 지표 알베도를 포함한다. 파장 범위는 복사전달모델 구동을 위해 파장의 범위를 설정하는 것으로서 본 연구에서는 단파장 영역인 $0.25\ \mu\text{m}\sim 4\ \mu\text{m}$ 의 영역대를 설정하였다. 태양 천정각은 지면에서

수직 방향과 태양이 이루는 각도이며, 태양 천정각이 커질수록 태양 복사에너지가 지구 대기를 통과하는 광경로가 길어지므로 복사강제 효과에 영향을 준다. 태양 천정각의 범위는 주간 동안 태양의 이동 범위를 고려하여 $0^\circ\sim 80^\circ$ 로 설정하였다. 대기 프로파일은 대기층의 수, 고도별 기압, 기온, 수증기압, 오존에 관한 값을 제공하며, 본 연구에서는 US76 표준대기모델을 선정하였다. 에어러솔 타입은 Rural, Urban, Oceanic, Tropospheric 에어러솔 모델이 사용되었으며, 각각 파장별 산란위상함수, 단산란 알베도, 소산계수 그리고 고도별 에어러솔 분포값이 포함된다. 그리고 에어러솔 광학두께는 $0.00\sim 5.00$ 까지 0.01씩 증가하도록 설정하였다. 이렇게 설정된 파라미터별 DL_ARF 모델의 학

Table 1. List of radiative transfer model input parameters used to generate training data for DL_ARF model.

Parameters	Input value	Description
Wavelength (λ)	0.25 μm ~4 μm	$\Delta\lambda = 0.01 \mu\text{m}$
Solar zenith angle (θ)	0°~80°	$\Delta\theta = 1^\circ$
Atmospheric profile	US 76 (Standard Atmosphere)	Number atmospheric layers, Layer altitude, Pressure in millibars, Temperature, Water vapor, Ozone
Aerosol type	Rural, Urban, Tropospheric, Oceanic	Scattering phase function, Single scattering albedo, Dissipation coefficient, Distribution of altitude
Aerosol optical depth (τ)	0.00~5.00	$\Delta\tau = 0.01$
Surface albedo (ρ)	Vegetation	$\Delta\rho = 0.005 \mu\text{m}$

Table 2. List of ground observation data used for comparative verification of DL_ARF output data.

Instrument	Parameters	Resolution	Period	Source
CE-318 Sunsky radiometer	Aerosol Optical Depth (AOD), Solar Zenith Angle (SZA), Single Scattering Albedo (SSA), Asymmetry Factor (ASY), Effective Radius (Reff)	5 minutes	2012~2021	https://aeronet.gsfc.nasa.gov
Automatic Weather System (AWS)	Relative Humidity (RH)	1 minutes	2012~2021	https://data.kma.go.kr

습을 위한 입력값인 태양 복사량과 대기 물리량이 산출된다.

표 2는 DL_ARF 결과값의 비교를 위하여 사용된 자료목록이다. 이 중 CE-318 Sun-sky radiometer 관측 자료는 전 세계 복사 관측 네트워크 중 하나인 AEROSOL ROBOTIC NETWORK (AERONET) (Hauser *et al.*, 2005)를 통하여 획득하였으며, 서울(북위 37.56°, 동경 126.93°, 고도 97 m)과, 강릉(북위 37.77°, 동경 128.86°, 고도 60 m)에서 2012년부터 2021년까지 관측된 자료를 사용하였다. 기상조건에 따른 연구 지역의 에어로솔의 특성 분석을 위해 상대습도 자료를 사용하였으며, CIMEL-318 Sun-sky radiometer 관측 지점과 가장 인접한 자동기상관측장비 (Automatic Weather System; AWS)의 관측 지점(강릉: 북위 37.78°, 동경 128.92°, 고도 7 m, 서울: 북위 37.57°, 동경 126.94°, 고도 103 m)에서 2012년부터 2021년까지의 자료를 사용하였다.

2.2 DL_ARF

ARF를 산출하기 위해 머신러닝 기법의 하나인 심층 신경망(Deep Neural Network; DNN) 기법을 사용하였다. 일반적으로, 신경망(Neural Network) 또는 퍼셉트론은 기본적으로 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer)으로 구성되며, 두 개 이상의 은닉층이 존재하면 다층 퍼셉트론 또는 심층 신경망이라고 한다(Rumelhart *et al.*, 1986). 입력층에 값이 입력되면 가중치 계산을 통해 은닉층, 출력층 순으로 계층적으로 전파된다. 모델의 오차를 줄여 성능을 높이기 위해 산출된 정보를 입력층으로 역전파(Backpropagation)하고 가중치를 기울기 하강법(Gradient descent algorithm)을 사용하여 지속적으로 업데이트하는 방식으로 학습을 시킨다(Rumelhart *et al.*, 1986). DNN은 이러한 신경망들의 결합으로 생성한 뉴런들이 학습으로 가중치를 변형 및 기억하여 문제를 해결하는 모델이며 비선형 문제를 해결하는 대

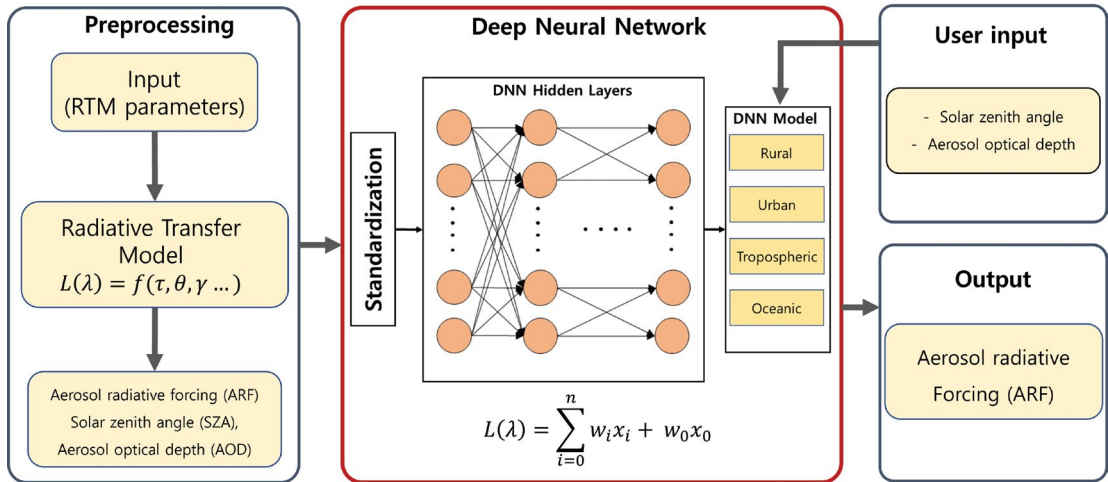


Fig. 2. Schematic diagram of data process for the deep neural network model to calculate ARF used in DL_ARF model.

표적 기법이다(Reifman and Feldman, 2002). 신경망 학습을 마친 후 구축된 모델을 사용하면 방대한 양의 데이터를 입력하였을 때 그에 상응하는 결과값을 기존의 복사전달모델에 비하여 빠르고 정확하게 산출이 가능하다.

그림 2는 본 연구에서 진행한 DL_ARF 모델을 구축하기 위한 데이터 처리 과정에 대한 모식도이다. DL_ARF 모델을 구축하기 위해 우선 정확하고 방대한 데이터를 이용하여 학습시키는 과정이 필요하다. 학습에 필요한 데이터는 복사전달모델을 이용하여 산출된 약 210,000개의 AOD와 태양 천정각, 지표면 순 복사량 데이터를 이용하였다. 에어러솔 타입은 표준 에어러솔 모델인 Rural, Urban, Tropospheric, Oceanic Aerosol에 대한 4가지 타입별로 모델을 이용하였다. DL_ARF 모델 학습과정에서 모델의 정확도를 높이는 가장 중요한 부분은 뉴런의 구조를 가장 효율적으로 구성하는 것이다. 뉴런의 구조는 레이어와 노드들로 구성되어 있으며 이러한 뉴런의 구조가 구성되면 결과를 산출하는 과정 및 알고리즘은 내부적으로만 처리되므로 그 과정을 정확히 알기 어렵다. DNN 기법에서 레이어와 노드의 구조는 데이터의 종류와 수에 따라 달라져야 하기 때문에 이를 효율적으로 구성하는 명확한 방

법이 정해지진 않았다(Choldun *et al.*, 2019; Chhachhiya *et al.*, 2017; Bunjongit *et al.*, 2014). 사용자가 직접 구조를 변경하면서 학습시킨 모델들을 전부 비교해 최적의 모델을 구축하는 방법이 널리 쓰인다. 이러한 방법은 학습시간이 오래 걸리는 단점이 있지만, 가장 효율적이며 정확한 모델이 구축된다는 장점이 있다. 본 연구에서도 사용자가 직접 뉴런의 구조를 변경하여 모델들을 구축하였으며, 각각의 타입별로 7가지의 형태로 학습시킨 28개의 모델 중 가장 정확한 모델을 선택하여 ARF를 산출하였다.

3. 결과 및 토의

3.1 DL_ARF 모델의 성능 평가 및 최적화

표 3과 4는 DL_ARF에서 사용된 뉴런의 구조별로 학습이 완료된 모델들의 성능과 예측값의 선형 회귀 결과 및 산출 시간을 정리한 표이다. 각 모델의 학습 결과에 대한 정확도를 평가하기 위하여 오차 제곱 합(Sum of Squares for Error; SSE)을 계산하였다. SSE는 손실함수(Loss Function) 중 하나로 신경망 모델의 성능을 나타내는 지표로 사용되며 학습데이터를 얼마나

Table 3. The accuracy of the DL_ARF model in Gangneung for different neuron structures. The computing times by DL_ARF and the radiative transfer model (RTM) for 2,138 dataset are also listed.

Aerosol types	Training			Validation			Compute time	
	Layers	Nodes	SSE	R	RMSE	Bias	DL_ARF	RTM
Rural	2	5-3	0.16	0.95	7.41	1.19	2.46 s	420 min (7 hours)
		4-2	0.63	0.94	7.63	2.13	2.48 s	
	3	4-4-4	0.16	0.95	6.53	0.99	2.16 s	
		5-5-5	0.09	0.95	6.54	0.76	2.4 s	
		6-5-4	0.11	0.95	6.53	0.75	2.14 s	
	4	5-4-3-2	0.102	0.97	6.51	0.68	2.2 s	
		3-5-3-2	0.11	0.95	6.53	0.62	2.31 s	
	Urban	2	5-3	0.26	0.94	8.27	31.42	
4-2			0.82	0.94	8.62	33.61	2.61	
3		4-4-4	0.038	0.94	7.22	30.92	2.1 s	
		5-5-5	0.071	0.94	7.2	31.39	2.12 s	
		6-5-4	0.062	0.94	7.15	31.12	2.42 s	
4		5-4-3-2	0.046	0.95	7.08	31.42	2.3 s	
		3-5-3-2	0.033	0.93	7.31	31.13	2.27 s	
Tropospheric		2	5-3	0.112	0.95	7.00	2.42	2.57 s
	4-2		0.78	0.95	7.14	1.63	2.62 s	
	3	4-4-4	0.234	0.95	6.55	2.39	2.36 s	
		5-5-5	0.082	0.95	6.51	2.50	2.24 s	
		6-5-4	0.113	0.95	6.48	2.63	2.2 s	
	4	5-4-3-2	0.136	0.95	6.51	2.39	2.52 s	
		3-5-3-2	0.255	0.95	6.52	2.10	2.8 s	
	Oceanic	2	5-3	0.11	0.95	7.56	4.11	2.56 s
4-2			0.79	0.95	7.47	3.54	2.53 s	
3		4-4-4	0.173	0.94	6.51	4.35	2.4 s	
		5-5-5	0.098	0.94	6.51	4.19	2.9 s	
		6-5-4	0.116	0.95	6.62	4.26	2.43 s	
4		5-4-3-2	0.154	0.95	6.51	4.10	2.2 s	
		3-5-3-2	0.175	0.95	6.52	4.32	2.3 s	

잘 처리하느냐를 나타내는 대표적인 지표이다. 식 (1)은 신경망에서의 SSE를 계산하는 식이며, 신경망이 예측한 ARF (F_D)에서 학습데이터에서의 ARF (F_A)의 차를 제공하여 모두 합하게 된다.

$$SSE = \frac{1}{2} \sum_{i=1}^n (F_{D,i} - F_{A,i})^2 \quad (1)$$

i = 데이터의 차원 수

F_D = 신경망이 예측한 값

F_A = 참값

본 연구에서는 전체 데이터 중 70%는 학습데이터로 사용하였고 나머지 30%는 시험데이터로 사용하였으므로 SSE는 70%에 해당하는 학습데이터를 학습하여 찾은 최적의 매개변수와 학습데이터의 오차 제곱(Squares Error; SE)을 모두 합한 값을 의미한다. 이 과

Table 4. The accuracy of the DL_ARF model in Seoul for different neuron structures. The computing times by DL_ARF and the radiative transfer model (RTM) for 3,948 datasets are also listed.

Aerosol types	Training			Validation			Compute time	
	Layers	Nodes	SSE	R	RMSE	Bias	DNN	RTM
Rural	2	5-3	0.16	0.97	10.36	2.63	2.46 s	775 min (13 hours)
		4-2	0.63	0.95	10.42	2.79	2.48 s	
	3	4-4-4	0.16	0.96	10.37	2.45	2.16 s	
		5-5-5	0.09	0.96	10.29	2.41	2.4 s	
		6-5-4	0.11	0.97	10.35	2.48	2.14 s	
	4	5-4-3-2	0.102	0.97	10.32	2.47	2.2 s	
		3-5-3-2	0.11	0.97	10.32	2.47	2.31 s	
	Urban	2	5-3	0.26	0.96	52.42	41.39	
4-2			0.82	0.96	52.54	41.75	2.61	
3		4-4-4	0.038	0.96	52.31	41.19	2.1 s	
		5-5-5	0.071	0.96	52.82	41.75	2.12 s	
		6-5-4	0.062	0.96	52.69	41.49	2.42 s	
4		5-4-3-2	0.046	0.96	52.21	41.46	2.3 s	
		3-5-3-2	0.033	0.96	52.90	41.95	2.27 s	
Tropospheric		2	5-3	0.112	0.97	8.48	2.42	2.57 s
	4-2		0.78	0.96	9.35	1.63	2.62 s	
	3	4-4-4	0.234	0.97	8.49	2.39	2.36 s	
		5-5-5	0.082	0.97	8.53	2.50	2.24 s	
		6-5-4	0.113	0.97	8.42	2.03	2.2 s	
	4	5-4-3-2	0.136	0.96	8.92	2.39	2.52 s	
		3-5-3-2	0.255	0.96	8.48	2.10	2.8 s	
	Oceanic	2	5-3	0.11	0.97	8.59	3.82	2.56 s
4-2			0.79	0.96	8.68	3.57	2.53 s	
3		4-4-4	0.173	0.97	8.67	3.89	2.4 s	
		5-5-5	0.098	0.97	8.66	3.88	2.9 s	
		6-5-4	0.116	0.97	8.65	3.89	2.43 s	
4		5-4-3-2	0.154	0.97	8.65	3.86	2.2 s	
		3-5-3-2	0.175	0.97	8.66	3.86	2.3 s	

정을 통해 모델의 성능을 평가할 수 있으며 SSE가 가장 낮게 나타나면 모델의 성능이 높다고 판단이 가능하지만(Kim *et al.*, 2019; Ghosh *et al.*, 2007), SSE는 학습데이터에 대해서만 판단이 가능하고 처음 입력되는 데이터 즉, 본 연구에서 사용된 입력자료에 대해서는 판단하기 힘들다. 따라서 SSE를 참고하여 추가로 새로운 데이터를 통해 예측한 결과와 실제 데이터를 비

교하면서 모델의 성능뿐만 아니라 정확도를 확인하는 과정을 추가로 진행하였다. 모델을 이용한 예측값의 정확도 확인은 통계적인 선형회귀 분석에서 사용되는 상관계수(R), 평균 제곱근 오차(RMSE), 편차(Bias)를 다음의 식 (2)~(4)와 같이 계산하였다.

$$R = \frac{\sum_{i=1}^n (F_{D,i} - F_{D,l})(F_{A,i} - F_{A,l})}{(n-1)S_D S_A} \quad (2)$$

F_D : DL_ARF로 예측한 값

F_A : AERONET ARF

$\overline{F_D}$: 예측 ARF에 대한 표본 평균

S_D : 예측 ARF에 대한 표준 편차

$\overline{F_A}$: AERONET ARF에 대한 표본 평균

S_A : AERONET ARF에 대한 표준 편차

n : 표본의 수

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (F_{D,i} - F_{A,i})^2}{n}} \quad (3)$$

F_D : DL_ARF로 예측한 ARF 값

F_A : AERONET의 ARF 값

n : 데이터 수

$$Bias = \frac{\sum_{i=1}^n (F_{D,i} - F_{A,i})}{n} \quad (4)$$

F_D : DL_ARF로 예측한 ARF 값

F_A : AERONET의 ARF 값

n : 데이터 수

DL_ARF는 복사전달모델을 이용하여 미리 계산된 총 210,000개의 데이터가 DNN의 학습을 위하여 사용되었으며, 최적의 DNN 모델을 찾기 위하여 3개의 레이어와 몇 가지의 노드 수의 조합인 총 28개의 독립된 모델을 구축하였다. 그리고 강릉과 서울에서 CEMEL-318 sun-sky radiometer로 측정된 에어러솔 광학 두께와 태양 천정각 데이터(강릉: 2,138개, 서울: 3,948개)를 입력자료로 사용하여 ARF를 산출하였다. 이렇게 DL_ARF로부터 산출된 ARF의 정확도 평가를 위하여 AERONET level 2.0 inversion product에서 제공되는 ARF 값(복사전달모델링에 의하여 계산된 값)과 비교하였으며, 28개의 DNN 모델 중 가장 높은 정확도를 나타낸 모델을 사용하여 지역별 ARF 값을 결정하였다. 그림 3~5는 강릉과 서울 두 지역에서 DL_ARF 기반의 ARF와 AERONET에서 제공하는 ARF와의 회귀 분석을 통한 상관계수와 RMSE 그리고 Bias를 비교한 결과이다.

강릉의 경우 Rural 에어러솔 타입과 (5-4-3-2) 노드

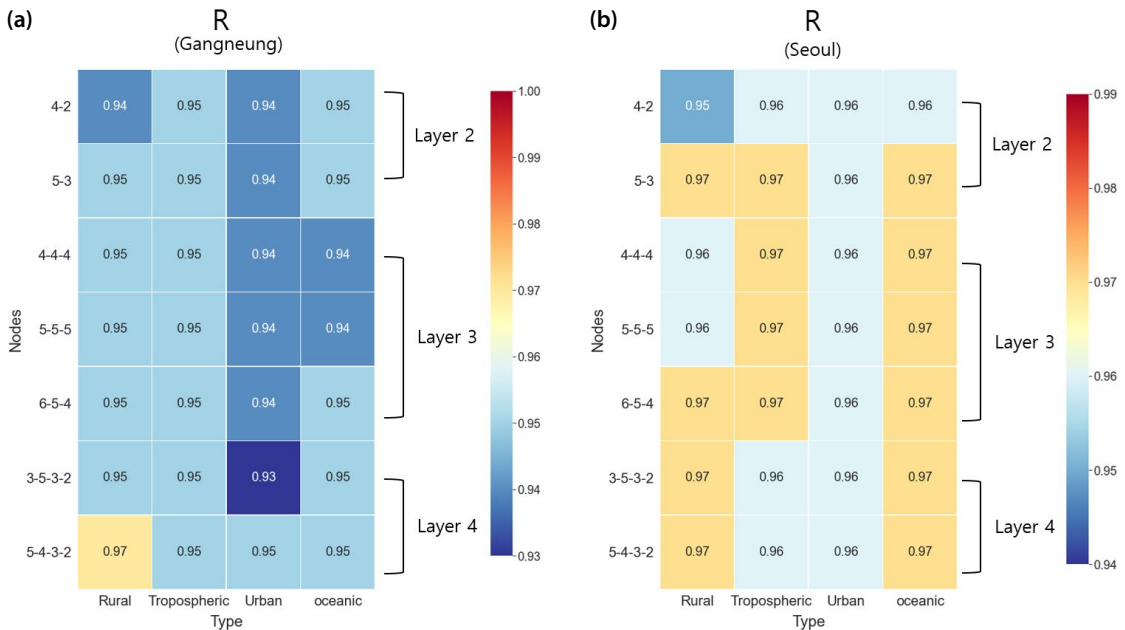


Fig. 3. Heatmap depicting correlation between DL_ARF ARF and AERONET ARF in (a) Gangneung and (b) Seoul. Rows represent the nodes and number of layers for neuron structures. Columns represent individual aerosol type. Color represents the Pearson's correlation coefficient (r).

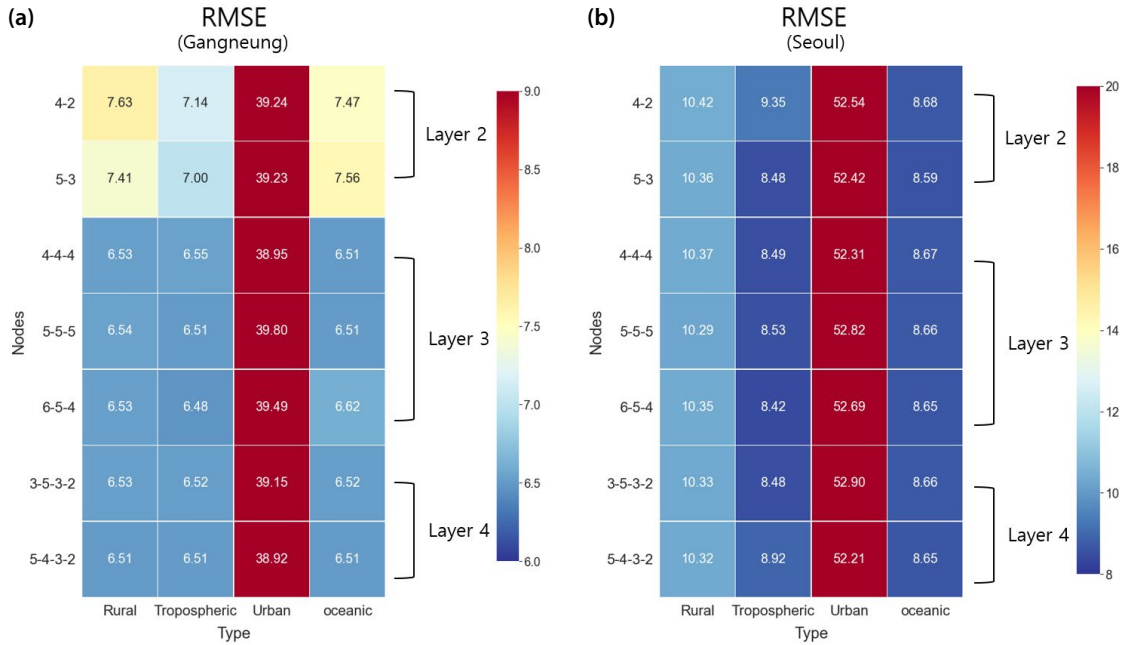


Fig. 4. Same as Fig. 3 but for root mean square error (RMSE).




Fig. 5. Same as Fig. 3 but for Bias.

로 구성된 DNN 모델을 사용할 때 $R=0.97$, $RMSE=6.51$, $Bias=0.68$ 로 가장 정확도가 높게 나타났다. 서울의 경우 Tropospheric 에어러솔 타입과 (6-5-4) 노드로 구성된 DNN 모델을 사용하였을 때, $R=0.97$, $RMSE=8.42$, $Bias=2.03$ 으로 가장 정확도가 높았다. 따라서 서울과 강릉의 에어러솔 광학 두께와 태양 천정각의 지상 관측값을 DL_ARF의 입력 자료로 하여 각각 Tropospheric 에어러솔과 (6-5-4) 노드, Rural 에어러솔과 (5-4-3-2) 노드로 구성된 DNN 모델을 사용하면 가장 높은 정확도의 ARF 값을 예측할 수 있는 것으로 판단된다.

3.2 ARF 산출 결과

그림 6은 강릉과 서울에서 DL_ARF를 이용해 산출된 ARF 결과와 AERONET에서 제공하는 ARF를 비교한 회귀분석 그래프이다. 강릉의 경우 회귀직선의 slope는 1.06이고 상관계수 R 은 0.97로 AERONET ARF와의 상관성이 매우 높았다. 또한 Bias와 RMSE가 각각 0.68, 6.51로 정확도도 높은 결과를 얻었다. 서울의 경우 회귀직선의 slope는 1.04이고 상관계수 R 은 0.97로 AERONET ARF와의 상관성이 매우 높았다.

또한 Bias와 RMSE가 각각 2.03, 8.42로 정확도 높은 모델 결과를 얻었다. 이렇게, 강릉과 서울 두 지역에서 DL_ARF를 이용한 ARF는 복사전달모델로 계산된 값과 상대편차는 2.38% (강릉), 9.67% (서울) 내외의 정확도를 가지는 값을 보였다.

그림 7은 DL_ARF를 이용하여 산출한 서울(a)과 강릉(b)의 과거 ARF를 연도별로 분석한 그림이다. 강릉과 서울 두 지역 모두 2015~2020년 기간 동안 연평균 에어러솔 복사강제력이 지속적으로 감소하는 추세를(서울: $3.04 \text{ W/m}^2/\text{yr}$, 강릉: $3.63 \text{ W/m}^2/\text{yr}$) 보였으며 2021년부터 다시 증가하는 결과를 보인다. 특히, 2020년의 연평균 ARF는 서울이 -36.9 W/m^2 , 강릉은 -27.34 W/m^2 으로 이전 5년간(2015년~2019년)의 평균 ARF(서울: -48.84 W/m^2 , 강릉: -35.46 W/m^2)에 비해 크게 감소하였다(서울: 18.8%, 강릉: 29.7%). 이는 대기오염물질 배출 저감 정책과 코로나 19로 인한 활동 제한 등 다양한 원인이 복합적으로 작용하여 나타난 결과로 보인다.

그림 8은 식 (5)를 이용하여 두 지역에서 단위 에어러솔 광학 두께당 에어러솔의 복사강제력인 에어러솔 복사강제효율(Aerosol Radiative Forcing Efficiency;

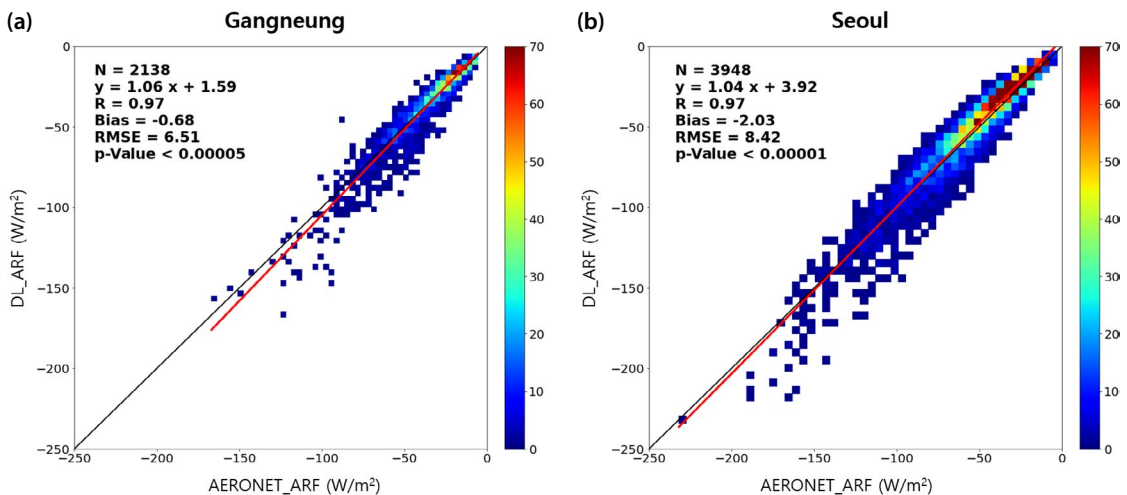


Fig. 6. Scatter plots of ARF determined by the optimal DL_ARF and AERONET ARF in (a) Gangneung and (b) Seoul, respectively.

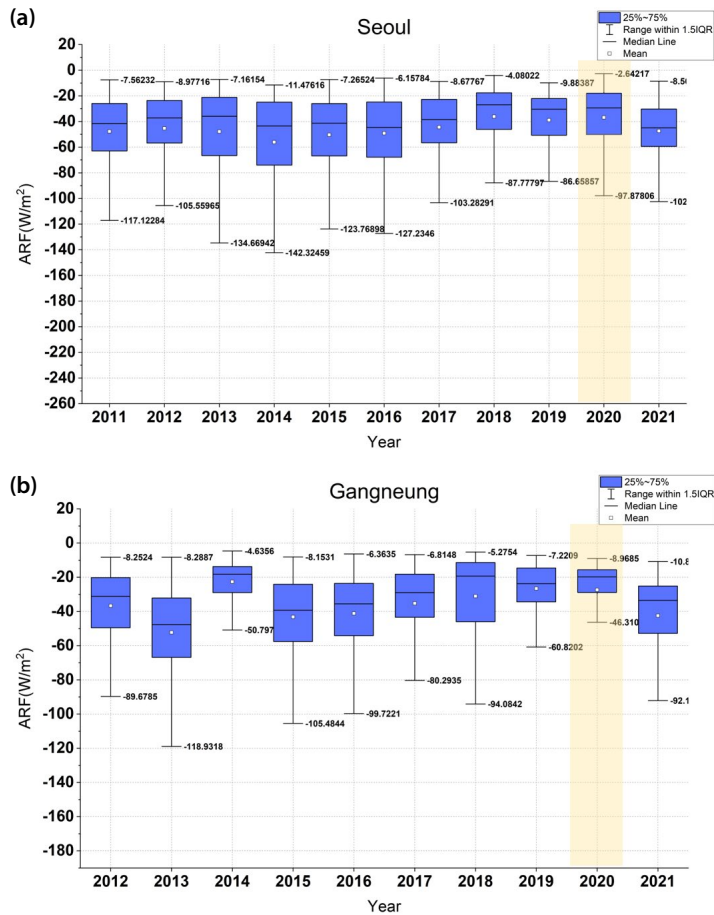


Fig. 7. Box plot showing the annual average ARF and Interquartile range (IQR) of (a) Gangneung and (b) Seoul predicted using DL_ARF.

ARFE)을 계산하여 비교한 결과이다.

$$ARFE = \frac{\Delta ARF}{\Delta AOD} \quad (5)$$

ΔARF : ARF의 변화량 (W/m^2)

ΔAOD : AOD의 변화량 (τ)

ARF는 에어러솔에 의한 총 복사강제력을 의미하지만, ARFE는 에어러솔의 부하량에 따른 복사강제력을 의미하므로 두 지역의 에어러솔의 특성에 따른 복사강제력의 차이를 비교할 수 있다. 강릉의 $ARFE = -1.22 W/m^2/\tau$ 이고, 서울의 $ARFE = -1.03 W/m^2/\tau$ 로서, 서울보다 강릉에서의 ARFE가 음의 방향으로 18.4% 더

크게 작용한다. 즉, 강릉의 대기 중 에어러솔 입자의 총량은 서울보다는 적지만, 단위 입자당 태양 복사량의 소산이 더 활발하여 이로 인한 복사냉각효율이 더욱 크게 나타난 결과이다.

3.3 지역별 에어러솔 특성

강릉과 서울의 에어러솔 복사강제효율을 비교한 결과 강릉의 에어러솔 복사강제효율이 더 크게 나타났으며, 이러한 결과에 대한 원인을 분석하기 위해 지역별 에어러솔의 광학 특성값을 비교하였다. 이를 위하여 2012년부터 2021년까지의 강릉과 서울의 파장별 단산란 알베도 (Single Scattering Albedo; SSA), 파장

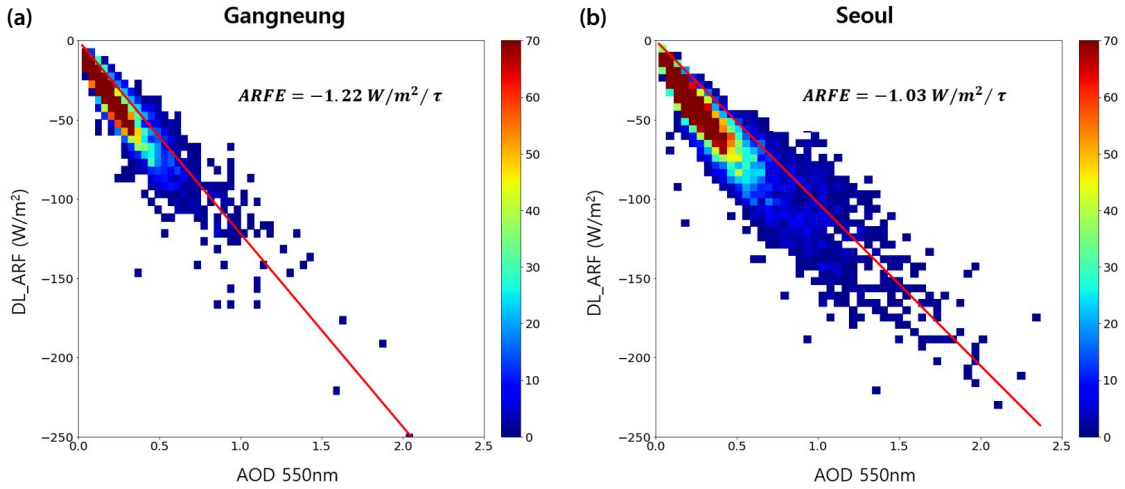


Fig. 8. Aerosol radiative forcing versus aerosol optical depth in (a) Gangneung and (b) Seoul. Slope of the linear regression line depicts aerosol radiative forcing efficiency (ARFE).

Table 5. Spectral asymmetry factor (ASY) and single scattering albedo (SSA) from the AERONET database and standard aerosol types.

Types/City		Single scattering albedo				Asymmetry factor			
		440 nm	675 nm	870 nm	1,020 nm	440 nm	675 nm	870 nm	1,020 nm
RTM	Rural	0.930	0.947	0.945	0.942	0.658	0.636	0.624	0.618
	Urban	0.567	0.702	0.760	0.790	0.682	0.644	0.627	0.617
	Oceanic	0.978	0.986	0.985	0.985	0.683	0.677	0.681	0.684
	Tropospheric	0.949	0.965	0.970	0.972	0.648	0.617	0.590	0.574
AERONET	Gangneung	0.933	0.927	0.908	0.896	0.697	0.653	0.639	0.637
	Seoul	0.935	0.938	0.928	0.921	0.701	0.645	0.626	0.624

별 비대칭 변수 (Asymmetry Factor; ASY), 상대습도 (Relative humidity; RH), 에어러솔 유효 반경 (Effective Radius; Reff)을 사용하여 두 지역의 복사강제효율의 차이가 발생하는 원인을 조사하였다.

그림 9와 표 5는 강릉과 서울에서 관측된 평균 SSA와 ASY 값을 표준 대기 에어러솔 모델과 비교한 것이다. SSA는 0과 1 사이의 값을 가지는 입자의 상대적인 광 흡수도를 나타내며, ASY는 산란된 복사에너지의 각도별 분포를 설명하는 데 사용된다. ASY는 기본적으로 -1 (후방 산란)에서 +1 (전방 산란) 범위에 있을 수 있다. 식 (6)과 식 (7)은 SSA와 ASY를 산출하는 식이다.

$$SSA = \frac{Q_{sca}}{Q_{ext}} \quad (6)$$

Q_{sca} : 산란 효율

Q_{ext} : 소산 효율

$$ASY = \frac{1}{2} \int_0^\pi \cos \theta P(\theta) \sin \theta d\theta \quad (7)$$

θ : 입사광과 산란광 사이의 각도

$P(\theta)$: 위상함수 (산란광의 각도 분포)

각 파장별 SSA는 모든 파장에 대해 서울보다 강릉의 SSA 값이 약 1.58% 더 작은 값이 나타났으며, 이로 인하여 강릉의 대기 중에서는 단위 AOD당 더 많은

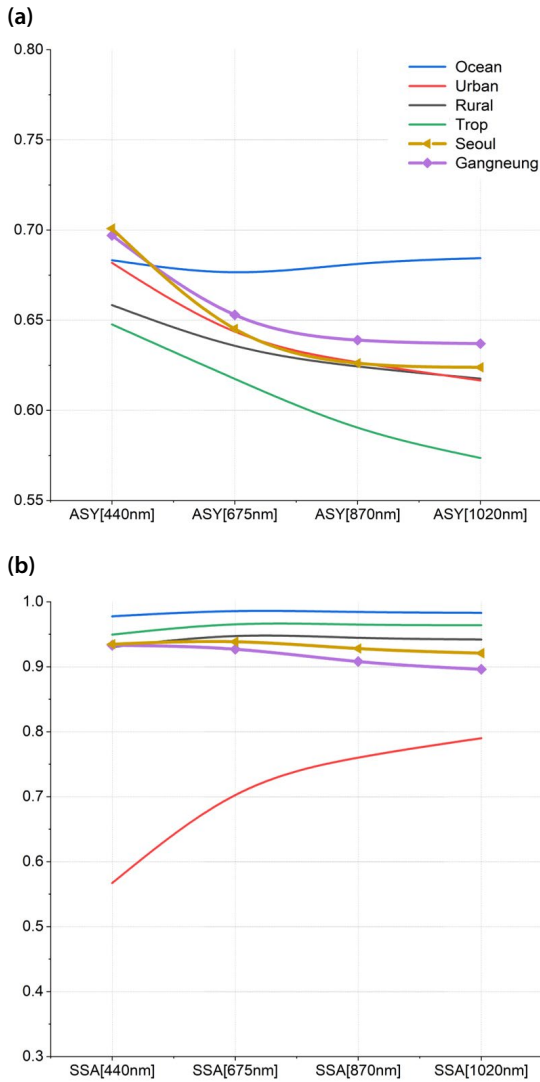


Fig. 9. (a) Asymmetry factor (ASY) and (b) single scattering albedo (SSA) from the AERONET database and standard aerosol types.

광 흡수가 발생한 것으로 판단된다. 그리고 파장별 ASY는 강릉이 서울보다 약 1.15% 더 큰 값을 나타낸다. 상대적으로 큰 ASY 값은 전방 산란이 큰 것을 의미하므로, 입자 산란(또는 Mie 산란)에 의하여 직달(direct)보다는 산란된(scattered or diffused) 복사량이 서울에 비해 강릉이 더 큰 것을 의미한다. 따라서 강릉의 ARFE가 서울보다 크게 나타나는 주요 원인

중 한 가지는 대기 중 에어러솔의 광 흡수성과 산란 특성으로 인하여 태양 복사를 더 많이 흡수 또는 산란시키는 특성을 가지는 것으로 나타났다.

대기 중에 동일한 성분의 입자 수가 존재할 때, 태양 복사 스펙트럼 영역에서 입자의 크기가 작을수록 미 산란 효과가 커지게 되므로 복사강제 효과에 더욱 큰 영향을 미칠 수 있게 된다. 따라서, 지역 대기 중의 입자 크기는 복사강제 효과의 영향요인으로 작용할 수 있다. 그림 10은 강릉과 서울의 에어러솔 유효 반경(aerosol effective radius, $Reff$)의 월평균 그래프이다. 강릉에서 관측된 입자의 $Reff$ 는 서울보다 약 4.5% ($\int \Delta Reff = 01.8$) 낮은 값을 나타내며, 이로 인하여 강릉의 대기 중 태양 복사의 미 산란 효과가 더욱 클 수 있음을 예상할 수 있다.

한편, 대기 중의 입자는 상대습도(RH)의 조건에 따라 굴절률 및 크기가 변하게 되므로, RH는 광학 특성 값인 AOD와 ASY, SSA에도 영향을 미칠 수 있다(Kim *et al.*, 2006; Markowicz *et al.*, 2003; Gasso *et al.*, 2000; Kotchenruther *et al.*, 1999). RH의 증가는 입자의 흡수성장에 따른 크기 증가와 전방 산란 효과의 증대로 ARF에도 영향을 미치게 된다(Chin *et al.*, 2002; Hegg *et al.*, 2002; Takemura *et al.*, 2002; Im *et al.*, 2001; Kotchenruther *et al.*, 1999; McInnes *et al.*, 1998; Nemesure *et al.*, 1995). 따라서 상대습도의 차이로 인한 ARF의 영향을 분석하기 위하여 강릉과 서울의 월별 평균 상대습도를 분석하였다. 그림 11(a)은 강릉과 서울의 상대습도 분포를 히스토그램이고, 그림 11(b)는 월별 RH 값의 변화 그래프이다. 그림 11(a)에서 강릉의 상대습도 분포의 폭이 서울보다 더 크게 나타났으며, 특히, 6월~10월은 강릉의 상대습도가 높고 그 외 달에는 서울의 상대습도가 더 높았다. 따라서, 상대습도와 에어러솔 유효 반경을 비교했을 때, 습도가 높을 때 습식흡착으로 인해 에어러솔 유효 입자의 크기가 변하는 것으로 판단된다. 이상의 결과를 통하여 강릉에서는 건조한 대기 조건하에서 서울보다 작은 크기의 에어러솔 입자가 존재하며, 상대적으로 낮은 SSA 값을 가지는 광 흡수성 입자의 특성을 나타냄으로써, 단

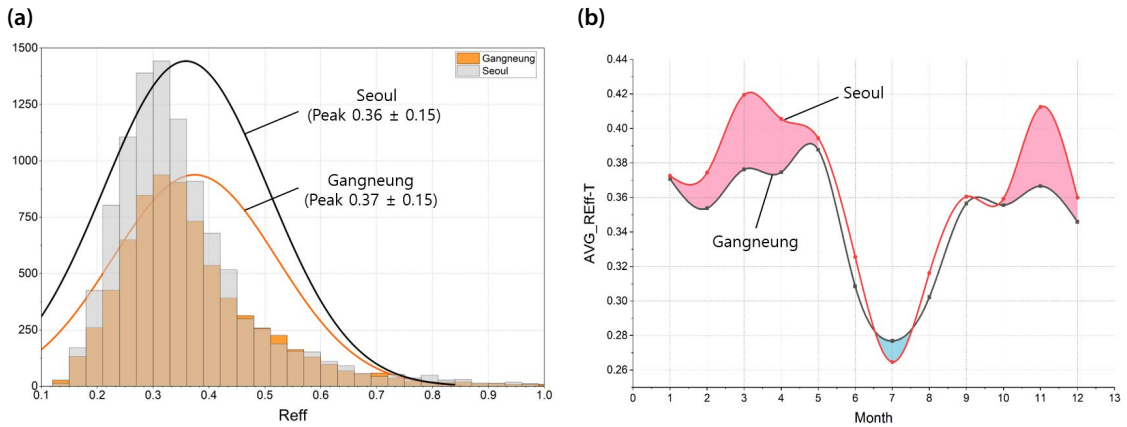


Fig. 10. The results of comparing the monthly average values of aerosol Effective Radius ($Reff$) observed in Gangneung and Seoul during the period from 2012 to 2021 with (a) histogram and (b) time series graph.

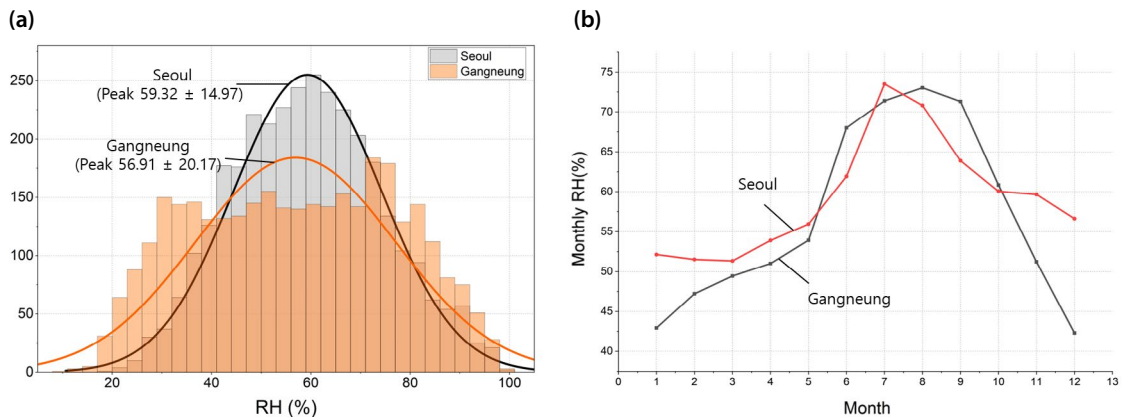


Fig. 11. The results of comparing the monthly average values of Relative humidity (RH) observed in Gangneung and Seoul during the period from 2012 to 2021 with (a) histogram and (b) time series graph.

일 입자에 대한 광 산란 및 흡수 효과가 커지게 되어 ARFE도 커짐을 알 수 있었다.

4. 결 론

대기 중 입자상 물질인 에어러솔의 광학 특성으로 인하여 지표면에 도달하는 복사량의 증감을 나타내는 물리량인 ARF는 에어러솔의 총량과 광학 특성값의 변화에 크게 영향을 받는다. 또한 이러한 변화로 에어

러솔 복사강제효율이 변하게 되는데 이는 해당지역의 대기 운동 및 기후에 영향을 주는 중요한 요소이며 실시간 자료의 유무가 중요하다. 본 연구에서는 특정 지역에서 관측된 AOD와 태양 천정각 데이터만을 입력 자료로 사용하여 ARF를 결정할 수 있는 딥러닝 기반의 모델인 DL_ARF를 구축하였으며 그리고 한반도의 중부권의 동서를 대표하는 서울과 강릉 지역에 DL_ARF를 적용한 결과를 통해 다음과 같은 결론을 도출하였다.

첫째, 강릉과 서울에서 2012년부터 2021년까지 관

측된 AERONET level 2.0 AOD와 태양 고도각 데이터 (강릉: 2,138개, 서울: 3,948개)를 DL_ARF 모델에 입력하여 산출된 ARF와 AERONET에서 복사전달모형을 이용하여 계산된 ARF를 비교분석한 결과는 상관 계수 R 값이 0.95 ± 0.02 를 나타내어 상관성이 매우 높았으며, 두 ARF 간의 정확도는 약 98% 이상을 나타냈다. 그리고 같은 수의 데이터를 별도의 복사전달모형을 이용하여 산출하면 약 420분(강릉), 775분(서울)의 산출 시간이 걸리지만 DL_ARF를 이용한 경우는 약 3초 미만의 시간 동안 ARF를 산출할 수 있었다. 즉, DL_ARF는 기존의 복사전달모형을 이용하여 ARF를 계산하는 것보다 매우 빠르고 정확한 결과를 획득할 수 있으며, 실시간 ARF 산출 및 예측까지 가능성을 확인하였다.

둘째, DL_ARF에서 사용되는 심층 신경망은 히든 레이어의 구조에 따라 다양한 뉴런 모델로 구성이 가능하므로, 최적의 뉴런 모델을 결정하기 위하여 총 28개의 DNN 모델을 구축하여 비교하였다. 각 지역별 최적의 모델을 선택하기 위하여 ARF 산출 결과에 대한 R, RMSE, Bias 값을 비교하였다. 그 결과 강릉은 Rural aerosol 타입의 모델을 5-4-3-2 구조의 뉴런으로 훈련시킨 모델 기반의 결과가 $R=0.97$, $Bias=0.68$, $RMSE=6.51$ 로 가장 정확한 모델로 선택되었다. 서울은 Tropospheric aerosol 타입의 모델을 6-5-4 구조의 뉴런으로 훈련시킨 모델로 산출된 ARF가 $R=0.97$, $Bias=2.03$, $RMSE=8.42$ 로 가장 정확한 모델로 선택되었다. 이러한 통계적 최적화 기법을 알고리즘화하여 지역별 에어러솔 특성에 맞는 모델을 선정 가능하며, ARF를 정확하고 빠르게 산출하는 결과를 얻을 수 있었다.

셋째, DL_ARF를 이용하여 2011년~2021년 기간 동안의 서울과 강릉의 연평균 ARF의 변화를 분석한 결과 두 지역 모두 2020년까지 연평균 ARF가 지속적으로 감소하였고 2021년에 다시 증가하였다. 2020년 이전의 5년 평균 ARF (서울: -36.9 W/m^2 , 강릉: -27.34 W/m^2)보다 감소하였다(서울: 18.8%, 강릉: 29.7%). 이는 대기오염물질 저감 정책과 코로나 19로 인한 통제

등 다양한 원인이 복합적으로 작용한 결과로 보인다.

넷째, ARFE를 분석한 결과는 강릉이 $ARFE = -1.22 \text{ W/m}^2/\tau$ 이고, 서울이 $ARFE = -1.03 \text{ W/m}^2/\tau$ 로서, 강릉의 ARFE 값이 더 낮은 값을 나타냈다. 이러한 원인은 서울보다 강릉의 대기가 상대적으로 건조하며 (약 4.1%), 더욱 작은 입자 크기와(약 4.5%), 큰 광 흡수성(약 1.58%)을 가지고 있기 때문이며, 이러한 특징이 대기 중 단일 입자에 의한 냉각효율을 더욱 낮게 유도하는 것을 확인하였다.

본 연구에서 사용된 DNN 기반의 DL_ARF 모델은 기존의 복사전달모형링을 통하여 계산하였던 복잡한 과정을 대신하여 정확성과 신속성을 확보하였다. 이와 같은 실시간 ARF 산출 결과는 지표면에서의 대기 운동과 기후변화를 연구하는 데 효과적으로 이용이 가능할 것이다. 향후 DL_ARF 모델의 학습데이터와 지상 관측 데이터 및 지역별 대기 중 입자상 물질의 특성에 대한 데이터의 양이 늘어난다면 더욱 정확한 DL_ARF 모델의 성능을 향상시키는 추가 연구가 가능할 것이다.

감사의 글

이 논문은 2022년도 강릉원주대학교 학술연구조성비 지원에 의하여 수행되었음.

References

Bates, T.-S., Anderson, T.-L., Baynard, T., Bond, T., Boucher, O., Carmichael, G., Clarke, A., Erlick, C., Guo, H., Horowitz, L., Howell, S., Kulkarni, S., Maring, H., McComiskey, A., Middlebrook, A., Noone, K., O'Dowd, C.-D., Ogren, J., Penner, J., Quinn, P.-K., Ravishankara, A.-R., Savoie, D.-L., Schwartz, S.-E., Shinozuka, Y., Tang, Y., Weber, R.-J., Wu, Y. (2006) Aerosol Direct Radiative Effects over the Northwest Atlantic, Northwest Pacific, and North Indian Oceans: Estimates based on In-situ Chemical and Optical Measurements and Chemical Transport Modeling, Atmospheric Chemistry and

- Physics, 6, 1657-1732. <https://doi.org/10.5194/acp-6-1657-2006>
- Bi, J., Huang, J., Hu, Z., Holben, B.-N., Guo, Z. (2014) Investigating the Aerosol Optical and Radiative Characteristics of Heavy Haze Episodes in Beijing during January of 2013, *Journal of Geophysical Research: Atmospheres*, 119, 9884-9900. <https://doi.org/10.1002/2014JD021757>
- Bunjongjit, S., Ngaopitakkul, A., Pothisarn, C., Jettanasen, C. (2014) Improvement to Reduce Training Time of Back-propagation Neural Networks for Discrimination Between External Short Circuit and Internal Winding Fault, *Electronics and Electrical Engineering*, 1, 614-618. <https://doi.org/10.1109/InfoSEEE.2014.6948187>
- Charlson, R.-J., Langner, J., Rodhe, H., Leovy, C.-B., Warren, S.-G. (1991) Perturbation of the Northern Hemisphere Radiative Balance by Backscattering from Anthropogenic Sulfate Aerosols, *Tellus A: Dynamic Meteorology and Oceanography*, 43(4), 152-163. <https://doi.org/10.3402/tellusa.v43i4.11944>
- Chhachhiya, D., Sharma, A., Gupta, M. (2017) Designing Optimal Architecture of Neural Network with Particle Swarm Optimization Techniques Specifically for Educational Dataset, *Data Science & Engineering-Confluence*, 52-57. <https://doi.org/10.1109/CONFLUENCE.2017.7943123>
- Chin, M., Ginoux, P., Kinne, S., Torres, O., Holben, B.-N., Duncan, B.-N., Martin, R.-V., Logan, J.-A., Higurashi, A., Nakajima, T. (2002) Tropospheric Aerosol Optical Thickness from the GOCART Model and Comparisons with Satellite and Sun photometer Measurements, *Journal of the Atmospheric Sciences*, 59, 461-483. [https://doi.org/10.1175/1520-0469\(2002\)059<0461:TAOTFT>2.0.CO;2](https://doi.org/10.1175/1520-0469(2002)059<0461:TAOTFT>2.0.CO;2)
- Choi, J.-S., Kim, J.-H., Lee, T.-H., Choi, Y.-J., Park, T.-H., Ahn, J.-Y., Park, J.-S., Kim, H.-J., Koo, Y.-S., Kim, S.-D., Hong, Y.-D., Hong, J.-H. (2016) A Study on Chemical Characteristics of Aerosol Composition at West Inflow Regions in the Korean Peninsula I. Characteristics of PM Concentration and Chemical Components, *Journal of Korean Society for Atmospheric Environment*, 32(5), 469-484, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2016.32.5.469>
- Choi, J.-S., Kim, J.-H., Lee, T.-H., Choi, Y.-J., Park, T.-H., Ahn, J.-Y., Park, J.-S., Kim, H.-J., Koo, Y.-S., Kim, S.-D., Hong, Y.-D., Hong, J.-H. (2016) A Study on Chemical Characteristics of Aerosol Composition at West Inflow Regions in the Korean Peninsula II. Characteristics of Inorganic Aerosol Acidity and Organic Aerosol Oxidation, *Journal of Korean Society for Atmospheric Environment*, 32(5), 485-500, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2016.32.5.485>
- Choldun, I., Santoso, J., Surendro, K. (2019) Determining the Number of Hidden Layers in Neural Network by using Principal Component Analysis, In *Proceedings of SAI Intelligent Systems Conference*, 490-500. https://doi.org/10.1007/978-3-030-29513-4_36
- Field, C.-B., Barros, V.-R. (2014) *Climate change 2014 - Impacts, adaptation and vulnerability: Regional aspects*, Cambridge University Press.
- Gasso, S., Hegg, D.-A., Covert, D.-S., Collins, D., Noone, K.-J., Öström, E., Schmid, B., Russell, P.-B., Livingston, J.-M., Durkee, P.-M., Jonsson, H. (2000) Influence of Humidity on The Aerosol Scattering Coefficient and Its Effect on the Upwelling Radiance During ACE-2, *Tellus B: Chemical and Physical Meteorology*, 52(2), 546-567. <https://doi.org/10.3402/tellusb.v52i2.16657>
- Ghosh, S., Deng, H., Luan, Y. (2007) Error Sum of Squares and Power Comparisons for Model Search, Identification and Discrimination, *Journal of Statistical Planning and Inference*, 137(11), 3475-3482.
- Hauser, A., Oesch, D., Foppa, N. (2005) Aerosol Optical Depth over Land: Comparing AERONET, AVHRR and MODIS, *Geophysical Research Letters*, 32, L17816. <https://doi.org/10.1029/2005GL023579>
- Hegg, D.-A., Covert, D.-S., Crahan, K., Jonssen, H. (2002) The Dependence of Aerosol Light-scattering on RH over the Pacific Ocean, *Geophysical Research Letters*, 29(8), 60-1-60-4. <https://doi.org/10.1029/2001GL014495>
- Hoesly, R.-M., Smith, S.-J., Feng, L., Klimont, Z., Janssens-Maenhout, G., Pitkanen, T., Seibert, J.-J., Vu, L., Andres, R.-J., Bolt, R.-M., Bond, T.-C., Dawidowski, L., Kholod, N., Kurokawa, J.-I., Li, M., Liu, L., Lu, Z., Moura, M.-C.-P., O'Rourke, P.-R., Zhang, Q. (2018) Historical (1750-2014) Anthropogenic Emissions of Reactive Gases and Aerosols from the Community Emissions Data System (CEDS), *Geoscientific Model Development*, 11, 369-408. <https://doi.org/10.5194/gmd-11-369-2018>
- Hua, S., Tian, H., Wang, K., Zhu, C., Gao, J., Ma, Y., Xue, Y., Wang, Y., Duan, S., Zhou, J. (2016) Atmospheric Emission Inventory of Hazardous Air Pollutants from China's Cement Plants: Temporal Trends, Spatial Variation Characteristics and Scenario Projections, *Atmospheric Environment*, 128, 1-9. <https://doi.org/10.1016/j.atmosenv.2015.12.056>
- Im, J.-S., Saxena, V.-K., Wenny, B.-N. (2001) An assessment of

- hygroscopic growth factors for aerosols in the surface boundary layer for computing direct radiative forcing, *Journal of Geophysical Research: Atmospheres*, 106, 20213-20224.
- Intergovernmental Panel on Climate Change (IPCC) (2022) Climate Change 2022: Mitigation of Climate Change. <https://doi.org/10.1017/9781009157926>
- Jiang, H., Lu, N., Qin, J., Tang, W., Yao, L. (2019) A Deep Learning Algorithm to Estimate Hourly Global Solar Radiation from Geostationary Satellite Data., *Renewable and Sustainable Energy Reviews*, 114, 109327. <https://doi.org/10.1016/j.rser.2019.109327>
- Kim, H.-M., Jeong, J.-H., Kim, H.-U., Park, C.-G., Kim, B.-J., Kim, S.-B. (2020) Effects of Observation Network Density Change on Spatial Distribution of Meteorological Variables: Three-Dimensional Meteorological Observation Project in the Yeongdong Region in 2019, *Korean Meteorological Society: Atmosphere*, 30(2), 169-181. <https://doi.org/10.14191/Atmos.2020.30.2.169>
- Kim, J.-H., Choi, J.-H., Kang, C.-W. (2019) Time Series Prediction Using Recurrent Neural Network, *Journal of The Korean Data Analysis Society*, 21(4), 1771-1779.
- Kim, J., Yoon, S.-C., Jefferson, A., Kim, S.-W. (2006) Aerosol Hygroscopic Properties During Asian Dust, Pollution, and Biomass Burning Episodes at Gosan, Korea in April 2001, *Atmospheric Environment*, 40(8), 1550-1560.
- Kotchenruther, R.-A., Hobbs, P.-V., Hegg, D.-A. (1999) Humidification Factors for Atmospheric Aerosols off the Mid-Atlantic Coast of the United States, *Journal of Geophysical Research*, 104, 2239-2251. <https://doi.org/10.1029/98JD01751>
- Krishnamurti, T.-N., Jha, B., Prospero, J., Jayaraman, A., Ramathan, V. (1998) Aerosol and Pollutant Transport and Their Impact on Radiative Forcing over The Tropical Indian Ocean during the January - February 1996 pre-INDOEX cruise, *Tellus B: Chemical and Physical Meteorology*, 50(5), 521-542. <https://doi.org/10.3402/tellusb.v50i5.16235>
- Lee, K.-H., Kim, Y.-J. (2010) Satellite Remote Sensing of Asian Aerosols: A Case Study of Clean, Polluted and Dust Storm Days, *Atmospheric Measurement Techniques Discussions*, 3(3), 2651-2680. <https://doi.org/10.5194/amt-3-1771-2010>
- Lee, K.-H., Lee, K.-T. (2020) Characteristics of Atmospheric Aerosols Based on Column Measurements by Using Machine Learning Clustering, *Journal of Korean Society for Atmospheric Environment*, 36(5), 608-619, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2020.36.5.608>
- Lee, Y.-H. (2021) A Study on Analytical Machine Learning Method Applying Discretization and Hierarchical Clustering Algorithm, *The Journal of Korean Institute of Information Technology*, 19(1), 55-61. <https://doi.org/10.14801/jkiit.2021.19.1.55>
- Markowicz, K.-M., Flatau, P.-J., Quinn, P.-K., Carrico, C.-M., Flatau, M.-K., Vogelmann, A.-M., David, B., Liu, M., Rood, M.-J. (2003) Influence of Relative Humidity on Aerosol Radiative Forcing: An ACE-Asia Experiment Perspective, *Journal of Geophysical Research: Atmospheres*, 108(D23), 8662. <https://doi.org/10.1029/2002JD003066>
- McInnes, L., Bergin, M., Ogren, J., Schwartz, S. (1998) Apportionment of Light Scattering and Hygroscopic Growth to Aerosol Composition, *Geophysical Research Letters*, 25(4), 513-516. <https://doi.org/10.1029/98GL00127>
- Murphy, K.-P. (2012) *Machine Learning: A Probabilistic Perspective*, MIT Press.
- Nemesure, S., Wagoner, R., Schwartz, S.-E. (1995) Direct Short-wave Forcing of Climate by the Anthropogenic Sulfate Aerosol: Sensitivity to Particle Size, Composition, and Relative Humidity, *Journal of Geophysical Research: Atmospheres*, 100(D12), 26105-26116. <https://doi.org/10.1029/95JD02897>
- Oh, H.-R., Ho, C.-H., Kim, J.-W., Chen, D., Lee, S.-M., Choi, Y.-S., Chang, L.-S., Song, C.-K. (2015) Long-range Transport of Air Pollutants Originating in China: A Possible Major Cause of Multi Day High PM₁₀ Episodes During Cold Season in Seoul, Korea, *Atmospheric Environment*, 109, 23-30. <https://doi.org/10.1016/j.atmosenv.2015.03.005>
- Penner, J.-E., Charlson, R.-J., Hales, J.-M., Laulainen, N.-S., Leifer, R., Novakov, T., Ogren, J., Radke, L.-F., Schwartz, S.-E., Travis, L. (1994) Quantifying and Minimizing Uncertainty of Climate Forcing by Anthropogenic Aerosols, *Bulletin of the American Meteorological Society*, 75(3), 375-400. [https://doi.org/10.1175/1520-0477\(1994\)075<0375:Qamuoc>2.0.Co;2](https://doi.org/10.1175/1520-0477(1994)075<0375:Qamuoc>2.0.Co;2)
- Pyo, S.-H., Lee, K.-H., Lee, K.-T. (2021) Estimation of Column Aerosol Contribution in Seoul and Gangneung Using Machine Learning Clustering Technique, *Journal of Korean Society for Atmospheric Environment*, 37(6), 931-945, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2021.37.6.931>
- Qin, W., Wang, L., Lin, A., Zhang, M., Bilal, M. (2018) Improving the Estimation of Daily Aerosol Optical Depth and Aerosol Radiative Effect using An Optimized Artificial Neural Network, *Remote Sensing*, 10(7), 1022. <https://doi.org/10.3390/rs10071022>

- org/10.3390/rs10071022
- Reifman, J., Feldman, E.-E. (2002) Multilayer Perceptron for Non-linear Programming, *Computers and Operations Research*, 29(9), 1237-1250. [https://doi.org/10.1016/S0305-0548\(01\)00027-2](https://doi.org/10.1016/S0305-0548(01)00027-2)
- Rumelhart, D.-E., Hinton, G.-E., Williams, R.-J. (1986) Learning Representations by Back-propagating Errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Shin, S.-K., Lee, K.-H. (2016) Trend Analysis of Wildland Fires and Their Impacts on Atmospheric Environment over East Asia, *Asian Journal of Atmospheric Environment*, 10(1), 22-31. <https://doi.org/10.5572/ajae.2016.10.1.022>
- Takemura, T., Nakajima, T., Dubovik, O., Holben, B.-N., Kinne, S. (2002) Single Scattering Albedo and Radiative Forcing of Various Aerosol Species with a global Three-Dimensional Model, *Journal of Climate*, 15, 333-352. [https://doi.org/10.1175/1520-0442\(2002\)015<0333:SSAARF>2.0.CO;2](https://doi.org/10.1175/1520-0442(2002)015<0333:SSAARF>2.0.CO;2)
- Ukkonen, P., Pincus, R., Hogan, R.-J., Pagh Nielsen, K., Kaas, E. (2020) Accelerating Radiation Computations for Dynamical Models with Targeted Machine Learning and Code Optimization, *Journal of Advances in Modeling Earth Systems*, 12(12). <https://doi.org/10.1029/2020MS002226>
- Yoon, S.-C., Won, J.-G., Omar, A.-H., Kim, S.-W., Sohn, B.-J. (2005) Estimation of the Radiative Forcing by Key Aerosol Types in Worldwide Locations using a Column Model and AERONET data, *Atmospheric Environment*, 39(35), 6620-6630. <https://doi.org/10.1016/j.atmosenv.2005.07.058>

Authors Information

표성훈 (강릉원주대학교 복사위성연구소, 공간정보협동과정, 석사과정) (pyos09562@gmail.com)

이권호 (강릉원주대학교 복사위성연구소, 대기환경과학과, 교수) (kwonho.lee@gmail.com)