

총 설

인공지능을 활용한 위성 기반 대기질 모니터링: 연구 현황과 전망 Satellite-based Air Quality Monitoring Using Artificial Intelligence: Research Trends and Future Perspectives

최현영[†], 황수민[†], 강은진, 김예진, 양세영, Saman Malik,
Jebun Naher Keya, 이시현, 임정호*

울산과학기술원 지구환경도시건설공학과

Hyunyoung Choi[†], Soomin Hwang[†], Eunjin Kang, Yejin Kim, Seyoung Yang,
Saman Malik, Jebun Naher Keya, Sihyun Lee, Jungcho Im*

Department of Civil, Urban, Earth, and Environmental Engineering,
Ulsan National Institute of Science and Technology, Ulsan, Republic of Korea

접수일 2025년 3월 11일
수정일 2025년 4월 3일
채택일 2025년 4월 4일

Received 11 March 2025
Revised 3 April 2025
Accepted 4 April 2025

[†]These two authors contributed
equally to this work as co-first authors.

*Corresponding author
Tel : +82-(0)52-217-2824
E-mail : ersgis@unist.ac.kr

Abstract Advancements in artificial intelligence (AI) and satellite remote sensing have become pivotal in air quality monitoring. This study presents a comprehensive review of 204 papers published between 2015 and 2025, synthesizing key research trends, limitations, and future directions. Based on this review, we identify three principal research approaches: (1) estimating ground-level concentrations from satellite column density products, (2) retrieving these values directly from top-of-atmosphere reflectance, and (3) addressing data gaps in satellite observations to achieve all-sky estimates. Furthermore, we highlight critical challenges identified in previous studies, including nighttime air quality monitoring, uncertainty quantification, consideration of interactions among multiple air pollutants, and the integration of AI techniques for air quality forecasting. Drawing on these findings, we propose targeted research directions to address existing gaps and advance the field. This study enhances the understanding of AI and satellite remote sensing integration, providing a foundation for future advancements in air quality monitoring. The development of a high-resolution, spatiotemporally continuous monitoring framework is expected to improve public health protection and strengthen climate change mitigation efforts.

Key words: Air quality monitoring, Artificial intelligence, Satellite, Remote sensing

1. 서 론

대기 오염은 인류 건강을 위협하고 기후 시스템을 변화시키며 생태계를 교란하는 주요 환경 문제로 인식되고 있다. 특히, PM₁₀, PM_{2.5}, NO₂, O₃ 등 주요 대기오염물질의 농도가 증가할 경우 천식, 기관지염, 심혈관 질환, 폐암, 뇌졸중과 같은 다양한 건강 영향을 유발할 수 있으며, 광화학 반응을 통해 2차 오염물질을 생성하고, 장거리 수송을 통해 광범위한 지역의 대기질을 악화시키는 등 인간 생활권에 직·간접적인

영향을 미친다(Kim *et al.*, 2025; Jung and Kim, 2024; Ayus *et al.*, 2023; Wei *et al.*, 2023b). 주요 지상 대기오염물질에는 미세먼지 (PM₁₀, PM_{2.5}), 이산화질소 (NO₂), 오존 (O₃), 이산화황 (SO₂), 일산화탄소 (CO) 등이 있으며, 산업 활동, 교통 배출, 화석연료 연소 등의 인위적 요인뿐 아니라 화산 폭발, 생물학적 분해와 같은 자연적 과정에서도 배출된다. 세계보건기구 (WHO; World Health Organization)는 대기오염을 연간 수백만 명의 조기 사망을 초래하는 주요 공중 보건 위협 요소로 규정하였다(WHO, 2021). 또한, 기후

변화에 관한 정부 간 협의체 (IPCC; Intergovernmental Panel on Climate Change)는 대기오염물질이 온실가스와 복합적으로 작용하여 기후 시스템을 변화시키며, 지구 온난화를 가속하거나 특정 지역의 기후 패턴을 변화시킬 수 있음을 지적하였다(Calvin *et al.*, 2023). 따라서, 지상 대기오염물질 농도를 지속적이고 정밀하게 모니터링하는 것은 공중보건 향상뿐만 아니라 기후변화 대응 및 대기질 평가를 위한 필수적 과제이다.

세계 각국에서는 지상 관측소 기반의 대기오염물질 모니터링 시스템을 운영하여 신뢰도 높은 데이터를 제공하고 있다(Wei *et al.*, 2022a; Wong *et al.*, 2021). 그러나 지상 관측소는 주로 인구 밀집 지역에 집중적으로 배치되어 있어 공간적 불균형이 존재하며, 광범위한 지역을 아우르는 대기오염의 공간적 분포 파악에 어려움이 따른다. 이러한 제약을 보완하기 위해 위성 원격탐사를 활용한 대기질 모니터링이 활발히 이루어지고 있다(Zaman *et al.*, 2024; Abu El-Magd *et al.*, 2023; Chen *et al.*, 2022a). 위성 자료는 원격 감지 기술을 이용하여 대기오염물질의 분광학적 특성을 분석하고, 대기에서 반사·산란된 빛의 세기 또는 흡수된 스펙트럼의 변화를 감지하여 대기 중 농도를 추정하는 방식으로 제공된다(Joy *et al.*, 2024; Valappil *et al.*, 2024; Holloway *et al.*, 2021; Prunet *et al.*, 2020). 이를 통해 넓은 지역을 지속적으로 모니터링할 수 있으며, 지상 관측소가 결여된 지역에서도 대기오염물질의 시공간적 변동성을 효과적으로 파악할 수 있다는 강점을 가진다. 따라서, 위성 기반 대기질 모니터링은 지상 관측소의 공간적 제약을 보완하는 중요한 수단으로 활용되고 있다.

그러나 위성 산출물은 인체 건강 및 환경과 직접 연관된 지상농도가 아닌 연직 컬럼 농도(VCD; Vertical Column Density)로 제공되며, 구름 등의 기상 조건에 의해 결측이 발생할 수 있다는 한계를 가진다(Choi *et al.*, 2021; Chi *et al.*, 2020). 또한, 연직 컬럼 농도와 지상농도는 단순한 선형 관계가 아닌 대기역학적 및 대기화학적 요인에 의해 복합적으로 영향을 받

는 비선형적 특성을 보인다(Kang *et al.*, 2021; You *et al.*, 2016). 이러한 복잡성을 전통적인 통계 기법만으로 정밀하게 해석하는 데에는 어려움이 있다. 이를 극복하기 위해, 최근에는 인공지능(AI; Artificial Intelligence) 기법과의 융합을 통해 위성 산출물의 활용도를 극대화하고자 하는 시도가 활발히 이루어지고 있다. 특히, 머신러닝 및 딥러닝 기법을 활용하여 위성 기반 대기오염물질 연직 컬럼 농도 또는 반사도 정보를 이용해 지상농도를 추정하는 연구가 활발히 이루어지고 있으며(Kakouri *et al.*, 2025; Shetty *et al.*, 2024; Choi *et al.*, 2023; Mao *et al.*, 2021; Zhang *et al.*, 2021b), 더 나아가 위성 자료의 결측을 보완하여 대기오염 감시의 공간적 연속성을 확보하려는 접근이 제안되고 있다(Yang *et al.*, 2025; Lee *et al.*, 2024b; Li *et al.*, 2023b; Wei *et al.*, 2022b). 이러한 접근은 보다 신뢰도 높은 지상 대기오염 정보를 제공 가능하게 함으로써, 환경 정책 수립 및 공중보건 대응 전략 마련에 중요한 과학적 근거로 활용될 수 있다.

본 논문에서는 인공지능을 활용한 위성 기반 대기질 모니터링 연구의 최신 동향을 분석하고 주요 연구 주제를 정리하며, 향후 연구 방향을 제시하는 것을 목표로 한다. 이를 위해 먼저 대기질 모니터링에 활용되는 주요 위성 산출물을 요약하고, 관련 연구의 출판 경향을 통계 분석하였다. 이후, 선별된 문헌을 바탕으로 주요 연구 주제를 분류하고 각 접근법의 특성과 시사점을 검토한 뒤, 인공지능 기반 대기질 모니터링의 한계를 논의하고 향후 나아가야 할 방향을 제시하고자 한다. 이를 통해 현시점에서 인공지능과 위성 원격탐사의 융합이 대기오염 감시에 미치는 영향을 파악하고, 연구자들이 향후 연구 방향을 설정하는 데 도움을 제공하고자 한다.

2. 인공지능 기반 위성 대기질 모니터링 연구 동향

연구 동향 분석을 위해 Scopus 데이터베이스의 ‘고

급 검색(Advanced search)’ 기능을 활용하여 인공지능 기반 위성 대기질 모니터링 관련 문헌을 수집하였다(<https://www.scopus.com/search/form.uri?display=advanced>). 검색 대상은 최근 10년간(2015년 1월부터 2025년 2월까지) 출판된 논문으로 제한하였으며, 다음과 같은 검색 쿼리(query)를 사용하였다: “TITLE-ABS-KEY ((“air quality monitoring” OR “air quality”) AND (“artificial intelligence” OR “machine learning” OR “deep learning”) AND (“satellite” OR “remote sensing”)) AND PUBYEAR > 2014 AND PUBYEAR < 2026 AND (LIMIT-TO (DOCTYPE , “ar”)) AND (LIMIT-TO (LANGUAGE , “English”) OR LIMIT-TO (LANGUAGE , “Korean”)) AND (LIMIT-TO (SRCTYPE , “j”))”. 검색 결과 총 316편의 문헌이 수집되었으며, 이후 추가 검토를 통해 ‘대기질’, ‘인공지능’, ‘위성 원격탐사’ 세 가지 공통 키워드와 직접적인 관련이 없는 논문을 제외하였다. 최종적으로 204편의 논문을 분석 대상으로 선정하였으며, 이를 바탕으로 인공지능 기반 위성 대기질 모니터링 연구의 주요 동향과 핵심 연구 주제를 분석하였다.

본 논문에서 다루는 인공지능은 크게 머신러닝과 딥러닝으로 구분되며, 딥러닝은 머신러닝의 하위 개념으로 이해할 수 있다. 머신러닝은 주어진 데이터를 바탕으로 규칙을 학습하는 방식으로, 구조가 비교적 단순하고 해석이 용이하다는 장점을 가진다(Linardatos *et al.*, 2020). 반면, 딥러닝은 사람의 뇌 구조를 모방한 인공신경망을 기반으로 복잡한 패턴을 자동으로 학습할 수 있으며, 특히 이미지나 시계열과 같은 고차원 데이터를 처리하는 데 강점을 보인다(Janiesch *et al.*, 2021; Shinde and Shah 2018). 이러한 차이로 인해 위성 기반 대기질 연구에서는 입력 데이터의 특성과 분석 목적에 따라 두 기법이 선택적으로 활용된다.

2.1 위성 산출물

인공지능 기반 위성 대기질 모니터링 연구에서는 에어로졸 광학 두께(AOD; Aerosol Optical Depth),

옹스트롬 지수(AE; Ångström Exponent), 미세입자 비율(FMF; Fine Mode Fraction), 단일산란 알베도(SSA; Single Scattering Albedo) 등 에어로졸 변수와 함께 NO₂, O₃, SO₂, CO, 포름알데히드(HCHO) 등의 대기오염물질의 연직 컬럼 농도가 주요하게 활용된다. 표 1에서는 극궤도(polar-orbiting)와 정지궤도(geostationary) 위성으로 구분하여 주요 위성 센서의 시공간 해상도 및 관측 범위 정보를 요약하였다. 극궤도 위성 탑재체인 MISR(Multi-angle Imaging Spectroradiometer)/Terra, MODIS(Moderate Resolution Imaging Spectroradiometer)/Terra, MODIS/Aqua, OMI(Ozone Monitoring Instrument)/Aura, VIIRS/SNPP(Visible Infrared Imaging Radiometer Suite/Suomi National Polar-orbiting Partnership), TROPOMI(TROPospheric Monitoring Instrument)/Sentinel-5P 등은 전 지구를 대상으로 관측이 가능하지만, 관측 주기가 1-2일로 제한된다. 반면 정지궤도 위성인 탑재체인 AHI(Advanced Himawari Imager)/Himawari-8, GOCI-I/COMS(Geostationary Ocean Color Imager-I/Communication Ocean and Meteorological Satellite), GOCI-II/GK-2B(Geostationary Ocean Color Imager-II/Geostationary Korea Multi-Purpose Satellite-2B), GEMS(Geostationary Environment Monitoring Spectrometer)/GK-2B 등은 관측 범위가 특정 지역에 한정되지만, 시간 단위로 연속적인 관측이 가능하다는 점에서 차이를 갖는다. 두 유형의 위성은 상호 보완적인 역할을 하며, 이를 결합해 공간적 분포와 시간적 변동성 모두 효과적으로 분석할 수 있다.

대부분의 대기질 감시 위성 센서는 자외선(UV; Ultraviolet), 가시광선(VIS; Visible), 근적외선(NIR; Near Infrared), 적외선(IR; Infrared), 단파 적외선(SWIR; Short Wave Infrared) 등 다양한 분광 채널을 이용해 에어로졸 총량에 대한 지표인 AOD를 산출한다. 일부 위성 센서(e.g., OMI, TROPOMI, GEMS)는 초분광(hyperspectral) 관측을 통해 대기 내 특정 기체의 흡수 및 산란 특성을 분석하여 NO₂, O₃, SO₂ 등

Table 1. Overview of commonly used satellite sensors for air quality monitoring. Products column values without any annotation indicate total column density, while values in parentheses represent vertical column density ranges (e.g., tropospheric, stratospheric, and profile).

Orbit	*Sensor/ **satellite	***Products	Spatial resolution	Temporal resolution	Spatial coverage	Temporal coverage
Polar	MISR / Terra	AOD, AE	Version 22: 17.6 km × 17.6 km / Version 23: 4.4 km × 4.4 km	~9 days (~10:30 Local time)	Global	2000.02–Present
	MODIS / Terra	AOD, AE, FMF	MAIAC: 1 km / Deep Blue: 3 km / Dark Target: 10 km	1–2 days (~10:30 Local time)		2000.02–Present
	MODIS / Aqua	AOD, AE, FMF	MAIAC: 1 km / Deep Blue: 3 km / Dark Target: 10 km	1–2 days (~13:30 Local time)		2002.07–Present
	OMI / Aura	AOD, SSA, UVAI, NO ₂ (Total/Tropospheric), O ₃ , SO ₂ , HCHO	13 km × 24 km (nadir)	Daily (~13:45 Local time)		2004.10–Present
	VIIRS / SNPP	AOD, AE	6 km	Daily (~13:30 Local time)		2011.10–Present
	TROPOMI / Sentinel-5P	UVAI, NO ₂ (Total/Tropospheric), O ₃ (Total/Tropospheric), SO ₂ , CO, HCHO	3.5 × 7 km (nadir) / 3.5 km × 5.5 km (2019.08–)	Daily (~13:30 Local time)		2017.10–Present
Geostationary	AHI/Himawari-8	AOD, AE, FMF	5 km × 5 km	10 minutes	Full Disk (60°S–60°N, 80°E–165°W)	2015.07–Present
	GOCI-I / COMS	AOD, AE, FMF, SSA	6 km × 6 km	Hourly (8 times / day)	East Asia (2,500 km × 2,500 km; @ Center coordinate 130°E, 36°N)	2011.04–2021.03
	GOCI-II / GK-2B	AOD, AE, FMF, SSA	2.5 km × 2.5 km	Hourly (10 times / day)		2020.12–Present
	GEMS / GK-2B	AOD, SSA, UVAI, VISAI, AEH, NO ₂ (Total/Tropospheric/Stratospheric), O ₃ (Total/Tropospheric/Stratospheric/Profile), SO ₂ , HCHO, CHOCHO	Aerosol: 3.5 km × 8 km / Gaseous: 7 km × 8 km	Hourly (6–10 times / day)	Asia-Pacific (5°S–45°N, 75°E–145°E)	2020.11–Present

*Sensor: MISR (Multi-angle Imaging SpectroRadiometer), MODIS (Moderate Resolution Imaging Spectroradiometer), VIIRS (Visible Infrared Imaging Radiometer Suite), OMI (Ozone Monitoring Instrument), TROPOMI (TROPOspheric Monitoring Instrument), AHI (Advanced Himawari Imager), GOCI-I/-II (Geostationary Ocean Color Imager-I/-II), GEMS (Geostationary Environment Monitoring Spectrometer)

**Satellite: SNPP (Suomi National Polar-orbiting Partnership), COMS (Communication Ocean and Meteorological Satellite), GK-2B (Geostationary KOREA Multi-Purpose SATellite-2B)

***Products: AOD (Aerosol Optical Depth), AE (Ångström exponent), FMF (Fine Mode Fraction), SSA (Single Scattering Albedo), UVAI (Ultraviolet Aerosol Index), VISAI (Visible-aerosol index), AEH (Aerosol Effective Height)

의 대기 성분 컬럼농도를 산출한다. 특히, 최신 위성 탑재체인 정지궤도 환경위성 (i.e., GEMS/GK-2B)은 300–500 nm의 초분광 파장대를 활용하여 대류권 및 성층권 대기오염물질 농도 프로파일 등 세분화된 산출물을 제공한다. 이와 같이 다양한 위성 산출물은 인공지능 기법과 접목되어 지상 대기오염물질 농도 추정 및 예측에 유용한 자료로 활용되고 있다.

2.2 연구 동향

그림 1은 2015년부터 2025년까지 최근 10년간 AI 기반 위성 대기질 연구 논문의 출판 추이와 주요 센서·위성 (Sensor/satellite)의 활용 비율을 나타낸다. 위성을 활용한 대기질 감시는 1900년대 후반부터 TOMS/Nimbus-7 (Total Ozone Mapping Spectrometer/Nimbus-7; 1978–1993), GOME/ERS-2 (Global Ozone Monitoring Experiment/European Remote-Sensing Satellite-2; 1995–2011), SCIAMACHY/ENVISAT (SCanning Imaging Absorption SpectroMeter for Atmospheric CHartography/ESA's ENVironmental SATellite; 2002–2012) 등의 초기 위성 센서를 활용하여 수행되었다(Wei *et al.*, 2020). 그러나, 초기 연구들은 주로 위성 산출물을 활용하여 전 지구적 오염물질

분포 및 시계열 변화를 분석하는 데 집중되었으며 (Herman *et al.*, 1997; Burrows *et al.*, 1995), 다중 선형 회귀 (multiple linear regression) 혹은 토지 이용 회귀 (land use regression)와 같은 전통적인 통계 기법에 의존하여 지상농도를 산출하는 데 그쳤다 (Kloog *et al.*, 2011; Gupta and Christopher, 2009). 위성 기반 대기질 모니터링에 AI가 접목되기 시작한 것은 비교적 최근인 2017년 이후부터이며, 특히 2021년 이후 관련 논문의 수가 급격히 증가하는 양상을 보인다 (그림 1a). 이는 AI 기술의 발전과 위성 데이터를 활용한 대기질 모니터링 연구의 확산에 따른 결과로 해석할 수 있다.

AI 기반 위성 대기질 분석 연구에서 센서별 활용 빈도를 분석한 결과, 2015–2025년 전체 분석 기간 동안 각 센서의 가용 연도 (표 1)를 고려한 정규화 기준에서 MODIS/Terra (20.7%)와 MODIS/Aqua (19.6%)가 가장 높은 활용 비율을 보이는 것으로 나타났다 (그림 1b). MODIS 센서는 2000년대 초반부터 안정적으로 관측을 지속해왔으며, 전 지구적 공간 커버리지를 제공함에 따라 다양한 대기질 연구에서 지속적으로 활용되어 왔다. TROPOMI/Sentinel-5P (19.5%)도 높은 활용 비율을 기록하였으며, 이는 최신 대기질




Fig. 1. Trends in the number of publications on AI-based remote sensing of air quality by year and distribution of sensor/satellite usage. (a) The dotted line represents the total annual number of publications from 2015 to 2025 (investigated until February 2025), and the stacked bar chart categorizes the yearly number of publications by commonly used sensors/satellites, as indicated by the color bars. (b) The pie chart illustrates the normalized usage share of each sensor/satellite, computed as the total usage count divided by its number of operational years.




Fig. 3. Analysis of AI-based remote sensing publications by target air pollutant type. (a) The horizontal bar chart represents the total number of publications categorized by air pollutants over the entire analysis period. (b) The line graph shows the annual publication trends from 2017 to 2025 (investigated until February 2025), classified by target pollutants, with different colors representing each pollutant. 2015–2016 are excluded because no relevant publications were found during that period.

이루어졌으며, 이는 두 물질이 인체 건강에 미치는 영향이 크고 차량 및 산업 활동에서 직접 배출되는 주요 오염물질이라는 점에서, 지속적인 감시의 필요성이 강조되어 왔음을 시사한다. 또한 PM_{2.5}는 직접 배출뿐만 아니라 황산염, 질산염 등 2차 생성 특성까지 포함하는 복합적인 성격을 지니기 때문에, 위성 자료를 활용한 광역 추정과 AI 기반 모델링에서 특히 활발하게 연구되고 있다. O₃ (42건)은 건강에 중요한 오염물질이지만, 위성 자료가 주로 오존 전량 정보를 제공하기 때문에 대류권 오존을 분리하는 데 기술적 한계가 존재하며 (Xu *et al.*, 2024), 이로 인해 AI 기반 연구 사례는 상대적으로 적은 것으로 나타난다. 그러

나 최근에는 AI 기술의 발전으로 O₃ VCD와 지상농도 간의 낮은 상관관계를 극복하려는 시도가 증가하고 있으며, 2021년 이후에는 관련 문헌 수도 빠르게 증가하는 추세를 보인다.

위성 기반 연구에서는 자료의 특성과 한계 또한 연구 대상 선택에 영향을 미친다. 위성 자료는 대기 조건 (e.g., 구름, 에어로졸)에 민감하며, 오염물질별로 관측 감도와 정확도에 차이가 존재한다. 특히 SO₂와 암모니아 (NH₃)의 경우 관측은 가능하지만, 높은 불확도와 낮은 신호 대 잡음비 (signal-to-noise ratio)로 인해 활용에 제약이 있으며 (Li *et al.*, 2022a; Van Damme *et al.*, 2014), 이에 따라 해당 물질을 다룬 연구는 상대적으로 제한적인 양상을 보인다. 아울러 대기오염의 종합적인 영향을 평가하는 대기질 지수 (AQI; Air Quality Index)를 분석하는 연구 (6건)도 일부 수행되었다. 전체 출판 건수의 증가와 함께 각 대기오염물질에 대한 연구도 2021년 이후 급격히 증가했으며, 특히 COVID-19 팬데믹이 대기오염물질 농도에 미친 영향을 분석한 연구가 다수 출판되었다 (Zhang *et al.*, 2023; Zhang *et al.*, 2021a). 한편, ‘그 외 (Others)’로 분류된 물질에는 이산화탄소 (CO₂)와 메탄 (CH₄)과 같은 온실가스와 블랙 카본 등이 포함되며, 이는 AI 기반 위성 대기질 연구가 기존의 대기오염물질을 넘어 보다 다양한 성분을 대상으로 확장되고 있음을 의미한다.

3. AI 활용 위성 기반 대기질 모니터링 분야 주요 연구 주제

본 리뷰에서는 인공지능을 활용한 위성 기반 대기질 모니터링 연구를 세 가지 주요 주제로 정리한다. 첫째, 위성 컬럼농도를 활용한 지상농도 추정, 둘째, 대기상한 반사도를 이용한 고해상도 지상농도 직접 추정, 셋째, 결측 보완을 통한 전천 지상농도 추정이다. 이는 위성 자료의 활용성을 극대화하고 대기오염 모니터링의 정확성과 시공간적 연속성을 향상시키기

위한 핵심 연구 분야로, 본 논문에서는 각 접근법의 원리와 주요 연구 사례를 중심으로 논의한다. 한편, AI 기반 위성 대기질 연구는 위성 VCD 및 프로파일 자료 산출 과정에서 AI를 활용한 편향 보정 (bias correction), 설명 가능한 인공지능 (XAI; eXplainable AI) 을 활용한 대기오염물질의 환경 영향 평가, 시계열 예측을 통한 대기질 변화 분석 등으로 확장되고 있다. 본 논문에서는 이러한 연구 흐름을 고려하되, AI 를 활용한 위성 기반 대기오염물질 지상농도 산출의 최신 연구 동향과 향후 전망에 대해 중점적으로 논의하고자 한다.

3.1 컬럼농도 산출물 활용 지상농도 추정

위성 기반 VCD 자료는 대기오염의 광범위한 공간적 패턴을 정량적으로 평가하는 데 핵심적인 역할을 하지만, 지상농도와 단순한 선형 관계를 형성하지 않으며 대기 혼합 상태, 행성경계층 내 오염물질 분포, 기상 조건, 국지적 배출원 등의 영향을 받는다 (Kang *et al.*, 2021). 따라서, 최근에는 머신러닝 및 딥러닝 기법을 활용하여 컬럼 농도와 지상농도 간의 비선형적 관계를 학습하는 연구가 활발히 이루어지고 있다 (Park *et al.*, 2024; Zhang *et al.*, 2022b; Huang *et al.*, 2021; Zhan *et al.*, 2018, 2017). 이 과정에서 위성 기반 VCD 자료를 주요 예측 변수로 활용하고, 기상 자료,

지표 특성, 인위적 배출량 자료 등의 보조 변수를 결합하여 보다 정교한 지상 대기오염 농도 추정 모델을 구축한다. 그림 4는 이러한 접근법의 개념적 모식도를 나타낸다.

지상농도를 정확히 추정하기 위해서는 각 대기오염물질의 특성을 반영할 수 있는 적절한 위성 자료를 선택하는 것이 매우 중요하다. 일반적으로 입자상 오염물질 (PM_{10} , $PM_{2.5}$)의 경우 AOD가 주요 예측 변수로 활용되며, MODIS, VIIRS, GOCI-I/II AOD 산출물 등이 널리 사용된다 (표 1) (Just *et al.*, 2025; Kakouri *et al.*, 2025; Su *et al.*, 2024; Aguilera *et al.*, 2023; Huang *et al.*, 2021; Lee *et al.*, 2021). AOD는 대기 중 에어로졸의 광학적 특성을 반영하여 지상 미세먼지 농도를 추정하는 데 유용한 정보를 제공한다. 반면, 가스상 오염물질 (NO_2 , O_3 , SO_2 , CO)의 경우에는 각 성분의 VCD가 핵심 예측 변수로 활용되며, OMI 및 TROPOMI 센서에서 산출된 자료가 대표적으로 사용된다 (표 1) (Chen *et al.*, 2024; Shetty *et al.*, 2024; Yu and Liu, 2021). 특히 NO_2 는 짧은 대기 수명 (atmospheric lifetime)과 강한 광학적 흡수 특성으로 인해 배출원 인근에 집중되어 분포하는 경향이 있으며, 이에 따라 위성 VCD는 지상농도 분포를 잘 반영하고 교통 및 산업 배출원의 국지적 특성을 뚜렷하게 포착할 수 있다 (Kim *et al.*, 2012). 한편, O_3 은 성층권과 대류권에




Fig. 4. Overall flow diagram of AI-based approaches for estimating ground-level air pollutant concentrations using satellite vertical column density data.

서의 분포 특성이 달라 이를 별도로 고려해야 하며, 광화학 반응 과정에서 NO_2 와 밀접하게 연관되므로 지상 O_3 농도를 추정할 때 NO_2 VCD를 함께 보조 변수로 사용하는 사례가 많다(Ni *et al.*, 2024; Tan *et al.*, 2024).

위성 VCD만으로는 지상 오염물질 농도를 정밀하게 추정하기에 한계가 있어, 기상 및 지표 환경 변수를 함께 고려하는 방식이 널리 사용된다. 대기 역학 및 오염물질 확산을 반영하기 위해 ERA5 (European centre for medium-range weather forecasts reanalysis v5)와 같은 기상 재분석 자료(reanalysis data)가 활용되며, 기온, 상대습도, 행성경계층 높이, 풍속 등의 변수를 포함한다(Kakouri *et al.*, 2025; Zhu *et al.*, 2023). 또한, 지역별 배출 특성을 반영하기 위해 토지 피복, 인구밀도, 도로밀도 등의 지표 환경 변수가 고려된다(Su *et al.*, 2024; Kang *et al.*, 2021). 아울러, 지형 변화에 따른 오염물질의 이동을 설명하기 위해 수치표고 모델(DEM; Digital Elevation Model) 자료도 활용된다. 이처럼 컬럼 농도와 다양한 보조 변수를 결합하면 높은 시공간 해상도의 대기오염 모니터링이 가능해지고, 기존 지상 관측소 중심 모니터링의 한계를 보완하는 데에도 기여할 수 있다.

현재까지의 지상농도 추정 연구에서는 일반적으로 지상 관측소 자료가 주요 참조 자료(reference)로 활용되었으며, 이를 기반으로 한 회귀 모델링이 주로 수행되었다. 이때 사용되는 입력 변수와 타겟 대기오염 물질은 정형(tabular) 데이터로 비교적 단순한 구조로 표현되기 때문에, 이러한 구조에 적합한 트리 기반 머신러닝 기법이 널리 활용되어 왔다. 트리 기반 모델은 계산 효율성이 높고 예측 성능이 우수할 뿐만 아니라, 변수 중요도(feature importance)를 산출할 수 있어 해석이 용이하다는 장점을 지닌다. 대표적으로 랜덤 포레스트(RF; Random Forest), XGBoost (eXtreme Gradient Boosting), LightGBM (Light Gradient Boosting Machine), Deep Forest 등이 널리 활용된다(Just *et al.*, 2025; Kakouri *et al.*, 2025; Kim *et al.*, 2024; Lee *et al.*, 2024a; Ni *et al.*, 2024; Zhu *et al.*, 2023). 한편, 최

근에는 위성 반사도 이미지 자체 혹은 시계열 형태로 누적된 고차원 비정형 데이터가 활용되면서, 이러한 복잡한 데이터를 효과적으로 학습할 수 있는 딥러닝 모델의 활용이 점차 확대되고 있다. 대표적으로 DNN (Deep neural network)과 장기 단기 기억 네트워크(LSTM; Long Short-Term Memory)가 적용되는 사례가 다수 등장하였으며(Chen *et al.*, 2023; Li *et al.*, 2023a; Zhang *et al.*, 2023; Yu and Liu, 2021), Li *et al.* (2023a)은 물리정보 신경망(PINN; Physics Informed Neural Network)을 활용해 시·공간적 특성을 학습함으로써 지상 NO_2 추정 정확도를 향상시켰다. 해당 연구에서는 PINN이 WRF-Chem (Weather Research and Forecasting-Chemistry) 모델 대비 높은 성능을 보이며 데이터 기반 접근법의 가능성을 입증하였다.

그러나, 위성 VCD 산출물을 활용한 지상 대기오염 농도 추정에는 몇 가지 한계가 존재한다. 첫째, 위성 자료의 시·공간 해상도가 제한적이므로 도시 내부의 미세한 변화를 정밀하게 분석하거나 단시간 대기질 변동을 포착하는 데 어려움이 있다. 둘째, 지상 관측소의 공간적 분포가 균등하지 않아 특정 지역의 특성에 과적합(overfitting)되거나, 미관측 지역에서는 위성 자료의 패턴을 그대로 따르는 편향이 발생할 수 있다. 특히, 지상 관측소가 부족한 농촌이나 개발도상국에서는 데이터 불균형이 심화되어 모델의 일반화 성능이 저하될 가능성이 크다. 따라서, 최근에는 이러한 한계를 보완하기 위한 연구가 지속적으로 이루어지고 있으며, 이에 대해서는 다음 섹션에서 상세히 논의한다.

3.2 대기상한 반사도 활용 지상농도 직접 추정

일반적으로 위성을 활용한 대기오염물질 지상농도 추정은 VCD 기반으로 이루어져 왔지만, 구름, 대기 산란, 지표 반사율 등의 영향으로 컬럼 농도와 지상 농도 간의 관계가 지역 및 환경에 따라 달라질 수 있으며, 이로 인해 불확실성이 증가한다(Choi *et al.*, 2023; Chen *et al.*, 2022b). 이러한 한계를 극복하기 위해 대기상한 반사도(TOAR; Top-of-Atmosphere

Reflectance)를 활용하여 지상농도를 직접 추정하는 방법이 연구되고 있다. TOAR 기반 모델은 지표면과 대기에서 반사된 신호를 분석하여 대기오염 정보를 추출하며, 머신러닝 기법과 결합하면 보다 정밀한 지상농도 추정이 가능하다(Chen *et al.*, 2022b). 이러한 접근법에서는 입력 변수로 사용될 파장대의 선정이 중요한 요소로 작용하며, 기존 연구에서는 크게 두 가지 접근법이 활용되고 있다. 첫째는 특정 대기오염 물질의 분광 흡수 특성을 고려하여 주요 파장대를 선택하는 방식이며(Kim *et al.*, 2025; Hu *et al.*, 2024; Kang *et al.*, 2023; Luo *et al.*, 2023; Yang *et al.*, 2023a), 둘째는 머신러닝 모델의 성능을 최적화하기 위해 특성 선택(feature selection) 기법을 적용하는 방식이다(Abu El-Magd *et al.*, 2023; Chen *et al.*, 2023; Chen *et al.*, 2022b; Li *et al.*, 2022c).

대기오염물질은 각 물질별로 특정 파장대에서 분광 흡수 강도가 다르게 나타나므로, 타겟 물질의 흡수 특성이 강한 파장대를 선정하여 활용하는 접근이 널리 적용되어 왔다. 예를 들어, Hu *et al.* (2024)는 NO₂ 흡수 특성이 강한 파장대와 상대적으로 약한 파장대 간의 비율을 계산하는 밴드 비율 기법을 적용하였다. 이는 복사 휘도(radiance)를 그대로 사용하는 것보다 신호 대 잡음비를 개선하고 모델의 복잡성을 줄이며 NO₂ 농도 추정의 정확도를 향상시키는 데 기여하였다.

또한, 특성 선택 기법은 머신러닝 모델의 성능을 최적화하기 위해 불필요한 변수를 제거하고 중요한 변수만을 선별하는 과정으로 활용된다. 모든 반사도 자료를 입력으로 사용할 경우, 모델의 복잡성이 증가하고 관련성이 낮은 변수가 추가되어 정확도가 저하될 수 있으며, 일반화 성능이 감소할 가능성이 크다. 이를 방지하기 위해 Chen *et al.* (2023)는 정보 엔트로피(information entropy)와 정보 이득(information gain)을 활용하여 타겟 변수와 높은 상관성을 가지는 채널을 선별하였다. 또한, 피어슨 상관 계수를 이용해 종속변수와 독립변수 간의 선형 관계를 평가하고, 공분산 및 분산 기반 분석을 통해 모델의 성능을 최적

화하는 연구도 진행되고 있다(Chen *et al.*, 2022b; Li *et al.*, 2022c).

Bai *et al.* (2021)은 TOAR 기반 모델이 VCD 기반 모델과 유사한 정확도를 유지하면서도 공간 해상도와 커버리지 측면에서 향상된 결과를 제공함을 보고하였으며, Yin *et al.* (2021)은 TOAR를 활용하면 밝은 표면과 같이 AOD 산출이 어려운 지역에서도 PM_{2.5} 추정의 시공간적 연속성을 개선할 수 있음을 강조하였다. Li *et al.* (2022c)는 기존 5 km 해상도의 오존 VCD를 활용한 경우와 비교하여 Landsat-8의 TOAR을 사용하면 300 m 해상도로 오존 지상농도를 추정할 수 있음을 확인하였다. 더불어, Choi *et al.* (2023)은 GOCI-II AOD 기반 PM_{2.5} 추정 모델 대비 GOCI-II TOAR 기반 모델이 최대 두 배 높은 공간 커버리지를 제공할 수 있음을 보고하였다. 이러한 연구들은 TOAR 기반 접근법이 기존 VCD 기반 방법보다 더 높은 공간 해상도와 시공간적 연속성을 제공할 수 있음을 시사한다.

그러나, TOAR 기반 접근법에도 몇 가지 한계가 존재한다. 머신러닝 모델의 블랙박스 특성으로 인해 결과 해석이 어렵고, 대기오염물질의 생성·수송·제거와 같은 물리적 과정이 충분히 반영되지 않기 때문에 단독으로 활용하는 데에는 한계가 있다(Mao *et al.*, 2021). 향후 연구에서는 이러한 한계를 보완하기 위해 PINN과 같은 기법을 도입하여 물리 모델과 머신러닝을 결합한 고도화된 지상 대기오염물질 농도 추정 모델을 구축할 필요가 있다. 또한, 모델의 신뢰성과 해석 가능성을 향상시키기 위해 XAI 기법을 적용하는 연구가 더욱 확대될 것으로 기대된다.

3.3 결측 보안을 통한 전천 지상농도 추정

위성 VCD 및 TOAR 활용 대기오염물질 지상농도 산출 결과는 지상 관측소 대비 넓은 공간적 커버리지를 제공하며, 대기화학수송모델(CTM; Chemical Transport Model)보다 높은 공간 해상도를 갖는다는 장점이 있다. 그러나 구름, 밝은 지표면 등의 영향으로 다수의 결측 값을 포함하고 있어 공간적으로 연속




적인 모니터링에 한계가 있다 (Tang *et al.*, 2024; Zhang *et al.*, 2024; Kang *et al.*, 2023). 이러한 한계를 극복하고 전천 (all-sky)에서 공간적으로 연속적인 지상농도를 추정하기 위해, 결측 보완 기법을 활용한 세 가지 주요 접근법 또한 제안되고 있다. 이러한 접근법은 첫째, 위성 산출물의 결측을 보완한 후 지상농도를 추정하는 방식 (Tang *et al.*, 2024; Milà *et al.*, 2023; Wei *et al.*, 2023a), 둘째, 딥러닝을 활용하여 결측 값을 직접 보완하는 방식 (Lee and Kim, 2024; Li *et al.*, 2023b; He *et al.*, 2022; Zhang *et al.*, 2022a), 셋째, 위성 산출물의 유무에 따라 각각 독립적으로 산출된 지상농도를 결합하는 방식 (Kim *et al.*, 2025; Li and Cheng, 2021)이며, 그림 5a-c는 각 접근법의 개념적 모식도를 제시한다.

다수의 전천 지상농도 추정을 위한 연구에서는 먼저 위성 산출물의 결측을 보완한 후, 이를 이용하여 지상농도를 산출하는 방식이 적용되어 왔다 (Pruthi *et al.*, 2024; Tang *et al.*, 2024; Zaman *et al.*, 2024; Milà *et al.*, 2023; Mu *et al.*, 2023; Wei *et al.*, 2023a, 2022b; Lei *et al.*, 2022). 이러한 접근법은 크게 두 단계로 구성된다 (그림 5a). 첫번째 단계 (Step 1)에서는 위성 VCD 산출물의 결측 값을 복원한다. 이를 위해 CTM 산출물로 결측 값을 단순 대체하는 방법 (Lei *et al.*, 2022), 다중 위성 데이터 융합 (Zaman *et al.*, 2024), 크리깅 (kriging)과 같은 통계 기법 (Mu *et al.*, 2023) 등이 활용된다. 최근에는 변수 간 비선형성을 고려한 보다 정교한 복원 기법이 적용되고 있으며, 특히 결측이 없는 위성 산출물 영역이나 지상 관측소 데이터를 타겟 변수로 설정한 기계학습 모델이 주로 사용된다 (Pruthi *et al.*, 2024; Tang *et al.*, 2024; Milà *et al.*, 2023; Wei *et al.*, 2023b, 2022b). 두번째 단계 (Step 2)에서는 결측 보완된 위성 산출물을 포함한 기상자료, 배출량, 지형 변수 등을 입력 변수로 활용하고, 지상 관측소 데이터를 타겟 변수로 설정하여 공간적으로 연속적인 대기오염물질 지상농도를 산출한다. 그러나 이 방식은 위성의 다양한 VCD 산출물을 활용할 경우 연산 비용이 증가하여 시간적 효율성이 저하될

가능성이 있으며, 결측 보완된 영역에서는 모델의 예측 오차 및 불확도가 증가할 위험이 있다.

이후 합성곱 신경망 (CNN; Convolutional Neural Network) 기반 딥러닝 기법을 활용하여 위성 자료와 수치 모델 기반 기상 자료를 직접 입력으로 사용해 지상농도를 추정하는 방법이 제안되었으며 (그림 5b), 특히 U-Net과 STNN (Spatiotemporal Neural Network)과 같은 모델이 널리 활용되었다 (Kanngieser and Fiedler, 2024; Li *et al.*, 2023b; He *et al.*, 2022; Zhang *et al.*, 2022a). 이 방법은 딥러닝을 통해 위성 및 수치모델 자료의 공간적 패턴을 학습하여 별도의 결측 보완 없이 지상농도를 추정할 수 있다는 장점이 있다. 그러나, 위성 산출물의 결측 지역에서는 수치 모델 기반 기상 자료와 CTM 산출물에 의존해야 하므로 해상도 및 예측 성능이 저하될 가능성이 있다.

마지막으로, 위성 기반 VCD 산출물의 포함 여부에 따라 개별적으로 AI 기반 지상농도 추정 모델을 개발한 후, 두 모델의 예측 결과를 결합하는 방식이 적용되고 있다 (그림 5c) (Kim *et al.*, 2025; Li and Cheng, 2021). 이 방법에서는 위성 VCD를 포함한 모델 (Model 1)에서 결측이 발생한 영역을 위성 VCD를 제외한 모델 (Model 2)의 예측 값으로 보완한다. 또한, Model 2는 CTM 자료, 기상 자료, 토지 피복, 정규 식생지수 등을 입력 변수로 활용하여, 결측 지역에서 CTM 및 수치 모델 기반 기상 자료에 대한 의존도를 줄이고 최종 산출물의 공간 해상도를 개선시킬 수 있었다. 두 모델의 결합 과정에서는 포아송 혹은 가우시안 필터를 적용하는 방식이 제안되었으나 (Li and Cheng, 2021), 위성 VCD 산출물의 포함 여부에 따라 예측 값의 공간 해상도 차이가 발생할 가능성이 있으며, 이로 인해 결합 과정에서 불연속성이 나타날 수 있다. 따라서, 향후 연구에서는 딥러닝 기반 이미지 융합 기법을 적용하여 결합 과정에서 발생하는 경계 영역의 불연속을 최소화할 필요가 있다. 이를 통해 공간적으로 연속적인 위성 기반 지상농도를 산출하고, 위성 데이터를 활용한 대기오염물질 모니터링의 신뢰도를 더욱 향상시킬 것으로 기대된다.

(a) Method 1: Usage of imputed VCD products**(b) Method 2: Usage of image-based deep learning algorithms****(c) Method 3: Combination of two models (with and w/o satellites)****Fig. 5.** Conceptual diagrams of three major approaches for gap-filling in satellite-based ground-level air pollution monitoring.

4. 한계점 및 나아갈 방향

최근 인공지능을 활용한 위성 기반 대기질 모니터링 연구가 활발히 진행되면서, 높은 시·공간적 해상도의 대기오염 정보를 제공하는 데 기여하고 있다. 그러나 이러한 발전에도 불구하고, 몇 가지 한계점이 지속적으로 논의됨을 확인하였다. 본 절에서는 현재 대기질 모니터링의 주요 제약을 분석하고, 향후 보완 및 발전이 필요한 연구 방향성을 논의하고자 한다.

4.1 밤시간 대기질 모니터링 부족

인공지능 기반 위성 대기질 모니터링은 정지궤도 위성의 높은 시간 해상도를 활용해 준실시간 분석을 가능하게 하지만(Lee *et al.*, 2024a; Li *et al.*, 2022b), 대부분의 연구가 주간 데이터에 의존하며 야간 모니터링은 제한적이다. 이는 대부분의 위성 센서가 태양광 반사에 의존하여 야간에는 충분한 에어로졸 및 기체상 대기오염물질 관측 신호를 확보하지 못하기 때문이다. 결과적으로 야간 데이터 결측이 빈번하게 발생하며, 이에 기반한 AI 모델의 추정 정확도 역시 낮아진다(Kanngießner and Fiedler, 2024; Wang *et al.*, 2022). 그러나 밤시간 대기오염 정보는 온도 역전층으로 인한 오염물질 축적과 질산염 형성 등 야간 화학 반응을 파악하는 데 필수적이며, 도시 오염 패턴과 대기질 관리의 연속성을 평가하는 데 중요한 역할을 한다.

이에 따라 최근 밤시간 대기질 모니터링을 보완하기 위한 다양한 접근법이 연구되고 있다. Mi *et al.* (2024)는 데이터 보강(data augmentation)을 통해 주간 AOD와 기상 변수에 노이즈를 추가해 합성 데이터를 생성하여 야간 조건을 모사함으로써 야간 $PM_{2.5}$ 농도를 간접적으로 추정하였다. Kim *et al.* (2025)는 대기오염물질 형성 요인과 높은 상관성을 갖는 위성 산출물을 활용하여 야간 농도를 추정해 24시간 연속적인 O_3 지상농도를 산출하였다. 그러나 이러한 시도에도 불구하고 야간 대기질 추정의 정확도는 여전히 낮으며, 낮 시간대 데이터를 중심으로 학습된 모델은

야간 환경에서의 일반화 성능이 제한되는 문제가 지속적으로 제기되고 있다(Liu *et al.*, 2022). 따라서 향후 연구에서는 야간 관측이 가능한 센서를 활용한 연구뿐만 아니라, AI 기반 대기질 추정 모델이 주야간 변화를 반영할 수 있도록 시공간적 데이터 융합 기법을 적용하는 전략이 요구된다. 이를 통해 주간에 집중된 위성 기반 대기질 모니터링의 한계를 극복하고, 보다 연속적인 대기질 분석이 가능할 것으로 기대된다.

4.2 불확실성 정보 제공

인공지능을 활용한 위성 기반 대기질 모니터링은 다양한 기상 및 환경 변수를 융합하여 높은 정확도를 달성하고 있다. 그러나 대부분의 연구는 모델 성능 개선에 집중하며, 추정 값의 불확실성(uncertainty)을 정량적으로 제시하는 경우는 제한적이다. 하지만 관측 오차, 결측 자료, 모델 구조적 한계 등 다양한 요인이 결과값에 영향을 미칠 수 있으므로, 추정 값의 신뢰도를 평가하고 활용성을 제고하기 위해 불확실성 정보를 제공하는 것이 필수적이다. 이에 따라, 최근 AI 기반 환경 연구에서는 베이지안 신경망, EDL(Evidential Deep Learning), CP(Conformal Prediction) 등을 활용하여 불확실성을 정량화하는 접근이 시도되고 있다.

Nguyen *et al.* (2023)은 베이지안 LSTM 신경망을 활용하여 $PM_{2.5}$ 및 O_3 농도를 예측하고, 신경망의 가중치를 확률적 변수로 처리함으로써 단일 예측 값이 아닌 확률 분포 형태의 결과를 생성하는 방법을 제안하였다. Schreck *et al.* (2024)은 EDL을 적용하여 모델의 최종 출력층에서 확률 분포를 학습하도록 설계하여 단일 신경망을 통해 예측 값과 불확실성을 동시에 출력할 수 있도록 하였다. 이러한 접근은 환경 데이터 기반 예측 모델의 신뢰도를 향상시키는 데 기여할 수 있다. 한편, Kakhani *et al.* (2024)는 CP를 활용하여 원격탐사 자료 기반 토양 유기 탄소 추정의 불확실성을 정량화하고, 모델 추정 값과 실제 값 간의 오차 분포를 기반으로 통계적 신뢰 구간을 설정하는 방법을

제시하였다. 이러한 연구들은 AI 기반 환경 모니터링에서 불확실성 정량화의 필요성을 강조하며, 대기질 모니터링에도 적용될 수 있음을 시사한다. 특히 신뢰 구간을 제공함으로써 모델의 오차 범위를 명확히 파악할 수 있으며, 이를 통해 정책 결정에 신뢰할 수 있는 과학적 근거를 제시할 수 있다. 따라서 향후 연구에서는 이러한 기법을 통합한 불확실성 정량화 체계를 구축함으로써, 위성 기반 대기질 모니터링의 신뢰성을 향상시킬 수 있을 것으로 기대된다.

4.3 다중 물질들 간의 상호작용 고려

기존 연구들은 주로 단일 대기오염물질을 대상으로 한 싱글 타겟(single-target) 모델을 구축하여 특정 오염물질의 농도를 정밀하게 모니터링하는 데 초점을 맞추어 왔다. 그러나 실제 대기환경에서는 여러 오염물질이 동일한 배출원과 기상 조건을 공유하며, 특히 2차 오염물질 형성과정에서는 복잡하고 비선형적인 화학적·물리적 상호작용이 빈번하게 발생한다. 이러한 특성으로 인해 단일 물질 중심의 모델링만으로는 오염물질 간 상관관계를 충분히 반영하기 어렵다는 한계가 지적되어 왔다(Milà *et al.*, 2023; Yan *et al.*, 2023).

이를 극복하기 위해 최근 연구에서는 여러 대기오염물질을 동시에 추정하는 멀티 타겟(multi-target) 모델링 접근법이 제안되고 있으며, 이는 물질 간 복합적 상호작용을 보다 체계적으로 반영하여 전반적인 예측 성능을 향상시킬 수 있는 것으로 보고되고 있다(Kim *et al.*, 2024; Yang *et al.*, 2023a; Zhu *et al.*, 2023). 특히, 물리 기반 정보를 결합한 PINN과 같은 기법이 도입되면서(Hu *et al.*, 2024; Li *et al.*, 2023a; Yang *et al.*, 2023b; Mao *et al.*, 2021), 다중 대기오염물질 간의 물리법칙과 현상에 대한 사전 지식을 모델 구조에 융합함으로써 예측력과 해석력을 동시에 강화할 수 있음을 시사하였다. 향후 연구에서는 다중 물질 간의 상호작용을 종합적으로 반영하는 멀티 타겟 모델링과 물리 기반 정보를 결합하여 보다 신뢰도 높은 대기질 모니터링 체계를 구축하는 것이 중요한

방향성이 될 것이다.

4.4 AI 활용 위성 기반 대기질 예측

기존 AI 기반 위성 기반 대기질 연구는 주로 대기 오염물질의 공간적 분포 추정에 초점을 맞추었으나, 최근에는 위성 자료와 AI를 결합하여 미래 대기질을 예측하는 방향으로 확장되고 있다. 대기오염은 기상 변화와 대기 화학 반응에 의해 시공간적으로 변동하기 때문에, 이를 정확하게 예측하는 것은 정책 수립 및 공공 건강 보호를 위해 필수적이다. Zhang *et al.* (2025)는 GEMS 위성 자료를 활용하여 ConvLSTM (Convolutional LSTM) 모델을 적용함으로써, NO₂의 24시간 뒤까지 네 시간 간격의 지상 농도를 예측하였다. Panicker and Valarmathi (2024)는 MODIS AOD 자료를 기반으로 SARIMA (Seasonal Autoregressive Integrated Moving Average)와 SVR (Support Vector Regression)을 결합하고, PSO (Particle Swarm Optimization) 기법을 활용하여 최적화된 모델을 개발하였다. 이를 통해 인도 북부 지역의 장·단기 AOD 변동성을 성공적으로 예측하였으며, 통계적 시계열 분석과 AI 융합을 통한 예측 정확도 향상 가능성을 입증하였다. Xia *et al.* (2024)는 베이징 및 톈진 지역에서 다중 관측소의 시계열 데이터와 원격탐사 이미지를 결합한 멀티 모달(multi-modal) 딥러닝 기법을 적용하여 PM_{2.5} 농도를 예측하며, 공간적 패턴과 시간적 변화를 종합적으로 반영하는 접근법의 유효성을 검증하였다.

향후 연구에서는 이러한 다중 데이터 융합 접근법을 확장하여 GEMS, TROPOMI, MODIS 등의 다양한 위성 센서에서 획득한 다중 스펙트럼 및 다중 시계열 데이터를 결합하고, 트랜스포머(Transformer) 및 그래프 신경망(Graph Neural Network)과 같은 최신 AI 기법을 적용할 수 있을 것이다. 또한, 기상 및 대기 화학 모델과의 결합을 통해 AI 기반 예측의 물리적 해석 가능성을 강화하고, 단기 예측을 넘어 중·장기 대기질 변화까지 예측할 수 있는 방향으로 발전해야 한다. 이러한 접근은 대기질 개선 정책 수립 및 대기오

염 저감 전략 마련을 위한 과학적 근거를 더욱 강화할 것으로 기대된다.

5. 결 론

본 논문에서는 인공지능(AI)을 활용한 위성 대기질 모니터링 연구의 최신 동향을 분석하고, 주요 연구 주제 및 향후 연구 방향을 논의하였다. 2015년부터 2025년까지 최근 10년간 출판된 영문 및 국문 논문 총 204편을 검토하고, 활용된 위성 센서, 연구 지역, 대상 대기오염물질별 연구 동향을 체계적으로 분석하였다. 분석 결과, AI 기반 위성 대기질 연구가 지상농도 추정의 정확도를 높이고 대기오염 감시의 공간적 연속성을 강화하는 데 기여함을 확인하였다. 향후 연구에서는 낮 시간 위주로 이루어진 대기질 모니터링을 야간까지 확장하여 보다 연속적인 감시 체계를 구축하고, AI 모델의 불확실성을 정량화하여 제시함으로써 신뢰도를 향상시킬 필요가 있다. 또한, 다중 대기오염물질 간의 상호작용을 반영하고 위성 데이터와 AI 기반 기법을 결합한 대기질 예측 연구로 확장한다면, 대기오염 변화에 대한 보다 정밀한 분석과 실시간 감시가 가능해질 것이다. 이러한 연구가 지속적으로 이루어진다면, AI 기반 위성 대기질 모니터링은 실시간 감시 및 정책적 의사결정의 핵심 도구로 기능할 것으로 기대된다.

감사의 글

본 논문은 환경부의 재원으로 국립환경과학원(NIER-2025-01-02-055)과 한국환경산업기술원의 환경보건디지털 조사기반 구축기술개발사업(2021003330001 (NTIS: 1485019478))의 지원을 받아 수행하였습니다. 최현영은 2024년도 정부(교육부)의 재원으로 부분적으로 한국연구재단의 지원을 받았습니다(No. RS-2024-00408922).

References

- Abu El-Magd, S., Soliman, G., Morsy, M., Kharbush, S. (2023) Environmental hazard assessment and monitoring for air pollution using machine learning and remote sensing, *International Journal of Environmental Science and Technology*, 20(6), 6103-6116. <https://doi.org/10.1007/s13762-022-04367-6>
- Aguilera, R., Luo, N., Basu, R., Wu, J., Clemesha, R., Gershunov, A., Benmarhnia, T. (2023) A novel ensemble-based statistical approach to estimate daily wildfire-specific PM_{2.5} in California (2006-2020), *Environment International*, 171, Article 107719. <https://doi.org/10.1016/j.envint.2022.107719>
- Ayus, I., Natarajan, N., Gupta, D. (2023) Comparison of machine learning and deep learning techniques for the prediction of air pollution: a case study from China, *Asian Journal of Atmospheric Environment*, 17(1), 4.
- Bai, H., Zheng, Z., Zhang, Y., Huang, H., Wang, L. (2021). Comparison of satellite-based PM_{2.5} estimation from aerosol optical depth and top-of-atmosphere reflectance, *Aerosol and Air Quality Research*, 21(2), 200257.
- Burrows, J., Hölzle, E., Goede, A., Visser, H., Fricke, W. (1995) SCIAMACHY-Scanning imaging absorption spectrometer for atmospheric cartography, *Acta Astronautica*, 35(7), 445-451.
- Calvin, K., Dasgupta, D., Krinner, G., Mukherji, A., Thorne, P.W., Trisos, C., Romero, J., Aldunce, P., Barrett, K., Blanco, G. (2023) IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland (No Title).
- Chen, B., Song, Z., Shi, B., Li, M. (2022a) An interpretable deep forest model for estimating hourly PM₁₀ concentration in China using Himawari-8 data, *Atmospheric Environment*, 268, 118827.
- Chen, C.C., Wang, Y.R., Wang, F.C., Shiu, Y.S., Wu, C.F., Lin, T.H. (2024) Estimating monthly NO₂, O₃, and SO₂ concentrations via an ensemble three-stage procedure with downscaled satellite remote sensing data and ground measurements, *Journal of Hazardous Materials*, 480, Article 136392. <https://doi.org/10.1016/j.jhazmat.2024.136392>
- Chen, R., Hu, J., Song, Z., Wang, Y., Zhou, X., Zhao, L., Chen, B. (2023) The Spatiotemporal Distribution of NO₂ in

- China Based on Refined 2DCNN-LSTM Model Retrieval and Factor Interpretability Analysis, *Remote Sensing*, 15(17), Article 4261. <https://doi.org/10.3390/rs15174261>
- Chen, Y., Fan, M., Li, M., Li, Z., Tao, J., Wang, Z., Chen, L. (2022b) Himawari-8/AHI Aerosol Optical Depth Detection Based on Machine Learning Algorithm, *Remote Sensing*, 14(13), Article 2967. <https://doi.org/10.3390/rs14132967>
- Chi, Y., Wu, Z., Liao, K., Ren, Y. (2020) Handling missing data in large-scale MODIS AOD products using a two-step model, *Remote Sensing*, 12(22), 3786.
- Choi, H., Kang, Y., Im, J. (2021) Estimation of TROPOMI-derived ground-level SO₂ concentrations using machine learning over East Asia, *Korean Journal of Remote Sensing*, 37(2), 275-290.
- Choi, H., Park, S., Kang, Y., Im, J., Song, S. (2023). Retrieval of hourly PM_{2.5} using top-of-atmosphere reflectance from geostationary ocean color imagers I and II, *Environmental Pollution*, 323, Article 121169. <https://doi.org/10.1016/j.envpol.2023.121169>
- Gupta, P., Christopher, S.A. (2009) Particulate matter air quality assessment using integrated surface, satellite, and meteorological products: Multiple regression approach, *Journal of Geophysical Research: Atmospheres*, 114(D14).
- He, T.L., Jones, D.B.A., Miyazaki, K., Bowman, K.W., Jiang, Z., Chen, X., Li, R., Zhang, Y., Li, K. (2022) Inverse modeling of Chinese Nox emissions using deep learning: integrating in situ observations with a satellite-based chemical reanalysis, *Atmospheric Chemistry and Physics*, 22(21), 14059-14074. <https://doi.org/10.5194/acp-22-14059-2022>
- Herman, J., Bhartia, P., Torres, O., Hsu, C., Seftor, C., Celarier, E. (1997) Global distribution of UV-absorbing aerosols from Nimbus 7/TOMS data, *Journal of Geophysical Research: Atmospheres*, 102(D14), 16911-16922.
- Holloway, T., Miller, D., Anenberg, S., Diao, M., Duncan, B., Fiore, A.M., Henze, D.K., Hess, J., Kinney, P.L., Liu, Y. (2021) Satellite monitoring for air quality and health, *Annual Review of Biomedical Data Science*, 4(1), 417-447.
- Hu, M., Bai, K., Li, K., Zheng, Z., Sun, Y., Shao, L., Li, R., Liu, C. (2024) Improving machine-learned surface NO₂ concentration mapping models with domain knowledge from data science perspective, *Atmospheric Environment*, 322, 120372.
- Huang, C., Hu, J., Xue, T., Xu, H., Wang, M. (2021) High-Resolution Spatiotemporal Modeling for Ambient PM_{2.5} Exposure Assessment in China from 2013 to 2019, *Environmental Science and Technology*, 55(3), 2152-2162. <https://doi.org/10.1021/acs.est.0c05815>
- Janiesch, C., Zschech, P., Heinrich, K. (2021) Machine learning and deep learning, *Electronic Markets*, 31(3), 685-695.
- Joy, K.S., Zaman, S.U., Pavel, M.R.S., Islam, M.S., Salam, A. (2024) Spatio-temporal variation of aerosol optical depth and black carbon mass concentration over five airports across Bangladesh: emphasis on effect of COVID-19 lockdown, *Asian Journal of Atmospheric Environment*, 18(1), 15.
- Jung, C.H., Kim, Y.P. (2024) Current Status of Air Quality and Greenhouse Gas Monitoring Networks: Case Studies from Various Countries and Implications for South Korea, *Journal of Korean Society for Atmospheric Environment*, 40(6), 704-732.
- Just, A.C., Arfer, K.B., Rush, J., Lyapustin, A., Kloog, I. (2025) XIS-PM_{2.5}: A daily spatiotemporal machine-learning model for PM_{2.5} in the contiguous United States, *Environmental Research*, 271, Article 120948. <https://doi.org/10.1016/j.envres.2025.120948>
- Kakhani, N., Alamdar, S., Kebonye, N.M., Amani, M., Scholten, T. (2024) Uncertainty quantification of soil organic carbon estimation from remote sensing data with conformal prediction, *Remote Sensing*, 16(3), 438.
- Kakouri, A., Kontos, T., Grivas, G., Filippis, G., Korras-Carraca, M.-B., Matsoukas, C., Gkikas, A., Athanasopoulou, E., Speyer, O., Chatzidiakos, C. (2025) Spatiotemporal modeling of long-term PM_{2.5} concentrations and population exposure in Greece, using machine learning and statistical methods, *Science of the Total Environment*, 958, 178113.
- Kang, E., Park, S., Kim, M., Yoo, C., Im, J., Song, C.K. (2023) Direct aerosol optical depth retrievals using MODIS reflectance data and machine learning over East Asia, *Atmospheric Environment*, 309, Article 119951. <https://doi.org/10.1016/j.atmosenv.2023.119951>
- Kang, Y., Choi, H., Im, J., Park, S., Shin, M., Song, C.-K., Kim, S. (2021) Estimation of surface-level NO₂ and O₃ concentrations using TROPOMI data and machine learning over East Asia, *Environmental Pollution*, 288, 117711.
- Kanngießer, F., Fiedler, S. (2024) "Seeing" Beneath the Clouds—Machine-Learning-Based Reconstruction of North African Dust Plumes, *AGU Advances*, 5(1), Article e2023AV001042. <https://doi.org/10.1029/2023AV001042>
- Kim, H., Son, J.-Y., Junger, W., Bell, M.L. (2024) Exposure to particulate matter and ozone, locations of regulatory

- monitors, and sociodemographic disparities in the city of Rio de Janeiro: Based on local air pollution estimates generated from machine learning models, *Atmospheric Environment*, 322, 120374.
- Kim, Y., Park, S., Choi, H., Im, J. (2025) Comprehensive 24-hour ground-level ozone monitoring: Leveraging machine learning for full-coverage estimation in East Asia, *Journal of Hazardous Materials*, 488, Article 137369. <https://doi.org/10.1016/j.jhazmat.2025.137369>
- Kloog, I., Koutrakis, P., Coull, B.A., Lee, H.J., Schwartz, J. (2011) Assessing temporally and spatially resolved PM_{2.5} exposures for epidemiological studies using satellite aerosol optical depth measurements, *Atmospheric Environment*, 45(35), 6267-6275.
- Lee, A., Jeong, S., Joo, J., Park, C.R., Kim, J., Kim, S. (2021) Potential role of urban forest in removing PM_{2.5}: A case study in Seoul by deep learning with satellite data, *Urban Climate*, 36, Article 100795. <https://doi.org/10.1016/j.uclim.2021.100795>
- Lee, J., Cho, Y., Lee, S., Kim, J., Park, Y.J. (2024a) Near-real-time hourly PM_{2.5} prediction over East Asia using geostationary satellite products and machine learning, *Atmospheric Environment*, 334, Article 120700. <https://doi.org/10.1016/j.atmosenv.2024.120700>
- Lee, K.H., Kim, K. (2024) Monitoring and Forecasting XCO₂ Using OCO-2 Satellite Data and Deep Learning, *Journal of Korean Society for Atmospheric Environment*, 40(5), 572-584.
- Lee, K.-H., Pyo, S.-H., Wong, M.S. (2024b) Spatiotemporal aerosol prediction model based on fusion of machine learning and spatial analysis, *Asian Journal of Atmospheric Environment*, 18(1), 9.
- Lei, C., Xu, X., Ma, Y., Jin, S., Liu, B., Gong, W. (2022) Full Coverage Estimation of the PM Concentration Across China Based on an Adaptive Spatiotemporal Approach, *IEEE Transactions on Geoscience and Remote Sensing*, 60, Article 5412314. <https://doi.org/10.1109/TGRS.2022.3213797>
- Li, B., Hu, Q., Gao, M., Liu, T., Zhang, C., Liu, C. (2023a) Physical informed neural network improving the WRF-CHEM results of air pollution using satellite-based remote sensing data, *Atmospheric Environment*, 311, Article 120031. <https://doi.org/10.1016/j.atmosenv.2023.120031>
- Li, B., Liu, C., Hu, Q., Sun, M., Zhang, C., Zhu, Y., Liu, T., Guo, Y., Carmichael, G.R., Gao, M. (2023b) A Deep Learning Approach to Increase the Value of Satellite Data for PM_{2.5} Monitoring in China, *Remote Sensing*, 15(15), 3724.
- Li, C., Joiner, J., Liu, F., Krotkov, N.A., Fioletov, V., McLinden, C. (2022a) A new machine-learning-based analysis for improving satellite-retrieved atmospheric composition data: OMI SO₂ as an example, *Atmospheric Measurement Techniques*, 15(18), 5497-5514.
- Li, J., Wong, M.S., Lee, K.H., Nichol, J.E., Abbas, S., Li, H., Wang, J. (2022b) A physical knowledge-based machine learning method for near-real-time dust aerosol properties retrieval from the Himawari-8 satellite data, *Atmospheric Environment*, 280, 119098.
- Li, M., Yang, Q., Yuan, Q., Zhu, L. (2022c) Estimation of high spatial resolution ground-level ozone concentrations based on Landsat 8 TIR bands with deep forest model, *Chemosphere*, 301, Article 134817. <https://doi.org/10.1016/j.chemosphere.2022.134817>
- Li, T., Cheng, X. (2021) Estimating daily full-coverage surface ozone concentration using satellite observations and a spatiotemporally embedded deep learning approach, *International Journal of Applied Earth Observation and Geoinformation*, 101, 102356.
- Linardatos, P., Papastefanopoulos, V., Kotsiantis, S. (2020) Explainable ai: A review of machine learning interpretability methods, *Entropy*, 23(1), 18.
- Liu, Y., Li, C., Liu, D., Tang, Y., Seyler, B.C., Zhou, Z., Hu, X., Yang, F., Zhan, Y. (2022) Deriving hourly full-coverage PM_{2.5} concentrations across China's Sichuan Basin by fusing multisource satellite retrievals: A machine-learning approach, *Atmospheric Environment*, 271, 118 930.
- Luo, R., Zhang, M., Ma, G. (2023) Regional Representativeness Analysis of Ground-Monitoring PM_{2.5} Concentration Based on Satellite Remote Sensing Imagery and Machine Learning Techniques, *Remote Sensing*, 15(12), Article 3040. <https://doi.org/10.3390/rs15123040>
- Mao, F., Hong, J., Min, Q., Gong, W., Zang, L., Yin, J. (2021) Estimating hourly full-coverage PM_{2.5} over China based on TOA reflectance data from the Fengyun-4A satellite, *Environmental Pollution*, 270, 116119.
- Mi, T., Tang, D., Fu, J., Zeng, W., Grieneisen, M.L., Zhou, Z., Jia, F., Yang, F., Zhan, Y. (2024) Data augmentation for bias correction in mapping PM_{2.5} based on satellite retrievals and ground observations, *Geoscience Frontiers*, 15(1), 101686.
- Milà, C., Ballester, J., Basagaña, X., Nieuwenhuijsen, M.J., Tonne, C. (2023) Estimating daily air temperature and pollution in Catalonia: A comprehensive spatiotemporal modelling of multiple exposures, *Environmental Pollution*, 337, 122501.

- Mu, X., Wang, S., Jiang, P., Wu, Y. (2023) Estimation of surface ozone concentration over Jiangsu province using a high-performance deep learning model, *Journal of Environmental Sciences (China)*, 132, 122-133. <https://doi.org/10.1016/j.jes.2022.09.032>
- Nguyen, H.A., Ha, Q.P., Duc, H., Azzi, M., Jiang, N., Barthelemy, X., Riley, M. (2023) Long short-term memory Bayesian neural network for air pollution forecast, *IEEE Access*, 11, 35710-35725.
- Ni, Y., Yang, Y., Wang, H., Li, H., Li, M., Wang, P., Li, K., Liao, H. (2024) Contrasting changes in ozone during 2019-2021 between eastern and the other regions of China attributed to anthropogenic emissions and meteorological conditions, *Science of the Total Environment*, 908, Article 168272. <https://doi.org/10.1016/j.scitotenv.2023.168272>
- Panicker, N.K.K., Valarmathi, J. (2024) Time series prediction of aerosol optical depth across the northern Indian region: integrating PSO-optimized SARIMA-SVR based on MODIS data, *Acta Geophysica*, 1-30.
- Park, S.-Y., Lee, H.-W., Kwon, J., Yoon, S.-W., Lee, C.-M. (2024) Proposal of a methodology for prediction of heavy metals concentration based on PM_{2.5} concentration and meteorological variables using machine learning, *Asian Journal of Atmospheric Environment*, 18(1), 7.
- Prunet, P., Lezeaux, O., Camy-Peyret, C., Thevenon, H. (2020) Analysis of the NO₂ tropospheric product from S5P TROPOMI for monitoring pollution at city scale, *City and Environment Interactions*, 8, 100051.
- Pruthi, D., Zhu, Q., Wang, W., Liu, Y. (2024) Multiresolution Analysis of HRRR Meteorological Parameters and GOES-R AOD for Hourly PM_{2.5} Prediction, *Environmental Science and Technology*, 58(45), 20040-20048. <https://doi.org/10.1021/acs.est.4c03795>
- Schreck, J.S., Gagne, D.J., Becker, C., Chapman, W.E., Elmore, K., Fan, D., Gantos, G., Kim, E., Kimpara, D., Martin, T. (2024) Evidential deep learning: Enhancing predictive uncertainty estimation for earth system science applications, *Artificial Intelligence for the Earth Systems*, 3(4), 230093.
- Shetty, S., Schneider, P., Stebel, K., Hamer, P.D., Kylling, A., Bernsten, T.K. (2024) Estimating surface NO₂ concentrations over Europe using Sentinel-5P TROPOMI observations and Machine Learning, *Remote Sensing of Environment*, 312, 114321.
- Shinde, P.P., Shah, S. (2018) A review of machine learning and deep learning applications. 2018 Fourth international conference on computing communication control and automation (ICCUBEA), (pp. 1-6). IEEE.
- Su, J.G., Shahriary, E., Sage, E., Jacobsen, J., Park, K., Mohegh, A. (2024) Development of over 30-years of high spatiotemporal resolution air pollution models and surfaces for California, *Environment International*, 193. <https://doi.org/10.1016/j.envint.2024.109100>
- Tan, Y., Zhang, Y., Wang, T., Chen, T., Mu, J., Xue, L. (2024) Dissecting Drivers of Ozone Pollution during the 2022 Multicity Lockdowns in China Sheds Light on Future Control Direction, *Environmental Science and Technology*, 58(16), 6988-6997. <https://doi.org/10.1021/acs.est.4c01197>
- Tang, B., Stanier, C.O., Carmichael, G.R., Gao, M. (2024) Ozone, nitrogen dioxide, and PM_{2.5} estimation from observation-model machine learning fusion over S. Korea: Influence of observation density, chemical transport model resolution, and geostationary remotely sensed AOD, *Atmospheric Environment*, 331, Article 120603. <https://doi.org/10.1016/j.atmosenv.2024.120603>
- Valappil, N.K.M., Ahmad, F.S., Hamza, V. (2024) Satellite measurement data-based assessment of spatiotemporal characteristics of ultraviolet index (UVI) over the state of Johor, Malaysia, *Asian Journal of Atmospheric Environment*, 18(1), 19.
- Van Damme, M., Clarisse, L., Heald, C.L., Hurtmans, D., Ngadi, Y., Clerbaux, C., Dolman, A., Erisman, J.W., Coheur, P.-F. (2014) Global distributions, time series and error characterization of atmospheric ammonia (NH₃) from IASI satellite observations, *Atmospheric Chemistry and Physics*, 14(6), 2905-2922.
- Wang, Y., Yuan, Q., Zhu, L., Zhang, L. (2022) Spatiotemporal estimation of hourly 2-km ground-level ozone over China based on Himawari-8 using a self-adaptive geospatially local model, *Geoscience Frontiers*, 13(1), 101286.
- Wei, J., Li, Z., Li, K., Dickerson, R.R., Pinker, R.T., Wang, J., Liu, X., Sun, L., Xue, W., Cribb, M. (2022a) Full-coverage mapping and spatiotemporal variations of ground-level ozone (O₃) pollution from 2013 to 2020 across China, *Remote Sensing of Environment*, 270, 112775.
- Wei, J., Li, Z., Lyapustin, A., Wang, J., Dubovik, O., Schwartz, J., Sun, L., Li, C., Liu, S., Zhu, T. (2023a) First close insight into global daily gapless 1 km PM_{2.5} pollution, variability, and health impact, *Nature Communications*, 14(1), Article 8349. <https://doi.org/10.1038/s41467-023-43862-3>
- Wei, J., Li, Z., Wang, J., Li, C., Gupta, P., Cribb, M. (2023b) Ground-level gaseous pollutants (NO₂, SO₂, and CO) in China: daily seamless mapping and spatiotempo-

- ral variations, *Atmospheric Chemistry and Physics*, 23(2), 1511-1532.
- Wei, J., Liu, S., Li, Z., Liu, C., Qin, K., Liu, X., Pinker, R.T., Dickerson, R.R., Lin, J., Boersma, K.F. (2022b) Ground-level NO₂ surveillance from space across China for high resolution using interpretable spatiotemporally weighted artificial intelligence, *Environmental Science & Technology*, 56(14), 9988-9998.
- Wei, X., Chang, N.-B., Bai, K., Gao, W. (2020) Satellite remote sensing of aerosol optical depth: advances, challenges, and perspectives, *Critical Reviews in Environmental Science and Technology*, 50(16), 1640-1725.
- Wong, P.-Y., Lee, H.-Y., Chen, Y.-C., Zeng, Y.-T., Chern, Y.-R., Chen, N.-T., Lung, S.-C.C., Su, H.-J., Wu, C.-D. (2021) Using a land use regression model with machine learning to estimate ground level PM_{2.5}, *Environmental Pollution*, 277, 116846.
- World Health Organization (WHO) (2021) WHO global air quality guidelines: particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. World Health Organization.
- Xia, H., Chen, X., Wang, Z., Chen, X., Dong, F. (2024) A Multi-Modal Deep-Learning Air Quality Prediction Method Based on Multi-Station Time-Series Data and Remote-Sensing Images: Case Study of Beijing and Tianjin, *Entropy*, 26(1).
- Xu, J., Zhang, Z., Rao, L., Wang, Y., Letu, H., Shi, C., Tana, G., Wang, W., Zhu, S., Liu, S. (2024) Remote sensing of tropospheric ozone from space: Progress and challenges, *Journal of Remote Sensing*, 4, 0178.
- Yan, X., Zuo, C., Li, Z., Chen, H.W., Jiang, Y., He, B., Liu, H., Chen, J., Shi, W. (2023) Cooperative simultaneous inversion of satellite-based real-time PM_{2.5} and ozone levels using an improved deep learning model with attention mechanism, *Environmental Pollution*, 327, 121509.
- Yang, Q., Kim, J., Cho, Y., Lee, W.-J., Lee, D.-W., Yuan, Q., Wang, F., Zhou, C., Zhang, X., Xiao, X. (2023a) A synchronized estimation of hourly surface concentrations of six criteria air pollutants with GEMS data, *npj Climate and Atmospheric Science*, 6(1), 94.
- Yang, Q., Yuan, Q., Gao, M., Li, T. (2023b) A new perspective to satellite-based retrieval of ground-level air pollution: Simultaneous estimation of multiple pollutants based on physics-informed multi-task learning, *Science of the Total Environment*, 857, 159542.
- Yang, Z., Li, Z., Cheng, F., Lv, Q., Li, K., Zhang, T., Zhou, Y., Zhao, B., Xue, W., Wei, J. (2025) Two-decade surface ozone (O₃) pollution in China: Enhanced fine-scale estimations and environmental health implications, *Remote Sensing of Environment*, 317, 114459.
- Yin, J., Mao, F., Zang, L., Chen, J., Lu, X., Hong, J. (2021) Retrieving PM_{2.5} with high spatio-temporal coverage by TOA reflectance of Himawari-8, *Atmospheric Pollution Research*, 12(4), 14-20.
- You, W., Zang, Z., Zhang, L., Zhang, M., Pan, X., Li, Y. (2016) A nonlinear model for estimating ground-level PM₁₀ concentration in Xi'an using MODIS aerosol optical depth retrieval, *Atmospheric Research*, 168, 169-179.
- Yu, M., Liu, Q. (2021) Deep learning-based downscaling of tropospheric nitrogen dioxide using ground-level and satellite observations, *Science of the Total Environment*, 773, Article 145145. <https://doi.org/10.1016/j.scitotenv.2021.145145>
- Zaman, N.A.F.K., Kanniah, K.D., Kaskaoutis, D.G., Latif, M.T. (2024) Improving the quantification of fine particulates (PM_{2.5}) concentrations in Malaysia using simplified and computationally efficient models, *Journal of Cleaner Production*, 448, Article 141559. <https://doi.org/10.1016/j.jclepro.2024.141559>
- Zhan, Y., Luo, Y., Deng, X., Chen, H., Grieneisen, M.L., Shen, X., Zhu, L., Zhang, M. (2017) Spatiotemporal prediction of continuous daily PM_{2.5} concentrations across China using a spatially explicit machine learning algorithm, *Atmospheric Environment*, 155, 129-139.
- Zhan, Y., Luo, Y., Deng, X., Zhang, K., Zhang, M., Grieneisen, M. L., Di, B. (2018) Satellite-based estimates of daily NO₂ exposure in China using hybrid random forest and spatiotemporal kriging model, *Environmental Science & Technology*, 52(7), 4180-4189.
- Zhang, C., Liu, C., Li, B., Zhao, F., Zhao, C. (2022a) Spatiotemporal neural network for estimating surface NO₂ concentrations over north China and their human health impact, *Environmental Pollution*, 307, Article 119510. <https://doi.org/10.1016/j.envpol.2022.119510>
- Zhang, C., Niu, X., Wu, H., Ding, Z., Chan, K.L., Kim, J., Wagner, T., Liu, C. (2025) Unleashing the potential of geostationary satellite observations in air quality forecasting through artificial intelligence techniques, *Atmospheric Chemistry and Physics*, 25(2), 759-770.
- Zhang, H., Lin, Y., Wei, S., Loo, B.P., Lai, P., Lam, Y.F., Wan, L., Li, Y. (2021a) Global association between satellite-derived nitrogen dioxide (NO₂) and lockdown policies under the COVID-19 pandemic, *Science of the Total Environment*, 761, 144148.
- Zhang, Q., Liu, X., Peng, T., Yang, X., Tang, M., Zou, X., Liu, M., Wu, L., Zhang, T. (2024) U-SeqNet: learning spatio-

temporal mapping relationships for multimodal multitemporal cloud removal, *GIScience & Remote Sensing*, 61(1), 2330185.

- Zhang, S., Mi, T., Wu, Q., Luo, Y., Grieneisen, M.L., Shi, G., Yang, F., Zhan, Y. (2022b) A data-augmentation approach to deriving long-term surface SO₂ across Northern China: Implications for interpretable machine learning, *Science of the Total Environment*, 827, Article 154278. <https://doi.org/10.1016/j.scitotenv.2022.154278>
- Zhang, T., He, W., Zheng, H., Cui, Y., Song, H., Fu, S. (2021b) Satellite-based ground PM_{2.5} estimation using a gradient boosting decision tree, *Chemosphere*, 268, 128801.
- Zhang, Y., Wu, W., Li, Y., Li, Y. (2023) An investigation of PM_{2.5} concentration changes in Mid-Eastern China before and after COVID-19 outbreak, *Environment international*, 175, 107941.
- Zhu, S., Xu, J., Fan, M., Yu, C., Letu, H., Zeng, Q., Zhu, H., Wang, H., Wang, Y., Shi, J. (2023) Estimating near-surface concentrations of major air pollutants from space: A universal estimation framework LAPSO, *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-11.

Authors Information

최현영 (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (hyong56@unist.ac.kr)

황수민 (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (suminn314@unist.ac.kr)

강은진 (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (jek0420@unist.ac.kr)

김예진 (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (happykimmy@unist.ac.kr)

양세영 (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (syyang1509@unist.ac.kr)

Saman Malik (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (saman@unist.ac.kr)

Jebun Naher Keya (울산과학기술원 지구환경도시건설공학과 석사과정 학생) (jnkeya@unist.ac.kr)

이시현 (울산과학기술원 지구환경도시건설공학과 석박사통합과정 학생) (lsh9034@unist.ac.kr)

임정호 (울산과학기술원 지구환경도시건설공학과 교수) (ersgis@unist.ac.kr)