

논문

MODIS 관측자료 기반 2단계 머신러닝 프레임워크를 이용한 픽셀 분류 및 에어로졸 광학두께 산출

A Generalizable Two-Stage Machine Learning Framework for Pixel Classification and Aerosol Optical Depth Retrieval from MODIS Observations

이권호^{1),2),*}

¹⁾강원대학교 대기환경과학과, ²⁾강원대학교 복사-위성 연구소

Kwon-Ho Lee^{1),2),*}

¹⁾Department of Atmospheric & Environmental Sciences, Kangwon National University, Gangneung, Republic of Korea

²⁾Research Institute for Radiation-Satellite, Kangwon National University, Gangneung, Republic of Korea

접수일 2026년 7월 16일
수정일 2026년 7월 24일
채택일 2026년 7월 29일

Received 16 July 2026
Revised 24 July 2026
Accepted 29 July 2026

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

Abstract Accurate retrieval of aerosol optical depth (AOD) from satellite observations is essential for monitoring regional air quality and aerosol distributions, yet conventional retrieval algorithms remain challenged by complex surface conditions and cloud contamination. This study proposes a two-stage machine learning pipeline for pixel classification and aerosol optical depth (AOD) retrieval from MODIS satellite observations over East Asia (20°~55°N, 110°~145°E). In the first stage, an eXtreme Gradient Boosting (XGBoost) classifier trained with MODIS Level-1B multi-spectral reflectance and geometric features classifies each pixel into six categories: cloud, probable cloud, bright land, bright ocean, clear land, and clear ocean. In the second stage, separate XGBoost regression models for land and ocean retrieve AOD at 550 nm for pixels identified as clear land or clear ocean, using the MODIS Level-2 combined aerosol product as the training reference. The models were trained using 2024 observations and independently validated with 2025 data to evaluate their temporal generalizability. The pixel classification model achieved an overall accuracy of 91.69% with a Cohen's κ coefficient of 0.76. The AOD retrieval models showed excellent performance on the 2024 test dataset, yielding R^2 values of 0.983 (RMSE = 0.051, %EE = 95.6%) over land and 0.987 (RMSE = 0.019, %EE = 99.6%) over ocean. Independent validation using 2025 observations further demonstrated robust model generalization, with an R^2 of 0.951, RMSE of 0.039, and %EE of 96.1% over land. Spatial comparisons indicate that the proposed framework successfully reproduces the major AOD distribution patterns across East Asia, including high-aerosol regions over the Asian continent and low-AOD conditions over adjacent oceans. Case studies further demonstrate reliable AOD retrieval under clean atmospheric conditions (%EE = 95.3%), whereas underestimation of extremely high AOD values associated with severe dust events ($AOD > 1.5$) remains a challenge. Overall, the proposed framework provides an accurate and computationally efficient approach for satellite-based AOD retrieval and demonstrates strong potential for next-generation AI-assisted aerosol remote sensing applications.

Key words: Satellite, MODIS, Aerosol, XGBoost, Machine learning

1. 서론

대기 에어로졸은 화학적 조성과 크기 분포에 따라

태양 복사를 산란, 흡수하는 직접 효과와 구름 응결핵으로 작용하여 구름의 미세물리적 특성을 변화시키는 간접 효과를 통해 지구 복사 수지에 복합적인 영향을

미친다. 에어로졸의 유효 복사 강제력 추정값은 약 -0.9 W/m^2 정도로 알려져 있으나, 오차 범위가 $-1.9 \sim 0.1 \text{ W/m}^2$ 로 큰 범위로 보고되었다(Boucher *et al.*, 2013). 그리고 에어로졸과 구름의 상호작용에 의한 복사 강제력 불확실성은 기후변화 예측에서 가장 큰 제한 요인이다(IPCC, 2021). 따라서 에어로졸의 정확한 시공간 분포 파악은 기후 모델 정확도 제고와 대기질 예보 개선 모두에 있어 핵심 요소이다.

에어로졸의 물리량 중 에어로졸 광학두께(Aerosol Optical Depth, AOD)는 대기 연직 방향의 에어로졸에 의한 소산(extinction)을 적분한 무차원의 지표값으로서, 에어로졸의 총량과 공간 분포를 파악하는 데 널리 활용된다. AOD 측정 수단으로서 지상에서 태양 광도계를 이용하여 정밀하게 관측할 수 있으나, 관측소의 지리적 위치와 청천(clear sky) 조건 확보에 따라 데이터 공백이 크다는 한계가 있다(Holben *et al.*, 1998). 이러한 관측 한계를 극복하기 위해 인공위성 기반의 전 지구 AOD 산출 연구가 수십 년에 걸쳐 진행되었다(Lee and Bae, 2023; Lee *et al.*, 2022; Lee, 2012; Kaufman *et al.*, 2002). 대표적인 지구 관측 인공위성인 Terra와 Aqua 위성에 탑재된 Moderate Resolution Imaging Spectroradiometer (MODIS) 센서는 36개 분광 채널을 통해 약 2,330 km의 관측 폭으로 전 지구를 관측하므로 에어로졸 연구의 핵심 플랫폼으로 사용되었다(King *et al.*, 2003; Salomonson *et al.*, 1989).

MODIS Level-2 (L2) 에어로졸 데이터(코드명 MOD 04/MYD04)에 사용된 AOD 산출 알고리즘은 목적과 적용 지역에 따라 크게 세 계열로 구분된다. Dark Target (DT) 알고리즘은 가시광 채널에서 반사도가 낮은 식생 및 습윤 지표면을 대상으로 지표 반사도와 에어로졸 특성을 분리 추정하는 방식을 사용한다(Levy *et al.*, 2013; Kaufman *et al.*, 1997). 한편 단파 가시광 채널에서 상대적으로 높은 에어로졸 민감도를 이용하는 Deep Blue (DB) 알고리즘은 DT가 적용되지 못하는 사막이나 도시와 같은 지표 반사도가 높은 지역까지 산출 범위를 확장하였다(Hsu *et al.*, 2013, 2004). 그리고 시계열 다중 관측 기하를 활용하여 지표 반사도와

AOD를 동시 추정하는 Multi-Angle Implementation of Atmospheric Correction (MAIAC) 알고리즘은 도심과 같이 반사 특성이 복잡한 지역에서 특히 향상된 성능을 나타내는 것으로 평가된다(Lyapustin *et al.*, 2012, 2011). 그러나 이러한 물리 기반의 AOD 산출 알고리즘은 공통적으로 복사전달 방정식과 에어로졸 광학 모델에 크게 의존하기 때문에, 실제 대기 조건에서의 에어로졸 크기 분포나 굴절률이 가정된 조건값과 다를 경우 산출 편향이 발생하며 계산 비용 또한 상당히 발생한다. 또한 각 알고리즘별로 산출 가능한 환경 조건으로 인하여 구름이나 밝은 지표가 분포하는 지역의 오차가 발생한다(Várnai and Marshak, 2009). 구름과 밝은 지표면의 정확한 식별 능력은 물리 기반 AOD 산출 알고리즘의 적용 범위와 정확도를 함께 결정하는 요인으로 작용한다.

최근 AI 기반 위성 데이터 해석 및 분석 기법의 시도가 증가함에 따라, 다양한 AOD 산출 방법론이 제시되고 있다. 예를 들면, 랜덤 포레스트(Random Forest)를 이용하여 MODIS 다중 채널 반사도로부터 AOD를 추정하는 연구(Chen *et al.*, 2021; Hu *et al.*, 2020)와 심층 신경망(Deep Neural Network, DNN)을 적용하여 기존 물리 알고리즘 대비 산출 범위를 확장한 사례(Li *et al.*, 2023; Wei *et al.*, 2019)가 보고되었다. 최근에는 높은 예측 성능과 계산 효율을 동시에 제공하는 Gradient Boosting 기반 알고리즘(XGBoost, LightGBM 등)이 위성 원격탐사 분야에서 활발히 적용되고 있다. 그러나 이들 연구는 공통적으로 두 가지 한계를 내포한다. 첫째, 화소 단위의 구름 및 지표 유형 분류 과정을 AOD 산출과 독립적으로 처리하거나 사전 정의된 규칙 기반 마스크에 의존함으로써, 분류 오류가 이후 AOD 산출 단계로 전파되는 구조적 취약성이 존재한다. 둘째, 입력 변수의 범위를 일부 가시광 채널이나 이미 처리된 L2 산출물에 한정하는 경우가 많아 원시 복사량이 제공하는 분광 정보를 충분히 활용하지 못하고 있다. 이처럼 화소 분류와 AOD 산출을 데이터 기반으로 통합하는 순차적 AI 파이프라인의 적용 사례는 매우 제한적이다.

따라서, 본 연구에서는 인공위성의 다중 분광 채널 관측값을 주요 입력 변수로 사용하고, MODIS L2 구름 마스크 및 에어로졸 산출 데이터의 정보를 학습 레이블로 각각 활용하는 2단계 머신러닝 기반 알고리즘을 제안하였다. 1단계에서는 eXtreme Gradient Boosting (XGBoost) (Chen and Guestrin, 2016) 분류 모델을 이용하여 각 화소를 구름(cloud), 구름 의심(probable cloud), 밝은 육지(bright land), 밝은 해양(bright ocean), 청천 육지(clear land), 청천 해양(clear ocean)의 6개 클래스로 분류하며, 2단계에서는 청천 화소에 한정하여 육지와 해양 각각에 특화된 XGBoost 회귀 모델을 적용하여 AOD를 산출한다. 화소 분류 정확도 평가에는 MODIS L2 청천 산출 데이터(코드명 MOD35) (Ackerman *et al.*, 1998) 기반으로 재구성한 6클래스 레이블을, AOD 산출 성능 평가에는 MOD04 산출물을 기준으로 활용하여 AI 기반 예측값과의 일치도를 정량적으로 평가하였다. 본 연구의 구성은 다음과 같다. 2장에서는 활용 데이터와 연구 영역을 기술하고, 제안하는 2단계 AI 알고리즘의 설계와 학습 및 검증 전략을 상세히 기술하며, 3장에서는 AI 기반 화소 분류 및 AOD 산출 정확도를 정량적으로 평가하고, MODIS L2 에어로졸 산출 데이터와의 공간 비교 및 사례 연구 결과를 제시한다. 4장에서는 주요 결과를 요약하고 향후 개선 방향을 논의한다.

2. 연구 데이터 및 방법

2.1 연구 데이터

본 연구의 대상 영역은 위도 20°~55°N, 경도 110°~145°E의 동아시아 지역으로 설정하였다(그림 1). 이 영역은 중국 내륙, 한반도, 일본 열도 및 주변 해역을 포함하며, 에어로졸 발생원과 지표 유형의 다양성을 나타내는 지역이다. 고비 및 타클라마칸 사막에서 발원한 황사는 편서풍을 따라 동진하면서 한반도와 일본에서도 높은 AOD를 유발하고(Lee, 2013), 중국 동부 산업 지대에서 발생한 인위적 에어로졸은 계절풍




Fig. 1. Study domain (20°~55°N, 110°~145°E) covering East Asia, including the Korean Peninsula, China, Japan, and the surrounding ocean.

순환에 따라 광역적으로 수송되므로(Yu *et al.*, 2015), AOD의 계절 변동폭이 다른 지역에 비해 뚜렷하게 나타난다(Lee and Bae, 2023). 그리고 사막이나 건조한 육지, 빙설지 또는 강설지, 계절별/지역별 식생 변화, 그리고 복잡한 해양 변화가 공존한다. 에어로졸 부하와 지표 특성이 모두 다양한 동아시아 지역은 AI 기반 화소 분류 알고리즘의 성능을 검증하는 데 적합한 동시에, 기존의 물리 기반 알고리즘이 안정적인 AOD 산출에 어려움을 겪는 도전적인 조건도 포함하고 있어 본 연구의 목적에 부합하는 연구 영역이다.

AI 모델의 입력 피쳐는 보정된 복사량 산출 데이터인 MODIS L1b 데이터(코드명 MOD02)를 사용하였다. MOD02 데이터는 센서 보정이 적용된 복사휘도(radiance) 및 반사도(reflectance) 데이터로서, 1 km 공간 해상도에서 36개 분광 채널 전체에 걸쳐 모든 화소별 관측값을 제공한다. 본 연구에서 활용한 분광 채널은 지표 반사와 에어로졸에 민감한 반사태양복사 밴드(Reflective Solar Bands, RSB) 중 중심파장 0.47 μm , 0.55 μm , 0.66 μm , 0.87 μm , 1.24 μm , 1.64 μm , 2.13 μm 에

서 반사도 값과 파생지수를 사용했다. 그리고 열적외 방출복사 밴드(Thermal Emissive Bands, TEB) 중 구름에 민감한 두 밴드 B31 (11.03 μm)과 B32 (12.02 μm)를 사용하였다. 이 채널은 얇은 권운(thin cirrus) 탐지에 민감하며, 상층 구름 화소를 식별하는 데 중요한 역할을 한다(Pavolonis and Heidinger, 2004; Inoue, 1985).

MOD02 데이터는 1 km 격자 크기로 제공되지만, 학습 레이블인 MOD04 데이터는 10 km 해상도의 격자를 기준으로 한다. 따라서 L1B 데이터는 10×10개의 화소에 대한 산출평균을 산출하여 피쳐로 사용하였으며, 결측 화소는 평균 산출에서 제외하였다. 관측 기하 정보(태양 천정각, 방위각, 위성 천정각, 방위각, 산란각, Sun Glint 각도)와 위경도 및 육지/해양 마스크는 MOD02 데이터에 포함된 보조 변수로부터 취득하였으며, 레이블 생성에 관여하지 않는 독립적인 피쳐로서 분류 및 AOD 산출 모델의 입력 데이터로 사용하였다.

AI 모델의 학습 레이블은 MOD35와 MOD04 데이터에서 추출하였다. 레이블 생성에 사용된 L2 변수는 화소별 구름 마스크(Aerosol_Cldmask_Land_Ocean), DT와 DB 산출 결과가 통합된 AOD(AOD_550_Dark_Target_Deep_Blue_Combined), 그리고 육지/해양 마스크(Land_sea_Flag, 10km)이며, 이 세 변수의 조합으로 6클래스 화소 마스크(pix_mask)를 정의한다. 레이블 생성 과정에서 L1B 피쳐 변수는 참조하지 않으므로, 피쳐와 레이블 간의 데이터 누출(data leakage)은 원천적으로 배제된다. 이처럼 피쳐와 레이블의 출처를 명확히 구분함으로써, 모델이 실제 대기과 지표의 분광 특성으로부터 화소 유형과 AOD를 학습하는 물리적으로 일관된 구조를 구현하였다.

본 연구에서는 AI 기반 AOD 산출 알고리즘의 가능성을 검증하기 위한 첫 단계로 MOD04 AOD를 참조 데이터(reference dataset)로 사용하였다. AOD 산출 모델의 성능 평가는 MOD04의 통합 AOD 산출물을 기준값으로 사용하며, 학습에 참여하지 않은 독립 시험 세트에서 AI 예측 AOD와의 일치도를 정량적으로 평가하는 방식으로 수행하였다. 이는 AI 모델이 MOD04

가 산출하는 AOD의 시공간 패턴을 얼마나 정확히 재현할 수 있는지를 1차적으로 검증하는 단계이다. MOD04 자체가 보유한 불확실성 및 지상 관측값 대비 절대적 정확도 검증은 본 연구의 범위를 벗어나며, 향후 충분한 시공간 매칭 데이터를 확보한 후속 연구에서 별도로 수행될 예정이다.

2.2 2단계 머신러닝 알고리즘

본 연구에서 제안하는 알고리즘은 화소 분류와 AOD 산출로 구성된 2단계 구조이며, 전체 처리 흐름은 그림 2에 제시하였다. MOD02 데이터에서 분광 데이터 피쳐를 추출하고 10 km 블록 평균으로 집계한 후, 기하 및 위치 관련 보조 변수와 결합하여 파생 피쳐를 산출하는 데이터 전처리 단계가 선행된다. 이렇게 구성된 피쳐 벡터는 두 단계의 XGBoost(Chen and Guestrin, 2016) 모델에 순차적으로 입력된다. 1단계에서는 XGBoost 다중 클래스 분류 모델이 각 화소를 6개 클래스로 분류하고, 동시에 각 클래스에 대한 소속 확률을 출력한다. 2단계에서는 1단계에서 청천 육지 또는 청천 해양으로 분류된 화소에 한하여 육지용과 해양용으로 각각 학습된 XGBoost 회귀 모델이 AOD를 예측한다. 이 과정에서 구름, 구름 의심, 맑은 육지, 맑은 해양으로 분류된 화소는 AOD 산출 대상에서 제외하여 결측으로 처리한다. 두 단계의 모델은 학습 완료 후 독립적으로 저장되어 신규 관측 데이터에 반복 적용할 수 있다.

XGBoost는 결정 트리를 약한 학습기로 사용하는 그래디언트 부스팅 앙상블 알고리즘으로, 구조화된 표 형식 데이터에서 높은 예측 정확도를 가지며 입력 변수 내 결측값을 각 분기에서 최적 방향으로 학습하여 자동으로 처리한다. 분류 모델의 주요 하이퍼파라미터는 표 1에 정리하였다. 그리고 클래스 불균형 처리를 위해 각 학습 화소에 역제곱근 빈도 기반의 샘플 가중치를 부여하였으며, XGBoost 모델의 학습 데이터 구성은 학습(60%), 검증(20%), 시험(20%) 세트로 계층적 무작위 분할(stratified random split)하였다. 이중 검증 세트는 학습 중 조기 종료 판단에만 사용하였




Fig. 2. Flowchart of the proposed two-stage machine learning algorithm. Stage 1 performs six-class pixel classification using an XGBoost classifier, and Stage 2 retrieves AOD for clear land and clear ocean pixels using separate land and ocean XGBoost regression models.

으며, 시험 세트는 최종 모델 성능 평가에만 활용하여 선택 편향을 배제하였다. 한편, 전체 화소에서 구름 클래스의 비율이 약 70~80% 수준으로 나타나지만 구름 의심이나 맑은 해양 화소는 상대적으로 매우 적어 심각한 클래스 불균형이 존재한다. 이를 완화하기 위해 클래스별 표본 빈도(N_c)의 제공근에 반비례하는 가중

치($w_c = 1/\sqrt{N_c}$)를 각 학습 화소에 부여하였다.

AOD 산출 모델은 1단계에서 청천 육지 또는 청천 해양으로 분류된 화소만을 대상으로 육지와 해양에 특화된 두 개의 독립적인 XGBoost 회귀 모델을 각각 학습한다. 육지와 해양은 지표의 분광 반사 특성이 다르므로, 하나의 회귀 모델보다 각각 독립적으로 최적

Table 1. Hyperparameter settings for the XGBoost classification and AOD retrieval models.

Parameter	Classification model	AOD retrieval model
n_estimators (max)	2,000	2,000
max_depth	8	8
learning_rate	0.05	0.05
subsample	0.8	0.8
colsample_bytree	0.8	0.8
min_child_weight	10	10
reg_alpha (L1)	0.1	0.05
reg_lambda (L2)	1.0	1.0
Objective function	multi:softmax	reg:squarederror
Evaluation metric	mlogloss	rmse
early_stopping_rounds	30	30

화된 모델이 비선형 관계를 더욱 효과적으로 학습할 수 있다. AOD 산출 모델의 입력 변수는 분류 모델의 경우와 동일하다. 그리고 물리적으로 AOD는 양수이므로 모델의 예측값이 음수로 산출되는 경우 0으로 강제 보정하였다.

6클래스 화소 분류 모델의 성능은 전체 정확도 (Overall Accuracy, OA), Cohen의 카파 계수(κ) (Cohen, 1960), 그리고 클래스별 정밀도 (Precision), 재현율 (Recall), F1-점수로 평가한다. 카파 계수는 식 (1)과 같이 우연 일치 가능성을 보정한 분류 일치도를 나타내며, 0.61~0.80 범위에 해당하는 값을 가지면 실질적 일치 (substantial agreement), 0.81 이상이면 거의 완전한 일치 (almost perfect agreement)로 해석된다 (Landis and Koch, 1977).

$$\kappa = \frac{p_0 - p_e}{1 - p_e} \quad (1)$$

위 식에서 p_0 와 p_e 는 각각 전체 정확도와 우연 일치 확률을 의미한다. 전체적인 성능 요약에는 클래스 빈도로 가중 평균한 F1-점수 (weighted F1)를 병행하여 제시하였다.

$$\text{Weighted F1} = \sum_{c=1}^C \frac{N_c}{N} \times \frac{2 \times P_c \times R_c}{P_c + R_c} \quad (2)$$

여기서 가중치 항(N_c/N)은 각 클래스의 실제 화소 수 비율이다. AOD 산출 모델의 성능은 AI 모델 예측

AOD (τ_{AI})와 MOD04 AOD (τ_{SAT}) 사이의 일치도를 기준으로 평가하며, 결정계수 (R^2), 평균 절대 오차 (MAE), 평균 제곱근 오차 (RMSE), 편의 (Bias)를 주요 지표로 사용한다.

$$R^2 = \frac{\sum (\tau_{AI} - \tau_{SAT})^2}{\sum (\tau_{SAT} - \bar{\tau}_{SAT})^2} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\tau_{AI,i} - \tau_{SAT,i})^2} \quad (4)$$

$$Bias = \frac{1}{N} \sum_{i=1}^N (\tau_{AI,i} - \tau_{SAT,i}) \quad (5)$$

그리고, MOD04가 Dark Target 알고리즘의 오차 허용 기준으로 제시한 기대 오차 (Expected Error, EE) 범위를 AI 예측과 MOD04 사이의 일치 기준으로 준용한다 (Levy *et al.*, 2013).

$$EE = \pm (0.05 + 0.15 \times \tau_{SAT}) \quad (6)$$

이를 기반으로 AI 예측 편차가 EE 이내에 드는 화소의 비율 (%EE)은 이 기준을 만족하는 정도를 나타내며, 값이 높을수록 AI 모델이 MOD04 산출값과 높은 수준으로 일치함을 의미한다.

3. 결과 및 고찰

3.1 화소 특성 분류 모델 성능 평가

2024년 전체 기간 동안의 AI 모델의 학습용 데이터 중 화소 특성 분류로 사용되는 레이블 데이터는 다음과 같다. 총 10,873,309개의 화소 중 구름 클래스가 8,868,791개 (81.6%)로 최대 수치를 나타냈으며, 그 다음으로 청천 육지 683,918개 (6.3%), 청천 해양 669,252개 (6.2%), 밝은 육지 290,823개 (2.7%), 구름 의심 269,976개 (2.5%) 순이었다. 밝은 해양은 90,549개 (0.8%)로 전체에서 가장 낮은 비율을 보였다. 이와 같은 심한 클래스 불균형에서는 전체 정확도만으로는 모델의 실제 분류 성능을 충분히 평가하기 어렵다. 따라서 OA만으로는 다수 클래스 편향만을 반영할 수 있으므로, 본 연구에서는 추가로 Cohen의 카파 계수 (κ)

와 클래스별 F1-점수를 주요 평가 지표로 병행하였다.

시험 세트에 대한 XGBoost 6클래스 분류 모델의 정확도는 OA=91.69%로 높은 정확도를 가지고 있다. 우연 일치 가능성을 보정한 Cohen의 카파 계수는 $\kappa=0.76$ 으로 실질적 일치 범위에 위치함으로써(Landis and Koch, 1977), 6개 클래스에 걸쳐 유의미한 분류 능력을 보유하고 있음을 나타낸다. Weighted F1=0.92로 높게 나타났으나, 이는 다수 클래스인 구름의 높은 성능이 전체 평균에 영향을 미치기 때문이며, 클래스 빈도를 동등하게 반영하는 거시 F1-점수(macro F1)는 0.70으로 상대적으로 낮아 소수 클래스의 분류 난이도가 상대적으로 높음을 의미한다.

그림 3은 클래스 분류 결과에 대한 혼동 행렬의 히트맵이다. 구름 클래스는 총 1,678,595개로 분류되었고, 이는 전체 화소 대비 94.6%의 정확도로 일치한다. 그러나, 일부 화소인 16,380개의 화소가 구름 의심으로 오분류되는 사례가 관찰되었다. 이는 두 클래스가 유사한 분광 특성을 가지기 때문인 것으로 추정된다. 청천 육지는 총 118,488개로 분류되었고, 이는 전체 화소 대비 86.6%의 정확도로 일치하지만 밝은 육지로의 오분류(6.1%)가 상대적으로 빈번하게 나타났다. 두 클래스는 모두 청천 조건을 공유하면서 화소별 분광 특성으로 구분되는 레이블 정의 특성상 일부 화소에서 분광 신호만으로는 명확한 경계를 학습하기 어렵다는 점을 반영한다. 실제 구름 의심 화소 중 구름 의심 클래스는 구름(56.2%)과 청천(43.8%) 양방향으로 오분류가 발생하는 양상을 보여, 부분 구름 조건의 본질적인 분광 모호성이 분류 불확실성으로 이어지고 있음을 확인할 수 있었다. 그리고 청천 해양과 밝은 해양 역시 일부 상호 오분류가 발생하였으나 전체적인 분류 성능은 양호하였다.

그림 4는 각 클래스별 정밀도, 재현율, F1-점수를 비교하기 위한 막대 그래프이다. 각 클래스의 성능은 뚜렷한 차이를 나타냈으며, 이를 성능 수준에 따라 구분하여 고찰하였다. 우선, 구름 클래스는 F1=0.963으로 6개 클래스 중 두 번째로 높았으며, 높은 정밀도(0.980)와 재현율(0.946)이 균형 있게 달성되었다. 이




Fig. 3. Confusion matrix of the XGBoost six-class pixel classifier on the test dataset. (a) Classified total counts and (b) row-normalized percentages are shown in each cell.

는 구름 화소의 수가 상대적으로 많고, 가시 채널 전반에서 높은 반사도를 나타내고 열적외 채널에서는 낮은 밝기온도를 보이는 등 다른 클래스와 분광적으로 뚜렷이 구분되는 특성에 의해 설명될 수 있다. 청천 해양 클래스는 F1=0.988로 6개 클래스 중 가장 높은 성능을 기록하였으며, 정밀도 0.979와 재현율 0.997로 실제 청천 해양 화소의 대부분이 정확하게 식별되었음을 보여준다. 이는 근적외 및 단파적외 영역에서 매우 낮은 반사율을 나타내는 해수의 분광 특성으로 인하여 다른 클래스로부터 명확하게 분리할 수 있었기 때문이다.

청천 육지 클래스는 F1=0.738로 재현율(0.866)이




Fig. 4. Per-class precision, recall, and F1-score of the XGBoost pixel classification model on the 2024 test dataset.

정밀도(0.642)보다 상당히 높게 나타났다. 이처럼 재현율이 높고 상대적으로 정밀도가 낮다는 것은 실제 청천 육지 화소의 대부분이 올바르게 탐지됨을 의미하지만, 청천 육지로 예측된 화소 가운데 상당 부분이 실제로는 다른 클래스에 속함을 의미한다. 청천 조건에서 청천 육지 화소의 분류 성공 여부는 지표 반사도의 절대적 크기와 밀접하게 연관되어 있으나, 분광 특성만으로는 시공간적으로 다양한 육지 피복의 반사 특성을 완전히 구분하기 어렵다.

밝은 해양은 $F1=0.690$ 으로 표본 수가 18,110개임을 고려하면 상대적으로 양호한 성능을 보였으며, 재현율(0.918)이 정밀도(0.552)보다 높게 나타났다. 이 클래스의 대표적인 발생 원인은 Sun Glint 각도가 특정 범위 이내일 때 집중적으로 발생하므로, 입력 변수 중 Sun Glint 각도가 이러한 분류 성능에 기여한 것으로 추정된다. 다만 정밀도 부족은 일부 청천 해양 화소가 밝은 해양으로 오분류되는 현상과 관련된 것으로 추정된다.

구름 의심 클래스는 $F1=0.279$ 로 전체 클래스 중 가장 낮은 성능을 보였다. 정밀도(0.302)와 재현율(0.258)이 모두 낮아 이 클래스는 AI 모델을 이용하여 학습하기 어려운 범주임을 나타낸다. 주요 원인으로는 구름 의심 클래스의 정의 자체가 10 km^2 영역 내의 구름 비율이 약 10~30%의 연속적 전이 구간에 해당하

로, 그 분광 특성은 구름 클래스와 청천 클래스 사이의 중간적 성격을 가진다는 점이다. 블록 평균으로 집계된 L1B 반사도 값은 이 미묘한 차이를 충분히 표현하는 데 한계가 있으며, 이는 인접 구름에 의한 3차원 복사 효과(cloud adjacency effect) (Várnai and Marshak, 2009)가 블록 내 반사도 분포를 복잡하게 만드는 데서도 비롯된다. 구름 의심 클래스의 성능 한계는 현 입력 변수 체계 내에서 구조적으로 내재된 문제로 판단된다. 그리고 향후 개선 사항으로는 고해상도 구름 분율 정보나 위성 다중각 관측 데이터의 활용이 고려될 수 있다.

밝은 육지 클래스는 $F1=0.531$ 로 구름 의심 다음으로 낮은 성능을 보였으며, 정밀도 0.502는 예측의 신뢰도가 높지 않음을 의미한다. 밝은 육지는 사막, 적설지, 도시 지역 등 서로 다른 분광 특성을 갖는 다양한 지표 유형을 포함한다. 사막의 모래 재질에 따른 황색~적색 계열의 밝은 반사, 적설 지역에서 가시광 전역에서 높은 반사, 도시 지역의 복합적인 분광 반사 특성은 지표의 구성 및 형태에 따라 상당한 분광 차이를 가지므로, 단일 클래스로 대표되는 밝은 육지 클래스를 분광 특성만으로 청천 육지와 구별하는 데 어려움이 따른다. 향후 토지 피복 분류 데이터를 보조 입력으로 활용하거나 밝은 육지를 세부 유형(사막, 적설, 도시)으로 분리하는 방안을 검토할 필요가 있다.




Fig. 5. Top 25 feature importance (gain-based) of the XGBoost pixel classification model trained on the 2024 dataset.

그림 5는 XGBoost 분류 모델로부터 산출한 피쳐 중요도(Gain 기준) 상위 25개 결과를 나타낸다. Gain은 모든 분할에서 손실 감소량(loss reduction)의 누적값으로 정의되며, 값이 클수록 해당 변수가 분류 성능 향상에 크게 기여했음을 의미한다. 피쳐 중 육지/해양 마스크(lsf)가 Gain=0.41로 가장 기여도가 크게 나타났다. 이는 6개 클래스 가운데 밝은 육지, 밝은 해양, 청천 육지, 청천 해양의 4개 클래스가 육지/해양 구분에 직접 의존하는 레이블 정의 구조를 반영한 결과로, 레이블 정의 자체가 육지와 해양을 기준으로 구성되

어 있기 때문으로 해석된다. 그 다음으로는 파생 분광 지수인 feat_b4_b3가 0.18, feat_ndvi가 0.12를 차지하였다. feat_b4_b3는 녹색($0.555\ \mu\text{m}$)과 청색($0.469\ \mu\text{m}$) 채널의 비율 지수로서 이는 청색과 녹색 파장에서 구름과 해양 및 육지의 반사 특성이 서로 다르기 때문으로 해석된다. feat_ndvi는 근적외와 적색 채널의 정규화 차이로 육지 피복 특성을 반영함으로써 육지 계열 클래스의 분리에 기여한 것으로 해석된다. 두 파생 변수가 반사도 채널보다 높은 기여도를 보인 것은 파생 변수 설계가 원시 분광 정보를 보다 구별력이 높은 특

성 공간(feature space)으로 변환하여 모델의 학습 효율을 향상시키는 효과가 있음을 시사한다. 네 번째는 `ref_land_ocean_b5` (0.10)로 단파 적외(SWIR) 계열 채널 반사도이다. SWIR 채널은 구름 및 지표의 반사 특성 차이에 민감하여 분류 성능 향상에 기여한 것으로 해석된다. 다섯 번째로 높은 중요도를 보인 `glint_angle` (0.031)은 Sun Glint 각도이며 밝은 해양 클래스 식별에 직접적으로 기여하는 기하 변수이다. Glint 각도가 36° 미만인 경우 해양 표면에서 정반사가 강해져 반사도가 비정상적으로 높아지는데 (Cox and Munk, 1954), 모델이 밝은 해양 화소를 식별하는 데 중요한 보조 변수로 활용한 것으로 해석된다. 여섯 번째 `ref_land_ocean_b1` (0.028)은 가시광 채널 반사도로 구름의 전 가시 채널 반사 특성을 반영한다. 위도와 경도의 높은 중요도는 연구 영역 내 지표 피복과 에어로졸 환경의 공간적 분포 특성을 일부 반영한 결과로 해석된다. 태양 천정각(`sza`), 위성 천정각(`vza`), 산란각(`scat_angle`), 공기 질량 인자(`feat_airmass`) 등 기하 변수들도 의미 있는 기여도를 보였으며, 이는 태양 및 위성 관측 기하가 위성 관측에 영향을 미치기 때문으로 해석된다. 이러한 결과는 파생 변수와 관측 기하 정보가 화소 분류 성능 향상에 중요한 역할을 함을 보여주며, 향후 새로운 분광지수나 공간 문맥 정보를 추가할 경우 구름 의심 및 밝은 육지 클래스의 성능을 더욱 향상시킬 가능성을 시사한다.

3.2 AOD 산출 모델 성능 평가

AOD 산출 모델은 1단계 분류 단계에서 청천으로 판정된 화소에 대해서만 회귀 모델을 적용함으로써 구름 오염에 따른 회귀 오차를 최소화하였다. 또한, 육지와 해양 각각에 특화된 XGBoost 회귀 모델을 독립적으로 학습하여 구성하였다. 육지 AOD 모델의 시험 세트 성능을 그림 6a에 제시하였다. 총 120,966개의 화소값에 대하여 $R^2=0.985$, $RMSE=0.049$, $MAE=0.029$, $Bias=0.0001$ 로 산출되어 전반적으로 MOD04 AOD와 높은 상관성과 낮은 오차를 보였다. AI 예측값과 MOD04 AOD와의 차이가 EE 이내에 드는 화소의 비율(%EE)은 95.9%로 산출되었다. 그림 6a의 밀도 산




Fig. 6. Density scatter plots of AI predicted AOD vs. MOD04 AOD for (a) the land model and (b) the ocean model on the 2024 test dataset, with the 1:1 line and EE bounds ($\pm(0.05 + 0.15 \times AOD_MOD04)$).

점도에서는 AOD가 낮은 영역(≤ 0.3)에서 점 군의 밀도가 높고 1:1 선을 따라 전반적으로 잘 분포하는 반면, AOD가 1.0을 상회하는 고농도 영역에서는 일부 과소 추정 경향이 나타난다. 학습 데이터 내에서 $AOD > 1.0$ 인 화소값이 상대적으로 희소하여 모델이 해당 영역의 비선형 관계를 충분히 학습하지 못한 데에서 비롯된 것으로 판단된다.

해양 AOD 모델은 총 133,832개의 화소에서 $R^2=0.987$, $RMSE=0.019$, $MAE=0.013$, $Bias=0.0001$,




Fig. 7. Top feature importance (gain-based) of the (a) land and (b) ocean AOD retrieval model.

%EE=99.5%로 육지 모델 대비 모든 지표에서 우수한 성능을 나타냈다(그림 6b). 특히 AI 예측값의 약 99.5%가 MOD04 기준값의 EE 범위 이내에 위치함을 보인다. 해양 모델이 육지 모델보다 우수한 성능을 보이는 것은 다음과 같은 물리적 배경에서 이해할 수 있다. 첫째, 해양은 표면 반사도가 낮고 공간적으로 균질하므로 위성이 관측하는 반사도에서 에어로졸의 기여가 상대적으로 크게 나타난다(Remer *et al.*, 2005). 본 연구에서 밝은 해양으로 분류된 화소는 AOD 산출에서 제외하였으므로, 해양 모델이 처리하는 청천 해양 화소는 표면 반사 특성이 단순한 조건에 집중된다. 둘째, MOD04 해양 산출물은 일반적으로 육지보다 불확실성이 작은 것으로 알려져 있으며(Levy *et al.*, 2013), 이는 레이블 노이즈(label noise)가 감소함에 따라 회귀

모델의 일반화 성능 향상에 기여한 것으로 해석된다.

그림 7은 육지와 해양 AOD 산출 모델의 피쳐 중요도 상위 25개 결과이다. 육지 모델(그림 7a)과 해양 모델(그림 7b)의 결과가 서로 다른 피쳐 중요도 분포를 보였으며, 이는 육지와 해양에서 AOD를 설명하는 분광 및 기하 정보의 상대적 기여가 다를 것을 시사한다. 그림 7a의 육지 AOD 모델에서는 ref_land_ocean_b2 채널 반사도의 Gain=0.35로 가장 높은 기여도를 나타낸다. 이는 육지 표면과 대기 에어로졸의 반사도가 결합하여 나타나는 신호는 이 채널에서 가장 민감하기 때문으로 해석된다(Levy *et al.*, 2013). 다음으로 높은 기여도는 공기 질량 인자(feat_airmass, Gain=0.15)이다. 공기 질량 인자는 대기 광학 경로 길이의 대리 변수로서, 동일한 에어로졸 농도라도 관측 기하에 따라

위성에서 측정되는 복사 신호가 크게 달라지기 때문에 AOD 추정에 필수적인 정보를 제공한다. 다음으로, 육지 모델에서도 *glint_angle*이 비교적 높은 중요도 ($\text{Gain}=0.11$)를 보인 것은 관측 기하가 TOA 반사도에 영향을 미치기 때문이며, 일부 해안 또는 내륙 수역 화소의 영향이 포함되었을 가능성도 있다. 네 번째 가시광 평균 밝기(*feat_vis_bright*, $\text{Gain}=0.08$)는 배경 반사도의 전반적인 수준을 나타내는 요약 변수로서 AOD 추정에 유용한 정보를 제공한 것으로 해석된다. 그리고 *ref_land_ocean_b1*, *b9*, *b8* 등 여러 반사도 채널이 뒤를 이었으며, 기하 변수들도 고르게 기여하였다. 주목할 점은 분류 모델에서 상위권을 차지했던 *feat_ndvi*와 *feat_b1_b3*가 AOD 회귀 모델에서는 하위권으로 이동하였는데, 분류 단계에서는 중요했던 식생 정보가 회귀 단계에서는 상대적으로 작은 기여도를 보였다.

그림 7b의 해양 AOD 모델의 기여도 분석 결과에서는 단일 반사도 채널인 *ref_land_ocean_b10* ($\text{Gain}=0.23$)이 가장 높은 기여도를 나타냈으며, 파생 분광 비율 지수인 *feat_b4_b3* ($\text{Gain}=0.21$)와 *feat_b1_b3* ($\text{Gain}=0.20$)가 그 다음의 기여도를 나타내었다. 상위 3개 변수가 모두 0.20 이상의 높은 Gain 을 기록하며 서로 유사한 기여도를 보인 점은, 해양 AOD 산출이 특정 단일 채널보다 가시광 단파 대역의 채널 간 상대적 반사도 패턴에 의존하고 있음을 시사한다. *feat_b4_b3*는 B4 ($0.555\ \mu\text{m}$)와 B3 ($0.469\ \mu\text{m}$)의 반사도 비율로, 해양의 파장 의존 반사도 모델을 기반으로 하는 MOD04 DT 알고리즘의 산출 원리와 유사한 경향을 보인다(Levy *et al.*, 2013). *feat_b1_b3*는 B1 (적색)과 B3 (청색)의 상대적인 반사 특성을 나타내는 지수로서, 해수면의 반사 특성을 정량화하는 데 기여하는 것으로 해석된다. 네 번째 *ref_land_ocean_b5* ($\text{Gain}=0.13$)는 단파 적외 계열 채널 반사도로 에어로졸 및 해양 표면의 분광 특성을 반영하는 데 기여한 것으로 해석된다. 다섯 번째 *ref_land_ocean_b4* ($\text{Gain}=0.05$)와 여섯 번째 *feat_ndvi* ($\text{Gain}=0.04$)에 이어, *feat_nir_swir*, *glint_angle*, *feat_swir_nir*, *feat_cpi* 등 파생 변수들이

상위 10위 내에 다수 포함되어 파생 변수의 종합적 기여도가 해양 모델에서 더욱 두드러지게 나타남을 확인하였다.

육지 모델과 해양 모델의 피쳐 중요도를 비교하면 두 가지 뚜렷한 차이가 나타난다. 첫째, 육지 모델은 단일 반사도 채널의 기여도가 전체의 35%를 차지하는 집중형 구조인 반면, 해양 모델은 상위 3개 변수의 기여도가 각각 20%대로 분산된 균형형 구조를 보인다. 이는 육지 지표 반사도의 공간적 이질성이 특정 채널의 대기-지표 신호 분리 효율을 높이는 반면, 해양에서는 표면 반사 특성이 균일하여 여러 채널의 비율 정보를 종합하는 방식이 유리함을 시사한다. 둘째, 공기 질량 인자가 육지 모델에서는 2위($\text{Gain}=0.15$)의 높은 중요도를 나타낸 반면 해양 모델에서는 12위($\text{Gain}=0.008$)로, 육지에서는 관측 기하에 따른 AOD 민감도 변화가 더욱 중요하게 작용함을 보여준다. 한편, 두 모델 모두에서 파생 변수들이 원시 반사도 채널과 대등하거나 그 이상의 기여도를 기록하였다. 이는 물리적으로 의미 있는 분광 비율 및 기하 파생 변수의 설계가 회귀 모델의 학습 효율을 실질적으로 향상시키며, 향후 추가적인 파생 변수 설계가 AOD 산출 정확도 개선에 기여할 수 있음을 시사한다.

그림 8은 전체 시험 화소를 MOD04 AOD 기준값에 따라 저($0.0\sim0.2$), 중($0.2\sim0.5$), 고($0.5\sim1.0$), 매우 높음(>1.0)의 4개 구간으로 나누어 육지와 해양 모델의 성능 변화를 분석한 결과이다. AOD 구간에 따른 성능 변화에서는 다음과 같이 두 가지 공통적인 경향이 확인되었다. 첫째, R^2 는 저 AOD 구간에서 가장 낮고 고 AOD 구간으로 갈수록 높아지는 경향을 보인다. 저 AOD 영역에서 R^2 가 낮게 산출되는 것은 AOD 절댓값이 작을수록 공간 변동폭 자체가 좁아지고 MOD04 산출물 내의 불확실성이 상대적으로 커지기 때문이다. 따라서 저 AOD 구간의 낮은 R^2 는 반드시 큰 절대 오차를 의미하는 것은 아니다. 실제로 DT 알고리즘은 저 AOD 조건에서 지표 반사도 가정의 불확실성이 AOD 신호 대비 크게 작용하여 정확도가 저하되는 특성이 알려져 있으며(Levy *et al.*, 2013), 이는 AI 모델의 예측




Fig. 8. R^2 , RMSE, and %EE by AOD range for the land and ocean AOD retrieval models.

성능 저하뿐만 아니라 기준 자료인 MOD04 AOD의 불확실성도 함께 반영된 결과로 해석된다. 반대로 높은 AOD 구간에서는 AOD의 절대 변동폭이 크고 공간 패턴이 뚜렷하여 AI 모델이 상대적으로 높은 설명력을 보였다.

둘째, EE 이내 화소 비율(%EE)은 저 AOD에서 낮고 고 AOD에서 높아진 후 매우 높은 AOD (>1.0) 구간에서는 다소 감소하는 역U자형 패턴을 보인다. 이는 EE 기준값이 AOD에 비례하여 증가하기 때문이다. 즉, 낮은 AOD (예: AOD=0.1) 조건에서는 EE 허용 범위가 ± 0.065 에 불과하여 작은 절대 오차도 EE 기준을 벗어나기 쉬운 반면, 중상 이상의 높은 AOD (예: AOD=0.7)에서는 EE 허용 범위가 ± 0.155 로 넓어져 상당한 절대 오차도 허용 범위 내에 포함된다. 매우 높은 AOD 구간에서의 %EE 소폭 감소는 학습 데이터 내 고농도 사례의 학습 표본 부족에 따른 일반화 한계와 관련된 것으로 추정된다.

육지와 해양을 비교하면, 모든 AOD 구간에서 해양 모델이 일관되게 높은 %EE와 낮은 RMSE를 기록하였다. 특히 고 AOD 구간(>1.0)에서 육지 모델의 %EE (97.5%)와 해양 모델의 %EE (100%) 간 격차가 2.5%로 다른 구간 대비 가장 작게 나타났는데, 이는 고농도 AOD 조건에서 에어로졸 신호가 지표 반사도보다 상

대적으로 우세하게 나타나기 때문으로 해석된다. 육지 모델의 저 AOD 구간 %EE (66.3%)가 비교적 낮게 나타난 점은 향후 알고리즘 개선 시 우선적으로 주목해야 할 과제이며, 저 AOD 조건에 특화된 피쳐 설계나 두 단계 회귀 구조(저·고 AOD 별도 모델)의 도입이 개선 방향으로 고려될 수 있다(Wei *et al.*, 2019). 종합적으로, 제안한 XGBoost 기반 2단계 AOD 산출 알고리즘은 MOD04 기준 자료의 공간적 분포와 농도 변화를 높은 수준으로 재현하였으며, 특히 해양에서 매우 우수한 일치도를 나타냈다. 이는 분류와 회귀를 분리한 순차적 AI 구조가 다양한 지표 환경에서 안정적인 AOD 산출에 효과적으로 적용될 수 있음을 보여준다.

3.3 AI 모델 기반 AOD 산출

3.1절에서 개발한 화소 분류 모델과 3.2절에서 학습한 육지·해양 AOD 회귀 모델을 통합한 AI 파이프라인을 2025년 독립 자료(전체 화소 수=1,007,902개)에 적용하였다. 이렇게 산출된 AI 기반의 AOD는 동일 기간의 MOD04 AOD와의 시공간적 일치도를 분석하였다. 검증 자료는 학습에 사용되지 않은 연도의 자료이므로 계절 및 연도에 따른 대기 조건 변화를 포함하고 있다. 연구 기간 동안 전체 검증 화소를 대상으로 한 통합 검증 지수를 그림 9에 제시하였다. 육지 AOD




Fig. 9. Density scatter plots of AI predicted AOD vs. MOD04 AOD for (a) the land model and (b) the ocean model on the 2025 dataset, with the 1:1 line and EE bounds ($\pm(0.05 + 0.15 \times AOD_MOD04)$).

산출 성능은 $R^2=0.927$, $RMSE=0.055$, $MAE=0.035$, $\%EE=90.9\%$ 로 나타났으며, 해양 AOD 산출 성능은 $R^2=0.973$, $RMSE=0.026$, $MAE=0.017$, $\%EE=99.0\%$ 이다. 육지에서 성능 감소가 해양보다 상대적으로 크게 나타난 것은 육지 표면 반사도의 높은 공간적 이질성과 계절 변화가 영향을 미친 것으로 해석된다. 또한, 이러한 결과는 시험 세트보다 다소 성능은 감소하였으나, 전반적으로 높은 R^2 와 $\%EE$ 를 유지하여 시간적으로 독립된 자료에서도 우수한 일반화 성능을 보

였다.

그림 10은 2025년 전체 기간 평균 AOD의 공간 분포를 나타내며, 육지와 해양을 모두 포함한 전체 검증 결과는 $R^2=0.950$, $RMSE=0.039$, $Bias=0.003$, $\%EE=96.1\%$ 로 산출되었다. Bias가 매우 작아 전반적으로 체계적인 과대 추정은 크지 않은 것으로 나타났으나 평균적으로는 AI가 MOD04보다 약간 높은 값을 예측하는 경향을 보였다. $\%EE$ 는 전체 유효 화소의 96.1%가 MOD04의 기대 오차 범위 이내에서 재현되었음을 보여준다. 그림 10a의 MOD04 AOD는 중국 화북의 허베이 및 산둥 지역($35^\circ\sim 40^\circ N$), 양쯔강 삼각주(약 $30^\circ N$, $120^\circ E$)를 중심으로 $AOD > 0.4$ 의 높은 에어로졸 부하가 나타났다. 서해는 중국 대륙으로부터의 장거리 수송 에어로졸에 의해 중간 수준($0.2\sim 0.3$)의 AOD가 관측되었으며, 한반도와 일본은 $0.1\sim 0.2$ 수준을, 북서 태평양 외해는 $AOD < 0.1$ 의 청정한 해양 배경 수준이 나타난다. 그림 10b의 AI 기반 AOD는 전반적인 공간 구조에서 MOD04와 높은 유사성을 보였으며, 중국 화북 높은 AOD 지역, 양쯔강 삼각주 중간 범위 영역, 태평양 외해 청정 배경 등 동아시아의 주요 AOD 공간 패턴이 AI 지도에서 높은 공간적 일관성을 보였다. 다만 중국 북동부(만주 및 화북 북부, $40^\circ\sim 50^\circ N$)에서 AI가 MOD04 대비 다소 더 높은 AOD를 산출하는 경향이 확인된다.

그림 10c의 차이값 지도는 전반적으로 양의 차이가 우세하여 AI가 MOD04 대비 전반적으로 AOD를 과대 추정하는 경향이 확인된다. 과대 추정이 가장 강하게 나타나는 지역은 중국 북동부($40^\circ\sim 50^\circ N$, $110^\circ\sim 130^\circ E$) 구간으로, 이 지역에서 AI AOD가 MOD04 AOD 대비 약 $0.05\sim 0.10$ 수준으로 과대 추정하였다. 이는 2024년 학습 데이터에서 이 지역의 AOD 결정 조건이 충분히 대표되지 않았을 가능성을 포함한다. 반면, 일부 음의 차이(과소 추정)는 남중국해 연안(약 $20^\circ\sim 25^\circ N$)과 북서 태평양 해역의 일부 격자에서 제한적으로 나타났다. 해양 격자 전반은 차이가 거의 중립적이거나 소폭 양의 값을 나타내어, 해양 모델이 3.2절에서 확인된 높은 성능($\%EE=99.6\%$)을 공간 분포에




Fig. 10. Spatial distribution of (a) mean MOD04 AOD, (b) mean AI predicted AOD, and (c) the difference (AI-MOD04) over the 2025 analysis period.

서도 높은 일치도를 유지하였다.

종합적으로, 제한한 2단계 AI 파이프라인은 학습에 사용되지 않은 독립 연도 자료에서도 MOD04 AOD의 공간 분포와 농도 변화를 높은 수준으로 재현하였다. 이는 제한한 순차적 분류-회귀 구조가 다양한 시기에도 안정적으로 적용될 수 있음을 보여준다. 다만 중국 북동부 고 AOD 격자를 중심으로 과대 추정 경향이 나타났으며, 이는 향후 학습 데이터 확충과 지역별 편차 보정 기법 도입을 통해 개선해야 할 과제이다.

3.4 사례 연구

3.3절의 전체 기간 통계 검증만으로는 다양한 대기 조건에서의 모델 거동을 충분히 설명하기 어렵다. 따라서 서로 다른 에어로졸 부하를 대표하는 고 AOD 사례와 저 AOD 사례를 선정하여 AI 모델의 공간 재현 특성을 추가적으로 분석하였다. 사례별 검증 지수를 표 2에 정리하였으며, 공간 비교 결과는 그림 11, 12에 제시하였다.

동아시아에서 고 AOD 이벤트를 유발하는 대표적인 원인 중 하나는 봄철 황사와 중국 동부 산업 지역으로부터의 인위적 에어로졸 장거리 수송이다. 봄철 고비 사막 및 황토고원 일대에서 발원한 황사는 편서풍 기류를 타고 한반도와 일본으로 수송되며, 수송 경로 상의 해양 상공에서도 AOD가 1.0을 상회하는 높은 에어로졸 부하를 만들어낸다(Choi *et al.*, 2020; Shimizu *et al.*, 2004). 연구 기간 중 이에 해당하는 대표적 고

AOD 이벤트 사례인 2025년 3월 8일 사례를 선정하여 분석을 수행하였다. 해당 이벤트일의 MOD04 AOD 공간 분포(그림 11a)는 중국 북동부 및 산둥반도에서 AOD 1.5~2.5의 높은 값이 나타났으며, 에어로졸 플룸이 서해를 거쳐 한반도 서쪽까지 뻗어 있는 구조가 뚜렷이 나타났다. AI 기반 AOD 지도(그림 11b)는 에어로졸 플룸의 전반적인 공간 구조를 비교적 충실히 재현하였으나, 에어로졸이 밀집된 영역에서는 AI AOD가 MOD04 AOD 대비 약 0.2 정도 낮게 산출되었다(그림 11c). 이는 AOD > 1.5를 초과하는 구간에서 학습 표본이 희소하여 XGBoost 회귀 모델의 외삽 능력이 제한적일 가능성이 있다. 일반적으로 그래디언트 부스팅 계열 모델은 학습 데이터의 종속 변수 범위 내에서는 안정적인 예측을 수행하지만, 범위를 벗어나는 극단값을 충분히 재현하지 못하는 경향이 보고되어 있다(Chen and Guestrin, 2016).

한편, 가을철 건조한 대륙성 고기압의 영향이 연구 영역으로 유입되어 AOD가 0.1 미만으로 낮아지는 청천 조건이 형성된다(그림 12). 이러한 조건은 위성 기반 AOD 산출에서는 에어로졸 신호 자체가 작아 알고리즘의 절대 정확도를 시험하는 조건이 된다. 본 연구에서는 연구 기간 중 이에 해당하는 대표적 저 AOD 조건인 2025년 9월 27일 사례를 선정하여 분석하였다. 해당 사례일의 MOD04 AOD 분포(그림 12a)는 한반도 주변 해역과 일본 동쪽 태평양 해역에서 AOD가 0.3 미만으로 유지되어 대기 상태가 매우 청결한 날임




Fig. 11. Spatial distribution of (a) MOD04 AOD, (b) AI predicted AOD, and (c) the difference (AI-MOD04) for the high-AOD event on 2025 March 8.




Fig. 12. Same as Fig. 11, but for the low-AOD clean case on 2025 September 27.

Table 2. Summary of validation metrics for the two selected case studies (AI predicted AOD vs. MOD04 AOD).

Case	Event type	R ² (combined)	RMSE	Bias	%EE	N (pixels)
2025/03/08	High AOD event	0.945	0.090	-0.019	95.8%	2,400
2025/09/27	Low AOD clear event	0.758	0.025	+0.009	95.3%	10,122

을 확인할 수 있다. AI 산출 AOD 지도(그림 12b)는 MOD04의 공간 분포 패턴과 전반적으로 잘 일치하였으며, 특히 해양에서 두 지도 사이의 시각적 유사성이 매우 높게 나타났다. 차이 지도(그림 12c)에서도 전반적으로 0.05 이하의 범위를 나타내었고, AI 모델이 저 AOD 조건에서도 MOD04의 공간 패턴을 체계적 오차 없이 재현하고 있음을 보여준다.

청천 사례의 정량적 지표는 RMSE=0.025로 전체 기간 평균 대비 현저히 낮아져 절대 오차 측면에서는 가장 우수한 성능을 보였다. %EE=95.3%이며 고 AOD 사례의 %EE=95.8% 대비 유사한 수준으로 나타났다.

반면 결정계수는 $R^2=0.758$ 로 전체 기간 평균 대비 낮게 산출되었다. 이는 분산이 매우 작은 자료에서는 작은 절대 오차도 결정계수에 큰 영향을 미치는 R^2 의 통계적 특성 때문이다. 표준화되지 않은 절대 오차(RMSE, MAE)와 %EE가 우수함에도 R^2 가 낮게 산출되는 이 역설적 현상은 AOD 연구에서 자주 지적되는 평가 지표의 함정으로(Sayer *et al.*, 2013), 저 AOD 조건에서의 모델 성능은 R^2 보다 RMSE와 %EE를 우선적 판단 기준으로 삼는 것이 적절하다.

두 사례를 종합적으로 비교하면, AI 파이프라인은 저 AOD 청천 조건에서 절대 정확도가 높고 MOD04

공간 패턴을 안정적으로 재현하는 반면, 고 AOD 이벤트 조건에서는 공간 분포 재현은 가능하나 극값 구간에서의 과소 추정이 성능을 제한하는 약점이 존재한다. 이러한 성능의 조건 의존성은 AI 기반의 AOD를 활용할 때 고 AOD 이벤트 기간에는 추가적인 불확실성을 감안하여야 함을 의미하며, 향후 고 AOD 학습 표본을 증강하거나 이벤트 탐지 기반의 후처리 보정을 도입하는 방향의 개선이 필요하다. 이러한 결과는 제안한 2단계 AI 파이프라인이 일반적인 대기 조건에서는 안정적으로 동작하지만, 극한 에어로졸 사건에서는 학습 자료의 대표성과 모델의 외삽 능력이 성능을 좌우함을 시사한다.

4. 결 론

본 연구는 동아시아 지역(위도 $20^{\circ}\sim 55^{\circ}\text{N}$, 경도 $110^{\circ}\sim 145^{\circ}\text{E}$)을 대상으로 MODIS L1B 다중 분광 채널 정보와 기하 관측 정보를 입력 피처로, MOD04 L2 구름 마스크 및 AOD 산출물을 학습 레이블로 활용하는 2단계 XGBoost 기반 머신러닝 파이프라인을 개발하였다. 본 연구의 주요 결과는 다음과 같다.

첫째, 6클래스 화소 분류 모델은 2024년 시험 세트에서 $OA=91.69\%$, $\kappa=0.76$, 가중 평균 $F1=0.92$ 를 달성하였다. 청천 해양($F1=0.988$)과 구름($F1=0.963$) 클래스는 분광 대비가 명확하여 높은 성능을 보인 반면, 구름 의심($F1=0.279$)과 맑은 육지($F1=0.531$)는 전이 영역의 분광 모호성으로 인해 상대적으로 낮은 성능을 나타냈다. 또한 피처 중요도 분석에서는 각 피처 변수 설계의 실질적 효과를 확인하였다.

둘째, AOD 산출 모델은 육지에서 $R^2=0.985$, $RMSE=0.049$, $\%EE=95.9\%$, 해양에서 $R^2=0.987$, $RMSE=0.019$, $\%EE=99.5\%$ 를 달성하여 두 환경 모두에서 MOD04 AOD의 공간 패턴을 매우 높은 정확도로 재현하였다. 피처 중요도 분석에서는 육지와 해양에서 서로 다른 변수 조합이 AOD 예측에 중요한 역할을 하는 것으로 나타났다. 이는 지표 반사 특성의 이질

성이 높은 육지에서는 특정 채널의 신호 분리 효율이 높은 반면, 해양에서는 채널 간 비율 정보를 종합하는 방식이 유리함을 시사한다. AOD 구간별 분석에서는 저 AOD 구간($0.0\sim 0.2$)에서 육지 모델의 $\%EE=95.6\%$ 가 다른 구간 대비 낮게 나타났으며, 이는 향후 개선의 우선 과제이다.

셋째, 2024년 데이터로 학습된 AI 파이프라인을 2025년 독립 데이터에 적용한 결과, $R^2=0.950$, $RMSE=0.039$, $Bias=0.003$, $\%EE=96.1\%$ ($N=1,007,902$)의 성능이 산출되었다. 양의 편차는 AI 모델이 MOD04 대비 전반적으로 AOD를 약간 과대 추정하는 경향을 나타낸다. 평균 공간 분포는 MOD04와 높은 공간적 일치도를 보였으며, 일부 중국 북동부에서 과대 추정이 나타났다. 반면 해양 격차는 차이가 거의 중립적이거나 소폭 양의 값에 그쳐 해양 모델의 안정적 일반화 성능을 공간적으로 뒷받침하였다.

넷째, 대기 조건이 극명히 대비되는 두 사례를 통해 모델의 조건별 성능을 점검하였다. 봄철 고농도 이벤트 사례(2025년 3월 8일)에서는 에어로졸 플룸의 전반적인 공간 구조를 비교적 충실히 재현하였다($R^2=0.945$, $\%EE=95.8\%$). 그러나, $AOD>1.5$ 를 초과하는 극값 구간에서는 과소 추정 경향이 나타났으며($RMSE=0.090$, $Bias=-0.019$), 이는 외삽 특성 또는 학습 표본 부족과 관련된 것으로 판단된다. 가을철 청천 사례(2025년 9월 27일)에서는 절대 오차가 현저히 낮고($RMSE=0.025$), $\%EE=95.3\%$ 로 높게 나타나 저 AOD 조건에서의 우수한 성능을 확인하였다.

결론적으로, 본 연구에서 제안한 2단계 머신러닝 파이프라인은 복사전달 계산을 직접 수행하지 않고 위성 데이터로부터 화소 분류와 AOD 산출을 통합적으로 수행하는 데이터 기반 접근법의 가능성을 제시하였다. 향후 고해상도 위성 센서 적용과 실시간 에어로졸 모니터링 시스템 개발의 기반이 될 것으로 기대된다. 향후 연구에서는 추가적인 피처 변수의 개발, 고 AOD 학습 표본 증강, 다양한 머신러닝 및 딥러닝 모델과의 비교, 그리고 지상 관측과 비교 검증 방안이 필요하다.

감사의 글

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (RS-2026-25486593).

References

- Ackerman, S.A., Strabala, K.I., Menzel, W.P., Frey, R.A., Moeller, C.C., Gumley, L.E. (1998) Discriminating clear sky from clouds with MODIS, *Journal of Geophysical Research: Atmospheres*, 103(D24), 32141-32157. <https://doi.org/10.1029/1998JD200032>
- Boucher, O., Randall, D., Artaxo, P., Bretherton, C., Feingold, G., Forster, P., Kerminen, V.M., Kondo, Y., Liao, H., Lohmann, U., Rasch, P., Satheesh, S.K., Sherwood, S., Stevens, B., Zhang, X.Y. (2013) Clouds and aerosols, in *Climate Change 2013: The Physical Science Basis*. Edited by Stocker, T.F. *et al.*, Cambridge University Press, Cambridge, 571-657.
- Chen, T., Guestrin, C. (2016) XGBoost: A scalable tree boosting system, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, CA, 785-794. <https://doi.org/10.1145/2939672.293978>
- Chen, X., de Leeuw, G., Arola, A., Liu, S., Liu, Y., Li, Z. (2021) Joint retrieval of the aerosol fine mode fraction and optical depth using MODIS spectral reflectance over northern and eastern China: Artificial neural network method, *Remote Sensing of Environment*, 249, 112006. <https://doi.org/10.1016/j.rse.2020.112006>
- Choi, M., Kim, J., Lee, J., Kim, M., Park, Y.J., Holben, B., Eck, T.F., Li, Z., Oh, C.Y. (2020) GOCI Yonsei aerosol retrieval version 2 products: An improved algorithm and error analysis with uncertainty estimation from 5-year validation over East Asia, *Atmospheric Measurement Techniques*, 13(2), 585-618. <https://doi.org/10.5194/amt-11-385-2018>
- Cohen, J. (1960) A coefficient of agreement for nominal scales, *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>
- Cox, C., Munk, W. (1954) Measurement of the roughness of the sea surface from photographs of the sun's glitter, *Journal of the Optical Society of America*, 44(11), 838-850. <https://doi.org/10.1364/JOSA.44.000838>
- Holben, B.N., Eck, T.F., Slutsker, I., Tanré, D., Buis, J.P., Setzer, A., Vermote, E., Reagan, J.A., Kaufman, Y.J., Nakajima, T., Lavenu, F., Jankowiak, I., Smirnov, A. (1998) AERONET - A federated instrument network and data archive for aerosol characterization, *Remote Sensing of Environment*, 66(1), 1-16. [https://doi.org/10.1016/S0034-4257\(98\)00031-5](https://doi.org/10.1016/S0034-4257(98)00031-5)
- Hsu, N.C., Jeong, M.J., Bettenhausen, C., Sayer, A.M., Hansell, R., Seftor, C.S., Huang, J., Tsay, S.C. (2013) Enhanced Deep Blue aerosol retrieval algorithm: The second generation, *Journal of Geophysical Research: Atmospheres*, 118(16), 9296-9315. <https://doi.org/10.1002/jgrd.50712>
- Hsu, N.C., Tsay, S.C., King, M.D., Herman, J.R. (2004) Aerosol properties over bright-reflecting source regions, *IEEE Transactions on Geoscience and Remote Sensing*, 42(3), 557-569. <https://doi.org/10.1109/TGRS.2004.824067>
- Hu, X., Zhang, H., Liu, X., Li, Y., He, Z. (2020) Ground level PM_{2.5} estimation over urban agglomeration of China with high spatiotemporal resolution based on Himawari-8, *Science of The Total Environment*, 758, 143434. <https://doi.org/10.1016/j.scitotenv.2019.04.299>
- Inoue, T. (1985) On the temperature and effective emissivity determination of semi-transparent cirrus clouds by bispectral measurements in the 10 μ m window region, *Journal of the Meteorological Society of Japan*, 63(1), 88-99. https://doi.org/10.2151/jmsj1965.63.1_88
- Intergovernmental Panel on Climate Change (IPCC) (2021) *Climate Change 2021: The Physical Science Basis, Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge. <https://doi.org/10.1017/9781009157896>
- Kaufman, Y.J., Tanré, D., Boucher, O. (2002) A satellite view of aerosols in the climate system, *Nature*, 419(6903), 215-223. <https://doi.org/10.1038/nature01091>
- Kaufman, Y.J., Tanré, D., Remer, L.A., Vermote, E.F., Chu, A., Holben, B.N. (1997) Operational remote sensing of tropospheric aerosol over land from EOS moderate resolution imaging spectroradiometer, *Journal of Geophysical Research: Atmospheres*, 102(D14), 17051-17067. <https://doi.org/10.1029/96JD03988>
- King, M.D., Menzel, W.P., Kaufman, Y.J., Tanré, D., Gao, B.C., Platnick, S., Ackerman, S.A., Remer, L.A., Pincus, R., Hubanks, P.A. (2003) Cloud and aerosol properties, precipitable water, and profiles of temperature and water vapor from MODIS, *IEEE Transactions on Geoscience and Remote Sensing*, 41(2), 442-458. <https://doi.org/10.1109/TGRS.2002.808226>

- Landis, J.R., Koch, G.G. (1977) The measurement of observer agreement for categorical data, *Biometrics*, 33(1), 159-174. <https://doi.org/10.2307/2529310>
- Lee, K. (2013) Three Dimensional Monitoring of the Asian Dust by the COMS/GOCI and CALIPSO Satellites Observation Data, *Journal of Korean Society for Atmospheric Environment*, 29, 199-210, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2013.29.2.199>
- Lee, K.-H. (2012) Aerosol Direct Radiative Forcing by Three Dimensional Observations from Passive- and Active-Satellite Sensors, *Journal of Korean Society for Atmospheric Environment*, 28(2), 159-171, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2012.28.2.159>
- Lee, K.H., Bae, M.S. (2023) Satellite Observation Based Air Quality Study, *Journal of Korean Society Atmospheric Environment*, 39(5), 571-587, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2023.39.5.571>
- Lee, K.H., Wong, M.S., Li, J. (2022) Review of Atmospheric Environmental Change from Earth Observing Satellites, *Asian Journal of Atmospheric Environment*, 16(1), 2287-1160. <https://doi.org/10.5572/ajae.2021.147>
- Levy, R.C., Mattoo, S., Munchak, L.A., Remer, L.A., Sayer, A.M., Patadia, F., Hsu, N.C. (2013) The collection 6 MODIS aerosol products over land and ocean, *Atmospheric Measurement Techniques*, 6(11), 2989-3034. <https://doi.org/10.1175/AMSMONOGRAPHIS-D-18-0009.1>
- Li, J., Carlson, B.E., Yung, Y.L., Lv, D., Hansen, J., Penner, J.E., Liao, H., Ramaswamy, V., Kahn, R.A., Zhang, P., Dubovik, O., Ding, A., Lacis, A.A., Zhang, L., Dong, Y. (2023) Scattering and absorbing aerosols in the climate system, *Nature Reviews Earth & Environment*, 3(6), 363-379. <https://doi.org/10.1038/s43017-022-00296-7>
- Lyapustin, A., Martonchik, J., Wang, Y., Laszlo, I., Korkin, S. (2011) Multiangle implementation of atmospheric correction (MAIAC): 1. Radiative transfer basis and look-up tables, *Journal of Geophysical Research: Atmospheres*, 116(D3), D03210. <https://doi.org/10.1029/2010JD014985>
- Lyapustin, A., Wang, Y., Laszlo, I., Hilker, T., Hall, F.G., Sellers, P.J., Tucker, C.J., Korkin, S.V. (2012) Multi-angle implementation of atmospheric correction for MODIS (MAIAC): 3. Atmospheric correction, *Remote Sensing of Environment*, 127, 385-393. <https://doi.org/10.1016/j.rse.2012.09.002>
- Pavolonis, M.J., Heidinger, A.K. (2004) Daytime cloud overlap detection from AVHRR and VIIRS, *Journal of Applied Meteorology*, 43(5), 762-778. <https://doi.org/10.1175/2099.1>
- Remer, L.A., Kaufman, Y.J., Tanré, D., Mattoo, S., Chu, D.A., Martins, J.V., Li, R.R., Ichoku, C., Levy, R.C., Kleidman, R.G., Eck, T.F., Vermote, E., Holben, B.N. (2005) The MODIS aerosol algorithm, products, and validation, *Journal of the Atmospheric Sciences*, 62(4), 947-973. <https://doi.org/10.1175/JAS3385.1>
- Salomonson, V.V., Barnes, W.L., Maymon, P.W., Montgomery, H.E., Ostrow, H. (1989) MODIS: Advanced facility instrument for studies of the Earth as a system, *IEEE Transactions on Geoscience and Remote Sensing*, 27(2), 145-153. <https://doi.org/10.1109/36.20292>
- Sayer, A.M., Hsu, N.C., Bettenhausen, C., Jeong, M.J. (2013) Validation and uncertainty estimates for MODIS Collection 6 "Deep Blue" aerosol data, *Journal of Geophysical Research: Atmospheres*, 118(14), 7864-7883. <https://doi.org/10.1002/jgrd.50600>
- Shimizu, A., Sugimoto, N., Matsui, I., Arao, K., Uno, I., Murayama, T., Kagawa, N., Aoki, K., Uchiyama, A., Yamazoe, A. (2004) Continuous observations of Asian dust and other aerosols by polarization lidars in China and Japan during ACE-Asia, *Journal of Geophysical Research: Atmospheres*, 109(D19), D19S17. <https://doi.org/10.1029/2002JD003253>
- Várnai, T., Marshak, A. (2009) MODIS observations of enhanced clear sky reflectance near clouds, *Geophysical Research Letters*, 36(6), L06807. <https://doi.org/10.1029/2008GL037089>
- Wei, J., Li, Z., Peng, Y., Sun, L. (2019) MODIS collection 6.1 aerosol optical depth products over land and ocean: Validation and comparison, *Atmospheric Environment*, 201, 428-440. <https://doi.org/10.1016/j.atmosenv.2018.12.004>
- Yu, G.-H., Cho, S.-Y., Bae, M.-S., Lee, K.-H., Park, S.-S. (2015) Investigation of PM_{2.5} Pollution Episodes in Gwangju, *Journal of Korean Society Atmospheric Environment*, 31(3), 269-286, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2015.31.3.269>

Author Information & Contribution

이권호 (강원대학교 대기환경과학과 교수, 강원대학교 복사-위성 연구소 소장, kwonho.lee@gmail.com) Conceptualization, Data curation, Formal analysis, Funding acquisition, Investigation, Methodology, Project administration, Resources, Software, Supervision, Validation, Visualization, Writing - original draft, Writing - review & editing