

논문

# OCO-2 위성자료와 딥러닝을 이용한 한반도 XCO<sub>2</sub> 모니터링과 예측 Monitoring and Forecasting XCO<sub>2</sub> Using OCO-2 Satellite Data and Deep Learning

이권호<sup>1),2)</sup>, 김관철<sup>3),\*</sup>

<sup>1)</sup>국립강릉원주대학교 대기환경과학과, <sup>2)</sup>국립강릉원주대학교 복사-위성연구소,  
<sup>3)</sup>차세대융합기술연구원 첨단환경감시센터

Kwon-Ho Lee<sup>1),2)</sup>, Kwanchul Kim<sup>3),\*</sup>

<sup>1)</sup>Department of Atmospheric & Environmental Sciences, Gangneung-Wonju National University (GWNW), Gangneung, Republic of Korea

<sup>2)</sup>Research Institute for Radiation-Satellite, Gangneung-Wonju National University (GWNW), Gangneung, Republic of Korea

<sup>3)</sup>Advanced Environmental Monitoring Center, Advanced Institute of Convergence Technology (AICT), Suwon, Republic of Korea

접수일 2024년 9월 13일  
수정일 2024년 10월 10일  
채택일 2024년 10월 10일

Received 13 September 2024  
Revised 10 October 2024  
Accepted 10 October 2024

\*Corresponding author  
Tel : +82-(0)31-888-9411  
E-mail : fehhouse@snu.ac.kr

**Abstract** Carbon dioxide (CO<sub>2</sub>) is a greenhouse gas that contributes to global scale climate change, but its spatial and temporal variations at the regional scale are not well understood. This study aims to investigate the long-term spatio-temporal variations of atmospheric CO<sub>2</sub> concentrations over the Korean Peninsula, utilizing satellite-observed XCO<sub>2</sub> data from September 2014 to December 2023. Analysis reveals that the average XCO<sub>2</sub> concentration in the Seoul metropolitan area ( $416.34 \pm 2.03$  ppm) is notably higher than in other regions, highlighting the uneven distribution of emissions. Furthermore, seasonal patterns and long-term trends indicate a consistent year-on-year increase in XCO<sub>2</sub> levels. To enhance our understanding of future CO<sub>2</sub> trends, we employed a CNN-LSTM deep learning model, which yielded promising accuracy metrics (MSE = 3.10 ppm, RMSE = 1.73 ppm, MAE = 1.49 ppm, MAPE = 0.36%). The model's predictions suggest a continued rise in XCO<sub>2</sub> concentrations, projecting a peak of 432 ppm in 2024~2025. Without substantial efforts to mitigate carbon emissions, further increases in CO<sub>2</sub> levels are anticipated. This research underscores the urgent need for effective climate policies to address rising greenhouse gas concentrations.

**Key words:** Carbon dioxide, Deep learning, Climate change, Global warming

## 1. 서론

이산화탄소(CO<sub>2</sub>)는 온실가스 중 한 가지로서 지구의 평균 기온을 조절하는 데 기여함으로써, 기후 변화와 생태계 변화 등 지구 시스템의 다양한 분야에서 중요한 역할을 담당한다. 최근까지 대기 중 이산화탄소 농도는 산업화 이전보다 약 40% 이상 증가했으며, 이는 기온 상승과 극단적인 기후 현상과 밀접한 관련이 있다(IPCC, 2021, 2014). 기후 변화로 인한 극단적인 기상 현상은 인명 피해와 질병의 확산을 초래할 수 있

다(Hathaway and Maibach, 2018; Frumkin *et al.*, 2008). 그리고 대기 중 이산화탄소 농도의 증가는 식물종에 따라 광합성 속도를 증가시키거나 적응하지 못하는 경우도 있으며, 농업 생산성 감소를 유발하여 경제적 손실로 이어질 수 있다(Lobell *et al.*, 2011; Reddy *et al.*, 2010). 이와 같이, 이산화탄소 농도 증가에 따른 다양한 문제가 제기됨에 따라 이산화탄소 농도의 모니터링과 감소를 위한 노력이 필요하다.

대기 중 이산화탄소의 농도 측정은 지상 관측 또는 원격탐지를 통하여 가능하다. 먼저 고정식 기상 관측

소에서는 정밀한 관측 센서를 사용하여 연속적으로 대기 중 이산화탄소 농도를 측정하며, 주로 장기적인 변화 추세를 파악하는 데 사용된다. 예를 들어, 미국 하와이에 위치한 Mauna Loa Observatory에서 수집된 데이터는 청정 대기 조건에서 지구 대기 중 이산화탄소 농도의 증가 추세를 입증하는 중요한 자료로 사용되었다(Keeling *et al.*, 2008). 그리고 이동식 측정 장비는 다양한 환경과 조건에서 이산화탄소 데이터를 획득할 수 있다(Lee *et al.*, 2017). 인공위성은 넓은 지역을 대상으로 대기 조성물질을 측정할 수 있으며(Lee and Bae, 2023; Lee *et al.*, 2022), 최근의 인공위성 관측 기술은 전 지구 이산화탄소 농도를 측정할 수 있게 되었다(Eldering *et al.*, 2017). 또한 위성 관측자료는 다양한 모델링 소스 자료와 함께 온실가스 배출량을 산정하는 데 사용된다(Andrade *et al.*, 2024).

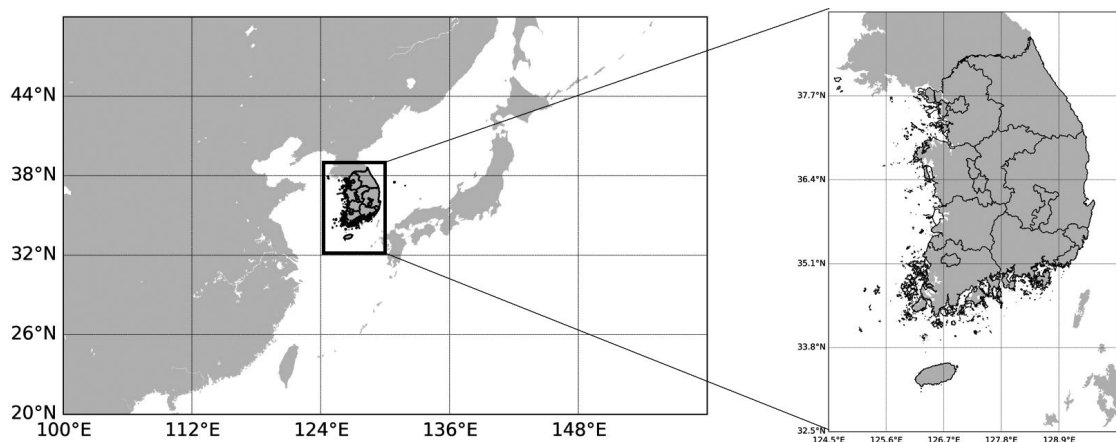
한반도는 급격한 산업화, 거대 도시화, 농축산업 활동의 변화 등으로 인해 이산화탄소 배출 패턴과 대기 중의 농도가 영향을 받고 있는 것으로 보고되었다(Park and Hong, 2013). 국내에서도 지점관측이나 이동관측을 통하여 지역 내 배출원에 대한 감시 및 농도 수준에 관한 정보를 제공하였다(Lee *et al.*, 2019). 보다 과거에는 GOSAT의 관측자료와 배출량 모델 및 화학예측 모델을 사용하여 한반도 인근지역의 이

산화탄소 농도 변화를 분석하기도 하였다(Shim *et al.*, 2018). 한반도 지역에서 이산화탄소 관련 연구들은 관측영역이나 관측 해상도의 한계로 인하여 지역 단위 수준의 농도 변화 및 미래 추세에 관한 정보를 제공하지 못한 단점이 존재한다. 따라서 본 연구에서는 장기간 지속적으로 이산화탄소를 관측하고 있는 OCO-2 위성자료를 이용하여 한반도 지역의 이산화탄소 농도에 대한 시공간적 변화와 미래 변화에 대한 예측 수준을 평가하였다. 이를 위하여 인공위성이 최초 관측을 수행한 2014년 9월부터 2023년 12월까지의 관측자료를 이용하여 각 행정구역별 이산화탄소의 변화 및 특성을 분석하였다. 그리고, 이산화탄소 농도 변화 추세 및 미래 예측을 위하여 딥러닝 기법을 적용하였다. 각 지역별 이산화탄소의 현황과 미래 예측 분석을 통하여 국내 이산화탄소 수준 및 기후 변화 영향 요인에 관한 증거를 제시하는 것을 목적으로 하였다.

## 2. 자료 및 방법

### 2.1 연구대상 지역

본 연구는 대한민국의 행정구역을 포함하는 북위 32.5~39도와 동경 124.5~130도에 해당하는 정방형 지



**Fig. 1.** The study area is a rectangular region corresponding to 32.5~39 degrees north latitude and 124.5~130 degrees east longitude.

역을 대상으로 하였다. 그림 1은 연구대상 지역에 대한 지리적 위치 및 영역의 범위를 나타낸다. 대한민국은 2023년 현재 총 인구 약 5177만 명이며, 이 중 약 51%에 해당하는 2623만 명(서울: 938만 명, 인천: 302만 명, 경기도: 1382만 명)이 수도권역의 인구이다(인구총조사, <https://kosis.kr/>). 뒤를 이어 부산(328만 명)과 경상남도(327만 명)의 순으로 인구밀집 지역이다.

## 2.2 위성 관측자료

현재까지 이산화탄소의 시공간적 관측이 가능한 인공위성자료 중 OCO-2 위성자료를 사용하였다. OCO-2 위성은 2014년 7월 2일 미국 캘리포니아의 반덴버그 공군 기지에서 발사되었으며, 2014년 9월 6일부터 정기적인 관측 산출물을 제공하고 있다. OCO-2는 고도 705 km에서 태양-동기 극궤도(적도 통과 시간 13:36 LT)를 따라 지구 관측을 수행하며(재방문 주기 약 16일)(Crisp, 2015), 비교적 좁은 동서방향 관측 범위(약 0.4~1.29 km)를 따라 2.25 km 길이의 8개의 관측영역을 측정한다(Crisp *et al.*, 2008). OCO-2 위성에 탑재된 분광센서 기기는 3개의 근적외선 대역(0.76  $\mu\text{m}$ , 1.6  $\mu\text{m}$ , 2.1  $\mu\text{m}$ )에서 분광 관측을 수행한다. 이렇게 관측된 스펙트럼은 포워드 모델의 입력 파라미터를 최적화하여 미리 계산된 스펙트럼과의 최적 추정 접근법을 적용하여 이산화탄소 농도를 역으로 추정하는 데 사용된다. OCO-2의 이산화탄소 산출 알고리즘은 대기 중 이산화탄소 산출 알고리즘(Atmospheric CO<sub>2</sub> Observations from Space (ACOS))으로 불리우며, XCO<sub>2</sub>를 산출하는 데 사용된다(O'Dell *et al.*, 2012). XCO<sub>2</sub>는 대기 고도별 이산화탄소의 수 밀도(Number density)를 적분한 값으로써, 대기 칼럼 내에 존재하는 이산화탄소의 평균 건조 몰 분율을 의미한다. OCO-2의 1.6  $\mu\text{m}$ , 2.1  $\mu\text{m}$  채널은 이산화탄소 흡수 밴드, 0.76  $\mu\text{m}$  채널은 산소 흡수 밴드를 포함하므로, 건조 대기의 몰 분율과 이산화탄소에 의한 광 흡수비를 결정할 수 있다. 건조공기 중 산소 분율은 일정하므로 각 채널별 관측값의 비율을 통하여 이산화탄소의 몰 분율이 결정된다(식 (1)).

$$XCO_2 = 0.20935 \frac{\int N_{CO_2} ds}{\int N_{O_2} ds} \quad (1)$$

위 식에서  $N_{CO_2}$ 는 이산화탄소 분자의 수 밀도,  $N_{O_2}$ 는 산소 분자의 수 밀도,  $s$ 는 광 경로이다. 본 연구에서는 2014년 9월부터 2023년 12월까지 사용 가능한 바이어스 보정된 XCO<sub>2</sub> 데이터를 포함하여 최신 재처리된 파일(버전 11.1r)을 사용하였다. OCO-2 XCO<sub>2</sub> 산출물과 지상관측 이산화탄소 농도와의 비교 결과는 약 1.3 ppm 이내의 오차범위 수준을 가지는 것으로 평가되었다(Reuter *et al.*, 2017).

## 2.3 이산화탄소 배출량 자료

위성 관측자료와의 비교를 위하여 탄소 배출량 자료를 이용하였다. 인위적 이산화탄소에 대한 오픈 데이터 인벤토리(Open-Data Inventory for Anthropogenic Carbon dioxide (ODIAC))는 1 km의 공간해상도를 가지는 화석 연료 기원의 이산화탄소 배출량에 관한 데이터셋으로, 2009년 일본 국립환경연구소(National Institute of Environmental Studies (NIES))에서 처음 개발되었다(Oda and Maksyutov, 2011). ODIAC은 개별 발전소의 배출량과 야간 조명 데이터 세트를 통합하여 이산화탄소 배출량을 추정하는 방법론이 사용되었으며, 첫 번째 버전 이후 계속적으로 업데이트되고 있다(Oda *et al.*, 2018).

## 2.4 딥러닝 기법

한반도 지역에서 관측된 이산화탄소의 시계열 분석 및 예측을 위하여 딥러닝 기법 중 Convolutional Neural Networks - Long Short-Term Memory (CNN-LSTM) 기법을 사용하였다. CNN-LSTM 기법은 시계열 자료 예측에서 뛰어난 성능을 발휘하는 딥러닝 모델로, CNN과 LSTM 네트워크를 결합하여 효과적으로 시계열 데이터를 분석하는 방법이다. 특히, CNN은 공간적 데이터의 패턴을 인식하는 데 효과적이며, 다차원의 영상 처리뿐 아니라 시계열 데이터의 특징을 추출할 때 유용한 것으로 알려져 있다(Shi *et al.*, 2015). 1D 합성곱 레이어는 시계열 입력 데이터의 각 시점에서

이웃하는 값들과의 관계를 파악하여, 지역적 특성과 변화를 감지할 수 있다. 즉, XCO<sub>2</sub> 농도의 변화는 시간적 흐름에 따라 나타나는 특정 패턴이나 경향성을 반영하기 때문에, 1D 합성곱을 통해 이러한 시계열 특성을 분석하는 것이 적절하다. 이후 연결된 LSTM에서는 CNN에서 추출된 공간적 특징을 기반으로 데이터의 시간적 종속성을 모델링하게 된다.

LSTM은 시계열 데이터의 장기적인 종속성을 학습하는 데 유리한 Recurrent Neural Network (RNN)의 확장 모델로서, 셀 상태와 게이트 메커니즘을 사용하여 시계열 변화에 관한 주요 정보를 유지하고 불필요한 정보를 걸러낸다. 이를 통해 LSTM은 단시간 동안의 변화 패턴과 장기적인 추세 의존성을 효과적으로 학습할 수 있다. 일반적으로, LSTM은 cell state, forget gate, input gate, output gate의 네 가지 파트로 구성되며, 식 (2)와 같이 입력데이터에 대한 가중치와 전차가 포함된 식으로 표현된다.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

위 식에서  $\sigma$ 는 활성화함수로서 입력값이나 출력값의 상태를 필터링하거나 전환하기 위하여 사용된다.  $W_f$ 와  $b_f$ 는 각각 forget gate의 가중치 행렬과 잔차,  $x$ 는 시계열 자료에서 얻은 다차원의 변수 입력값이다.

그림 2는 본 연구에서 사용된 딥러닝 기법에 의한

데이터 처리과정을 나타낸다. CNN-LSTM 결합 모델에서는 시계열 입력 데이터의 지역적 특성을 추출하기 위하여 필터를 사용해 합성곱 연산을 수행하여 주요 특징을 추출한다. 이 모델의 특징 추출기는 1D 합성곱 레이어와 최대 풀링 레이어를 사용하며, 뉴런의 활성화 함수로 Rectified linear units (ReLU) 함수를 사용하여 기존의 시그모이드 및 탄젠트 활성화 함수의 소실 경사도 문제를 해결한다. 이후 CNN의 마지막 층에서 산출된 특징맵을 평탄화(Flatten)하여 1차원 배열로 변환한다. 이 과정을 통해 CNN에서 추출한 특징값이 LSTM으로 전달된다. LSTM에서는 CNN 과정에서 획득된 평탄화된 특징들 간의 순서와 시간적 상관관계를 고려하여 예측에 필요한 주요 패턴을 학습한다. 최종 단계에서 LSTM의 출력값은 완전 연결층(Fully Connected Layer)을 거친 후 예측값을 출력한다. CNN-LSTM 기법의 장점으로는 CNN을 이용한 공간적 특징 변화 예측, LSTM을 이용한 시간 변화 특징을 학습함으로써 두 기법의 강점을 극대화할 수 있다. 그리고 복잡한 시계열 데이터에 포함된 비선형적 패턴 추출과 노이즈에 의한 영향을 최소화할 수 있으므로 예측과정에서의 오류를 최소화할 수 있다.

CNN-LSTM 모델이 시계열 자료의 변화를 설명하는 데 적합한지 확인하기 위해 식 (3)~(7)과 같은 Mean Square Error (MSE), Root Mean Square Error

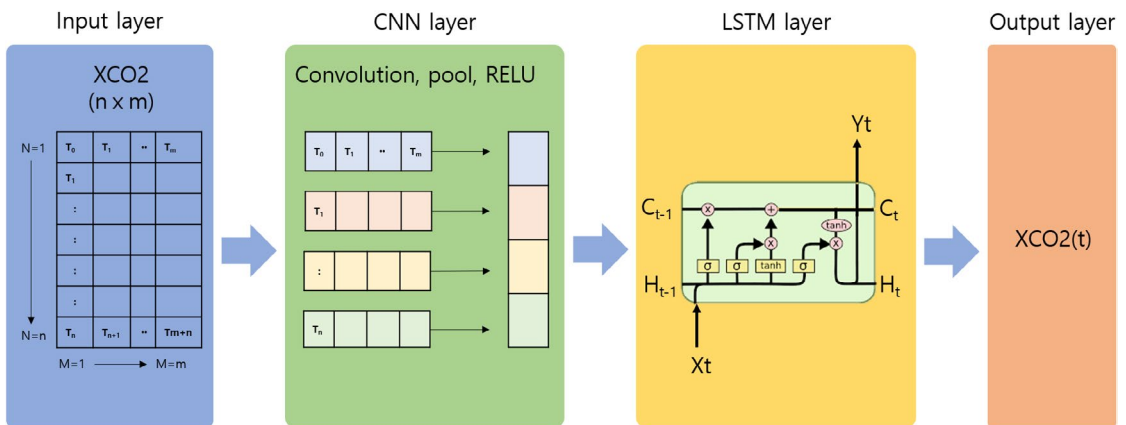


Fig. 2. Configuration of CNN-LSTM model to train and predict XCO<sub>2</sub> time series data.

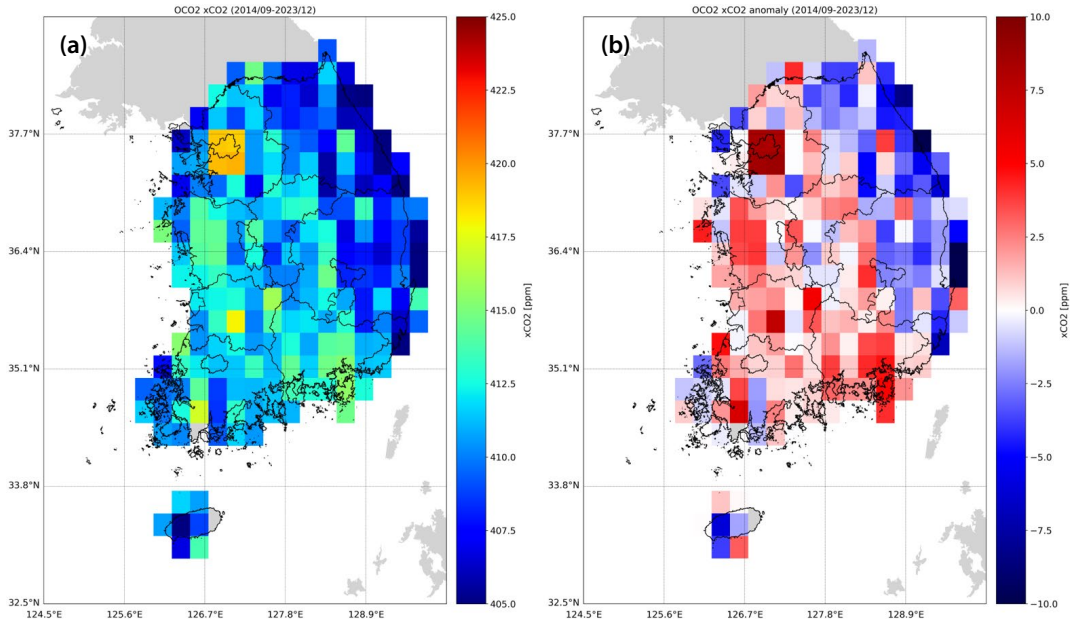


Fig. 3. (a) Mean OCO-2 XCO2 and (b) anomaly ( $\Delta XCO_2$ ) over study region (32.5~39, 124.5~130).

(RMSE), Mean Bias (MB), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE)를 계산하여 모델의 성능을 평가하였다. 일반적으로, 참값과 모델 예측값과의 상대비교 범위를 표현하는 이 지수값들은 적은 값일수록 모델의 예측능력이 좋은 것으로 판단할 수 있다.

$$MSE = \frac{1}{n} \sum_{i=0}^n (y_i - \bar{y}_i)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (y_i - \bar{y}_i)^2} \quad (4)$$

$$MB = \frac{1}{n} \sum_{i=0}^n (y_i - \bar{y}_i) \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - \bar{y}_i| \quad (6)$$

$$MAPE = \frac{100}{n} \sum_{i=0}^n \left| \frac{y_i - \bar{y}_i}{y_i} \right| \quad (7)$$

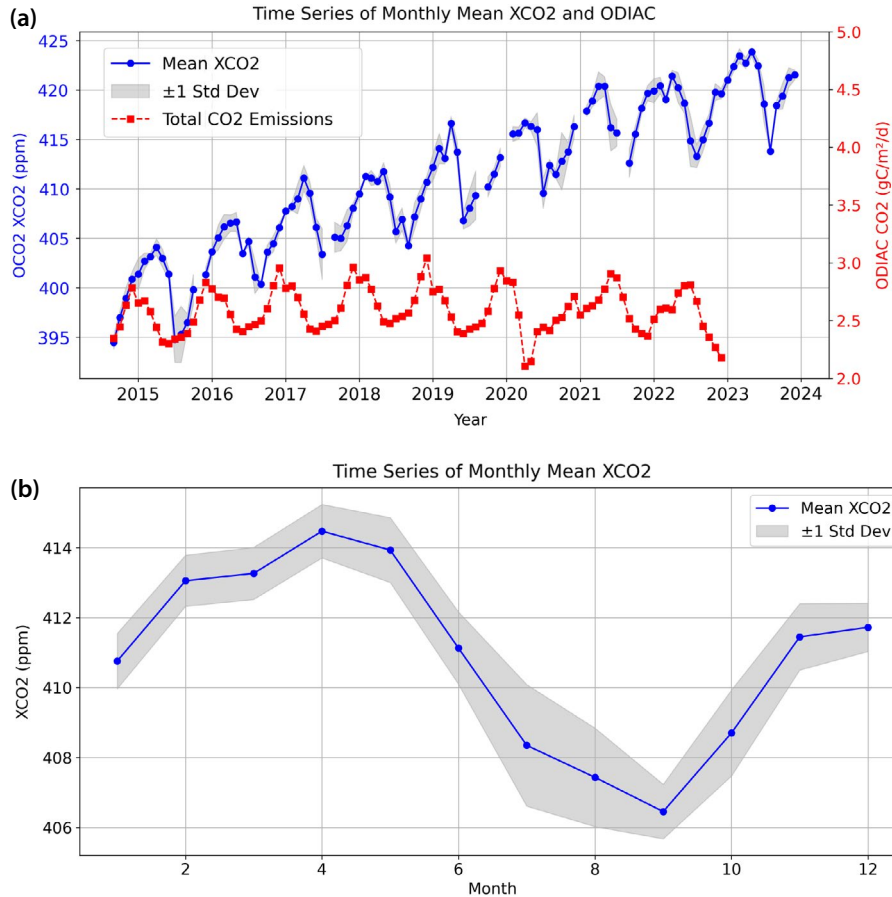
위 식에서  $y$ 는 실제 관측값 또는 참값,  $\bar{y}$ 는 모델 예측값 또는 실험값,  $n$ 은 사용된 자료의 총 개수를 의미한다.

### 3. 결과 및 토의

#### 3.1 XCO2 시공간 변동 특성

그림 3(a)는 관심대상 지역에서 2014년 9월부터 2023년 12월까지 관측된 XCO2 농도값에 대한 전체 기간 평균값을 나타낸다. 각 격자는 0.25도 간격으로 채구성하였으며, 격자별 평균은 최소 100개의 유효 측정값이 사용가능한 경우에 대해서만 계산되었다. 대기 중으로 배출된 이산화탄소가 배출원과 계절 변화, 그리고 기상 조건에 따라 변화하기 때문에 인위적 배출량에 대한 기여도를 판단하기 어렵다. 따라서, 광역 평균값이나 중앙값은 자연적인 요인의 영향을 크게 받으며 변화하는 값으로 가정하여, 이보다 큰 값을 인위적 배출에 기여도가 높은 값으로 가정하였다. 그림 3(b)는 XCO2 고농도 지역을 분리하기 위하여 전체 영역에 대한 평균값을 개별 관측치에서 차감한 값(식 (8))을 표시하였다.

$$\Delta XCO_2 = XCO_{2,ij} - \frac{\sum_{ij} XCO_{2,ij}}{\sum_{ij} n} \quad (8)$$



**Fig. 4.** (a) Time series of the monthly mean OCO-2 XCO<sub>2</sub> with ODIAC CO<sub>2</sub> emission and (b) OCO<sub>2</sub> XCO<sub>2</sub> by month during 2014~2023.

이러한 상대적 지역 차원의 편차 계산은 데이터의 계절 변화와 관측 포인트의 불균형으로 인한 편향성을 감소시킬 수 있다.

그림 3(a)에서 XCO<sub>2</sub> 고농도 지역은 주요 인구밀집 지역인 서울 주변 수도권 지역에서 가장 높은 농도 분포를 보였으며, 충청북도-전라북도를 포함하는 서부 권역, 그리고 경상남도 지역에서 410 ppm 이상의 상대적으로 높은 XCO<sub>2</sub> 수치가 관측되었다. 그림 3(b)에서는 식 (8)로부터 계산된 공간적 평균값 대비 변화 수치를 나타낸다. 지역 평균 대비 높은 값은 수도권과 서부권역에서 전부 양의 수치를 나타냈으며, 강원권과 경북권에서는 음의 수치값을 보였다. 따라서, 장기

간 이산화탄소의 관측 결과를 통하여 한반도의 이산화탄소 분포는 지역적으로 불균형한 분포를 나타내고 있음이 확인되었다.

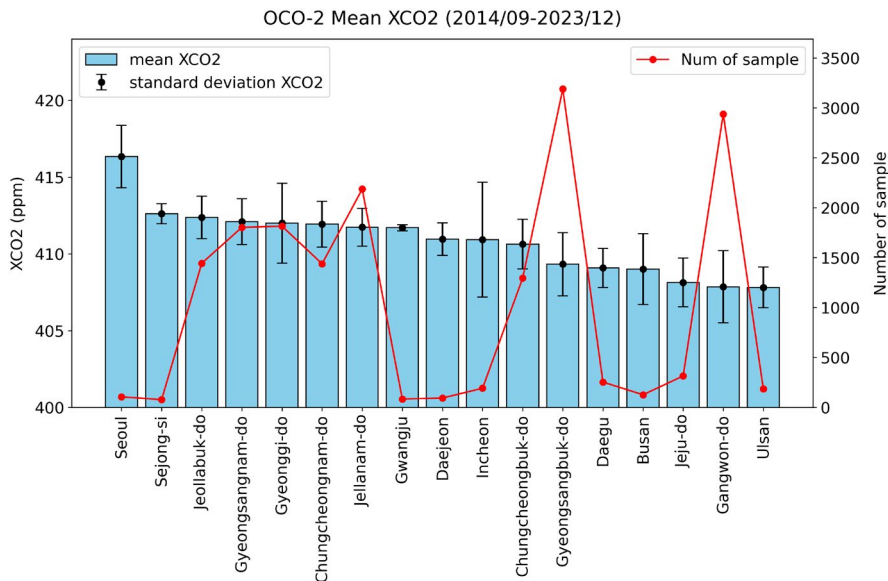
그림 4(a)는 2014년 9월부터 2023년 12월까지 연구 대상 지역에서 장기간 동안의 OCO-2 XCO<sub>2</sub> 농도와 ODIAC 이산화탄소 배출량에 관한 시계열 변화를 나타낸다. 각 월의 대기 중 XCO<sub>2</sub> 농도는 전년도 같은 달의 농도보다 높았으며, 연평균값도 매년 증가하였다. 이는 한반도에서 XCO<sub>2</sub> 농도가 지속적으로 증가했음을 반영한다. ODIAC 이산화탄소 배출량의 변화에서는 2014년부터 2019년까지 배출량이 지속적으로 증가하였으나, 2020년 코로나 팬데믹 기간 동안 일시

적으로 크게 감소 후 배출량은 예년 수준으로 회복하였다. 특이사항으로는 2021년 이후 배출량의 최대값이 겨울철이 아닌 여름철에 나타나고 있다는 점이다. 이는 팬데믹 이후 산업 활동의 회복과 계절적 에너지 생산의 변화로 인하여 여름철에 배출량이 증가한 것으로 판단된다. 이러한 국내 이산화탄소 배출량의 변화는 원인과 영향에 대한 정밀한 분석이 필요하지만, 본 연구의 범위를 벗어나므로 향후 추가 연구를 통하여 분석할 예정이다.

2014년부터 2023년까지 기간 중 각 월별 평균 XCO<sub>2</sub> 농도 변화는 그림 4(b)와 같다. 한반도의 XCO<sub>2</sub>는 10월부터 점차 증가하면서 이듬해 4월에 최대값을 기록하였으며, 이후 점차 감소하여 9월에 최저값을 나타냈다. 일반적으로, 대기 중 이산화탄소의 계절 변화는 인위적 활동과 식물의 상태와 관련지어 설명된다(Graven *et al.*, 2013; Peters *et al.*, 2007). 겨울철에는 난방 사용으로 인한 에너지 수요가 증가하면서 화석연료 사용이 늘어나고, 이에 따라 이산화탄소 배출량이 크게 증가한다. 그리고 대부분의 식물에서 광합성이 거의 일어나지 않기 때문에 대기 중 흡수 비율이 감소한다. 이

로 인해 겨울철 대기 중 이산화탄소가 점차 축적되고, 광합성이 본격적으로 시작되는 봄철이 되기 전까지 축적된 이산화탄소 농도는 최고치를 기록하게 된다. 여름이 가까워지면 난방 사용량이 줄고 식물의 광합성이 증가하여 점차 대기 중 CO<sub>2</sub>를 많이 흡수하게 되어 여름철에 최소값이 나타나게 된다. 하지만, 한여름의 냉방 사용량의 증가는 이산화탄소 배출을 증가시킴으로써 7, 8월의 감소 추세를 상대적으로 느리게 발생한다. 따라서, XCO<sub>2</sub>의 월별 변화 패턴은 인위적 배출 및 식물의 광합성 주기와 대기-지표 탄소 플럭스의 변동에 따른 영향을 크게 받을 것이다.

그림 5는 2014년 9월부터 2023년 12월까지 OCO-2에서 관측된 XCO<sub>2</sub> 농도에 대해 대한민국의 각 행정구역별 평균과 표준편차값, 그리고 통계에 사용된 화소의 수를 나타낸다. 일반적으로, 표본의 수가 많을수록 평균값은 모집단의 평균에 근접하고 표준편차의 신뢰도가 증가한다. 본 연구에서 사용된 격자화된 XCO<sub>2</sub> 자료는 공간상의 관측손실값이 발생되지 않았으나, 각 행정구역별 총 유효화소수의 크기는 면적에 크게 의존한다. 즉, 광역시와 특별시 단위의 행정구역



**Fig. 5.** Average XCO<sub>2</sub> concentrations by administrative region in Korea. Error bars represent  $\pm 1\sigma$  for each region. Numbers of samples used in statistics is shown as red line.

은 100개 이하의 화소값이 사용된 반면, 제주도 (315 개)를 제외한 도 단위의 행정구역은 1000개 이상(경상도 최대 3188개)이다. 그림 5의 결과에서는 각 행정 구역별 표본의 수가 다름에도 불구하고, 표본의 수에 따른 표준편차의 변화가 선형적으로 나타나지 않으므로 각 지역별 유효한 통계값으로 간주될 수 있다.

이 결과에서는 서울이 가장 높은 XCO<sub>2</sub> 농도인  $416.34 \pm 2.03$  ppm을 기록하였다. 서울의 면적이 타 행정지역보다 적음에도 불구하고 타 지역 대비 인구 밀집이 높은 지역이므로, 전국에서 가장 높은 이산화탄소 배출이 이러한 대기 중의 농도값을 높게 하는 주요 원인으로 작용할 수 있다. 그 다음으로는 세종시  $412.63 \pm 0.65$  ppm, 전라북도  $412.37 \pm 1.38$  ppm, 경상남도  $412.10 \pm 1.50$  ppm, 경기도  $412.01 \pm 2.60$  ppm, 충청남도  $412.00 \pm 1.50$  ppm의 순으로 나타났으며, 서울을 제외한 상위 5개 지역 모두 412 ppm 근처의 값을 나타냈다. 반대로 울산  $407.82 \pm 1.33$  ppm과 강원  $407.86 \pm 2.35$  ppm은 상대적으로 낮은 농도를 보였다. 울산은 산업시설이 밀집되어 있음에도 불구하고 인구 밀집이 높지 않고 해양이 인접해 있는 특성이 반영되어 최저값이 나타난 것으로 보인다. 강원도는 상대적으로 공간적 영역이 넓지만 인구가 적고 주요 산업시설 또한 해안가에 위치하고 있는 것을 반영한 결과로 판단된다.

지역별 표준편차 범위는 인천이  $\pm 3.74$  ppm으로 가장 높은 변동성을 기록하였으며, 이는 특정 환경 요인이나 산업 활동의 공간적 불규칙성을 반영한다. 뒤를 이어 경기도  $\pm 2.60$  ppm, 강원도  $\pm 2.35$  ppm, 부산  $\pm 2.31$  ppm, 경상북도 2.06 ppm, 서울 2.03 ppm의 순으로  $\pm 2$  ppm 근처의 값을 나타냈다. 이러한 결과는 타 지역 대비(주로  $< 1.6$  ppm) 행정구역 내 지역 변동성이 상대적으로 높은 것을 의미한다. 그리고 지역별 XCO<sub>2</sub> 농도값의 차이는 주로 인구밀집도, 산업 구조 및 환경 조건에 의존하여 나타나는 결과일 것이다. 특히, 서울과 인천, 경기도를 포함하는 수도권 지역의 높은 XCO<sub>2</sub> 농도는 국내 온실기체의 높은 현황 수준을 반영하는 결과로서, 이에 대한 체계적인 관리 방안이

필요함을 시사한다.

### 3.2 딥러닝 기반 XCO<sub>2</sub> 예측

OCO-2 위성으로 관측된 장기간 XCO<sub>2</sub>의 변화는 계절 변화와 장기 추세 변화 특성을 가지고 있는 시계열 자료임이 확인되었다. 이러한 시계열 특성으로부터 이산화탄소 농도에 기여하는 요인을 구분하는 것과 미래 추세 예측에 대한 딥러닝 기반 분석을 수행하였다. 먼저, XCO<sub>2</sub>의 시계열 분해(Time Series Decomposition (TSD))를 이용하여 시계열 데이터를 추세(Trend), 계절성(Seasonality), 그리고 잔차(Residual)로 분리하였다. 그림 6의 추세는 XCO<sub>2</sub>의 장기적인 방향성을 나타내며, 2014년 약 400 ppm으로부터 2023년 420 ppm으로 약 20 ppm이 증가하였으므로 전체 관측 기간 동안 증가 경향을 확인할 수 있다. XCO<sub>2</sub>의 계절성은 일정 기간 동안 규칙적으로 반복되는 주기적 변동 패턴을 나타낸다. 계절성에 영향을 미치는 주요인은 식물의 광합성 활동에 따른 계절적 변화를 반영한다. 국내 평균값의 범위는 약  $\pm 1$  ppm으로서 진동하는 변화를 나타낸다. 마지막으로 잔차는 시계열 관측 데이터에서 추세 성분과 계절 성분을 제거한 후 남는 불규칙적인 변동 부분으로 결정된다. XCO<sub>2</sub>의 잔차 범위는 약 1 ppm을 기준으로 매년 불규칙한 변화를 나타내고 있으나 상대적으로 잔차값이 증가한 2016년 여름과 2019년 늦은 봄-여름 기간에 감소한 시점이 확인된다. 이러한 불특정 기간 동안의 비정상적인 XCO<sub>2</sub> 증가는 산업 활동 증가 또는 산발 활동의 발생 등으로 인한 단기적 이벤트가 발생한 것이 한 원인이 될 수 있다. 실제로 2016년에는 강한 엘니뇨가 발생하여 CO<sub>2</sub> 농도가 일시적으로 증가하였음이 보고되기도 하였다(Chatterjee *et al.*, 2017). 이와는 반대로 2019년 잔차의 감소는 산업 활동이나 교통량 감소 등으로 인해 CO<sub>2</sub> 배출이 줄어든 경우를 주요 원인으로 고려할 수 있다.

미래의 XCO<sub>2</sub> 농도값을 예측하기 위하여 그림 2에서 설명된 CNN-LSTM 결합모델을 사용하였다. 입력자료의 구성은 전국 단위 각 월별 XCO<sub>2</sub> 농도 데이



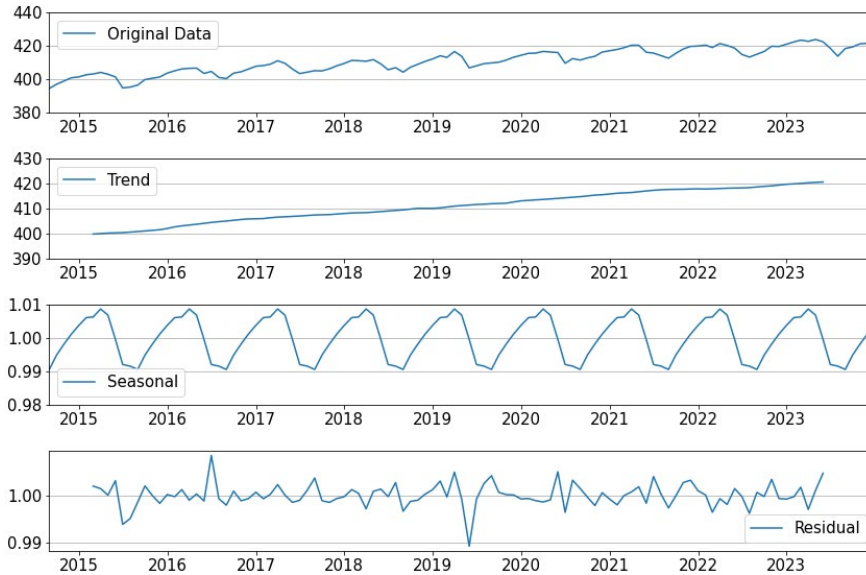


Fig. 6. Decompositions of observed XCO<sub>2</sub> concentrations (ppm) time series in Korea.

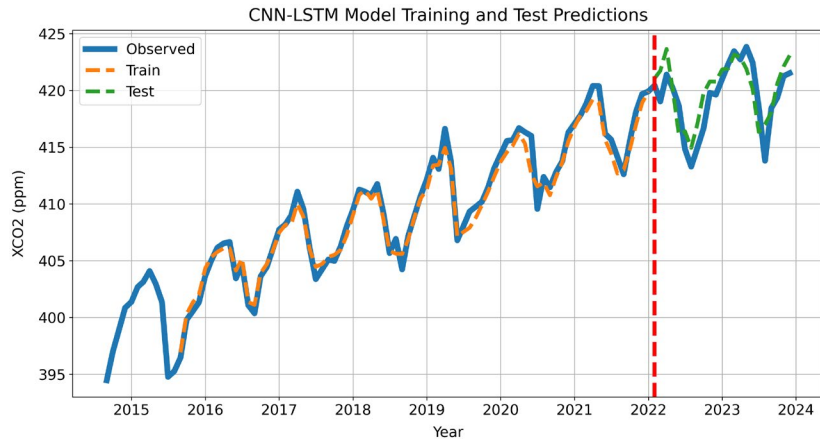
터셋으로서 12개월 단위의 데이터를 기준으로 다음 1개월의 XCO<sub>2</sub> 농도값에 대한 관계를 텐서로 재구성하여 모델의 학습과 테스트를 위하여 사용하였다. CNN-LSTM 모델의 구성은 CNN, Max Pooling, Flatten, LSTM, Dense를 포함하는 5개의 은닉층(Hidden layer)으로 구성하였다. 일반적으로, Max Pooling은 CNN에서 주로 사용되는 다운샘플링 기법으로, 입력 데이터의 공간적 크기를 줄이면서 가장 중요한 정보를 유지하는 역할을 담당한다. Flatten은 다차원 배열을 1차원 배열로 변환하여 LSTM에 연결한다. Dense Layer는 입력 벡터에 가중치를 곱하고 편향을 더한 후, 활성화 함수를 적용함으로써 비선형성을 계산한다. 모델의 하이퍼 파라미터는 최적의 성능 구현을 위하여 다양한 변수값이 테스트되었으며, 예측 성능과 효율의 최적화 및 과적합 방지를 위하여 Epoch는 3000회, Batch Size는 100, Learning Rate는 0.01로 설정하였다.

CNN-LSTM 모델의 성능평가를 위하여 2014~2022년 기간과 2023~2024년 기간 동안의 XCO<sub>2</sub> 데이터를 각각 학습용과 테스트용 데이터로 구분하였다. CNN-

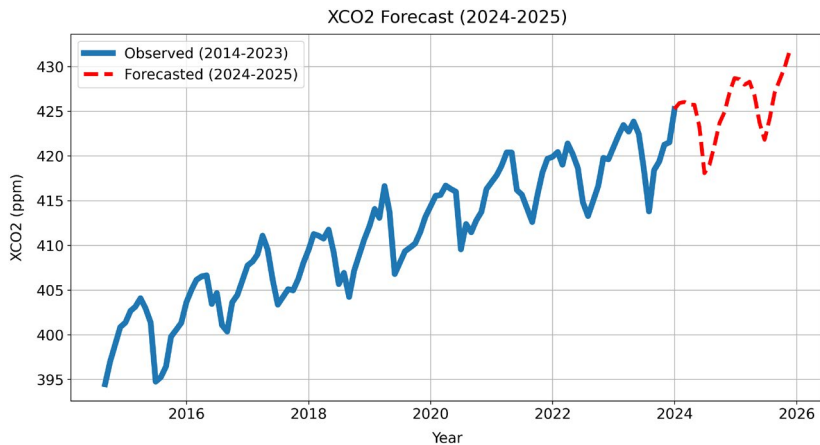
Table 1. List of validation indices for training and testing results of CNN-LSTM models used in this study.

Mode	MAE	MSE	RMSE	MB	MAPE
Train	0.66	0.69	0.83	-0.31	0.16
Test	1.49	3.10	1.73	0.60	0.36

LSTM 모델의 수행 결과에 대한 정확도 검증지수값은 표 1에 나열하였다. 모델의 학습을 통한 예측값과 학습기간 동안 실제 관측값과의 비교 결과 MAE=0.66 ppm, MSE=0.69 ppm, RMSE=0.83 ppm, MB=-0.31 ppm, MAPE=0.16%의 범위를 획득하였으며, 학습 결과에 대한 정확도가 매우 높게 나타났다. 이렇게 학습된 CNN-LSTM 모델은 학습기간 이후의 약 2년 기간 동안의 테스트용 입력자료를 이용하여 예측을 수행하였으며, 그 결과는 MAE=1.49 ppm, MSE=3.10 ppm, RMSE=1.73 ppm, MB=0.60 ppm, MAPE=0.36%의 범위를 획득하였다. 모델의 테스트 결과를 통하여 학습 결과 대비 다소 오차범위가 증가한 것을 확인할 수 있었다. 그러나 두 경우 모두 MAPE 값이 1%보다 적은 수준이므로 CNN-LSTM 모델의 성능이 XCO<sub>2</sub>의



**Fig. 7.** Monthly time series of the observed (blue), of a CNN-LSTM model trained (orange), and tested (green) results. Red dashed line divides between the training and testing periods.



**Fig. 8.** Monthly time series of the observed (blue) and CNN-LSTM model forecasted (red) XCO2 concentrations.

시계열 예측에 충분히 활용 가능함을 확인하였다.

그림 7은 OCO-2 XCO<sub>2</sub> 관측 결과와 CNN-LSTM 모델을 이용하여 학습 및 테스트 결과에 대한 시계열 변화 그래프이다. 이 결과에서는 관측 결과 대비 CNN-LSTM 모델의 학습 결과는 월별 시계열 변화 추세 및 계절변동성을 잘 따르고 있는 것을 확인할 수 있다. 학습된 모델을 이용하여 2022년부터 2023년까지 기간 동안의 테스트 기간에 예측 결과는 실제 관측 값보다 다소 크거나 작은 오차를 나타내었다. 표 1에서 정리된 검증지수값들은 이러한 결과를 반영한다.

이상으로 학습된 CNN-LSTM 모델의 정확도와 실행 가능성이 평가 완료된 상태에서 미래에 대한 XCO<sub>2</sub> 농도값을 예측하기 위하여 2024년부터 2025년까지의 XCO<sub>2</sub> 농도를 예측하였다. 그림 8은 OCO-2 XCO<sub>2</sub> 농도의 전체 관측기간과 CNN-LSTM 모델로 예측한 미래 농도값에 대한 시계열 농도 변화 그래프이다. 2024년과 2025년의 연평균 XCO<sub>2</sub>는  $423.82 \pm 2.92$  ppm,  $427.26 \pm 2.81$  ppm, 2025년에 최대값인  $431.76$  ppm에 이를 것으로 예측되었다. 한반도에서 XCO<sub>2</sub>의 변화 추세는 자연적 또는 인위적인 배출원에 대한 적

극적인 개입이 없다면, 향후에도 지속적으로 증가할 것으로 예상된다.

#### 4. 요약 및 결론

이산화탄소 측정이 가능한 인공위성인 OCO-2 위성 관측자료를 이용하여 한반도 영역에서 약 10년(2014년 9월~2023년 12월) 동안의 XCO<sub>2</sub> 농도의 시공간 분포 및 변화 특성을 분석하였다. 행정구역별 평균 XCO<sub>2</sub>는 서울이  $416.34 \pm 2.03$  ppm으로 최대값을 기록하였으며, 세종시, 전라북도, 경상남도, 경기도, 충청남도 순으로 높은 XCO<sub>2</sub> 값이 관측되었다. 계절적 변화를 최소화하기 위하여 계산된 지역 편차값은 수도권과 서부권역에서 양의 값, 강원권과 경북권에서는 음의 값 범위를 나타냈다. 이러한 XCO<sub>2</sub>의 시공간적 불균형은 배출량의 증가 및 대기 중의 누적이 지역별로 다르게 나타나며, 인구밀집도, 특정 환경 요인이나 산업 활동의 불규칙성에 의한 결과로 판단된다.

OCO-2 XCO<sub>2</sub>의 장기간 관측자료는 딥러닝 기법에서 사용되는 시계열 분해를 통해 추세, 계절성, 잔차로 분리할 수 있다. 이로부터 한반도의 평균 XCO<sub>2</sub>는 2014년 약 400 ppm에서 2023년 420 ppm으로 10년 동안 약 5% 증가하였으며, 식물의 광합성 활동에 따른 계절성 변화 범위인  $\pm 1$  ppm보다 매우 큰 수준을 나타냈다. 또한, XCO<sub>2</sub>의 시계열 분해 결과 중 추세 변화와 계절 변화를 제거한 후 남은 불규칙적 변동값은 2016년과 2019년 중 XCO<sub>2</sub>의 비정상적인 증가 및 감소 이벤트가 있었음을 확인할 수 있었다. 이러한 이벤트성 기여도에 대한 평가를 위하여 전 지구적 이산화탄소 농도 변화가 국내 환경에 미치는 영향에 관한 추가 연구가 필요할 것이다.

미래의 XCO<sub>2</sub> 농도 예측을 위해 CNN-LSTM 결합 모델을 사용하였다. 모델의 하이퍼 파라미터는 최적의 성능을 위해 조정되었으며, 2014년부터 2023년까지의 데이터를 학습하여 예측 능력을 평가한 결과는 MSE = 0.69 ppm, RMSE = 0.83 ppm, MAE = 0.66 ppm, MAPE = 0.16%로 높은 정확도를 확보하였다.

학습된 모델을 테스트한 결과는 MSE = 3.10 ppm, RMSE = 1.73 ppm, MAE = 1.49 ppm, MAPE = 0.36%의 범위로서 정확도 1% 내의 성능을 가짐을 확인하였다. CNN-LSTM 결합모델로 예측한 연평균 XCO<sub>2</sub>는 각각  $423.82 \pm 2.92$  ppm (2024년),  $427.26 \pm 2.81$  ppm (2025년)으로 매년 증가될 것이며, 이 기간 동안 2025년 12월은 최대값인 431.76 ppm을 나타낼 수 있음을 보였다.

한반도 지역에서 증가하고 있는 이산화탄소 농도의 증가는 지역 규모의 온실효과 및 각종 물질수지에도 영향을 미칠 가능성이 있다. 대기의 온도 상승은 기류 및 수증기 패턴의 변화로 인한 불확실한 피드백이 생성되기 때문이다. 향후 이와 관련된 추가 연구를 통하여 지역적 불균형 요인이 온실효과 변동성에 미치는 영향에 관하여 연구가 진행될 예정이다. 이는 지역 규모의 기후 역학에 대한 이해를 증진하고 기후 변화 완화 및 적응 전략을 개선하는 데 도움이 될 것이다. 그러나, 본 연구의 분석과정에 관한 한계점이 존재하는데 우선 OCO-2 위성은 관측영역이 매우 좁고 재방문 주기가 상대적으로 길기 때문에 일별 변화 및 도시규모 연속 모니터링에 제한적이다. 이로 인하여, 이산화탄소의 갑작스러운 증가나 감소와 같은 이벤트성 사례가 발생하는 경우에 대해 해당 지점에서 원인-과정-영향권에 대한 종합적인 해석이 어려운 점이다. 이러한 한계를 극복하기 위하여 위성관측뿐 아니라, 지상이나 모델링 자료와 연계된 통합 분석을 통하여 다차원적인 자료를 해석하는 노력이 필요하다.

#### 감사의 글

이 연구는 2024년 차세대융합기술연구원 첨단환경감시센터의 지원을 받아 수행되었습니다. 연구에서 사용된 OCO-2 위성 산출물은 NASA Goddard Earth Science Data and Information Services Center, ODIAC 배출량 데이터는 NIES에서 제공받았습니다. 자료를 제공하는 두 기관에 깊은 감사를 표합니다.

## References

- Andrade, F.B., Buchwitz, M., Reuter, M., Bovensmann, H., Richter, A., Boesch, H., Burrows, J.P. (2024) A method for estimating localized CO<sub>2</sub> emissions from co-located satellite XCO<sub>2</sub> and NO<sub>2</sub> images, *Atmospheric Measurement Techniques*, 17, 1145-1173. <https://doi.org/10.5194/amt-17-1145-2024>
- Chatterjee, A., Gierach, M.M., Sutton, A.J., Sutton, A.J., Feely, R.A., Crisp, D., Eldering, A., Gunson, M.R., O'Dell, C.W., Stephens, B.B., Schimel, D.S. (2017) Influence of El Niño on atmospheric CO<sub>2</sub> over the tropical Pacific Ocean: Findings from NASA's OCO-2 mission, *Science*, 358. <https://doi.org/10.1126/science.aam5776>
- Crisp, D. (2015) Measuring atmospheric carbon dioxide from space with the Orbiting Carbon Observatory-2 (OCO-2), *Proc. SPIE 9607 Earth Observ. Syst. XX*, 960702. <https://doi.org/10.1117/12.2187291>
- Crisp, D., Miller, C.E., DeCola, P.L. (2008) NASA Orbiting Carbon Observatory: Measuring the column averaged carbon dioxide mole fraction from space, *Journal of Applied Remote Sensing*, 2(1), 023508. <https://doi.org/10.1117/1.2898457>
- Eldering, A., Wennberg, P.O., Crisp, D., Schimel, D.S., Gunson, M.R., Chatterjee, A., Liu, J., Schwandner, F.M., Sun, Y., O'Dell, C.W., Frankenberg, C., Taylor, T.E., Fisher, B.M., Osterman, G.B., Wunch, D., Hakkarainen, J., Tamminen, J., Weir, B. (2017) The Orbiting Carbon Observatory-2 early science investigations of regional carbon dioxide fluxes, *Science*, 358. <https://doi.org/10.1126/science.aam5745>
- Frumkin, H., Hess, J.J., Luber, G., Malilay, J., Mcgeehin, M.A. (2008) Climate change: the public health response, *American Journal of Public Health*, 98(3), 435-445. <https://doi.org/10.2105/AJPH.2007.119362>
- Graven, H.D., Keeling, R.F., Piper, S.C., Patra, P.K., Stephens, B.B., Wofsy, S.C., Welp, L.R., Sweeney, C., Tans, P.P., Kelley, J.J., Daube, B.C., Kort, E.A., Santoni, G.W., Bent, J.D. (2013) Enhanced Seasonal Exchange of CO<sub>2</sub> by Northern Ecosystems Since 1960, *Science*, 341, 1085-1089. <https://doi.org/10.1126/science.1239207>
- Hathaway, J., Maibach, E.W. (2018) Health Implications of Climate Change: a Review of the Literature About the Perception of the Public and Health Professionals, *Current Environmental Health Reports*, 5, 197-204. <https://doi.org/10.1007/s40572-018-0190-3>
- Intergovernmental Panel on Climate Change (IPCC) (2014) Anthropogenic and Natural Radiative Forcing, in *Climate Change 2013 - The Physical Science Basis: Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press, 659-740. <https://doi.org/10.1017/CBO9781107415324.018>
- Intergovernmental Panel on Climate Change (IPCC) (2021) *Climate Change 2021: The Physical Science Basis*. Cambridge University Press.
- Keeling, R.F., Piper, S.C., Bollenbacher, A.F., Walker, J.S. (2008) Atmospheric CO<sub>2</sub> Records from Sites in the Scripps Institution of Oceanography (SIO) Air Sampling Network (1985-2007), *Environmental Science*. <https://doi.org/10.3334/CDIAC/ATG.012>
- Lee, H., Han, S.-O., Ryoo, S.-B., Lee, J.-S., Lee, G.-W. (2019) The measurement of atmospheric CO<sub>2</sub> at KMA GAW regional stations, its characteristics, and comparisons with other East Asian sites, *Atmospheric Chemistry and Physics*, 19, 2149-2163. <https://doi.org/10.5194/acp-19-2149-2019>
- Lee, J.K., Christen, A., Ketler, R., Nestic, Z. (2017) A mobile sensor network to map carbon dioxide emissions in urban environments, *Atmospheric Measurement Techniques*, 10, 645-665. <https://doi.org/10.5194/amt-10-645-2017>
- Lee, K., Wong, M.S., Li, J. (2022) Review of Atmospheric Environmental Change from Earth Observing Satellites, *Asian Journal of Atmospheric Environment*, 16(1), 2021147. <https://doi.org/10.5572/ajae.2021.147>
- Lee, K.H., Bae, M.S. (2023) Satellite Observation Based Air Quality Study, *Journal of Korean Society Atmospheric Environment*, 39(5), 571-587. <https://doi.org/10.5572/KOSAE.2023.39.5.571>
- Lobell, D., Schlenker, W., Costa-Roberts, J. (2011) Climate Trends and Global Crop Production Since 1980, *Science*, 333, 616-620. <https://doi.org/10.1126/science.1204531>
- O'Dell, C.W., Connor, B.J., Bösch, H., O'Brien, D.M., Frankenberg, C., Castaño, R., Christi, M., Crisp, D., Eldering, A., Fisher, B.M., Gunson, M.R., McDuffie, J., Miller, C.E., Natraj, V., Oyafuso, F.A., Polonsky, I., Smyth, M.M., Taylor, T.E., Toon, G.C., Wennberg, P.O., Wunch, D. (2012) Corrigendum to "The ACOS CO<sub>2</sub> retrieval algorithm - Part 1: Description and validation against synthetic observations" published in *Atmos. Meas. Tech.*, 5, 99-121, 2012, *Atmospheric Measurement Techniques*, 5, 193-193. <https://doi.org/10.5194/AMT-5-193-2012>
- Oda, T., Maksyutov, S. (2011) A very high-resolution (1 km × 1 km) global fossil fuel CO<sub>2</sub> emission inventory derived using a point source database and satellite observations of nighttime lights, *Atmospheric Chemistry and*

- Physics, 11, 543-556. <https://doi.org/10.5194/acp-11-543-2011>
- Oda, T., Maksyutov, S., Andres, R.J. (2018) The Open-source Data Inventory for Anthropogenic CO<sub>2</sub>, version 2016 (ODIAC 2016): a global monthly fossil fuel CO<sub>2</sub> gridded emissions data product for tracer transport simulations and surface flux inversions, Earth System Science Data, 10, 87-107. <https://doi.org/10.5194/essd-10-87-2018>
- Park, J., Hong, T. (2013) Analysis of South Korea's economic growth, carbon dioxide emission, and energy consumption using the Markov switching model, Renewable & Sustainable Energy Reviews, 18, 543-551. <https://doi.org/10.1016/j.rser.2012.11.003>
- Peters, W., Jacobson, A.R., Sweeney, C., Andrews, A.E., Conway, T.J., Masarie, K.A., Miller, J.B., Bruhwiler, L., Pétron, G., Hirsch, A.J., Worthy, D.E., van der Werf, G.R., Rander-son, J.T., Wennberg, P.O., Krol, M.C., Tans, P.P. (2007) An atmospheric perspective on North American carbon dioxide exchange: CarbonTracker, Proceedings of the National Academy of Sciences, 104, 18925-18930. <https://doi.org/10.1073/pnas.0708986104>
- Reddy, A.R., Rasineni, G.K., Raghavendra, A.S. (2010) The impact of global elevated CO<sub>2</sub> concentration on photosynthesis and plant productivity, Current Science, 99, 46-57.
- Reuter, M., Buchwitz, M., Schneising, O., Noël, S., Bovensmann, H., Burrows, J.P. (2017) A fast atmospheric trace gas retrieval for hyperspectral instruments approximating multiple scattering - Part 2: application to XCO<sub>2</sub> retrievals from OCO-2, Remote Sensing, 9, 1102. <https://doi.org/10.3390/rs9111102>
- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., Woo, W.-C. (2015) Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. Advances in Neural Information Processing Systems - Volume 1 (NIPS'15). MIT Press, Cambridge, MA, USA, 802-810.
- Shim, C., Han, J., Henze, D.K., Yoon, T. (2018) Identifying local anthropogenic CO<sub>2</sub> emissions with satellite retrievals: a case study in South Korea, International Journal of Remote Sensing, 40, 1011-1029. <https://doi.org/10.1080/01431161.2018.1523585>

### Authors Information

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

김관철 (차세대융합기술연구원 첨단환경감시센터 센터장) (fehouse@snu.ac.kr)