



## 실내 이산화탄소 농도 예측 기반 적응형 환기 제어 알고리즘 개발

### Development of Adaptive Ventilation Control Algorithm Based on Indoor Carbon Dioxide Concentration Prediction

최영재\* · 배강우\*\* · 정용기\*\*\* · 문현준\*\*\*\* · 문진우\*\*\*\*\*

Young Jae Choi\* · Kang Woo Bac\*\* · Yong Gi Jung\*\*\* · Hyeun Jun Moon\*\*\*\* · Jin Woo Moon\*\*\*\*\*

\* Main author, Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (chyoungwo@gmail.com)

\*\* Coauthor, Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (rkddn2@gmail.com)

\*\*\* Coauthor, Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (popopop12@naver.com)

\*\*\*\* Coauthor, Professor, Dept. of Architecture Engineering, Dankook Univ., South Korea (hmoon@dankook.ac.kr)

\*\*\*\*\* Corresponding author, Professor, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (gilerbert73@cau.ac.kr)

#### ABSTRACT

**Purpose:** This study aimed to develop an adaptive ventilation control algorithm for occupant-centric control (OCC). The control algorithm utilizes a real-time indoor carbon dioxide concentration prediction model that reflects occupant information and is continuously updated through daily learning. **Method:** The prediction model was developed using a long short-term memory (LSTM) learning algorithm based on data obtained from a living lab. The indoor CO<sub>2</sub> concentration after 5 minutes was predicted through the data of the past 1 hour, and the prediction accuracy was evaluated with the test data. The adaptive ventilation control algorithm, which incorporates the prediction model, was then applied to the living lab for experiments to evaluate its real-time prediction accuracy, adaptability, and control performance. **Result:** As a result of the performance evaluation of the predictive model, the coefficient of variation of the root mean squared error (CVRMSE) was 1.78% and the R<sup>2</sup> was 0.97. The adaptability evaluation over four days presented an improvement in CVRMSE from 1.78% to 1.13%, which is approximately 36.52% improvement from the initial performance. During the experiment with the adaptive ventilation control algorithm, the accuracy decreased slightly with a CVRMSE of 2.90% and R<sup>2</sup> of 0.98, likely due to frequent ventilation control leading to large data variations. Despite short period of the indoor carbon dioxide concentration exceeding 1,000 ppm, the control was effective. According to the results, it is expected that providing comfortable indoor air quality at all times can be achieved by improving the optimal control cycle and supplementing data learning for various control modes in future research.

#### KEYWORD

환기 시스템  
실내 이산화탄소 예측모델  
적응형 제어 알고리즘

Ventilation System  
Indoor Carbon Dioxide Prediction Model  
Adaptive Control Algorithm

#### ACCEPTANCE INFO

Received Mar. 27, 2023

Final revision received Apr. 5, 2023

Accepted Apr. 10, 2023

© 2023. KIEAE all rights reserved.

## 1. 서론

### 1.1. 연구의 배경

최근 탄소중립 및 국민건강에 대한 관심이 증가함에 따라 건물 에너지 절감과 쾌적한 실내환경 제공을 위한 기술 개발이 주목받고 있다[1]. 특히, 재실자 중심 제어(occupant-centric control, OCC)는 재실자에게 쾌적한 실내환경을 제공함과 동시에 건물 에너지 효율을 극대화하는 제어 방법으로, 재실자 모델링을 목적으로 하는 IEA EBC Annex 66 프로젝트로부터 시작되어 현재는 ‘Occupant behavior-centric building design and operation’을 시행하는 Annex 79 프로젝트를 중심으로 연구되고 있다[2].

OCC는 IoT에 기반한 최신 센싱 기술과 데이터 마이닝, 기계학습 사용을 장려한다[3]. 이는 실시간 실내외환경, 설비, 에너지 데이터를 사용한 인공지능 기반 최적 제어 분야에서 적극적으로 적용되고 있으며 냉난방, 환기, 조명의 최적 제어를 통한 건물 에너지 절감효

과가 기존 On/Off 제어나 PID제어에 비해 큰 것으로 보고되고 있다 [4][5][6].

OCC에서 가장 중요한 정보 중 하나는 재실자 정보이다. 재실자 정보는 재실자 유무, 수, 스케줄, 동선 등을 포함하며 OCC를 위한 다양한 제어 방법에 적용된다[7]. 재실자 유무, 재실자 수 및 스케줄은 환기 설비 제어와 직접적인 관련이 있다. 이는 일반적 환기 제어 변수인 이산화탄소가 재실자에 의해 발생되기 때문이며 공간 내 재실자 유무 및 수에 따라 이산화탄소를 실내 기준 이하로 만족시키기 위한 풍량이 달라지기 때문이다. 재실자 정보를 환기량 제어에 반영하려는 기존 방법으로는 재실자 스케줄 기반의 환기량 제어[8], 이산화탄소 농도 계측에 기반한 수요제어환기 (demand controlled ventilation, DCV) [9][10][11]등이 있으나 실시간으로 재실자 정보를 계측하여 환기에 적용하려는 시도는 미비한 실정이다.

또한, 기존 방법은 피드백 제어를 기반으로 한다. 피드백 제어는 제어 변수가 기준치를 초과할 경우 시스템 조작 변수를 변동시키는 제어방법으로 자동제어가 가능하다는 장점이 있으나, 제어 변수가 이미 기준치를 초과했다는 상황을 가정하기 때문에 해당 문제점이 보완되어야 한다. 예측제어는 미래 실내환경을 예측함으로써 설비

의 선제적 대응을 가능하게 하여 환기에 적용될 경우 이산화탄소 농도의 기준치 초과 비율을 감소시킬 수 있다[12].

영상 데이터, 이산화탄소 농도, 적외선 감지 센서 등을 사용한 실시간 재실자 정보 산출과 이산화탄소 농도 예측을 위한 수학적 모델, 기계학습 기반 모델은 다방면으로 개발이 진행 중이다. 그러나 두 요소를 통합한 환기 제어 방법과 이를 실제 환경에 적용한 연구는 미비한 상황이다. 따라서, 성공적인 OCC 제어 실현을 위해서는 재실자 정보를 적극적으로 반영한 예측 기반 환기 제어 알고리즘 개발 및 적용이 필수적이다.

## 1.2. 선행연구 고찰

실내 이산화탄소 농도 예측과 변동하는 이산화탄소 농도를 반영한 환기 제어 알고리즘 관련 연구는 다양하게 진행 중이다. 본 장에서는 대표 선행연구 분석을 통해 핵심 기술 동향을 파악하고 한계점 도출을 통해 필요 개선사항을 정의한다.

먼저, 실내 이산화탄소 예측 모델의 경우 수학적 모델과 인공지능 기반 모델이 주를 이루고 있다. Kim et al. (2021) [13]은 실내 이산화탄소 농도 예측을 위한 수학적 모델링을 실시하였다. 실내 이산화탄소 농도가 모니터링되지 않는 공간의 농도를 예측하고자 공간의 체적, 이산화탄소 발생량 초기 농도, 공급 농도, 공급 풍량 데이터를 사용하였으며 현장 실험을 통해 성능평가를 실시하였다. 그 결과 총 27가지 상황에 대한 mean bias error (MBE)와 coefficient of variation of the root mean squared error (CVRMSE)가 각각 10%, 30% 이하를 만족하였다. Kallio et al. (2021) [14]은 머신러닝을 활용하여 1분, 5분, 10분, 15분 후의 이산화탄소 농도를 예측하는 모델을 개발하였다. Ridge regression, decision tree, random forest, 그리고 multilayer perceptron 알고리즘이 사용되었으며 과거와 현재의 이산화탄소 농도, 적외선 센서 값, 온도, 습도 데이터를 입력 데이터로 사용하였다. 성능평가 결과 네 모델 모두 큰 정확도 차이를 나타내지는 않았으나 실제 적용을 위한 메모리 사용량 및 연산 시간을 고려하여 Decision tree 모델이 가장 우수한 것으로 분석되었다. Alavi et al. (2020) [15]은 이산화탄소 농도 예측을 시계열 문제로 구분하고 통계 모델인 autoregressive integrated moving average (ARIMA) 계열 모델과 순환 신경망 기반의 long short-term memory (LSTM)을 통해 5분, 10분, 30분 후의 이산화탄소 농도를 예측하였다. 그 결과 5분 후의 농도를 예측하는 autoregressive (AR) 모델이 97.66%의 정확도로 가장 우수한 성능을 나타냈다.

실시간으로 이산화탄소 농도 변화를 반영하는 환기 제어 알고리즘 연구는 주로 DCV를 중심으로 진행되었다. Yoon & Kim (2019) [16]는 도서관에서 재실인원과 환기 풍량을 변화시키며 1인당 최소 풍량을 만족시키는 최적 풍량을 산출하였다. 실험 결과 학교보건법에 명시된 1인당 21.6 CMH 기준이 부족한 것으로 분석되었으며 정확한 재실인원 산출에 따른 적정 풍량 제공 시 실내 공기질을 적절히 유지함과 동시에 팬 동력을 감소시킬 수 있음을 증명하였다. Taheri & Razban (2021) [12]은 multilayer perceptron을 통해 이산화탄소 농도를 예측하고 예측 값을 바탕으로 재실자 수를 산출하여 최적 환기량을 도출하였다. 이때 환기 가동 기준 이산화탄소 농도를 1,000ppm으로 설정하였을 시 약 51.4%의 에너지 절감이 가능함을

확인하였다. Li & Cai (2022) [11]은 이산화탄소 농도에 기반하여 감제어를 방지하기 위한 풍량 제어를 실시하였으며 정풍량 제어 대비 30%에서 50%의 에너지 절감을 달성하였다.

선행연구 분석 결과 실내 이산화탄소 예측과 이산화탄소 기반 DCV에 관한 연구는 진행되고 있으나 두 요소가 통합되어 적용된 연구는 미비했다. 이산화탄소 예측의 경우 재실자 수 예측의 어려움으로 인해 이산화탄소 농도를 기반으로 재실자 수를 예측하는 연구가 주를 이루었는데, 이는 결국 현 재실자 수를 기준으로 최적 환기량을 결정하는 방법으로 예측제어로 구분하기는 어렵다. DCV 또한 냉난방 분야에서 인공지능이 적극적으로 적용되는 것과 달리 제어 변수(이산화탄소, 미세먼지 등) 예측에 인공지능이 활용된 사례는 많지 않았다. 따라서, 실시간 재실자 정보를 반영한 이산화탄소 예측모델과 이를 통합한 환기 제어 알고리즘 개발 시 기존 제어 방법 대비 쾌적한 실내 공기질을 제공하며 에너지 절감을 달성할 수 있을 것으로 판단된다.

## 1.3. 연구의 목적

선행연구 분석 결과 OCC를 위한 환기 제어 방법 개발을 위해서는 실시간 재실자 정보, 인공지능 기반의 제어 변수 예측, 예측제어 기반의 최적 제어 알고리즘의 통합 개발이 시행되어야 한다. 따라서, 본 연구에서는 실시간 재실자 정보를 활용한 인공지능 기반 이산화탄소 예측모델을 개발하고 이를 포함하는 환기 제어 알고리즘을 개발하였다. 또한, 알고리즘에 실시간 학습 기능을 추가함으로써 새로운 데이터에 대한 지속적 학습을 가능하게 하였다. 해당 적응형 환기 제어 알고리즘은 최신 IoT 기반 센싱 자원을 적극적으로 활용함으로써 추후 OCC 구현에 핵심 기술로 사용될 수 있을 것이며 실시간 학습을 통해 다양한 환경에 적응하여 최적 실내 공기질 제공 및 환기 시스템 에너지 절감을 가능하게 할 것으로 기대된다.

## 2. 연구 방법

### 2.1. 연구 개요

적응형 환기 제어 알고리즘 개발 및 성능평가를 위한 연구는 Fig. 1.과 같이 총 4단계로 진행되었다. 첫째, 리빙랩으로부터 실내 이산화탄소 농도 예측모델 개발을 위한 데이터를 취득하였다. 둘째, 해당 데이터를 활용하여 순환 신경망 기반 실내 이산화탄소 농도 예측 모델을 개발하였다. 셋째, 개발된 예측모델을 포함하는 적응형 환기 제어 알고리즘을 개발하였다. 마지막으로 예측모델에 대한 정확도를 평가하고 알고리즘을 리빙랩에 적용하여 실시간 예측 정확도, 적응 성능, 제어 성능에 대한 성능평가를 실시하였다.

### 2.2. 리빙랩 정보

리빙랩은 실내 이산화탄소 예측모델 개발을 위한 데이터 취득 및 적응형 환기 제어 알고리즘 성능평가에 사용되며 정보는 Fig. 2.과 같다. 서울 동작구 C 대학에 위치하며 바닥면적 67.08m<sup>2</sup> 규모의 연구실로 재실자는 11명이다. 재실 스케줄은 10시-18시이나 8시-10시, 18시-20시 사이에는 불규칙적인 패턴을 나타낸다.

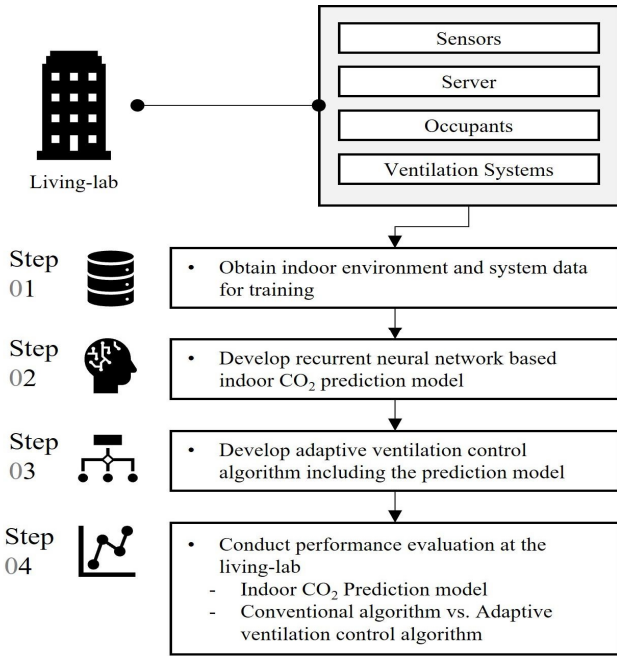


Fig. 1. Research process

Information	Details	
Plan		
Location	'C' University, Seoul, South Korea	
Scale	Floor area: 67.08m <sup>2</sup>	
Occupants	11 people	
Sensors	Outdoor	Temperature, humidity, PM <sub>10</sub> , PM <sub>2.5</sub> , CO <sub>2</sub>
	Indoor	Temperature, humidity, PM <sub>10</sub> , PM <sub>2.5</sub> , CO <sub>2</sub>
	CCTV	Video & image
HVAC Systems	Air conditioner	System air conditioner
	Ventilation	Energy recovery ventilator (ERV) integrated with air purifier

Fig. 2. Living-lab information

시스템 구성은 실내의 환경 센서, 영상센서, 냉난방기 2대, 공기청정 기능이 있는 스탠드형 환기 시스템(이하 환기청정기) 2대, DB가 설치된 서버 1대이다. 환경 센서(AM1008W-K)는 외부 백엽상 1개와 실내 4개가 1.2m 높이로 설치되어 있으며 아두이노와 라즈베리파이를 통해 DB로 실시간 센서값을 전송한다. 영상센서(DH-IPC-HDBW1431EN-S4)는 real time streaming protocol

Table 1. Information of data base

Information	Details
Time step	15 seconds
Variables	<ul style="list-style-type: none"> <li>Outdoor &amp; Indoor sensors                             <ul style="list-style-type: none"> <li>- Drybulb temperature [°C]</li> <li>- Relative humidity [%]</li> <li>- PM10 [<math>\mu\text{g}/\text{m}^3</math>]</li> <li>- PM2.5 [<math>\mu\text{g}/\text{m}^3</math>]</li> <li>- CO<sub>2</sub> [ppm]</li> </ul> </li> <li>Ventilation systems                             <ul style="list-style-type: none"> <li>- On/Off [0: off, 1: on]</li> <li>- Mode [1: ventilation, 2: purify, 3: bypass]</li> <li>- Flowrate [cmh]</li> </ul> </li> <li>CCTV                             <ul style="list-style-type: none"> <li>- Number of occupants [person]</li> </ul> </li> </ul>

(RTSP) 방식으로 서버와 연결되어 실시간 데이터 취득이 가능하며 냉난방기(AC090RA4PBH1SY)와 환기청정기(S2-400) 또한 서버에 연결되어 실시간 제어 신호 전송이 가능하다. DB는 MySQL을 사용한다. 센서, 시스템 변수 데이터가 15초 간격으로 저장되며 변수 목록은 Table 1.와 같다.

### 2.3. 실내 이산화탄소 농도 예측모델 개발

실내 이산화탄소 농도는 수학적 모델링이 가능한 변수이나 해당 모델을 구축하고 사용하기 위해서는 전문적인 지식이 필요하다. 따라서, 본 연구에서는 data-driven 기반의 머신러닝 모델로 이산화탄소 농도 예측모델 개발을 실시하였다. 실내 이산화탄소 농도는 시간에 의해 순서를 가지며 과거 값이 현재 값에 의해 영향을 주기 때문에 시계열 데이터로 분류할 수 있다. 신경망 모델(neural network)은 데이터들의 비선형적 관계 학습에 강점을 가지는 것으로 알려져 있는데 [17], 이 중 순환 신경망(recurrent neural network, RNN)은 학습 과정에서 출력력이 다음 학습의 입력에 사용되는 순환 구조를 가지 시계열 데이터 학습에 유리하다[18]. 다만, 입력 데이터의 길이가 길어질수록 과거 데이터의 영향성이 적어지는 장기 의존성 문제(long term dependency)가 발생할 수 있어 본 연구에서는 이 문제를 보완한 LSTM 모델을 사용하였다.

입력 변수는 Costanzo et al. (2011) [19]가 제안한 실내 이산화탄소 농도 형성 수식의 구성 요소인 초기 실내 이산화탄소 농도, 실외 이산화탄소 농도, 환기 시스템에서 재순환 되는 이산화탄소 농도, 이산화탄소 생산량, 환기 풍량, 공간 체적 중 DB에서 취득이 가능한 데이터를 선별하였다. 선별된 데이터는 실내외 이산화탄소 농도와 환기 시스템 On/Off, 모드, 풍량, 재실자 수이며 이때 재실자 수는 이산화탄소 발생원이다. 출력변수는 5분 후의 실내 이산화탄소 농도로 설정하였다.

학습을 위한 데이터는 리빙랩에서 취득하였으며 데이터 취득 기간은 13일이다. 입력 데이터의 time step은 출력 데이터와 동일해야 하기 때문에 15초 간격의 데이터를 5분 간격으로 평균 처리 하였다. 과거 데이터 개수를 의미하는 window size는 12로 1시간 전부터 현재 취득된 데이터가 입력되도록 데이터 전처리를 실시하였다. 데이터 정규화는 0과 1사이로 모든 데이터를 조정하는 min-max scaler를 적용하였으며 모델 구조 및 학습은 Tensorflow에서 제공하는

Keras 라이브러리를 사용하였다.

LSTM 모델은 입력층, LSTM 층, 출력층으로 구성되며 LSTM 층은 50개의 뉴런으로 구성된다. 활성화 함수는 ReLu, 최적화 함수는 adam optimizer를 사용하였으며 손실함수는 mean squared error (MSE)로 설정하였다. 학습 횟수(epochs)는 150회이나 과적합 방지를 위하여 5회 이상 검증 값이 개선되지 않으면 학습을 종료하도록 early stopping callbacks를 적용하였다. 예측모델 정보는 Table 2. 과 같다.

### 2.4. 적응형 환기 제어 알고리즘 개발

적응형 환기 제어 알고리즘 개발의 핵심 기능은 실내 이산화탄소 예측모델 기반 제어와 실시간 학습이며 두 기능을 반영한 제어 알고리즘은 Fig. 3.와 같다. 기능적으로 5개의 파트(Part A - E)로 구분되며 파트별 세부 내용은 다음과 같다.

#### 1) Part A

DB로부터 시간, 실외 이산화탄소 농도, 실내 이산화탄소 농도, 재실자 수, 환기 시스템 작동, 모드, 풍량 데이터를 취득한다.

#### 2) Part B

시간 비교 부분으로 평일과 주말을 구분하여 주말에는 환기 시스템을 가동하지 않는다. 평일의 경우 일과시간인 오전 8시부터 오후 8시까지 환기 시스템을 가동한다.

#### 3) Part C, D

제어 주기는 5분이기 때문에 15초 간격의 데이터를 5분 동안의 평균으로 변환한다. 이후 과거 1시간 동안의 데이터 (총 12개)에 대

한 전처리를 통해 예측모델 입력을 위한 시퀀스 데이터를 생성한다. 입력 데이터는 바로 예측모델에 투입하지 않으며 5분 평균 재실자 수가 1 이상일 때 예측을 실시한다. 이는 영상 데이터 기반 재실자 검출의 경우 사물을 사람으로 인식하는 오류가 간헐적으로 발생하기 때문에 재실자가 없음에도 재실자가 있는 것으로 인식하는 상황을 방지하기 위함이다.

5분 평균 재실자 수가 1 이상을 만족하는 경우 5분 후 실내 이산화탄소 농도를 예측한다. 이때 예측값이 1,000ppm을 초과하면 5분 후 이산화탄소 농도가 높다는 것을 의미하기 때문에 환기를 실시하고 1,000ppm 이하인 경우에는 환기 시스템을 정지시킨다. 이산화탄소 농도 기준은 업무시설 실내공기질 관리 기준을 따른다[21].

#### 4) Part E

기존 모델 재학습 관련 연구에 의하면 제어 알고리즘 학습의 경우 sliding window, vector augmentation, vector adaptation 방법을 적용할 수 있다[20]. Sliding window는 기존 학습 데이터 세트의 크기를 유지하며 새로운 데이터를 삽입하는 방식으로 모델의 안정적 학습이 가능하지만 학습 시간이 오래 걸린다는 단점이 있다. Vector augmentation은 새로운 데이터 학습 시 계속해서 데이터를 누적하여 학습하는 방법으로 매 제어 스텝마다 학습을 시행할 수 있다는 장점이 있으나 반복되는 학습으로 인해 제어에 시간 지연(time delay)가 발생할 수 있다. Vector adaptation은 매 제어 스텝마다 새로운 데이터 포인트 1개를 학습하는 방법으로 신속한 적응이 가능하나 학습의 안정성이 저하한다는 단점이 있다. 따라서, 본 연구에서는 모델 학습 시의 안정성 및 실시간 제어에서의 연산 부하를 고려하여 하루에 한 번 일과시간이 종료되고 당일 데이터 학습을 진행하였다.

Table 2. Information of prediction model

Information	Details
Input data	<ul style="list-style-type: none"> <li>Outdoor CO<sub>2</sub> concentration</li> <li>Indoor CO<sub>2</sub> concentration (average of 4 sensors)</li> <li>Ventilation system On/Off signal (2 EA)</li> <li>Ventilation system mode (2 EA)</li> <li>Ventilation system supply flowrate (2 EA)</li> <li>Number of occupants</li> </ul>
Output data	<ul style="list-style-type: none"> <li>Indoor CO<sub>2</sub> concentration after 5 minutes</li> </ul>
Window size	<ul style="list-style-type: none"> <li>12 (history data for 1 hour)</li> </ul>
Machine learning algorithm	<ul style="list-style-type: none"> <li>Long short-term memory (LSTM)</li> </ul>
Model structure	<ul style="list-style-type: none"> <li>Input layer (9 neurons)</li> <li>LSTM layer (50 neurons)</li> <li>Output layer (1 neurons)</li> </ul>
Normalization	<ul style="list-style-type: none"> <li>min-max scaler</li> </ul>
Activation function	<ul style="list-style-type: none"> <li>ReLu</li> </ul>
Optimization function	<ul style="list-style-type: none"> <li>Adam optimizer</li> </ul>
Loss function	<ul style="list-style-type: none"> <li>Mean squared error (MSE)</li> </ul>
Epochs	<ul style="list-style-type: none"> <li>150</li> </ul>
Options	<ul style="list-style-type: none"> <li>Early stopping callbacks (patience = 5)</li> </ul>

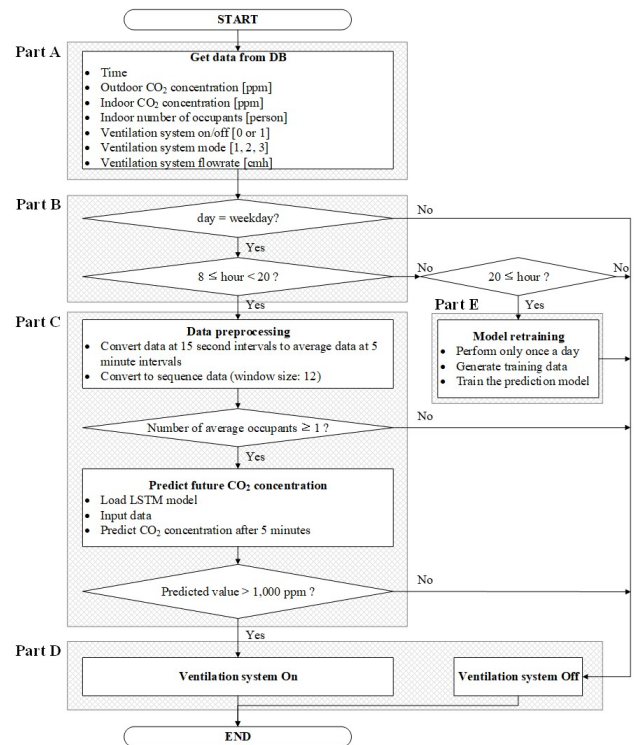


Fig. 3. Adaptive ventilation control algorithm

## 2.5. 예측모델 및 제어 알고리즘 성능평가

성능평가는 예측모델과 리빙랩 기반 적응형 환기 제어 알고리즘 성능평가로 구분된다. 예측모델의 경우 데이터 세트 중 20%를 test data로 분리하여 학습이 아닌 성능평가용으로 사용하였다. 학습이 종료된 후, test data를 입력하여 예측값을 출력하였으며 예측값과 정답의 오차를 산출하여 mean absolute error (MAE), root mean squared error (RMSE), CVMSE, R<sup>2</sup>로 정확도 평가를 진행하였다.

적응형 환기 제어 알고리즘 성능평가는 적응성 평가와 제어 알고리즘 평가로 구분된다. 알고리즘 적용 시의 안정성 문제를 고려하여 예측모델의 일별 데이터 학습 시 안정적인 예측이 가능한지에 대한 실험을 선행적으로 진행하였으며 해당 부분이 확인된 후 재실자가 모두 재실하고 있는 날을 선정하여 제어 알고리즘을 적용하였다. 적응성 평가는 일별 학습 이후의 정확도를 비교하였으며 제어 알고리즘의 경우 실시간 예측 정확도와 실내 공기질 쾌적도에 대한 평가를 실시하였다.

## 3. 성능평가

### 3.1. 이산화탄소 농도 예측모델 성능평가

Test data에 대한 이산화탄소 농도 예측모델 성능평가 결과는 Table 3., Fig. 4.과 같다. Test data와 predicted value의 R<sup>2</sup>는 0.9737로 매우 높은 상관관계를 나타냈으며 최대 오차는 100ppm을 초과하지 않았다. 두 값의 오차로 계산한 MAE, RMSE는 각각 5.15ppm, 8.48ppm으로 산출되었으며 CVMSE는 1.78%로 매우 높은 정확도를 나타냈다. 따라서, 이산화탄소 농도 예측모델은 제어 알고리즘에 적용되기에 충분한 예측 정확도가 확보되었음이 검증되었다.

Table 3. Performance evaluation by test data

MAE	RMSE	CVMSE	R <sup>2</sup>
5.15ppm	8.48ppm	1.78%	0.97

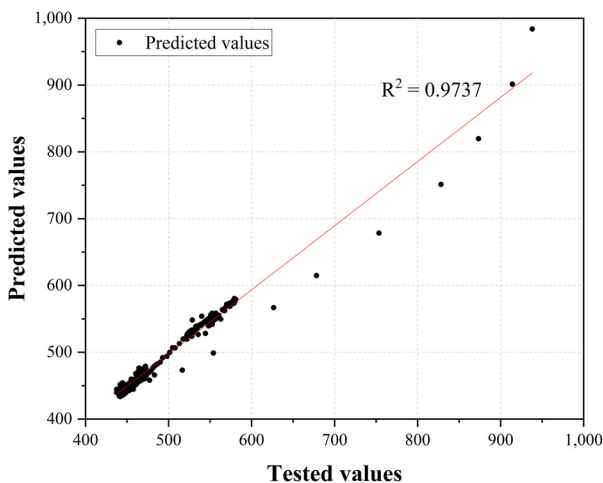


Fig. 4. R<sup>2</sup> of tested values and predicted values

### 3.2. 적응형 환기 제어 알고리즘 성능평가

제어 알고리즘 적용 이전, 예측모델의 리빙랩 적용에 대한 안정성 및 일별 학습에 따른 성능변화를 파악하기 위하여 총 4일간 예측모델 학습을 통한 업데이트를 진행하였으며 결과는 Fig. 5.와 같다. 초기 모델의 CVMSE는 1.78%였으며 1일 차에 1.89%로 소폭 상승하였으나 2일부터 4일 차까지는 지속적으로 CVMSE가 감소하여 최종적으로는 1.13%를 나타냈다. 초기 모델과 학습이 진행된 모델 모두 예측 정확도는 우수하였음에도 불구하고 약 36.52%의 성능개선이 이루어졌다.

적응형 환기 제어 알고리즘 적용 결과에 따른 실시간 예측 정확도는 Table 4., Fig. 6.와 같다. MAE는 21.49ppm, RMSE는 27.84ppm, CVMSE는 2.90%로 재학습 시와 비교하여 성능이 다소 저하되었는데 이는 제어 알고리즘 적용으로 인한 낮은 풍량 변화 때문인 것으로 분석된다. Fig. 6.에 의하면 실측값과 예측값의 R<sup>2</sup>는 0.9775로 높은 상관관계를 나타냈으며 이상치에 해당하는 큰 오차는 발생하지 않았다. 이는 제어 알고리즘 적용 시에도 모델의 예측 안정성은 크게 감소하지 않았다는 것을 의미하며 추후 충분한 상황에 대한 데이터 학습 시 개선될 수 있는 가능성이 있다는 점을 시사한다.




Fig. 5. Results of adaptation

Table 4. Results of real-time prediction

MAE	RMSE	CVMSE	R <sup>2</sup>
21.49ppm	27.84ppm	2.90%	0.98

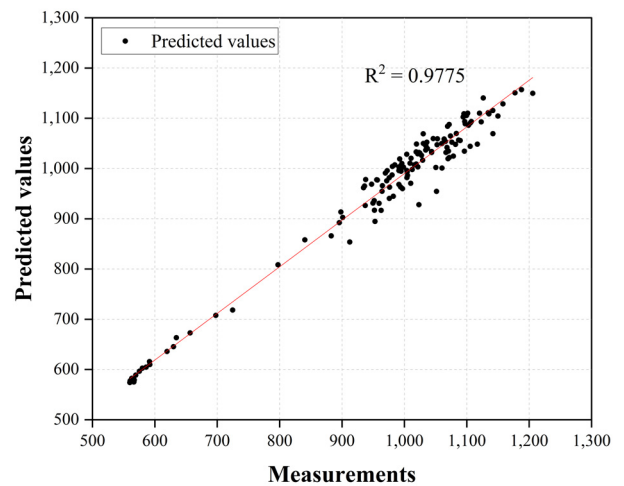


Fig. 6. R<sup>2</sup> of measurements and predicted values




Fig. 7. Results of applying adaptive ventilation control algorithm

제어 결과는 Fig. 7.와 같다. 실시간 예측이 잘 이루어졌으며 예측값이 1,000ppm을 넘는 경우 환기청정기가 가동되어 재실자가 계속 재실중임에도 불구하고 실내 이산화탄소 농도가 감소하는 모습을 나타냈다. 이때 환기를 실시하였음에도 실내 이산화탄소 농도가 1,000ppm 이상인 모습이 관찰되는데 이는 현재 제어 사이클이 짧기 때문인 것으로 판단된다.

예측제어에서 제어 사이클이 짧은 경우 시스템 가동을 통해 제어 변수를 허용 범위 내로 조절하는 시간이 부족할 수 있다. 이는 제어 시행 후 약 15분 후에 그래프가 감소하는 현상에 의해 설명되며, 공간 체적 및 설비 용량에 따라 최적 제어 사이클은 상이하기 때문에 이에 대한 보완이 이루어져야 할 것으로 사료된다.

해당 실험 기간에서는 제어 스케줄인 20시가 넘었음에도 재실자가 계속 재실하였기 때문에 실내 이산화탄소 농도가 증가하였다. 이때 평균 재실 인원이 6명 미만이었음에도 불구하고 1,200ppm을 초과하였으며 이는 약 8-10명이 재실하던 제어 시간에 적절한 환기가 이루어졌음을 의미한다. 따라서, 최적 제어 사이클에 대한 보완이 이루어진다면, 재실 기간 내 1,000ppm 미만의 실내 이산화탄소 농도를 유지하여 쾌적한 실내 공기질을 제공할 수 있을 것으로 판단된다.

#### 4. 결론

건물 에너지 절감과 국민건강에 대한 관심이 증가함에 따라 재실자 중심 제어가 주목받고 있다. 이를 위해 다양한 환기 전략이 제시되고 있으나 실시간 재실자 정보를 활용한 지능형 환기 제어 알고리즘 관련 연구는 부족한 실정이다. 따라서, 본 연구에서는 인공지능 기반의 실내 이산화탄소 예측모델을 개발하고 이를 탑재한 적응형 환기 제어 알고리즘을 개발하였다. 이후 리빙랩 적용을 통해 예측 정확도, 적응성, 제어 알고리즘에 대한 성능평가를 실시하였다.

실내 이산화탄소 예측모델은 시계열 데이터 학습에 유리한 LSTM 모델로 개발하였으며 test data에 대한 성능평가 결과 CVMSE 1.78%,  $R^2$  0.97의 우수한 예측 정확도를 나타냈다. 해당 모델은 제어 알고리즘에 탑재되었으며 실시간으로 5분 후의 실내 이산화탄소 농도를 예측하였다.

적응형 환기 제어 알고리즘은 예측값을 바탕으로 환기 시스템 작동 여부를 결정하며 제어 스케줄 이후 당일 데이터 학습을 실시하도록 개발되었다. 일별 학습에 대한 적응성 평가 결과 4일 후 CVMSE는 1.13%로 초기 모델 대비 약 36.52% 개선되어 예측 안정성이 검증되었다.

제어 알고리즘의 리빙랩 적용 결과 실시간 실내 이산화탄소 농도

예측 정확도는 CVMSE 2.90%,  $R^2$  0.98로 산출되었다. CVMSE는 다소 감소한 모습을 나타냈으나 이는 잦은 환기 제어에 의한 데이터의 변동 때문인 것으로 분석되며 높은  $R^2$ 는 큰 이상치 발생 없이 안정적으로 예측이 시행되었음을 의미한다. 다만, 해당 실험에서 제어 기간 내 실내 이산화탄소 농도가 1,000ppm을 넘는 구간이 발생하였는데 이는 짧은 제어 사이클 때문인 것으로 분석되었으며 이에 따라 최적 제어 사이클 도출에 대한 필요성이 도출되었다.

본 연구의 한계점은 단일 모드 및 풍량 제어, 최적 제어 사이클의 부재, 그리고 짧은 성능평가 기간이다. 이러한 한계점에도 불구하고 성공적인 예측 및 제어 결과를 나타냈으며 추가 연구 진행을 통해 한계점을 보완한다면 재실자 중심 제어를 위한 핵심 기술로 활용될 수 있을 것으로 기대된다. 따라서, 추후 연구로는 다양한 모드 및 풍량을 반영한 최적 환기 제어 알고리즘을 개발할 계획이며 기존 DCV와의 비교 실험을 통해 에너지 성능평가를 진행할 예정이다.

## Acknowledgement

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 20212020800120).

## References

- [1] 김남현 외 3인, 건물 열쾌적 제어를 위한 다중 재실자 대상 활동량 산출모델 성능평가, KIEAE Journal, 23(1), 2023, pp.69-74. // (N.H. Kim et al., Performance evaluation of the multiple occupants real-time MET estimation model for thermal comfort control of building, KIEAE Journal, 23(1), 2023, pp.69-74.)
- [2] W. O'Brien et al., Introducing IEA EBC annex 79: Key challenges and opportunities in the field of occupant-centric building design and operation, Building and Environment, 178, 2020, 106738.
- [3] ANNEX E. Occupant-centric Building Design and Operation. 2019.
- [4] Y.J. Choi et al., Development of an adaptive artificial neural network model and optimal control algorithm for a data center cyber-physical system, Building and Environment, 210, 2022, 108704.
- [5] S.K. Kim et al., Optimal control method for HVAC systems in offices with a control algorithm based on thermal environment. Buildings, 10(5), 2020, pp.95.
- [6] P. Satrio et al., Optimization of HVAC system energy consumption in a building using artificial neural network and multi-objective genetic algorithm, Sustainable Energy Technologies and Assessments, 35, 2019, pp.48-57.
- [7] 최영재 외 3인, 순환 신경망 모델에 따른 재실 인원 예측모델 개발 및 성능비교, 대한건축학회논문집 38(10), 2022, pp.231-240. // (Y.J. Choi et al., Development of occupancy prediction model and performance comparison according to the recurrent neural network models, Journal of the Architectural Institute of Korea, 38(10), 2022, pp.231-240.)
- [8] B. Poirier et al., Pollutants emission scenarios for residential ventilation performance assessment. A review, Journal of Building Engineering, 42, 2021, 102488.
- [9] 김진효 외 5인, 수요기반 환기량 조절법의 공동주택 적용 방안, 대한건축학회 학술발표대회 논문집 - 계획계, 29(1), 2009, pp.173-176. // (J.H. Kim et al., The use of demand controlled ventilation in apartment houses, Conference Journal of the Architectural Institute of Korea - Planning & Design, 29(1), 2009, pp.173-176.)
- [10] C. Li, C. Cui, M. Li, A proactive 2-stage indoor CO<sub>2</sub>-based demand-controlled ventilation method considering control performance and energy efficiency, Applied Energy, 329, 2023, 120288.
- [11] B. Li, W. Cai, A novel CO<sub>2</sub>-based demand-controlled ventilation strategy to limit the spread of COVID-19 in the indoor environment. Building and Environment, 219, 2022, 109232.
- [12] S. Taher, A. Razban, Learning-based CO<sub>2</sub> concentration prediction: Application to indoor air quality control using demand-controlled ventilation. Building and Environment, 205, 2021, 108164.
- [13] 김효준 외 3인, 실내 이산화탄소 농도 예측을 위한 실험적 연구, 한국건축환경설비학회 논문집, 15(6), 2021, pp.613-623. // (H.J. Kim et al., Experimental study on the indoor CO<sub>2</sub> concentration prediction, Journal of KIAEBS, 15(6), 2021, pp.613-623.)
- [14] J. Kallio et al., Forecasting office indoor CO<sub>2</sub> concentration using machine learning with a one-year dataset, Building and Environment, 187, 2021, 107409.
- [15] H. S. Alavi, S. Zhong, D. Lalanne, Predictive models of indoor carbon dioxide concentration to prevent daily decay of productivity and well-being in shared offices, SmartPhil@ IUI, 2020, pp.59-68.
- [16] 윤정욱, 김선훈, 도서관 전열교환기의 재실자수에 따른 기준 환기량 산정 및 수요기반제어, KIEAE Journal, 19(2), 2019, pp.87-92. // (J.W. Yoon, S.H. Kim, A suggestion of ventilation requirements and demand controlled ventilation for energy recovery ventilator based on number of occupants in a library, and its pilot tests, KIE Journal, 19(2), 2019, pp.87-92.)
- [17] J. Schmidhuber, Deep learning in neural networks: An overview, Neural Networks, 61, 2015, pp.85-117.
- [18] B. Lim, S. Zohren, Time-series forecasting with deep learning: a survey, Philosophical Transactions of the Royal Society A, 379(2194), 2021, 20200209.
- [19] S. Costanzo, A. Cusumano, C. Giaconia. Ventilation rates and unsatisfied percentage from indoor CO<sub>2</sub> concentration, Indoor and Built Environment, 20(2), 2011, 232-245.
- [20] 박보량 외 4인, 데이터센터 냉방 에너지 절약을 위한 최적 냉수 유량 예측 제어 알고리즘 개발, KIEAE Journal, 21(3), 2021, pp.47-53. // (B.R. Park et al., Development of optimal chilled water mass flow rate prediction and control algorithm for data center cooling energy saving, KIEAE Journal, 21(3), 2021, pp.47-53.)
- [21] 환경부, 실내공기질 관리법 시행규칙, 환경부령 제918호. // (Ministry of Environment, Enforcement decree of the indoor air quality control act, Ordinance of Ministry of Environment.)