

# 인공지능 모델 기반 환기설비 예측제어 알고리즘 개발

## Development of predictive control algorithm for ventilation systems based on artificial intelligence model

○배 강 우\*      최 영 재\*\*      박 동 혁\*\*\*      서 민 채\*\*\*\*      문 진 우\*\*\*\*\*  
Kang Woo Bae\*    Young Jae Choi\*\*    Dong Hyuk Park\*\*\*    Min Chae Seo\*\*\*\*    Jin Woo Moon\*\*\*\*\*

### Abstract

Existing ventilation control methods that do not reflect occupancy information lead to unnecessary energy consumption. Therefore, in this study, an indoor CO<sub>2</sub> concentration predictive model reflecting real-time occupant information and a predictive ventilation control algorithm was developed. The developed control algorithm was compared to feedback based on/off control. As a result, the ratio exceeding 1,000 ppm was 25.91% lower than the on/off control. A study to increase the comfort rate of indoor air quality through the application of various control cycles will be conducted as a future work.

키워드 : 환기시스템, 예측제어, 인공지능, 재실자 정보

Keywords : ventilation system, predictive control, artificial intelligence, occupant information

## 1. 서 론

### 1.1 연구의 목적

최근 2050 탄소중립 정책 시행에 따라 건축 분야의 에너지 사용량 절감 및 효율 향상이 요구되고 있다. 건물 에너지 사용량 중 환기시스템 에너지 사용 비율은 약 20%로 효율적인 운영이 요구된다. 기존 환기 제어의 경우 건물 스케줄에 따라 가동되며 이는 실시간 재실자 스케줄을 반영하지 않기 때문에 불필요한 에너지소비를 야기한다. 또한, 피드백 제어의 경우 제어변수가 기준치를 초과한 경우 제어를 실시하기 때문에 실내공기질 불쾌적 기간이 발생한다.

따라서, 본 연구에서는 실시간 재실자 정보를 반영한 실내 이산화탄소 농도 예측모델 및 이를 탑재한 예측제어 알고리즘을 개발하였으며, 리빙랩 적용을 통해 제어 성능평가를 실시하였다.

## 2. 연구 방법

### 2.1 리빙랩 구축 및 개요

데이터 취득 대상인 리빙랩은 서울 동작구 C 대학에 위치하며 바닥면적 67.08 m<sup>2</sup>, 재실 인원은 11명 규모이다. 재실 스케줄은 8시부터 20시이며 상황에 따라 유동적이다. 외기 도입과 공기청정이 가능한 환기청정기와 실내외 환경 측정을 위한 IoT 센서 및 재실자 감지를 위한 영상 센서가 설치되어 있다. 데이터는 로컬 서버에 1분 간격으로 저장되며 취득 데이터 목록은 표 1과 같다.

표 1. 리빙랩 개요

| Information       | Details                                                                                                                                     |
|-------------------|---------------------------------------------------------------------------------------------------------------------------------------------|
| Location          | ‘C’ University, Seoul, South Korea                                                                                                          |
| Floor area        | 67.08 m <sup>2</sup>                                                                                                                        |
| Occupant schedule | 11 people<br>08:00 ~ 20:00                                                                                                                  |
| Data list         | CO <sub>2</sub> concentration [ppm],<br>air flowrate [1, 2, 3], system on/off [0, 1],<br>system mode [1, 2, 3],<br>occupant number [person] |

### 2.2 실내 CO<sub>2</sub> 농도 예측 모델 개발

리빙랩을 통해 4월 3일부터 7일까지 데이터를 취득하였고 10분 간격으로 샘플링하여 총 720개의 학습 데이터셋을 구축하였다. 예측모델의 입력데이터는 표 1의 취득데이터와 동일하며 출력데이터는 10분 후의 실내 CO<sub>2</sub> 농도이다. Min-max scaler를 통해 입출력 데이터를 0과 1사이로 정규화하였고, 학습 및 성능평가를 위해 train data (80%), validation data (10%), test data (10%)로 분류하였다.

예측모델은 시계열 데이터 학습에 유리한 long short-term memory (LSTM) 모델을 사용하였다. 모델 구조는 은닉층 수 1개, 뉴런 50개이며 손실함수는 mean squared error (MSE)를 적용하였다. 최적화 함수는 adam optimizer, 활성화 함수는 ReLu를 사용하였고 epoch는 150회, batch size는 5로 설정하였다. 또한, 과적합(overfitting) 방지를 위해 5회 이내 성능개선이 되지 않는 경우 학습을 조기 종료하는 early stopping callback을 적용하였다.

### 2.3 예측제어 알고리즘 개발

리빙랩 실내 CO<sub>2</sub> 농도 기준은 산업보건법 ‘사무실 공기관리 지침’ 권장에 따라 1,000ppm 이하를 만족시켜야한다. 환기청정기의 풍량은 약, 중, 강 3단계로 구분되나, 약·중풍은 풍량이 부족하여 실내 CO<sub>2</sub> 농도 기준을 충족시키지 못해 강풍만 사용하였다.

예측제어 알고리즘은 4단계로 구분되며 그림 1과 같다. 첫째, 실내 CO<sub>2</sub> 농도, 환기설비 가동 상태 및

\* 중앙대 대학원 석사과정

\*\* 중앙대 대학원 박사과정

\*\*\* 중앙대 대학원 석사과정

\*\*\*\* 중앙대 대학원 학석사연계과정

\*\*\*\*\* 중앙대 건축학과 교수, 공학박사

(교신저자 : gilerbert73@gmail.com)

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

모드, 풍량, 재실자 수 데이터를 가져온다. 둘째, 주중 및 주말을 구분하고 일과 시간에 따른 가동 여부를 판단한다. 셋째, LSTM 예측 모델을 통해 10분 후 실내 CO<sub>2</sub> 농도를 예측한다. 마지막으로 예측값이 1,000ppm을 초과하는 경우 환기설비를 가동하며, 10분마다 해당 알고리즘을 반복한다.




그림 1. 예측제어 알고리즘 구성도

### 3. 성능 평가

#### 3.1 실내 CO<sub>2</sub> 예측모델 성능평가

성능평가는 학습에 사용되지 않은 test 데이터와 예측값을 비교하였으며, 예측정확도 평가지표는 mean absolute error (MAE), coefficient of variation of root mean square error (CvRMSE), R<sup>2</sup>이다. 두 지표는 예측값과 실측값의 오차에 기반하여 산출되므로 0에 가까울수록 성능이 우수한 것을 의미한다.

성능평가 결과는 표 2와 같다. MAE는 29.56 ppm, CvRMSE는 7.05%, R<sup>2</sup>는 0.9416로 우수한 예측정확도를 나타냈으며, 해당 예측모델은 예측제어 알고리즘에 탑재하였다.

표 2. 예측모델 성능평가

| MAE       | CvRMSE | R <sup>2</sup> |
|-----------|--------|----------------|
| 29.56 ppm | 7.05%  | 0.9416         |

#### 3.2 예측제어 알고리즘 성능평가

예측제어 알고리즘은 on-off 제어와 비교하였으며, 실시간 예측정확도 및 제어성능에 대한 평가를 실시하였다. 실시간 예측정확도 결과는 표 3과 같다. MAE, CvRMSE, R<sup>2</sup>는 각각 48.29 ppm, 6.67%, 0.9130로 산출되었다. MAE가 예측모델 성능평가 대비 높아진 이유는 실제 적용시 CO<sub>2</sub> 농도가 급변하는 구간에서 비교적 큰 오차가 발생했기 때문인 것으로 분석된다.

제어성능 평가는 객관적 비교를 위해 6인 이상 재실 기간

중 실내 CO<sub>2</sub> 농도 실측값이 1,000ppm이 넘는 구간 비율을 산출하여 비교하였으며 제어 결과는 그림 2, 3과 같다. 1,000ppm 초과 비율은 예측제어 모델이 28.17%, on-off 제어가 38.03%로 예측제어 모델 1,000ppm 초과 비율이 25.91% 낮음을 확인할 수 있었다.

표 3. 예측제어 알고리즘 성능평가

| MAE       | CvRMSE | R <sup>2</sup> |
|-----------|--------|----------------|
| 48.29 ppm | 6.67%  | 0.9130         |




그림 2. 예측제어 모델 적용 결과




그림 3. on-off 제어 모델 적용 결과

### 4. 결 론

기존 환기제어 방식은 재실자 정보를 반영하지 않아 에너지 과소비를 야기하였다. 본 논문에서는 이를 개선하기 위하여 실시간 재실자 정보 기반 CO<sub>2</sub> 예측 모델 및 제어 알고리즘을 개발하였으며 결과는 다음과 같다.

첫째, CO<sub>2</sub> 예측모델 성능평가 결과 MAE, CvRMSE, R<sup>2</sup>는 각각 29.56 ppm, 7.05%, 0.9416의 우수한 성능을 나타냈다.

둘째, 예측제어 알고리즘과 on/off 제어를 비교하였다. 그 결과 6인 이상 재실 기간 중 예측제어 시 CO<sub>2</sub> 1,000 ppm 초과 비율이 on-off 제어모델 대비 25.91% 감소하였다.

이를 통해 예측제어 적용시 보다 쾌적한 실내공기질 제공이 가능함을 확인할 수 있었으며 추후 연구로는 다양한 제어 주기 적용을 통해 실내 쾌적 구간을 증가시키고 동시에 에너지소비를 최소화할 수 있는 연구를 진행할 예정이다.

### 참고문헌

- 최영재, 박보량, 현지연, 문진우 순환 신형망 모델에 따른 재실 인원 예측모델 개발 및 성능비교, 대한건축학회논문집, Vol.38, 2022
- 김승범, 김주형, and 김재준. "강의실에서의 이산화탄소 농도 제어 방안 연구." 한국건축환경설비학회 학술발표대회 논문집 (2012): 97-100.
- '사무실 공기관리 지침', 산업보건법 고용노동부고시 제2020-45호