

인공지능 기반 실내 PM_{2.5} 및 CO₂ 통합 제어 알고리즘을 적용한 외기도입형 환기청정기 성능 분석

Performance Analysis of an Outdoor Air-Introduced Ventilation Cleaner Applied with an AI based Indoor PM_{2.5} and CO₂ Integrated Control Algorithm

변재윤(Jea Yoon Byun)¹, 김태원(Tae Won Kim)², 최은지(Eun Ji Choi)³, 문진우(Jin Woo Moon)^{4†}

¹중앙대학교 건축학과 대학원 석사과정, ²중앙대학교 건축학과 대학원 박사과정,

³중앙대학교 건축학과 건축학부 연구전담교수, ⁴중앙대학교 건축학과 건축학부 교수

¹Master's Program, Department of Architecture, Chung-Ang University, 84, Heukseok-ro, Dongjak-gu, 06974, Korea

²Ph.D. Program, Department of Architecture, Chung-Ang University, 84, Heukseok-ro, Dongjak-gu, 06974, Korea

³Ph.D, Department of Architecture, Chung-Ang University, 84, Heukseok-ro, Dongjak-gu, 06974, Korea

⁴Professor, Department of Architecture, Chung-Ang University, 84, Heukseok-ro, Dongjak-gu, 06974, Korea

(Received December 27, 2024; revision received January 13, 2025; Accepted: January 15, 2025)

Abstract Amid growing concerns about health risks, the demand for safer indoor air quality has significantly increased, necessitating advanced control solutions. Previous studies focused on ventilation, air purification control, and the proactive management of indoor air pollutants. However, most of these studies relied on computer simulations, with few applications in real-world environments. In response, this study developed an AI-based integrated control algorithm for indoor PM_{2.5} and CO₂ using empirical data. The algorithm incorporates prediction models for indoor PM_{2.5} and CO₂ based on artificial neural networks, enabling proactive control. It was applied in a living lab to validate its effectiveness in improving indoor air quality and reducing energy consumption. The integrated control algorithm demonstrated an average reduction of 19.69% in indoor PM_{2.5} concentrations and 6.59% in CO₂ concentrations compared to the existing rule-based algorithm, while also decreasing energy consumption by 9.42%. Furthermore, the algorithm maintained indoor PM_{2.5} and CO₂ concentrations below established criteria for a longer duration, confirming its superior performance. The integrated control algorithm developed in this study effectively achieved both indoor air quality management and energy consumption reduction, contributing to the sustainable development of building environment management and control.

Key words Control algorithm(제어 알고리즘), Indoor air quality(실내공기질), Prediction model(예측모델), Ventilation systems(환기시스템)

† Corresponding author, E-mail: gilerbert73@cau.ac.kr

기호설명

TE : 외기도입형 환기청정기 모드 및 풍량별 총 에너지 소비량 [kWh] 후 절약설계기준 열관류율의 변화율 [%]

Q_i : 외기도입형 환기청정기 모드 및 풍량별 작동시간 [분]

PE_n : 외기도입형 환기청정기 운전 상태별 에너지 소비량 [kWh]

1. 서 론

실내 공기질은 건물 내 가스 및 미세먼지와 미생물 등 오염물질에 따라 유해 정도가 달라지며, 재실자의

생산성과 건강에 매우 중요한 역할을 한다.^(1,2) 최근에는 이러한 실내 공기질에 대한 관심도가 높아지며 깨끗하고 안전한 공기질에 대한 수요가 증가하고 있는 추세다. 세계보건기구(WHO, World Health Organization)에서는 2020년에 대기오염으로 인해 약 320만 명, 실내 공기질 오염으로 약 350만 명이 사망한 것으로 추산하고 있다.⁽³⁾ 그중 입자형 오염물질인 미세먼지(Particulate Matter, PM)는 대기오염물질의 중요한 구성요소로 실내 공기질에서 가장 유해한 물질인 것으로 보고되고 있다.⁽⁴⁾ Kyung et al.⁽⁵⁾은 PM_{2.5} 농도가 10 µg/m³ 증가할수록 폐암 발생이 9% 증가하고, PM₁₀ 농도가 10 µg/m³ 증가할수록 만성폐쇄성폐질환 관련 입원이 2.7%, 만성폐질환 관련 사망이 1.1% 증가한다고 한다는 연구결과를 발표했으며, Kim et al.⁽⁶⁾은 PM_{2.5}가 아토피 피부염을 가진 사람들에게 증상을 악화시킬 수 있음을 확인하였다. 특히, 면역력 취약 계층들에게 장기적으로 노출될 시 면역력을 약화시켜 기관지염과 호흡기 질환을 발생시킬 수 있고 심장질환을 가진 사람에게는 심장기능이 저하될 수 있다.⁽⁷⁾ 따라서, 미세먼지는 재실자 안전을 위해 실내 공기질 제어 시 최우선적으로 고려되어야 할 요소라 할 수 있다.

이러한 실내 미세먼지는 대표적으로 환기 및 공기청정을 통해 저감이 가능하다. 이 두 개의 시스템은 하나의 시스템만을 사용했을 경우 실외의 공기를 들여와 냉난방 부하가 증가한다거나, 환기 없이 실내 공기 순환만을 반복하여 이산화탄소(Carbon dioxide, CO₂) 농도를 급격히 높이는 등의 문제점을 야기할 수 있다. 이 경우 환기량 감소로 인해 이산화탄소 농도가 2,300 ppm까지 증가하는 등의 부작용을 초래할 수 있으며, 실내 이산화탄소 농도가 2,000 ppm 이상으로 증가하면 재실자들에게 피로감, 두통, 집중력 저하 등과 같은 증상을 유발하고 특히 사무 환경에서 생산성 저하를 일으킬 수 있다.⁽⁸⁾ 따라서, 실내공기질 오염물질 중 미세먼지 및 이산화탄소는 쾌적하고 효과적인 실내환경을 유지하기 위해 필수적으로 제어되어야 할 요소라고 할 수 있다.

실내 미세먼지는 제어 시 저감 난이도 측면에서 단순 자연 환기만으로는 실내에 축적, 침착된 미세먼지를 저감하기 어렵기 때문에 기계적인 환기시스템과 공기청정 기능이 복합적으로 적용될 필요가 있다. 또한, 가스형 오염물질인 이산화탄소는 창문, 문을 열어 자연 환기를 시키는 것만으로도 빠른 저감이 가능하므로 공조시스템의 복합적인 제어가 중요하다 할 수 있다. 이러한 복합적 제어는 실시간으로 변화하는 오염원에 대한 예측을 기반으로 하기 때문에 예측모델을 사용한 연구가 주를 이룬다. 선행연구 분석 결과, 실내공기질 예측은 인공신경망, 퍼지이론, 회귀모델 등 다양한 방식이 있으며 그중 인공신경망(Artificial Neural Network, ANN) 모델을 사용할 경우 가장 높은 예측 정확도를 보임이 확인되었다.⁽⁹⁾ 특히 최근에는 예측 기술을 통해 선제적으로 실내공기질을 제어하고자 하는 시도가 확인되고 있다. Cho et al.⁽¹⁰⁾은 지능형 HVAC 제어 전략을 고안하고 실내의 다양한 실내공기질 영향 요소를 복합적으로 고려하여 컴퓨터 시뮬레이션을 활용해 그 성능을 검증하였으며, Choi and Lee⁽¹¹⁾는 중등학교시설에서 이산화탄소를 사전 제어하기 위한 창호개폐 작동 알고리즘을 개발하고 컴퓨터 시뮬레이션 모델링을 진행하였다. 또한, Shi et al.⁽¹²⁾은 실내 PM_{2.5} 예측 알고리즘인 LATCN를 제안하고 기존 예측 알고리즘과 성능을 비교하였다. 하지만 대부분의 연구가 다양한 인공신경망 기술들의 성능을 비교하는 것에 그쳤으며, 실증 실험을 통해 성능을 검증하지 않은 한계를 가지고 있었다. 실제로 실내공기질 제어 관련 연구의 대다수가 수치 분석 혹은 컴퓨터 시뮬레이션을 활용한 연구로 조사되고 있으며, 실제 공간에 적용하여 실측 데이터를 취득하거나 제안한 제어 전략의 실증을 진행한 연구는 상대적으로 적었다.⁽¹³⁾

따라서, 본 연구에서는 이러한 문제를 해결하기 위하여 실측데이터 기반 인공지능 예측모델과 실내공기질을 선제적으로 제어할 수 있는 미세먼지 및 이산화탄소 통합 제어 알고리즘을 개발하였다. 이후 실제 사용 중인 리빙랩에 제어 알고리즘을 적용하여 실내공기질 개선 성능과 에너지소비량을 비교 분석하였다.

2. 실내 PM_{2.5} 및 CO₂ 통합 제어 알고리즘 개발

2.1 알고리즘 단계별 구조

본 연구에서 개발된 제어 알고리즘은 실내 오염물질 중 입자형 오염물질인 PM_{2.5}와 가스형 오염물질인 CO₂를 제어 대상으로 고려하며 인공지능 기반의 실내 PM_{2.5} 및 CO₂ 농도 예측모델이 탑재되어 예측값과 실시간 공기질 데이터를 기반으로 제어를 수행한다. 이때 예측모델은 실내공기질 오염물질 예측에 적합하다고 판단된 ANN, 그중에서도 MLP를 예측모델로 선정하여 개발하였으며 시뮬레이션 모델링 및 실제 환경에 적용한 실증 실험 등을 수행한 선행연구를 통해 실시간 예측이 가능함을 확인하였다.⁽¹⁴⁻¹⁶⁾ 제어 알고리즘은 Fig. 1과 같이 총

5단계로 나누어져 있으며, 매 제어 사이클에 모든 과정이 순서대로 반복된다.

1단계는 설치된 환경센서를 통해 취득되는 실내환경 데이터와 외기도입형 환기청정기에서 수집되는 가동 상태 데이터를 DB에 실시간으로 저장한다. 2단계는 제어 알고리즘이 적용될 공간의 재실 스케줄을 입력하여 일별 상황에 따라 운영 여부를 결정한다. 3단계에서는 탑재된 실내 PM_{2.5} 및 CO₂ 예측모델이 1단계에서 수집된 실내환경 데이터와 시스템 가동 상태 데이터를 사용하여 예측을 수행한다. 이때 각 풍량(약, 중, 강)을 입력값으로 사용한 3개 예측값이 도출되는데, 이 중 PM_{2.5} 농도를 15 µg/m³ 미만으로 예측한 풍량 중 에너지가 가장 적게 소비되는 풍량이 시스템 풍량값으로 사용된다.

4단계는 외기도입형 환기청정기의 작동 모드가 선택되는 단계이다. 이때 첫 번째로 실내 PM_{2.5} 농도는 한국 환경부 대기환경기준 PM_{2.5} 농도 “좋음”(15 µg/m³)을 달성하는 것을 목표로 하며, 두 번째로 실내 CO₂ 농도는 한국 교육부 학교보건법 시행규칙 기준 CO₂ 농도 권고 사항(1,500 ppm)을 달성하는 것을 목표로 한다. 이는 개발된 제어 알고리즘이 적용될 리빙랩 특성에 따라 13세 미만 어린이들의 건강을 보호하기 위함이며, 해당 기준은 사용 지역과 적용 공간에 따라 변경될 수 있다. 작동 모드 선택 순서는 다음과 같다. 첫 번째로 현재 실내 PM_{2.5} 농도 및 CO₂ 농도를 고려한다. 현재 실내 PM_{2.5} 농도가 35 µg/m³ 초과일 경우, 이는 학교보건법 시행규칙 기준 교실 PM_{2.5} 농도 권고 사항을 초과한 수치이므로 신속한 저감을 위해 즉시 중 풍량으로 환기장치를 가동하도록 설정하였다. 마찬가지로 현재 실내 CO₂ 농도가 1,500 ppm 초과일 경우 신속한 저감을 위해 즉시 외기도입 모드를 가동하도록 설정하였다.

이후, 3단계에서 도출한 실내 PM_{2.5} 및 CO₂ 농도 예측값에 따라 환기장치의 풍량 및 모드를 선택하도록 설정하였다. 우선 실내 PM_{2.5} 농도가 15 µg/m³ 초과일 때, 실내 PM_{2.5} 농도 예측값이 15 µg/m³ 이하일 경우

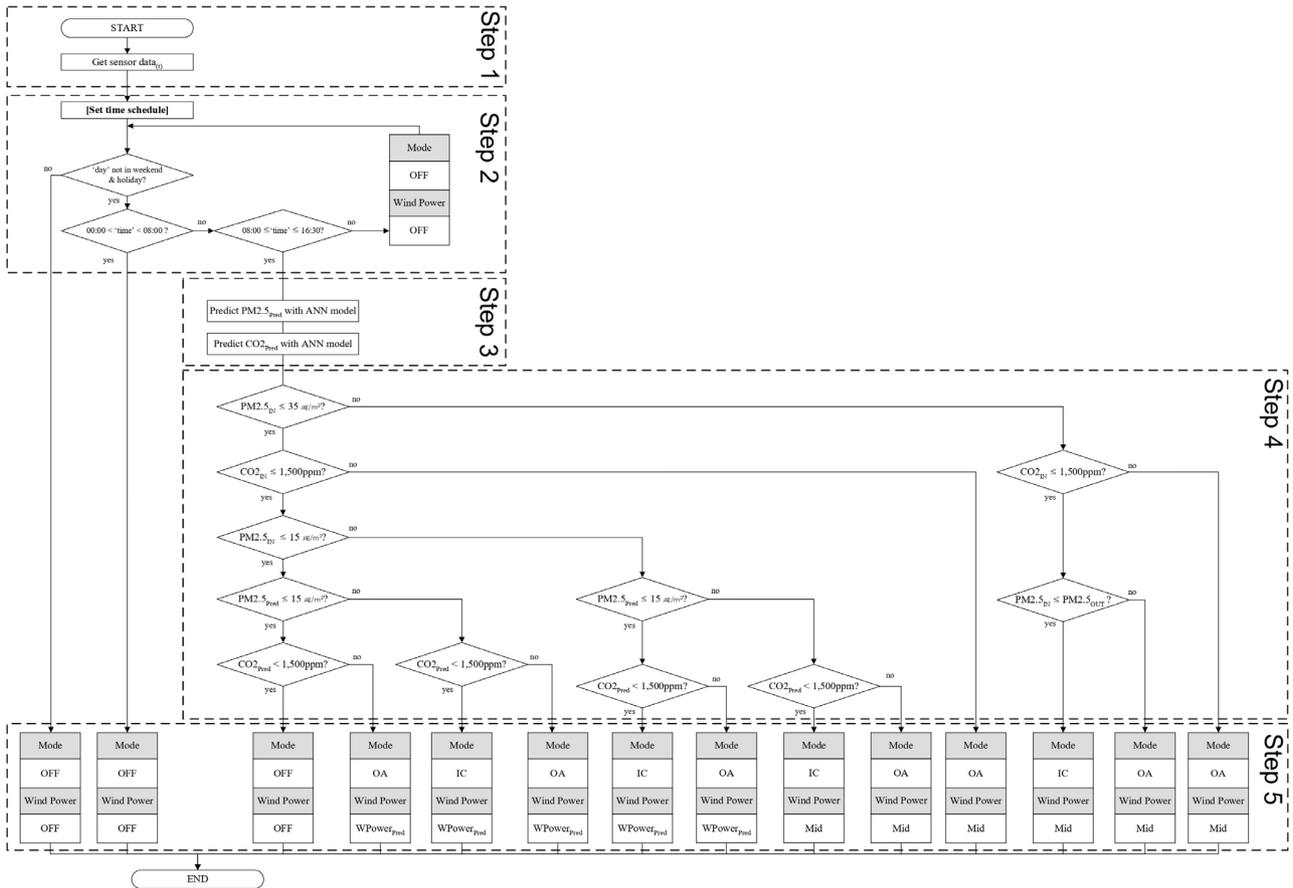


Fig. 1 PM_{2.5} and CO₂ integrated control algorithm flow chart.

3단계에서 도출한 풍량에 따라 가동하고 초과일 경우 중 풍량으로 가동한다. 이때 실내 CO₂ 농도 예측값이 1,500 ppm 이하일 경우 내기 순환 모드를, 초과일 경우 외기도입 모드를 가동한다. 반대로, 실내 PM_{2.5} 농도가 15 µg/m³ 이하일 경우에는 3단계에서 도출된 풍량에 따라 가동하며, 실내 CO₂ 농도 예측값에 따라 내기순환 및 외기도입 모드를 선택 가동한다. 만약 현재 실내 PM_{2.5} 및 CO₂ 농도와 예측된 실내 PM_{2.5} 및 CO₂ 농도 모두 기준 이하를 충족할 경우 환기장치의 모드 및 풍량을 OFF로 설정한다. 이후 마지막 5단계에서는 상기 단계에서 도출된 제어값으로 시스템을 가동하도록 환기장치에 명령을 보낸다.

2.2 예측모델 개발

예측모델은 실시간으로 변화하는 오염원에 대한 예측을 기반으로 하며 다양한 상황에 대한 정확하고 안정적인 예측이 필요한 최적제어 분야에 강점을 가진다. 특히 실내공기질 예측의 경우 비선형 데이터 예측이며 타 방식 대비 병렬 분산처리에 적합하여 연산 처리 속도가 빠르고 학습 적응이 가능해 주위 환경 변화에 대한 적응력이 뛰어나다는 장점을 보이는 ANN으로 개발되었다.⁽¹⁷⁾ ANN 중 특히 MLP 모델은 다른 인공지능 모델보다 가용성이 빠르며 구현이 쉽고 모델의 구조가 단순하다는 특징을 가지며 예측이 안정적이고 시간적 의존성이 약하다. 따라서, 본 연구에서는 MLP를 기반으로 하는 실내공기질 오염원 예측모델을 개발하였다.

본 연구에서 개발된 예측모델의 학습데이터는 실증이 진행될 리빙랩의 실제 운영 데이터를 사용하였다. 이는 예측모델 및 예측값 기반 실시간 제어 알고리즘의 특성상 해당 공간에서 취득된 데이터를 사용해서 예측모델을 개발할 경우에 가장 높은 예측 정확도를 보이기 때문이며, 이를 위해 실제 적용될 공간 맞춤형으로 개발될 필요가 있기 때문이다. 학습데이터 세트는 21년 9월부터 23년 6월까지의 데이터 중 재실 시간 평균 실내 PM_{2.5} 농도 5 µg/m³ 이상, 실내 CO₂ 농도 600 ppm 이상, 오전 시간 동안 2회 이상 실내 수업 진행을 모두 만족한 날의 데이터만 사용하여 구축되었다. 이는 학습에 재실시간의 데이터만을 사용하기 위한 조건으로, 예측모델의 정확성을 향상하기 위한 조치이다. 학습데이터는 총 13,422개가 수집되었다.

각 예측모델별 입력변수는 실내 PM_{2.5} 및 CO₂ 농도 형성에 영향을 미치는 것으로 조사된 인자들 중 실시간 취득이 용이한 요소들을 대상으로 설정하였다. 먼저 실내 PM_{2.5} 예측모델의 입력변수는 실내외 온도, 실내외 CO₂ 농도, 실내외 PM₁₀ 및 PM_{2.5} 농도와 외기도입형 환기청정기의 급기 풍량이 사용되었으며, 실내 CO₂ 예측모델의 입력변수는 실내외 PM₁₀ 및 PM_{2.5} 농도, 실내외 CO₂ 농도, 외기도입형 환기청정기 급기 풍량 및 작동모드가 사용되었다. 이때 실내 PM_{2.5} 예측모델 입력변수 중 작동모드가 포함되지 않는 것은 실외 공기를 실내로 들여올 때 HEPA 필터를 통해 유입되므로 PM_{2.5} 농도의 차이가 크지 않기 때문이다. 각 예측모델의 출력변수는 5분 후의 PM_{2.5} 및 CO₂ 농도이다. 학습데이터에 대한 자세한 내용은 Table 1과 같다.

Table 1 Details of each prediction model training data

Classifications	Details
Data collection period	Sep. 2021 - Jun. 2023
Training data selection criteria	1) Average indoor PM _{2.5} concentration above 5 µg/m ³ during occupancy 2) Average indoor CO ₂ concentration above 600 ppm during occupancy 3) Two or more sessions of indoor class before noon 4) Days that passes 1, 2, and 3 criteria
Number of data	13,422
Input data	PM _{2.5} Model Indoor: Temperature, Relative Humidity, CO ₂ / PM _{2.5} / PM ₁₀ concentration Outdoor: Temperature, Relative Humidity, CO ₂ / PM _{2.5} / PM ₁₀ concentration System: Wind power
	CO ₂ Model Indoor: CO ₂ / PM _{2.5} / PM ₁₀ concentration Outdoor: CO ₂ / PM _{2.5} / PM ₁₀ concentration System: Mode, Wind power
Output data	Indoor PM _{2.5} concentration after 5 minutes / Indoor CO ₂ concentration after 5 minutes

Table 2 Structure of each prediction model

Hyperparameters	Details	Optimizers	Details
Number of neurons for hidden layers	10 ~ 100	Batch size	32
Number of hidden layers	1 ~ 10	Number of epochs	50
Activation function	relu	Type of optimizer	Adam
Learning rate	0.0001	Loss function	MSE

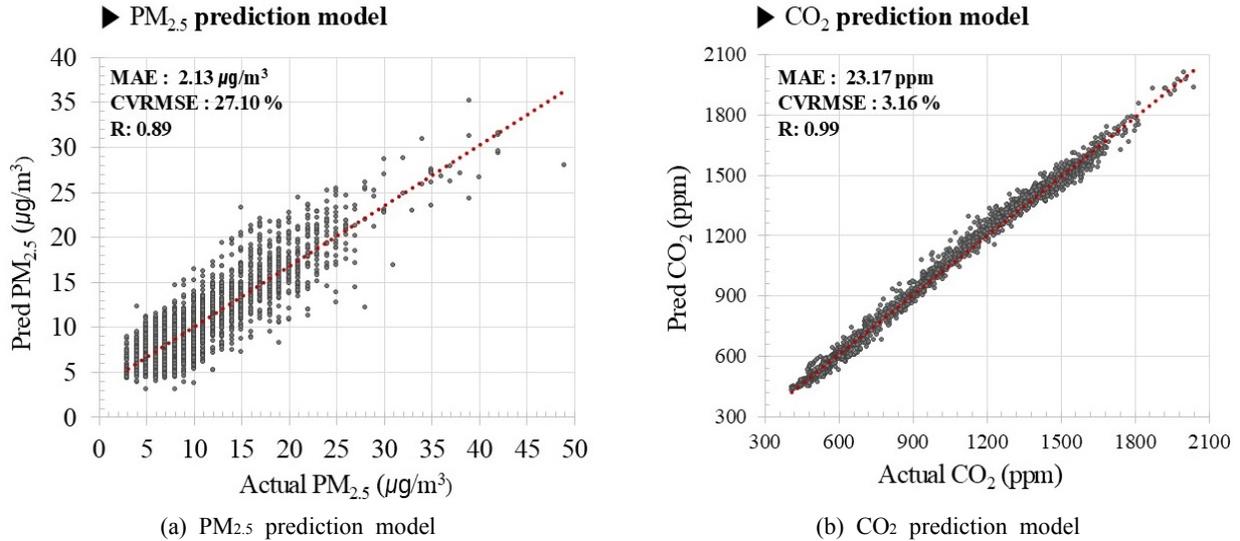


Fig. 2 Performance of each prediction model.

본 연구에서 개발된 각 예측모델은 베이지안 최적화기를 통해 최적의 하이퍼파라미터 조합을 탐색 및 도출하였다. 이에 하이퍼파라미터 탐색 대상으로 층간뉴런(Hidden neurons), 은닉층(Hidden layer), 학습률(Learning rate)을 선정하였으며, 최적화기로는 아담(Adam)을, 활성화함수(Activation Function)는 reLu, 손실함수(Loss Function)는 MSE(Mean Square Error)로 설정하였다. 이에 대한 자세한 내용은 Table 2와 같다. 그 결과 도출된 예측모델의 최적 구조는 실내 PM_{2.5} 예측모델과 CO₂ 예측모델 모두 입력 레이어 1개, 은닉 레이어 4개(25, 49, 45, 5), 출력 레이어 1개로 나타났다.

예측모델의 성능은 MAE (Mean Average Error)와 CVRMSE(Coefficient of Variation, Root Mean Square Error), Pearson's r(Pearson correlation coefficient) 세 가지 지표를 통해 검증을 진행하였다. 각 예측모델별 성능은 실내 PM_{2.5} 예측모델이 MAE 2.13 µg/m³, CVRMSE 27.10%, R 0.89로, 실내 CO₂ 예측모델은 MAE 23.17 ppm, CVRMSE 3.16%, R 0.99로 나타났다. 예측모델의 Test data에 대한 예측값을 실제 데이터와 비교하여 분산형으로 나타낸 Fig. 2를 살펴보면, 실내 PM_{2.5} 및 CO₂ 예측모델 모두 y=x 함수에 근사하게 나타나는 것을 확인할 수 있다. 이는 본 연구와 유사한 연구를 수행한 타 연구와 비교했을 때 유사한 수치이다.^(18,19) 개발된 예측모델은 통합 제어 알고리즘에 탑재되어 선제적 제어 수행 시에 활용하였다.

3. 성능 분석

본 연구에서 개발된 실내 PM_{2.5} 및 CO₂ 통합 제어 알고리즘은 예측모델이 탑재되지 않은 룰베이스 알고리즘과 함께 실제 사용 중인 초등학교 교실 리빙랩 2개소에 각각 적용되었다. 리빙랩은 1층에 있는 1학년 교실로 학급당 약 21명 학생과 선생님 1인이 배정되어 있는 보편적인 초등학교 특성을 가지며, 주출입구 에어커튼 및 먼지흡입 발판 설치 등의 건축적, 기계 설비적 개선 리모델링 사업이 진행되었다. 실험은 총 6일 동안 진행되었으며 두 리빙랩이 모두 재실 중인 시간 동안 분석을 진행하였다. 초등학교 리빙랩 특성상 단축수업이

잡고 방과 후 활동의 여부에 따라 재실 시간이 매일 다르기 때문에, 각 날짜 별 취득된 데이터의 수는 달라질 수 있다. 이때 두 리빙랩은 인접한 교실로, 같은 스케줄을 공유하고 재실 인원수가 동일하다.

3.1 실내 PM_{2.5} 및 CO₂ 농도

리빙랩에서 6일 동안 수집된 실내 공기질 데이터 분석 결과, 두 알고리즘 모두 대부분의 시간대에서 환경부 대기환경기준 “중음”(15 $\mu\text{g}/\text{m}^3$)과 교육부 학교보건법 시행규칙 “공기 질 등의 유지 관리기준”(1,500 ppm)을 만족시켰다. 실내 PM_{2.5} 농도의 경우, 통합 제어 알고리즘이 적용된 교실의 6일 평균 실내 PM_{2.5} 농도는 10.73 $\mu\text{g}/\text{m}^3$, 룰베이스 알고리즘이 적용된 교실은 PM_{2.5} 농도는 13.36 $\mu\text{g}/\text{m}^3$ 으로 나타났으며, 이를 통해 통합 제어 알고리즘이 룰베이스 알고리즘 보다 약 19.69% 더 낮게 유지함을 확인하였다. 또한 통합 제어 알고리즘이 적용된 교실의 경우 실내 PM_{2.5} 농도가 15 $\mu\text{g}/\text{m}^3$ 이하를 유지한 비율은 81.52%로, 룰베이스 알고리즘이 적용된 교실의 79.37% 대비 더 길게 유지되었음을 확인하였다. 제어 알고리즘 별 실내 PM_{2.5} 농도는 Fig. 3에서 확인할 수 있다.

실내 CO₂ 농도의 경우, 통합 제어 알고리즘이 적용된 교실의 6일 평균 실내 CO₂ 농도는 1,000.75 ppm이었으며, 룰베이스 알고리즘이 적용된 교실은 CO₂ 농도는 1,071.39 ppm으로 통합 제어 알고리즘이 룰베이스 알고리즘 보다 약 6.59% 더 낮게 유지함을 확인하였다. 또한 실내 PM_{2.5} 농도와 마찬가지로, 통합 제어 알고리즘이 적용된 교실의 경우 실내 CO₂ 농도가 1,500 ppm 이하를 유지한 비율이 87.10%로, 룰베이스 알고리즘이 적용된 교실의 83.79% 보다 더 길게 유지되었음을 확인하였다. 제어 알고리즘 별 실내 CO₂ 농도는 Fig. 4에서 확인할 수 있다.

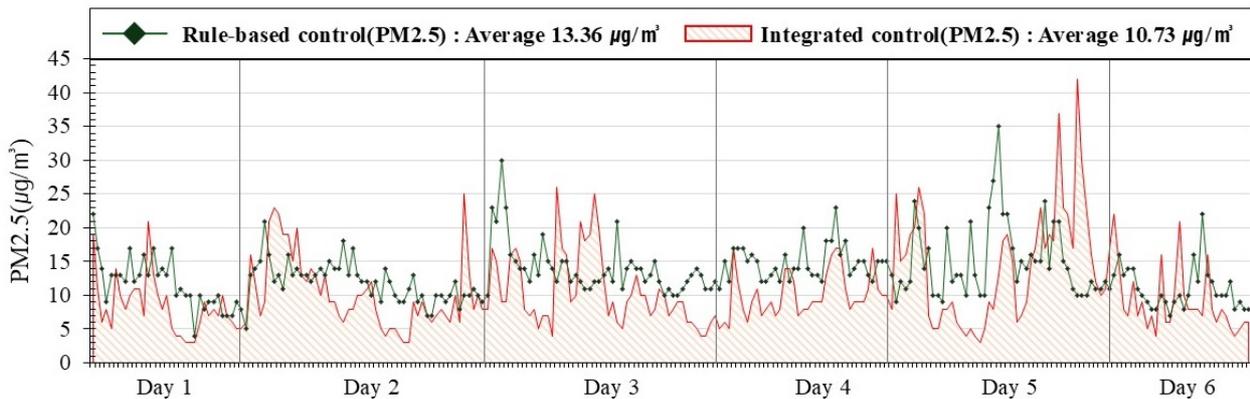


Fig. 3 Indoor PM_{2.5} concentration by control algorithm.

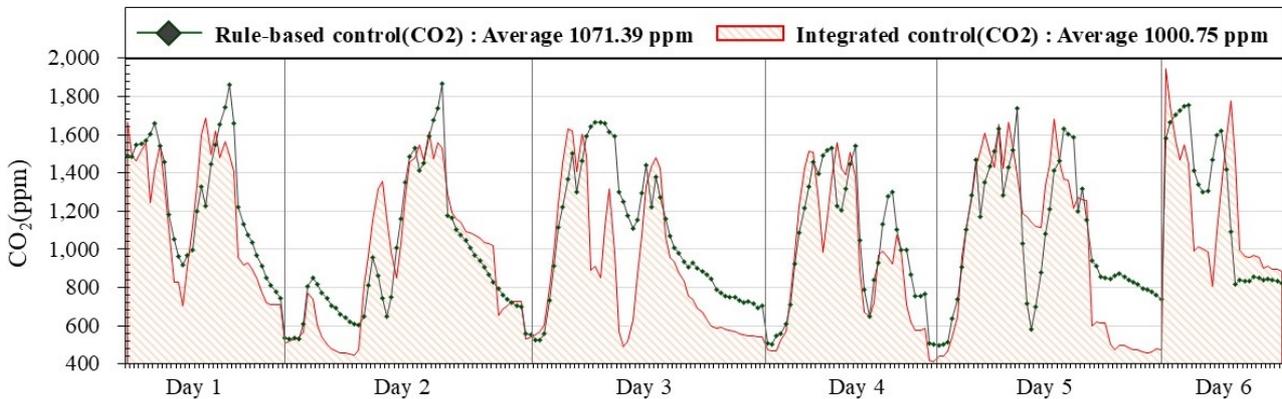


Fig. 4 Indoor CO₂ concentration by control algorithm.

3.2 가동 시간에 따른 에너지 사용량

해당 파트에서는 리빙랩 외기도입형 환기청정기에 적용된 각 제어 방법별 에너지소비량과 시스템 가동시간을 비교하였다. 데이터 분석은 Fig. 1에서 수집된 6일 데이터가 사용되었으며, 계산과정은 식(1)로 정의된다. TE 는 총 에너지 O_t 는 모드 및 풍량별 작동 시간, PE_n 작동되는 모터의 풍량별 에너지소비량을 의미하며, 분모의 60은 분당 에너지 소비량으로 환산하기 위함이다.

$$TE = \sum_{i=1}^n (O_t (\frac{PE_n + PE_n}{60})) \tag{1}$$

Table 3은 각 알고리즘별 운전모드에 따른 에너지소비량과 가동시간을 보여준다. 이때 통합 제어 알고리즘의 총 가동 시간이 룰베이스 제어 알고리즘보다 78분 긴 것은 통합 제어 알고리즘이 가동된 교실에서 수업 종료 후 학사회의 회의가 30여 분 씩 2차례 진행되었기 때문으로 확인됐다. 해당 78분 중 환기장치가 가동하여 발생한 에너지 소비량은 0.02 kWh로 전체 에너지 소비량 분석에 유의미한 영향을 미치지 않는다.

데이터 분석 결과 에너지소비량은 통합 제어 알고리즘이 룰베이스 알고리즘보다 9.42% 적은 것으로 나타났으며, 가동 시간은 룰베이스 제어 알고리즘이 2.99% 더 짧은 것으로 나타났다. 이는 알고리즘의 특성이 전체 가동 시간 및 가동 모드에 영향을 미쳤기 때문으로 판단된다. 본 연구에서 사용된 환기장치의 경우 외기도입 모드 가동 시에는 모터가 2개 가동되고 내부순환 모드 가동 시에는 1개 가동되기 때문에 에너지 소비량이 외기도입 모드 가동 시 내부순환 모드 대비 약 2배 크다. 또한, 통합 제어 알고리즘은 예측값에 따라 제어하기 때문에 실내 CO₂가 더 낮은 농도에서 선제적으로 저감되어 실내 CO₂ 농도가 1,500 ppm을 초과한 시간이 짧다. 이에 따라 통합 제어 알고리즘은 내부순환 모드의 가동이 상대적으로 더 많았다. 반면 룰베이스 알고리즘은 실내 CO₂ 농도가 1,500 ppm을 초과한 순간부터 환기장치 가동이 시작되므로, 실내 CO₂ 농도가 1,500 ppm을 초과한 시간이 길며 저감에 필요한 시간도 더 길었다. 이에 룰베이스 알고리즘은 외기도입 모드가 내부순환 모드보다 더 많이 가동되었다. 따라서 룰베이스 알고리즘은 통합 제어 알고리즘보다 가동 시간이 더 짧음에도 불구하고 외기도입 모드 가동의 비중이 커서 에너지소비량이 더 높게 나온 것을 확인할 수 있다.

Fig. 5는 통합 제어 알고리즘이 실내공기질을 선제적으로 제어하기 위해 가동되는 시간을 룰베이스 알고리즘과 비교한 그래프이다. 전체 가동 시간 중 실내 PM_{2.5} 및 CO₂ 농도가 기준치 이하로 유지되는 시간은 통합 제어 알고리즘 1,697분, 룰베이스 알고리즘 1,213분으로 통합 제어 알고리즘이 484분 더 길었다. 전체 가동 시간 대비 비율의 경우, 통합 제어 알고리즘이 가동된 교실은 전체 가동 시간 중 64.94%의 시간 동안 실내 PM_{2.5} 및 CO₂ 농도가 기준치 이하로 유지되었으며, 룰베이스 알고리즘의 47.85% 대비 더 길게 유지됨을 확인하였다. 이는 각 제어 방법별 전체 가동 시간을 백분위로 환산하였을 시 17.09% 차이 나는 수치로 통합 제어 알고리즘의 실내공기질 제어 성능이 룰베이스 제어 알고리즘보다 우수하다는 것을 의미한다. 이때 통합 제어 알고리즘은 실내공기질이 기준치 이하로 유지되는 쾌적 상태에서 668분 작동되었는데, 이는 탑재된 예측모델 예측값에 따라 실내공기질이 선제적으로 제어되었음을 의미한다. 선제적 제어를 위해 가동된 시간은 통합 제어 알고리즘 총 가동 시간 2,613분 중 25.56%, 전체 에너지소비량 0.519 kWh 중 44%를 차지한다.

Table 3 Energy consumption and operating time of outdoor air-introduced ventilation cleaner operation mode

	Rule-based Control Algorithm		Integrated Control Algorithm	
	Energy Consumption[kWh]	Operation Time[min]	Energy Consumption[kWh]	Operation Time[min]
OFF	0	1,199	0	1,209
Indoor-air recirculation	0.108	502	0.235	809
Outdoor-air intake	0.465	834	0.284	585
Total	0.573	2,535	0.519	2,613

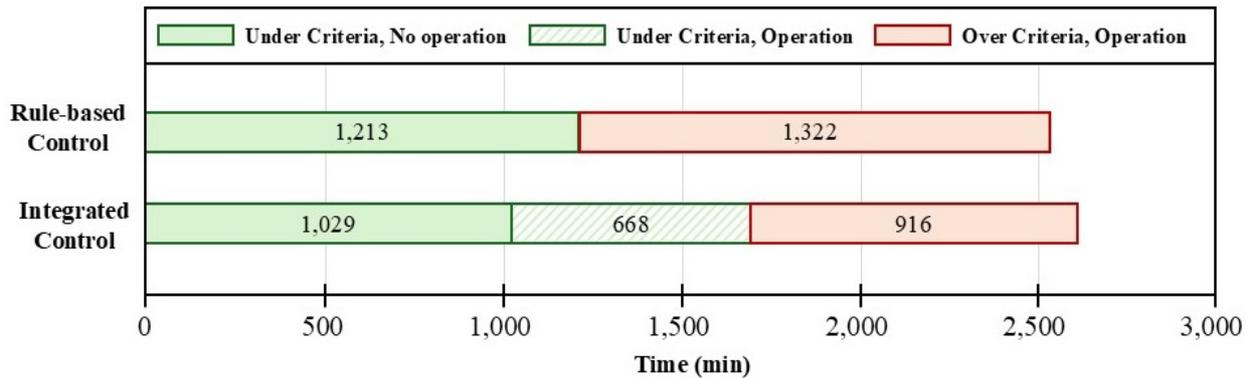


Fig. 5 Comparison of indoor PM_{2.5} and CO₂ concentration standards compliance time and operation time.

4. 결 론

본 연구는 재실자에게 쾌적한 공기질을 제공할 수 있는 인공지능 기반 실내 PM_{2.5} 및 CO₂ 통합 제어 알고리즘을 개발하고자 하였다. 이를 위해 MLP를 활용한 실내 PM_{2.5} 및 CO₂ 예측모델을 개발하고, 통합 제어할 수 있는 알고리즘을 개발하였다. 개발된 기술의 성능은 면역력 취약계층인 13세 미만 어린이들이 대부분 시간을 보내는 초등학교에 리빙랩에서 검증되었다. 초등학교는 밀집도와 미세먼지 발생량이 많아 실내공기질 관리가 중요한 공간 중 하나로 분류된다. 실험을 통해 도출된 결과는 다음과 같다.

- (1) 리빙랩에서 6일 동안 실험한 결과 실내 PM_{2.5} 및 CO₂ 농도가 통합 제어 알고리즘의 경우 평균 10.73 µg/m³, 1,000.75 ppm, 룰베이스 알고리즘의 경우 평균 13.36 µg/m³, 1,071.39 ppm로 두 알고리즘 모두 환경부 대기환경기준 및 교육부 학교보건법 시행규칙 기준 이하로 제어됨을 확인하였다. 통합 제어 알고리즘이 룰베이스 알고리즘보다 PM_{2.5} 평균 19.69%, CO₂ 평균 6.59%가량 낮은 농도를 유지하는 것으로 나타났는데, 이는 통합 제어 알고리즘이 룰베이스 제어 알고리즘 보다 제어 성능이 뛰어남을 의미한다.
- (2) 가동 시간 및 에너지 사용량 비교 결과 통합 제어 알고리즘이 룰베이스 알고리즘 대비 에너지소비량이 9.42% 더 적게 나타났다. 하지만 가동시간은 룰베이스 제어 알고리즘이 2.99% 더 짧았다. 이는 통합 제어 알고리즘의 예측값에 따라 제어되는 특성으로 인한 것으로, 통합 제어 알고리즘이 룰베이스 제어 알고리즘 보다 에너지 효율에서 우수한 것을 확인하였다.
- (3) 통합 제어 알고리즘은 선제적 제어를 통해 룰베이스 알고리즘보다 실내 PM_{2.5} 및 CO₂ 농도를 더 낮게 유지시키는 것으로 나타났다. 선제적 제어는 실내 오염물질이 기준치 이하로 유지되는 시간 동안 약 668분간 작동하여 전체 에너지소비량의 약 44%의 비중을 차지하였으며 이를 통해 실내공기질 쾌적에 기여하는 것을 확인하였다.

종합하자면, 본 연구에서 개발한 인공지능 기반 예측모델을 활용한 실내공기질 제어 알고리즘은 실내 PM_{2.5} 및 CO₂ 농도를 선제적으로 제어하여 기존 룰베이스 제어 알고리즘 대비 쾌적한 상태를 더 긴 시간 유지할 수 있으며 더 우수한 에너지 효율을 보인다. 이러한 결과를 통해 해당 기술을 활용 시 선제적 제어를 통해 재실자의 PM_{2.5} 및 CO₂ 노출을 최소화하고 재실 시간 중 에너지소비량을 저감하여 건물환경 관리 및 제어 분야에 기여할 수 있을 것으로 사료된다. 다만, 본 연구는 실내 환기를 통한 공기질만 제어한 결과로, 냉난방 부하는 고려되지 않았다. 이는 HVAC 에너지소비량 저감을 위해서는 별도의 실내 온습도 예측모델이나 이를 탑재한 HVAC 예측 제어 방안의 개발이 필요함을 의미한다. 따라서, 개발된 기술의 범용적 활용을 위해서는 추가적인 HVAC 제어 알고리즘 개발 및 성능 향상 연구가 추가로 수행되어야 한다. 이를 위해 지속적인 현장 데이터 재학습 및 열, 공기 환경 통합 선제적 제어 로직 개발 연구가 진행될 예정이다.

후 기

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2023-00217322).

References

1. Bradford, K., Coleman, J., and Meggers, F., 2022, Understanding the gap between efficiency and comfort, IEEE International Workshop on Metrology for Living Environment (MetroLivEn), pp. 180-185.
2. Fisk, W. J. and De Almeida, A. T., 1998, Sensor-based demand-controlled ventilation: A review, Energy and Buildings, Vol. 29, pp. 35-45.
3. World Health Organization (WHO), 2022, Household air pollution and health, Paper format, <https://www.who.int/en/news-room/fact-sheets/detail/household-air-pollution-and-health>.
4. Nachman, K. E. and Parker, J. D., 2012, Exposures to fine particulate air pollution and respiratory outcomes in adults using two national datasets: A cross-sectional study, Environmental Health, Vol. 11, No. 25.
5. Kyung, S. Y., Kim, Y. S., Kim, W. J., Park, M. S., Song, J. W., Yum, H., Yoon, H. K., Rhee, C. K., and Jeong, H. S., 2015, Guideline for the prevention and management of particulate matter/Asia dust particle-induced adverse health effect on the patients with pulmonary diseases, J Korean Med Assoc., Vol. 58, No. 11, pp. 1060-1069.
6. Kim, Y. M., Kim, J., Ha, S. C., and Ahn, K., 2021, Effects of exposure to indoor fine particulate matter on atopic dermatitis in children, International Journal of Environmental Research and Public Health, Vol. 18, No. 21.
7. Newly found health effects of air pollution call for stronger European Union air policies, Paper format, <https://www.who.int/europe/news/item/31-01-2013-newly-found-health-effects-of-air-pollution-call-for-stronger-european-union-air-policies>, 2013.01.31.
8. Choi, Y. J., Park, B. R., Song, Y. W., Choi, E. J., and Moon, J. W., 2020, Analysis of Ventilation Systems and Control Methods for Optimal Indoor Air Quality in School Buildings, KIEAE Journal, Vol. 20, pp. 131-137.
9. Kim, M. K. and Hong, C. E., 2016, The Artificial Neural Network based electric power demand forecast using a season and weather informations, Journal of the Institute of Electronics and Information Engineers, Vol. 53, pp. 71-78.
10. Cho, J., Heo, Y., and Moon, J. W., 2023, An intelligent HVAC control strategy for supplying comfortable and energy-efficient school environment, Advanced Engineering Informants, Vol. 55.
11. Choi, Y. Y. and Lee, H. S., 2018, Intelligent and responsive window opening-closing operation process for carbon dioxide(CO₂) management of secondary school classroom, Journal of the Korean Institute of Educational Facilities, Vol. 25, pp. 19-30.
12. Shi, T., Yang, W., Qi, A., Li, P., and Qiao, J., 2023, LASSO and attention-TCN: A concurrent method for indoor particulate matter prediction, Applied Intelligence, Vol. 53, pp. 20076-20090.
13. Peng, Y., Lei, Y., Tekler, Z. D., Antanuri, N., Lau, S., and Chong, A., 2022, Hybrid system controls of natural ventilation and HVAC in mixed-mode buildings: A comprehensive review, Energy and Buildings, Vol. 276, p. 112509.
14. Choi, Y. J., Choi, E., Cho, H. U., and Moon, J. W., 2021, Development of an indoor particulate matter (PM_{2.5}) prediction model for improving school indoor air quality environment, KIEAE Journal, Vol. 21, No. 1, pp. 35-40.
15. Byun, J. Y., Kim, T. W., Choi, Y. J., and Moon, J. W., 2022, Development of particulate matter (PM_{2.5}) prediction model for school facilities based on living lab data, KIEAE Journal, Vol. 22, No. 1, pp. 90-91.
16. Taheri, S. and Razban, A., 2021, Learning-based CO₂ concentration prediction: Application to indoor air quality control using demand-controlled ventilation, Building and Environment, Vol. 205, p. 108164.

17. Lagesse, B., Wang, S., Larson, T. V., and Kim, A. A., 2020, Predicting PM_{2.5} in well-mixed indoor air for a large office building using regression and artificial neural network models, *Environmental Science & Technology*, Vol. 54, pp. 15320-15328.
18. Kim, T. W., Byun, J. Y., Yun, J. Y., Jung, Y. G., and Moon, J. W., 2024, Performance analysis of particulate matter priority control algorithm for outdoor Air-Introduced ventilation cleaner using prediction model, *Energy and Buildings*, Vol. 324, p. 114885.
19. Bae, K. W., Kim, T. W., Byun, J. Y., Seo, M. C., and Moon, J. W., 2024, Development of an indoor CO₂ prediction model and optimal ventilation control algorithm based on an occupant personal information. *KIEAE Journal*, Vol. 24, No. 5, pp. 45-52.