



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

제 141 회 석사학위논문
지도교수 문 진 우

재실자 정보 기반
최적 환기 제어 알고리즘 개발
및 성능 평가

Development and performance evaluation of an optimal
ventilation control algorithm based on an occupant
information

중앙대학교 대학원
건축학과 건축환경계획전공
배 강 우
2024년 8월

재실자 정보 기반
최적 환기 제어 알고리즘 개발
및 성능 평가

Development and performance evaluation of an optimal
ventilation control algorithm based on an occupant
information

이 논문을 석사학위논문으로 제출함

2024년 8월

중앙대학교 대학원
건축학과 건축환경계획전공
배 강 우

배강우의 석사학위논문으로 인정함

심사위원장 _____ (인)

심사위원 _____ (인)

심사위원 _____ (인)

중앙대학교 대학원

2024년 8월

목 차

제 1 장 서 론	1
1.1 연구 배경 및 목적	1
1.2 연구 범위 및 방법	5
제 2 장 이론고찰	8
2.1 실내 공기질 오염물질 분석	8
2.2 재실자 개인변수 정의	14
2.3 실내 CO ₂ 환기 제어 선행연구 조사 및 분석	23
2.4 소결	28
제 3 장 예측 모델 및 최적 환기 제어 알고리즘 개발	29
3.1 재실자 정보 기반 실내 CO ₂ 예측 모델 개발	29
3.2 최적 환기 제어 알고리즘 개발	39
3.3. 소결	47
제 4 장 Mock-up 및 베이스라인 구축	48
4.1 Mock-up 구축	48
4.2 컴퓨터 시뮬레이션 기반 모델링	60
4.3 소결	66
제 5 장 성능 평가 및 결과 분석	67
5.1 Mock-up 실험	67

5.2 컴퓨터 시뮬레이션	88
5.3 소결	102
제 6 장 결 론	104
6.1 연구 결론	104
6.2 기대효과 및 한계점	106
참고문헌	107
국문초록	121
ABSTRACT	124

기 호 표

기호	내용	단위
V	실내 체적	m^3
$Q_{(t)}$	외부 공기 환기율	m^2/s
$G_{(t)}$	실내에서 발생하는 CO ₂ 의 생성 또는 제거율	m^2/s
\dot{m}_i	환기시스템 풍량	CMH
i	제어변수 ($i = [0, 1, 2, 3, \dots, n]$)	
CO	일산화탄소	ppm
CO_2	이산화탄소	ppm
$HCHO$	포름알데히드	$\mu g/m^3$

약 어 표

기호	내용	단위
CO_2_{out}	실외 CO ₂ 농도	ppm
CO_2_{indoor}	실내 CO ₂ 농도	ppm
$CO_2_{indoor}(t)$	현재시점(t) 실내 CO ₂ 농도	ppm
$CO_2_{pred}(t)$	예측시점(t+1) 실내 CO ₂ 농도	ppm
CO_2_{limit}	실내 CO ₂ 농도 기준	ppm
\dot{m}_{opt}	환기시스템 최적 제어 풍량	CMH
BMI	Body mass index	kg/m ²
MET	Metabolic rate	W/m ²
PM	Particular matter	μg/m ³
SA	Supply air flowrate	CMH
RA	Return air flowrate	CMH
MAE	Mean Absolute Error	
MSE	Mean Squared Error	
$MAPE$	Mean Absolute Percentage Error	
$CvRMSE$	Coefficient of Variation of the Root Mean Squared Error	
R^2	R-squared, Coefficient of Determination	

표 목 차

Table 1. 실내 CO ₂ 농도에 따른 재실자 영향 연구	11
Table 2. 국내외 실내공기 오염물질 기준 비교	12
Table 3. 다양한 활동에 따른 MET	16
Table 4. 6가지 MET 추정 방법	17
Table 5. MET 산출을 위한 접촉식 방법 선행연구	19
Table 6. MET 산출을 위한 비접촉식 방법 선행연구	21
Table 7. 실내 CO ₂ 농도 예측 모델 입·출력 변수	33
Table 8. DNN 및 LSTM 모델 하이퍼파라미터 구성 및 범위	38
Table 9. Mock-up 개요	50
Table 10. Mock-up 설치 장비 정보	52
Table 11. PWM 값에 따른 급·배기 풍량 측정 결과	56
Table 12. Test별 SA, RA 풍량	59
Table 13. 풍량 성능 실험 결과	59
Table 14. 시뮬레이션 개요	62
Table 15. 리빙랩 환기시스템 풍량제어 스케줄	64
Table 16. 리빙랩 재실자 수	64
Table 17. Mock-up 실험 피실험자 스케줄	67
Table 18. DIN EN ISO 13779 실내공기질의 구분	68
Table 19. 초기 예측 모델별 베이지안 최적화 결과	70
Table 20. Case별 환기 제어 알고리즘 예측 정확도	72
Table 21. 제어별 실내 쾌적도 비율	83
Table 22. Inlet Vane Damper 팬 계수	85
Table 23. SA, RA 풍량별 팬 풍량 비율 산출	85
Table 24. PLF 계수 및 실제 전력 값	86
Table 25. 규칙 기반 제어 알고리즘 에너지소비량	87
Table 26. 최적 환기 제어 알고리즘 에너지소비량	87
Table 27. 리빙랩 재실자 스케줄	89

Table 28. 전이학습 모델 성능 평가	90
Table 29. 요일별 환기 제어 알고리즘 예측 정확도	93
Table 30. 제어별 실내 쾌적도 비율	99
Table 31. 풍량별 에너지소비량	101
Table 32. 제어 알고리즘별 에너지소비량	101

그림 목차

Fig. 1. 연구 프로세스	7
Fig. 2. 실내 CO ₂ 농도 변화 요소	9
Fig. 3. DNN 모델 구조	30
Fig. 4. LSTM 모델 구조	31
Fig. 5. 입출력 데이터 Pearson 상관관계 분석	33
Fig. 6. 학습모델별 입출력데이터 구조	35
Fig. 7. 최적 환기 제어 프로세스	39
Fig. 8. 최적 환기 제어 알고리즘	40
Fig. 9. 최적 환기 제어 알고리즘 데이터	41
Fig. 10. 최적 환기 제어 알고리즘 입력 데이터 생성	42
Fig. 11. 최적 환기 제어 알고리즘 풍량별 CO ₂ 농도 예측	42
Fig. 12. 최적 환기 제어 알고리즘 오차 계산	43
Fig. 13. 최적 환기 제어 알고리즘 풍량 선정 및 제어	44
Fig. 14. Mock-up 구축 및 센서, 환기시스템 설치	51
Fig. 15. 피실험자 실험 진행	51
Fig. 16. 환기시스템 구성도	53
Fig. 17. PWM 제어 듀티 사이클	54
Fig. 18. 시뮬레이션 캘리브레이션 결과	65
Fig. 19. 규칙 기반 제어 알고리즘	69
Fig. 20. Mock-up 제어변수 상자 수염 그래프	71
Fig. 21. Case별 비교 그래프	72
Fig. 22. Case 1 제어 알고리즘 결과	77
Fig. 23. Case 2 제어 알고리즘 결과	78
Fig. 24. Case 3 제어 알고리즘 결과	79
Fig. 25. Case 4 제어 알고리즘 결과	80
Fig. 26. Case 5 제어 알고리즘 결과	81
Fig. 27. Case 6 제어 알고리즘 결과	82

Fig. 28. 제어별 실내 공기질 쾌적도	83
Fig. 29. 제어별 에너지소비량	88
Fig. 30. 시뮬레이션 제어변수 상자 수염 그래프	91
Fig. 31. 요일별 시뮬레이션 결과	92
Fig. 32. Day 1 스케줄 제어 알고리즘 별 실험 결과	94
Fig. 33. Day 2 스케줄 제어 알고리즘 별 실험 결과	95

제 1 장 서 론

1.1 연구 배경 및 목적

현대사회의 대다수 인원은 하루 평균 90%의 시간을 건물 내부에서 보내고 있으며, 이에 따라 재실자 건강을 위한 실내 공기질(indoor air quality, IAQ)관리의 중요성이 강조되고 있다(Cincinelli et al., 2017). 또한, 주요 국가들은 실내 공기질 기준과 규제를 강화하고 있으며, 이를 준수하기 위한 다양한 정책적 노력을 기울이고 있다(Paleologos et al., 2021). 이러한 정책들은 재실자 건강 보호와 더불어 지속 가능한 건물 운영을 가능하게 한다.

실내 공기질 저하 원인으로는 재실자들의 호흡 과정에서 발생하는 CO₂ 누적, 건물 내부 마감재와 건축 자재에서 발생하는 휘발성 유기 화합물 및 화학물질, 외부 공기 오염으로 인한 실내 미세먼지(particulate matter) 유입 등이 있으며(Kumar et al., 2013), 이와 같은 오염 물질로부터 장시간 노출되는 경우 재실자의 건강을 위협할 수 있다(Koivisto, Antti Joonas, et al., 2019).

실내 공기질 저하 원인 물질인 CO₂는 실내공기질 뿐만 아니라 적정 환기량의 기준이 되는 중요 지표이다(Guo, L. & Lewis, J. O., 2007). CO₂의 발생 원인은 외부적 요인과 내부적 요인이 있다. 외부적 요인은 외기와 통하는 창문이나 문의 개방을 통해 자연 환기에 의한 유입, 외벽인 크랙 등을 통해 발생하는 침기에 의해 침투되는 경우 등으로 확인된다. 내부적 요인은 실내 재실자의 호흡으로 인한 CO₂ 배출이 있다. CO₂ 농도에 대한 기준은 국가, 건물, 용도별로 최대 5,000 ppm 까지 다양하게 제시되고 있다(Lowther, S. D. et al., 2021). ASHRAE (American Society of Heating, Refrigeration and Air Conditioning Engineers)에서는 실외 CO₂ 농도 대비 700 ppm 이상 넘어가지 않도록 권장하고 있다. 국내 기준은 실내공기질 관리기준에서 사무공간의 경우 1,000 ppm 이하로 유지할 것으로 권고되며, 환기 제어를 통해 실내 CO₂ 농도를 효과적으로 관리하는 것이 중요하다.

현재 실시간 CO₂ 제어의 한계점 중 하나는 기준치를 넘은 후에야 제어가

시작된다는 점이다. 또한, 특정 환경에 최적화된 모델은 다른 환경에서 동일한 성능을 보장하기 어렵다. 반면, CO₂ 예측 제어는 환경 변화에 대한 선제적 대응을 가능하게 하여 효율적인 제어를 돕는다. 예측 모델을 통해 장기적인 경향을 파악할 수 있어 에너지 절감 및 실내 쾌적도 유지에 기여할 수 있다. 따라서, 예측 모델의 일반화 능력 향상과 다양한 환경에서 일관된 성능을 발휘할 수 있는 기술 개발이 필요하다.

실내 공기질 관리를 위해 건물에서는 자연 환기 및 기계 환기를 적용한다. 자연 환기는 재실자에 의해 쉽게 제어될 수 있을 뿐만 아니라 개폐 장치 설치시 시스템 제어도 가능하기 때문에 환기 에너지가 크게 소모되지 않는다. 다만, 자연 환기시 미세먼지의 경우 외부에 영향을 많이 받고 기상 따라 항시적 사용이 어렵기 때문에 기계 환기 사용이 병행되어야 한다(Chenari et al., 2016). 기계 환기시스템은 댐퍼와 팬(fan)으로 구성되어 외기 도입을 위해서는 지속적인 에너지 소비가 필요하지만, 필터 설치 및 열원설비와의 결합을 통해 공급 공기의 공조가 가능하다는 장점이 있다. 실내 CO₂ 농도 제어를 위해서는 외기 도입이 반드시 이루어져야 해서 실내외 조건과 에너지 효율을 동시에 고려한 기계 환기 제어 방법 적용은 필수적으로 적용되어야 한다.

최근에는 사물인터넷 (Internet of Things, IoT) 기반 공기질 모니터링 시스템, 스마트 환기시스템, AI를 활용한 공기질 예측 및 제어 기술 등 최신 기술이 환기 제어에 도입되고 있다. 이러한 기술들은 실시간 데이터 수집 및 분석을 통해 최적 환기 전략을 제공하며, 에너지 효율성을 극대화하고 공기질을 개선하는 데 기여하고 있다(Marques et al., 2019). 2023년까지 진행된 occupant-centric building design and operation을 주제로 하는 IEA EBC Annex 79 프로젝트에서 재실자 행동을 이해하고 이를 모델링하여 에너지 소비와 실내 환경의 질을 최적화하는 방안을 모색하고 있다(O'Brien, William, et al. 2020). 이를 재실자 중심 제어(occupant-centric control, OCC)라 하며, OCC를 적용해 건물 열환경, 환기 분야에서 다양한 연구가 진행되고 있다. 건물 열환경 측면에서는 재실자 부하(Turley, Christina, et al. 2020), 활동량(Hong, Seong-Hyeop, et al. 2017), 착의량(Choi, 2023) 등의

정보를 활용하여 열쾌적 지표를 산출한 후 이를 냉난방 제어에 활용하는 연구가 있으며, 환기 분야에서는 재실자 CO₂ 배출량(Skön et al., 2012; Putra et al., 2018; Zhu et al. 2022), 재실자 점유(Pang, Zhihong et al. 2020, Choi et al. 2023), 재실자 밀도(Wang, Junqi, et al. 2021) 등을 통해 모니터링하고 분석하여 적절한 환기량을 조절하는 방식으로 OCC를 구현하고 있다.

선행연구 분석 결과 대부분의 OCC는 열환경 및 에너지 분야에 집중되어 있으며 환기 분야에서는 재실자 유무, 재실자 수 데이터만 활용이 되고 있었다. 실내 CO₂ 배출량은 재실자의 성별, BMI, 재실자 활동량(Metabolic rate, MET) 등에 따라 상이하기 때문에 보다 정확한 제어를 위해서는 다양한 재실자 정보 반영이 필수적이다.

따라서, 본 연구에서는 최근 개발되고 있는 AI 기반의 재실자 활동량, 산출모델뿐만 아니라 성별, BMI 정보를 반영한 최적 환기 제어 알고리즘을 제안하고자 한다. 이러한 방식은 기존 연구들이 고려하지 않았던 재실자의 세부적인 특성을 반영함으로써 실내 공기질 관리의 정확성과 효율성을 높일 수 있을 것으로 기대된다.

본 연구의 목적은 실내 공기질 쾌적도 유지를 위해 실시간 재실자 정보인 MET, BMI, 성별 데이터를 반영한 최적 환기 제어 알고리즘을 개발하는 것이다. 최적 환기 제어 알고리즘은 CO₂ 예측제어를 기반으로 하여 최적 공급 풍량을 도출한다. 이를 위해 실내 CO₂ 예측 모델이 개발되었으며, CO₂를 예측하는 과정에서 실내외 환경 및 재실자 정보 데이터가 활용된다. 예측 모델에서 AI를 활용하는 이유로는 첫째, AI는 대규모 데이터 세트에서 패턴을 학습하고 이를 기반으로 예측을 수행하는 데 탁월한 성능을 보인다. 이는 다양한 환경 변수와 개인 변수를 동시에 고려하여 정확한 CO₂ 농도 예측을 가능하게 한다. 둘째, AI 모델은 실시간으로 데이터를 처리하고 예측할 수 있어, 빠르고 효율적인 제어 시스템을 구축할 수 있다. 이는 실시간으로 변동하는 실내 환경과 재실자 정보를 반영하여 최적의 환기 전략을 제공하는 데 유리하다. 셋째, AI는 복잡한 수학적 모델링과 계산 과정을 자동화할 수 있어, 계산의 정확성을 높이면서도 시간과 자원을 절약할 수 있다. 이는 특히 다양한 변수를 고려해야 하는 실내 공기질

관리에서 매우 유용하다. 마지막으로, AI 기반 제어 알고리즘은 환경 변화에 적응할 수 있는 능력을 가지고 있다. 이는 실내외 환경이 변화함에 따라 최적의 제어 전략을 자동으로 조정할 수 있게 하여, 쾌적한 실내 공기질을 유지하는 데 기여한다. 이러한 이유로 본 연구는 AI 기술을 활용하여 실내 공기질 관리의 효율성을 극대화하고, 실시간으로 변화하는 환경과 재실자 정보를 반영한 최적의 환기 제어 알고리즘을 개발하고자 한다.

본 연구의 차별성은 최적 환기 제어 알고리즘을 위해 실시간 재실자의 개인변수를 반영하는 것이다. Lin, Ching Kai et al. (2012)의 연구에 따르면, BMI와 인간의 호흡량 사이에는 선형적 관계가 존재한다. 이는 BMI가 증가함에 따라 호흡량도 함께 증가한다는 것이며, 개인의 BMI가 높을수록 그들의 호흡 활동이 활발해짐을 의미한다. 이러한 관계 검증을 위해 Yang, Liu et al. (2020)은 다양한 BMI와 체지방율을 가진 20대부터 70대까지의 남녀 피실험자를 대상으로 MET에 따른 CO₂ 배출량 실험을 진행하였다. 실험 결과 BMI가 가장 높은 40대 인원들의 CO₂ 배출량이 가장 높은 것으로 나타났으며, 여성보다 남성의 호흡량이 더 많은 것으로 확인되었다.

이와 같은 결과는 본 연구에서 재실자의 개인변수를 반영한 최적 환기 제어 알고리즘을 적용시 기존 환기시스템에 비해 실내공기질을 더 정밀하게 제어할 수 있음을 시사한다. 또한, 재실자 개인변수에 맞춘 최적 풍량을 가동함으로써 에너지 낭비를 줄여 에너지 효율을 향상시킬 수 있을 것으로 사료된다. 이를 검증하기 위한 연구 가설은 다음과 같다.

- 재실자 정보를 고려한 최적 환기 제어 알고리즘을 적용하면 실내 쾌적도 유지 기간이 규칙 기반 제어 알고리즘을 사용할 때와 비교하여 더 길어질 것이다.
- 재실자 정보를 고려한 최적 환기 제어 알고리즘의 적용은 규칙 기반 제어 알고리즘에 비해 환기시스템 에너지 소비를 감소시킬 것이다.

1.2 연구 범위 및 방법

본 연구의 진행 과정은 Fig. 1과 같다. 제1장에서는 연구의 배경 및 목적을 서술하며, 연구의 방향성 및 가설을 설정하였다.

제2장에서는 이론고찰 및 선행 연구분석을 실시하여, 실내 CO₂ 농도 형성 과정과 재실자 개인변수 정의를 설명하며, 기존 제어 관련 선행연구 조사 및 분석을 통해 재실자 개인변수를 반영한 실내 공기질 제어 방법을 제시한다.

제3장에서는 예측 모델 및 최적제어 알고리즘 개발과정을 설명한다. 먼저 실내 CO₂ 농도 예측 모델 개발과정은 예측 모델 선정이후, mock-up을 통해 학습데이터를 취득한다. 입출력 데이터 선정 및 전처리 과정을 진행하고 학습을 위한 하이퍼파라미터를 선정 후 실내 CO₂ 예측 모델을 개발을 진행하였다. 그리고 시뮬레이션 적용을 위해 전이학습을 실시하였다. 최적 환기제어 알고리즘은 구성, 풍량 선정과정의 세부적인 내용을 설명한다.

제4장에서는 실험 진행을 위한 mock-up 및 시뮬레이션의 개요와 구축 과정을 설명한다. Mock-up과 시뮬레이션 모델링의 위치, 설치된 센서 종류, 환기시스템 구성, 재실자 스케줄과 같은 구축 과정을 상세히 서술하였다. Mock-up에서는 예비실험을 통해 풍량 선정을 실시하였으며, 시뮬레이션은 캘리브레이션을 진행하여 실제 환경과의 타당성 분석을 진행하였다.

제5장에서는 성능 평가 및 결과 분석을 진행한다. Mock-up과 시뮬레이션의 실험 진행에 대한 개요를 설명하고, 실험에 앞서 알고리즘간 성능 비교를 위해 규칙 기반 제어 알고리즘을 추가 개발하였다. 그리고 예측 모델 성능 평가를 실시한 뒤, 본실험을 진행하였다. 실험 결과는 실시간 예측 정확도, 두 알고리즘간의 실내 CO₂ 쾌적도 및 에너지 소비량의 비교를 실시하였다.

마지막으로 제6장에서는 분석내용에 따른 결론을 서술하였다. 재실자 정보 기반 예측 환기 제어의 기대효과와 한계점을 설명하고 개선을 위해 추후 진행될 연구의 방향성을 제시하였다.

본 연구는 CO₂ 농도를 중심으로 실내 공기질을 예측하고 최적의 환기 제어 알고리즘을 개발하는 것을 목표로 한다. CO₂ 농도를 선택한 이유는 실내 공기질의 주요 지표로서 환기 상태를 평가하는 데 중요한 역할을 하기 때문이다. 높은 CO₂ 농도는 실내 공기질 저하를 의미하며, 적절한 환기가 필요함을 나타낸다. 또한, CO₂ 농도는 실내 환경이 사람들의 건강에 미치는 영향을 직접적으로 반영하고, 피로, 집중력 저하, 두통 등의 증상을 유발할 수 있다. 환기시스템의 효율성을 평가하는 데도 중요한 변수로 작용하며, 다양한 센서를 통해 실시간으로 모니터링하고 수집하기 용이한 데이터이다.

개인 변수 중 MET와 CO₂ 농도를 연계한 이유는 MET가 개인의 신체 활동 강도를 나타내는 지표로서, 개인의 에너지 소비량을 반영하기 때문이다. 이는 재실자의 활동 수준에 따라 CO₂ 배출량이 달라지기 때문에 중요한 변수입니다. 예를 들어, 앉아 있는 상태와 운동하는 상태에서의 CO₂ 배출량은 크게 차이가 나므로, MET 값을 포함하면 보다 정확한 CO₂ 농도 예측이 가능하다. MET를 통해 재실자의 활동 수준을 파악하면, 공기질 관리와 에너지 소비 간의 균형을 맞추는 데 도움이 된다. 이는 더 효율적인 환기시스템 운영을 가능하게 하며, MET를 반영함으로써 CO₂ 농도 예측 모델의 정확성을 높일 수 있다.

본 연구에서는 실내 CO₂ 농도 예측과 최적 환기 제어 알고리즘의 성능을 평가하기 위해 mock-up 실험과 컴퓨터 시뮬레이션을 수행하였다. 이러한 실험 환경을 통해 다양한 재실자 조건과 환경 변수에 따른 실내 CO₂ 농도변화를 모니터링하고 분석하였다. 이를 위해, 실내 CO₂ 농도, MET, 성별, 체질량지수(BMI), 환기시스템의 풍량 등을 모니터링할 수 있는 영상 및 IoT 센서를 설치하여 실시간 데이터를 수집하였다. 여기서 환기시스템 풍량은 mock-up과 컴퓨터 시뮬레이션 모두 4단계(미풍, 약풍, 중풍, 강풍)로 구성된다. 수집된 데이터와 사용자 피드백을 바탕으로, 기계 학습 알고리즘을 활용하여 환기 패턴을 학습시키고 예측 모델을 개발하였다. 개발된 예측 모델은 다양한 통계적 기법을 사용하여 성능 평가를 실시하며, 이를 통해 최적화된 환기 제어 알고리즘을 개발하였다.

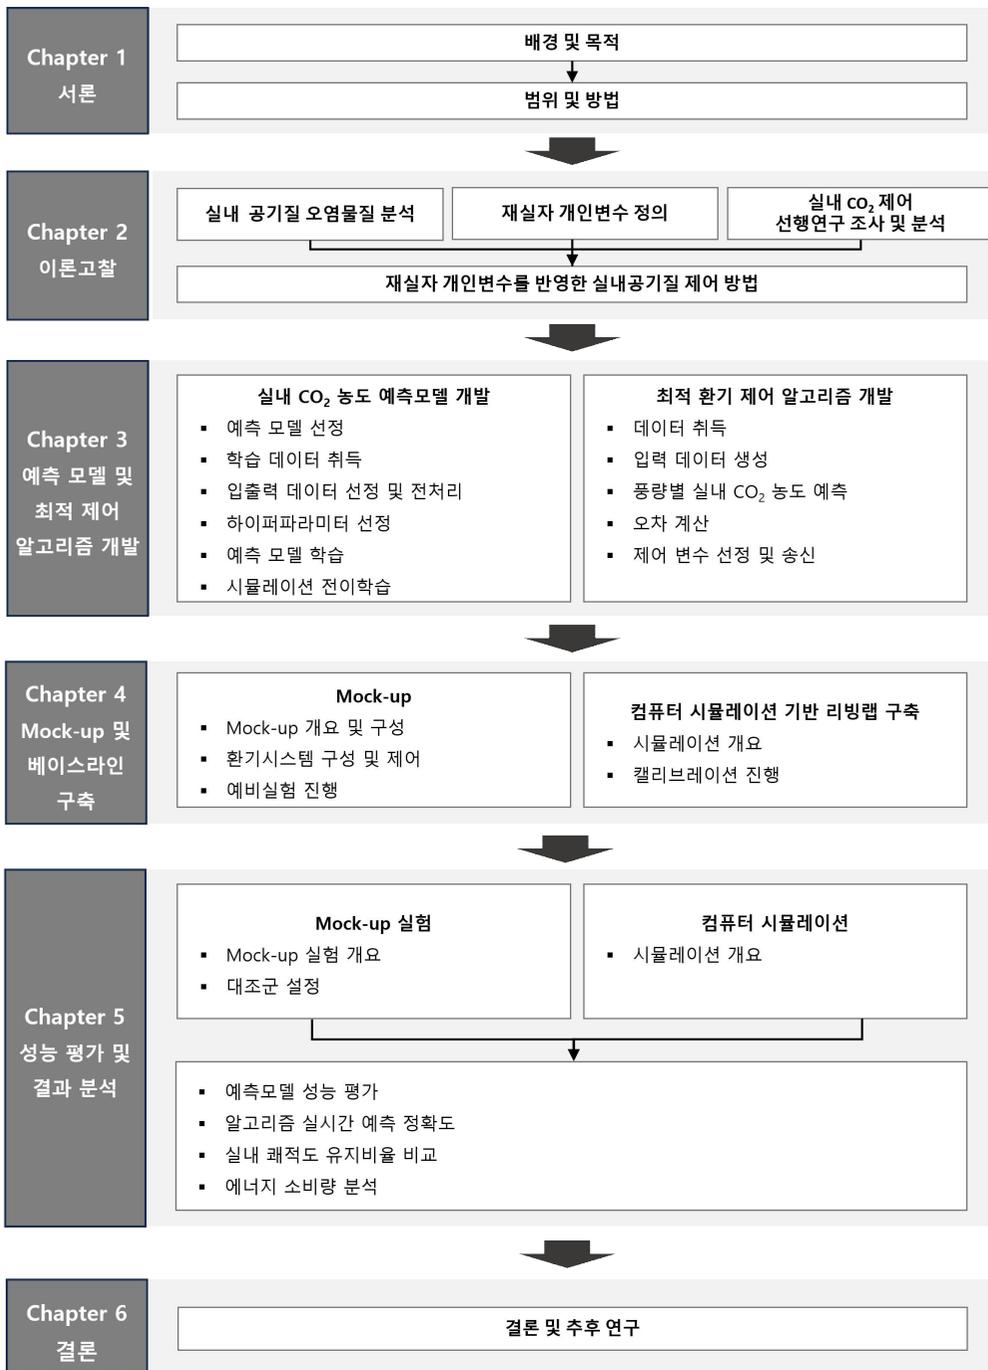


Fig. 1. 연구 프로세스

제 2 장 이론 고찰

2.1 실내 공기질 오염물질 분석

본 장에서는 실내 공기질 오염물질중 하나인 실내 CO₂의 특성 및 형성 메커니즘에 대한 이론을 고찰하였다. 본 연구의 대상인 환기시스템 제어 알고리즘 개발의 근간이 되는 실내 CO₂의 재실자 건강 위해성을 알아 본 뒤, 실내 CO₂ 농도 형성 메커니즘의 이해 과정을 통해 발생원이 되는 영향 인자를 파악하였다.

(1) 실내 CO₂ 농도 형성 메커니즘

다양한 요인에 의해 실내 CO₂ 농도 변화가 생기며, 이를 식 1과 같이 정리하였다(Zhi, Shaodan, et al., 2017). 실내 공간에서 시간에 따른 CO₂ 농도 변화율은 환기율, 실내외 CO₂ 농도, 실내에서 발생하는 CO₂ 생성 혹은 제거율에 영향을 받게 된다(Persily, Andrew. 2022). CO₂ 생성에 영향을 주는 것은 재실자의 호흡, 난방, 취사시 발생하게 된다. 이 중 난방에 의해 CO₂ 농도가 오르는 것은 과거 등유, 프로판 가스등을 사용했기 때문이며, 현대 사회에서는 전기 히터를 주로 사용하여 영향이 미미하다(ARASHIDANI, Keiichi, et al. 1996). 취사 행위 역시 주거를 제외한 일반적인 환경에서 잦은 빈도로 발생하는 행동은 아니다. 따라서, 실내 CO₂ 농도 생성에 가장 많이 영향을 미치는 것은 재실자 호흡의 영향이 크며, MET에 따라 0.02~0.04 m³/hr의 CO₂ 배출량이 정해진다. 다음으로 실내 CO₂ 농도 제거에 영향을 주는 것은 외벽, 틈새, 균열 등의 crack에 의한 침기(infiltration), 누기(exfiltration)와 자연 및 기계 환기의 요소가 있으며(Park, Sowoo, et al. 2021), 개념도는 Fig. 2와 같다.

$$V \frac{dC}{dt} = Q_{(t)} (CO_{2\ out} - CO_{2\ indoor}) + G_{(t)} \dots\dots\dots (식 1)$$

여기서,

V : 실내 공간의 부피 [m^3]

dC/dt : 시간에 따른 CO_2 농도 변화율

$Q_{(t)}$: 외부 공기 환기율 [m^3/h]

$CO_{2\ out}$: 외부 CO_2 농도 [ppm]

$CO_{2\ indoor}$: 실내 CO_2 농도 [ppm]

$G_{(t)}$: 실내에서 발생하는 CO_2 의 생성 또는 제거율 [m^3/h]

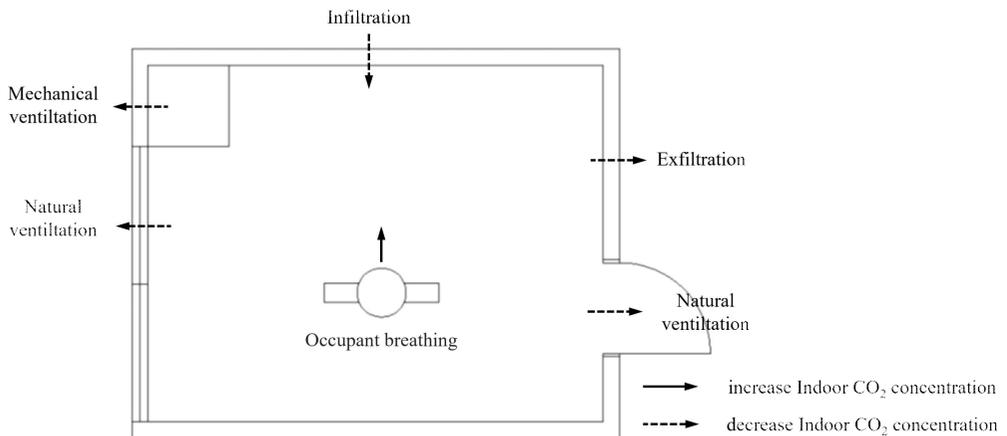


Fig. 2. 실내 CO_2 농도 변화 요소

(2) 실내 CO₂ 특성 및 영향성

실내에서 발생하는 CO₂의 특성은 상온에서 기체상태로 존재하고 산소보다 무거워 일반적인 공간에선 지면과 가깝게 형성된다. 물질 자체는 매우 안정적이고 불연성을 띠며, 무색, 무취로 주로 산소로 호흡하는 생물체의 연소작용으로 발생된다(Persily, Andrew et al. 2017). 실내 CO₂ 농도는 18세기부터 환기 및 실내 공기질(indoor air quality)에 대한 연구에서 중요한 역할을 해왔다. 실내 CO₂ 농도가 건물 재실자에게 미치는 영향과 환기율을 추정하기 위한 실내 CO₂ 농도 사용 및 CO₂ 기반 수요 조절 환기(demand control ventilation)에 초점을 맞춘 기술들이 수년에 걸쳐 발전해왔다(Persily, Andrew. 2015). 실내 CO₂ 농도가 재실자에게 미치는 영향에 대한 진행된 연구는 Table 1과 같다. 다양한 환경에서 고농도의 실내 CO₂ 실험들은 모두 재실자에게 심혈관계, 호흡계 질환, 중추 신경계에 질환을 발생시키며, 대표적인 증상들은 집중력 저하, 호흡량 증가, 두통, 졸림현상을 있었다. 반대로 저농도 CO₂ 실험에서도 과호흡, 어지러움, 기침과 같은 현상을 확인하였다.

이처럼 실내 CO₂ 농도는 재실자 건강을 위해 필수적으로 관리 되어야 하는 실내 오염물이며, 각 국가별로 정해진 기준에 의해 관리하고 있으며, 내용은 Table 2와 같다. 실내 CO₂ 농도는 자연 환기, 기계 환기등을 사용하여 미국 및 유럽의 일부 국가들을 제외한 대다수의 국가들이 1,000 ppm 미만으로 유지하도록 권고하고 있다. Eliseeva (1964)는 짧은 기간동안 1,000 ppm의 CO₂ 농도에 노출된 사람들의 말초 신경의 혈류량 증가 및 대뇌 피질의 기능적 변화가 생겼다고 한다. 또한, 실내 CO₂ 농도 1,000 ppm이하 공간에서 생활한 인원들이 해당 농도를 넘기는 공간에서 생활한 인원들보다 반응 속도, 학습 능력과 같은 인지능력이 향상되었음을 확인하였다(Zhang, Xiaojing, et al. 2017; Azuma, Kenichi, et al. 2018).

Table 1. 실내 CO₂ 농도에 따른 재실자 영향 연구

분야	저자	내용
심혈관	Sechzeret al. (1960)	<ul style="list-style-type: none"> 사무실의 부피 7~14%의 CO₂ 농도로 10~20분간 실험 진행 모든 인원 심박수 및 혈압 증가
	Gortner et al. (1971)	<ul style="list-style-type: none"> 고농도의 CO₂ 잠수정 환경에서 재실 인원의 건강상태 분석 혈액내 pH 농도 감소
	Vehviläinen, Tommi, et al (2016)	<ul style="list-style-type: none"> 환기를 한 사무실과 진행하지 않은 사무실의 재실자 혈중 농도 분석 환기를 하지 않은 사무실 재실자의 흉조 현상, 말초신경의 혈류량 증가
호흡기	Samet, Jonathan M. et al. (1987)	<ul style="list-style-type: none"> 일반적인 공간에서 다수의 인원에게 CO₂ 발생 실험 진행 농도가 2,500 ppm이 넘어간 순간부터 기침, 과호흡 증상 확인
	Rice, Susan A.(2014)	<ul style="list-style-type: none"> 급성 고농도 CO₂에 노출된 인원들 모두 두통, 발열, 호흡 저하의 현상 발생 저농도 CO₂에 노출된 인원들도 기침, 과호흡과 같은 호흡기의 변화가 발생
중추신경계	Myhrvold, A et al. (1996)	<ul style="list-style-type: none"> 학교 실내 환경과 학생들의 건강과 학업 성취에 미치는 영향 분석 자연 환기를 진행하지 않은 그룹에서 잦은 하품, 기침, 발열 현상 확인
	Satish, Usha, et al.(2012)	<ul style="list-style-type: none"> 22명의 참가자를 600, 1,000, 2,500 ppm의 CO₂ 학교환경에 노출 후 9가지 테스트 진행 고농도일때, 정보 검색 및 집중력 활동에서는 비슷하거나 더 우수한 성과를 보임
	Maula, H., et al. (2017)	<ul style="list-style-type: none"> 540 ppm과 2,260 ppm의 사무공간에서 MET, CLO를 고정하고 7가지 작업 진행 고농도 공간에서 전체적으로 발열 증상 확인

Table 2. 국내외 실내공기 오염물질 기준 비교

구분	한국	일본	미국	EU	캐나다	WHO
CO ₂ [ppm]	1,000	1,000	-	1,000~ 1,670	1,000	1,000
CO [ppm]	10	10	10	3~12.5	25	31
HCHO [μg/m ³]	100	100	100	10~100	60	0.1
PM ₁₀ [μg/m ³]	100	150	50	20~150	-	50
PM _{2.5} [μg/m ³]	50	35	15	25	27	25

(3) 실내 CO₂ 농도 변화 영향인자 분석

실내 CO₂ 농도 변화에 영향을 주는 인자 분석을 위해 영향인자를 실외 CO₂ 농도, 침기율 및 누기율, 재실자 호흡, 환기율, 환기시스템 풍량으로 5가지로 구분하였다. 구분한 이유는 각각이 실내 공기질에 중요한 영향을 미치기 때문이다. 실외 CO₂ 농도는 실내로 유입되는 공기의 기초 농도를 결정하며, 침기율 및 누기율은 비의도적인 공기 교환을 나타내고, 재실자 호흡은 CO₂ 배출의 주요 원인이다. 환기율은 실내외 공기 교환 속도를 나타내고, 환기 시스템 풍량은 외부 공기 공급량을 결정하여 실내 CO₂ 농도를 조절하기 때문이다.

실외 CO₂ 농도는 침기, 자연 환기, 기계 환기 등에 의해 건물로 유입된다. 이때 유입되는 실외 CO₂ 농도에 따라 실내 CO₂ 농도를 하락시키는 속도가 결정 되게 된다. 이를 통해 실외 CO₂ 농도는 실내 CO₂ 농도변화 발생시키는 요소 중 하나로 볼 수 있다. 실외 CO₂ 농도는 도심지, 도로변, 주거지 등

환경에 따라 분포가 다르며, 같은 지역내에서도 계속하여 농도변화가 발생한다(Kim, Moon Keun, 2019).

침기 및 누기는 건물 외벽의 균열, 틈새, 이음부의 부분에서 재실자가 의도하지 않은 공기 교환을 의미하며, 침기는 외부 공기가 실내로 유입되는 현상이고, 누기는 실내 공기가 외부로 유출되는 현상이다. 유입되는 공기의 부피 혹은 유출되는 공기의 부피를 실의 부피로 나누게 되면 침기율과 누기율을 취득할 수 있다. 두 비율은 실내외 온도차, 풍향과 풍속, 건물 외피 형태, 기밀 성능, 적용된 설비시스템 등 다양한 요소의 영향을 받는다. 따라서, 동일한 건물일지라도 내외부의 환경에 따라 침기율, 누기율은 달라질 수 있다(Mumma, Stanley A. et al. 1998; Villi, Giacomo, et al. 2013).

재실자 호흡에 의한 CO₂ 배출량은 신체 크기, 연령, 성별, MET 등과 같이 다양한 요소의 영향을 받는다. Yang, Liu et al (2020)은 20~79세의 신체 표면적이 비슷한 여성 50명, 남성 49명을 실험에 참여시켜 눕기, 앉기, 걷기, 가사활동등 7가지 행동을 진행하였고, 전체적으로 남성이 모든행동에 대해 CO₂ 배출량이 높았으며, 체지방율이 가장 높은 40대 남성들의 CO₂ 배출량이 제일 높았음을 확인하였다. 또한, Jung ChienCheng et al.(2015)은 체질량지수(BMI)를 활용하여 해당 수치가 높을수록 호흡량이 많아져 실내 CO₂ 배출량도 함께 증가함을 확인하였다. 이와 같은 결과로 재실자 정보는 실내 CO₂ 배출량과 밀접한 요소가 있음을 확인하였다.

환기란 재실자가 의도한 실내외 공기 교환을 의미하며, 단위시간당 환기에 의해 유입된 공기의 부피를 실의 부피로 나눈 값을 환기율이라고 한다. 자연 환기에 의한 환기율은 침기율과 동일하게 실내외 온도차, 풍향과 풍속, 건물의 형태, 개구부 특성 등 다양한 요소의 영향을 받는다. 기계 환기시스템을 통해 환기하는 경우, 외기를 일정하고 안정적으로 실내로 공급할 수 있다.

환기시스템 풍량은 기계 환기에 의해 정해지는 바람의 세기이다. 풍량이 커질수록 유입되는 공기량이 늘어나 더 빠르게 실내 CO₂ 농도를 하락시키게

된다. 필요환기량은 공간의 용도, 부피, 사용 목적에 따라 바뀌며, ASHRAE 62.2에서는 1인당 25 CMH 혹은 1시간 0.35회 이상의 환기량 중 큰 환기량을 적용하며, 국내의 경우 1인당 21.6 CMH 혹은 1시간 0.5회 중 큰 환기량을 반영한다.

2.2 재실자 개인변수 정의

실내 CO₂ 농도 상승에 높은 연관성을 지닌 재실자 개인변수에 대한 이론을 고찰하였다. 2.1장의 영향인자 분석에서 실내 CO₂ 농도 상승은 재실자 호흡에 의한 영향성이 가장 높음을 확인하였고, 이를 통해 재실자 호흡량을 결정하는 개인변수들에 대한 이론 고찰을 실시하였으며, 실내 CO₂ 농도 예측 모델에 사용하기 위한 해당 변수들의 취득 방법에 대해 선행 연구 조사를 진행하였다. 조사는 2015년부터 2023년까지의 연구를 대상으로 하였으며, '실내공기질', 'CO₂ 예측', '지능형 환기 제어', '재실자 개인 변수' 등의 키워드를 사용하였다. 조사 방법으로는 구글 스칼라(Google Scholar)와 디비피아(DBpia)를 활용하였다.

(1) 재실자 개인변수 정의 및 측정

재실자의 호흡량에 영향을 미치는 개인변수로는 MET, BMI, 성별이 있으며, 이들 변수는 실내 CO₂ 농도 변화와 밀접한 관련이 있다. 이러한 변수를 고려하여 실내 공기질 관리와 환기시스템을 설계하는 것이 중요하다. 이를 통해 실내 환경의 쾌적성을 유지하고, 재실자의 건강과 업무 능력 향상에 긍정적인 영향을 줄 수 있다. 각 개인변수의 특성을 이해하고 이를 모델에 반영함으로써 더 정확하고 신뢰성 있는 예측을 할 수 있으며, 효율적인 환기 전략을 수립할 수 있다.

MET는 사람이 수행하는 활동의 대사 요구량을 나타내는 단위로, 1 met는

사람이 앉아서 조용히 쉬고 있을 때의 에너지 소비량을 의미한다. 예를 들어, 걷기, 달리기, 청소 등과 같은 활동은 더 높은 MET 값을 가지며 수치는 Table 3과 같다. 이는 더 많은 에너지를 소비하고 더 많은 CO₂를 발생시킨다. 따라서, 재실자가 수행하는 활동의 강도에 따라 CO₂ 배출량이 변화 한다(Dominelli et al., 2022). ISO 8996 기준에 따르면 level 1~4까지 4단계의 측정 방법이 있으며 Table 4와 같다. level 1A는 resting, low, moderate, high, very high의 5가지의 활동 종류에 따라 분류하며, level 1B는 직업에 따른 분류를 실시한다. 해당 방법은 별도의 작업 현장 평가를 실시하지 않으며, 대략적인 정보를 제공하기 때문에 실험 오차의 범위가 매우 크다. 다음 level 2A는 여러 사람의 활동을 그룹으로 평가하여 대사율을 추정하며, level 2B의 표준 추정표를 사용하여 사람의 자세와 업무 강도를 고려한 전체 활동량을 계산하게 된다. level 3은 정해진 조건하에 심박수를 측정하여 대사율을 추정한다. 마지막 level 4는 전문가의 정확한 측정이 수반되는 작업으로 산소 소비량, 체수분내 수소와 산소 전환율의 차이를 기반으로 하는 CO₂ 측정, 직접열량계(direct calorimetry)를 기반으로 호기성 및 혐기성 대사에서 생성된 열을 정량화하여 열교환량 측정의 방법으로 적용된다(최은지, 2023). 해당 방법들은 level이 높아질수록 정확도가 높아지지만, 높아질수록 요구되는 장비, 실험인력, 전문가, 작업 공간, 실험 스케줄과 같은 자원적인 요소가 많이 필요하다(Gauthier, 2012). 따라서, MET 추정에서 가장 많이 사용되는 방법은 상대적으로 제약 사항이 적은 level 2와 3의 방식이 주로 사용 된다(Zhai, Yongchao, et al. 2018).

BMI는 체중(kg)을 신장(m)의 제곱으로 나눈 값으로, 개인의 체지방량을 추정하는 데 사용된다. BMI가 높을수록 일반적으로 대사율이 높아지며, 이는 더 많은 에너지 소비와 CO₂ 발생으로 이어진다. Peralta, Gabriela P., et al. (2020)은 비만인 경우 호흡 기능이 저하되며, 호흡 빈도와 강도가 증가하여 더 많은 CO₂를 발생시킬 수 있음을 확인하였다. 또한, 비만은 폐 기능 저하와 관련이 있으며, 이는 폐활량 감소와 호흡 효율 저하로 이어져

호흡량과 CO₂ 배출량에 영향을 미친다(Chen Y et al., 1993).

성별 역시 CO₂ 배출량과 밀접한 관계가 있다. 남성과 여성은 생리학적으로 폐 용적, 근육량, 대사율 등에서 차이가 있다. 일반적으로 남성은 여성보다 더 큰 폐 용적과 높은 대사율을 가지며, 이는 더 많은 CO₂를 발생시킨다(Harms CA, 2008). 남성은 동일한 활동 수준에서도 여성보다 더 많은 CO₂를 발생시키며, 이는 근육량과 기초대사량에 의한 결과이다(Dominelli et al., 2022).

Table 3. 다양한 활동에 따른 MET

활동명	구분	
	MET	에너지 소비량 (W/m ²)
Sleeping	0.7	41
Seated (quiet)	1.0	58
Reading (seated)	1.0	58
Writing	1.0	58
Typing	1.1	64
Standing (relaxed)	1.2	70
Walking about	1.7	99
Walking (3.2 km/h)	2.0	116

Table 4. 6가지 MET 추정 방법

구분	방법	정확도
Level 1	A- Classification according to kind of activity	Rough information when the risk of error is very great
	B- Classification according to occupation	
Level 2	A- Use of tables of group assesment	High error risk accuracy $\pm 20\%$
	B- Use of estimation tables for specific activites	
Level 3	Use of heart rate under defined conditions	$\pm 10\%$
Level 4	Oxygen consumption measured over short periods	$\pm 5\%$
	Doubly labelled water method or isotopic method characterising the average metabolic rate over longer periods	
	Direct calorimetry method	

(2) 개인변수 산출방법

MET, BMI, 성별과 같은 개인변수를 산출하는 방법에는 다양한 접근법이 있으며, 특히 인공신경망(Artificial Neural Networks, ANN)을 활용하면 측정 장비 영향을 최소화하며, 효율적으로 데이터를 수집하고 분석할 수 있다. 아래는 이러한 개인변수 산출을 위한 방법에 대해 서술한다.

MET 산출방법 분석 결과 대부분 Table 4에서 제시한 level 3~4수준의 연구가 진행중이며 크게 집축식과 비집축식으로 나뉘어 구분할 수 있었다. 먼저, 집축식은 웨어러블 기기를 사용한 심박수 측정, 호흡계 장비를 통한 호흡량 확인과 같은 방식이 주를 이루었으며, 내용은 Table 5와 같다. Lee, Miyoung, et al. (2010)은 하반신 마비 환자들을 대상으로 심박수 비율을 사용하여 MET 값을 추정하는 방법을 제안하였다. 연구 결과에 따르면,

심박수와 MET 수준 간의 상관 계수는 0.77로 나타났으며, 예상된 MET 값과 관찰된 MET 값 간의 상관 계수는 0.78로 높은 상관성을 보였다. Nakanishi, Motofumi, et al. (2018)은 웨어러블 기기를 사용하여 일상 활동의 MET를 추정하는 방법을 제안한다. 가속도계와 심박수 데이터를 활용한 웨어러블 기기는 일상 활동의 MET 값을 정확하게 추정하는 데 매우 유용함을 확인하였다. 다만, 고강도 행동에서는 높은 정확도를 보였지만, 일반적인 행동에서는 고강도 대비 정확도가 하락하였다. Zhai, Yongchao, et al. (2018)은 다양한 연령대의 피실험자를 모집하여, 호흡량 및 심박수 측정기를 착용시킨 뒤 인원마다 10가지 행동을 지시하였다. 연구 결과 MET가 높아질수록, 호흡량 및 심박수가 함께 높아지는 것을 확인하였다. 하지만 접촉식 산출방법은 매 실험마다 장비들의 초기화 과정을 거쳐야 하며, 실제 환경에서 모든 재실자가 디바이스를 착용해야 한다는 한계를 가지고 있다. 또한, 일부 연구에서는 지속적인 고강도 행동에서는 심박수와 선형적 관계를 확인하였지만 간헐적 고강도 행동에서는 오히려 관계성이 떨어지기도 하였다(Silva, Henrique Santos da, et al., 2021). 이는 심박수가 운동의 강도는 나타내나 대사율이 정량적 수치를 제시하는 것에 한계가 있음을 의미한다(Charlot, K. et al., 2014). 이와 같은 문제를 해결 및 정확도 향상을 위해 지속적으로 연구가 진행 중이다.

Table 5. MET 산출을 위한 접촉식 방법 선행연구

구분	저자	내용
Level 3	Lee, Miyoung, et al. (2010)	<ul style="list-style-type: none"> • 하반신마비 환자들에게 심박수 측정기기를 착용시키고, 10가지 신체 활동을 진행함 • MET와 심박수간의 높은 상관관계 확인
	Nakanishi, Motofumi, et al. (2018)	<ul style="list-style-type: none"> • 웨어러블 기기를 사용하여 가속도와 심박수를 통해 일상 활동의 MET 값을 추정하는 알고리즘을 제안 • BMI, 체중 등을 독립 변수로 사용한 다중 회귀 모델을 통해 MET 값을 추정 및 높은 정확도를 확인
	Caballero, Yuko, et al. (2020)	<ul style="list-style-type: none"> • 심박수 모니터링을 활용하여 행동에 따른 MET 추론 연구 진행 • 개인별 보정 없이 심박수 데이터를 통해 MET 값을 정확하게 예측할 수 있음을 확인하였으며, 특히, 고강도 활동에서 높은 정확도를 보임
	Hübner, T., et al.	<ul style="list-style-type: none"> • 손목형 웨어러블 기기를 통해 심박수와 MET간의 연관성 분석 • 심박수와 MET는 선형적 관계임을 확인
Level 4	Zhai, Yongchao, et al. (2018)	<ul style="list-style-type: none"> • 피실험자들에게 호흡측정기를 착용시킨 뒤 앉기, 서기, 걷기 행동에 대한 실험 진행 • MET 값이 올라갈수록 CO₂ 배출량도 함께 증가함을 확인

비접촉 산출방법은 실내 CO₂ 농도, 이미지를 분석하는 방법이 있으며, 이미지 분석은 인공지능망과 결합하여 MET를 산출하는 데 활용된다. 이러한 방법들은 센서를 통해 비접촉식으로 데이터수집 이후 대사활동을 추정한다. 예를 들어, 실내 CO₂ 농도는 재실자의 호흡 패턴과 밀접한 관련이 있으며, 이를 통해 대사량을 간접적으로 추정할 수 있다. 또한, 피실험자의 움직임과 자세 변화를 감지하여 신체 활동 수준을 평가하는 데 사용된다. 열화상 이미지는 신체 표면의 열 방출을 측정하여 대사율을 추정하는 데 사용된다. 이와 같은 비접촉식 방법들은 신체 활동과 대사율을 평가하는 다양한 접근법으로 개발되고 있고, 내용은 Table 6와 같다. Ji, Wenjie, et al. (2018)은 물리적 운동 중 인간의 대사율 변화와 열적 편안함을 평가하기 위해 챔버를 통해 CO₂ 측정 방법에 대해 제시하였다. 특히 활동의 전환 단계의 변화를 연구하였다. CO₂ 농도변화를 측정하고, 물리적 활동 중 인간의 열적 편안함에 필수적인 MET 추정 방법을 제공한다. Shu et al. (2020)은 OpenPose 알고리즘을 사용하여 사람 RGB 이미지에 18개의 관절을 입힌 뒤, 활동량 분류를 진행하였다. 기존 자세 인식 알고리즘이 가려진 신체 부위를 인식할 때 정확도가 떨어지는 문제를 해결하기 위해 연구하였다. 이 방법은 복잡한 배경에서도 높은 인식 정확도를 달성할 수 있음을 실험을 통해 확인하였다. 최은지 (2018)은 해당 OpenPose를 사용하여 10가지 포즈 분류를 실시하였으며, 88.01%의 정확도를 확인하였다. Park, Bo Rang, et al. (2020)은 주거 및 사무실에서 주로 측정되는 MET 분류를 위해 식별 알고리즘을 개발하였다. 그 결과, 주거에선 평균 95%, 사무실은 평균 81.67% 이상의 정확도를 확인하였다. Smith, Javier, et al.(2023)는 열화상 이미지를 사용하여 야간 및 가려진 환경에서도 인간의 체온을 기반으로 MET 추정이 가능한 모델을 개발하였다. 다만, 열화상 이미지 데이터셋이 거의 없어 RGB이미지를 흑백으로 변환시킨 COCO(common objects in context) 데이터셋을 사용하여 학습에 이용하였다. 이처럼 이미지 기반의 MET 산출 방법이 대다수를 이루고 있으며, 특히 OpenPose를 활용한 관절 탐색 방식이 대중적으로 사용되고 있다. 본 연구에서도 이러한 OpenPose 모델을 채택하여, 최종적으로 개발할 환기 제어 알고리즘에 한 요소로 내재시킬 예정이다.

Table 6. MET 산출을 위한 비접촉식 방법 선행연구

구분	저자	내용
실내 CO ₂ 농도	Ji, Wenjie, et al. (2018)	<ul style="list-style-type: none"> • 밀폐된 실험 챔버에서 CO₂ 측정 센서 설치후 자전거 타기 운동, 회복, 안정 3단계의 실험 진행 • CO₂ 농도 측정을 통한 대사율 평가가 유효하며, 실내 공기질 및 열적 쾌적성 관리에 중요한 기여를 할 수 있음을 확인
RGB 이미지	Shu et al. (2020)	<ul style="list-style-type: none"> • OpenPose 인체 인식을 기반으로 안면 포함 18개의 관절로 구분하여 활동량 분류 진행 • 인식 정확도 91.5%, 평균 계산 속도 9.7 frame/s로 인식 탐지 요구사항 충족 확인
	최은지 등 (2018)	<ul style="list-style-type: none"> • 이미지에서 14개의 사람 주요 관절 좌표를 인식하는 인공신경망 모델로 10가지 포즈분류를 진행 • Test data set의 MET 정확도 88.01% 확인
	Park, Bo Rang, et al. (2020)	<ul style="list-style-type: none"> • DNN을 사용하여 실내 공간에서 재실자 이미지 기반 주거, 사무실 주 행위 자세 분류 및 활동 식별 알고리즘 개발 • 주거 평균 95% 이상의 정확도 확인 • 사무실 평균 81.67% 이상의 정확도 확인
열화상 이미지	Smith, Javier, et al.(2023)	<ul style="list-style-type: none"> • Thermal image를 사용하여, CNN 및 ViT와 같은 기존의 인간 자세 추정 방법을 적용 • 야간이나 시각적으로 가려진 환경에서도 인간의 체온을 기반으로 자세를 추정 가능
X-ray	Silva, Henrique Santos da, et al.(2021)	<ul style="list-style-type: none"> • dual-energy X-ray absorptiometry (DXA)을 사용하여 풋살 경기중인 선수들의 산소 소비량, 심박수의 관계를 분석 • 풋살 경기에서 에너지 소비 및 산소 소비량 간의 상관관계가 낮아 대략적인 추정만 가능

BMI 산출은 정의에서 언급한 수학적 공식을 사용하는 산출방법이 보편적으로 사용되고 있다. 하지만 해당 방법은 재질자 수 변동시 매번 산출의 번거로움이 수반 된다. 이와 같은 문제를 개선하기 위해 최근 영상 및 열화상 센서에서 취득된 이미지나 영상 데이터처리에 용이한 convolutional neural network (CNN) 기반 산출방법이 연구되고 있어 분석을 실시하였다. Siddiqui, Hera, et al. (2020)은 총 4,206개의 저체중~중증 비만으로 구분된 다민족 얼굴 이미지 데이터셋을 CNN 모델을 통해 학습시켜 성능 평가를 실시하였으며, 평가 결과 남녀 포함 MAE 5~6 kg/m²의 결과를 나타냈다. Jiang et al. (2019)는 백인과 흑인으로 구성된 얼굴 이미지 데이터셋을 CNN의 VGG-Face, pointer feature (PF), psychology inspired geometric features (PIGF), PIGF+PF, LightCNN, ArcFace, Centerloss 다차원 방식을 적용하여 BMI 추론을 실시하였으며, 모델별 MAE 3.43~3.91 kg/m²의 결과를 나타냈다. 추가적인 실험으로 PF의 landmark 개수를 조정하며 많을수록 성능이 개선되는 것은 아니며, 최적의 개수를 찾는게 중요하다고 정리하였다. 이외에도 얼굴 이미지를 사용한 BMI 산출방법이 제시되고 있지만 사용된 데이터셋들이 모두 인물의 정면사진을 기준으로 개발되었기 때문에 측면과 같이 각도가 변경되어지는 경우 정확도가 현저히 떨어지는 경향을 보였다. Pantanowitz, Adam, et al. (2021)은 161명의 피실험자들로부터 취득한 전신 사진을 사용하여 실루엣화 시킨뒤, CNN의 MiniVGGNet을 통해 BMI 산출을 실시하였다. 산출 결과 평균 MAE 1.66 kg/m²의 결과를 나타냈다. 다만, 해당 실험에서는 반팔, 반바지, 스타킹과 같은 신체 형태가 잘보이는 의복을 입고 진행하여 입은 옷 유형에 따라 산출 결과의 오차 변동이 발생하였다. Jiang et al. (2019)는 신체 이미지에 18개의 관절 포인트를 지정하였고, SVR과 을 통해 산출을 진행하였으며 약 81.3%의 정확도를 나타냈다.

성별 산출 역시 BMI와 비슷하게 CNN 기반의 산출모델이 대다수를 이루었다. Antipov et al. (2016)은 얼굴 이미지로 성별을 산출하는 모델을

만들었다. 여러 개의 간소화된 CNN 모델을 앙상블 방식으로 결합하여, 단일 모델보다 더 높은 정확도와 안정성을 확보하였다. 실험 결과, 앙상블 모델은 최대 97.5%의 정확도를 나타내며, 단일 CNN 모델보다 우수한 성능을 보였다. 이를 통해 실시간 응용과 같은 제한된 자원 환경에서 유용하게 사용될 수 있음을 확인하였다. 이처럼, BMI와 성별 산출 연구의 대다수는 CNN 기반으로 진행되고 있으며 얼굴 및 신체 이미지를 사용하여 산출을 실시한다. 하지만 해당 모델들은 특정 데이터를 기반으로 개발되어 다양한 조건에서의 실적용은 아직 어려움을 겪고 있다. 따라서, 본 연구에서는 MET는 딥러닝 기반 산출모델을 사용하고, BMI와 성별은 지금까지 연구되고있는 산출모델이 100% 산출정확도를 가진다는 가정하에 진행하였다.

2.3 실내 CO₂ 농도 제어 선행연구 조사 및 분석

실내 CO₂ 농도 제어는 실내 재실자 건강을 위해 반드시 갖춰야 할 요소 중 하나이다. 제어는 크게 자연 환기, 기계 환기 두 가지로 나뉜다. 자연 환기는 건물의 창문을 통해 주로 이루어지며, 빠른 환기 성능을 보여준다. 다만, 외부 공기 유입 과정에서 오염물질도 함께 들어오기 때문에 장시간 자연 환기는 오히려 재실자의 건강에 악영향을 미칠 수 있다. 따라서, 본 연구에서는 기계 환기를 통한 실내 CO₂ 농도 제어를 진행할 예정이다.

기계 환기시스템은 실내 공기질을 유지하고 에너지 효율성을 높이기 위해 다양한 제어 방법을 사용하고 있다. 제어 방법은 크게 일반 제어, 최적 제어, 지능형 제어로 구분되며, 최근까지 진행된 다양한 제어 방법에 대한 선행연구 고찰을 실시하였다.

(1) 일반 제어 방법

실내 CO₂ 농도 제어를 위해 일반적으로 사용되는 제어 방식은 on/off 제어와 demand control ventilation (DCV), proportional integral (PI),

proportional integral derivative (PID) 제어가 있다(Lü, Xiaoshu, et al., 2013). 먼저 on/off 제어 시스템은 특정 임계값을 기준으로 시스템을 켜거나 끄며, 이 임계값은 시스템의 목적과 환경에 따라 설정된다(Ke et al., 1997). 이처럼 단순한 구조이기 때문에 구현이 매우 쉽고, 비용 역시 저렴하다. 하지만 과잉 환기 및 환기 부족이 발생하여 에너지 효율성이 낮고, 공기질 변화에 대한 반응이 느리다는 단점이 있다(Takahashi et al., 2010). DCV 제어는 센서를 통해 실내 CO₂ 농도를 실시간으로 모니터링하여 필요에 따른 환기량 조절을 실시한다. 따라서, 필요한 만큼만 환기를 실시하기 때문에 난방, 냉방 및 제습에 소모되는 에너지를 절약시킬 수 있다(Metelskiy, Konstantin, 2011). 단점으로는 초기 설치 비용이 높고, 복잡한 시스템 구성과 주기적인 유지보수가 필요하다. Lu (2011)은 실제 건물을 시뮬레이션화 하여 DCV 제어 실험을 진행하였다. 그 결과, 제어 기간동안 실내 CO₂ 농도가 설정값을 넘지 않고 제어함을 확인하였으며, 에너지 소비도 on/off 제어대비 최대 34% 감소시킴을 확인하였다. Merema, Bart, et al. (2018)은 학교 건물에서 7개월간 DCV 제어를 적용하였고, 팬 에너지는 최대 55% 감소, 열 손실은 최대 47% 감소시키며 에너지 효율적 측면에서 우수함을 증명하였다. PI 제어는 비례와 적분 제어를 결합하여 현재 오차와 누적 오차를 모두 고려해 제어 신호를 생성한다. 이는 오차를 제거하고 구현이 간단하지만, 급격한 변화에 대응하기 어렵다는 단점이 있다. PID 제어는 비례, 적분, 미분 제어를 결합해 현재 오차, 누적 오차, 오차 변화율을 모두 고려한 정밀한 제어를 제공한다. 빠른 응답과 높은 안정성을 제공하지만, 설정과 튜닝이 복잡하고 노이즈에 민감하다(Cai, Hui, et al., 2020). Pistochini, Theresa, et al. (2023)은 DCV 제어를 탑재한 6가지 기성품과 연구를 통해 개발한 PI 제어와 성능 비교를 실시하였다. DCV 제어는 최소한의 댐퍼 사용으로 실내 CO₂ 농도 제어 수준을 최대 80%까지 달성했으며, PI 제어는 92%까지 달성했으나, DCV보다 3배 이상 더 자주 댐퍼를 사용하였다. PI 제어는 제어 성능 면에서는 우수하지만, 에너지 소비 측면에서는 불리함이 확인되었다.

Okochi et al. (2016)은 PID 제어가 적용된 VAV 시스템을 분석하여 PID 제어가 다양한 로직과 결합이 가능함을 확인하였다.

하지만 on/off 제어, DCV 제어, PI 제어, PID 제어는 모두 실시간 제어 방법으로, 실시간 데이터를 기반으로 즉각적인 반응을 통해 공기질을 조절한다. 이러한 실시간 제어는 환경 변화에 즉각 대응할 수 있는 장점이 있지만, 현재 상태에만 의존하기 때문에 미래의 변화를 예측하고 대비하는데 한계가 있다. 따라서, 실내 공기질을 보다 효율적이고 안정적으로 유지하기 위해서는 예측 제어의 도입이 필요하다. 예측 제어는 과거 데이터와 현재 데이터를 분석하여 미래의 상태를 예측하고, 이에 따라 환기 시스템을 미리 조절함으로써 에너지 효율성과 공기질을 동시에 최적화할 수 있기 때문이다.

(2) 최적 및 지능형 제어 방법

최적 제어는 시스템의 동작을 최적화하는 데 초점을 맞추며, 수학적 모델을 기반으로 최적의 해결책을 도출하는 방법이다(Kirk, Donald E., 2004). 시스템의 효율성 향상, 시스템 관리, 미래 예측 및 계획, 에너지 비용 절감 등을 위해 사용된다. 예시로, 스마트 HVAC 시스템은 실내 환경을 쾌적하게 유지하면서 에너지 소비를 최소화하기 위해 CO₂ 농도, 온도, 습도 등을 예측하고 최적의 환기 및 냉난방 전략을 실행한다. 이처럼 최적 제어는 다양한 시스템에서 제어 성능을 극대화하고 효율성을 높이며, 제약 조건을 만족시키는 데 필수적이다(Afram et al., 2014).

최적 제어를 활용한 실내 환경 제어에 관한 선행 연구를 분석한 결과, 대부분의 연구는 실내 온도, CO₂ 농도, 미세먼지 수치 및 에너지 소비 등을 예측하고 있다(김태호 et al., 2012; del Mar Castilla, Maria et al., 2013; Berouine, Anass et al., 2020; Liang, Wei et al., 2015; Ganesh, Hari S. et al., 2021). 기존 연구들은 주로 시스템의 동적 특성 반영에 유리한 모델 예측 제어(Model Predictive Control, MPC)를 사용하여 예측 모델을 개발하였다.

그러나 이들 연구는 주로 실내 열쾌적성과 에너지 절약에 중점을 두었으며, 실내 공기질에만 초점을 맞춘 연구는 상대적으로 부족하다. 또한, MPC는 복잡한 수학적 지식과 계산 기술을 요구하며, 입력 변수가 많아질 경우 계산 과정이 길어져 결과 산출까지 상당한 시간이 소요될 수 있다. 지능형 제어는 복잡한 수학적 모델링과 계산 과정을 필요로 하는 MPC에 비해 훨씬 유연하다. Artificial intelligence (AI)와 machine learning (ML)은 대규모 데이터 세트에서 패턴을 학습하고 이를 기반으로 예측을 수행할 수 있기 때문에, 정확도는 높으면서 계산 과정에 소요되는 부담은 상대적으로 적다(Koedinger, Kenneth R, et al. 2013).

지능형 제어는 인공지능 기술과 기계 학습을 활용하여 시스템을 제어하며, 시스템이 자동으로 학습하고 환경 변화에 적응하는 능력을 통해 복잡하거나 불확실한 환경에서의 운용이 용이하다(Wang et al., 2016). 실내 CO₂ 농도 예측 관련 선행연구 분석 결과, W. Zhang et al(2022)은 160여 개의 실험에서 최근 사용되는 예측 모델들의 점유율을 비교하였다. 그 중 실내 공기질 예측에 있어서 SVM, ANN, DNN, LSTM과 같은 인공지능망 모델들이 주로 사용되었으며, 특히 실내 CO₂ 농도 예측에서는 ANN과 DNN이, 미세먼지(PM₁₀, PM_{2.5}) 예측에서는 LSTM이 가장 우수한 성능을 보였다. Xie, Jingjing (2017)과 Choi, Inho et al. (2022) 등의 연구에서도 다양한 모델이 실내 CO₂ 및 PM_{2.5} 농도 예측에 활용되고 있으며, 연구마다 적용된 환경에 따라 모델의 선택이 다르게 이루어졌다. 이는 실내 공기질 오염요소별로 각기 다른 모델과 예측 정확도를 보이며, 모델 선정 시 현재 적용하고자 하는 환경에 적합한 최적화된 모델 선정이 필요함을 의미한다. Shaikh et al(2016)은 유전자 알고리즘 기반 multi-objective genetic algorithms (MOGA) 및 hybrid multi-objective genetic algorithms (HMOGA)을 사용하여 실내 온도, 조도, CO₂ 농도 제어를 실시하였으며, HMOGA를 적용한 모델이 실내 쾌적도 98.3% 유지 및 에너지 소비량을 31.60% 감축하였다. 김선호 등(2022)는 강화학습(reinforcement learning) 중

하나인 Double Deep Q-network (DDQN)을 활용하여 실내 공기질 최적 환기 제어 알고리즘을 개발하였다.

CO₂ 예측 제어 연구에는 몇 가지 한계점이 존재한다. 먼저, 특정 환경에 맞춰진 모델은 다른 환경에서 동일한 성능을 보장하기 어려운 경우가 많다. 이 문제를 해결하기 위해 모델의 일반화 능력을 향상시키는 연구가 필요하다. 또한, 많은 예측 모델은 계산 복잡도가 높아 실시간 적용이 어렵다. 실시간 제어 시스템을 개발하기 위해 이러한 모델의 효율성을 높이는 방안이 필요하며 해당 문제를 해결하기 위해서는 모델의 복잡성을 관리하는 연구가 필요하다. 마지막으로, 데이터의 품질과 양이 예측성능에 큰 영향을 미친다. 따라서 양질의 데이터를 확보하는 것이 필수적이다.

(3) 재실자 정보 활용 제어

Energy Plus와 python의 co-simulation을 통해 MET에 의한 CO₂ 농도와 미세먼지(PM_{2.5}) 농도 개선과 에너지 소비량 절감을 달성하였다. Wang (2023)은 재실자 중심의 OCHNVC (Occupant-Centric Heating and Natural Ventilation Control) HVAC 제어 방식을 제시하였다. 이를 위해 deep vision algorithm 기반 재실자 산출모델을 적용하였으며, 인공지능 기반 실내 CO₂ 예측 모델을 개발하였다. 그 결과 재실 기간동안 실내 CO₂ 농도를 1,000 ppm 미만으로 89.2% 유지하였다. 이처럼 AI 기반 환기 제어는 재실자에 의한 실내 CO₂ 농도 변화를 효과적으로 관리하며, 지속적인 성과를 보이고 있다. 그러나 현재 연구들은 대부분 재실자 수에 국한되어 있으며 재실자의 MET, BMI, 성별과 같은 개인변수를 충분히 반영하지 못하는 실정이다. 개인변수를 반영하지 않으면 CO₂ 농도 예측 모델의 성능과 신뢰성이 저하될 수 있으며, 이는 실내 공기질 관리와 재실자의 건강 및 에너지 효율성 측면에서 여러 문제를 초래할 수 있다. 따라서, 실내 CO₂ 농도 제어를 위해 재실자의 MET, BMI, 성별을 반영한 최적 환기 제어 알고리즘을 개발하였다.

2.4 소결

본 장에서는 본 연구는 실내 공기질 오염물질 중 하나인 실내 CO₂의 특성과 형성 메커니즘, 그리고 이를 제어하기 위한 다양한 방법들을 이론 고찰 및 선행연구 분석을 통해 확인되었다.

본 연구의 목적은 재실자의 개인 변수를 반영한 실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘을 개발하는 것이다. 이를 통해 기존의 규칙 기반 제어보다 높은 예측 정확도와 에너지 효율성을 달성하고자 한다.

실내 공기질은 재실자의 건강과 생산성에 직접적인 영향을 미치는 중요한 요소이다. 특히 CO₂ 농도가 높은 환경에서는 집중력 저하, 호흡기 질환, 두통 등의 문제가 발생할 수 있어 적절한 관리가 필수적이다. 그러나 기존의 실내 CO₂ 제어 방법은 대부분 실시간 제어에 의존하며, 재실자의 수와 같은 단순 변수만을 고려하여 예측의 정확성이 떨어진다. 이러한 방식은 미래의 변화를 예측하지 못하고, 재실자의 다양한 특성을 충분히 반영하지 못하여 실내 공기질 관리의 효과를 제한한다.

따라서, 본 연구에서는 재실자의 MET, BMI, 성별 등 개인 변수를 반영한 예측 모델을 개발하여 실내 CO₂ 농도를 보다 정확하게 예측하고, 이를 바탕으로 최적의 환기 제어 알고리즘을 구현함으로써 실내 공기질을 개선하고 에너지 효율성을 높이는 것을 목표로 한다. 이러한 접근은 기존 연구들에서 다루지 않은 재실자 개인 변수의 중요성을 강조하며, 보다 정밀하고 신뢰성 있는 실내 공기질 관리 방법을 제시한다.

제 3 장 예측 모델 및 최적 제어 알고리즘 개발

본 연구에서는 mock-up 실험과 컴퓨터 시뮬레이션을 통해 실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘 개발 및 성능평가를 실시한다. Mock-up에서는 실제 데이터를 기반으로 예측 모델 및 제어알고리즘을 개발하고 1차적인 성능평가를 진행하며, 컴퓨터 시뮬레이션에서는 mock-up 실험을 통해 재현하기 어려운 다양한 시나리오에 대한 성능평가를 실시한다. 이때, 컴퓨터 시뮬레이션에 사용되는 실내 CO₂ 예측 모델은 mock-up에서 개발된 초기 예측 모델에 전이학습(transfer learning) 진행 이후 컴퓨터 시뮬레이션 환경에 적용된다. Mock-up과 컴퓨터 시뮬레이션에 대한 세부내용은 제4장에서 서술한다.

3.1 재실자 정보 기반 실내 CO₂ 농도 예측 모델 개발

본 장에서는 mock-up 환경을 기준으로 실내 CO₂ 농도 예측 모델 개발과정을 서술한 이후 전이학습에 따른 학습과정을 다룬다. 예측 모델 개발과정은 1) 예측 모델 선정, 2) 데이터 취득, 3) 입출력 데이터 선정, 4) 학습데이터 전처리, 5) 예측 모델 학습으로 구성되며, 각 과정별 세부 내용은 다음과 같다.

(1) 예측 모델 선정

인공신경망은 다양한 종류가 있지만, 현재 건축 및 환경 분야에서 주로 사용되는 모델은 심층 신경망 모델(Deep Neural Network, DNN)과 장단기 메모리(Long-Short Term Memory, LSTM) 모델이다(Liu, Yangdong, et al, 2017; Liu, Song, et al., 2020; Jo, Sung-Jae, et al., 2020). DNN은 복잡한 비선형 함수 처리에 용이하며, 입·출력데이터 간 연속성, 범주형 변수에 국한되지 않고 분석이 가능하기 때문에 비선형적 특징을 나타내는 데이터 학습에 유리하다(Du, Mengnan, et al., 2018). LSTM은 시계열 데이터

학습에 유리한 것으로 보고되고 있으며, 건물 환경 및 에너지 관련 데이터는 대부분 시계열 데이터로 표현된다(Wang, Jingyang, et al., 2021). LSTM은 학습 및 예측과정에서 과거 데이터(historical data) 반영이 가능하며 이러한 시퀀스 데이터에서 발생하는 패턴 파악에 강점을 나타낸다(Veena, S. 2021; Ramachandraarjunan et al. 2022). 따라서, 본 연구에서는 DNN과 LSTM을 학습 모델로 선정하였다.

DNN 모델은 1989년 Yann LeCun에 의해 제안되었으며, 모델 구조는 Fig. 3과 같다. 2개 이상의 은닉층을 가지는 다층 신경망 구조로 모양과 크기가 다양하지만 MLP의 뉴런, 레이어, 가중치와 같은 기본 요소는 동일하게 적용된다(Pedding et al., 2015). 은닉층이 많아질수록 학습 성능이 증가할 수 있으나, 학습데이터에 과도하게 최적화 되는 데이터 과적합(overfitting) 및 학습 시간 증가로 인한 예측 지연 현상이 발생할 수 있다(최영재 등, 2022). 이를 해결하기 위해 sparsity (ℓ_1 -regularization) 또는 weight decay (ℓ_2 -regularization)와 같은 가중치 규제 (weight regularization) 방법들을 사용하여 모델의 손실 함수 값이 너무 작아지지 않도록 특정한 함수를 추가하거나, 은닉층 유닛을 일부 생략하는 dropout 레이어 추가 방식이 적용되고 있다(Nusrat et al., 2018).

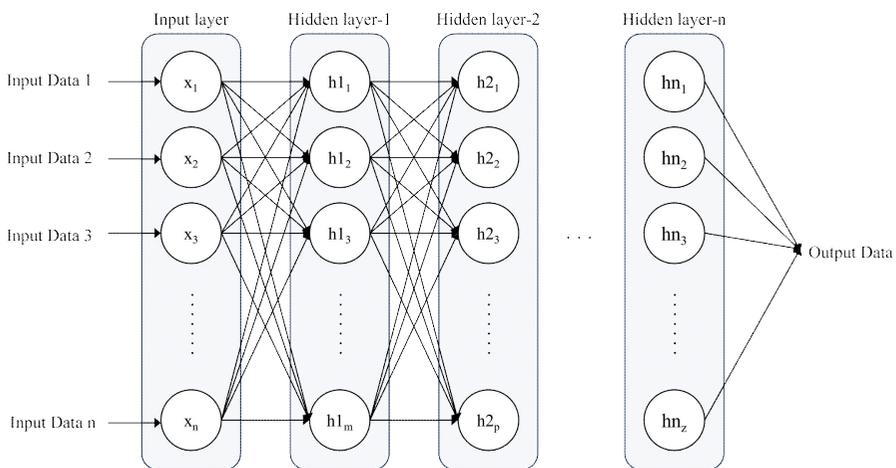


Fig. 3. DNN 모델 구조

LSTM 모델은 1997년 Sepp Hochreiter에 의해 제안되었으며, 모델 구조는 Fig. 4와 같다. 모델의 구조는 망각 게이트(forget gate), 입력 게이트(input gate), 출력 게이트(output gate)로 구성된다(Yao, et al. 2015). 먼저, 망각 게이트는 과거 정보를 잊기 위한 게이트이다. 현재(t) 입력값과 과거($t-1$) 은닉값에 sigmoid 함수를 적용하여 0이 출력되면 과거 은닉값을 잊고, 1이 나오면 기억한다. 입력 게이트는 현재 정보를 기억하기 위한 게이트로 망각 게이트와 동일하게 현재 입력값과 과거 은닉값을 받아 sigmoid 함수를 취하고, 동일한 값들을 tanh 함수를 취해 연산한 값이다. 마지막으로, 출력 게이트는 다음 시점으로 출력을 전송하는 게이트이며, 망각 및 입력 게이트의 결과값에 tanh 함수를 취해 $t+1$ 은닉값을 출력한다. 이러한 과정을 통해 LSTM은 장기간의 정보를 효과적으로 유지하고 필요에 따라 정보를 갱신하거나 버리며, 장기간에 걸쳐 의존성이 있는 패턴을 효과적으로 학습할 수 있다(Gers, Felix A. et al., 2000; Yao, et al., 2015). 그러나, 복잡한 내부 구조로 인해 학습데이터가 방대해지는 경우 시간이 오래 걸린다는 단점이 있다.

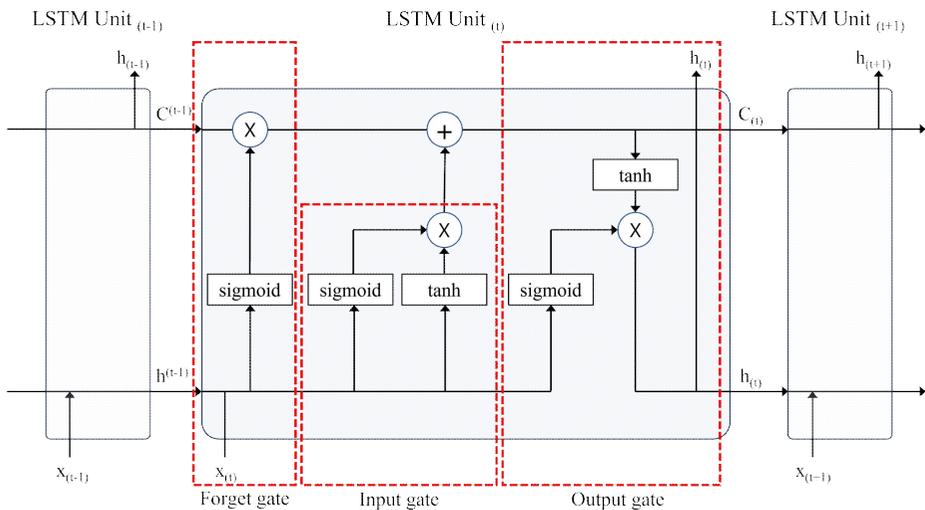


Fig. 4. LSTM 모델 구조

(2) 입출력 데이터 선정

예측 모델 성능확보를 위해서는 적절한 입력변수가 정의되어야 한다. 이를 위해 본 연구에서는 통계적 기법에 기반한 상관관계분석을 실시하였다. 상관관계분석에서 주로 사용되는 방법은 피어슨 상관계수(r)로 -1과 1사이의 상관계수를 가진다(Gogtay, Nithya J. et al., 2017). -1에 가까울수록 음의 상관관계를, 1에 가까울수록 양의 상관관계를 의미하며, 0은 변수 간 상관관계가 없음을 나타낸다. 일반적으로 상관계수의 절댓값이 0.8 이상이면 강한 상관관계, 0.8과 0.4사이면 중간수준의 상관관계, 0.4 이하면 약한 상관관계가 있는 것으로 간주한다(Klami et al. 2013; Franzese et al., 2018).

취득한 원본 데이터에 대한 상관관계분석 결과는 Fig. 5, 이에 따라 최종적으로 선정된 입력변수 및 출력변수 목록은 Table 7과 같다. Fig 5에 의하면 0.5 이상의 상관계수를 가진 변수는 재실자 수, MET, BMI, gender가 있으며, 상관계수가 0.3 이상인 변수는 SA (supply air flowrate), RA (return air flowrate)로 나타났다. SA와 RA의 상관계수는 0.35로 낮은 편이지만, 급기와 배기를 통해 실내 CO₂ 농도가 변화한다는 점을 고려하여 예측 모델의 입력변수로 선정하였다. 실외 CO₂ 농도의 경우, 상관계수가 높을 것으로 예상하였으나 실내 CO₂ 농도 변화에 대한 영향력이 거의 없는 것으로 산출되어 입력데이터에서 제외하였다. 따라서, 예측 모델의 입력변수는 상관계수가 0.3 이상인 변수들로 선정하였으며, 그 내용은 실내외 온도, 습도, CO₂ 농도, SA, RA, 재실자 수, MET, BMI, 성별의 12가지 취득 데이터 중 실내 CO₂ 농도, SA, RA, 재실자 수, MET, BMI, 성별 7가지를 선정하였다. 출력변수는 제어 주기인 5분 후 실내 CO₂ 농도이다.

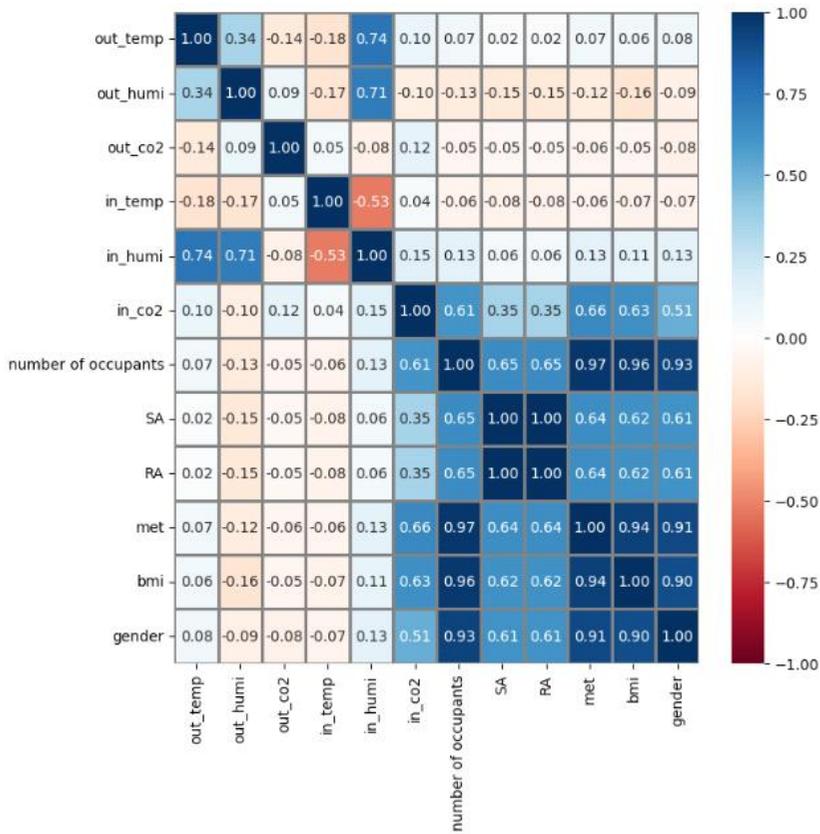


Fig. 5. 입출력 데이터 Pearson 상관관계 분석

Table 7. 실내 CO₂ 농도 예측 모델 입·출력 변수

구분	입력변수	출력변수
실내 CO ₂ 농도 예측 모델	<ul style="list-style-type: none"> 실내 CO₂ 농도 [ppm] (in_co2) SA [CMH] RA [CMH] 채실자 수 [명] (number of occupants) MET [met] (met) BMI [kg/m²] (bmi) 성별 [0, 1, 2] (gender) 	<ul style="list-style-type: none"> 5분 후 실내 CO₂ 농도 [ppm]

(3) 학습데이터 취득

초기 실내 CO₂ 농도 예측 모델 개발을 위해 mock-up으로부터 데이터를 취득하였다. 데이터 취득은 mock-up 내부에 환기시스템을 설치한 뒤 피실험자를 구해 2024년 2월 2일부터 19일까지 재실자 활동별 다양한 풍량 제어실험을 진행하여 취득하였다. 취득된 데이터는 환경정보(실내 CO₂ 농도), 재실자 정보(재실자 수, MET, BMI, 성별), 환기시스템 풍량(SA, RA)이고 15~20초 간격으로 DB에 저장되며 총 66,632개의 데이터가 생성되었다. 통신 불안정으로 발생한 이상치는 해당 값 전후의 평균으로 처리하였으며, 결측값은 확인되지 않았다. Mock-up에서의 제어주기는 5분이기 때문에 취득된 원본 데이터 또한 5분 단위 데이터로 변환할 필요가 있다. 따라서, 취득된 원본 데이터를 5분 평균처리하여 총 3,336개의 학습데이터를 생성하였다. Mock-up에 대한 자세한 정보는 4장에서 서술하였다.

(4) 학습데이터 전처리

데이터 전처리는 학습데이터에 대한 결측값 및 노이즈 현상 제거부터 학습 알고리즘에 입력시키기 위한 구조화 및 스케일링까지 일련의 과정을 의미한다. 적절한 데이터 전처리가 시행되지 않는 경우, 예측 모델의 성능이 좋지 않거나, 학습이 진행되지 않는 예러가 발생할 수 있다(Famili, A., et al., 1997; Kotsiantis et al., 2006) 본 연구에서는 mock-up에서 취득한 학습데이터에 결측값 및 노이즈 현상이 발생하지 않았기 때문에 데이터 구조화와 스케일링 처리를 하였다. 데이터 구조화는 학습데이터를 행렬화하고, DNN, LSTM 모델에 적용할 수 있는 형태로 변환하는 과정이다. DNN 모델은 학습데이터와 동일한 2차원 행렬 구조를 입력받으며 n번째의 입력데이터로 n+1번째 출력데이터를 예측하는 구조이다. 따라서, 학습데이터를 Fig. 6과 같이 구조화 하였다.

다음은 3차원 데이터 배열 형태를 사용하는 LSTM 학습을 위해 데이터 구조화를 진행하였다. 먼저 입력데이터를 나누기 위해 window size를 2와

3으로 설정하였다. 다음으로 $n+1$ 번째 출력데이터를 예측하기 위해 $n - (\text{window size} - 1)$ 부터 n 번째 입력데이터를 사용하고, horizon 값을 1로 지정해 1개의 출력데이터를 생성하였다.

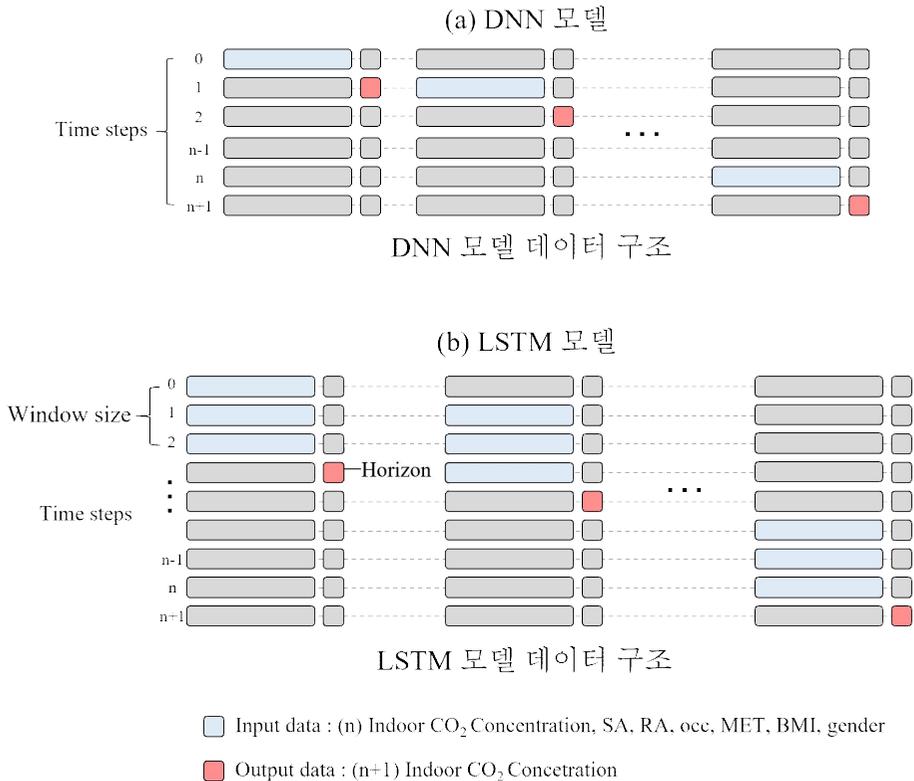


Fig. 6. 학습모델별 입출력데이터 구조

다음으로 데이터 스케일링 및 분할 과정을 진행하였다. 데이터 스케일링은 예측 모델 학습 과정에서 입력변수들 간 상이한 단위 및 범위로 인해 특정 입력변수에 가중치가 편향되는 현상을 방지해 준다(Ahsan, Md Manjurul, et al., 2021). 일반적으로 정규화(normalization)과 표준화(standardization)가 사용되며 본 연구에서는 각 입력변수의 최솟값과 최댓값을 0과 1로 변환해주는 min-max normalization 방법을 사용하였다. 이후, 예측 모델의

train, validation, test 과정을 위해 정규화된 데이터를 8:1:1로 분할하여 2,670개, 333개, 333개로 구분하였다.

(5) 하이퍼파라미터 최적화

머신러닝에서 하이퍼파라미터는 구조와 학습 방법을 결정하는 변수로 뉴런(neuron), 은닉층(hidden layer), dropout, 활성화 함수 등이 있다(Probst, et al., 2019). 예측 모델의 성능은 하이퍼파라미터 조합에 따라 상이하며 튜닝(tuning)을 통해 예측 성능을 극대화 하는 최적 하이퍼파라미터 조합을 탐색하여야한다(Weerts, et al., 2020). 하이퍼파라미터의 튜닝 기법으로는 그리드 탐색(grid search), 랜덤 탐색(random search), 휴리스틱 탐색(heuristic search), 베이지안 최적화(bayesian optimization) 등이 있다(Schratz, Patrick, et al., 2019; Yang, Li, et al., 2020).

그리드 탐색은 사전에 정의된 하이퍼파라미터 값들의 모든 조합을 탐색하는 방식으로 진행하기 때문에 하이퍼파라미터 값들의 범위가 증가할수록 학습시간이 매우 오래 걸리게 된다(Adnan, Muhammad, et al., 2022). 랜덤 탐색은 사전에 정의된 하이퍼파라미터 값들의 조합 범위내에서 모든 조합을 탐색하지 않고 임의의 조합을 선택하여 학습을 진행한다(Bergstra, et al., 2012). 그리드 탐색보다 학습시간은 줄어들지만 출력된 결과가 최적의 조합이라고 단정 지을수 없다. 휴리스틱 탐색은 이전에 얻은 경험적인 지식을 활용하여 하이퍼파라미터를 지정하는 것으로 구현이 간단하고 빠르게 결과를 얻을 수 있지만 개발자의 지식이나 과거 경험의 의존성이 크다(Mirshekarian, et al., 2018). 마지막으로 베이지안 최적화는 하이퍼파라미터 최적화를 위한 반복적인 모델 학습 및 평가 과정에서 이전 결과를 활용하여 확률적으로 효율적인 조합을 탐색하는 방법이다(Snoek, et al. 2012). 해당 방법은 탐색(exploration)과 활용(exploitation) 사이의 균형을 맞추는 것이 중요하다. 탐색은 불확실성이 높은 영역에서 샘플링하여 더 많은 정보를 얻는 것을 의미하고, 활용은

현재의 모델에 따라 최고의 결과를 예상할 수 있는 영역에서 샘플링하는 것을 말한다(Klein, Aaron, et al., 2017). 이 과정에서 취득 함수(acquisition function)가 사용되며 취득 함수는 다음에 샘플링 할 위치를 결정하기 위해 사용된다. 이 함수는 예상되는 성능 향상을 최대화하는 방향으로 입력값에 따른 조합을 도출해낸다. 본 연구에서는 탐색 효율 및 시간을 고려하여 베이지안 최적화 방법을 채택하였고, Keras-Tuner에서 제공하는 BayesianOptimization 라이브러리를 사용하였다.

(6) 예측 모델 학습

베이지안 최적화를 진행하기 위해서는 하이퍼모델(hypermodel)이 구축되어야 하며, 사용자가 모델의 뉴런, 은닉층, dropout, 활성화 함수에 대해 탐색 범위를 정의하여야 한다. 정의된 범위 내에서 반복 학습을 진행하며 베이지안 최적화를 통해 최적 하이퍼파라미터 조합을 도출해낸다. 하이퍼파라미터 구성 및 범위는 Table 8와 같다. 학습에 사용한 손실 함수는 식 2의 평균제곱오차 (Mean Squared Error, MSE)이고, 최적화 함수는 adam optimization을 사용하였다. 학습 옵션으로 탐색 횟수(epoch)는 100회로 설정하였다. 과적합을 방지하기 위해 early stopping기능을 도입하여 5회 이상 성능 개선이 되지 않으면 학습을 종료하도록 설정하였다. 반복 학습 횟수는 15회이다. LSTM 모델의 경우 window size도 주요 하이퍼파라미터로 지정되는 경우가 있으나 본 연구에서는 고정값을 적용하였다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \dots\dots\dots (식 2)$$

여기서,

y_i : 정답 값

t_i : 예측 값

n : 데이터 개수

Table 8. DNN 및 LSTM 모델 하이퍼파라미터 구성 및 범위

하이퍼파라미터 변수명		범 위
모델 공통 사항	뉴런 (Neuron)	• 5 ~ 100, step = 2
	은닉층 (Hidden layer)	• 0 ~ 5
	Dropout	• 0 ~ 0.5, step = 0.1
	활성화 함수 (Activation function)	• ReLU, sigmoid, tanh
	손실 함수 (Loss function)	• MSE
	최적화 함수 (Optimization function)	• Adam optimization
	실행 횟수 (Max trial)	• 15
	탐색 횟수 (Epoch)	• 100
	학습 옵션 (Training option)	• Early stopping = 5
LSTM	Window size	• 2, 3

3.2 최적 환기 제어 알고리즘 개발

개발된 초기 예측 모델 그리고 전이학습 모델은 성능 검증 후 최적 환기 제어 알고리즘에 탑재되었다. 최적 환기 제어 알고리즘은 탑재된 모델에 기반하여 예측제어를 시행함으로써 실내 CO₂ 농도를 특정 수치 미만으로 유지시키기 위해 최적 풍량을 산출해 낸다. 최적 환기 제어 알고리즘 프로세스는 Fig. 7과 같으며 1) 데이터 취득, 2) 입력데이터 생성, 3) 제어변수별 실내 CO₂ 농도 예측, 4) 오차 계산, 5) 제어변수 선정 및 장비 신호송신으로 구분된다. Step. (1) ~ (5) 과정의 전체적인 알고리즘은 Fig. 8과 같다.

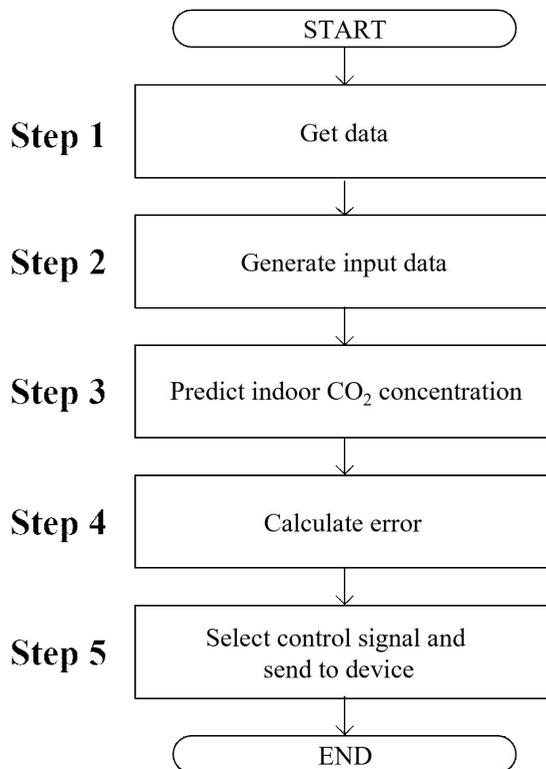


Fig. 7. 최적 환기 제어 프로세스

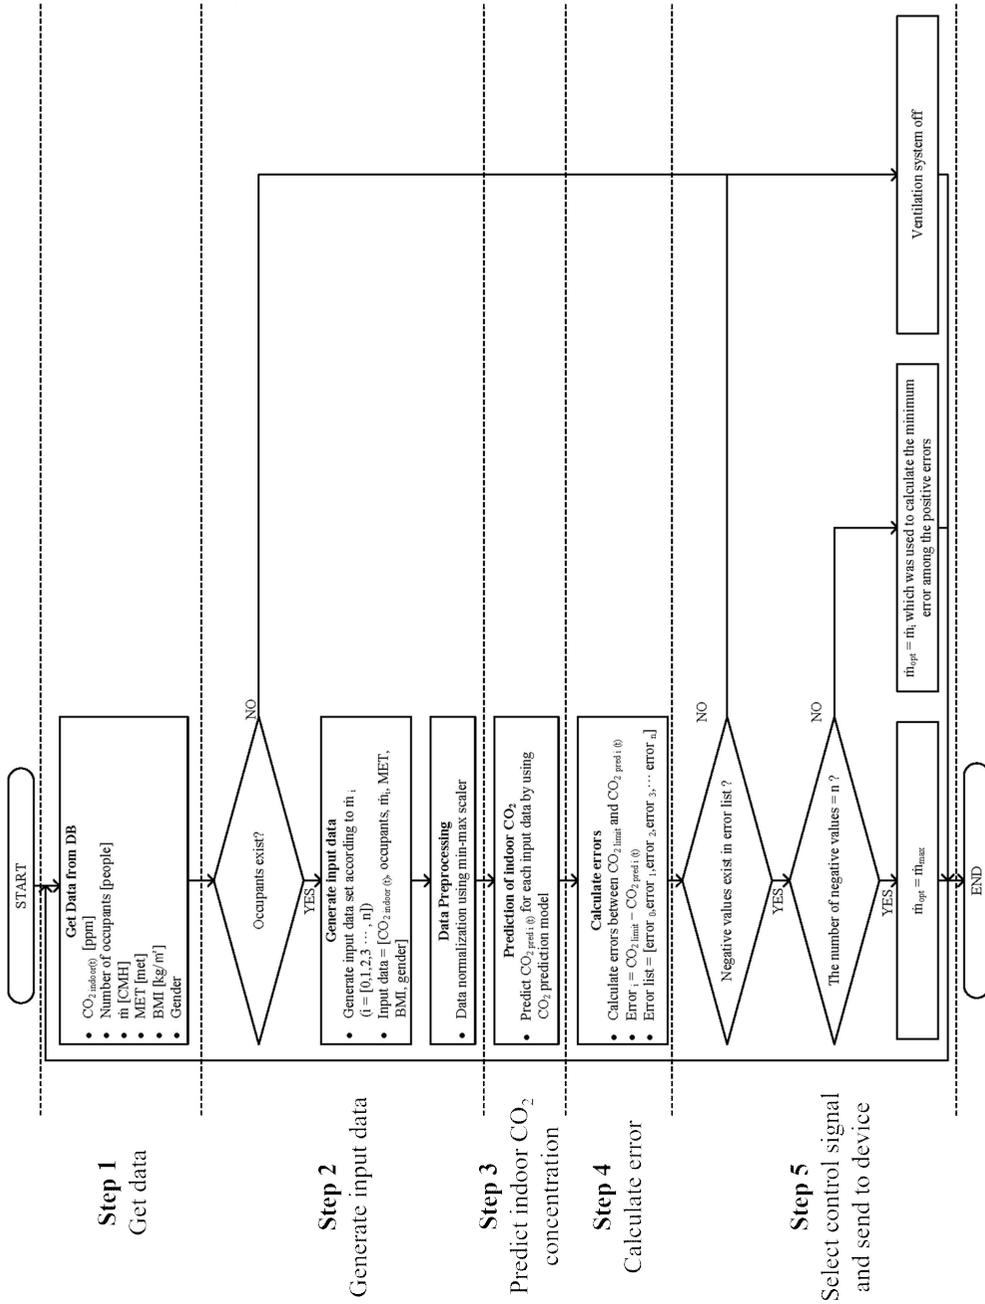


Fig. 8. 최적 환기 제어 알고리즘

- Step 1. 데이터 취득

최적 환기 제어 알고리즘의 첫 단계는 Fig. 9와 같이 DB로부터 실시간 저장된 데이터를 불러오는 과정이다. 취득 데이터는 실내 CO₂ 농도, 재실자 수, MET, 환기시스템 풍량, BMI, 성별이며, 실내 CO₂ 농도는 5분 평균값, 재실자 수와 MET는 5분 최빈값, 환기시스템 풍량은 취득 시점의 제어값, BMI와 성별은 재실자에 따른 고정값이다.

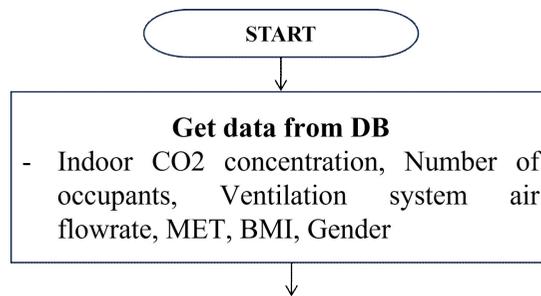


Fig. 9. 최적 환기 제어 알고리즘 데이터

- Step 2. 입력 데이터 생성

입력 데이터 생성과정은 Fig. 10과 같다. 먼저, 재실자가 감지된 경우 실내 CO₂ 예측을 위한 입력 데이터를 생성한다. 환기시스템 풍량에 따른 실내 CO₂를 예측하여야 하므로 제어변수 경우의 수 만큼의 리스트를 생성한다. 제어변수 (i)는 0, 1, 2, 3, ... , n으로 표현되며 입력데이터 리스트 구성은 다음과 같다.

- Input data = [실내 CO₂ 농도, 재실자 수, MET, 환기시스템 풍량(i) (i = [0, 1, 2, 3, ..., n]), BMI, 성별]

배열화 된 입력데이터는 min-max normalization을 사용하여 0과 1사이의 값으로 변환시켜 예측에 사용 될 수 있도록 한다. 재실자가 없는 경우에는 환기시스템을 가동하지 않는다.

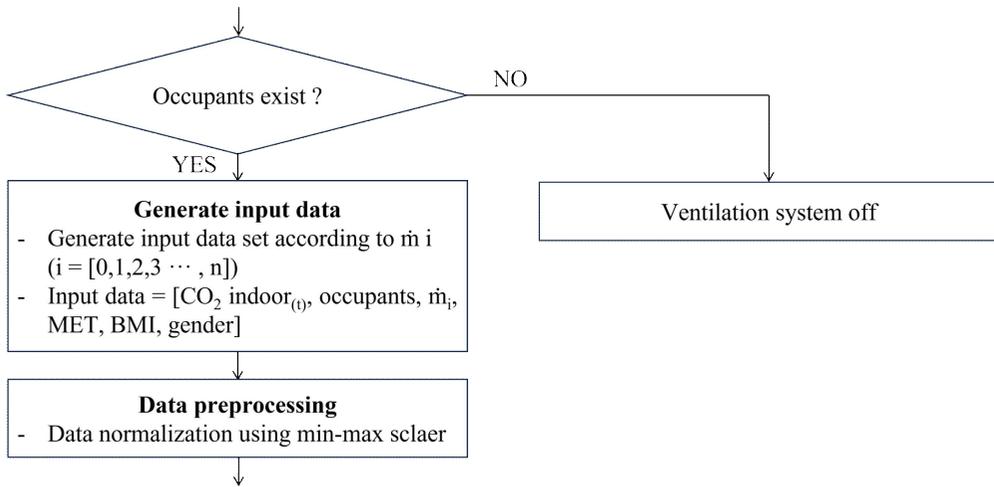


Fig. 10. 최적 환기 제어 알고리즘 입력 데이터 생성

• Step 3. 풍량별 실내 CO₂ 농도 예측

입력데이터 리스트를 예측 모델에 입력하여 환기시스템 풍량에 따른 5분 후의 실내 CO₂ 농도 n개를 예측하며 Fig. 11과 같다. 예측값은 CO₂ pred_{i(t)} (i = [0, 1, 2, 3, 4, ...,n])로 표현한다.

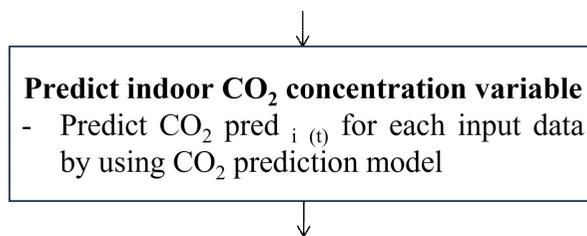


Fig. 11. 최적 환기 제어 알고리즘 풍량별 CO₂ 농도 예측

• Step 4. 오차 계산

오차값을 통해 제어변수별 적용 가능 풍량 목록을 확인할 수 있으며, 계산 과정은 Fig. 12와 같다. 먼저, 오차 계산을 위한 기준치 선정은 재실자 실내 공기질 쾌적도를 고려하여 산업안전보건법 제13조 제1항 ‘사무실 공기의 오염물질별 관리기준’에 따라 1,000 ppm으로 하였다. 오차값은 기준치로부터 $CO_2\ pred_{i(t)}$ 의 각 항목별 수치를 식 3과 계산하여 오차값을 구한 뒤 오차값들을 error list로 배열화한다.

$$Error_i = CO_{2\ limit} - CO_{2\ pred\ i(t)} \dots\dots\dots (식\ 3)$$

여기서,

$Error$: 오차 값

$CO_{2\ pred\ (t)}$: 예측시점(t+1) 실내 CO_2 농도 [ppm]

$CO_{2\ limit}$: 1,000 ppm, 실내 CO_2 농도 기준 [ppm]

i : 제어변수 ($i = [0, 1, 2, 3, 4, \dots, n]$)

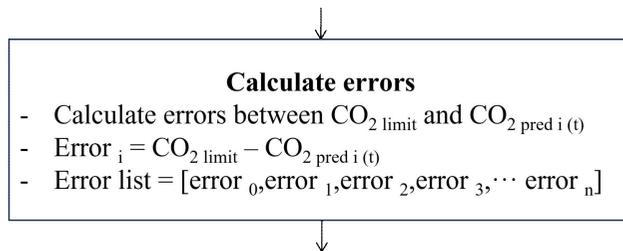


Fig. 12. 최적 환기 제어 알고리즘 오차 계산

- Step 5. 제어 변수 선정 및 송신

최적 풍량은 Fig. 13과 같이 error list에서 양수 및 음수 여부를 확인하여 선정된다. 오차값 중 음수가 없다면 모든 제어변수를 넣어도 실내 CO₂ 농도가 CO₂ limit보다 작음을 의미하며, 환기시스템 가동을 종료한다. 오차값의 음수가 제어변수와 개수가 동일하면 모든 제어변수를 적용해도 CO₂ limit값보다 높아지는 것을 의미하며, 신속한 실내 공기질 개선을 위해 가장 강한 풍량으로 제어한다. 마지막으로, 오차값의 음수 개수가 최소 1개 이상 최대 n-1개 이하인 경우 에너지 소비를 최소화 시키기 위해 오차값 중 0과 가까우며 양수인 제어변수를 선택하여 최적 풍량 제어를 실시하고 해당 제어변수를 DB로 저장한다.

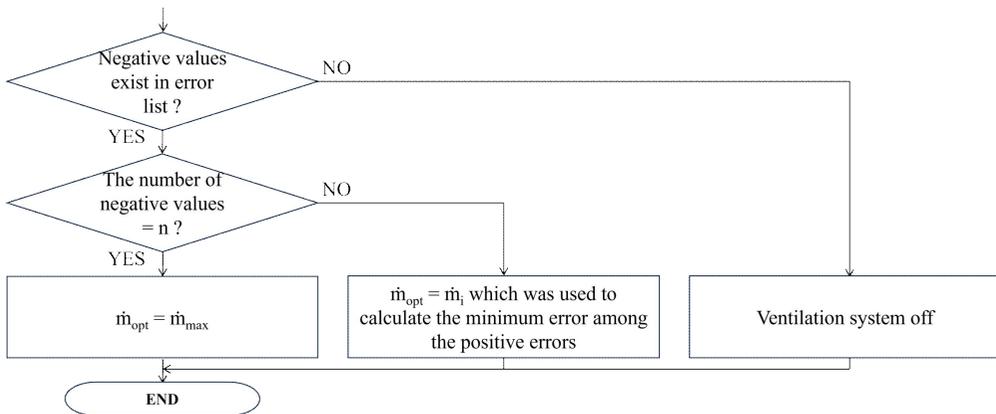


Fig. 13. 최적 환기 제어 알고리즘 풍량 선정 및 제어

(6) 평가 지표

성능 평가 항목은 먼저, 실내 CO₂ 농도 예측 모델 예측 정확도, 최적 환기 제어 알고리즘 예측 정확도를 평가한다. 실내 CO₂ 농도 예측 모델의 예측 정확도는 모델이 실내 CO₂ 농도를 얼마나 정확하게 예측하는지를 평가하며,

최적 환기 제어 알고리즘의 예측 정확도는 알고리즘이 환기 전략을 얼마나 효과적으로 예측하고 적용하는지를 평가한다. 두 항목의 차이는 전자는 실내 공기질의 상태를 예측하는 데 중점을 두고, 후자는 그 예측을 바탕으로 최적의 환기 전략을 실행하는 데 중점을 둔다. 다음으로 공기질 쾌적기간 유지비율을 평가한다. 먼저 실내 CO₂ 농도 예측 모델 및 최적 환기 제어 알고리즘 예측 정확도는 관련 연구에서 주로 사용하는 평균 절대 오차 (Mean Absolute Error, MAE), 평균 절대 백분율 오차 (Mean Absolute Percentage Error, MAPE), 평균 제곱근 오차의 변동 계수 (Coefficient of Variation of Root Mean Square Error, CvRMSE), 결정 계수(coefficient of determination, R²)를 사용하였다(Wu, et al., 2021; Dong et al., 2022; Fang et al., 2021), MAE, MAPE, CvRMSE는 0에 가까울수록 성능이 좋을 것을 의미하며, R²는 1에 가까울수록 모델에 의한 예측성능이 우수함을 의미한다. 각 지표별 수식은 식 4~7과 같다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - t_i| \dots\dots\dots (식 4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - t_i}{y_i} \right| \times 100 \dots\dots\dots (식 5)$$

$$CvRMSE = \frac{1}{\bar{Y}_i} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2} \dots\dots\dots (식 6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - t_i)^2}{\sum_{i=1}^n (y_i - \bar{Y}_i)^2} \dots\dots\dots (식 7)$$

여기서,
 \bar{Y}_i : 평균 값

y_i : 정답 값

t_i : 예측 값

n : 데이터 개수

공기질 쾌적기간 유지비율은 제어 기간내 실내 CO₂ 농도 기준치인 1,000ppm을 넘기지 않은 비율이며, 식 8과 같다.

$$\frac{\text{number of points where indoor } CO_2 < 1,000 \text{ ppm}}{\text{number of points of control period}} \times 100 \quad (\text{식 8})$$

3.3 소결

본 장에서는 실내 CO₂ 예측 모델과 이를 탑재한 최적 환기 제어 알고리즘의 개발 과정 및 구성에 대해 서술하였다. 이를 통해 실내 공기질을 효과적으로 관리하고, 에너지 효율성을 극대화하는 목표를 달성하고자 한다.

(1) 실내 CO₂ 예측 모델 개발

실내 CO₂ 예측 모델은 DNN과 LSTM 모델을 사용하였으며, mock-up 예비실험 데이터를 기반으로 입출력 데이터 선정 및 데이터 전처리 과정을 진행하였다. 전처리된 데이터는 정해진 하이퍼파라미터 범위내에서 가장 우수한 성능의 조합을 도출하는 베이지안 최적화를 사용하여 초기 실내 CO₂ 예측 모델을 개발하였다.

(2) 최적 환기 제어 알고리즘 개발

최적 환기 제어 알고리즘은 데이터취득, 입력데이터 생성, 제어 풍량별 실내 CO₂ 예측, 오차 계산, 풍량 선정 및 장비 신호송신의 5단계로 구성된다. 먼저, 데이터 취득은 DB를 통해 실내 CO₂ 농도, 환기시스템 풍량, 재실자 수, MET, BMI, gender의 데이터를 불러온다. 불러온 데이터는 환기시스템 풍량을 제어변수(i) ($i = 0, 1, 2, 3, \dots, n$)로 설정하여 0부터 n 까지 정수값을 대입하여 입력데이터를 생성한다. 입력데이터로 $t+1$ 의 실내 CO₂ 농도를 예측하고 예측값을 리스트화 한다. 기준값으로부터 예측값과의 차이를 구해 오차값이 모두 양수일 때, 이는 어떤 제어변수를 넣어도 실내 CO₂ 농도가 기준값보다 낮음을 의미하며 환기시스템 가동을 중단한다. 그리고 모든 오차값이 음수일 때, 환기시스템 풍량을 최대로 가동한다. 마지막으로 오차값 중 음수가 1개이상 $n-1$ 개라면 오차가 양수이면서 0과 가까운 오차값의 제어변수를 환기시스템으로 송신하여 해당 풍량으로 가동한다.

제 4 장 Mock-up 및 베이스라인 구축

4.1 Mock-up 구축

본 장에서는 실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘의 개발과 적용을 위한 mock-up 구축 및 검증 과정에 대해 서술한다. 다수의 인원이 재실하고 있는 공간에서 공기질 관련 실험을 위해 환기시스템을 동의 없이 강제로 제어하는 것은 재실자 건강에 악영향을 미칠 수 있다. 따라서, 본 연구에서는 통제된 환경에서의 데이터 취득과 성능평가를 위해 환경센서, 영상센서, 그리고 환기시스템이 설치된 mock-up을 구축하였다. Mock-up 실험의 목적은 실제 데이터 바탕의 실내 CO₂ 농도 예측 모델 개발과 이를 탑재한 최적 환기 제어 알고리즘 적용에 대한 가능성을 시험하는데 있다.

(1) 개요 및 구성

Mock-up의 개요와 구성은 Table 9와 같고, 구축 및 실험 사진은 Fig. 14, 15와 같다. Mock-up의 설치 위치는 서울시 동작구 흑석동 'C' 대학교 2층이다. 내부 면적은 정부청사관리규정 시행규칙 제274호 제2조 2항 '청사 취득 및 배정면적' 기준에 따라 업무 전용공간 면적인 3.54m² 기준과 유사한 2.6m (D) * 1.35m (W) * 2.4m (H) 규모이다. 외피는 바닥을 제외한 모든 면을 통해 재실자 정보 관측이 가능하도록 투명한 무정전 패널로 제작하였다. Mock-up은 실내에 위치하며, 실과 mock-up 사이 공간(이하, 사이공간)에는 서버 및 관리자가 위치한다. 따라서, 해당 실이 차폐되는 경우 mock-up 내부의 CO₂ 농도에도 영향을 미칠 수 있기 때문에 창문과 문을 모두 개방하여 실외 조건과 차이가 거의 없도록 조성하였다.

실내 CO₂ 농도 예측 모델 및 최적 환기 제어 알고리즘 성능평가를 위해서는 실내외 환경변수, 재실자 정보, 그리고 환기시스템 가동 상태에 대한 실시간 데이터 취득이 필수적이다. 이를 위해 실외와 mock-up 내부에 IoT 기반의 환경센서를 설치하였고, 사이공간에는 영상센서와 서버를

설치하였다. 센서에 대한 세부 내용은 Table 10과 같다.

환경센서(AW-1008-K-P)는 mock-up 내부 높이 1.2m의 벽면에 3개를 설치하였다. 온도, 습도, CO₂, PM₁₀, PM_{2.5}, VOC가 취득되며 본 실험에서는 CO₂ 데이터만 사용하였다. 서버와의 연결을 위해 마이크로 컨트롤러 유닛(Micro Controller Unit, MCU)인 Arduino Uno를 설치하였으며 이를 통해 순시값과 5분 평균값을 DB에 저장하였다.

재실자 정보인 재실자 수, MET, BMI, 성별 데이터 취득은 기존 연구에서 개발된 딥러닝 알고리즘 기반 재실자 정보 산출모델을 사용하였다. 재실자 수와 MET는 해당 산출모델로 검출이 가능하지만, BMI와 성별 데이터는 현재 명확한 검출 기술이 개발되지 않았기 때문에 피실험자 정보를 입력했다.

재실자 정보 산출모델은 영상센서로부터 이미지를 취득하여 객체 인식을 통해 재실자를 검출한다(Choi et al., 2019; Choi et al., 2021). 이후, 활동인지 방법론을 활용하여 재실자 이미지로부터 추출된 18개의 관절 포인트를 기반으로 사람의 활동 및 그에 해당하는 MET 값을 산출한다. 재실자 검출 및 MET 값 산출 정확도는 기존 연구에서 시뮬레이션 및 mock-up 실험을 통해 MET의 평균값을 사용하는 경우 오차가 발생하였고, 최빈값을 적용할 때 100% 정확한 대푯값을 산출하였다(박보량 등, 2017; 최은지, 2023). 따라서, 본 연구에서는 해당 모델을 서버 컴퓨터에 적용하고 영상센서를 설치하여 재실자 정보 감지하고 30초 뒤 환기시스템 제어와 연계될 수 있도록 설정하였다. 산출된 재실자 정보 중 재실자 수는 10~15초 마다 저장되며, MET 값은 5분 동안의 최빈값이 저장된다.

환경 및 영상 센서들로부터 얻은 데이터를 동시에 하나의 서버로 보내는 경우 데이터 간 충돌이 발생하여 일부 데이터가 누락 혹은 소실 될 수 있다. 이를 해결하기 위해 MCU인 Raspberry pi 4와 Arduino Uno를 중간 단계에 설치하여 데이터 통신을 분산시켰다. 최종적으로 전달된 데이터는 DB에 저장되며, 사용한 통신 프로토콜은 Modbus RTU (RS485)이다.

Table 9. Mock-up 개요

구분	내용	
평면도		
위치	서울 동작구 'C' 대학교	
면적	3.51m ²	
체적	8.42m ³	
외피 정보	바닥	MDF
	외벽	무정전 아크릴
	천장	
재실자 수	1명	
시스템	제 1종 환기 설비	
취득 데이터	<ol style="list-style-type: none"> 1) 실내·외 온도 [°C] 2) 실내·외 습도 [%] 3) 실내·외 CO₂ 농도 [ppm] 4) 환기시스템 급·배기 풍량 [CMH] 5) BMI [kg/m²] 6) MET [met] 7) 재실자 수 [명] 8) 성별 [0,1,2] 	



Fig. 14. Mock-up 구축 및 센서, 환기시스템 설치

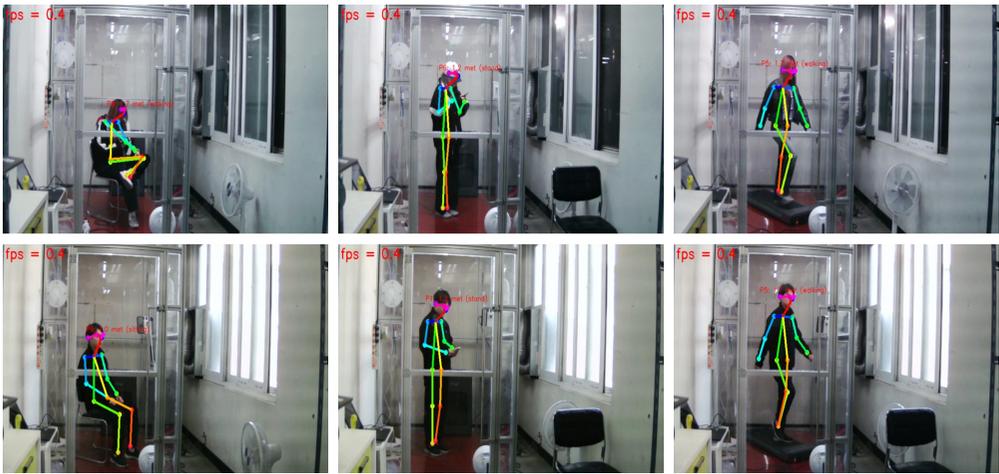
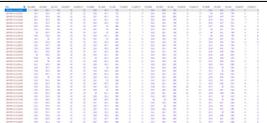


Fig. 15. 피실험자 실험 진행

Table 10. Mock-up 설치 장비 정보

구분		정보	사진
AM1008W -K-P	Temp	• -40 °C ~ 85 °C	
	Humi	• 5 ~ 95% RH	
	CO ₂	• 0 ~ 5,000 ppm	
	PM	• 0 ~ 1,000 µg/m ³	
Occupant information	STWC-500	<ul style="list-style-type: none"> • 재실자 수 산출 • 해상도 : 1080p • 프레임 : 30 fps 	
	HW20	<ul style="list-style-type: none"> • MET 산출 • 해상도 : 1440p • 프레임 : 30 fps 	
Ventilation System	Fan (BFM 17051B)	• 24V / 5A DC Brushless Fan	
	Damper	• ø125 Damper	
	Relay	• Arduino 5V 4-Channel Relay interface board.	
	Power	• 24V 5A Adapter	
MCU		• Raspberry Pi 4	
		• Arduino Uno	
DB		• HeidiSQL	

(2) 환기시스템 구성 및 제어

환기시스템은 협소한 mock-up 내부공간으로 인해 기성 제품을 설치가 불가하여 직접 제작하였으며, 구성은 Fig. 16과 같다. 급배기를 위한 2개의 팬과 제어 모드(off, 외기도입, 내부순환) 구현을 위한 4개의 댐퍼를 설치하였으며 개별 제어가 가능하도록 구성하였다.

②, ③번 위치에 설치된 급배기 팬(BFM17051B)은 24V DC 팬으로 크기는 170mm (D) * 170mm (W) * 51mm (H)이다. 정적 압력이 13.54 mmH₂O 일 때, 최대 377.4 CMH의 풍량을 발생시킨다. 제어 모드를 결정하는 댐퍼는 총 4대로 ①-1~4에 해당하며, 공급팬 앞쪽에는 고성능 필터를 적용하여 실외 미세먼지 유입을 최소화 하였다. 제어 모드별 댐퍼작동은 다음과 같다.

- 시스템 미작동(off): ①-1~4 모든 댐퍼 off
- 외기 도입모드: ①-1, 2 댐퍼 on, ①-3, 4 댐퍼 off
- 내부 순환모드: ①-1, 2 댐퍼 off, ①-3, 4 댐퍼 on

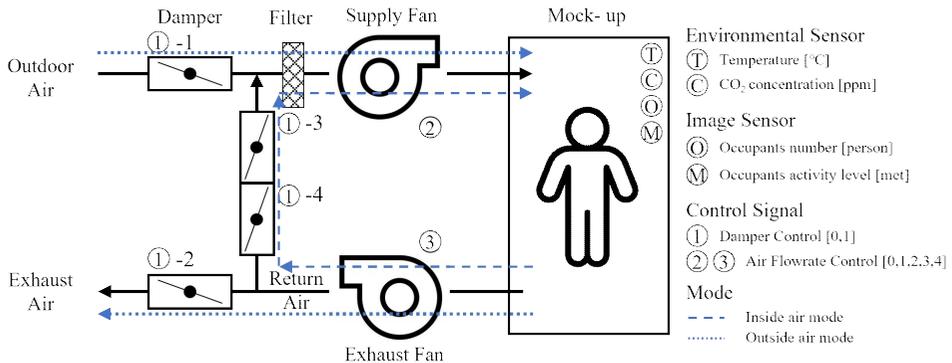


Fig. 16. 환기시스템 구성도

공급 풍량에 따른 실내 CO₂ 농도 변화를 분석하기 위해서는 세부적인 풍량 조절이 필수적이다. 이에 본 연구에서는, MCU를 활용한 실시간 풍량 조절 제어 방법을 적용하였다. 먼저, 구성된 팬과 댐퍼를 하나의 MCU에 연결하여 각각 독립적인 제어신호를 받도록 구성하였다. 팬은 MCU를 통해 PWM (Pulse Width Modulation) 제어신호를 받아 작동한다. 전압 제어 방식중 하나인 PWM 제어는 전자기기에서 널리 사용되는 기술로 디지털 신호를 사용하여 아날로그 결과를 생성하는 방법이다(A.M. Wu et al., 2019). PWM 제어의 기본 요소로는 주파수(Frequency), 듀티 사이클(Duty Cycle), 해상도(Resolution) 로 구성된다. PWM 신호를 주게 되면 정해진 주파수 주기에 펄스 신호를 보내며 듀티 사이클이 형성된다. 듀티 사이클은 HIGH 상태(ON 상태)인 시간의 비율을 말한다. 퍼센트(%)로 표현되며, 전체 주기 대비 펄스의 길이를 결정한다. 예를 들어, Fig. 17와 같이 듀티 사이클이 50%인 경우, 펄스는 반 시간 동안 ON 상태이고 반 시간 동안 OFF 상태이다. 해상도는 PWM 신호의 듀티 사이클을 얼마나 세밀하게 조절할 수 있는지를 나타내는 값이며, 해상도가 높을수록 더 정밀한 전력 제어를 한다. 이와 같은 방식으로 PWM 제어신호에 따라 풍량 제어가 가능하다.

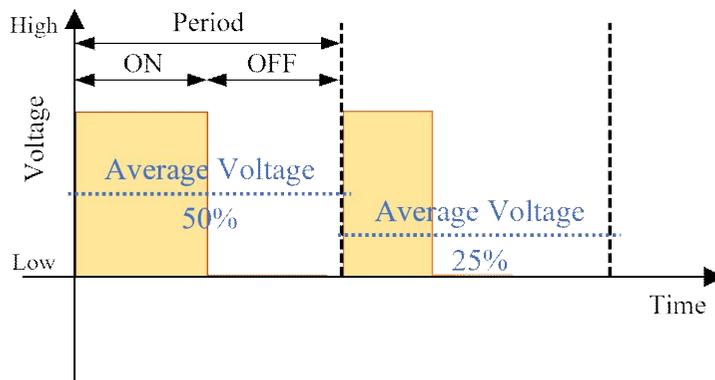


Fig. 17. PWM 제어 듀티 사이클

댐퍼는 4채널 릴레이 모듈(arduino 4ch relay module)에 연결하여 on/off 전자신호에 의해 개폐가 결정되도록 구성하였다. 각 댐퍼별로 on/off 제어가 가능하도록 댐퍼의 전류 흐름 on 값을 'a' off 값을 'A'로 정의하였으며, 'a' 입력시 댐퍼가 열리고, 'A' 입력시 댐퍼가 닫히도록 변수값을 지정하였다.

(3) 예비 실험

환기시스템의 팬은 설치되는 공간형상 및 정압에 따라 풍량이 변동된다. 따라서, mock-up 환경에 맞는 정확한 풍량 산출을 위한 실험을 진행하였다. 서버 컴퓨터로 PWM 제어신호를 변경하고 풍속계(ALNOR RVA+)를 사용하여 측정하였다. PWM 아날로그 변수 범위는 0~255이며, 설치된 팬의 최소 가동 변수는 190부터 시작한다. 풍량 측정은 PWM을 5씩 증가시키며 진행하였다. 데이터 노이즈 및 변동 최소화를 위해 각 PWM 변수별 세 번의 측정 과정을 거쳐 평균값을 사용하였으며, 측정된 팬의 급·배기 풍량(CMH)은 Table 11와 같다.

Table 11. PWM 값에 따른 급·배기 풍량 측정 결과

PWM	SA 풍량 [CMH]	RA 풍량 [CMH]
190	4.23	5.11
195	7.84	8.07
200	9.94	12.21
202	12.52	15.36
205	24.36	30.03
207	30.11	35.66
210	35.78	42.12
213	42.18	50.44
215	54.19	60.46
219	60.12	71.09
220	69.23	73.07
225	82.99	88.43
230	83.23	89.94
235	84.02	90.54
240	84.32	91.22
245	84.61	92.81
250	85.41	93.12
255	88.56	93.66

단계별 풍량제어의 최소 기준을 정하기 위해 Table 11의 결과를 참고하여 ASHRAE Standard 62.1의 식 9를 사용해 mock-up의 최소 환기량을 계산하였다.

$$Q = P_x \times R_p + A_x \times R_a \dots\dots\dots (식 9)$$

여기서,

Q : 최소 환기량 [cfm]

P_x : 재실자 수 [person]

R_p : 재실자 1인당 필요 환기량 [cfm]

A_x : 바닥 면적 [ft^2]

R_a : 바닥 면적당 필요 환기량 [cfm]

본 연구의 대상 건물은 사무실로 이에 대응하는 R_p 값은 5 cfm 이고 R_a 값은 0.06 cfm 이며, 이는 ASHRAE Standard 62.1에 건물 용도별로 규정되어 있다. 이를 토대로 계산시 7.27 cfm 이며, cubic meter/hour [CMH]로 변환하여 12.35 CMH의 최소 환기량을 구하였다. 최소 환기량은 Supply Air Flow(이하 SA)의 미풍으로 지정하고 약, 중, 강풍을 최소 환기량 홀수 배수의 근삿값인 35.78 CMH, 60.12 CMH, 88.56 CMH로 선정하였다.

선정된 풍량이 실제 재실자 활동시 실내 CO₂ 농도 감소 성능 확인을 위해 SA 값을 고정시키고, Return Air Flow(이하 RA) 값에 변화를 주는 실험을 계획하였다. 실험 내용은 4가지로 분류되는데 Test 1은 환기시스템의 가동을 하지 않을 때이며, Test 2는 일반적인 건물들과 같이 mock-up 내부의 압력 균형을 유지하기 위해 SA, RA의 풍량을 동일하게 설정하였다. Test 3는 RA보다 SA 풍량을 높게 하여 mock-up 내부를 양압 상태로 유지되게 하였다. 마지막 Test 4는 SA보다 RA 풍량을 높게 하여 mock-up 내부를

음압으로 유지되게 하였다. 이 경우 외부 오염물질이 내부로 들어올 확률이 높아지지만, 해파 필터를 통해 이를 최소화 하였다. 실험 진행을 위해 BMI 정상 범주의 남녀 각 1명씩 피실험자를 구하였고 제시된 4가지 Test마다 앉기 (met 1.0), 서기 (met 1.2), 걷기 (met 1.7) 총 3가지 활동을 20분씩 진행하였다. 실험에 적용된 Test별 풍량을 Table 12와 같이 설정하였으며, 실험 결과는 Table 13와 같다.

Test 1~4 중 환기 성능이 가장 우수한 것은 RA 값이 SA 값보다 높은 Test 4로 CO₂ 배출량이 가장 많은 걷기 기준 off일 때와 비교시 약 50% 감소하였다. 환기 성능이 가장 부족한 것은 Test 3로 걷기 기준 off일 때와 비교시 약 32% 감소하였다. 그 이유로는 mock-up 기밀도가 매우 높아 자연 배기가 거의 되지 않으며 이에 따라 유일한 배출 수단인 RA 풍량에 의존도가 높음을 확인하였다. 최적 환기 제어 알고리즘 실험에서는 환기 성능이 가장 우수한 Test 4 풍량을 적용하였다.

Table 12. Test별 SA, RA 풍량

유형	세기	PWM	SA [CMH]	PWM	RA [CMH]
Test 2 SA=RA	미	202	12.52	200	12.21
	약	210	35.78	207	35.66
	중	219	60.12	215	60.46
	강	255	88.56	225	88.43
Test 3 SA>RA	미	202	12.52	195	8.07
	약	210	35.78	205	30.03
	중	219	60.12	213	50.44
	강	255	88.56	220	73.07
Test 4 SA<RA	미	202	12.52	202	15.36
	약	210	35.78	210	42.12
	중	219	60.12	219	71.09
	강	255	88.56	255	93.66

Table 13. 풍량 성능 실험 결과

조건	피실험자 A(남) 평균 실내 CO ₂ 농도 [ppm]			피실험자 B(여) 평균 실내 CO ₂ 농도 [ppm]		
	앞기	서기	건기	앞기	서기	건기
	Test 1 Ventilation System off	1,486	1,325	2,547	1,140	1,085
Test 2 (SA=RA)	875	886	1,393	822	887	1,227
Test 3 (SA>RA)	1,045	975	1,735	948	984	1,352
Test 4 (SA<RA)	852	868	1,274	748	784	1,208

4.2 컴퓨터 시뮬레이션 기반 모델링

본 장에서는 리빙랩 기반 컴퓨터 시뮬레이션 모델링 과정과 예측 모델 및 제어 알고리즘 개발을 위한 데이터 취득 방법에 대해 서술한다. 컴퓨터 시뮬레이션의 목적은 다양한 제어환경을 동일한 환경에 적용하여 객관적 비교를 진행하기 위함이다. 모델링은 Design Builder와 EnergyPlus를 사용해 진행하였으며, 실제 데이터를 바탕으로 캘리브레이션을 진행하여 타당성을 검증하였다.

(1) 모델링 개요

대상 리빙랩은 'C' 대학교 1층에 위치한 업무공간으로 개요는 Table 14과 같다. 해당 건물은 1995년에 준공된 건물이며, 2010년도에 외벽 리모델링을 진행하였다. 외벽 및 바닥의 200 mm 콘크리트 위로 단열재가 설치되어있으며, 두께는 준공 당시 기준과 동일한 XPS 50 mm이다. 창은 서측으로 2개가 위치해 있다. 인접공간은 석고보드 가벽으로 구분되어 있으며 출입을 위한 문이 설치되어 있다. 재실자 인원은 총 9명이며, ERV(Energy Recovery Ventilation) 환기시스템 및 EHP(Electric Heat Pump) 냉난방기가 설치되어있다.

리빙랩 내부에 총 4개의 환경 센서를 1.2m 높이에 설치하였고, 외부에는 백엽상을 설치하였다. 취득 데이터는 실·내외 온도, 습도, CO₂ 농도, PM₁₀, PM_{2.5} 농도로 MCU와 연결되어 15초마다 DB에 데이터가 저장된다. 재실자 정보 취득 방법은 mock-up과 동일하다. 재실자 수 및 MET 산출 데이터는 영상 센서를 통해 25 ~ 45초 주기로 산출되며 DB에 저장된다. BMI와 성별은 검출이 완벽하게 된다는 가정하에 전체 재실 인원의 평균값을 사용하였다

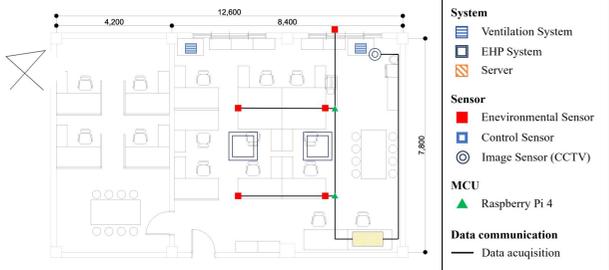
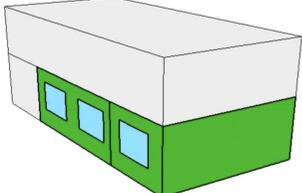
환기시스템은 'H' 사의 HRD2-1000EGS 모델을 사용하였다. 해당 모델은 환기, 자동, 바이패스 3가지 모드 선택이 가능하다. 풍량은 미풍 ~ 터보의 5단계로 구성되며 각각 200 CMH, 300 CMH, 500 CMH, 1,000 CMH, 1,100

CMH의 풍량을 토출한다. 외기 도입을 위해 서측 창가쪽으로 배치하였으며 공간의 크기 및 재실자 수를 고려하여 총 2대를 설치하였다.

시뮬레이션 프로그램은 LBNL (Lawrence Berkeley National Laboratory)에서 개발된 오픈 소스 소프트웨어인 EnergyPlus V9.4.0와 DesignBuilder Software Ltd에서 운영하는 Design Builder 7.0.2.003 version을 사용하였다. Design Builder는 EnergyPlus의 동적 열 시뮬레이션 엔진에 대한 그래픽 인터페이스를 지원하는 프로그램이다. 건물 설계, 에너지 성능 및 CFD 시뮬레이션이 가능하며, EnergyPlus 파일인 IDF로 추출이 가능하다(Bharath et al, 2021). EnergyPlus에서 IDF 파일을 불러오는 경우 DesignBuilder 보다 더 많은 종류의 데이터를 취득할 수 있다. 따라서, 모델링은 Design Builder, 시뮬레이션 및 데이터 취득은 EnergyPlus로 진행하였다.

리빙랩에 설치된 ERV 환기시스템과 동일한 환기 모델은 DesignBuilder와 EnergyPlus에서 제공하지 않는다. 따라서, Off, 외기도입, 내부순환 모드의 모사가 가능한 VAV noReheat 모델을 환기시스템으로 선정하였으며, 냉난방에 의한 에너지소비량을 배제하기 위해 냉동기 및 보일러는 삭제하였다. 캘리브레이션을 위해 재실자 스케줄 및 시스템 가동 스케줄은 일반 업무시설과 동일하게 수정하였다.

Table 14. 시뮬레이션 개요

구분		내용	
평면도			
모델링			
위치		서울 동작구 'C' 대학교	
면적		62.83m ²	
체적		169.64m ³	
재실자 정보	재실자 수	9명	
	스케줄	평일, 10:00 ~ 20:00 주말, 공휴일 재실없음	
침기량		180 CMH	
열관류율	지붕	3.322 W/m ² k	
	외벽	0.463 W/m ² k	
	바닥	0.463 W/m ² k	
환기시스템	풍량	mode 1	mode 2
		200 CMH, mode 3	300 CMH mode 4
	500 CMH	1000 CMH	
모드	바이패스, 환기모드, 자동모드		
취득 데이터		1) 실·내외 CO ₂ 농도 [ppm] 2) 급배기 풍량 [CMH] 3) BMI [kg/m ²] 4) MET [met] 5) 재실자 수 [명] 6) 성별 [0,1,2]	

(2) 시뮬레이션 캘리브레이션

시뮬레이션 캘리브레이션은 컴퓨터 시뮬레이션 모델의 정확성을 향상시키기 위해 실제 시스템의 데이터와 비교하여 모델의 매개 변수를 조정하는 프로세스이다(Higdon, Dave, et al, 2004). 또한, 모델의 예측이 실제 시스템과 일치하도록 하여 모델의 유효성 및 타당성을 확인하는 중요한 과정이다(Trottini, Mario, et al, 2020).

캘리브레이션을 위해 2024년 3월 11일부터 3월 24일, 2주간의 실·내외 CO₂ 농도 데이터를 취득하였다. 추가적으로, 환기시스템 풍량 조절에 따른 실내 CO₂ 농도 변화량을 측정하기 위해 재실자들의 동의를 받은 후 Table 15과 같이 풍량 제어를 실시하였으며, 실험 중 답답함을 느끼는 인원이 발생하는 경우 10분의 휴식시간을 제공하여 재실자에게 미치는 악영향을 최소화하였다.

취득 기간의 첫 주(3월 11일 ~ 17일)는 센서 안정화 및 데이터 정확도 판단 기간이며, 캘리브레이션에 사용된 데이터는 2주차(3월 18일 ~ 24일) 데이터이다. 실·내외 CO₂ 농도와 재실자 데이터는 15 ~ 30초의 저장 주기를 갖지만 EnergyPlus에서는 1시간 단위 스케줄만 입력이 가능하기 때문에 1시간 평균 데이터를 사용하였다. 취득된 재실자 수 데이터는 Table 16과 같다. 활동량 측정 결과, 대부분 1.0 met가 관측되었으며 이는 업무공간 특성상 앉아 있는 시간이 길기 때문인 것으로 판단된다. BMI 및 성별 데이터는 리빙랩 재실 인원의 평균값인 22.43 kg/m²과 1.5 값을 고정하여 사용하였다. 환기청정기 가동 시간은 업무 시간인 10:00~20:00 으로 고정하였고, 주말에는 가동을 중지하였다.

Table 15. 리빙랩 환기시스템 풍량제어 스케줄

환기시스템 풍량 스케줄								
보정 기간	1주차	3/11	3/12	3/13	3/14	3/15	3/16	3/17
	풍량	OFF	미풍	약풍	중풍	강풍	-	-
취득 기간	2주차	3/18	3/19	3/20	3/21	3/22	3/23	3/24
	풍량	미풍	OFF	약풍	강풍	중풍	-	-

Table 16. 리빙랩 재실자 수

시 간	18일	19일	20일	21일	22일	23일	24일
00:00~08:00	0	0	0	0	0	0	0
08:00~09:00	2	1	2	1	1		
09:00~10:00	4	8	7	3	7		
10:00~11:00	3	4	4	2	4		
11:00~12:00	1	5	4	1	5		
12:00~13:00	7	8	7	6	8		
13:00~14:00	7	9	7	5	4		
14:00~15:00	7	9	8	5	9		
15:00~16:00	7	9	7	4	9		
16:00~17:00	7	9	5	6	7		
17:00~18:00	2	3	1	2	4		
18:00~19:00	2	2	1	0	0		
19:00~20:00	1	0	0	0	0		
20:00~24:00	0	0	0	0	0		

캘리브레이션 결과는 Fig. 18과 같다. 캘리브레이션 성능 평가는 MAPE, CvRMSE, R^2 를 사용하였으며, MAPE는 예측값과 실제값 간의 차이의 절대값을 실제 데이터의 평균값으로 나누어 백분율로 나타낸 것이다. 모델의 예측 성능을 직관적으로 평가하고, 다른 데이터 세트나 모델 간의 성능을 비교할 수 있는 지표이다. 낮은 MAPE 값은 예측 모델이 실제값에 가깝다는 것을 의미한다. CvRMSE는 RMSE(Root Mean Squared Error)를 실제 데이터의 평균값으로 나눈 후 백분율로 나타낸 것이다. RMSE는 예측값과 실제값 간의 차이의 제곱을 평균한 후 제곱근을 취한 값으로, 예측값의 변동성을 나타내며, 예측 오차를 데이터의 변동성에 비례하여 표현하므로, 모델의 예측 오차를 상대적으로 평가할 수 있다. 특히 다른 데이터 세트나 모델 간의 비교 시 유용하다. R^2 는 모델이 실제 데이터를 얼마나 잘 설명하는지를 나타내는 지표이다. 0에서 1 사이의 값을 가지며, 1에 가까울수록 모델이 데이터를 잘 설명한다는 것을 의미한다. R^2 는 총 변동성 중에서 모델이 설명하는 비율을 나타낸다. R^2 는 모델의 설명력을 평가하는 중요한 지표로, 모델이 실제 데이터의 변동을 얼마나 잘 설명하는지 확인할 수 있다. 높은 R^2 값은 예측 모델이 실제 데이터를 잘 설명하고 있다는 것을 의미한다. 본 연구에서는 이러한 지표들을 함께 사용함으로써, 예측 모델의 성능을 다각적으로 평가할 수 있으며, 모델의 예측 정확성, 오차의 상대적 크기, 데이터 설명력 등을 종합적으로 판단할 수 있다. 실제 데이터와 시뮬레이션 결과를 비교한 결과, MAPE, CvRMSE, R^2 는 각각 6.01%, 7.53%, 0.9717로 우수한 정확도를 확인하였다.

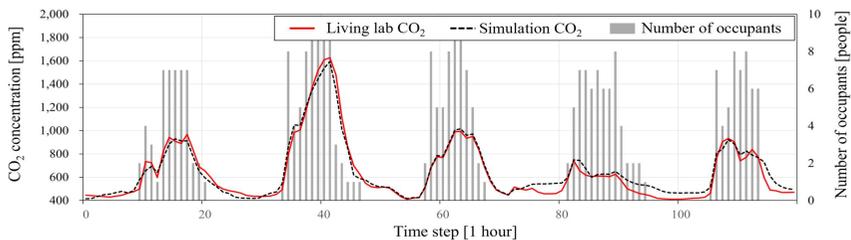


Fig. 18. 시뮬레이션 캘리브레이션 결과

4.3 소결

본 장에서는 재실자 정보 기반 실내 CO₂ 농도 예측 모델 및 최적 환기 제어 알고리즘 개발 및 적용을 위해 mock-up 구축과 컴퓨터 시뮬레이션 모델링 과정에 대해 서술하였다.

Mock-up은 서울 동작구 'C' 대학교에 설치하였으며, 면적은 3.51 m²이다. 내부에는 별도로 제작한 환기시스템을 탑재하였고 IoT 기반 환경센서와 사이공간에 영상센서를 설치하였으며 데이터 취득 및 제어 알고리즘을 위한 서버와 통신체계를 구축하였다. 예비 실험을 통해 풍량 설정 및 시스템 제어 작동 및 환경 변수 취득을 확인하였고, 최적 환기 제어 알고리즘 적용 및 성능 비교를 위한 환경을 구축하였다.

컴퓨터 시뮬레이션은 EnergyPlus와 Design Builder를 사용하여 모델링 하였다. 시뮬레이션은 mock-up과 동일한 위치의 리빙랩을 대상으로 선정하였으며, 면적은 62.83 m²이다. 내부에는 ERV 환기시스템과 EHP 냉난방기가 설치되어있으며, 이를 시뮬레이션에도 동일하게 구성하였다. IoT 기반 환경센서와 영상센서를 설치하였다. 3월 18일부터 3월 24일까지 진행된 풍량 제어 실험을 통해 취득된 데이터로 캘리브레이션을 진행하였다. 캘리브레이션 결과는 MAPE, CvRMSE, R² 각각 6.01%, 7.53%, 0.9717의 우수한 성능을 통해 시뮬레이션 모델링의 타당성을 입증하였다.

제 5 장 성능 평가 및 결과 분석

본 장에서는 제3장에서 개발된 실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘을 mock-up 및 시뮬레이션에 적용한 결과에 대해 서술한다. 분석 내용은 예측 모델 학습 결과, 실시간 예측 정확도, 실내 CO₂ 쾌적 비율, 그리고 에너지소비량이며, 최적 환기 제어 알고리즘의 우수성을 입증하기 위해 규칙 기반 제어와의 비교 분석을 실시하였다.

5.1 Mock-up 실험

(1) Mock-up 실험 개요

Mock-up 실험은 2명의 피실험자 활동에 따라 각각 3가지로 총 6가지 Case로 구분된다. Case 1~3은 피실험자 A, Case 4~6은 피실험자 B에 해당된다. 각 Case는 활동에 따라 분류되며, 피실험자 별로 앉기, 서기, 걷기를 수행한다. 하나의 Case는 총 80분 실험으로 진행되며, 40분은 규칙 기반 제어 알고리즘, 40분은 최적 환기 제어 알고리즘이 적용되었다. 동일한 초기 실내 CO₂ 농도 조건을 조성하기 위해 규칙 기반 제어 알고리즘 이후 약 10분 간의 환기를 실시하였다. 실험 개요는 Table 17과 같다.

Table 17. Mock-up 실험 피실험자 스케줄

구분	Case 1	Case 2	Case 3	Case 4	Case 5	Case 6
실험자	피실험자 A			피실험자 B		
활동	앉기	서기	걷기	앉기	서기	걷기
실험 스케줄	규칙 기반 제어 알고리즘 (40분)					
	최적 환기 제어 알고리즘 (40분)					

(2) 대조군 설정

대조군은 규칙 기반 제어 알고리즘으로 mock-up과 컴퓨터 시뮬레이션에 알고리즘간 비교를 위해 사용되며 현재 실내 CO₂ 농도가 기준치를 넘긴 경우 정의된 풍량에 따라 시스템을 가동시키는 방식으로 작동된다. 실내 CO₂ 기준치는 Fig. 11의 최적 환기 제어 알고리즘과 동일한 1,000 ppm미만이며 제어 기준은 CO₂ 농도에 따른 공기질 쾌적성에 관한 국제 표준인 DIN EN ISO 13779의 ‘실내공기질의 구분’에 근거하였다. Table 18는 실내 CO₂ 농도에 따른 쾌적도 지표를 나타낸다. 해당 지표를 바탕으로 CO₂ 농도 구간별 공급 풍량을 정의하였으며, 실내 CO₂ 농도가 1,000 ppm 이상 1,200 ppm 미만인 경우 1단계 풍량인 mode 2, 1,200 ppm 이상 1,400 ppm 미만인 경우 2단계 풍량인 mode 3, 그리고 1,400 ppm을 초과하는 경우 3단계 풍량의 mode 4를 가동시키도록 설계하였으며 해당 풍량은 최적 환기 제어 알고리즘과 동일하다. 또한 CO₂ 농도가 1,000 ppm 미만인 경우에는 시스템이 자동으로 가동을 중지하도록 설정하였다. 규칙 기반 제어 알고리즘은 Fig. 19과 같다.

Table 18. DIN EN ISO 13779 실내공기질의 구분

구분	공기질 정도	실내외 CO ₂ 농도 차이의 범위	실내 CO ₂ 농도 최대값 * 실외 CO ₂ 농도 400ppm 기준
IDA 1	아주 좋음	400 이하	800
IDA 2	좋음	400 ~ 600	1,000
IDA 3	보통	600 ~ 1,000	1,400
IDA 4	나쁨	1,000 초과	1,400 초과

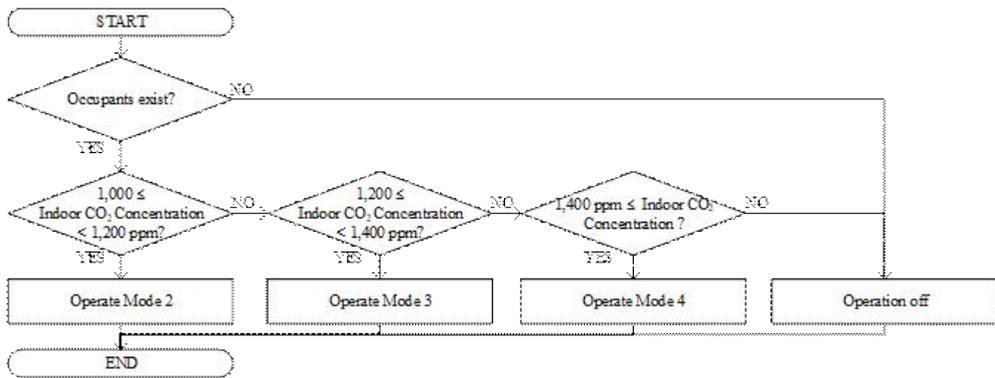


Fig. 19. 규칙 기반 제어 알고리즘

(3) 예측 모델 성능 평가

예측 모델 학습 결과는 예비 실험을 통해 취득한 학습데이터 중 학습에 사용되지 않은 test data를 사용하여 실시하였다. Table 19은 학습 모델별 페이지안 최적화에 의해 결정된 하이퍼파라미터들과 예측성능을 나타낸다.

먼저, DNN 기반 예측 모델의 학습률은 0.0001, 활성화 함수는 ReLU이며 최적 구조는 57개, 41개의 뉴런으로 구성된 2개의 은닉층으로 결정되었다. 모델의 예측 정확도 평가 결과, MAE 45.46 ppm, CvRMSE 13.87%, 그리고 R^2 0.8464로 나타났다. 다음으로 LSTM 최적 구조는 window size 3, horizon 1, 그리고 2개의 은닉층에 각각 75개, 11개의 뉴런으로 결정 되었다. 해당 모델의 학습률 및 활성화 함수는 DNN 모델과 동일한 0.0001과 ReLU이다. 예측 정확도는 MAE 29.19 ppm, CvRMSE 11.66%, R^2 0.8561로 우수한 성능을 나타냈다. 평가 지표 비교 결과 모든 지표에서 window size 3개를 갖는 LSTM 모델이 우수하였으며, 해당 예측 모델을 최적 환기 제어 알고리즘에 탑재하였다.

Table 19. 초기 예측 모델별 베이지안 최적화 결과

구분	최적화 결과			예측성능		
	구조	학습률	활성화 함수	MAE	CvRMSE	R ²
DNN	7-57-41-1	0.0001	ReLU	45.46 ppm	13.87%	0.8464
LSTM window size = 2 horizon = 1	7-35-42-1	0.0001	ReLU	31.67 ppm	15.38%	0.8412
LSTM window size = 3 horizon = 1	7-75-11-1	0.0001	ReLU	29.19 ppm	11.66%	0.8561

(4) 예측 모델 실시간 예측 정확도

실시간 예측 정확도는 매 time step 마다 제어 알고리즘이 가동되며 실내 CO₂ 예측 모델에 의해 출력된 예측값과 t+1 번째의 실제 실내 CO₂ 농도 비교를 통해 산출되었다. 두 데이터에 대한 실내 CO₂ 분포는 Fig. 20와 같다.

실내 CO₂ 농도의 분포 분석 결과, 대부분의 값이 860 ppm에서 1,047 ppm 사이에 위치하였으며, 최대치는 1,210 ppm을 초과하지 않았다. 예측된 값은 885 ppm에서 1,052 ppm 사이로 실측 값과 유사한 데이터 범위를 보였다. Fig. 21는 실측값과 예측값 비교그래프로 제어 초기 단계에서 이상치가 가장 높았으며, 이는 실내 CO₂ 농도 상승을 반영한 학습데이터가 부족한 것으로 보인다.

각 Case별 예측 정확도는 Table 20과 같다. 피실험자 A의 경우 1에서

3까지의 Case에 대한 MAE는 각각 53.75 ppm, 45.33 ppm, 56.42 ppm이었으며, CvRMSE는 6.90%, 7.50%, 5.91%이고, R^2 0.6683, 0.0047, 0.0276으로 나타났다. 피실험자 B의 경우 4에서 6까지의 Case에 대한 MAE는 각각 37.50 ppm, 37.39 ppm, 34.17 ppm이며, CvRMSE는 4.84%, 4.99%, 4.81%이고, R^2 는 0.9157, 0.9344, 0.8065로 우수한 예측 성능을 보였다. 이 결과들은 두 피실험자 모두 추세를 잘 따르고 있음을 보여주나, 초기에 CO₂ 농도가 급격히 변하는 구간에서 큰 오차가 지속적으로 발생하였다. 추후 추가적인 데이터 수집과 학습을 통해 오차 범위를 감소시킬 계획이다.

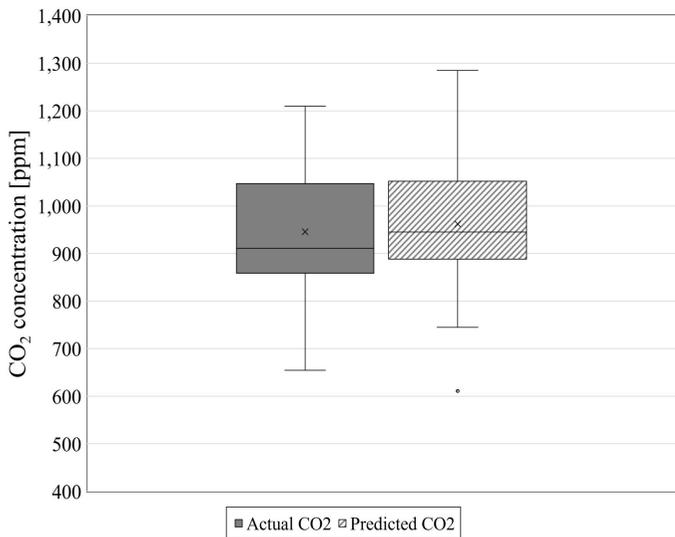


Fig. 20. Mock-up 제어변수 상자 수염 그래프

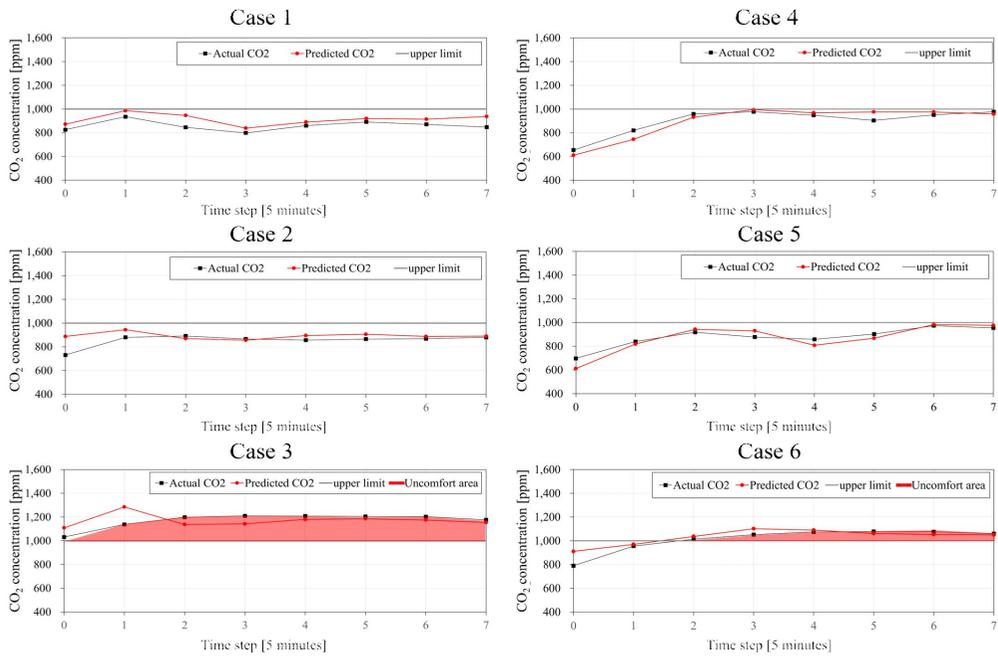


Fig. 21. Case별 비교 그래프

Table 20. Case별 환기 제어 알고리즘 예측 정확도

Case	MAE	CvRMSE	R ²
Case 1	53.75 ppm	6.90%	0.6683
Case 2	45.33 ppm	7.50%	0.0047
Case 3	56.42 ppm	5.91%	0.0276
Case 4	37.50 ppm	4.84%	0.9157
Case 5	37.39 ppm	4.99%	0.9344
Case 6	34.17 ppm	4.81%	0.8605

(5) 실내 CO₂ 쾌적도 비교

실내 CO₂ 쾌적도는 식 7과 같이 제어 기간 내 실내 CO₂ 농도가 기준치를 넘기지 않는 비율로 산출하였다. 피실험자들의 행동별 결과 그래프는 Fig. 22~27이다. 두 피실험자 모두 모든 행동에서 최적 환기 제어 알고리즘의 유지비율이 더 높았으며, 피실험자 A의 행동별 세부 분석은 Case 1~3, 피실험자 B는 Case 4~6으로 정리하였다.

- Case 1: 피실험자 A의 앉기 행동의 규칙 기반 제어 알고리즘 실험은 Fig. 22.(a)이며 시작 13분에 실내 CO₂ 농도 1,000 ppm을 달성하였다. 제어는 15분부터 시작되었으며 15분~35분까지는 약풍(mode 2)으로 제어가 되고, 35분에 1,200 ppm을 넘기며 중풍(mode 3)이 가동되었다. 제어를 진행하였음에도 실험의 2/3를 넘기는 기간동안 실내 CO₂ 농도가 1,100 ~ 1,200 ppm을 유지하였다.

최적 환기 제어 알고리즘의 실험은 Fig. 22.(b)이며 시작 10분 시점에 약풍 가동시 5분 뒤 CO₂ 농도 985 ppm을 예측하며 제어를 시작하였고, 모든 기간동안 기준치 보다 낮게 CO₂ 농도를 유지하였다. 이를 통해 약풍은 CO₂ 농도를 감소시키지 않지만 상승 속도를 천천히 늦춰주는 정도이며, 중풍은 CO₂ 농도를 감소시키는 풍량임을 확인할 수 있었다.

- Case 2: 피실험자 A의 서기 행동의 규칙 기반 제어 알고리즘 실험은 Fig. 23.(a)이며, 시작 16분에 실내 CO₂ 농도 1,000 ppm을 달성하였다. 제어는 20분부터 시작되었으며 제어가 시작되었음에도 1,200 ppm을 넘겨 중풍을 가동하였다. 이후 종료 시점직전에 가동 종료(mode off)되며, 제어 기간중 절반 이상을 1,100 ~ 1,200 ppm을 유지하며 실험이 종료되었다.

최적 환기 제어 알고리즘인 Fig. 23.(b)에서 실험 시작 5분 시점에 약풍 가동시 CO₂ 농도 922 ppm을 예측하며 제어를 시작하였고 다음 time step에 강풍(mode 4)을 예측해 큰 수치로 CO₂ 농도를 하락시켰다. 제어

기간동안 실내 CO₂ 농도가 평균 862 ppm이 나오며 모든 행동들 중 가장 낮은 결과를 보였다. 다만, 강풍대신 중풍을 가동하였어도 실내 CO₂ 농도에 대해 현상 유지 시킬 수 있었으나, 과한 예측으로 불필요한 에너지 소비를 야기할 수 있어 해당 부분은 재학습을 통해 보정이 필요한 것으로 판단된다.

- Case 3: 피실험자A 걷기 실험에선 규칙 기반 제어 알고리즘인 Fig. 24.(a)와 최적 환기 제어 알고리즘인 Fig. 24.(b) 모두 쾌적도 유지비율 8.59%, 13.95%로 초반 상승구간을 제외하고 모든 제어 기간동안 기준치 밑으로 유지시키지 못하였다. 다만, 최적 환기 제어 알고리즘의 경우 선제적 제어를 통해 초반 쾌적도 유지 기간을 늘렸으나 영향은 미미했다. 이는 환기시스템의 풍량이 부족하여 생긴 문제로 확인된다. 따라서, 제어시스템의 효과를 비교하기 위해 두 제어간 기준치와 얼마나 가깝게 제어했는지 비교하였다. 그 결과 규칙 기반 제어 알고리즘은 평균 1,327 ppm, 최적 환기 제어 알고리즘은 1,128 ppm로 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘 대비 약 15% 낮은 결과를 보이며, 기준치와 더 가깝게 제어했음을 확인하였다.

- Case 4: 피실험자 B의 앉기 실험에서 규칙 기반 제어 알고리즘 Fig. 25.(a)의 경우 시작 19분에 1,000 ppm에 도달하며, 20분부터 제어를 시작하였다. 실험 기간동안 약풍으로 가동 되었지만 실내 CO₂ 농도는 계속 상승하였다.

Fig. 25.(b)인 최적 환기 제어 알고리즘의 경우 실험 시작 15분 시점에서 20분째의 CO₂ 농도를 예측하며, 선제적 제어를 실시하였다. 이후 약풍 및 중풍으로 제어되어 실내 CO₂ 농도를 기준치보다 아래로 유지시켰다.

- Case 5: 피실험자 B의 서기 규칙 기반 제어 알고리즘 실험의 경우 Fig. 26.(a)이며, 실험 19분에 1,000 ppm에 도달하며, 20분부터 제어를 시작하였다. 제어는 약풍으로만 진행되었으며, 실험 종료까지 CO₂ 농도가 상승하였다. 실험 기간의 절반 이상을 기준치 아래로 유지하지 못하였다.

최적 환기 제어 알고리즘은 Fig. 26.(b)로 20분 시점에서 다음 time step CO₂ 농도를 예측하며 약풍으로 제어를 시작하였다. 25분 시점에서는 강풍을 틀어 실내 CO₂ 농도를 크게 감소시켰고, 이후 중풍과 약풍을 번갈아 틀며 실내 CO₂ 농도를 기준치 아래로 유지시켰다.

- Case 6: 피실험자 B 걷기는 Fig. 27.(a),(b)이며, Case 3와 동일하게 두 제어 방식 모두 절반 이상 기간동안 실내 CO₂ 농도를 기준치 밑으로 내리지 못하였다. 최적 환기 제어 알고리즘에서 실험 시작 5분 시점에서 선제적으로 강풍으로 제어를 시작하였지만 기준치를 넘기게 되었다. 이는 남자, 여자 성별 상관없이 걷기시 실내 환기 쾌적도를 유지하기 위한 풍량 자체가 약함을 의미한다. 따라서, 해당 실험에서도 피실험자 A 실험과 동일하게 제어 기간동안 쾌적 기준치와 얼마나 근접하여 실내 공간을 유지하였는지 확인하였으며, 규칙 기반 제어 알고리즘의 경우 평균 1,258 ppm, 최적 환기 제어 알고리즘은 1,028 ppm 으로 최적 환기 제어 알고리즘이 약 23% 낮았으며, 기준치와 근접하게 제어함을 확인하였다.

실내 CO₂ 쾌적도 결과와 비교 그래프는 각각 Table 21과 Fig. 28이다. 해당 비율은 실험 기간동안 환기시스템의 제어변수에 의해 실내 CO₂ 농도가 기준값 이하로 유지된 비율을 나타낸 것이며, 그래프의 time step은 DB 저장 주기인 5분 단위로 제시하였다.

결과를 정리하면, 피실험자 A는 규칙 기반 제어 알고리즘 적용시 유지비율이 앉기 29.63%, 서기 40.25%, 걷기 8.59%이며, 최적 환기 제어

알고리즘은 앉기, 서기, 걷기 각각 100%, 100%, 13.95%를 나타냈다. 피실험자 B는 규칙 기반 제어 알고리즘 적용시 앉기 46.3%, 서기 48.77%, 걷기 24.69%이며, 최적 환기 제어 알고리즘 적용시 앉기, 서기, 걷기 각각 100%, 100%, 36.65%의 결과를 나타냈다. 피실험자 A보다 피실험자 B의 CO₂ 배출량이 더 적은 이유는 주로 성별에 따른 MET와 체격 차이에서 기인할 수 있다. 일반적으로 남성은 여성보다 대사율이 높고, 체격이 큰 경우가 많아 호흡량이 더 많고 CO₂ 배출량이 증가한다. 이러한 성별 차이는 실내 CO₂ 농도에 직접적인 영향을 미치며, 이는 성별에 따른 대사율과 호흡 패턴의 차이가 실내 공기질 관리에 중요한 변수임을 확인하였다.

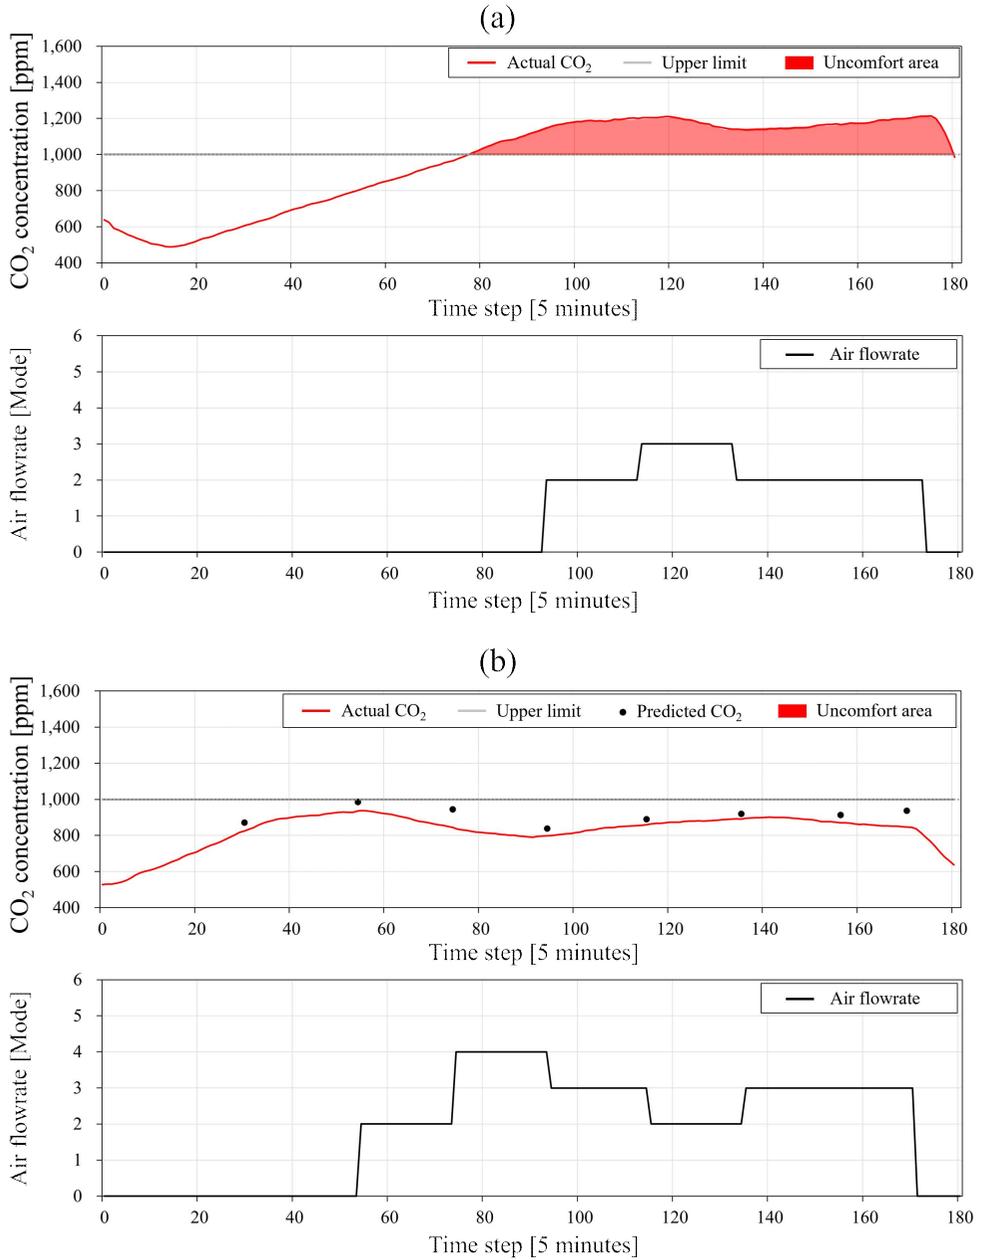


Fig. 22. Case 1 제어 알고리즘 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

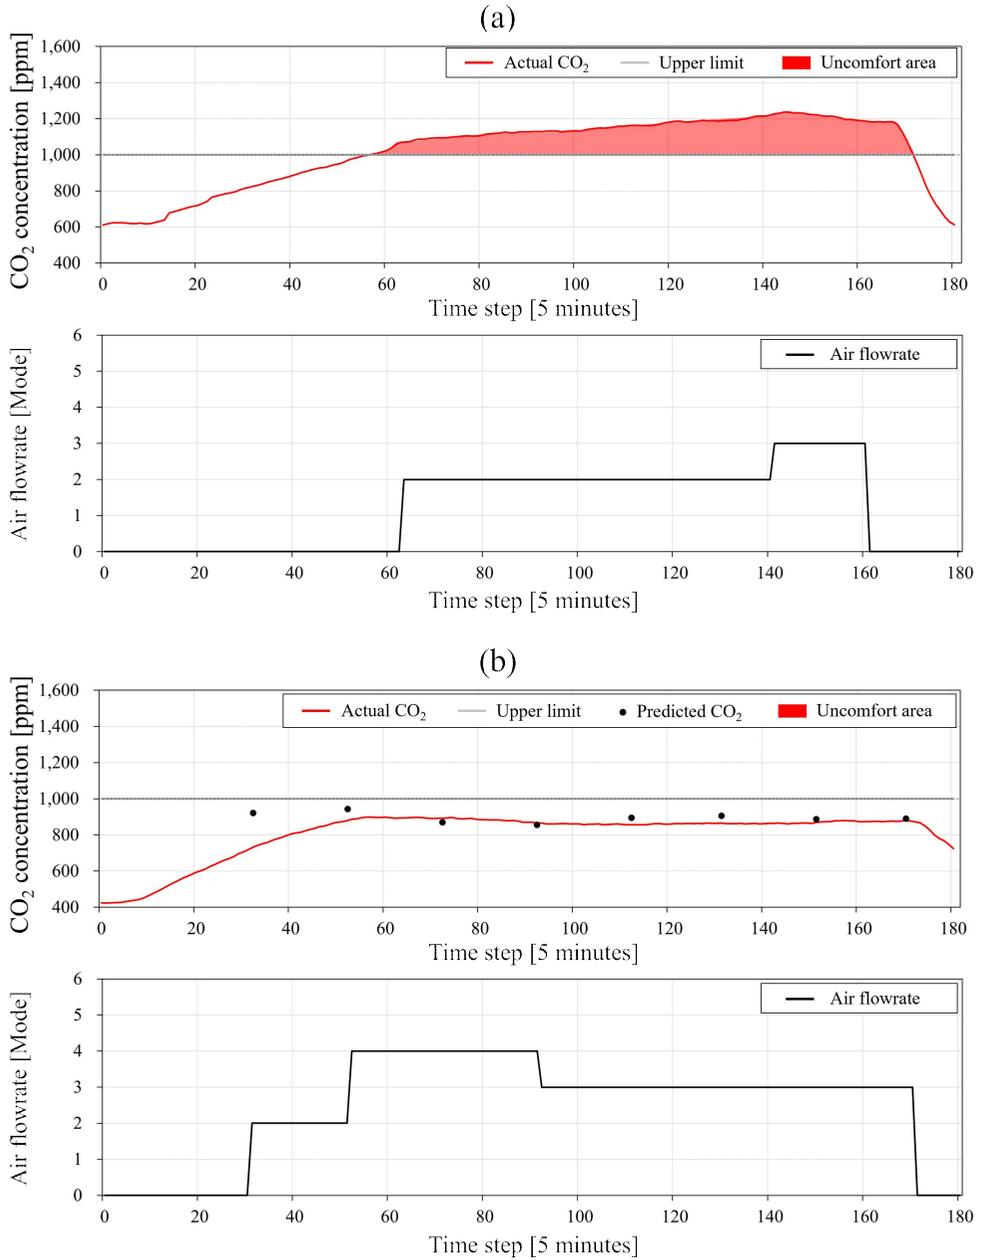


Fig. 23. Case 2 제어 알고리즘 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

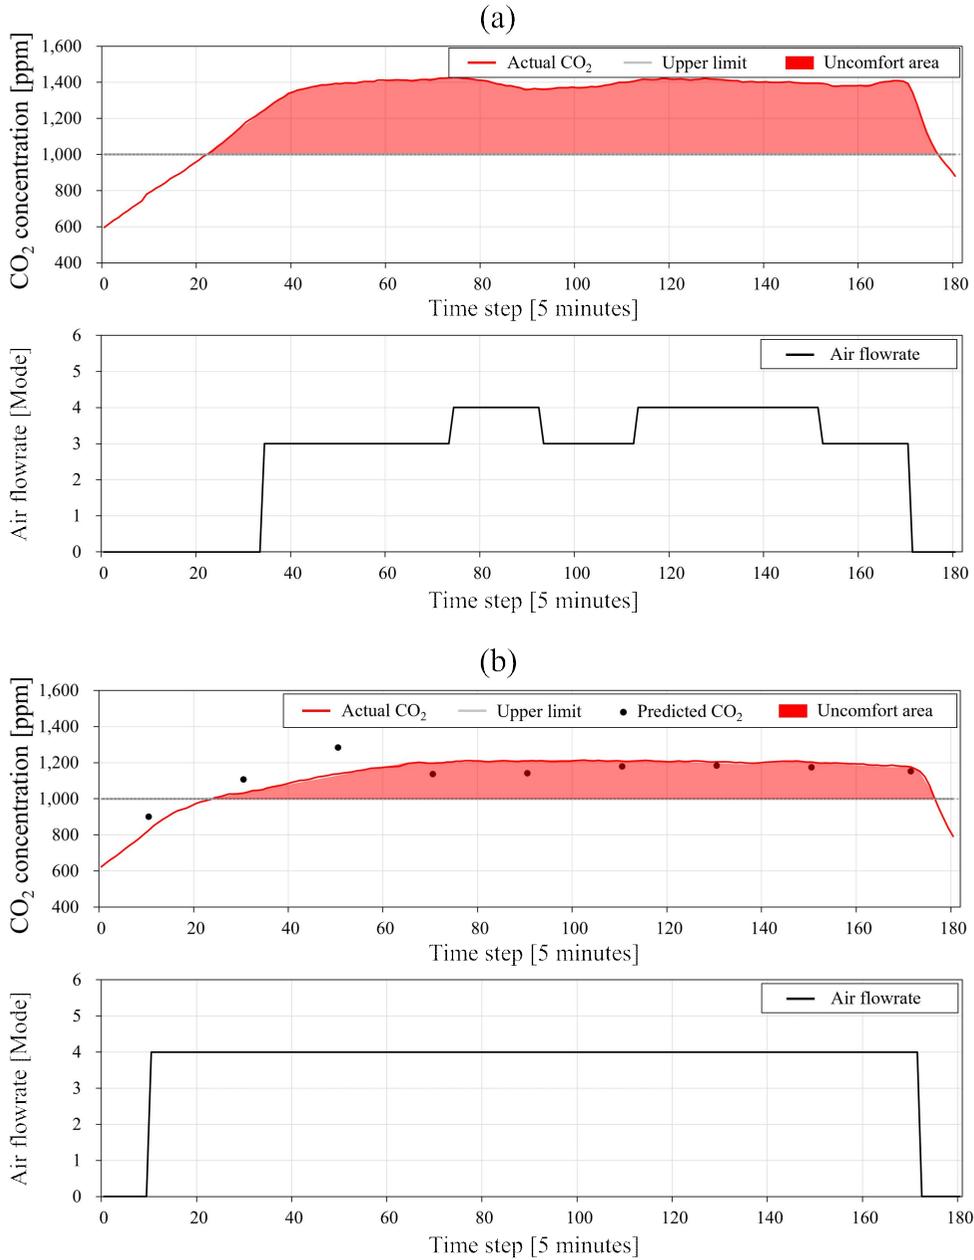


Fig. 24. Case 3 제어 알고리즘 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

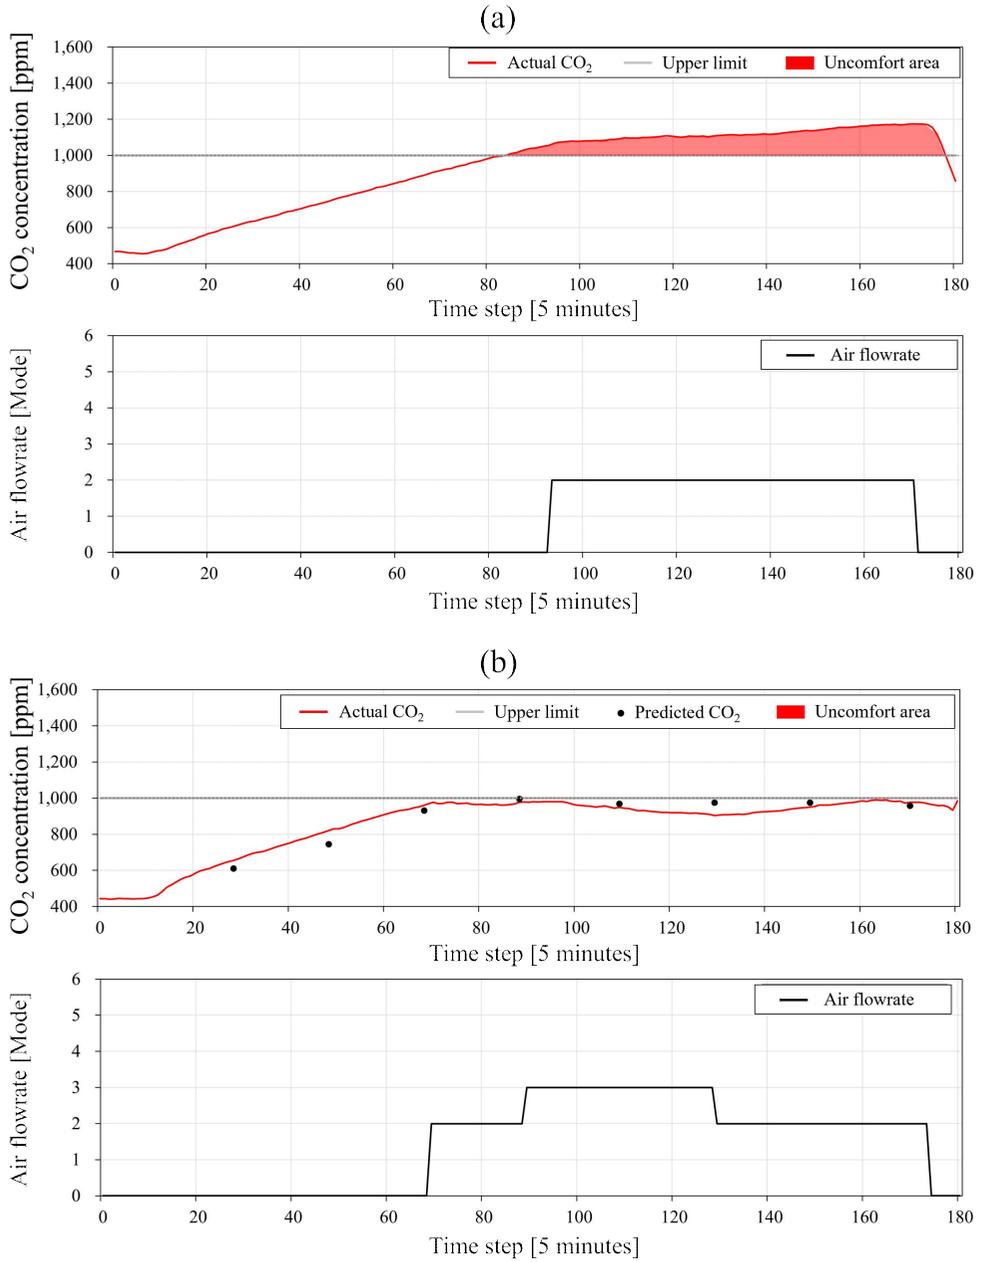


Fig. 25. Case 4 제어 알고리즘 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

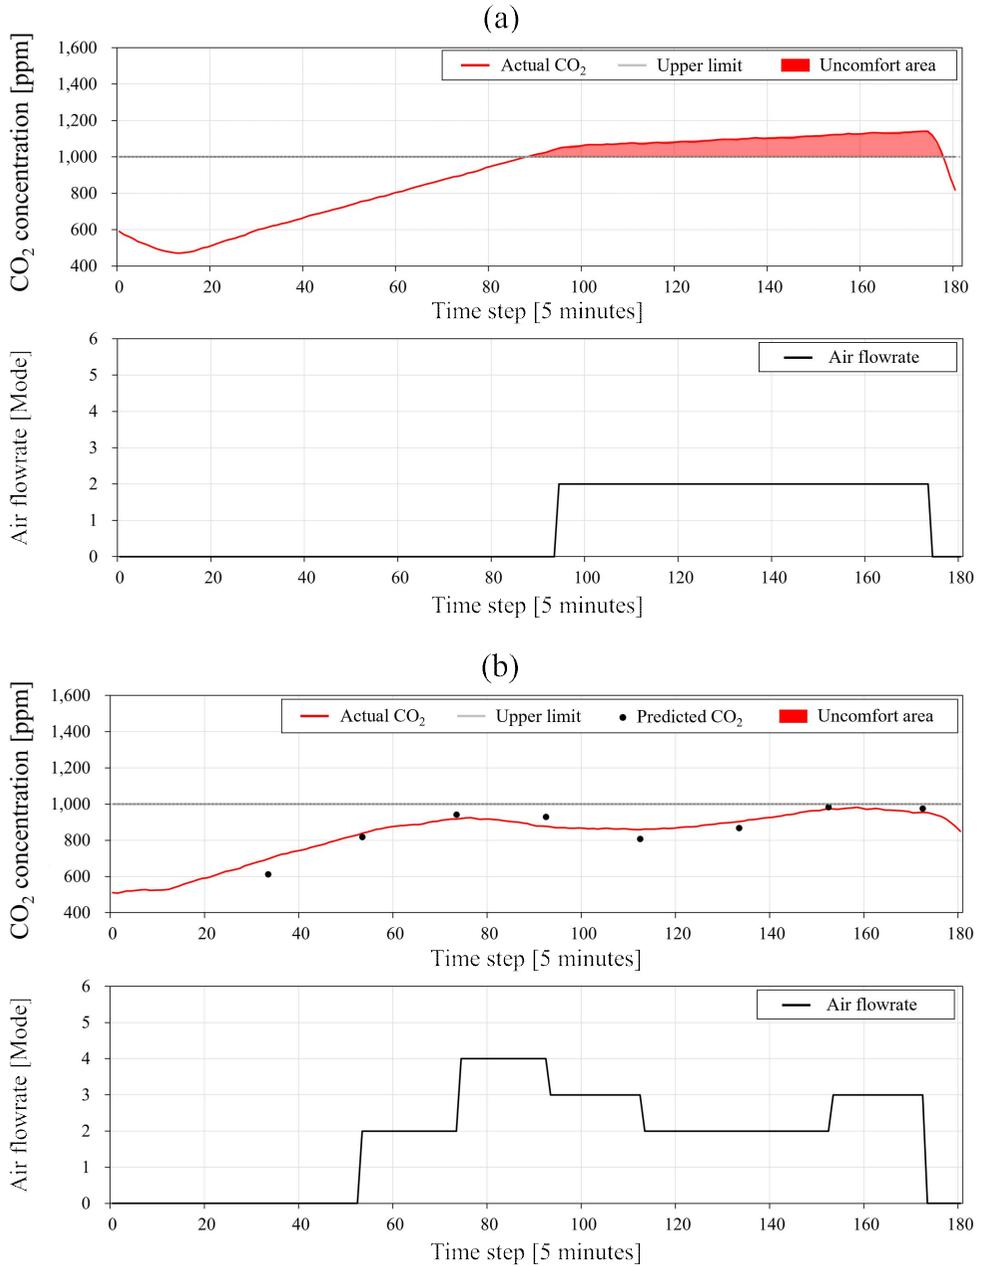


Fig. 26. Case 5 제어 알고리즘 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

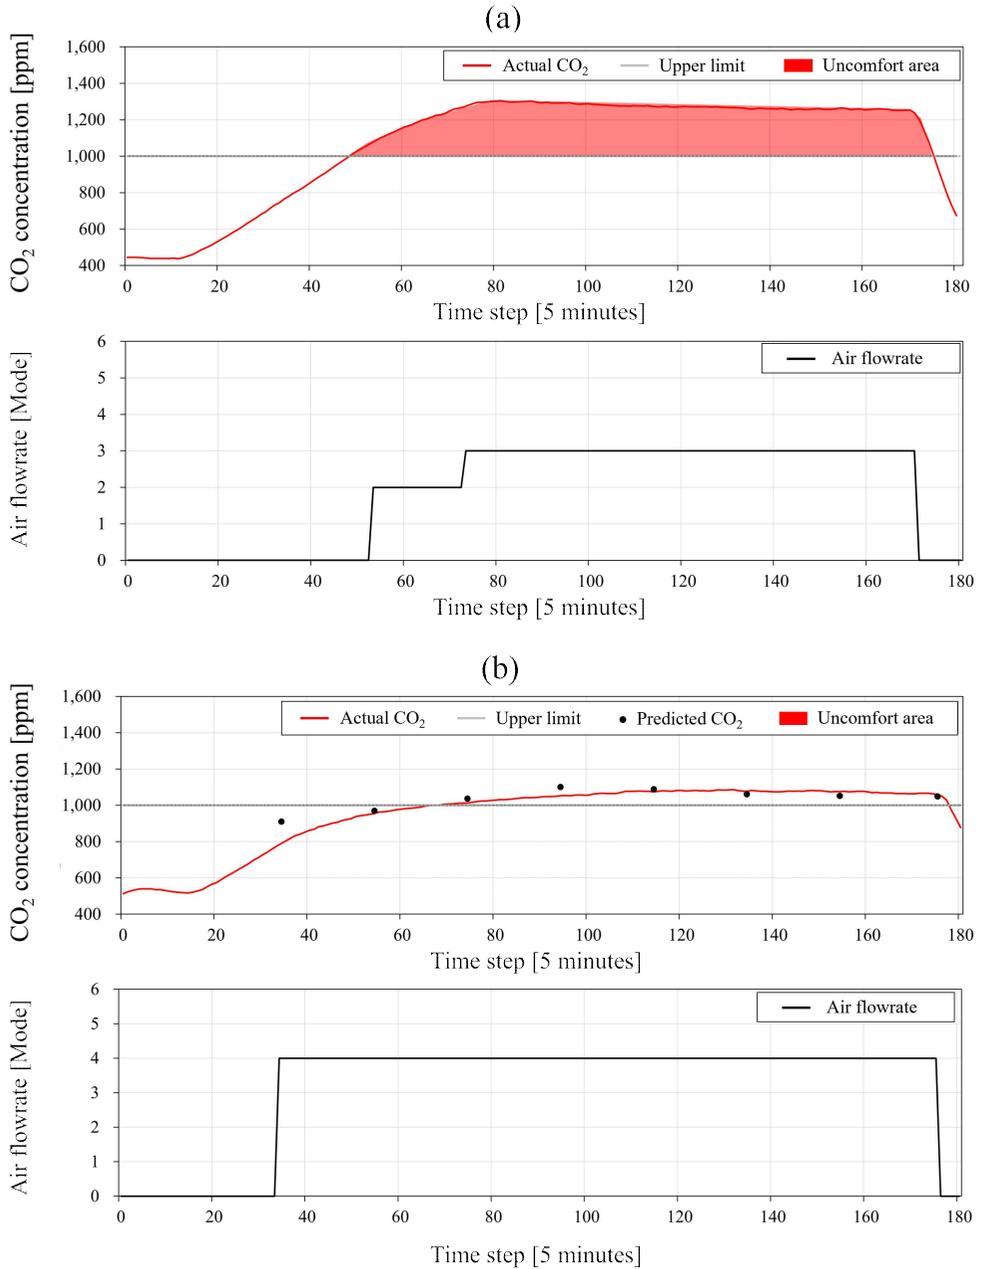


Fig. 27. Case 6 제어 알고리즘 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

Table 21. 제어별 실내 쾌적도 비율

구분	피실험자 A			피실험자 B		
	Case 1	Case 2	Case 3	Case 4	Case 5	Case 6
규칙 기반 제어 알고리즘	29.63%	40.25%	8.59%	46.3%	48.77%	24.69%
최적 환기 제어 알고리즘	100%	100%	13.95%	100%	100%	36.65%

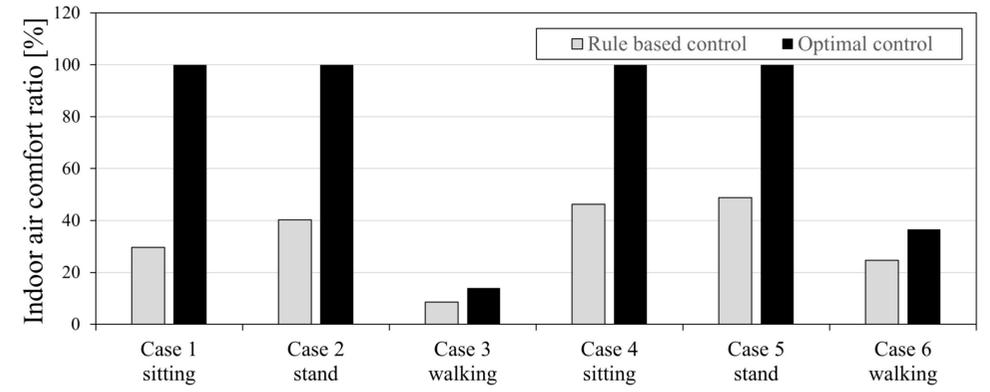


Fig. 28. 제어별 실내 공기질 쾌적도

(5) 에너지소비량 분석

본실험을 통해 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘보다 실내 CO₂ 쾌적도가 더 우수함을 확인하였다. 다만, 최적 제어를 통해 에너지 소비량 개선이 되었는지 확인이 필요하며, 분석 대상은 환기시스템 팬으로 설정하였다. 먼저, 전압 24V, 전류 5A의 팬 에너지소비량을 식 10으로 계산하였고, 최대 출력시 14.4W임을 확인하였다. 각 풍량별 에너지소비량 산출을 위해 EnergyPlus에서 사용하는 Performance Load Factor (PLF)를 사용하였으며, 계산식은 식 11과 같다. PLF는 EnergyPlus 내에서 팬의 전력 소비를 모델링하는 데 사용되는 다항식 곡선의 계수이다. 이 곡선은 풍량 비율(Flow Fraction, FF)에 따라 팬이 소비하는 전력의 비율 계수를 나타내는 것으로, 팬이 최대 출력 상태가 아닐 때 소비하는 전력을 예측하는 데 사용된다. 일반적으로 PLF는 0에서 1 사이의 값으로 표현되며, 1에 가까울수록 출력이 강함을 의미한다. 해당 공식의 상수 계수, 선형 계수, 2~4차 계수는 EnergyPlus에서 제공하는 Inlet Vane Dampers의 계수를 적용하였고, 내용은 Table 22와 같다.

PLF 계산을 위해 적용된 풍량 비율을 Table 23와 같이 정리하였다. 이는 Table 13의 Test 4의 값의 비율을 넣어 계산하였다. 해당 과정을 통해 얻은 PLF 계수 및 실제 전력값은 Table 24과 같다. SA의 PLF는 0.39, 0.44, 0.58, 0.99이며, RA의 PLF는 0.39, 0.46, 0.66, 0.99로 이를 14.4W와 곱한 뒤 같은 풍량끼리 더해 11.17W, 13.00W, 17.85W, 28.51W의 결과를 산출하였다.

$$P = V \times I \dots\dots\dots (식 10)$$

여기서,

P: 에너지소비량 (*W*)

V: 팬 전압 (*V*)

I: 팬 전류 (*A*)

$$PLF = C_1 + C_2 \cdot FF + C_3 \cdot FF^2 + C_4 \cdot FF^3 + C_5 \cdot FF^4$$

..... (식 11)

여기서,

PLF: 에너지 소비 계수

C₁: 상수 계수

C₂: 선형 계수

C₃: 2차 계수

C₄: 3차 계수

C₅: 4차 계수

FF : 풍량 비율

Table 22. Inlet Vane Damper 팬 계수

구분	C ₁	C ₂	C ₃	C ₄	C ₅
계수	0.3507	0.3085	-0.5414	0.8720	0.000

Table 23. SA, RA 풍량별 팬 풍량 비율 산출

모드	SA		RA	
	풍량 [CMH]	비율	풍량 [CMH]	비율
미	12.52	0.14	15.36	0.16
약	35.78	0.40	42.12	0.45
중	60.12	0.68	71.09	0.76
강	88.56	1.00	93.66	1.00

Table 24. PLF 계수 및 실제 전력 값

모드	SA		RA		합계 (W)
	PLF 계수	에너지 소비량(W)	PLF 계수	에너지 소비량(W)	
미	0.39	5.55	0.39	5.61	11.17
약	0.44	6.38	0.46	6.61	13.00
중	0.58	8.41	0.66	9.44	17.85
강	0.99	14.25	0.99	14.25	28.51

산출된 에너지소비량을 기준으로 규칙 기반 제어 알고리즘과 최적 환기 제어 알고리즘의 에너지소비량을 확인하였다. 제어별 에너지 소비량은 Table 25, 26와 같다. 피실험자 A가 규칙 기반 제어 알고리즘에서 얇기, 서기, 걷기에 대한 에너지소비량이 각각 5.81 Wh, 3.65 Wh, 11.61 Wh이며, 최적 환기 제어 알고리즘에서는 7.52 Wh, 10.31 Wh, 19.04 Wh로 모든 행동에서 최적 환기 제어 알고리즘이 최소 29%에서 최대 182% 더 많은 에너지를 사용하였다. 피실험자 B도 마찬가지로 얇기, 서기, 걷기 에너지소비량은 규칙 기반 제어 알고리즘 적용시 4.32 Wh, 4.32 Wh, 13.39 Wh, 최적 환기 제어 알고리즘 적용시 6.22 Wh, 8.6 Wh, 16.66 Wh로 규칙 기반 제어 알고리즘 대비 최소 24%에서 최대 99% 더 많은 에너지를 사용하였다.

제어별 에너지 소비량 그래프인 Fig. 29를 보면 두 피실험자 모두 에너지소비량 차이가 가장 큰 행동은 ‘서기’였다. 얇기와 걷기에서 최적 환기 제어 알고리즘은 1 step 앞선 선제적 제어를 시작하였다. 하지만 서기 행동에서는 2~3 step 앞선 과한 예측을 하며 불필요한 에너지 소비를 야기하였다. 이는 서기 행동에 대한 학습데이터 부족으로 오차가 큰 값을 예측한 것으로 판단되며, 추후 성능 개선을 진행할 예정이다.

Table 25. 규칙 기반 제어 알고리즘 에너지소비량

규칙 기반 제어 알고리즘										
구분		제어 주기별 에너지소비량(Wh)								합계 (Wh)
		1	2	3	4	5	6	7	8	
Case1	얕기	-	-	-	1.08	1.08	1.08	1.08	1.49	5.81
Case2	서기	-	-	-	-	1.08	1.49	1.08	1.08	3.65
Case3	깊기	-	1.49	1.49	2.38	1.49	2.38	2.38	1.49	11.61
합계 (Wh)										21.07
Case4	얕기	-	-	-	-	1.08	1.08	1.08	1.08	4.32
Case5	서기	-	-	-	-	1.08	1.08	1.08	1.08	4.32
Case6	깊기	-	-	1.49	2.38	2.38	2.38	2.38	2.38	13.39
합계 (Wh)										22.03

Table 26. 최적 환기 제어 알고리즘 에너지소비량

최적 환기 제어 알고리즘										
구분		제어 주기별 에너지소비량(Wh)								합계 (Wh)
		1	2	3	4	5	6	7	8	
Case1	얕기	-	-	1.08	2.38	1.49	1.08	1.49	1.49	7.52
Case2	서기	-	1.08	2.38	2.38	1.49	1.49	1.49	1.49	10.31
Case3	깊기	2.38	2.38	2.38	2.38	2.38	2.38	2.38	2.38	19.04
합계 (Wh)										36.87
Case4	얕기	-	-	-	1.08	1.49	1.49	1.08	1.08	6.22
Case5	서기	-	-	1.08	2.38	1.49	1.08	1.08	1.49	8.6
Case6	깊기	-	2.38	2.38	2.38	2.38	2.38	2.38	2.38	16.66
합계 (Wh)										31.48

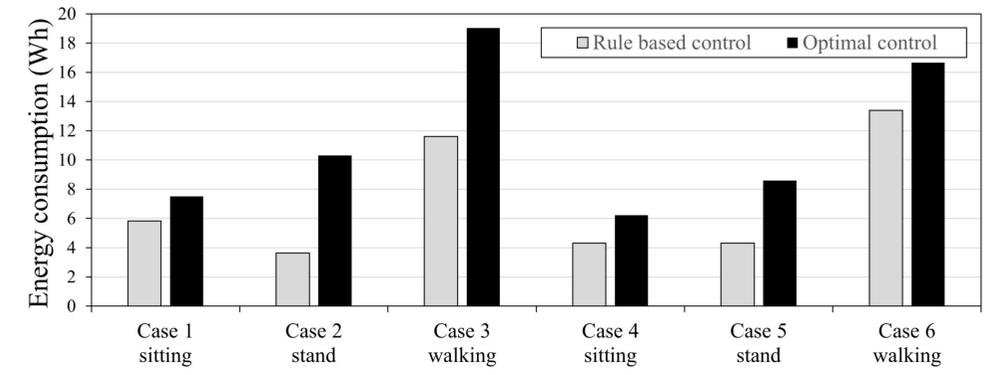


Fig. 29. 제어별 에너지소비량

5.2 컴퓨터 시뮬레이션

(1) 컴퓨터 시뮬레이션 개요

본 연구에서 개발된 최적 환기 제어 알고리즘이 다른 환경에서의 적용 가능성을 확인하기 위해 컴퓨터 시뮬레이션 기반 리빙랩 모델링을 수행하였다. 외부 환경변수 설정, 재실자 스케줄 지정 후 mock-up에 적용한 두 알고리즘을 적용하여 실내 쾌적도 비율 및 에너지 소비량 비교를 실시하였다. 먼저, 실외 CO₂ 농도는 CO₂ Earth에서 제공하는 global January 2024 평균 데이터인 422.16 ppm을 일괄 적용하였다. 실험 기간은 Table 27의 리빙랩 재실자 스케줄을 기준으로 1주일로 설정하였으며 각 요일별로 수업, 회의, 연장 및 재택근무와 같은 재실자 변동 상황을 반영하였다. 재실자 수는 캘리브레이션과 동일한 값을 적용하였다. 실내 CO₂ 쾌적도 비교는 재실 구간인 09시~20시까지로 선정하였다.

Table 27. 리빙랩 재실자 스케줄

[단위 :명]

Time	Day 1	Day 2	Day 3	Day 4	Day 5	Day 6	Day 7
00:00~09:00	0	0	0	0	0	0	0
09:00~10:00	2	2	3	2	2		
10:00~11:00	7	9	7	9	5		
11:00~12:00	7	9	8	9	5		
12:00~13:00	3	1	4	0	0		
13:00~14:00	8	6	8	8	4		
14:00~15:00	9	5	9	9	5		
15:00~16:00	7	5	9	9	6		
16:00~17:00	7	9	9	9	6		
17:00~18:00	7	9	8	8	6		
18:00~19:00	2	2	6	3	0		
19:00~20:00	1	0	5	1	0		
20:00~24:00	0	0	0	0	0		

(2) 전이학습

초기 예측 모델을 다른 환경에 적용하게 되면 개발 당시 적용한 독립변수들의 스케일링 범위를 넘어가는 입력값을 받게 될 수 있으며 입출력 데이터 간의 상관관계가 상이할 수 있다. 이런 경우 정상적인 값을 예측하지 못하거나 예측이 중지될 위험성이 있다(Torrey, Lisa et al, 2010; Hu, Qinghua et al, 2016). 컴퓨터 시뮬레이션을 통한 성능평가를 위해 초기 실내 CO₂ 예측 모델을 기반으로 mock-up 및 시뮬레이션 데이터로 전이학습을 진행하였다.

전이학습을 위한 학습데이터 생성을 위해 시뮬레이션에 3월 5일부터 12일까지의 weather data를 입력하였다. 해당 데이터는 대상 건물에 대한 실측 데이터이며 세부 내용은 4.2장에서 서술한다. 매 요일마다 0~4의 풍량값을 순차적으로 입력하여 총 8번의 시뮬레이션을 진행하였다. 취득된

학습데이터는 총 13,824개로 정규화를 통해 0과 1사이의 숫자로 변환하다. 이후 학습 및 검증을 위해 8:1:1로 분할하였으며 학습을 통해 전이학습을 완료하였다.

(3) 예측 모델 성능 평가

사전 훈련된 초기 예측 모델에 전이학습을 진행하여 개발된 전이학습모델 성능평가를 실시하였다. 해당 모델은 가장 우수한 성능을 보인 LSTM 초기 예측 모델에 시뮬레이션 데이터를 추가 학습시켰다. 전이학습 모델 평가 결과는 Table 28와 같다. MAE는 5.10 ppm, MAPE 1.60%, CvRMSE 2.37%, R^2 0.997로 우수한 정확도를 나타내었다.

Table 28. 전이학습 모델 성능 평가

MAE	MAPE	CvRMSE	R^2
5.10 ppm	1.60%	2.37%	0.997

(4) 예측 정확도 분석

실내 CO₂ 농도의 분포 분석 결과는 Fig. 30과 같다. 대부분의 실측값이 744 ppm에서 960 ppm 사이에 위치하였고, 예측값은 765 ppm에서 970 ppm 사이를 유지하였다. 최대값은 998 ppm을 초과하지 않았으며, 큰 폭의 이상치는 관찰되지 않았다. 예측 정확도의 결과는 Fig. 31 및 Table 29와 같다. Day 1에서 Day 5까지의 MAE는 평균 13.514 ppm을 나타냈고, CvRMSE는 평균 1.92% 였으며, R^2 는 0.9902로 나타나 우수한 예측 정확도를 보였다. 모든 요일에서 재실자 수의 급격한 변화 구간에서 평균 오차율은 2.25%로 확인되었고, 최대 오차율은 실측값 986 ppm 대비 예측값 947 ppm으로 4.11%였다. 이러한 결과는 재실자 수가 0명에서 8명으로 급증한 구간에서 발생한 것으로 이와 같은 급증하는 스케줄 데이터를 추가로

학습시켜 모델의 성능을 개선할 필요가 있음을 시사한다.

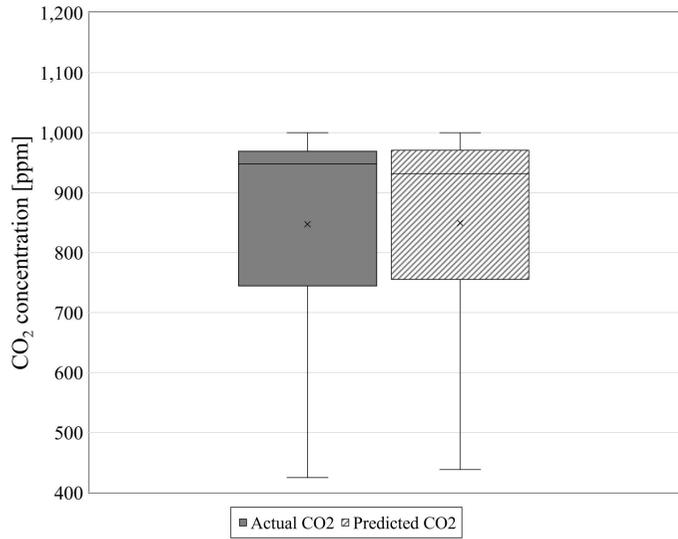


Fig. 30. 시뮬레이션 제어변수 상자 수염 그래프

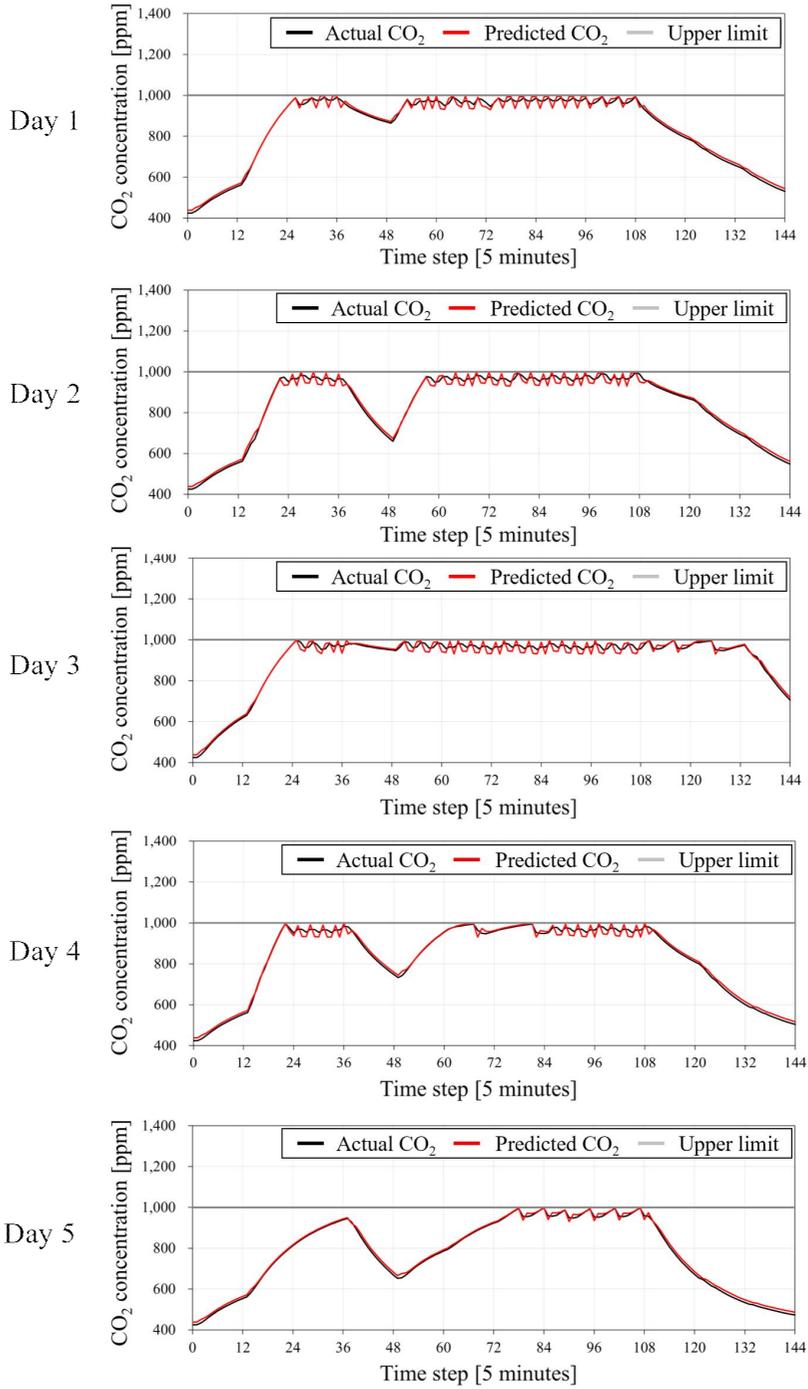


Fig. 31. 요일별 시뮬레이션 결과

Table 29. 요일별 환기 제어 알고리즘 예측 정확도

구분	MAE	CvRMSE	R ²
Day 1	13.69 ppm	1.98%	0.9913
Day 2	13.40 ppm	1.97%	0.9924
Day 3	15.43 ppm	2.11%	0.9816
Day 4	16.71 ppm	2.31%	0.9879
Day 5	8.30 ppm	1.22%	0.9978

(5) 실내 CO₂ 쾌적도 비교

실험 결과는 Fig. 32~36과 같다. 먼저 Day 1인 Fig. 32.(a)에서 59.85%, Day 2 Fig. 33.(a)에서는 65.91%, Day 3 Fig. 34.(a)에서는 42.42%, Day 4 Fig. 35.(a)에서는 47.73%, 그리고 Day 5 Fig. 36.(a)에서는 90.91%를 확인하였다. 유지비율이 가장 낮은 Day 3의 최고 실내 CO₂ 농도는 1,066 ppm이며, 유지비율이 가장 높은 Day 5의 CO₂ 농도는 1,006 ppm으로 기준치와 근접한 수치를 보였다. 최적 환기 제어 알고리즘인 Fig. 32~36.(b)에서는 모든 기간동안 유지비율이 100%를 나타내며 규칙 기반 제어 알고리즘대비 우수한 제어 성능을 확인하였다. 실내 CO₂ 쾌적도 결과와 해당 비교 그래프는 Table 30와 Fig. 37이다. 분석 결과, 규칙 기반 제어 알고리즘을 적용했을 때 다음과 같은 일별 쾌적도 유지비율을 확인할 수 있었다. 이를 통해, 전이학습 모델이 다양한 환경에서의 적용가능성을 확인하였다.

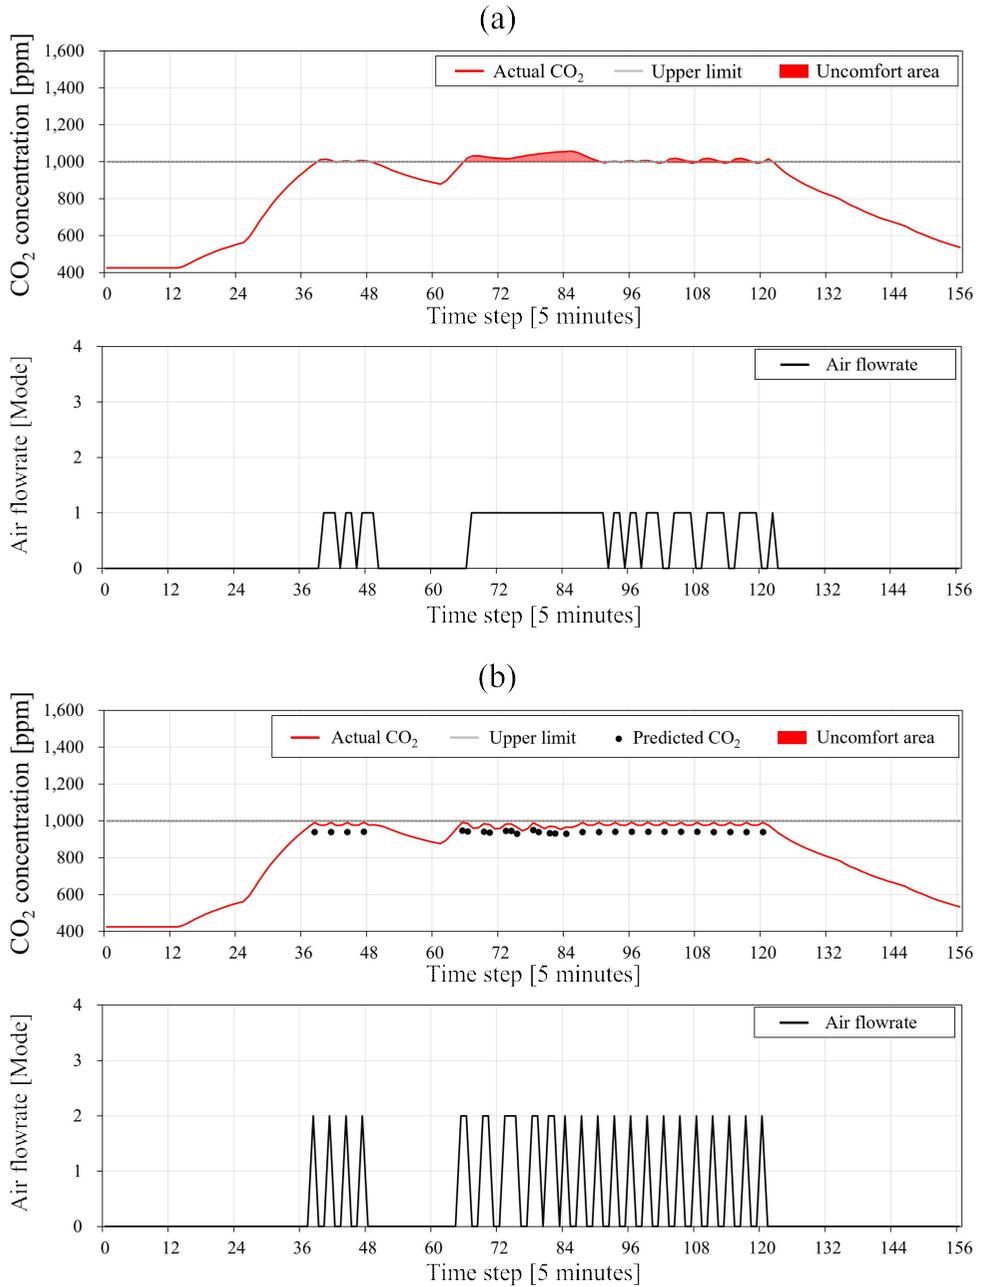


Fig. 32. Day 1 스케줄 제어 알고리즘 별 실험 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

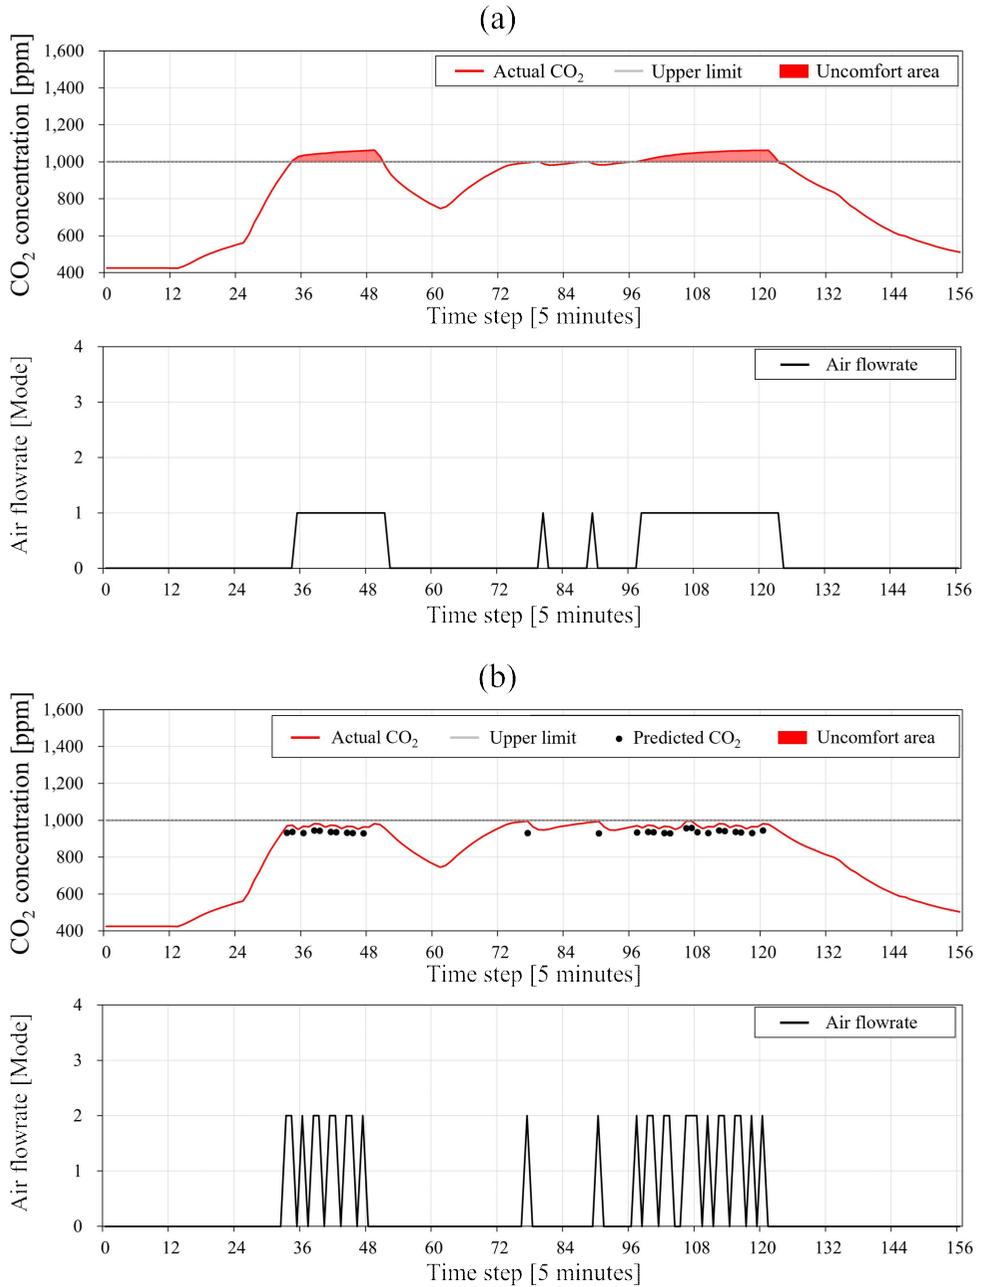


Fig. 33. Day 2 스케줄 제어 알고리즘 별 실험 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

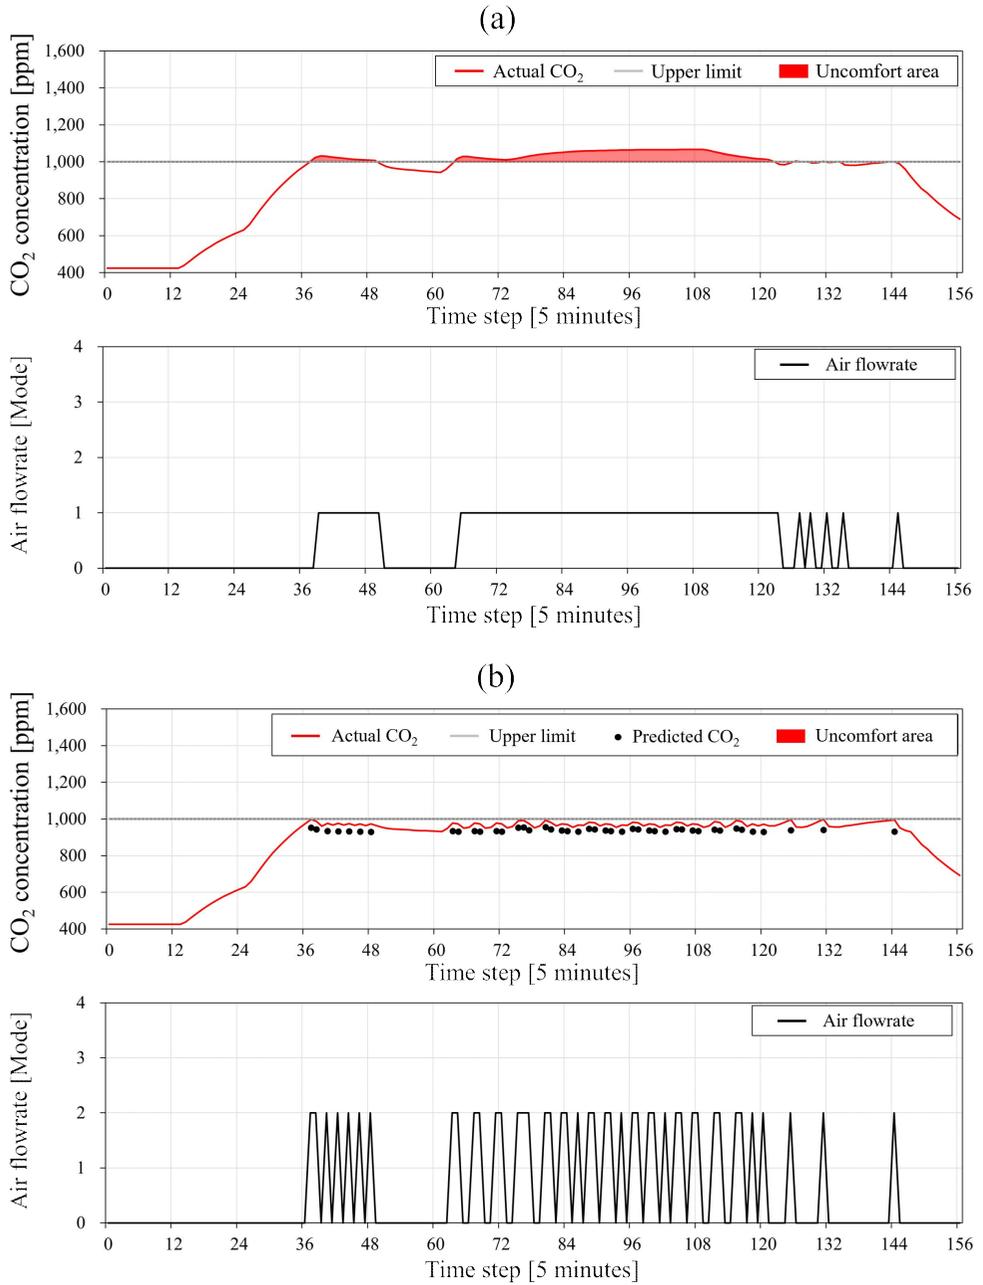


Fig. 34. Day 3 스케줄 제어 알고리즘 별 실험 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

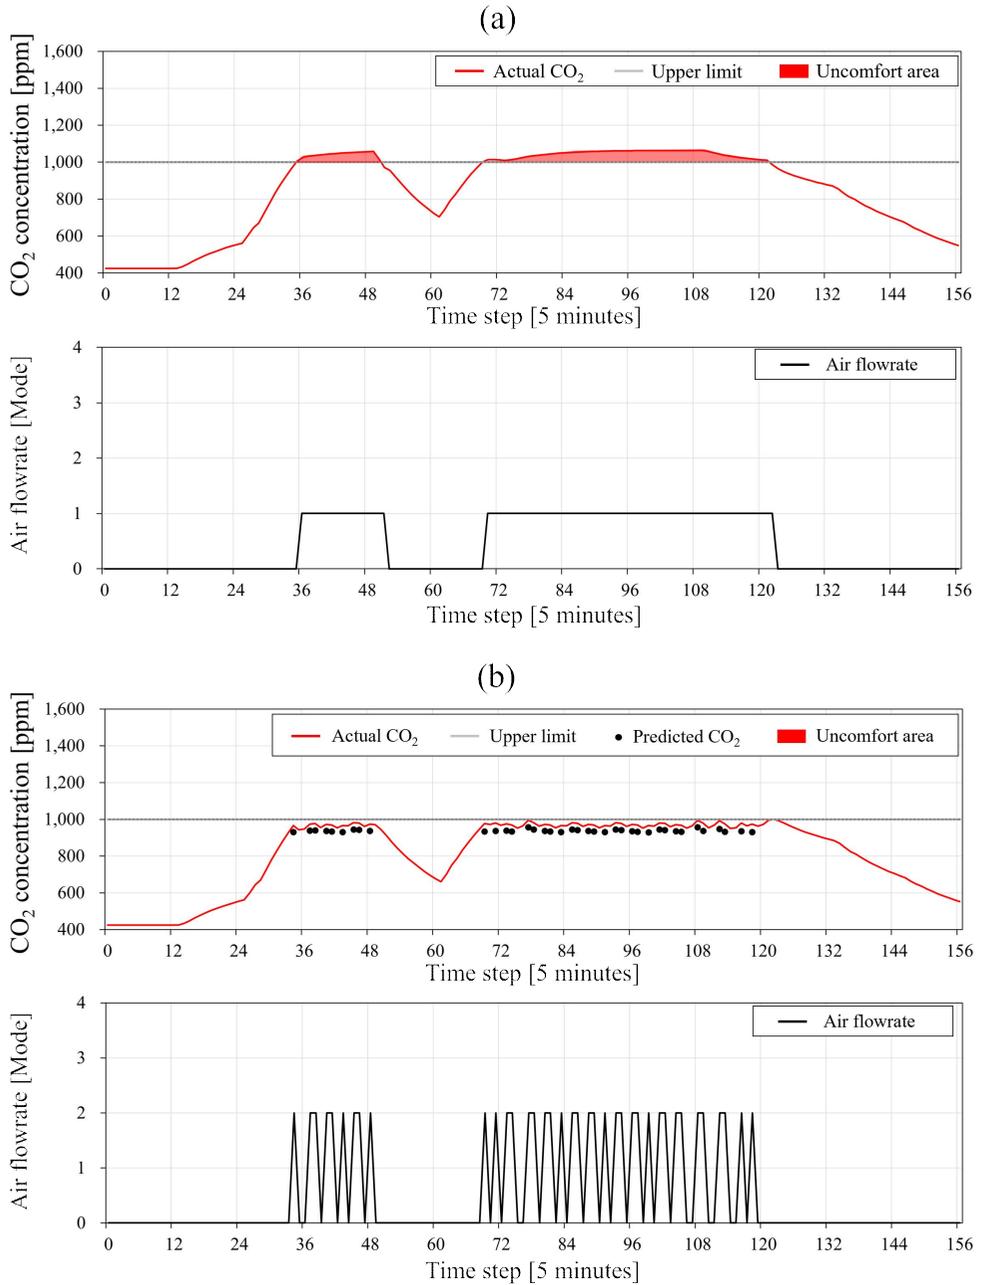


Fig. 35. Day 4 스케줄 제어 알고리즘 별 실험 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

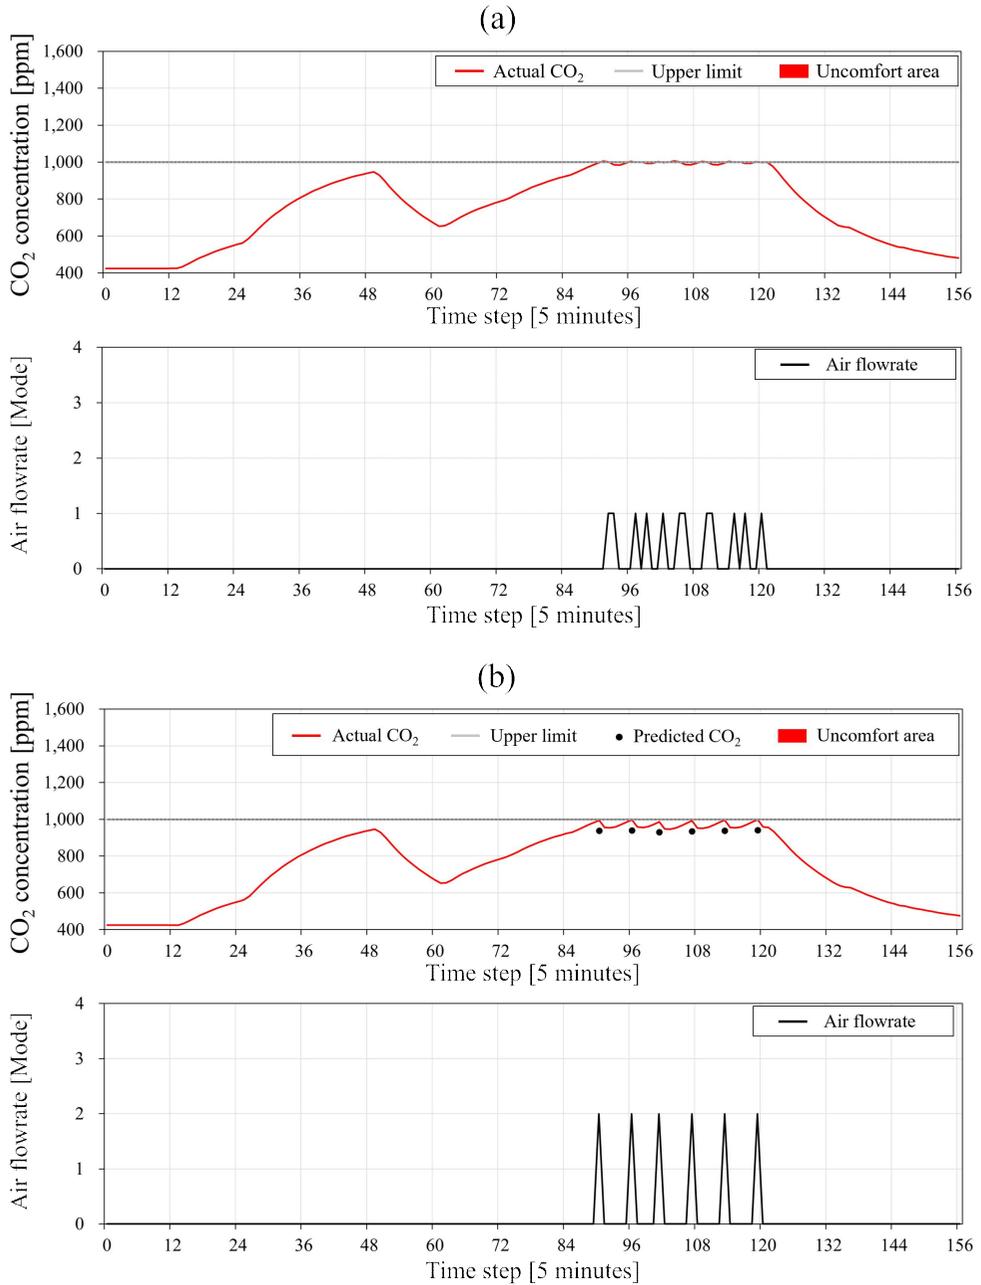


Fig. 36. Day 5 스케줄 제어 알고리즘 별 실험 결과
 (a) - 규칙 기반 제어, (b)- 최적 환기 제어

Table 30. 제어별 실내 실내 쾌적도 비율

구분	Day 1	Day 2	Day 3	Day 4	Day 5
규칙 기반 제어 알고리즘	59.85 %	65.91%	42.42%	47.73%	90.91%
최적 환기 제어 알고리즘	100 %				

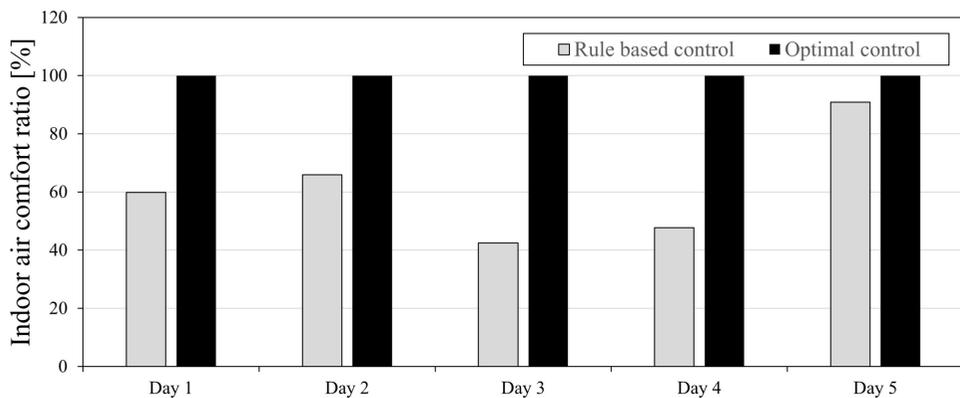


Fig. 37. 시뮬레이션 제어별 실내 공기질 쾌적도

(6) 에너지소비량 분석

Mock-up과 동일하게 팬의 에너지소비량을 구하였으며 풍량별 에너지소비량은 Table 31과 같이 정리하였다. 규칙 기반 제어와 최적 환기 제어 두 알고리즘의 에너지소비량 비교 결과는 Table 32, Fig. 38과 같다. 전체 기간동안 두 알고리즘은 각각 547.93 Wh과 688.65 Wh를 사용하였으며 최적 환기 제어 알고리즘이 25.68% 더 많은 에너지를 사용하였다. 먼저 규칙 기반 제어 알고리즘의 경우 Day 1~5 모두 약풍(mode 2)만 사용하였으며, 에너지소비량은 각각 113.88 Wh, 96.69 Wh, 163.3 Wh, 148.27 Wh, 25.79 Wh의 사용량을 나타냈다. 분석 결과 해당 풍량 적용시 실내 CO₂ 농도를 상승시키지는 않았으나 기준치를 넘어간 실내 CO₂ 농도를 하락시키기에는

부족한 풍량임을 확인하였다.

최적 환기 제어 알고리즘의 풍량은 실험기간동안 중풍(mode 3)만 가동하였다. 에너지소비량은 각각 134.84 Wh, 130.03 Wh, 211.89 Wh, 183 Wh, 28.89 Wh의 에너지 사용량을 보였다, 풍량 선정은 알고리즘의 오차 산출 과정에서 중풍부터 양수가 나와 이를 반영하여 최적 제어를 실시한 것으로 판단되며, 이는 에너지소비량이 규칙 기반 제어 알고리즘대비 최소 12.02%, 최대 34.48% 더 높은 에너지를 사용하는 결과로 이어졌다.

실험 기간중 에너지를 가장 많이 사용한 날은 Table 32에서 Day 3로 규칙 기반 제어 및 최적 환기 제어 알고리즘은 각각 163.3 Wh, 211.89 Wh를 사용하였으며, 가장 적게 사용한 날은 25.79 Wh, 28.89 Wh로 Day 5였다. 이와 같이 요일별로 에너지 소비량 차이가 나는 환경적인 이유는 재실자 수와 재실기간의 차이가 컸다. Day 3의 평균 재실자 수는 6.9명이고, Day 5는 4.3명으로 37% 더 적었으며, 재실 기간은 각각 09~20시, 09~18시였다. 또한, Day 5 12~13시의 재실인원이 0명으로 발생원이 없어서 실내 CO₂ 농도가 침기에 의해 하락하여 600 ppm으로 형성시킨 것도 제어빈도에 영향을 미쳤다.

Table 31. 풍량별 에너지소비량

구분	미풍	약풍	중풍	강풍	터보
소비 전력 (W)	58	76	137	395	519

Table 32. 제어 알고리즘별 에너지소비량

구분	요일별 에너지소비량(Wh)					합계 (Wh)
	Day 1	Day 2	Day 3	Day 4	Day 5	
규칙 기반 제어 알고리즘	113.88	96.69	163.3	148.27	25.79	547.93
최적 환기 제어 알고리즘	134.84	130.03	211.89	183	28.89	688.65

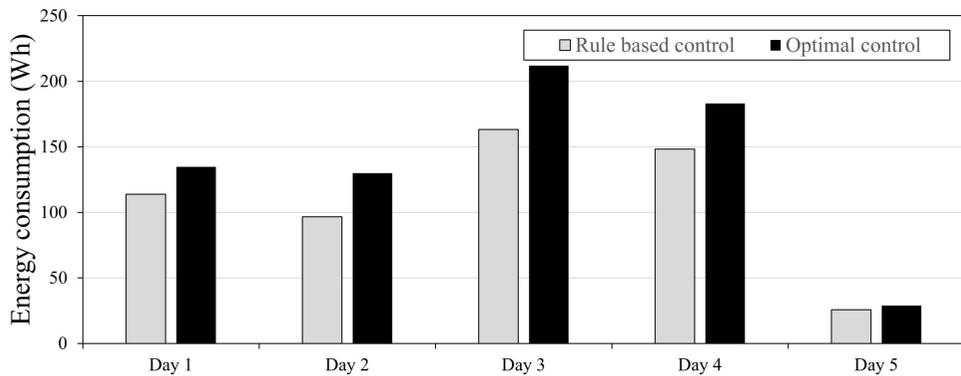


Fig. 38. 제어별 시뮬레이션 에너지소비량

5.3 소결

본 장에서는 제3장에서 개발된 실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘을 mock-up 실험과 컴퓨터 시뮬레이션에 적용하여 성능을 평가하였다. 주요 분석 항목은 예측 모델의 학습 결과와 실시간 예측 정확도, 실내 CO₂ 쾌적도, 에너지 소비량이며, 규칙 기반 제어 알고리즘과 비교하여 최적 환기 제어 알고리즘의 우수성을 입증하고자 하였다.

(1) Mock-up 실험

Mock-up 실험에서는 피실험자의 활동에 따라 총 3가지 케이스로 구분하여 실험을 진행하였다. 각 케이스는 피실험자의 앉기, 서기, 걷기 활동을 포함하며, 실험 결과 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘에 비해 실내 CO₂ 쾌적도가 높음을 확인하였다. 특히, 최적 환기 제어 알고리즘은 앉기와 서기 활동에서 100%의 쾌적도 유지비율을 보였으나, 걷기 활동에서는 환기시스템의 풍량이 부족하여 모든 제어 기간동안 기준치 이하로 유지하지 못했다. 그러나, 평균 CO₂ 농도는 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘보다 낮아 기준치와 더 근접하게 유지됨을 확인하였다. 에너지 소비량 분석 결과, 모든 활동에서 최적 환기 제어 알고리즘이 더 많은 에너지를 사용하였으며, 이러한 부분은 추가적인 데이터 수집과 학습을 통해 성능을 개선할 예정이다.

(2) 컴퓨터 시뮬레이션

컴퓨터 시뮬레이션에서는 다양한 환경에서의 적용 가능성을 확인하기 위해 리빙랩 모델링을 구축하고, 해당 모델링에서 취득된 데이터 기반 전이 학습 모델을 개발하여 다양한 환경에 적용할 수 있도록 하였다. 전이학습은 우수한 예측 정확도를 나타냈으며, 실내 CO₂ 농도의 예측 정확도 분석 결과, 전이학습 모델이 다양한 환경에서도 높은 정확도를 유지함을 확인하였다.

실내 CO₂ 쾌적도 비교 결과, 최적 환기 제어 알고리즘이 모든 기간 동안 100%의 쾌적도 유지비율을 보여 규칙 기반 제어 알고리즘보다 우수한 성능을 입증하였다. 에너지 소비량 분석 결과, 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘보다 약 25.68% 더 많은 에너지를 사용하였으며, 이는 중풍으로만 제어가 이루어졌기 때문인 것으로 판단된다.

결론적으로, 본 연구에서 개발된 실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘은 규칙 기반 제어 알고리즘에 비해 실내 공기질 유지에서 우수한 성능을 보였으나, 에너지 효율성 측면에서는 성능 개선이 필요함을 확인하였다. 특히, 재실자의 MET와 개인변수를 고려한 예측 모델은 다양한 환경에서 높은 예측 정확도를 유지하였으며, 실내 CO₂ 쾌적도를 크게 향상시켰다. 향후 연구에서는 학습 데이터의 다양성을 늘리고, 예측 모델의 성능을 더욱 개선하여 실제 적용 가능한 시스템으로 발전시키는 것이 필요하다.

제 6 장 결 론

6.1 연구 결론

최근 다수의 인원들이 하루 평균 90%를 건물 내부에서 보내며, 이에 따라 실내 공기질 및 재실자 건강에 대한 관심도가 높아지고 있다. 최근 진행된 연구를 살펴보면 인공 신경망 기반 재실자 산출, 실내 공기질 예측 및 HVAC 에너지 소비량 절감의 연구가 활발히 진행되고 있으나, 실시간 재실자 정보를 고려한 실내 공기질 제어에 대한 연구는 미비한 실정이다. 특히, 재실자 정보 기반의 CO₂ 농도 개선 연구는 상대적으로 부족하여, 실내 공기질을 효율적으로 관리하는 데 한계가 있다.

따라서, 본 연구는 실시간 재실자 정보를 반영한 실내 CO₂ 예측 모델과 이를 탑재한 최적 환기 제어 알고리즘의 개발 및 성능 평가를 목적으로 하였다. 예측 모델은 비선형 데이터 학습에 유리한 DNN과 시계열 데이터 학습에 적합한 LSTM 모델을 사용하여 개발하였다. 입력 데이터는 실내 CO₂ 농도, 환기시스템의 풍량(SA, RA), 재실자 수, MET, BMI, 성별로 선정하였으며, 출력 데이터는 5분 후의 실내 CO₂ 농도를 예측하였다.

최적 환기 제어 알고리즘은 다음과 같은 단계로 구성된다. 첫째, DB에서 실시간으로 환경, 재실자, 풍량 데이터를 불러 온다. 둘째, 제어 변수(i)를 0부터 n까지 설정하여 입력 데이터를 생성한다. 셋째, 각 제어 변수에 대한 예측값을 산출하고, 넷째, 예측값과 기준값의 차이를 계산하여 오차 값을 도출한다. 마지막으로, 오차 값 중 양수이면서 0에 가장 가까운 값을 선택하여 해당 풍량으로 환기시스템을 가동시킨다.

예측 모델 및 최적 환기 제어 알고리즘 성능 평가 결과, LSTM 모델이 DNN 모델보다 우수한 예측성능을 보였다. 특히, 최적 환기 제어 알고리즘을 적용한 컴퓨터 시뮬레이션 결과, Day 1에서 MAE 13.69 ppm, CvRMSE 1.98%, R2 0.9913을 나타냈으며, Day 5에서는 MAE 8.30 ppm, CvRMSE 1.22%, R2 0.9978로 나타났다. 이를 통해 예측 모델이 높은 정확도로 실내 CO₂ 농도를 예측할 수 있음을 입증하였다.

Mock-up 실험과 컴퓨터 시뮬레이션을 통해 최적 환기 제어 알고리즘이

규칙 기반 제어 알고리즘에 비해 실내 쾌적도를 더 오래 유지할 수 있음을 증명하였다. 예를 들어, Mock-up 실험에서는 피실험자 B의 경우 모든 활동에서 높은 예측 정확도를 보였으며, 컴퓨터 시뮬레이션에서도 모든 조건에서 100%의 쾌적도를 나타냈다.

반면, 에너지 소비량 분석 결과, 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘 대비 더 많은 에너지를 소비하는 것으로 나타났다. 이는 급격한 CO₂ 농도 변화에 대한 예측 정확도 개선이 필요함을 시사한다.

본 연구는 실시간 재실자 정보를 활용한 CO₂ 예측 모델과 최적 환기 제어 알고리즘의 중요성을 강조하며, 이를 통해 실내 공기질을 효과적으로 개선하고 에너지 효율성을 높일 수 있는 가능성을 제시하였다. 향후 연구에서는 더욱 다양한 환경과 조건에서의 실험을 통해 알고리즘의 정확성과 효율성을 검증하고, 실내 공기질 관리에 있어 보다 정밀한 접근이 가능하도록 발전시켜야 할 것이다.

6.2 기대 효과 및 한계점

본 연구를 통해 개발된 최적 환기 제어 접근 방식은 실내 공기질 관리를 위한 실질적인 방안을 제시하며, 재실자의 편안함과 건강을 향상시키는 데 기여할 것으로 기대된다. 기존 연구들에서 사용이 미비하였던 실시간 재실자 정보인 재실자 수, MET, BMI, 성별을 받아오며 이를 통해 더욱 정확한 예측성능을 보일 것으로 기대된다. 또한, 실내 CO₂ 농도에만 국한되지 않고, 실내 미세먼지(PM₁₀, PM_{2.5}) 농도, PMV 기반 실내 온습도 제어와 같은 여러 분야와 접목시켜 모델의 성능을 발전시킬 수 있는 성장성을 내포하고 있다.

그러나, 본 연구에서 사용된 최적 환기 제어 알고리즘은 아직 초기 단계로, 에너지 소비를 줄이면서도 실내 공기질을 유지하기 위해 더욱 다양한 조건의 데이터 학습이 필요하다. 따라서, 향후 연구에서는 에너지 효율과 실내 공기질의 균형을 잡는 새로운 알고리즘 개발에 초점을 맞추어 환기시스템이 최소의 에너지로 최대의 효과를 낼 수 있는 방안에 대해 연구를 진행 할 예정이다.

추후 연구에서는 에너지 효율과 실내 공기질의 균형을 최적화하기 위해 재실자 정보 기반 다변량 최적화 기법을 개발할 예정이다. 이를 위해 다양한 환경 데이터를 포함하는 데이터 세트를 기반한 기계 학습 알고리즘을 활용하여 연구를 진행할 예정이다. 또한, 장기적인 모니터링을 통해 시스템의 성능을 지속적으로 개선하는 방안을 모색할 예정이다. 이러한 접근은 보다 효과적이고 지속 가능한 실내 환경 관리 솔루션을 제공할 수 있을 것으로 판단된다.

참 고 문 헌

<국내문헌>

1. 김태호, et al. "외기부하와 연동한 환기장치의 제어에 관한 연구." 대한기계학회 춘추학술대회 (2012): 847-852.
2. 김선호, et al. "건강 실내공기질 (IAQ) 유지를 위한 강화학습 기반 환기시스템, 공기 청정기의 최적 통합 제어." 한국생활환경학회지 29.2 (2022): 176-190.
3. 이강희, and 양재혁. "주요 건축자재의 에너지소비와 이산화탄소 배출원단위 산정 연구." 대한건축학회 논문집-계획계 25.6 (2009): 43-50.
4. 이주용, et al. "PM 2.5 구성 성분 입력자료를 이용한 DNN 의 XAI 분석과 PM 2.5 예측 정확도 개선." 한국대기환경학회지 (국문) 39.4 (2023): 411-426.
5. 박용규, (2001). 통계시리즈 : 상관분석과 회귀분석
6. 최영재, et al. "순환 신경망 모델에 따른 재실 인원 예측 모델 개발 및 성능비교." 대한건축학회논문집 38.10 (2022): 231-240.
7. 김지혜, 공동주택의 실내외 미세먼지 환경조건을 고려한 Ventilation과 Filtration 제어 전략, 서울대학교 대학원, 박사학위 논문
8. 이우창, 소규모 공간의 실내공기질 실험 및 이산화탄소 농도 시뮬레이션 기반 겨울철 적정 자연 환기에 관한 연구, 서울과학기술대학교 일반대학원, 석사학위 논문
9. 강동화. "재실자 발생 이산화탄소 가스를 활용한 주거건물의 공기교환율 추정." 대한건축학회 논문집-계획계 29.10 (2013): 293-300.
10. 김기철, 박철수, and 김인한. "실내 환경 정보와 재실자의 반응."

- 대한건축학회 논문집-계획계 29.7 (2013): 229-237.
11. 문진우. (2011). PMV, TS 기준 건물 열 환경 제어법의 성능 및 적용성 분석. 설비공학논문집, 23(6), 430-440.
 12. 최은지, 박보랑, 최영재, 문진우. (2018). 재실자 활동량 산출을 위한 Pose 분류 모델 개발, KIEAE Journal, 18(5), 93-98
 13. 한지훈, 최은지, 문진우, 유용석. (2018). 심층신경망 기반 재실자 이미지 학습을 통한 인체 관절 인식 모델 개발. 한국생활환경학회 추계학술대회 논문집. 47-48
 14. 홍성협, 도성록, 이광호. (2018). 아파트 건물에서 재실자 활동량이 고려된 PMV제어에 따른 연간 국가 차원의 1차 에너지 및 온실가스 감축량 분석, 대한건축학회논문집, 34(10), 37-44.
 15. 최영재, et al. "실내 이산화탄소 농도 예측 기반 적응형 환기 제어 알고리즘 개발." KIEAE Journal 23.2 (2023): 23-29.

<국외문헌>

1. Kirk, Donald E. Optimal control theory: an introduction. Courier Corporation, 2004.
2. Cincinelli, Alessandra, and Tania Martellini. "Indoor air quality and health." International journal of environmental research and public health 14.11 (2017): 1286.
3. Kumar, Prashant, and Boulent Imam. "Footprints of air pollution and changing environment on the sustainability of built infrastructure." Science of the total environment 444 (2013): 85-101.
4. Koivisto, Antti Joonas, et al. "Source specific exposure and risk assessment for indoor aerosols." Science of the total environment 668

- (2019): 13–24.
5. Chenari, Behrang, João Dias Carrilho, and Manuel Gameiro Da Silva. "Towards sustainable, energy-efficient and healthy ventilation strategies in buildings: A review." *Renewable and Sustainable Energy Reviews* 59 (2016): 1426–1447.
 6. Åström, Karl Johan, and Thomas J. McAvoy. "Intelligent control." *Journal of Process control* 2.3 (1992): 115–127.
 7. Wang, Huanqing, Wanjing Sun, and Peter Xiaoping Liu. "Adaptive intelligent control of nonaffine nonlinear time-delay systems with dynamic uncertainties." *IEEE Transactions on Systems, Man, and Cybernetics: Systems* 47.7 (2016): 1474–1485.
 8. del Mar Castilla, María, et al. "A multivariable nonlinear MPC control strategy for thermal comfort and indoor-air quality." *IECON 2013–39th Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2013.
 9. Berouine, Anass, et al. "Towards a real-time predictive management approach of indoor air quality in energy-efficient buildings." *Energies* 13.12 (2020): 3246.
 10. Liang, Wei, et al. "MPC control for improving energy efficiency of a building air handler for multi-zone VAVs." *Building and Environment* 92 (2015): 256–268.
 11. Ganesh, Hari S., et al. "Indoor air quality and energy management in buildings using combined moving horizon estimation and model predictive control." *Journal of Building Engineering* 33 (2021): 101552.
 12. Koedinger, Kenneth R., et al. "New potentials for data-driven intelligent tutoring system development and optimization." *AI Magazine* 34.3 (2013): 27–41.

13. Wang, Zu, et al. "An occupant-centric control strategy for indoor thermal comfort, air quality and energy management." *Energy and Buildings* 285 (2023): 112899.
14. Shaikh, Pervez Hameed, et al. "Intelligent multi-objective control and management for smart energy efficient buildings." *International Journal of Electrical Power & Energy Systems* 74 (2016): 403-409.
15. W. Zhang, Y Wu and J.K. Calautit, "A review on occupancy prediction through machine learning for enhancing energy efficiency air quality and thermal comfort in the built environment", *Renewable and Sustainable Energy Reviews*, vol. 167, pp. 112704, 2022.
16. Esrafilian-Najafabadi, Mohammad, and Fariborz Haghghat. "Occupancy-based HVAC control systems in buildings: A state-of-the-art review." *Building and Environment* 197 (2021): 107810.
17. Choi, Inho, et al. "A Study on Prediction of PM 2.5 Concentration Using DNN." *Journal of Environmental Impact Assessment* 31.2 (2022): 83-94.
18. Xie, Jingjing. "Deep neural network for PM2. 5 pollution forecasting based on manifold learning." 2017 international conference on sensing, diagnostics, prognostics, and control (SDPC). IEEE, 2017.
19. Lin, Ching Kai, and Ching Chi Lin. "Work of breathing and respiratory drive in obesity." *Respirology* 17.3 (2012): 402-411.
20. Persily, Andrew, and Lilian de Jonge. "Carbon dioxide generation rates for building occupants." *Indoor air* 27.5 (2017): 868-879.
21. Li, Yanyan, et al. "A method for estimating occupant carbon dioxide generation rates." *Energy and Buildings* (2024): 114163.
22. Langford, Nigel J. "Carbon dioxide poisoning." *Toxicological reviews* 24 (2005): 229-235.

23. Prentice, Iain Colin, et al. "The carbon cycle and atmospheric carbon dioxide." *Climate change 2001: the scientific basis*, Intergovernmental panel on climate change (2001).
24. Persily, Andrew, and W. Stuart Dols. "The relation of CO₂ concentration to office building ventilation." *Air change rate and airtightness in buildings*. ASTM International, 1990.
25. Persily, Andrew. "Indoor carbon dioxide concentrations in ventilation and indoor air quality standards." (2015).
26. Brelih, Nejc, and Olli Seppänen. "Ventilation rates and IAQ in European standards and national regulations." (2011).
27. Azuma, Kenichi, et al. "Effects of low-level inhalation exposure to carbon dioxide in indoor environments: A short review on human health and psychomotor performance." *Environment international* 121 (2018): 51–56.
28. Zhang, Xiaojing, et al. "Effects of exposure to carbon dioxide and bioeffluents on perceived air quality, self assessed acute health symptoms, and cognitive performance." *Indoor air* 27.1 (2017): 47–64.
29. Rice, Susan A. "Human health risk assessment of CO₂: survivors of acute high-level exposure and populations sensitive to prolonged low-level exposure." *environments* 3.5 (2014): 7–15.
30. Vehviläinen, Tommi, et al. "High indoor CO₂ concentrations in an office environment increases the transcutaneous CO₂ level and sleepiness during cognitive work." *Journal of occupational and environmental hygiene* 13.1 (2016): 19–29.
31. Samet, Jonathan M., Marian C. Marbury, and John D. Spengler. "Health effects and sources of indoor air pollution. Part I." *American review of respiratory Disease* 136.6 (1987): 1486–1508.

32. Myhrvold, A. N., E. Olsen, and O. Lauridsen. "Indoor environment in schools - pupils health and performance in regard to CO₂ concentrations." *Indoor Air* 96.4 (1996): 369-371.
33. Satish, Usha, et al. "Is CO₂ an indoor pollutant? Direct effects of low-to-moderate CO₂ concentrations on human decision-making performance." *Environmental health perspectives* 120.12 (2012): 1671-1677.
34. Ramalho, Olivier, et al. "Association of carbon dioxide with indoor air pollutants and exceedance of health guideline values." *Building and Environment* 93 (2015): 115-124.
35. Yang, Liu, et al. "Carbon dioxide generation rates of different age and gender under various activity levels." *Building and Environment* 186 (2020): 107317.
36. Villi, Giacomo, et al. "Building leakage analysis and infiltration modelling for an Italian multi-family building." *Journal of Building Performance Simulation* 6.2 (2013): 98-118.
37. Mumma, Stanley A., and Brian W. Lee. "Extension of the multiple spaces concept of ASHRAE Standard 62 to include infiltration, exhaust/exfiltration, interzonal transfer, and additional short-circuit paths." *TRANSACTIONS-AMERICAN SOCIETY OF HEATING REFRIGERATING AND AIR CONDITIONING ENGINEERS* 104 (1998): 1232-1244.
38. Kim, Moon Keun, and Joon-Ho Choi. "Can increased outdoor CO₂ concentrations impact on the ventilation and energy in buildings? A case study in Shanghai, China." *Atmospheric environment* 210 (2019): 220-230.
39. ASHRAE62.2 EN15251

40. Wu, Yanwen, et al. "Carbon dioxide generation rates for children and adolescents." *Building and Environment* 237 (2023): 110310.
41. Zhi, Shaodan, et al. "Intelligent controlling of indoor air quality based on remote monitoring platform by considering building environment." 2017 4th International conference on systems and informatics (ICSAI). IEEE, 2017.
42. Jiang, Chaoyang, et al. "Indoor occupancy estimation from carbon dioxide concentration." *Energy and Buildings* 131 (2016): 132-141.
43. Aitkin, M., & Foxall, R. (2003). Statistical modelling of artificial neural networks using the multi-layer perceptron. *Statistics and Computing*, 13, 227-239.
44. Rajesh, S., Geetha, S., Nandhitha, S. P., & Sujitha, M. (2022). Deep learning based short and long term air quality prediction. *NeuroQuantology*, 20(17), 1386-1393.
45. Y. Bengio, A. Courville, and P. Vincent., "Representation Learning: A Review and New Perspectives," *IEEE Trans. PAMI*, special issue Learning Deep Architectures, 2013
46. G. Dahl et al., "Improving DNNs for LVCSR using rectified linear units and dropout," *ICASSP*, 2013.
47. Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9.8 (1997): 1735-1780.
48. Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 25.
49. Liu, Yangdong, et al. "Short-term travel time prediction by deep learning: A comparison of different LSTM-DNN models." 2017 IEEE 20th international conference on intelligent transportation systems

- (ITSC). IEEE, 2017.
50. Liu, Song, et al. "Comprehensive system based on a DNN and LSTM for predicting sinter composition." *Applied Soft Computing* 95 (2020): 106574.
 51. Jo, Sung-Jae, et al. "A Comparative Study on the Performance of Air Quality Prediction Model Based on DNN and LSTM." *Proceedings of the Korea Information Processing Society Conference*. Korea Information Processing Society, 2020.
 52. Veena, S. "Air Quality Monitoring and Predicting the People to be Affected using LSTM for Hospitals." *Turkish Journal of Computer and Mathematics Education (TURCOMAT)* 12.10 (2021): 4382-4390.
 53. Ramachandraarjunan, Senthilkumar, Venkatakrisnan Perumalsamy, and Balaji Narayanan. "IoT based artificial intelligence indoor air quality monitoring system using enabled RNN algorithm techniques." *Journal of Intelligent & Fuzzy Systems* 43.3 (2022): 2853-2868.
 54. Torrey, Lisa, and Jude Shavlik. "Transfer learning." *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*. IGI global, 2010. 242-264.
 55. Hu, Qinghua, Rujia Zhang, and Yucan Zhou. "Transfer learning for short-term wind speed prediction with deep neural networks." *Renewable Energy* 85 (2016): 83-95.
 56. Du, Mengnan, et al. "Towards explanation of dnn-based prediction with guided feature inversion." *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2018.
 57. Wang, Jingyang, et al. "Air quality prediction using CT-LSTM." *Neural Computing and Applications* 33 (2021): 4779-4792.

58. Klami, Arto, Seppo Virtanen, and Samuel Kaski. "Bayesian Canonical correlation analysis." *Journal of Machine Learning Research* 14.4 (2013).
59. Bergstra, James, and Yoshua Bengio. "Random search for hyper-parameter optimization." *Journal of machine learning research* 13.2 (2012).
60. Snoek, Jasper, Hugo Larochelle, and Ryan P. Adams. "Practical bayesian optimization of machine learning algorithms." *Advances in neural information processing systems* 25 (2012).
61. Mirshekarian, Sadegh, and Dusan Sormaz. "Machine learning approaches to learning heuristics for combinatorial optimization problems." *Procedia Manufacturing* 17 (2018): 102-109.
62. Klein, Aaron, et al. "Fast bayesian optimization of machine learning hyperparameters on large datasets." *Artificial intelligence and statistics*. PMLR, 2017.
63. Aitkin, M., & Foxall, R. (2003). *Statistical modelling of artificial neural networks using the multi-layer perceptron*. *Statistics and Computing*,
64. Marques, Gonalo, Cristina Roque Ferreira, and Rui Pitarma. "Indoor air quality assessment using a CO2 monitoring system based on internet of things." *Journal of medical systems* 43.3 (2019): 67.
65. Paleologos, Katrina E., Mohamed YE Selim, and Abdel-Mohsen O. Mohamed. "Indoor air quality: pollutants, health effects, and regulations." *Pollution assessment for sustainable practices in applied sciences and engineering*. Butterworth-Heinemann, 2021. 405-489.
66. Skön, J., et al. "Modelling indoor air carbon dioxide (CO2) concentration using neural network." *methods* 14.15 (2012): 16.
67. Putra, Jouvan Chandra Pratama, Safrilah Safrilah, and Mohammad

- Ihsan. "The prediction of indoor air quality in office room using artificial neural network." AIP Conference Proceedings. Vol. 1977. No. 1. AIP Publishing, 2018.
68. Zhu, Yingbo, et al. "LSTM-based IoT-enabled CO₂ steady-state forecasting for indoor air quality monitoring." *Electronics* 12.1 (2022): 107.
69. Freedson, Patty S., et al. "Evaluation of artificial neural network algorithms for predicting METs and activity type from accelerometer data: validation on an independent sample." *Journal of Applied Physiology* 111.6 (2011): 1804-1812.
70. Han, Jie, Han Lin, and Zhenkai Qin. "Prediction and Comparison of In-Vehicle CO₂ Concentration Based on ARIMA and LSTM Models." *Applied Sciences* 13.19 (2023): 10858.
71. O'Brien, William, 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.
72. Hong, Seong-Hyeop, et al. "Variations of PMV based thermal comfort and cooling/heating load according to MET." *KIEAE journal* 17.6 (2017): 39-44.
73. Turley, Christina, et al. "Development and evaluation of occupancy-aware HVAC control for residential building energy efficiency and occupant comfort." *Energies* 13.20 (2020): 5396.
74. Zhang, Sheng, Zhengtao Ai, and Zhang Lin. "Novel demand-controlled optimization of constant-air-volume mechanical ventilation for indoor air quality, durability and energy saving." *Applied Energy* 293 (2021): 116954.
75. Pang, Zhihong, et al. "Nationwide energy saving potential evaluation

- for office buildings with occupant-based building controls." *ASHRAE Transactions* 126 (2020): 273-281.
76. Wang, Junqi, et al. "Occupant-density-detection based energy efficient ventilation system: Prevention of infection transmission." *Energy and Buildings* 240 (2021): 110883.
77. Jetté, Maurice, Ken Sidney, and G. Blümchen. "Metabolic equivalents (METs) in exercise testing, exercise prescription, and evaluation of functional capacity." *Clinical cardiology* 13.8 (1990): 555-565.
78. Dominelli, Paolo B., and Yannick Molgat-Seon. "Sex, gender and the pulmonary physiology of exercise." *European Respiratory Review* 31.163 (2022).
79. Peralta, Gabriela P., et al. "Body mass index and weight change are associated with adult lung function trajectories: the prospective ECRHS study." *Thorax* 75.4 (2020): 313-320.
80. Harms, Craig A., and Sara Rosenkranz. "Sex differences in pulmonary function during exercise." *Medicine and science in sports and exercise* 40.4 (2008): 664-668.
81. ISO 8996: Ergonomics of the thermal environment - Determination of metabolic rate
82. Siddiqui, Hera, et al. "AI-based bmi inference from facial images: An application to weight monitoring." 2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA). IEEE, 2020.
83. Jiang, Min, Yuanyuan Shang, and Guodong Guo. "On visual BMI analysis from facial images." *Image and Vision Computing* 89 (2019): 183-196.
84. Pantanowitz, Adam, et al. "Estimation of body mass index from

- photographs using deep convolutional neural networks." *Informatics in Medicine Unlocked* 26 (2021): 100727.
85. Jiang, Min, and Guodong Guo. "Body weight analysis from human body images." *IEEE Transactions on Information Forensics and Security* 14.10 (2019): 2676–2688.
 86. Antipov, Grigory, Sid-Ahmed Berrani, and Jean-Luc Dugelay. "Minimalistic CNN-based ensemble model for gender prediction from face images." *Pattern recognition letters* 70 (2016): 59–65.
 87. Nada, AM Abu, et al. "Age and gender prediction and validation through single user images using CNN." *Int. J. Acad. Eng. Res.(IJAER)* 4 (2020): 21–24.
 88. Achten, Juul, and Asker E. Jeukendrup. "Heart rate monitoring: applications and limitations." *Sports medicine* 33 (2003): 517–538.
 89. Zhai, Yongchao, et al. "Indirect calorimetry on the metabolic rate of sitting, standing and walking office activities." *Building and Environment* 145 (2018): 77–84.
 90. Gauthier, Stephanie, and David Shipworth. "Predictive thermal comfort model: Are current field studies measuring the most influential variables?." (2012): 1–14.
 91. Lee, Miyoung, et al. "Estimating MET values using the ratio of HR for persons with paraplegia." *Medicine and science in sports and exercise* 42.5 (2010): 985–990.
 92. Silva, Henrique Santos da, et al. "Relationship between heart rate, oxygen consumption, and energy expenditure in futsal." *Frontiers in Psychology* 12 (2021): 698622.
 93. Nakanishi, Motofumi, et al. "Estimating metabolic equivalents for activities in daily life using acceleration and heart rate in wearable

- devices." *Biomedical engineering online* 17 (2018): 1–18.
94. Caballero, Yuko, et al. "Simple prediction of metabolic equivalents of daily activities using heart rate monitor without calibration of individuals." *International journal of environmental research and public health* 17.1 (2020): 216.
95. Hübner, T., et al. "Comparative evaluation of physical activity parameters based on wrist-wearable devices." (2018): 75–78.
96. Ji, Wenjie, et al. "A new method to study human metabolic rate changes and thermal comfort in physical exercise by CO₂ measurement in an airtight chamber." *Energy and Buildings* 177 (2018): 402–412.
97. Park, Bo Rang, et al. "Accuracy analysis of DNN-based pose-categorization model and activity-decision algorithm." *Energies* 13.4 (2020): 839.
98. Shu, Zihuan, Peng Wang, and Wei Zhan. "The research and implementation of human posture recognition algorithm via OpenPose." 2020 2nd International Conference on Artificial Intelligence and Advanced Manufacture (AIAM). IEEE, 2020.
99. Lü, Xiaoshu, et al. "A new method for controlling CO₂ in buildings with unscheduled opening hours." *Energy and Buildings* 59 (2013): 161–170.
100. Ke, Yu-Pei, and Stanley A. Mumma. "Using carbon dioxide measurements to determine occupancy for ventilation controls." (1997).
101. Takahashi, Norio, Takaya Yamada, and Daisuke Miyagi. "Examination of optimal design of IPM motor using ON/OFF method." *IEEE Transactions on Magnetics* 46.8 (2010): 3149–3152.
102. Metelskiy, Konstantin. "Demand Controlled Ventilation Systems: CO₂

- Controlled Ventilation Systems." (2011).
103. Cai, Hui, et al. "Research on a hierarchical air balancing control method of variable air volume ventilation system." *Building and Environment* 175 (2020): 106710.
 104. Merema, Bart, et al. "Demand controlled ventilation (DCV) in school and office buildings: Lessons learnt from case studies." *Energy and Buildings* 172 (2018): 349–360.
 105. Lu, Tao, Xiaoshu Lü, and Martti Viljanen. "A novel and dynamic demand-controlled ventilation strategy for CO₂ control and energy saving in buildings." *Energy and buildings* 43.9 (2011): 2499–2508.
 106. Pistochini, Theresa, et al. "Method of test for CO₂-based demand control ventilation systems: Benchmarking the state-of-the-art and the undervalued potential of proportional-integral control." *Energy and Buildings* 301 (2023): 113717.
 107. Okochi, Godwine Swere, and Ye Yao. "A review of recent developments and technological advancements of variable-air-volume (VAV) air-conditioning systems." *Renewable and Sustainable Energy Reviews* 59 (2016): 784–817.
 108. Afram, Abdul, and Farrokh Janabi-Sharifi. "Theory and applications of HVAC control systems - A review of model predictive control (MPC)." *Building and Environment* 72 (2014): 343–355.

국 문 초 록

재실자 정보 기반 최적 환기 제어 알고리즘 개발 및 성능 평가

배 강 우

건축학과 건축환경계획전공

중앙대학교 대학원

현대 사회에서 사람들은 대부분의 시간을 실내에서 보내며, 이에 따라 실내 공기질 관리의 중요성이 강조되고 있다. 실내 공기질 저하의 주요 원인으로서는 CO₂ 축적, 휘발성 유기 화합물 및 화학물질, 외부 미세먼지 유입 등이 있으며, 이는 건강에 부정적인 영향을 미칠 수 있다. 이를 해결하기 위해 자연 환기 및 기계 환기시스템이 사용되고 있으며, 최근에는 IoT 기반 공기질 모니터링 시스템, 스마트 환기시스템, AI를 활용한 공기질 예측 및 제어 기술이 도입되고 있다. 선행 연구 분석 결과, 대부분의 OCC는 열환경 및 에너지 분야에 집중되어 있으며, 환기 분야에서는 재실자의 유무 및 재실자 수 데이터만 활용되고 있다. 그러나 실내 CO₂ 배출량은 재실자의 성별, BMI, 활동량 등에 따라 달라지기 때문에 보다 정확한 제어를 위해서는 다양한 재실자 정보를 반영하는 것이 필수적이다.

따라서, 본 연구에서는 최근 개발되고 있는 AI 기반의 재실자 활동량 산출

모델뿐만 아니라 성별, BMI 정보를 반영한 최적 환기 제어 알고리즘을 개발하는 것이다.

실내 CO₂ 농도 예측을 위해 DNN과 LSTM 모델을 선정하고, mock-up 예비 실험을 통해 수집된 데이터를 바탕으로 모델을 학습시켰다. 예측 정확도 비교 결과 두 모델 중 성능이 우수한 LSTM 모델을 선정하였다. 학습된 모델은 다양한 환경에 적용할 수 있도록 전이학습을 진행하였다. 최적 환기 제어 알고리즘은 실시간 데이터를 기반으로 최적의 환기량을 산출하여 실내 CO₂ 농도를 유지하도록 설계되었다. 이 알고리즘은 재실자의 MET, BMI, 성별을 반영하여 환기시스템 풍량 선정을 위한 실내 CO₂ 농도 예측 정확도를 높히는데 중점을 두었다.

실내 CO₂ 농도 예측 모델과 최적 환기 제어 알고리즘 적용을 위해 mock-up과 컴퓨터 시뮬레이션 기반의 모델링을 수행하였다. mock-up에서 예비 실험을 통해 맞춤 제작된 환기시스템과 IoT 기반 환경센서, 영상센서로부터 시스템 제어 및 환경 변수 취득을 진행하였다. 컴퓨터 시뮬레이션은 Design Builder와 EnergyPlus를 사용하여 모델링 하였으며, 리빙랩에서 2주간 진행된 풍량 제어실험 데이터를 바탕으로 캘리브레이션을 수행하였다.

최적 환기 제어 알고리즘은 규칙 기반 제어 알고리즘과 비교하였다. 실시간 예측성능 평가 결과 mock-up은 평균 MAE 44.09 ppm, CvRMSE 5.83%, R² 0.5685으로 나타났으며, 시뮬레이션은 MAE, MAPE, CvRMSE, R² 각각 13.51 ppm, 1.92%, 0.9902으로 나타났다. 다음 실내 CO₂ 쾌적도는 mock-up에서 환기시스템 풍량 부족으로 걷기 행동에서 피실험자별 각각 24.69%, 36.65%의 유지비율을 보였으며, 나머지 행동에서 100%를 유지하였다. 또한, 시뮬레이션에서는 전체 실험 기간동안 100% 실내 CO₂ 쾌적도를 확인하였다. 이를 통해 mock-up, 시뮬레이션 모두 최적 환기 제어 알고리즘이 규칙 기반 제어 알고리즘보다 우수함을 확인하였다. 다만, 에너지 절감은 규칙 기반 제어 알고리즘이 mock-up에서 피실험자 A는 42.85%, 피실험자 B는 30.02%

더 낮은 수치를 나타냈고, 시뮬레이션은 20.42% 더 낮은 수치를 나타냈다. 이와 같은 결과는 규칙 제어 알고리즘이 최적 환기 제어 알고리즘 대비 에너지 절감 성능이 더 우수함을 의미한다. 향후 연구에서는 다양한 학습데이터를 학습하여 예측 모델의 성능을 더욱 개선 예정이며, 이를 통해 실제 적용가능한 시스템으로 발전시키는 것이 목표이다.

본 연구를 통해 개발된 최적 환기 제어는 실내 공기질 관리를 위한 실질적인 해결 방안을 제시하며, 재실자의 쾌적함 및 건강 향상에 기여할 것으로 기대된다. 특히 실시간 재실자 정보를 활용함으로써 더욱 세밀한 예측성능을 보일 것으로 예상된다. 또한, 이 접근 방식은 실내 CO₂ 농도뿐만 아니라 실내 미세먼지 농도, PMV 기반 실내 온습도 제어 등 다양한 분야와의 접목을 통해 성능을 발전시킬 연구를 진행할 예정이다.

핵심어 : 실내 공기질, 최적 환기 제어, 재실자 정보, 인공 신경망, 지능형 제어

ABSTRACT

Development and performance evaluation of an optimal ventilation control algorithm based on an occupant information

Bae, Kang Woo

Major in Environmental Design in Architecture
Department of Architecture and Building Science
The Graduate School of Chung-Ang University

In modern society, people spend most of their time indoors, emphasizing the importance of IAQ management. The primary causes of IAQ deterioration include CO₂ accumulation, VOCs, chemical pollutants, and the infiltration of outdoor fine particulate matter, all of which can negatively impact health. To address these issues, natural and mechanical ventilation systems are used, and recently, IoT-based air quality monitoring systems, smart ventilation systems, and AI-driven air quality prediction and control technologies have been introduced.

A review of previous studies indicates that most OCC research has focused on thermal environment and energy sectors, with ventilation studies primarily utilizing occupancy presence and occupant count data. However, indoor CO₂ generation varies based on occupants gender, BMI,

and activity levels, making it essential to incorporate diverse occupant information for more accurate control.

Therefore, this study aims to develop an optimal ventilation control algorithm that integrates recent AI-based occupant activity models and factors such as gender and BMI. For predicting indoor CO₂ concentration, DNN and LSTM models were selected and trained using data collected from preliminary mock-up experiments. The LSTM model, demonstrating superior performance, was chosen for further development. The trained model was subjected to transfer learning to enhance its applicability to various environments. The optimal ventilation control algorithm was designed to maintain indoor CO₂ concentration by calculating the optimal ventilation rate based on real-time data. This algorithm emphasizes improving the prediction accuracy of indoor CO₂ concentration by incorporating occupants MET, BMI, and gender information for ventilation system airflow selection.

To implement the indoor CO₂ concentration prediction model and the optimal ventilation control algorithm, modeling was performed using both mock-up and computer simulations. In the mock-up experiments, customized ventilation systems and IoT-based environmental and video sensors were used to acquire system control and environmental variables. The computer simulations were conducted using Design Builder and EnergyPlus, calibrated with airflow control experiment data collected over two weeks in a living lab setting.

The optimal ventilation control algorithm was compared with a rule-based control algorithm. Real-time prediction performance evaluation showed that the mock-up achieved an average MAE of 44.09 ppm, CvRMSE of 5.83%, and R² of 0.5685. The simulation results showed MAE,

CvRMSE, and R^2 values of 13.51 ppm, 1.92%, and 0.9902, respectively. In terms of indoor comfort maintenance, the mock-up showed a comfort maintenance ratio of 24.69% and 36.65% during walking activities due to insufficient ventilation airflow, while maintaining 100% in other activities. The simulation confirmed a 100% indoor comfort maintenance ratio throughout the entire experiment period. These results indicate that the optimal ventilation control algorithm outperforms the rule-based control algorithm in both mock-up and simulation settings. However, energy savings performance was lower with the optimal control algorithm, showing 42.85% and 30.02% lower values for subjects A and B in the mock-up, and 20.42% lower in the simulation compared to the rule-based control algorithm. This suggests that the rule-based control algorithm is more efficient in terms of energy savings compared to the optimal ventilation control algorithm.

Future research aims to enhance the prediction model's performance by incorporating a broader range of training data, ultimately developing a practically applicable system. The optimal ventilation control developed through this study provides a practical solution for IAQ management and is expected to improve occupant comfort and health. By utilizing real-time occupant information, more precise prediction performance can be achieved. Additionally, future research will explore integrating this approach with other fields, such as indoor fine particulate matter concentration and PMV-based indoor temperature and humidity control, to further advance performance.

Keyword : Indoor air quality, Optimal ventilation control, Occupant information, Artificial neural network, Intelligent control