



실내 환경 예측 모델의 파인튜닝을 통한 대상지별 적응 기간 비교

Comparison of Adaptation Periods by Sites through Fine-Tuning of Indoor Environment Prediction Models

배강우* · 윤지영** · 성재호*** · 문진우****

Kang Woo Bae* · Ji Young Yun** · Jae Ho Sung*** · Jin Woo Moon****

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

** Coauthor, Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (yjyjjy5350@naver.com)

*** Coauthor, Graduate Student, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (imsjh992@gmail.com)

**** Corresponding author, Professor, Dept. of Architecture Building Science, Chung-Ang Univ., South Korea (gilbert73@cau.ac.kr)

ABSTRACT

Purpose: This study aimed to quantify how quickly indoor environmental prediction models adapt when transferred between different buildings using fine-tuning-based transfer learning. By focusing on temperature, CO₂, and PM_{2.5} prediction, the study examines both the initial performance degradation caused by domain shift and the subsequent recovery process, in order to identify a practical adaptation period for reliable model deployment. **Method:** DNN models trained on long-term data from an office building (Site A) were transferred to two large commercial buildings (Sites B and C). For each target site, daily fine-tuning was performed for 7 days using sliding-window datasets from the previous week, and day-by-day MAE, CvRMSE, and R² were evaluated. **Result:** n Site B, temperature and CO₂ models showed severe errors in the first 1~2 days (CvRMSE up to 91.51% and 60.78%) but converged to stable levels after about 3~5 days of fine-tuning, whereas PM_{2.5} remained more variable (CvRMSE about 9~28%). The results indicate that several days of fine-tuning are required for reliable model transfer between buildings, and that PM_{2.5} prediction in particular needs longer training and further model refinement.

KEYWORD

실내 환경 예측모델
파인튜닝
전이학습

Indoor Environmental Prediction Model
Fine-Tuning
Transfer Learning

ACCEPTANCE INFO

Received Nov. 17, 2025

Final revision received Dec. 2, 2025

Accepted Dec. 5, 2025

© 2025. KIEAE all rights reserved.

1. 서론

1.1. 연구의 배경

최근 공동주택, 업무시설 등 건축물에서 실내 공기질과 열환경에 대한 관심이 확대되면서, 실내 CO₂ 농도와 미세먼지(PM_{2.5}) 농도, 온도 등 실내 환경지표를 정량적으로 관리하기 위한 연구가 활발히 진행되고 있다[1]. 실내 환경은 재실자 활동, 외기 조건, 설비 운전 상태가 복합적으로 작용하는 비선형 시스템으로, 단순히 경험을 통한 제어나 규칙 기반 제어만으로는 목표 수준의 쾌적성과 에너지 성능을 동시에 만족시키는 데 한계가 있다[2]. 이에 따라, 센서 데이터와 설비 운전 데이터를 활용하여 실내 환경 변화를 사전에 예측하고, 이를 기반으로 환기 및 공조 설비를 능동적으로 제어하려는 인공지능 기반 예측-제어 기법의 필요성이 대두되고 있다.

지금까지 건축 및 환경 분야에서는 인공지능영향을 포함한 다양한 데이터 기반 예측모델이 제안되어 왔으며, 특정 건물이나 실험대상에서 온도, CO₂, PM_{2.5} 등의 변화를 비교적 높은 정확도로 예측할 수 있음이 보고된 바 있다[3]. 그러나 이러한 모델은 대개 단일 대상지의 데이터를 이용하여 학습되기 때문에, 물리적 구조, 환기-공조 시스템 구성, 재실 패턴이 상이한 다른 건물에 그대로 적용할 경우

예측 성능이 저하되는 문제가 발생한다. 즉, 한 건물에서 학습된 모델을 다른 건물에 적용할 때 도메인 이동에 의해 초기 예측 오차가 크게 증가하며, 이를 보정하기 위한 추가 학습 과정이 필수적이라는 점이 반복적으로 지적되고 있다.

이러한 문제를 개선하기 위한 접근으로, 한 대상지에서 사전 학습한 인공지능 모델을 다른 대상지의 데이터로 미세 조정하는 파인튜닝(fine-tuning) 기반 전이학습 기법이 주목받고 있다. 파인튜닝은 공통적인 패턴을 포착한 기본 모델의 가중치를 활용함으로써, 새로운 대상지에서 상대적으로 적은 양의 데이터로도 예측 성능을 빠르게 개선할 수 있다는 장점이 있다[4]. 그럼에도 불구하고, 파인튜닝이 새로운 대상지에서 얼마나 효율적으로 성능을 회복-개선하는지를 설명하는 근거는 아직 충분히 축적되지 않았다. 기존 연구는 전후 성능을 요약 지표로 제시하는 데 집중하는 경향이 있으며[5], 대상지 특성에 따른 적용 전략과 검증 체계를 정립할 필요가 있다. 따라서 파인튜닝 기반 실내 환경 예측 모델의 대상지별 일반화 특성과 성능 안정화 특성을 체계적으로 규명하는 연구가 요구된다.

1.2. 선행연구 고찰

건축-환경 분야에서는 건물 간 물리적 특성과 운전 패턴이 상이하다는 점을 고려하여, 한 건물에서 학습한 모델을 다른 건물에 효율적으로 이식하기 위한 전이학습 및 파인튜닝 기법이 꾸준히 제안되고

있다. Pinto et al. (2022)[6]는 스마트빌딩 분야 전이학습 연구를 종합적으로 분석한 결과, 건물 열동특성 예측에서 전이학습이 전통적인 개별 학습 모델보다 RMSE 수치를 유의하게 낮추며, 특히 타깃 건물 데이터가 제한적인 경우 파라미터 일부만을 파인튜닝하는 전략이 전체 재학습보다 안정적인 성능을 보인다고 보고하고 있다. Li et al. (2024)[7]은 대규모 주거용 스마트 온도조절기 데이터를 활용해 CNN-LSTM 기반 실내온도 예측 모델을 구축하고, 한 건물에서 학습한 모델을 다른 건물에 전이하는 딥 전이학습 프레임워크를 제안하였다. 이들은 LSTM 계층을 고정된 채 나머지 계층만 파인튜닝할 경우, 동일 데이터 양에서 학습한 기준 모델 대비 평균 RMSE 가 약 10% 감소하는 성능 향상을 확인하였다.

실내 환경의 공간적 비균일성을 고려한 연구에서도 프리트레이닝과 파인튜닝을 결합한 시도가 이루어지고 있다. Jing et al. (2023)[8]은 비균일 실내 온도를 빠르게 예측하기 위해, 먼저 수치해석 또는 고해상도 시뮬레이션 결과를 활용하여 신경망 모델을 사전 학습한 후, 실제 대상 공간에서 취득한 제한된 센서 데이터를 이용하여 모델 일부를 파인튜닝하는 방법을 제안하였다. 이를 통해 전 공간에 대한 CFD 해석을 반복 수행하지 않고도, 소량의 관측 정보를 바탕으로 실내 온도 분포를 고속·고정밀로 예측할 수 있음을 보였다. Zhang et al. (2024)[9]은 다수의 건물 데이터셋을 대상으로, 타깃 건물에 전이할 소스 도메인을 어떻게 선택하는지가 단기 냉방부하 예측 성능에 미치는 영향을 분석하고, 유사성 지표를 기반으로 소스 도메인을 선별하는 방안을 제안하였다.

이와 같이 선행연구들은 전이학습 및 파인튜닝을 통해 데이터 부족과 건물 간 특성 차이 문제를 완화하고, 열환경·열쾌적·실내온도 예측의 성능을 개선할 수 있음을 수치적으로 입증하였다. 다만 성능 보고가 RMSE 등 단일 요약 지표 중심으로 이루어지는 경우가 많아, 파인튜닝의 효과를 운영 관점에서 재현 가능하게 설명할 근거가 충분히 제시되지 못하는 한계가 있다. 또한, 온도 중심의 적용 사례가 상대적으로 많아, CO₂ 및 PM_{2.5}를 포함한 복수 실내 환경지표를 동일 프레임에서 다루고, 서로 다른 실증지 간 결과를 공통 기준으로 비교·정리한 연구 축적은 아직 제한적이다.

1.3. 연구의 목적

본 연구는 이러한 한계를 보완하기 위하여, 실내 환경 예측 모델의 파인튜닝을 통해 서로 다른 대상지에서의 적응 기간을 정량적으로 비교·분석하고, 이를 통해 건물 간 모델 이전 시 필요한 최소 학습 기간과 안정화 과정을 규명하고자 한다. 특히 실제 현장 적용에서는 동일 용도의 건물 간 이전뿐 아니라, 업무시설에서 판매시설로와 같이 용도가 상이한 건물 간에도 예측모델의 이전이 요구되는 경우가 많다. 이에 본 연구는 용도 차이에 따른 도메인 불일치가 존재하는 조건에서 파인튜닝이 예측 성능을 얼마나 회복 및 안정화할 수 있는지를 검증하고자, 업무시설(실증지 A)에서 구축한 기본 모델을 판매시설(실증지 B, C)에 적용하는 시나리오를 설정하였다.

우선, 실증지 A에서 장기간 취득한 실측 데이터를 이용하여 실내 온도, CO₂, PM_{2.5} 농도를 예측하는 기본 모델을 구축한다. 이후 동일한 모델을 실증지 B와 C에 각각 적용하되, 각 대상지의 데이터베이스(DB)로부터 매일 자정마다 이전 1주일치 실측 데이터를 불러

와 window slide 방식으로 학습 데이터를 구성하고, 이를 이용하여 일별 파인튜닝을 수행한다. 이때 파인튜닝 반복에 따른 예측오차의 변화 추이를 분석함으로써, 실증지 B와 C에서 모델이 안정적인 성능 수준에 도달하는 시점, 즉 대상지별 적응 기간을 비교·평가하고자 한다. 본 연구는 현장 실증 데이터 기반 연구의 적용성을 고려하여, 전 기간에 걸쳐 공통적으로 계측 가능한 변수(실내·외 환경 센서 및 HVAC 데이터, 재실자 수 등)를 중심으로 모델을 구성하였다. 자연환기 여부, 침기량, 단열 성능과 같은 계획적 요인은 실내환경에 중요한 영향을 미치지 않지만, 실증지 전 구간에서 상시 계측·정량화된 자료 확보가 제한적이므로 본 연구의 입력 변수에는 포함하지 않았다.

본 연구를 통해 기대되는 효과는 다음과 같다. 첫째, 파인튜닝 적용 시 모델이 새로운 대상지에 충분히 적응하기 위해 요구되는 최소 학습 기간을 정량적으로 제시함으로써, 건물 간 모델 이전 시 초기 운전 단계의 불확실성과 리스크를 감소시키는 데 기여할 수 있다. 둘째, 대상지별 적응 기간과 성능 수렴 특성을 비교·분석함으로써, 건물 특성에 따라 필요한 데이터 확보 기간과 파인튜닝 주기를 합리적으로 설계하기 위한 기초자료를 제공할 수 있다. 셋째, 온도, CO₂, PM_{2.5} 등 복수의 실내 환경 지표를 동시에 대상으로 하는 파인튜닝 절차와 일별 학습 구조를 제시함으로써, 향후 실증형 환기·공조 제어 시스템에 인공지능 기반 예측 모델을 적용할 때 재학습 전략 수립 및 실무적 운용 지침 마련에 활용 가능한 시사점을 제공할 것으로 기대된다.

2. 연구 방법

2.1. 연구 개요

본 연구에서는 Table 1.에 정리된 실증지 A에서 취득한 데이터를 기반으로 예측 모델을 개발하였다. 실증지 A는 서울시 강남구에 위치한 연면적 26,402.2m²의 업무시설로, 운영시간은 08:00부터 20:00까지이다. 해당 실증지에서는 환경·영상·초음파 센서가 설치되어 실내·외 온도, 습도, CO₂ 농도, PM₁₀, PM_{2.5} 농도, HVAC 시스템의 가동 상태 및 풍량, 운전 모드, 공기청정기 가동 상태, 재실자 수의 데이터 취득이 가능하다.

개발된 예측 모델의 파인튜닝 성능 검증을 위해 실증지 두 곳을 추가 선정하였으며, 그 개요는 다음과 같다. 실증지 B는 서울시 노원구에 위치한 연면적 38,456.70m²의 대형 판매시설이며, 운영시간은 10:00부터 22:30까지이다. 실증지 C는 부산시 부산진구에 위치한 연면적 379,246.91m²의 대형 종합소매점으로, 운영시간은 10:00부터 20:30까지이며, 세 실증지 모두 동일한 유형의 센서가 설치되어 있다.

본 연구의 분석 단위는 ‘실’이 아닌 ‘공조존(zone)’이며, 공조존 내 다중 센서 측정값을 동일 시각 기준으로 시간 동기화한 후 존 평균값으로 정리하였다. 실증지 A는 층별 공조존이 1개로 구성되어 단일 공조존 평균 데이터를 사용하였고, 실증지 B는 층별 4개 공조존의 평균 데이터를 사용하였다. 실증지 C는 층별 3개 공조존으로 구성되며, 2개 층을 대상으로 총 6개 공조존(3존×2층)에 동일한 절차를

적용하였다. 또한 스케줄 정보는 별도의 일정표를 사용하지 않고 HVAC 가동 상태, 풍량, 운전 모드, 재실자 수 등 예측 가능한 운영 변수를 통해 반영하였다.

연구 방법의 전체적인 흐름은 Fig. 1.과 같다. 먼저, 실증지 A에서 2025년 1월 1일부터 2025년 4월 7일의 데이터를 제공 받아 이상치 및 결측값 데이터를 모두 소거하였다. 이상치는 (1) 각 변수별 물리적·측정 범위를 벗어난 값과 (2) 인접 시점 대비 비정상적으로 큰 변화를 보이는 값으로 정의하였다. 예를 들어 온도는 10°C 미만 40°C

Table 1. Site overview

Type		Contents
Site A	Adress	'H' Building, Gangnam-gu, Seoul
	Floor area	26,402.20m ² /1 Zone
	Type	Office
	Operating hour	08:00~20:00
Site B	Adress	'L' Market, Gangnam-gu, Seoul
	Floor area	38,456.70m ² /4 Zones
	Type	Market
	Operating hour	10:00~22:30
Site C	Adress	'L' Store, Busangin-gu, Busan
	Floor area	379,246.91m ² /6 Zones
	Type	Department store
	Operating hour	10:00~20:30

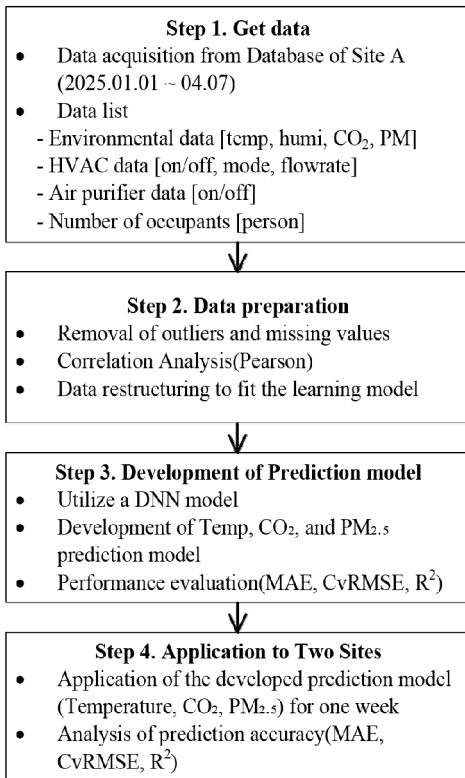


Fig. 1. Research process

이상 범위를 벗어나는 값을 제거하였고, CO₂는 400ppm 미만 3,000ppm 이상, PM_{2.5}는 0 μ g/m³ 이하, 200 μ g/m³의 범위를 벗어나는 값을 제거하였다. 또한 센서 오류로 판단되는 순간 스파이크를 배제하기 위해 시계열 인접 시점 변화량(Δ)이 사전 설정한 임계값인 50을 초과하는 경우 해당 값을 이상치로 간주하여 제거하였다. 그 다음 정리된 데이터는 상관분석을 실시하여 각 예측 모델별 입출력 데이터를 선정하였다. 해당 데이터는 학습을 위해 데이터 스케일링 작업 후 데이터 분할 및 학습 모델에 맞추어 구조 조정을 하였다.

개발된 예측 모델은 성능 지표를 통해 평가한 후, 동일한 유형의 센서 환경을 가진 실증지 B와 C에 적용하였다. 각 실증지에서 1주일 간 모델을 파인튜닝하였으며, 공조존별로 성능 지표를 산정한 뒤 이를 평균으로 요약하여 대상지 간 예측 적용 가능성과 적용 특성을 분석하였다.

2.2. 데이터 구성

머신러닝 모델의 재현성과 해석 가능성을 확보하기 위해, 실증지별 데이터 구성과 주요 변수의 분포 정보를 함께 제시하였다. 실증지 A의 원시 데이터는 2025년 1월 1일부터 2025년 4월 7일까지 1분 간격으로 취득되어 총 139,680개로 구성되며, 예측 주기(10분)에 맞추어 동일 시각 기준으로 집계된 값을 10분 구간 평균으로 리샘플링하였다. 이론상 13,968개의 10분 샘플이 생성 가능하나, 결측값 및 이상치가 포함된 구간을 제거한 결과 최종적으로 12,941개의 유효 데이터 샘플을 확보하였다. 또한 Table 2.에는 실증지 A의 온도, CO₂, PM_{2.5}와 주요 운전 변수(HVAC 급·배기 풍량, 운수·외기 댐퍼 개도율, 공기청정기 가동상태, 재실자 수)의 기술통계(최소값, 최대

Table 2. Descriptive statistics of key variables in site A

Type	Contents			
	Min.	Max.	Mean	Standard deviation
Indoor Temp. [°C]	17.86	29.18	23.38	1.73
Indoor Humi. [%]	10.59	43.63	21.39	4.58
Indoor CO ₂ [ppm]	400	991	500.4	49.56
Outdoor PM _{2.5} [μ g/m ³]	0.1	135.6	27.72	21.65
Indoor PM _{2.5} [μ g/m ³]	0	45.04	8.49	6.82
Hvac supply air flow [CMH]	0	30,384	12,445	14,258.5
Hvac return air flow [CMH]	0	35,209	14,553	16,679
Hvac hot water damper ratio [%]	0	100	6.93	15.46
Hvac damper ratio [%]	0	100	6.36	17.85
Air purifier operation [0, 1]	0	1	0.36	0.48
Number of occupants [people]	0	51.15	6.48	9.41

값, 평균, 표준편차)를 제시하였다.

먼저, 실내 온도는 17.86~29.18℃ 범위에서 평균 23.38℃ (표준편차 1.73)로 나타나, 분석 기간 동안 비교적 안정적인 수준을 유지하였다.

실내 습도는 평균 21.39% (10.59~43.63%)로 분포하였으며, 실내 CO₂ 농도는 평균 500.4ppm (400~991ppm), 표준편차 49.56으로 확인되어 극단적 고농도 구간은 제한적인 것으로 판단된다.

미세먼지의 경우, 실외 PM_{2.5}는 평균 27.72 $\mu\text{g}/\text{m}^3$ (0.1~135.6 $\mu\text{g}/\text{m}^3$), 표준편차 21.65로 변동성이 비교적 크게 나타난 반면, 실내 PM_{2.5}는 평균 8.49 $\mu\text{g}/\text{m}^3$ (0~45.04 $\mu\text{g}/\text{m}^3$), 표준편차 6.82로 실외 대비 낮은 수준과 상대적으로 완화된 변동폭을 보였다. 이는 실내 환경이 외기 오염도의 영향을 받되, 환기·여과 및 실내 정화 조건에 의해 실내 농도가 일정 수준 저감될 수 있음을 시사한다.

HVAC 운전 변수에서는 급기 풍량과 환기 풍량이 각각 평균 12,445 CMH와 14,553 CMH로 나타났으며, 표준편차가 각각 14,258.5 CMH와 16,679 CMH로 운전 상태 변화가 빈번하게 발생했음을 알 수 있다. 온수 탭퍼 및 외기 탭퍼 개도율은 평균이 각각 6.93%와 6.36%로 낮은 편이나 표준편차가 15.46% 및 17.85%로 나타나, 평상시에는 낮게 유지되다가 특정 기간에 개도율이 증가하는 운전 패턴이 존재했을 가능성을 보여준다. 또한, 공기청정기 운전 여부는 평균 0.36(표준편차 0.48)으로, 분석 기간 중 일정 비율로 운전이 수행되었음을 확인하였다. 재실자 수는 0~51.15명 범위에서 평균 6.48명(표준편차 9.41)으로 나타나, 재실 변화가 실내 환경 변동의 주요 요인 중 하나임을 시사한다.

2.3. 입출력 변수 선정

예측 모델의 성능을 확보하기 위해서는 출력 변수와 충분한 관련성을 가지는 입력 변수를 선별하는 과정이 중요하다[10]. 이에 본 연구에서는 변수 간 상관 구조를 파악하기 위해 피어슨 상관계수를 산정하였으며, 해당 결과를 토대로 예측 모델 학습에 사용할 입력 변수를 선정하였다.

피어슨 상관계수는 두 연속형 변수 간 선형 상관성을 나타내는 지표로, 계수 값은 -1에서 1 사이의 범위를 갖는다. 상관 계수가 1에 가까울수록 두 변수 간에 강한 양의 선형 관계가 있음을 의미하고, -1에 가까울수록 강한 음의 선형 관계가 있음을 의미한다. 반면, 계수 값이 0에 근접할수록 두 변수 간 선형 상관성이 미약하거나 거의 없음을 나타낸다[11].

본 연구에서는 실내 온도, CO₂ 농도, PM_{2.5} 농도 총 3가지의 예측 모델을 개발하였으며, 상관계수 분석 결과는 Fig. 2.에, 각 모델에 사용되는 입·출력 변수는 Table 3.과 같이 정리하였다. 먼저, 상관계수는 절댓값이 0.4 이상인 항목을 우선적으로 고려하였고, 이에 더해 물리적·운영적 연관성이 높은 변수들을 추가로 입력 변수에 포함하였다.

실내 온도 모델의 경우, 실내 온도는 공급·환기 풍량(ahu_s, ahu_r)과 세트포인트 온도(ahu_temp), 재실자 수(occ)와 각각 약 0.43, 0.42, 0.54, 0.51의 양의 상관성을 보여 해당 변수들을 주요 입력 변수로 채택하였다. CO₂ 농도 모델에서는 재실자 수(occ), HVAC 공급·환기 풍량(ahu_s, ahu_r)이 CO₂ 농도와 0.43, -0.41,




Fig. 2. Pearson correlation analysis

Table 3. In-output variables

Model	Input variables	Output variable
Temp.	<ul style="list-style-type: none"> Indoor temp. (temp) Indoor humi. (humi) HVAC supply airflow (ahu_s) HVAC return airflow (ahu_r) HVAC setpoint (ahu_temp) Number of occupants (occ) 	<ul style="list-style-type: none"> Indoor temperature after 10 minutes
CO ₂	<ul style="list-style-type: none"> Indoor CO₂ concentration (co₂) HVAC supply airflow (ahu_s) HVAC return airflow (ahu_r) HVAC damper ratio (ahu_damper) Number of occupants (occ) 	<ul style="list-style-type: none"> Indoor CO₂ concentration after 10 minutes
PM _{2.5}	<ul style="list-style-type: none"> Outdoor PM_{2.5} concentration (out_pm2_5) Indoor PM_{2.5} concentration (pm2_5) Indoor humi. (humi) HVAC supply airflow (ahu_s) HVAC return airflow (ahu_r) HVAC damper ratio (ahu_damper) Air purifier (air_purifier) Number of occupants (occ) 	<ul style="list-style-type: none"> Indoor PM_{2.5} concentration after 10 minutes

-0.41의 상관관계를 보여 입력 변수로 우선 반영하였다. PM_{2.5} 모델에서는 실외 PM_{2.5} 농도(out_pm2_5)와 HVAC 공급·환기 풍량(ahu_s, ahu_r)이 실내 PM_{2.5} 농도와 각각 약 0.46, 0.56, 0.56의 비교적 높은 상관계수를 나타내어 입력변수로 선정하였다.

한편, 상관계수는 0.4 미만이지만 실내 환경 형성에 물리적으로 밀접하게 관련된 실내 습도(humi), 탭퍼 개도율(ahu_damp), 공기청정기 운전 여부(air_purifier) 등은 운영 특성과 선형 연구를 고려하여 추가적인 입력 변수로 포함하였다[12]. 이러한 입력 변수 조합을 기반으로, 실내 온도 모델은 10분 후 실내 온도, CO₂ 농도 모델은 10분 후 실내 CO₂ 농도, PM_{2.5} 농도 모델은 10분 후 실내 PM_{2.5} 농도를 각각 출력 변수로 설정하였다.

2.4. 데이터 전처리

데이터 전처리는 학습 데이터에 존재할 수 있는 결측값 및 노이즈를 제거하고, 학습 알고리즘에 적합한 형태로 데이터를 구조화·스케일링하는 일련의 과정을 의미한다. 적절한 데이터 전처리가 수행되지 않을 경우 예측 모델의 성능이 저하되거나, 극단적인 경우 학습 자체가 수렴하지 않는 등의 문제가 발생할 수 있다[13].

본 연구에서는 취득한 학습데이터에서 결측값이 다수 발생하였으며, 단기간에 국한된 결측 구간의 경우에는 직전값과 직후값의 평균을 적용하여 보정하였고, 장기간 연속으로 발생한 결측 구간은 데이터 세트에서 삭제하였다. 이후 학습 모델인 DNN에 맞추어 데이터 구조화와 스케일링을 수행하였다. DNN 모델은 학습 데이터와 동일한 2차원 행렬 구조를 입력으로 사용하며, n번째 시점의 입력 변수를 바탕으로 n+1번째 시점의 출력 변수를 예측하도록 구성하였다.

데이터에 대한 스케일링과 데이터셋 분할 과정도 함께 수행하였다. 일반적으로는 정규화(normalization)와 표준화(standardization)가 많이 사용되며, 본 연구에서는 각 입력 변수의 최솟값과 최댓값을 0과 1의 범위로 선형 변환하는 min-max normalization 방법을 적용하였다. 이후 예측 모델의 학습(train), 검증(validation), 테스트(test) 단계를 위해 정규화된 데이터를 8:1:1의 비율로 분할하였으며, 이때 각 단계에 사용된 샘플 수는 각각 10,404개, 1,301개, 1,300개이다.

3. 실내 환경 예측 모델 개발

3.1. 모델 구조

다양한 인공지능명종류가 있지만 현재 건축 및 환경 분야에서 주로 사용되는 모델은 심층 신경망 모델(Deep Neural Network, DNN)이다[14]. DNN은 복잡한 비선형 함수 처리에 용이하며, 입·출력 변수 간 연속성, 범주형 변수에 국한되지 않고 분석이 가능하기 때문에 비선형적 특징을 나타내는 데이터 학습에 유리하다[15].

특히 건축 및 환경 분야에서는 온도, 습도, CO₂, PM_{2.5} 농도, 설비 운전신호 등 다양한 센서 데이터가 시간에 따라 상호 영향을 주고받기 때문에, 이러한 고차 상호작용과 시계열 패턴을 동시에 고려할 수 있는 DNN의 장점이 두드러진다[16]. 다층 구조를 통해 저차원의 단순 관계부터 고차원의 복잡한 관계까지 단계적으로 표현할 수 있어, 전통적인 선형 회귀 모형이나 경험식 기반 예측기법에 비해 예측 정밀도를 향상시키는 데 유리하다. 또한 별도의 수작업 특징 추출 없이도 은닉층에서 자동으로 유의미한 특징을 학습할 수 있어, 물리식이나 규칙 기반 모델링이 어려운 복잡계 시스템의 대체모델로 활용 가능하다는 점에서 활용성이 크다[17]. 다만 높은 자유도로 인해 충분한 학습데이터와 적절한 정규화, 하이퍼파라미터 튜닝이 병행되어야 과적합을 방지하고 일반화 성능을 확보할 수 있다.

3.2. 하이퍼파라미터 설정

실내 환경 예측 모델의 성능을 향상시키기 위해 하이퍼파라미터 최적화 과정을 별도로 수행하였다. 하이퍼파라미터는 학습 과정에서 데이터로부터 직접 추정되는 가중치와 달리, 모델의 구조와 학습

Table 4. Input variables for indoor environmental prediction model

Hyperparameter variables	Range
Neuron	• 32~512, step=32
Hidden layer	• 0~5
Dropout	• 0~0.5, step=0.1
Activation function	• ReLU, sigmoid, tanh
Loss function	• MSE
Optimization function	• Adam optimization
Max trial	• 10
Epoch	• 60
Training option	• Early stopping=5

방식 전반을 미리 규정하는 설정값으로서 은닉층의 개수, 각 층의 뉴런 수, 드롭아웃 비율, 활성화 함수 등이 이에 해당한다. 이러한 하이퍼파라미터의 조합에 따라 예측 성능이 크게 달라지므로, 적절한 조합을 탐색하는 튜닝 과정은 필수적인 단계라 할 수 있다[18].

하이퍼파라미터 탐색 기법으로는 전 탐색(grid search), 무작위 탐색(random search), 휴리스틱 기반 기법, 베이지안 최적화 등 다양한 방법이 보고되어 있다[19]. 이 가운데 베이지안 최적화는 이전 탐색에서 얻은 정보를 이용해 성능이 우수할 가능성이 높은 영역을 점진적으로 집중 탐색하는 방식으로, 탐색 비용을 줄이면서도 효율적으로 후보 조합을 찾을 수 있다는 장점이 있다.

본 연구에서는 탐색 효율과 계산 시간을 동시에 고려하여 베이지안 최적화 기반 접근법을 채택하였으며, Keras-Tuner에서 제공하는 BayesianOptimization 모듈을 사용하였다. 이를 위해 하이퍼모델(hypermodel)을 구성한 뒤, 은닉층 수, 층별 뉴런 수, 드롭아웃 비율, 활성화 함수 등에 대한 탐색 범위를 설정하였고, 구체적인 범위는 Table 4.에 정리하였다. 여기서 하이퍼모델(hypermodel)이란, 하이퍼파라미터 값에 따라 서로 다른 네트워크 구조를 자동으로 생성·학습할 수 있도록 정의한 모델 설계 템플릿을 의미한다[20]. 학습에는 평균제곱오차(Mean Squared Error, MSE)를 손실 함수로, Adam 알고리즘을 최적화 기법으로 사용하였다. 최대 학습 epoch 수는 60으로 설정하였으며, 검증 성능이 5회 연속으로 개선되지 않을 경우 학습을 조기 종료하도록 Early stopping 기법을 적용하여 과적합을 완화하였다.

3.3. 파인튜닝

파인튜닝(fine-tuning)은 사전 학습된 인공지능명종 모델을 새로운 데이터셋이나 응용 환경에 맞게 미세 조정하는 전이학습(transfer learning)의 한 방법이다[21]. 일반적으로 대규모 또는 대표성이 높은 데이터로 기초 모델을 학습한 후, 목표 도메인에서 취득한 비교적 적은 양의 데이터를 이용하여 가중치를 부분적으로 재학습함으로써, 학습 효율을 높이고 과적합을 억제하면서도 대상 시스템에 특화된 예측 성능을 확보할 수 있다[22]. 특히 건축·환경 분야와 같이 건물 간 물리적 특성, 설비 운영 패턴, 재질 특성이 상이한 경우, 파인튜닝은 공통적인 패턴을 포착한 기본 모델을 유지하면서도 개별 건물의 특성을 반영할 수 있는 효과적인 적응(adaptation) 기법으로 활용된다.

본 연구에서는 실증지 A에서 개발한 실내 환경 예측 모델을 기본

모델로 활용하고, 이를 실증지 B와 C에 각각 적용하기 위해 일별 파인튜닝 절차를 수행하였다. 먼저, 실증지 A의 실측 데이터를 이용하여 온도, CO₂, PM_{2.5} 농도를 예측하는 초기 모델을 학습하였다. 이후 실증지 B와 C에서는 각 실증지의 DB에 저장된 최신 실측 데이터를 활용하여, 매일 자정(00:00)에 이전 1주일간(24시간×7일) 축적된 데이터를 불러온 뒤, 일정 길이의 입력-출력 시퀀스를 구성하는 window slide 방식으로 학습용 샘플을 재구성하였다. 이렇게 구성된 1주일치 sliding window 데이터셋을 이용하여, 전일까지의 가중치를 초기값으로 하는 파인튜닝을 수행함으로써, 모델이 시간 경과에 따라 각 실증지의 운전 조건 변화와 실내 환경 특성에 점진적으로 적응하도록 하였다. 이를 통해 초기에는 실증지 A의 학습 특성이 강하게 반영된 모델이지만, 반복적인 일별 파인튜닝을 거치면서 실증지 B와 C 고유의 시계열 패턴과 비선형 특성을 반영하는 방향으로 모델이 업데이트되도록 하였다.

4. 예측 모델 성능 평가

4.1. 초기모델 성능 평가 결과

Table 5.는 실증지 A에서 구축한 3가지 DNN 기반 예측 모델의 초기 성능 평가 결과를 정리한 것이다. 모델의 은닉층 수와 노드 수는 변수 간 비선형 관계를 충분히 학습하면서도 과적합을 억제하는 균형을 고려하여 결정하였다. 구체적으로, 과도하게 큰 은닉층을 가진 모델은 학습 데이터에 과적합되어 타 실증지 파인튜닝 시 일반화 성능이 저하될 수 있으므로, 본 연구에서는 은닉층 2~3개 수준의 비교적 단순한 DNN을 기본 구조로 채택하였다. 또한 동일한 전처리-학습 조건에서 후보 구조를 비교하고, 검증 성능(MAE, CvRMSE, R²)과 학습 안정성을 종합적으로 고려하여 최종 구조를 선정하였다.

먼저, 실내 온도 예측 모델은 6-192-32-128-1 구조와 학습률 0.0001, ReLU 활성화 함수를 사용하였으며, MAE 0.07°C, CvRMSE 0.42%, R² 0.9947로 매우 우수한 예측 성능을 보였다.

실내 CO₂ 농도 예측 모델(5-64-128-1 구조)의 경우 MAE 8.66

ppm, CvRMSE 4.58%, R²=0.9504를 나타내어, 실내 CO₂ 농도 변화에 대해서도 높은 수준의 재현성을 확보한 것으로 판단된다.

실내 PM_{2.5} 농도 예측 모델(8-128-64-64-1 구조)은 MAE 0.54 μg/m³, CvRMSE 10.35%, R² 0.9863를 나타내어, 다른 모델에 비해 상대적으로 오차가 다소 크지만 여전히 높은 결정계수를 확보하여 실내 PM_{2.5} 농도 예측에도 충분한 설명력을 갖는 것으로 평가된다. 전체적으로 세 모델 모두 낮은 오차와 높은 R² 값을 보여, 실증지 A 데이터를 기반으로 한 초기 예측 모델의 신뢰성이 전반적으로 양호한 수준임을 확인할 수 있다.

4.2. 실증지별 적용 결과

Table 6.은 실증지 B에 7일간 순차적으로 예측 모델을 적용한 결과를 나타낸 것이다. 온도 예측 모델은 Day 1~2에서 MAE가 각각 1.97°C, 1.62°C, CvRMSE가 91.51%, 59.11%로 매우 큰 오차를 보였으나, Day 3 이후부터는 MAE 0.13~0.19°C, CvRMSE 0.67~1.00% 수준으로 급격히 감소하였다. 이 구간에서 R²는 0.7807~0.9730 범위로 수렴하여, 초기 2일을 제외하면 전반적으로 양호한 온도 예측 성능을 확인할 수 있다. CO₂ 예측 모델 역시 Day 1~4에서는 MAE 112.30~672.01ppm, CvRMSE 25.85~60.78% 등 지표 변동이 큰 편이지만, Day 5 이후에는 MAE 5.42~13.21ppm, CvRMSE 1.88~3.66% 수준으로 안정화되며, R²도 최대 0.9802까지 향상되는 양상을 보였다. PM_{2.5} 예측 모델의 경우 전 기간 동안 MAE는 0.47~4.81 μg/m³로 비교적 작은 값을 유지하였으나, CvRMSE와 R²는 일자별로 다소 변동폭이 큰 것으로 나타났다.

Table 7.의 실증지 C 결과를 보면, 온도 예측 모델은 적용 초기부터 전반적으로 안정적인 성능을 유지하였다. 7일 동안 MAE는 0.08~0.8°C, CvRMSE는 0.45~7.98% 범위에 분포하였으며, R²는 최소 0.5926, 최대 0.9848로 전반적으로 높은 계수를 보였다. CO₂ 예측 모델은 Day 2에서 MAE 62.70ppm, CvRMSE 20.25%, R²는 0.3346 등 비교적 큰 오차가 관찰되었으나, Day 3 이후에는 MAE 6.14~17.39ppm, CvRMSE 2.16~5.02% 수준으로 감소하였고, R²

Table 5. Initial model performance evaluation results

Type		Structure	Learning rate	Activation function	MAE	CvRMSE	R ²
DNN model	Temp.	6-192-32-128-1	0.0001	ReLU	0.07°C	0.42%	0.9947
	CO ₂	5-64-128-1	0.0001	ReLU	8.66ppm	4.58%	0.9504
	PM _{2.5}	8-128-64-64-1	0.0001	ReLU	0.54 μg/m ³	10.35%	0.9863

Table 6. Performance changes over 7 days in test site 'B'

Day	Temperature			CO ₂			PM _{2.5}		
	MAE [°C]	CvRMSE [%]	R ²	MAE [ppm]	CvRMSE [%]	R ²	MAE [μg/m ³]	CvRMSE [%]	R ²
Day 1	1.97	91.51	-	281.84	60.78	-	2.49	18.85	-
Day 2	1.62	59.11	0.2871	568.64	25.85	0.7345	4.81	44.99	0.4324
Day 3	0.13	0.74	0.9467	672.01	44.31	0.2967	1.85	45.82	0.2897
Day 4	0.18	1.00	0.7807	112.30	29.40	0.3935	2.36	76.84	-
Day 5	0.14	0.73	0.9689	5.42	1.88	0.9802	0.87	64.63	0.6246
Day 6	0.13	0.67	0.9730	9.73	3.36	0.5438	0.47	21.99	0.8531
Day 7	0.19	0.88	0.9359	13.21	3.66	0.7832	0.76	12.86	0.6956

Table 7. Performance changes over 7 days in test site 'C'

Day	Temperature			CO ₂			PM _{2.5}		
	MAE [°C]	CvRMSE [%]	R ²	MAE [ppm]	CvRMSE [%]	R ²	MAE [µg/m ³]	CvRMSE [%]	R ²
Day 1	0.19	2.33	0.8844	26.59	7.07	-	0.75	12.10	0.9801
Day 2	0.88	7.98	0.8504	62.70	20.25	0.3346	0.44	23.09	0.9649
Day 3	0.12	0.70	0.5926	7.81	2.34	0.9007	0.43	9.01	0.9374
Day 4	0.12	0.55	0.8281	17.39	5.02	0.3502	0.30	14.02	0.9785
Day 5	0.12	0.66	0.9755	13.69	3.50	0.9875	0.30	28.36	0.9508
Day 6	0.09	0.50	0.9842	11.95	3.08	0.9907	0.37	25.54	0.9646
Day 7	0.08	0.45	0.9848	6.14	2.16	0.9707	0.38	18.70	0.9645

역시 대부분의 일자에서 0.90 이상을 기록하였다. PM_{2.5} 예측 모델은 전 기간에 걸쳐 MAE 0.30~0.75µg/m³, CvRMSE 9.01~28.36% 범위로 유지되었으며, R²는 0.9466~0.9801 수준으로 비교적 안정적인 예측 성능을 나타냈다.

4.3. 오차 분석 및 보완사항 도출

실증지와 무관하게 세 예측모델 모두 적용 초기 1~2일차에 성능이 크게 저하되는 공통된 양상을 보였다. 이는 실증지 A에서 학습된 최초모델을 실증지 B, C의 공조존 운영 조건에 그대로 적용하는 과정에서 입력 변수의 분포가 학습 구간과 달라지는 도메인 전이(domain shift)가 발생했기 때문으로 해석된다. 특히 대규모 건물의 공조존 단위 데이터는 존별 운영 스케줄과 설비 제어 특성이 직접 반영되므로, 동일 변수 체계를 사용하더라도 운전 조건이 달라질 경우 모델의 일반화 성능이 적용 초기 구간에서 급격히 저하될 수 있다. 이후 일별 파인튜닝을 통해 목표 대상지 데이터가 점진적으로 축적되면서, MAE와 CvRMSE는 감소하고 R²는 증가하는 방향으로 수렴하는 경향을 확인하였으며, 이는 반복 파인튜닝이 대상지별 환경·운전 특성을 모델 가중치에 반영하여 예측 성능을 회복시키는 데 유효함을 시사한다.

실증지 B의 경우, 온도 모델은 적용 4일차에 DB 상 다수의 결측치가 발생하여 입력·출력 시계열의 연속성이 저하되면서 일시적으로 성능이 악화되었으나, 결측 구간이 해소된 이후에는 지표가 다시 정상 범위로 회복되었다. CO₂ 모델은 적용 초기(1~4일차) 재실자 수 및 환기 운전 조건 변화에 민감하게 반응하며 지표 변동이 크게 나타났으나, 외기 댐퍼 개도율과 같은 환기 관련 변수를 반영한 파인튜닝을 통해 5일차 이후에는 초기모델 대비 낮은 오차 성능을 확보하였다. 이는 판매시설의 경우 재실 변동과 환기 제어의 영향이 상대적으로 크게 나타나며, 해당 영향이 입력 변수로 충분히 반영될 때 모델의 적응 속도 및 안정화 수준이 향상될 수 있음을 보여준다. 반면 PM_{2.5} 모델은 유동 인구, 시식 코너 및 물류 이동 등 다양한 오염원이 시간적으로 비정규적으로 발생하는 환경 특성상 예측 난이도가 높아, MAE와 CvRMSE는 점진적으로 개선되었음에도 R²가 상대적으로 낮게 유지되는 경향을 보였다. 이는 평균 오차는 감소하더라도 변동 패턴을 충분히 재현하지 못한 구간이 존재했음을 의미하며, 복합 오염원 환경에서의 스파이크 예측을 위해서는 추가 변수(인원 밀집도, 시식 코너 스케줄, 출입문 개폐 여부)와 함께 보다 긴 기간의 학습 데이터가 필요함을 시사한다.

실증지 C에서는 전반적으로 실증지 B에 비해 성능 변동폭이 작고 안정적인 수렴 양상이 관찰되었다. 온도 및 CO₂ 모델은 휴무일이 포함된 3일차에 설비 운전 패턴이 평일과 상이하게 나타나면서 일시적인 예측 성능 저하가 발생하였으나, 파인튜닝이 누적된 5~7일차에는 초기모델과 동등하거나 그 이상의 수준으로 회복되었다. PM_{2.5} 모델은 휴무일을 포함하여 전 기간 동안 상대적으로 안정적인 성능 지표를 유지하였으며, 이는 실증지 C에서의 오염원 및 재실 변동이 비교적 제한적이거나, 공조운전 및 정화 조건이 일정하여 모델이 학습하기 쉬운 패턴이 형성되었을 가능성을 시사한다. 다만 CvRMSE는 평균 농도가 작아지는 구간에서 상대적으로 민감하게 변동할 수 있으므로, PM_{2.5}와 같이 평균 값이 낮고 스파이크가 존재하는 지표에서는 MAE와 R²를 함께 고려하여 성능을 해석할 필요가 있다.

종합하면, 초기 1~2일차를 제외할 경우 일별 파인튜닝을 통해 대상지별 예측 성능이 일정 수준까지 회복·안정화되는 경향을 확인할 수 있었다. 그러나 실내 미세먼지(PM_{2.5}) 모델은 오염원 발생의 간헐성 및 비선형성으로 인해 단기 데이터만으로 성능 안정화 여부를 단정하기에는 한계가 있으며, 장기 실측 데이터 기반 추가 검증, 스파이크 구간을 반영한 학습 전략 및 운영·행태 관련 대리 변수의 확장을 통해 예측 성능을 추가로 고도화할 필요가 있다.

5. 결론

본 연구에서는 실증지 A에서 구축한 DNN 기반 실내 온도, CO₂, PM_{2.5} 예측 모델을 실증지 B와 C로 전이하고, 1주일간 일별 파인튜닝을 수행하여 대상지별 적용 기간과 성능 수렴 양상을 비교·분석하였다. 실증지 A에서 개발된 기본 모델은 온도 MAE 0.07°C, CO₂ MAE 8.66ppm, PM_{2.5} MAE 0.54µg/m³ 및 R² 0.95 이상으로 전반적으로 우수한 예측 성능을 나타냈다. 그러나 실증지 B에 적용한 초기 1~2일차에는 도메인 전이에 따른 입력 분포 불일치로 온도 및 CO₂의 CvRMSE가 각각 최대 91.51%와 60.78%까지 증가하는 등 성능 저하가 관찰되었다. 이후 일별 파인튜닝을 진행함에 따라 온도 모델은 3일차 이후, CO₂ 모델은 5일차 이후 오차 지표가 안정적으로 감소하고 R²가 회복되는 경향을 보였으며, 이는 건물 간 모델 이전 시 단기간의 반복 파인튜닝만으로도 주요 지표(온도, CO₂)의 적응이 가능함을 시사한다. 반면 PM_{2.5} 모델은 실증지 B와 C 모두에서 CvRMSE가 9~28% 범위로 변동성이 크게 나타나, 1주일의 파인튜

닝 기간만으로 성능 안정화 여부를 단정하기 어려웠다. 이러한 결과는 건물 간 모델 이식 시 최소 3~5일 이상의 파인튜닝 기간이 온도·CO₂ 예측 성능 회복에 유효하며, PM_{2.5} 예측의 경우 오염원 발생의 간헐성과 비정상성 특성을 반영하기 위한 장기 학습 및 모델 고도화가 필요함을 보여준다.

본 연구는 실증지 B와 C의 파인튜닝 기간을 7일로 제한하였고, DNN 구조 및 제한된 입력 변수에 기반하여 자연환기, 침기, 단열 등 계획적 요인을 직접 반영하지 못했다는 한계를 가진다. 그럼에도 불구하고, 온도·CO₂는 3~5일 이내 성능 수렴 경향을, PM_{2.5}는 7일 동안의 부분적 개선과 잔여 변동성을 동시에 확인함으로써 파인튜닝 기반 적응 기간을 정량적으로 논의하기 위한 기초 결과를 제시하였다. 향후 연구에서는 장기 실측 데이터에 기반한 파인튜닝 기간 확장과 함께, GRU·LSTM 등 시계열 특화 모델 및 스파이크 구간을 고려한 학습 전략을 적용하여 PM_{2.5} 예측 성능의 안정화와 일반화 성능을 추가로 개선할 예정이다.

Acknowledgement

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)과 정부(과학기술정보통신부)의 지원을 받아 수행한 연구 과제입니다(No. RS-2021-KP002461, No. RS-2023-00217322).

References

[1] M. Mannan, S.G. Al-Ghamdi, Indoor air quality in buildings: A comprehensive review on the factors influencing air pollution in residential and commercial structure, *International Journal of Environmental Research and Public Health*, 18(6), 2021, 3276.

[2] H.P. Kim et al., Human-building interaction for indoor environmental control: Evolution of technology and future prospects, *Automation in Construction*, 152, 2023, 104938.

[3] J.H. Kim et al., Assessment of ann algorithms for the concentration prediction of indoor air pollutants in child daycare centers, *Energies*, 15(7), 2022, 2654.

[4] I.C. Akyol et al., Transfer learning and parameter-efficient fine-tuning for heating energy consumption prediction using urban building energy models (UBEM), *Advanced Engineering Informatics*, 68, 2025, 103576.

[5] D. Coraci et al., Online transfer learning strategy for enhancing the scalability and deployment of deep reinforcement learning control in smart buildings, *Applied Energy*, 333, 2023, 120598.

[6] G. Pinto et al., Sharing is caring: An extensive analysis of parameter-based transfer learning for the prediction of building thermal dynamics, *Energy and Buildings*, 276, 2022, 112530.

[7] H. Li et al., Building thermal dynamics modeling with deep transfer learning using a large residential smart thermostat dataset, *Engineering Applications of Artificial Intelligence*, 130, 2024, 107701.

[8] G. Jing et al., A modeling method of pre-training and fine-tuning for non-uniform indoor environment. China: 2023 IEEE 18th Conference on Industrial Electronics and Applications (ICIEA), 2023. pp.1651-1655.

[9] Q. Zhang et al., A study on source domain selection for transfer learning-based cross-building cooling load prediction, *Energy and Buildings*, 324, 2024, 114856.

[10] 최영재 외 3인, 순환 신경망 모델에 따른 재실 인원 예측모델 개발 및 성능비교, *대한건축학회논문집*, 제38권 제10호, 2022, pp.231-240. // (Y.J. Choi et al., Development of occupancy prediction model and performance comparison according to the recurrent neural network models, *Journal of the Architectural Institute of Korea*, 38(10), 2022, pp.231-240.)

[11] J. Benesty et al., Pearson correlation coefficient, In: *Noise reduction in*

speech processing, Berlin: Springer, 2009, pp. 1-4.

[12] 배강우 외 3인, 머신러닝기반 비접촉식 실내 미세먼지 농도 추정 모델 개발, 한국: 대한건축학회 춘계학술발표대회논문집, 2025, pp.366-367. // (G.W. Bae et al., Development of a machine learning-based non-contact for estimation model indoor particulate matter concentration, Korea: Spring Annual Conference of the Architectural Institute of Korea, 2025, pp.366-367.)

[13] 최영재 외 4인, 실내 이산화탄소 농도 예측 기반 적응형 환기 제어 알고리즘 개발, *KIEAE Journal*, 제23권 제2호, 2023, pp.23-29. // (Y.J. Choi et al., Development of adaptive ventilation control algorithm based on indoor carbon dioxide concentration prediction, *KIEAE Journal*, 23(2), 2023, pp.23-29.)

[14] 변재운 외 3인, 인공지능 기반 실내 PM_{2.5} 및 CO₂ 통합 제어 알고리즘을 적용한 외기도입형 환기청정기 성능 분석, *설비공학 논문집*, 제37권 제4호, 2025, pp.175-184. // (J.Y. Byun et al., Performance analysis of an outdoor air-introduced ventilation cleaner applied with an ai based indoor PM_{2.5} and CO₂ integrated control algorithm, *Korea Journal of Air-Conditioning and Refrigeration Engineering*, 37(4), 2025, pp.175-184.)

[15] V. Sze et al., Efficient processing of deep neural networks: A tutorial and survey, *Proceedings of the IEEE*, 105(12), 2017, pp.2295-2329.

[16] H. Larochelle et al., Exploring strategies for training deep neural networks, *Journal of machine learning research*, 10(1), 2009, pp.1-40.

[17] G. Montavon, W. Samek, K.R. Müller, Methods for interpreting and understanding deep neural networks, *Digital Signal Processing*, 73, 2018, pp.1-15.

[18] Y.J. Choi et al., CO₂ and PM_{2.5} Focused optimal ventilation strategy based on predictive control, *Indoor Air*, 2025, 2025, 6652442.

[19] M. Claesen, B. De Moor, Hyperparameter search in machine learning, *arXiv:1502.02127*, 2015.

[20] V. Dwaracherla et al., Hypermodels for exploration, *arXiv:2006.07464*, 2020.

[21] G.W. Anderson, D.J. Castano, Measures of fine tuning, *Physics Letters B*, 347(3-4), 1995, pp.300-308.

[22] E. Cetinic, T. Lipic, S. Grgic, Fine-tuning convolutional neural networks for fine art classification, *Expert Systems with Applications*, 114, 2018, pp.107-118.