



실내 PM_{2.5} 선제적 제어 알고리즘 개발 및 성능 분석

Development and Performance Analysis of Indoor PM_{2.5} Preemptive Control Algorithm

김태원* · 이정형**

Tae Won Kim* · Jung Hyung Lee**

* Ph.D Course, School of Architecture and Building Science, Chung-Ang Univ., South Korea (xngilsh@naver.com)

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

ABSTRACT

Purpose: Recently, as the demand for comfortable indoor environments has significantly increased, the importance of the health of occupants has come to the forefront. In response to this societal issue, this study developed an integrated control algorithm for ventilation and air purification system that can proactively manage indoor PM_{2.5} levels. **Method:** To analyze the performance of the developed indoor PM_{2.5} preemptive control algorithm, ventilation and air purification systems installed in two actively used elementary school classrooms were utilized. The control algorithm incorporates an ANN based indoor PM_{2.5} prediction model and derives control values using the predicted values and real-time environmental data. Data obtained through empirical studies were analyzed according to occupancy schedules to verify compliance with national recommended standards. Additionally, an analysis of the control algorithm's inherent performance was conducted. **Result:** The preemptive control algorithm was observed to maintain lower indoor PM_{2.5} concentrations and sustain the comfortable range for extended periods compared to rule based control algorithms. However, the system operating time was longer than that of rule based control algorithms.

KEYWORD

실내공기질
환기시스템
미세먼지

Indoor Air Quality
Ventilation System
Particulate Matter

ACCEPTANCE INFO

Received Nov. 5, 2024

Final revision received Nov. 11, 2024

Accepted Nov. 15, 2024

© 2024. KIEAE all rights reserved.

1. 서론

실내 공간의 쾌적성은 재실자의 생산성과[1] 연관되어 있을 뿐 아니라 건강에 매우 중요한 역할을 한다[2-4]. 최근에는 COVID-19와 같은 호흡기 질환의 발생 이후 환경오염에 대한 관심이 높아지며 실내환경을 쾌적하게 유지하고자 하는 수요가 증가하고 있다. 하루 중 90% 이상을 건물 안에서 생활하는 현대인들에게 실내환경은 건강에 매우 큰 영향을 미치는데[5], 미국에서 발표한 '2012 Environ Health Perfect'에 따르면 질병을 유발하는 실내공기질 요소 중 PM_{2.5}가 가장 유해한 물질인 것으로 나타났다. 세계보건기구(WHO, World Health Organization)에서는 실내 공기 오염으로 인해 매년 380만명이 사망한다고 발표했다[6]. 이러한 사회적 이슈들에 따라 쾌적한 실내공기질은 필수 생활 조건으로 여겨지는 추세이다. 최근에는 각국의 보건 기구에서 실내 CO₂ 농도 및 환기 횟수를 규정하는 등 실내공기질의 중요성이 대두되고 있으며[7, 8], WHO에서는 2005년 공기질 가이드라인 수립 이후 15년만에 개정된 2021년 공기질 가이드라인을 발표했다[9]. 개정된 주요 오염물질은 PM_{2.5}, PM₁₀, 오존, 이산화질소, 이산화황, 일산화탄소로 권고 기준이 더욱 엄격해졌다. 해당 가이드라인 개정 후 UN Environment Programme Pollution Action Note에서 조사한 바에 따르면 세계 인구의 99%가 2021년 WHO 공기질 가이드라인 기준에 미치지 못하는 지역에 살고 있다는 연구결과를 발표했다[10]. 대

한민국 역시 대부분의 오염물질로부터 WHO 기준 5.4배 높은 수치로 노출되고 있는 것으로 조사되었다. 하지만, 관심이 높아지고 있는 것에 비해 WHO의 실내공기질에 대한 기준은 개정되지 않고 2010년에 머물러 있는 실정이다[11].

실내공기질은 건물 내 오염물질 종류에 따라 유해 정도가 달라진다. 그중 입자형 오염물질인 미세먼지는 대기오염의 중요한 구성요소 중 하나로, 흡입 시 심장과 폐 건강에 매우 큰 영향을 미치는 것으로 알려져 있다. 미국에서 발표한 '2012 Environ Health Perfect'에 따르면 질병을 유발하는 실내공기질 요소 중 2.5 μ m 이하(PM_{2.5})의 미세먼지가 가장 유해한 물질인 것으로 나타났으며[12], PM_{2.5}는 기관지와 폐에 영향을 주어 염증을 유발할 수 있다는 사실이 확인되었다[13]. 또한, PM_{2.5} 농도가 10 μ g/m³ 증가할수록 폐암 발생이 9% 증가하며, PM₁₀ 농도가 10 μ g/m³ 증가할수록 만성폐쇄성폐질환 관련 입원이 2.7%, 만성폐질환 관련 사망이 1.1% 증가한다고 한다는 연구결과도 발표되었다[14]. 특히, 중요 발달 단계에 있는 13세 미만의 어린이들은 장기적으로 노출될 시 면역력을 약화시켜 아토피 피부염 증상을 악화시키거나[15] 호흡기를 자극해 천식과 기관지염 등 호흡기 질환을 발생시킬 수 있고, 심장질환이 있는 아이들에게는 심박수 증가 및 심장기능 저하 등에 영향을 미칠 수 있다[16]. 따라서, 미세먼지는 쾌적한 실내환경을 유지하기 위해 최우선적으로 제어되어야 할 요소라고 할 수 있으며, 재실자의 건강을 보호하기 위해 주거 생활공간에서 노출을 최소화해야 한다.

이러한 실내 미세먼지는 대표적으로 환기시스템과 공기청정기

를 통해 저감이 가능하다. 이 두개의 시스템은 하나의 시스템만을 사용했을 경우 실내외 온도차가 심해도 실외의 공기를 실내로 들여와 냉난방 부하가 증가한다거나, 환기 없이 실내 공기 순환만을 반복하여 실내 이산화탄소 농도가 급격히 높아지는 등의 문제점을 야기할 수 있다. 따라서, 실내 미세먼지를 효과적으로 관리하기 위해서는 환기와 공기청정을 동시에 제어하는 방법이 고려되어야 한다. 이와 관련된 문제를 해결하기 위한 연구들은 활발히 수행되고 있는 추세이다. 최연희(2019)는 공기청정기와 전열교환기가 적용된 환기시스템을 위한 제어 알고리즘을 제안하고 시뮬레이션을 통해 실내 PM_{2.5} 및 CO₂ 개선 정도와 에너지 소비량을 분석하였으며[17], Justo Alonso et al. (2022)는 시뮬레이션을 통해 다양한 수요조절 환기 전략을 구현하여 실내 PM_{2.5} 농도를 연평균 10 μg/m³ 이하로 유지, 에너지 사용량을 저감시킬 수 있는 방법을 제안하였다[18].

최근에는 인공지능 기술 등을 통해 미세먼지를 선제적으로 제어하고자 하는 시도도 다수 이루어지고 있었다. 하지만 대부분의 연구가 다양한 인공지능 기술들의 성능을 비교하는 것에 그쳤으며, 실증 실험을 통해 성능을 검증하지 않은 한계를 가지고 있었다. 관련 연구를 살펴보면 다음과 같다. Weiran et al. (2019)는 인공지능 기술 중 다중선형회귀와 랜덤포레스트를 결합한 실내 PM_{2.5} 예측모델을 개발하여 성능을 비교하였다[19]. Yuhe and Guangfei (2022)는 밀집도가 높고 환자와 방문객 간의 동선이 겹치는 병원 외래병동 실내 오염을 방지하기 위해 공간 점유율을 고려한 PM_{2.5} 예측모델을 개발했다[20]. Shi et al. (2023)는 실내 PM_{2.5} 예측 알고리즘인 LATCN를 제안하고 기존 예측 알고리즘과 성능을 비교하였다[21].

선행연구를 종합해본 결과, 환기와 공기청정 기능에 대한 제어 연구와 실내 오염물질을 선제적으로 제어하기 위한 연구가 다수 이루어지고 있는 것으로 확인되었다. 하지만, 이를 실증하여 실제적 효과를 증명한 연구는 찾아볼 수 없었다. 실제로 관련 연구의 대부분은 예측 제어 혹은 강화학습을 사용한 경우가 많았으며, 사례의 80%는 시뮬레이션을 통한 연구인 것으로 조사되고 있다[22]. 따라서, 본 연구에서는 선행연구들에서 확인할 수 없었던 실용성을 확인하고 실내 미세먼지를 선제적으로 제어하는 알고리즘을 제안하였으며, 이를 실현할 수 있는 인공지능 기반 실내 PM_{2.5} 예측모델을 개발하였다.


2. 연구방법

2.1. 실내 PM_{2.5} 선제적 제어 알고리즘 개발

본 연구에서 개발된 선제적 제어 알고리즘은 실내 PM_{2.5} 예측값을 기반으로 제어를 수행한다. 이때 시스템은 ON/OFF를 반복하며, 풍량과 모드를 선택하게 된다. 이러한 제어 방식은 예측을 기반으로 최적의 제어값을 선택하는 제어 알고리즘으로 건축 분야에서는 스마트 빌딩, 효율적 제어, 에너지 관리, 실내 환경 유지 등에 적용되고 있다[23]. 하지만, 알고리즘 제어 성능이 예측모델 정확성에 따라 크게 좌우되기 때문에 예측모델에 의존성을 가진다. 따라서, 적용 공간의 환경 변수가 단순하고, 환경 변화가 정적이라면 단순한 규칙 기반 제어(Rule Based Control)가 효율적일 수 있다. 본 연구에서 제안되는 알고리즘은 이러한 사실에 기초하여 미세먼지 선제적

Table 1. Ventilation and air purification integrated system and Classroom details

System Information	
Characteristics	Installed above the windows, Total heat exchanger, HAPA Filters, Pre-Filter
Operation modes	Indoor air circulation, Outdoor air intake
Air supply volume	Weak 150 CMH / Medium 250 CMH / Strong 400 CMH



Classroom Information	
Location	Uijeongbu-si, Gyeonggi-do, South Korea
Size	11m × 8m × 3m (W × D × H)
Occupancy	1 teacher and 21 lower grade students



제어 알고리즘과 규칙 기반 제어 알고리즘의 성능을 비교하였다.

1) 제어 알고리즘 적용 시스템 및 공간

제어 알고리즘은 창문 상단에 부착되는 형태의 환기 및 공기청정 기능이 통합된 시스템에 적용된다. 내부 구성은 모터, 전열교환기, 필터로 나뉘어 있으며 외기도입 모드와 내부순환 모드를 제공한다. 풍량은 강, 중, 약으로 조절이 가능하다. 모터는 시스템의 급배기구 측에 위치하며 외부 공기를 실내로 들여오는 급기구와 실내의 공기를 외부로 내보내는 배기구 측에는 필터가 부착된다. 또한, 전열교환기를 통해 외부에서 들어오는 공기는 실내공기와 열교환을 하면서 서로 간 혼합되지 않는다. 이때 외기도입 모드는 시스템 구조상 모터 2개가 가동되며, 내부순환 모드는 모터 1개가 가동된다. 이러한 시스템은 초등학교 교실 두곳에 적용되었다. 해당 교실은 선생님 1명과 학생 21명이 생활하는 보편적인 구조의 교실이며, 노후된 창문 및 문, 바닥 등의 교체가 이루어졌다. 이에 대한 상세 내용은 Table 1.과 같다.

2) 제어 요소별 설정 기준

입자형 오염물질인 미세먼지는 흡입 시 심장과 폐 건강에 심각한 영향을 미칠 수 있기 때문에 최우선으로 제어되어야 할 요소이다. 국내에서는 환경부 실내공기질 관리법에서 시설별 유지기준을 제시하고 있으며, 의료기관과 노인요양시설 및 어린이집 등 면역력 취약계층 활동 시설은 연평균 PM₁₀ 50 μg/m³ 이하, PM_{2.5} 35 μg/m³ 이하로 유지시킬 것을 권고하고 있다[24]. 반면 대기 미세먼지 농도는 환

경부 대기환경기준에서 실내 보다 강화된 기준을 적용하고 있다. 총 4가지(좋음, 보통, 나쁨, 매우나쁨) 단계로 나뉘며 PM₁₀의 경우 30 μg/m³ 이하 “좋음”, PM_{2.5}의 경우 15 μg/m³ 이하가 “좋음” 기준이다[25]. 일반적으로 PM₁₀은 PM_{2.5} 보다 입자가 크기 때문에 PM_{2.5}을 저감시키면 PM₁₀도 같이 저감된다. 또한, PM_{2.5}는 PM₁₀ 보다 건강상 큰 영향을 미치는 것으로 조사되고 있다. 따라서 본 연구에서는 실내 PM_{2.5}를 저감하는 것으로 기준을 잡았으며, 환경부 대기환경기준 PM_{2.5} 농도 “좋음”(15 μg/m³)을 항상 달성하고 환경부령 실내공기질 관리법 PM_{2.5} 권고 기준(35 μg/m³)를 충족시킬 수 있도록 알고리즘이 설정되었다.

실내 CO₂ 농도는 실내공기질을 대표할 뿐만 아니라 적정 환기량의 기준이 되는 중요한 지표이다[26]. 실내 CO₂ 농도에 대한 기준은 국가, 건물, 용도별로 최대 5,000ppm 까지 다양하게 제시하고 있으며[27], CO₂ 농도가 건강상 영향을 어떻게 미치는지에 대한 연구가 다양하게 이루어지고 있다. 본 연구가 진행되는 한국은 “교육부 학교보건법 시행규칙”에서 교실이 기계 환기장치를 이용하여 주환기를 하는 경우 1,500ppm 이하로 유지관리할 것을 권고하고 있다[28]. 따라서, 본 연구에서 CO₂는 1,500ppm을 넘지 않도록 모드와 풍량이 설정된다.

3) 개발된 제어 알고리즘 구조

실내 미세먼지 중 PM_{2.5}를 최우선적으로 저감하도록 개발된 선제적 제어 알고리즘은 다섯 단계로 나뉘어져 사이클이 돌아간다. 제어 알고리즘에는 선제적 제어를 위해 PM_{2.5} 예측모델이 탑재되며, 시스템의 제어값은 현재 실내공기질과 예측된 PM_{2.5} 농도, 실외 PM_{2.5} 농도를 고려하여 도출된다. 각 단계는 Fig. 1.과 같이 순차적으로 진행된다. 가장 먼저 진행되는 1단계는 환경센서를 통해 수집되는 실내외 환경 데이터와 모드 및 풍량을 실시간으로 수집하는 단계이다. 2단계는 시스템의 ON/OFF 여부를 결정하는 부분으로, 제어 알고리즘이 적용되는 공간의 스케줄이 입력된다. 만약 일정상 휴일이나 주말, 방학 등의 기간일 경우 미리 입력해둔 스케줄에 따라 시스템이 작동하지 않는다.

3단계에서는 센서를 통해 측정된 과거 데이터(t-1)와 현재 실시간으로 측정되고 있는 데이터(t)를 통해 예측모델을 재학습 시키고

실내 PM_{2.5}를 예측(t+1)한다. 이때 예측모델은 환경 변수와 시스템 문제, 현장 특성 등에 의해 정확도가 크게 달라지므로 적용된 공간 데이터를 통한 환경 적응성이 부여되어야 한다. 적응성은 측정된 과거(t-1)의 입력데이터에 대해 현재(t) 측정되고 있는 결과값을 정답으로 설정하여 데이터셋을 구성하고 재학습 시키며, 지속적인 성능 유지를 위해 지속적으로 반복된다. 이후 예측모델은 1단계에서 수집되는 시스템 풍량을 입력데이터로 사용하여 총 3개 실내 PM_{2.5} 예측값을 도출하는데, 이 중 기준치 미만으로 예측한 풍량 중 에너지가 가장 적게 소비되는 풍량이 제어에 사용된다. 만약 예측값 중 설정한 기준 농도 보다 낮은 값이 없다면 가장 낮은 농도를 예측한 풍량으로 제어한다.

4단계에서는 시스템 가동 모드와 풍량을 결정한다. 첫 번째로 3단계에서 도출된 실내 PM_{2.5} 농도 예측값을 고려한다. 만약 예측값이 10 μg/m³ 보다 작을 경우 다음 우선순위의 CO₂ 농도를 고려하고, 10 μg/m³ 보다 높을 경우 외기 PM_{2.5} 농도와 비교한다. PM_{2.5} 농도 기준(10 μg/m³)은 환경부 대기환경기준 PM_{2.5} 농도 “좋음”(15 μg/m³)을 달성하기 위해 더 강한 기준을 적용하였다. 이는 노인 및 13세 미만 어린이 등 면역력 취약계층의 건강을 보호하기 위함이며, 해당 기준은 사용 지역과 적용 공간에 따라 변경될 수 있다. 실시간 외부 PM_{2.5} 농도가 환경부 실내공기질 관리법 권고 기준(35 μg/m³) 이상일 때는 내부순환 모드를 가동한다. 이는 실외 PM_{2.5}가 높은 날 실내 PM_{2.5} 수치가 약 20배에서 50배까지 증가할 수 있다는 연구 결과와[29] 실내외의 PM_{2.5} 농도는 높은 상관관계를 보인다는 연구 결과[30, 31]에 의한 조치이다. 두 번째로 고려되는 요소는 실내 CO₂ 농도이다. 가스형 오염물질인 CO₂는 재실자에게 PM_{2.5} 보다 즉각적인 영향을 줄 수 있으며, 환기 시 저감되는 속도가 빠르다. 이에 제어 알고리즘에서는 실시간으로 측정된 실내 CO₂ 농도가 1,500ppm 이상으로 높아지면 무조건 외기도입을 모드로 가동된다. 마지막 5단계에서는 3단계에서 도출된 풍량과 4단계에서 모드로 시스템을 가동시킨다. 이 모든 과정은 시스템이 작동될 동안 반복된다.

비교 대상인 규칙 기반 제어 알고리즘은 오염물질 저감 우선순위 및 제어 기준이 동일하지만 예측모델이 탑재되지 않아 선제적 제어를 수행하지 않는다. 따라서, 예측값이 아닌 실시간 측정 데이터 기

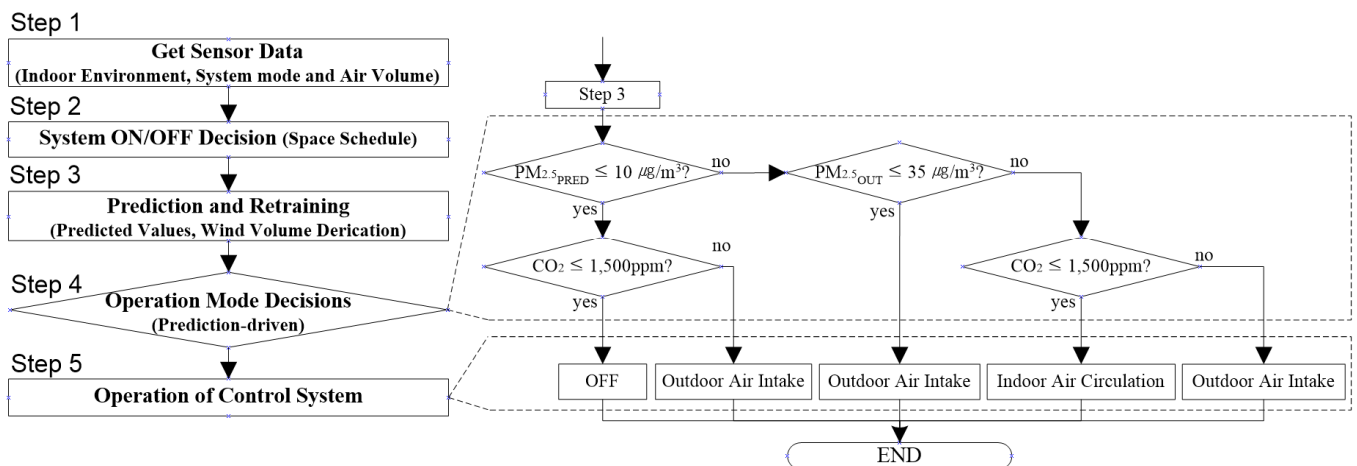


Fig. 1. Control algorithm step structure

준으로 제어되도록 로직이 구성된다. 이때 실내 PM_{2.5} 농도가 대기 환경기준 “좋음”(15 μg/m³) 이상일 경우 약풍으로 작동되고, 실내 공기질 관리법 기준(35 μg/m³) 이상일 경우에는 중 풍량으로 작동된다. 외기 도입 모드 및 내부순환 모드 작동 기준과 CO₂ 농도에 따른 제어 기준은 선제적 제어 알고리즘과 같다.

2.2. ANN 기반 실내 PM_{2.5} 예측모델 개발

선제적 제어 알고리즘에 탑재되는 실내 PM_{2.5} 예측모델은 재실자에게 쾌적한 공기질을 제공한다. 이를 위해 예측모델은 이미지 인식, 자연어 처리 및 예측을 포함한 다양한 응용 분야에서 널리 사용되고 있는 ANN (Artificial Neural Network)을 통해 개발되었다. ANN은 지도학습 방법의 하나로 다른 인공지능 모델 보다 데이터의 가용성이 빠르고 효율적인 학습이 가능하다. 또한, 모델이 단순하고 구현과 적용이 용이하여 예측이 안정적이고 시간적 의존성이 강하지 않기 때문에 시간이나 및 재실 패턴이 달라지더라도 높은 정확도를 유지할 수 있다.

1) 데이터 취득 및 학습 데이터세트 구축

미세먼지는 입자형 오염물질로 분류되며 농도 형성에 직접적으로 영향을 미치는 재실 상황 및 의복 상태뿐만 아니라 실내 습도와 CO₂, 실외 미세먼지 농도 등 측정 현장의 다양한 인자들에 의해 농도가 결정된다[32, 33]. 따라서, 예측모델이 보다 정확하게 예측하기 위해서는 실제 적용될 현장의 상황을 고려하여 맞춤형으로 개발될 필요가 있다. 이를 위해 본 연구에서는 제어 알고리즘 실증이 진행될 초등학교 2개 교실의 운영 데이터를 취득하여 학습 데이터세트를 구축하였다. 각 실증지의 스케줄은 평균적으로 일 수업 3회, 휴식 3회, 점심식사 1회가 진행되며, 주 2회 체육활동과 1회 외부활동이 동일하게 진행된다. 또한, 학교시간 이후 매일 청소가 이루어진다.

예측모델 학습에 사용될 데이터는 학교 교실 두 곳에 규칙 기반 제어 알고리즘을 적용하여 1년(1학기, 2학기) 동안 취득된 데이터로 구축되었다. 이때 데이터 취득은 실내외에 설치된 환경센서를 통해 취득되었다. 학습 데이터는 일 재실 시간 평균 실내 PM_{2.5} 농도 5 μg/m³ 이상, CO₂ 농도 600ppm 이상 오전 수업을 2회 이상 진행하였을 때를 동시에 만족하는 데이터 중 재실시간인 8시~16시 30분 사이의 데이터로 선별하였다. 비재실자 시간의 데이터는 ANN 기반으로 개

발되는 예측모델 특성상 성능의 저하를 야기할 수 있기 때문에 학습 데이터에서 제외하였다. 각 오염물질 농도 기준 또한 재실자 유무를 판단하여 예측모델 학습 시 비재실 시간의 데이터를 제외시키기 위한 기준으로 설정되었다. 이를 위해 실증지 환경 데이터 모니터링 분석 결과 재실자가 없는 시간의 평균 실내 PM_{2.5} 농도는 5 μg/m³ 이하로 유지되었으며, 실내 CO₂는 480~600ppm 사이로 유지되는 것을 확인하였다. 이러한 일련의 과정들은 입력변수를 신중하게 선택하는 것이 예측모델의 성능을 향상시킨다는 연구결과를 기반으로 수행되었다[34].

개발에 사용될 학습 데이터세트의 입력변수는 실내 미세먼지 농도 형성에 영향을 미치는 것으로 조사된 여러 주요 인자들 중 센서 측정에 의해 취득이 용이한 실내외 온도, 실내 습도, 실내외 PM_{2.5} 농도, 실내외 PM₁₀ 농도, 실내 PM_{2.5} 농도 변화량과 시스템 급기풍량, 작동 모드를 대상으로 한다. 또한, 운영시간 동안 항시 재실자가 존재하며 활동량에 따라 미세먼지 발생량이 달라지는 교실 특성을 반영하기 위해 실내 CO₂ 농도를 추가하였다. 출력변수는 10분 후의 실내 PM_{2.5} 농도로 정의하였다. 이후 학습 데이터세트는 최솟값과 최댓값을 이용해 데이터 범위를 0과 1 사이로 변환해주는 Min-MaxScaler로 정규화되었으며, Train Data - 60%, Validation Data - 20%, Test Data - 20%로 분류하였다. 이에 대한 자세한 내용은 Table 2.와 같다.

2) 예측모델 최적화 및 하이퍼파라미터 설정

본 연구에서 개발된 ANN 기반 예측모델은 상호 연결된 노드를 통해 정보를 처리하고 전송하는 입력층, 은닉층, 출력층 구조로 이루어져 있다. 이러한 구조는 하이퍼파라미터 설정에 따라 성능이 달라지기 때문에 정확도 향상을 위한 탐색 작업이 진행될 필요가 있다[35]. 개발된 예측모델은 베이지안 최적화 방법으로 하이퍼파라미터 조합을 도출하였다. 베이지안 최적화 방법은 베이스 확률에 기반하여 랜덤하게 샘플링된 하이퍼파라미터 조합에 따른 결과를 관측하고 해당 관측값을 기반으로 우수한 성능 조합을 도출하는 방법으로, 기존에 사용되어 오던 그리드 서치 및 랜덤 서치 보다 탐색 시간이 짧고 범위가 넓다는 장점이 있다. 하지만, 베이지안 최적화 방법은 모델 구조가 정의되어 있어야 적용이 가능하므로 본 연구에서는 Table 3.과 같이 하이퍼파라미터를 구분하고 탐색 범위와 학습 조건을 설정하였다. 이 중 탐색 대상으로는 은닉층 수와 학습률(Learning Rate)을 선정하였으며, 최적화기는 아담(Adam)을 사용하였다. 활성화함수(Activation Function)은 reLu, 손실함수(Loss Function)은 MSE (Mean Square Error)로 설정하였다. 또한, 과적합 방지를 위해 3회 연속 성능 개선이 이루어지지 않으면 학습을 조기 종료하도록 설정했다.

Table 2. Details of the learning data

Data period	
March to July and September to December	
Input data	
Indoor	Temperature, Relative Humidity, CO ₂ concentration, PM _{2.5} concentration, PM ₁₀ concentration, ΔPM _{2.5}
Outdoor System	Temperature, PM _{2.5} concentration, PM ₁₀ concentration Mode, Air Volume
Output data	
PM _{2.5} concentration 10 min later	
Data selection criteria	
- Average indoor PM _{2.5} and CO ₂ concentration during occupancy hours at or above 5μg/m ³ and 600 ppm	
- At least 2 morning indoor classes	
- Data between 08:00 and 16:30	

Table 3. Hyperparameter setting conditions

Hyperparameter	Setting
Hidden neurons	10-100
Hidden layers	1-10
Activation function	ReLU
Learning rate	0.01-0.0001
Type of optimizer	Adam
Loss function	MSE

그 결과 예측모델 최적 구조는 입력층 1개, 은닉층 2개, 출력층 1개로 도출되었으며, 각 층의 노드는 입력노드(11개), 은닉노드(33개, 21개), 출력노드(1개)로 구성되었다.

3) 실내 PM_{2.5} 예측모델 성능

예측모델의 성능은 MAE (Mean Average Error)와 CVRMSE (Coefficient of Variation, Root Mean Square Error), Pearson's r (Pearson correlation coefficient) 세 가지 지표를 통해 검증을 진행하였다. MAE는 오차 절댓값의 평균으로 발생한 오차의 절대적인 크기 의미하고, CVRMSE는 평균제곱근 오차의 변동계수로 실제값과 예측값의 차이를 파악하는 척도이다. 이때 MAE와 CVRMSE 모두 값이 작을수록 예측이 정확하다는 것을 의미한다[36]. Pearson's r의 경우에는 두 변수 간의 선형 관계의 강도와 방향을 측정하기 위한 통계지표 중 하나로, r 값이 0에 가까울수록 두 변수간의 선형 관계가 없는 것으로 해석된다.

초등학교 교실 운영 데이터로 개발된 ANN 기반 실내 PM_{2.5} 예측 모델은 제어 알고리즘에 탑재되어 실제 적용될 초등학교 교실에서 25일간 운영 데이터를 취득하였다. 이후 데이터를 예측모델에 재학습시켜 변수에 대한 적응력을 향상시켰다. 재학습은 발생한 오차에 대한 보정을 통해 정답 값에 만족하기 위한 필요 가중치를 업데이트 하게 되는데, 이러한 지속적인 성능 개선은 데이터의 다양성이 반영 되어 환경 변화에 유연하게 대응할 수 있게 만든다.

그 결과 초기 예측모델의 성능은 MAE 3.18 $\mu\text{g}/\text{m}^3$, CVRMSE 27.27%로 도출되었으며, 재학습한 예측모델은 MAE 2.25 $\mu\text{g}/\text{m}^3$, CVRMSE 19.93%로 나타났다. 이는 ASRAEH에서 제시하는 예측 성능 달성 기준인 CVRMSE 30% 이내를 만족하는 수치이다. Table 4.는 초기 예측모델과 재학습한 예측모델의 성능을 비교하여 분산 형으로 나타내고 성능 향상 정도 표현한 것이다. 예측모델의 성능은 MSE 0.93 $\mu\text{g}/\text{m}^3$, CVRMSE 7.88% 개선되었다.

Table 4. Performance of indoor PM_{2.5} prediction model

	MAE ($\mu\text{g}/\text{m}^3$)	CVRMSE (%)	Pearson's r
Initial model	27.27	3.18	0.84
Retraining model	19.39	2.25	0.94

3. 연구결과

실내 PM_{2.5} 선제적 제어 알고리즘은 재학습된 예측모델을 탑재 후 실제 사용 중인 초등학교 교실 2곳에서 한 달간(6월 15일~7월 20일) 실증을 진행하였다. 이때 교실 한 곳은 예측모델이 탑재되지 않은 규칙 기반 제어 알고리즘이 적용된다. 각 교실은 선생님 1명, 약 21명 학생이 생활하는 보편적인 초등학교 규모를 가진다. 또한, 리모델링 사업을 통해 기밀성능 개선(창문 및 출입문 교체)와 기계적 개선(출입구 에어커튼 설치)가 진행되었다.

3.1. 재실시간 실내 PM_{2.5} 농도

한 달간 진행된 실증을 통해 휴일을 제외하고 총 23일의 시스템 운영 및 실내외환경 데이터가 취득되었다. Fig. 2.는 각 알고리즘별 일평균 PM_{2.5} 농도를 나타낸 그래프이다. 데이터 분석 결과 두 알고리즘 모두 실내공기질 관리법 PM_{2.5} 권고 기준(35 $\mu\text{g}/\text{m}^3$) 이내를 만족하였으며, 대기환경기준 PM_{2.5} 농도 “좋음”(15 $\mu\text{g}/\text{m}^3$)은 선제적 제어 알고리즘 2회, 규칙 기반 제어 알고리즘 7회 만족하지 못한 것으로 나타났다. 또한, 23일 전체 평균 농도는 선제적 제어 알고리즘 9.54 $\mu\text{g}/\text{m}^3$, 규칙 기반 제어 알고리즘 11.52 $\mu\text{g}/\text{m}^3$ 로 선제적 제어 알고리즘이 1.98 $\mu\text{g}/\text{m}^3$ 더 낮았다. 해당 그래프는 일별 평균 농도만을 보여주고 있으므로 분 단위의 자세한 데이터 분석을 추가로 실시하였다.

Fig. 3.은 재실자 스케줄에 따른 실내 PM_{2.5} 평균 농도와 대기환경 기준 PM_{2.5} 농도 “좋음”(15 $\mu\text{g}/\text{m}^3$) 이하로 유지되는 비율을 보여준다. 재실자 스케줄은 수업시간, 쉬는시간, 점심시간, 등하교시간 네 가지 활동으로 구분했다. 먼저 수업시간은 교실 내에서 진행된 수업만이 포함되며, 체육시간과 같은 외부 활동은 분석에서 제외된다. 일 평균 약 45분간 4회 진행된다. 쉬는시간은 수업시간이 끝난 후 약 10분간 3회 진행되며, 점심시간은 매일 50분간 1회 진행된다. 등교시간은 오전 8시 30분부터 수업 시작 시간인 오전 9시까지이며, 하교시간은 교실 스케줄에 따라 모든 일정이 종료된 시간부터 30분 이내를 의미한다.

그 결과 모든 시간대에서 선제적 제어 알고리즘이 규칙 기반 제어 알고리즘 보다 낮은 PM_{2.5} 농도를 유지하는 것으로 나타났다. 그중




Fig. 2. Indoor PM_{2.5} concentration data acquired over 23 days

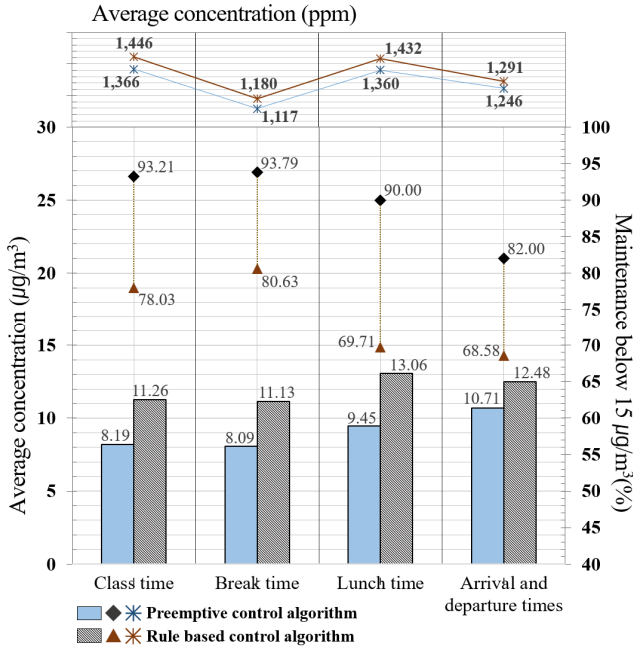


Fig. 3. Indoor PM_{2.5} concentration and maintenance below 15 µg/m³ by occupant schedule

규칙 기반 제어 알고리즘과 가장 큰 차이를 보이는 시간대는 점심시간으로 3.61 µg/m³ 차이가 났다. 또한, 환경부 대기환경기준 PM_{2.5} 농도 “ 좋음”(15 µg/m³) 이하로 유지되는 시간 비율도 선제적 제어 알고리즘이 적용된 교실이 더 길게 유지되는 것으로 나타났다. 규칙 기반 제어 알고리즘이 적용된 교실은 점심시간을 제외하고 80%를 넘기지 못한 반면에 선제적 제어 알고리즘이 적용된 교실은 등하교 시간을 제외하고 모두 90% 이상 유지되었다. 이러한 결과는 등하교 시간대 특성상 실내 PM_{2.5} 농도가 급변하기 때문에 예측의 정확도가 떨어진 결과로 판단된다. 반면 수업시간과 쉬는시간에 성능이 가장 좋게 나타난 이유는 활동량이 가장 적은 시간대인 수업시간에 미세먼지가 침착되고, 그 영향이 바로 다음 쉬는시간에까지 영향을 미치는 것으로 판단된다. 이는 실내 CO₂ 농도를 통해 재실자 활동량 유추 및 분석이 가능하다.

3.2. 선제적 제어 효과

실내 PM_{2.5} 선제적 제어 알고리즘은 탑재된 예측모델의 예측값과 실시간 실내공기질에 따라 제어를 수행한다. 이때 선제적 제어란 미래의 실내 PM_{2.5} 농도를 예측하여 시스템을 미리 가동시키거나, 가동 풍량에 변화를 주는 등의 행동을 의미한다. 즉, 기준치 농도가 아님에도 시스템이 실내 PM_{2.5} 농도를 저감시키기 위해 가동되는 것을 의미한다. 이러한 선제적 제어는 가동시간을 증가시키지만 재실시간 중 피크 농도를 낮출 수 있다는 장점이 있다. Table 5는 실내 PM_{2.5} 농도와 CO₂ 농도가 쾌적 범위일 때 각 제어 알고리즘 별 PM_{2.5} 농도 범위와 쾌적 유지시간, 시스템 가동시간을 나타낸 내용이다. 이때 PM_{2.5}와 CO₂ 농도를 같이 고려한 것은 CO₂ 농도에 따른 시스템 제어를 배제하고, 예측값에 따른 시스템 제어 성능만을 분석하기 위함이다.

그 결과, 실내 PM_{2.5} 10 µg/m³ 이하 및 CO₂ 1500ppm 이하로 유

Table 5. Indoor PM_{2.5} concentration comfort maintenance time and system operation time for each control algorithm (Data criteria: Indoor PM_{2.5} concentration below 10 µg/m³ and CO₂ concentration below 1500ppm)

	Total period (minute)	Uptime (minute)	Average prediction value (µg/m ³)
Preemptive control algorithm	3021	872	13.03
Rule based control algorithm	264	24	-

지된 시간은 선제적 제어 알고리즘이 3021분, 규칙 기반 제어 알고리즘은 264분으로 선제적 제어 알고리즘이 약 11.44배 길었다. 그중 시스템이 작동된 시간은 선제적 제어 알고리즘이 872분, 규칙 기반 제어 알고리즘 24분으로 선제적 제어 알고리즘이 약 36.33배 더 많이 가동된 것으로 나타났다. 이는 선제적 제어 알고리즘이 실내 PM_{2.5}를 저농도로 유지하는 것에 효과적이지만, 총 가동시간은 길어짐에 따라 에너지 소비량을 크게 증가시킬 가능성이 있음을 시사한다. 하지만, 본 연구에서는 에너지 계측을 진행하지 않았으므로 추후 진행될 연구에서 제어 알고리즘 및 스케줄별 에너지 사용량 분석이 진행될 예정이다.

4. 결론

본 연구의 목적은 재실자에게 보다 쾌적한 실내 공기질을 제공할 수 있는 제어 기술을 개발하는 것이다. 이를 위해 실내 환기 및 공기 청정기의 통합 제어가 가능한 실내 PM_{2.5} 선제적 제어 알고리즘과 이에 탑재되는 실내 PM_{2.5} 예측모델을 개발하였다. 개발된 제어 알고리즘은 실제 사용 중인 초등학교 교실에서 실증을 진행하며 PM_{2.5} 국내 권고 기준 충족 여부와 제어 알고리즘 자체의 성능을 비교 분석하였다. 주요 결과를 종합하면 다음과 같다.

1. 실증이 진행된 23일간 실내 PM_{2.5} 평균 농도 분석 결과 선제적 제어 알고리즘이 적용된 교실은 9.54 µg/m³, 규칙 기반 제어 알고리즘이 적용된 교실은 평균 11.52 µg/m³로 선제적 제어 알고리즘이 적용된 교실이 더 낮은 농도를 유지하는 것으로 나타났다.
2. 재실 스케줄별 실내 PM_{2.5} 농도 분석 결과 선제적 제어 알고리즘이 모든 시간대에서 규칙 기반 제어 알고리즘 보다 낮은 PM_{2.5} 농도를 보임. 특히, 환경부 대기환경기준 PM_{2.5} 농도 “ 좋음” 이하로 유지되는 시간은 등하교시간을 제외하고 90% 이상으로 유지되는 것을 확인함. 이러한 결과는 실내 PM_{2.5} 쾌적 범위 유지뿐만 아니라 재실자에게 PM_{2.5} 노출을 최소화할 수 있음을 의미함.
3. 실내 PM_{2.5} 및 CO₂ 모두 쾌적 범위 이내로 만족시키는 시간은 선제적 제어 알고리즘이 규칙 기반 제어 알고리즘 보다 약 11.44배 긴 것으로 나타남. 하지만 선제적 제어 알고리즘의 가동시간이 더 길게 나타났는데, 이는 미래의 실내 PM_{2.5} 농도를 예측하여 선제적으로 가동된 결과임.

본 연구에서 도출된 결과를 통해 재실자의 PM_{2.5} 노출을 최소화하고 재실자 건강 증진과 면역력 확보에 기여할 수 있을 것으로 사료된다. 다만, 본 연구에서 개발된 제어 알고리즘은 실내환경 요소 중 PM_{2.5} 저감에만 초점을 두고 있기 때문에 추후 실내 온도에 따른 재실자 면역력과 환기에 따른 냉난방 부하를 고려할 필요가 있다. 이에 대한 후속연구로 실내공기질과 열환경을 통합적으로 예측하고 제어할 수 있는 알고리즘의 개발과 제어 효율성 향상을 위한 에너지 사용량 측면에서의 분석이 진행될 예정이다.

Acknowledgement

이 논문은 2021년도 중앙대학교 연구장학기금 지원에 의한 것임.

References

- [1] K. Bradford, J. Coleman, F. Meggers, Understanding the gap between efficiency and comfort, 2022 IEEE International Workshop on Metrology for Living Environment (MetroLivEn), 2022.05, pp.180-185.
- [2] W.J. Fisk, A.T. De Almeida, Sensor-based demand-controlled ventilation: A review, *Energy and Buildings*, 29(1), 1998.12, pp.35-45.
- [3] D.J. Moschandreas, S.C. Sofuoglu, The indoor environmental index and its relationship with symptoms of office building occupants, *Journal of Air & Waste Management Association*, 54(11), 2004, pp.1440-1451.
- [4] D.G. Shendell et al., Associations between classroom CO₂ concentrations and student attendance in Washington and Idaho, *Indoor Air*, 14(5), 2004.10, pp.333-341.
- [5] J.A. Leech et al., It's about time: A comparison of Canadian and American time-activity patterns, *Journal of Exposure Science & Environmental Epidemiology*, 12(6), 2002.11, pp.427-432.
- [6] WHO (World Health Organization), Household air pollution and health, <https://www.who.int/en/news-room/fact-sheets/detail/household-air-pollution-and-health>, 2022.10.16.
- [7] CDC (Centers for Disease Control and Prevention), Ventilation in buildings, <https://www.cdc.gov/coronavirus/2019-ncov>, 2021.06.02.
- [8] 질병관리청, 중앙재난안전대책본부 [별지] 생활 속 거리 두기 기본지침, 2020. // (Korea Disease Control and Prevention Agency, Central Disaster and Safety Countermeasures Headquarters [Appendix] Basic guidelines for distancing in daily life, 2020)
- [9] WHO (World Health Organization), Global air quality guidelines: Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide, 2021.
- [10] UNEP (UN Environment Programme), Actions on air quality: A global summary of policies and programmes to reduce air pollution, 2021.
- [11] WHO (World Health Organization), Guidelines for indoor air quality: Selected pollutants, 2010.
- [12] K.E. Nachman, J.D. Parker, Exposures to fine particulate air pollution and respiratory outcomes in adults using two national datasets: A cross-sectional study, *Environmental Health*, 11, 2012.04, 25.
- [13] R.D. Brook et al., Particulate matter air pollution and cardiovascular disease: An update to the scientific statement from the American Heart Association, *Circulation*, 121(21), 2010.06, pp.2331-2378.
- [14] 경선영 외 8인, 미세먼지/황사 건강피해 예방 및 권고지침: 호흡기질환, 대한의사협회지, 제58권 제11호, 2015.01, pp.1060-1069. // (S.Y. Kyung et al., Guideline for the prevention and management of particulate matter/Asian dust particle induced adverse health effect on the patients with pulmonary diseases, *Journal of the Korean Medical Association*, 58(11), 2015.01, pp.1060-1069.)
- [15] Y.M. Kim et al., Effects of exposure to indoor fine particulate matter on atopic dermatitis in children, *International Journal of Environmental Research and Public Health*, 18(21), 2021.11, 11509.
- [16] WHO (World Health Organization), Newly found health effects of air pollution call for stronger European Union air policies, <https://www.who.int/europe/news/item/31-01-2013-newly-found-health-eff>
- [17] 최연희, 송두삼, 공기청정모드를 가지는 환기시스템의 주거건물 실내외 미세먼지 및 실내 CO₂ 농도를 고려한 제어전략, 설비공학논문집, 제31권 제12호, 2019.12, pp.568-575. // (Y.H. Choi, D.S. Song, Control strategy of ventilation system with air filtration mode considering indoor and outdoor air quality in residential buildings, *Korean Journal of Air-Conditioning and Refrigeration Engineering*, 31(12), 2019.12, pp.568-575.)
- [18] M.J. Alonso, W.S. Dols, H.M. Mathisen, Using co-simulation between EnergyPlus and CONTAM to evaluate recirculation-based, demand-controlled ventilation strategies in an office building, *Building and Environment*, 211, 2022.03, 108737.
- [19] W. Yuchi et al., Evaluation of random forest regression and multiple linear regression for predicting indoor fine particulate matter concentrations in a highly polluted city, *Environmental Pollution*, 245, 2019.02, pp.746-753.
- [20] Y. Zhou, G. Yang, A predictive model of indoor PM_{2.5} considering occupancy level in a hospital outpatient hall, *Science of the Total Environment*, 844, 2022.10, 157233.
- [21] T. Shi et al., LASSO and attention-TCN: A concurrent method for indoor particulate matter prediction, *Applied Intelligence*, 53(17), 2023.09, pp.20076-20090.
- [22] Y. Peng et al., Hybrid system controls of natural ventilation and HVAC in mixed-mode buildings: A comprehensive review, *Energy and Buildings*, 276, 2022.12, 112509.
- [23] F. Belic, Z. Hocenski, D. Sliskovic, HVAC control methods - A review, 2015 19th International Conference on System Theory, Control and Computing (ICSTCC), 2015.10, pp.679-686.
- [24] 환경부, 실내공기질 관리법 시행규칙 (환경부령 제1082호) [별표 2] 실내공기질 유지기준, 2024. // (Ministry of Environment, Enforcement Rules of the Indoor Air Quality Management Act [Appendix 2] Indoor Air Quality Maintenance Standards, 2024)
- [25] 수도권대기환경청, 대기환경 기준, <https://www.me.go.kr/mamo/web/index.do?menuId=586>, 2024.11. // (Metropolitan Air Quality Management Office, Air quality standards, <https://www.me.go.kr/mamo/web/index.do?menuId=586>, 2024.11.)
- [26] L. Guo, J.O. Lewis, Carbon dioxide concentration and its application on estimating the air change rate in typical Irish houses, *International Journal of Ventilation*, 6(3), 2007, pp.235-245.
- [27] S.D. Lowther, Low level carbon dioxide indoors—A pollution indicator or a pollutant? A health-based perspective, *Environments*, 8(11), 2021.11, 125.
- [28] H.S. Alavi, S. Zhong, D. Lalanne, Predictive models of indoor carbon dioxide concentration to prevent daily decay of productivity and well-being in shared offices, *SmartPhil* 2020, 2020.03, pp.59-68.
- [29] T.K. Kanatani et al., Indoor particle counts during Asian dust events under everyday conditions at an apartment in Japan, *Environmental Health and Preventive Medicine*, 19, 2014.01, pp.81-88.
- [30] H.W. Kuo, H.Y. Shen, Indoor and outdoor PM_{2.5} and PM₁₀ concentrations in the air during a dust storm, *Building and Environment*, 45(3), 2010.03, pp.610-614.
- [31] H. Krasnov et al., Increased indoor PM concentrations controlled by atmospheric dust events and urban factors, *Building and Environment*, 87, 2015.05, pp.169-176.
- [32] P. Wargoki et al., Sensory pollution loads in six office buildings and a department store, *Energy and Buildings*, 36(10), 2004.10, pp.995-1001.
- [33] P. Kumar, B. Imam, Footprints of air pollution and changing environment on the sustainability of built infrastructure, *Science of the Total Environment*, 444, 2013.02, pp.85-101.
- [34] S. Brandi et al., Deep reinforcement learning to optimise indoor temperature control and heating energy consumption in buildings, *Energy and Buildings*, 224, 2020.10, 110225.
- [35] H.U. Cho et al., Comparative analysis of the optimized ANN, SVM, and tree ensemble models using Bayesian optimization for predicting GSHP COP, *Journal of Building Engineering*, 44, 2021.12, 103411.
- [36] K.P. Murphy, *Machine learning: A probabilistic perspective*, Massachusetts: MIT Press, 2012.