

# 멀티 에이전트 강화학습 기반 에너지 및 실내환경 통합 최적 제어 모델 개발 및 중간기 판매시설 실증

김준섭, 김선호, 문현준\*  
단국대학교

jskim24@dankook.ac.kr, sinocap@dankook.com, \*hmoon@dankook.ac.kr

## Field Demonstration of a MARL-Based Multi-Zone Control of Energy and Indoor Environmental Quality in a Commercial Building During the Shoulder Season

Jun-Sub Kim, Sun Ho Kim, Hyeun Jun Moon\*  
Dankook Univ.

### 요 약

본 연구는 대형 상업용 건물의 에너지 효율과 실내 쾌적성을 동시에 최적화하는 멀티에이전트 강화학습(MARL) 기반 제어 전략을 제안한다. 이를 위해, Modelica, EnergyPlus, 그리고 딥러닝 기반 PM2.5 Surrogate Model 을 통합한 Co-simulation 환경을 구축하였으며, 이 환경에서 각 공조 구역을 담당하는 독립적인 제어 에이전트를 학습시켰다. 개발된 MARL 모델을 서울시 노원구 소재의 대형마트에 적용한 결과, 일반 제어 대비 AHU 의 에너지를 36.1% 절감하면서 모든 실내환경 지표를 쾌적 범위 내로 안정적으로 유지하여 개선된 성능을 검증하였다.

### I. 서 론

#### 1.1 연구 배경

건물 부문은 국가 총에너지 소비의 상당 부분을 차지하고 있으며, 그중 상업용 건물의 에너지 사용 비중이 지속적으로 증가하고 있다[1]. 특히, 상업용 건물 중 대형 판매시설은 넓은 공간, 단위면적 당 다수의 설비 및 조명 부하 집중, 불규칙한 재실자 패턴으로 인해 Heating, Ventilation, and Air Conditioning (HVAC) 시스템의 에너지 소비가 크다[2].

기존 건물 자동화 시스템(Building Automation System, BAS)된 건물들은 고정된 설정값과 스케줄로 HVAC 를 운영한다. 이는 실시간으로 변화하는 환경 요인에 능동적으로 대응하지 못하여 과도한 에너지 소비를 유발하거나 재실자 쾌적성을 저해한다[2]. 이를 해결하기 위하여, 본 연구에선 대형 판매시설의 HVAC 공조 구역별 운영 특성을 고려한 강화학습 모델을 개발 및 적용하여 성능을 평가하였다.

#### 1.2. 연구 목표

다수의 Zone 에서 발생하는 모든 변수를 하나의 에이전트가 관찰하고 제어해야 하므로, State-Action 공간이 커지는 문제에 직면하기 때문에[4] 기존의 단일 에이전트 강화학습을 대형 건물 전체에 직접 적용하는 것은 현실적인 어려움이 따른다.

이러한 한계를 극복하기 위해, 본 연구는 각 공조기(Air Handling Unit, AHU)에 개별 에이전트를 할당하여 문제를 분산적으로 해결하는 멀티 에이전트 강화학습(Multi-Agent Reinforcement Learning, MARL) 프레임워크를 활용한다. 이를 통해 MARL 기반 제어 모델을 상업용 건물에 적용하여, 에너지 절감과 실내 쾌적성 유지를 동시에 달성하는 것을 목표로 한다.

### II. 본론

#### 2.1 Co-simulation Environment 구축

대상 건물의 에너지 및 실내환경 거동을 모사하기 위해 세 가지 모델을 결합한 Co-simulation 환경을 구축했다. 건물의 외피, 내부 발열 등 열적 특성은 EnergyPlus 로 모델링했으며, 냉온수기, AHU 등 HVAC 설비는 Modelica 로 구현했다. 실내 PM2.5 농도는 실측 데이터를 학습한 딥러닝 기반 Surrogate Model 을 활용하였다. Surrogate Model 은 외기 PM2.5, 외기 댐퍼 개도율, 재실자 수, 공기청정기 가동 상태를 입력 변수로 사용한다. 구축된 세가지 모델은 Python 환경에서 연동되며, 매 10 분마다 시뮬레이션을 수행한다.

#### 2.2 MARL 구조 설계

본 연구에서는 건물의 각 Zone 에 독립적인 Double Deep Q-Network(DDQN) 기반 에이전트를 할당했다. 각 에이전트는 담당 Zone 의 상태를 관찰하여 해당 AHU 를 제어할 수 있도록, 아래와 같이 State, Action, Reward 를 설계했다.

Table 1. MARL 구조

구분	상세 내용
State	<ul style="list-style-type: none"> <li>실외 환경: 온도, 습도, 엔탈피, CO<sub>2</sub>, PM2.5</li> <li>실내 환경: 온도, 습도, 엔탈피, CO<sub>2</sub>, PM2.5, 재실자 수</li> <li>제어/설비: 외기 댐퍼 개도율, 설비 가동 상태, AHU/공기청정기 전력 사용량</li> </ul>
Action	<ul style="list-style-type: none"> <li>외기 댐퍼: 3 단계 (0, 50, 100%)</li> <li>AHU 가동: 2 단계 (정지/가동)</li> <li>공기청정기 가동: 2 단계 (정지/가동)</li> </ul>
Reward	<ul style="list-style-type: none"> <li><math>R_{total} = R_{temperature} + R_{humidity} + R_{CO2} + R_{PM2.5} + R_{energy}</math></li> <li>Indoor Environment (temperature, humidity, CO<sub>2</sub>, PM2.5): 설정된 쾌적 범위를 만족할 경우 Positive Reward, 설정된 쾌적 범위를 벗어날 경우 비례하여 Negative</li> </ul>

Reward 부여
• Energy: 정규화된 에너지 사용량에 비례하여 Negative Reward 부여

### 2.3. 시뮬레이션을 통한 정책 학습 및 검증

제안된 MARL Control 의 성능을 정량적으로 검증하고자, Co-simulation 환경에서 환절기 조건을 대상으로 일반 제어(스케줄 기반 제어) 와의 비교 시뮬레이션을 수행하였다. 성능 평가 기준은 에너지 소비량과 실내 환경 쾌적 여부를 기준으로 분석하였다.

시뮬레이션 결과, 일반제어 대비, MARL Control 은 에너지 절감과 실내 쾌적성 유지라는 두 가지 목표 모두 달성하였다. 에너지 측면에서, 일반제어 방식 대비 AHU 에너지 사용량을 70.4%, 공기청정기 전력 사용량을 30.5% 절감하였다. 에이전트가 실내 환경이 쾌적하고 재실 부하가 낮은 상황을 인지하여 불필요한 설비가동을 중지한 결과로 분석된다. 동시에, 운영 시간 동안 Figure 1, Figure 2와 같이 실내 온도, 상대 습도, CO<sub>2</sub>, PM2.5 지표는 목표 쾌적 범위를 유지하였다.




Figure 1. MARL Control 시뮬레이션 결과(온도, 습도)




Figure 2. MARL Control 시뮬레이션 결과(CO<sub>2</sub>, PM2.5)

### 2.4. 건물 적용 및 성능 평가

시뮬레이션으로 학습된 MARL 모델의 실효성을 검증하기 위해, 중간기에 서울시 노원구에 위치한 대형마트에 적용하여 실험을 진행하였다. MARL 모델은 해당 건물 BAS 와 API 로 연동되어 10 분 단위로 State 값을 전달받고 이를 통해 도출된 Action 신호를 BAS 로 전송하였다.




Figure 3. 실제 건물 AHU 에너지 소비량 비교



Figure 4. 실제 건물 공기청정기 에너지 소비량 비교

성능 평가는 일반 제어와 제안된 MARL Control 방식을 적용하여 운전 데이터를 비교 분석하는 방식으로 진행하였다. Figure 3과 같이, AHU(공조기)의 에너지 소비량은 기존 방식 대비 36.1% 절감되었다. 또한 Figure 4에서 볼 수 있듯이, 공기청정기의 에너지 소비량은 13.0% 절감하는 효과를 확인하였다. 동시에 모든 제어 구역의 온도, 습도 및 공기질 지표는 설정된 쾌적 범위 내에서 안정적으로 유지되어, 에너지 절감과 실내 쾌적성 목표를 동시에 달성하였음을 확인하였다.




Figure 5. 실제 건물 MARL Control 결과(CO<sub>2</sub>, PM2.5)

### III. 결론

본 연구는 대형 상업용 건물 제어에서 발생하는 단일 에이전트 강화학습의 확장성 한계를 극복하기 위해, 각 공조 구역을 독립적으로 제어하는 MARL 프레임워크를 제안하고 그 실효성을 검증하였다. 이를 위해 Modelica, EnergyPlus 와 딥러닝 기반의 PM2.5 Surrogate Model 을 결합하여 실제와 유사한 Co-simulation 환경을 구축하였다.

MARL Control 은 시뮬레이션 일반 제어 대비 AHU 에너지 70.4% 절감과 안정적으로 실내 쾌적을 유지하였다. 이후, 시뮬레이션으로 학습된 제어 모델을 실제 건물에 적용하여 36.1%의 에너지 절감 효과를 달성하였다. 시뮬레이션 대비 실제 건물의 에너지 절감률 차이는 이상적인 환경과 동적으로 변동하는 현실 간의 차이에 기인한다. MARL 에이전트가 시뮬레이션에는 없던 환경의 동적 변화에 적응하며 제어했음을 보여주는 결과로 분석된다.

본 연구의 의의는 Zone 별 분산 제어 전략이 대형 건물의 복잡한 제어 문제를 해결하고, 시뮬레이션 기반 학습 모델이 실제 건물 설비 시스템에서도 작동함을 보인 데에 있다. 향후 연구에서는 계절별 성능 검증, 다양한 건물 유형으로의 확장을 통해 발전시킬 계획이다.

### ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구과제입니다. (No. RS-2021-KP002461)

### 참 고 문 헌

- [1] 김기중, & 이창효. (2019). 건물용도별 냉방에너지 소비량 차이에 관한 연구. *서울도시연구*, 20(2), 91-103.
- [2] Li, H., & Li, X. (2018). Benchmarking energy performance for cooling in large commercial buildings. *Energy and Buildings*, 176, 179-193.
- [3] Xue, W., Jia, N., & Zhao, M. (2025). Multi-agent deep reinforcement learning based HVAC control for multi-zone buildings considering zone-energy-allocation optimization. *Energy and Buildings*, 329, 115241.
- [4] Wang, Z., Xiao, F., Ran, Y., Li, Y., & Xu, Y. (2024). Scalable energy management approach of residential hybrid energy system using multi-agent deep reinforcement learning. *Applied Energy*, 367, 123414.