

HVAC 시스템 대상 제어 설정값 최적화를 위한 데이터 기반 예측 모델 개발에 대한 연구

박석민 · 이제현[†]
부경대학교(학생) · [†]부경대학교(교수)

A Study on the Development of a Data-Based Prediction Model for Optimal Control in HVAC System

Seok-Min PARK · Je-Hyeon LEE[†]
Pukyong National University(student) · [†]Pukyong National University(professor)

Abstract

This paper proposes a method to supplement the lack of operation data according to various control settings in the development of data-based prediction models for heating, ventilation & air conditioning (HVAC) system optimal control. Multiple linear regression (MLR) was used to develop a performance prediction model of the target device, and a simulation model of the heat source system was developed in connection with this. In order to secure sufficient learning data for the development of predictive models through simulation, we generated operation data for various boundary conditions and control settings, developed a Deep Neural Network (DNN) model, and improved predictive performance through hyper parameter optimization.

Key words : Data-based prediction model, DNN, HVAC, Learning data, Optimal control

I. 서론

지구 온난화에 대응하여 전 세계적으로 온실가스 배출량 감소를 위해 많은 노력과 투자를 하고 있지만, 온실가스 배출량은 매년 증가하는 추세이다. 2020년 COVID-19 팬데믹으로 인해 온실가스 배출량이 일시적으로 감소하였으나, 팬데믹 이후 대부분의 제한 조치가 완화되고 경제 활동이 회복됨에 따라 다시 급격히 증가하였다. 2020년 한국의 온실가스 배출량은 팬데믹의 영향으로 인해 656.2백만톤으로 전년 대비 6.5% 감소하였으나, 2021년 679.6백만톤으로 다시 증가하는 추

세를 보였다(ME, 2022). 국회예산정책처에서는 22년의 온실가스 배출량도 전년 대비 증가할 것으로 예측하고 있다(NABO, 2023). 한국의 총 온실가스 배출량 중 건물 분야가 차지하는 비중은 직접 배출량 7%, 직간접 배출량 24.6%이며, 이는 건물의 대형화 및 고층화로 인해 계속해서 증가하는 추세이다(KEEI, 2022). 건물 분야에서의 에너지 절감을 위해서는 약 절반을 차지하고 있는 공조시스템에 대한 에너지 절감 대책이 필수적으로 요구되고 있다.

공조시스템에 대한 에너지 절감 대책 중 하나로 예측 모델 기반의 제어 최적화에 대한 연구가

[†] Corresponding author : 051-659-6175, ljh8993@pknu.ac.kr

* 이 논문은 부경대학교 자율창의학술연구비(2022년)에 의하여 연구되었음.

활발히 진행되고 있다. 선행연구에 의하면 예측 모델 기반의 제어 최적화를 실시함으로써 에너지 소비량과 운영 비용을 6% ~ 73% 절감할 수 있다고 한다(Afram A, et al., 2017). 기존의 제어 및 운영 상태에 따라 에너지 절감 효과는 큰 차이를 보이고 있으나, 기기의 교체 없이 부하 조건에 따른 설정값 제어 최적화만으로 높은 에너지 절감 효과를 얻을 수 있다는 점에서 상당히 유용하다.

일반적으로 공조시스템의 에너지소비량 예측 모델은 크게 물리 기반 모델과 데이터 기반 모델로 나눌 수 있다(Ding Y, et al., 2017). 열역학 제 1법칙을 기반으로 한 물리 기반 예측 모델을 개발하기 위해서는 기기의 작동 원리 및 관련 물리학에 대한 상세한 이해가 필요하다(Afram A, et al., 2014). 반면 데이터 기반 방법은 다양한 예측 모델(support vector machines (SVM), artificial neural network(ANN), random forest (RF) 등)을 사용하여 입력력 데이터 간의 관계를 학습하여 예측한다. 그러므로 다양한 변수를 이용해 복잡한 상호작용을 예측하는 모델을 개발할 수 있으며, 전문지식을 바탕으로 한 판단이나 보정 작업 없이 높은 예측 정확도를 도출할 수 있다(Ra et al., 2023). 최근에는 건물 에너지 효율화를 위해 BEMS(Building Energy Management System)를 도입하는 건물이 증가하고 있어 냉난방, 환기, 조명과 같은 건축 설비에 대한 운전데이터 및 에너지 데이터를 입수하는 것이 가능하여 데이터 기반 방법이 많이 채용되고 있다.

하지만 데이터 기반 방법은 데이터 품질 및 양에 따라 예측 정확도가 제한된다는 문제가 있다. 예를 들어, 신축 건물의 경우 BEMS가 설치되어 운전데이터 및 에너지데이터를 저장하고 있어도 저장기간이 짧아 충분한 양의 데이터를 얻기 어렵다(Ahn and Kim, 2022). 그리고 과거 데이터에 기반하므로 새로운 조건에서는 예측 정확도가 낮아질 수 있다. 특히, 공조시스템의 제어 설정값 최적화(이하, 최적 제어)를 위한 데이터 기반 예

측 모델을 개발하기 위해서는 제어 설정값을 변경하며 운전한 데이터가 필요하나, 실제 건물에서는 설계 시 계산한 최대 열부하를 통해 선정하거나 관리자의 경험에 의해 선정한 값을 연간 변경 없이 운전하고 있어 모델 개발에 적절한 학습 데이터를 입수하는 것이 어려운 실정이다. 그리고, 기존의 데이터 기반 방법을 이용한 최적 제어에 대한 연구는 대부분 예측 모델의 높은 예측 정확도를 도출하기 위한 매개변수의 최적화에 중점을 두고 있으며, 수집이 어렵거나 부족한 학습 데이터를 보완하기 위한 연구는 부족한 실정이다(Ahn and Kim, 2022).

본 연구에서는 최적 제어를 위한 데이터 기반 예측 모델 개발에 있어 다양한 제어 설정값에 따른 운전데이터가 부족한 경우, 이를 보완할 수 있는 방안을 제안하였다. 모델 구축이 비교적 간단하며 적은 데이터로 기기 성능 예측 성능이 우수한 Multiple Linear Regression(MLR)을 사용하여 대상 기기의 성능 예측 모델을 개발하고, 이를 연동하여 열원시스템에 대한 시뮬레이션 모델을 개발하였다. 시뮬레이션을 통해 각종 경계조건 및 제어 설정값에 대한 운전데이터를 생성하여 예측 모델 개발에 필요한 충분한 학습데이터를 확보하였다. 예측 모델로 인공신경망(Artificial Neural Network, ANN) 모델 중 다중 은닉층을 가지는 DNN(Deep Neural Network) 모델을 활용하여 개발하였고 하이퍼 파라미터 최적화를 통해 예측 성능을 향상하였다.

II. 연구 방법

1. 대상 건물 및 HVAC system

수원에 위치한 대상 건물은 소규모 소매점, 식당, 사무실, 강당 및 외부 회의실 등으로 구성된 오피스 건물로 지하 5층, 지상 27층 포디움 동 2개로 구성되어 있다. 건물 연면적은 309,980 m², 재실자 수는 약 1만명에 달한다. 본 연구에서는

알고리즘 적용으로 인해 발생할 수 있는 실내 온도 습도 문제를 고려하여 포디움 공조를 담당하는 열원시스템을 대상으로 하였다.

대상 열원시스템은 water cooled VRF(Variable refrigerant flow) 시스템이며, 실외기 17대와 냉각탑 2대, 냉각수 펌프 3대로 구성되어 있다. 각 기기 사양을 <Table 1>에 나타낸다. 실외기는 R410A 냉매를 사용하고 있으며, digital scroll과 FVI scroll 압축기를 탑재한 모델이다. 냉방 능력은 4대가 116 kW, 5대가 145 kW, 8대가 174 kW이다. 소비전력은 각각 23.2 kW, 29.0 kW, 34.8 kW로, 모두 EER 5.0의 기기이다. 냉각탑은 냉각 능력 2476.7 kW이며, 냉각수 유량은 426 m³/h이다. 냉각탑 1대당 fan이 3개가 설치되어 있으며, 각 fan의 풍량은 6,444 m³/h이다. 냉각수 펌프는 정격유량이 426 m³/h이며, 인버터가 탑재되어 변유량 제어가 가능하다. 냉각탑 fan 제어와 냉각수 펌프의 변유량 제어에 대한 방법은 아래와 같다.

- Control of cooling tower fan : 냉각탑 출구 냉각수 온도가 설정값에 도달하도록 냉각탑 팬의 속도(high, low)와 대수를 제어한다.

- Control of cooling water flow : 말단배관의 압력이 설정값에 도달하도록 PI 제어를 통해 냉각수 펌프 주파수를 변경하여 냉각수 유량을 제어한다.

2. 시뮬레이션 구축 및 학습데이터 생성

본 Section에서는 인공지능망 모델 구축에 필요한 초기 학습데이터를 생성하기 위해, 대상 열원 시스템에 대한 시뮬레이션을 개발하였다. 시뮬레이션의 Flow chart를 [Fig. 1]에 나타낸다. Flow chart의 좌측은 입력값을, 우측은 출력값을 나타낸다. 시뮬레이션은 실외기가 처리한 열량, 즉 실내 부하(kWh)와 외기 습구온도(°C), 그리고 제어 설정값인 냉각탑 출구 냉각수 온도(°C)와 냉각수 계통 배관 차압(mmAq)을 입력하여 각 기기의 전력 소비량(kWh)을 산출한다.

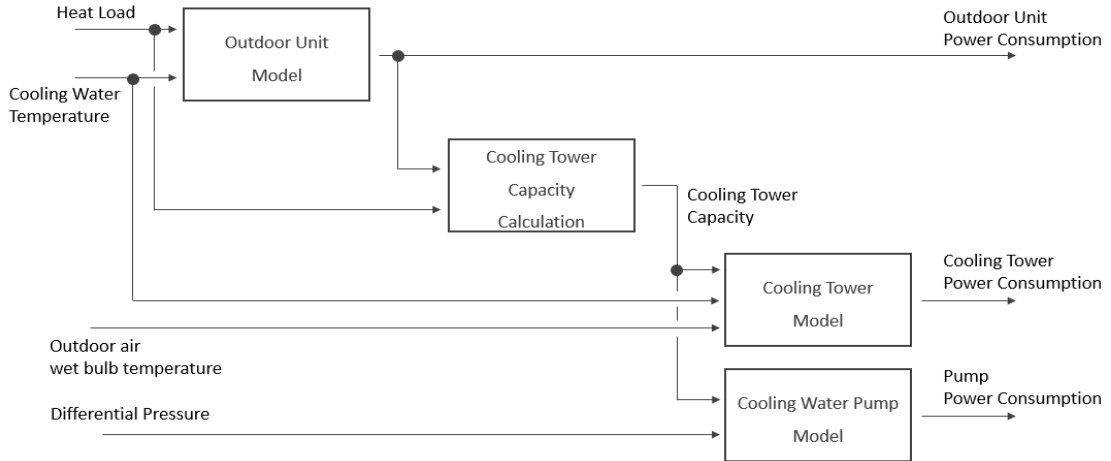
각 기기 모델은 적은 데이터로 기기의 성능 특성을 잘 나타낼 수 있는 MLR 기반 Empirical model을 개발하였다. 기기 모델 식의 형태는 아래 식과 같다.

$$y(x_1, x_2) = c \cdot (\alpha_1 + \alpha_2 \cdot x_1 + \alpha_3 \cdot x_1^2 + \alpha_4 \cdot x_2 + \alpha_5 \cdot x_2^2 + \alpha_6 \cdot x_1 \cdot x_2)$$

x_1, x_2 는 모델의 입력변수로 물리 기반 모델을 참고하여 기기의 에너지소비량에 영향을 미치는 경계조건과 제어 설정값을 선정하였다. 실외기 모델의 입력변수는 실내 부하와 냉각수 출구 온도이며, 냉각탑 모델의 입력변수는 냉각수 출구

<Table 1> Equipment Specification

Equipment	Quantity (EA)	Specification
Water cooled VRF outdoor units	17	Refrigerant : R410A, Compressor : Digital scroll + FVI scroll Cooling capacity : 116 kW (4EA), 145 kW (5EA), 174 kW (8EA), Rated power : 23.2 kW, 29.0 kW, 34.8 kW, EER : 5.0 Cooling water flow : 22.8 m ³ /h, 28.5m ³ /h, 34.2m ³ /h
Cooling Tower	2	Cooling capacity : 2,476.7 kW, Cooling water flow : 426 m ³ /h, Cooling water inlet temperature : 32°C, Cooling water outlet temperature : 37°C Number of fans : 3 EA, Air volume per fan : 6,444 m ³ /h, Fan rated power : 30 kW
Cooling Water Pump (Inverter)	3	Cooling water flow : 426 m ³ /h, Head : 30m, Moter : 55kW



[Fig. 1] Simulation Flow Chart.

온도와 외기 습구온도차인 Cooling approach temperature와 냉각탑 처리열량이고, 냉각수 펌프 모델의 입력변수는 냉각탑 처리 열량과 배관 차압이다. y 는 각 기기의 에너지소비량이다. $\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5, \alpha_6$ 은 Regression coefficient (-)이며, c 는 Calibration coefficient (-)이다.

Regression coefficient는 2015년 데이터를 바탕으로 최소자승법을 이용하여 산출하였다. 그리고 15년과 현재의 기기 성능 차이를 보정 하기 위해 2022년 데이터를 이용하여 Calibration coefficient

를 산출하였다. 각 모델의 Regression coefficient와 Calibration coefficient를 <Table 2>에, 모델 정확도를 나타내는 Coefficient of the Variation of the Root Mean Square Error (CVRMSE) 및 결정 계수 R^2 값을 <Table 3>에 나타낸다. 각 기기의 Calibration coefficient는 실외기가 1.34, 냉각탑이 1.19, 냉각수 펌프가 1.09이다. 모든 기기가 1.0보다 큰 값이 산출되었으며, 이는 동일 경계조건에서 2015년보다 2022년의 기기 전력 소비량이 증가했음을 의미한다.

<Table 2> Regression coefficient and Calibration coefficient of Equipment

	Regression coefficient						Calibration coefficient
	α_1	α_2	α_3	α_4	α_5	α_6	c
Outdoor Unit	-42.25977	4.92163	-0.12947	-0.06958	-0.000007	0.00978	1.34
Cooling Tower	28.41861	-7.69810	0.42334	0.05969	-0.000008	-0.00193	1.19
Cooling Water Pump	40.13495	-0.07147	0.00002	-61.48010	17.97997	0.06436	1.09

<Table 3> Simulation Accuracy

	Outdoor Unit	Cooling Tower	Cooling Water Pump
CVRMSE [%]	17.3	22.2	13.2
R^2 [-]	0.89	0.81	0.95

<Table 4> Type and Range of Input values


Input values	Range	Total number of data
Heat load	381.0 kWh - 1905.2 kWh (interval 381.0 kWh)	3,675
Outdoor air web bulb temperature	18°C - 31°C (interval 1°C)	
Cooling water temperature	20°C - 33°C (interval 1°C)	
Differential pressure	0.4 mmAq - 1.0 mmAq (interval 0.1)	

모델 예측 정확도는 CVMSE 13.2% ~ 22.2%, R²값 0.81 ~ 0.95으로, ASHRAE Guideline 14에서 제시하는 hourly criteria CVMSE 30%와 R²값 0.75 이상을 모두 만족한다.

개발한 시뮬레이션을 이용하여 입력 데이터인 실내 부하, 외기 습구온도, 냉각수 설정온도, 차압 설정값에 대한 모든 구간에서의 기기 에너지 소비량을 산출하였다. 각 입력 데이터의 범위 및 생성한 학습데이터의 수를 <Table 4>에 나타낸다. 실내 부하의 범위는 실외기 정격능력의 20% (381.0 kWh)에서 100% (1905.2 kWh)로 하였으며 간격은 20% (381.0 kWh)으로 하였다. 외기 습구온도는 18°C ~ 31°C, 1°C 간격이며, 냉각수 온도는 20°C ~ 33°C, 1°C 간격이다. 이때, 냉각수 온도는 “외기 습구온도 + Approach temperature”보다 낮을 수 없으므로 외기 습구온도에 따라 냉각수 온도 범위를 설정하였다. 차압 범위는 0.4mmAq ~ 1.0mmAq, 1mmAq 간격이다. 이렇게 각 입력 데이터에 대한 학습데이터 총 3,675개를 생성하였다.

3. 인공신경망 모델 개발

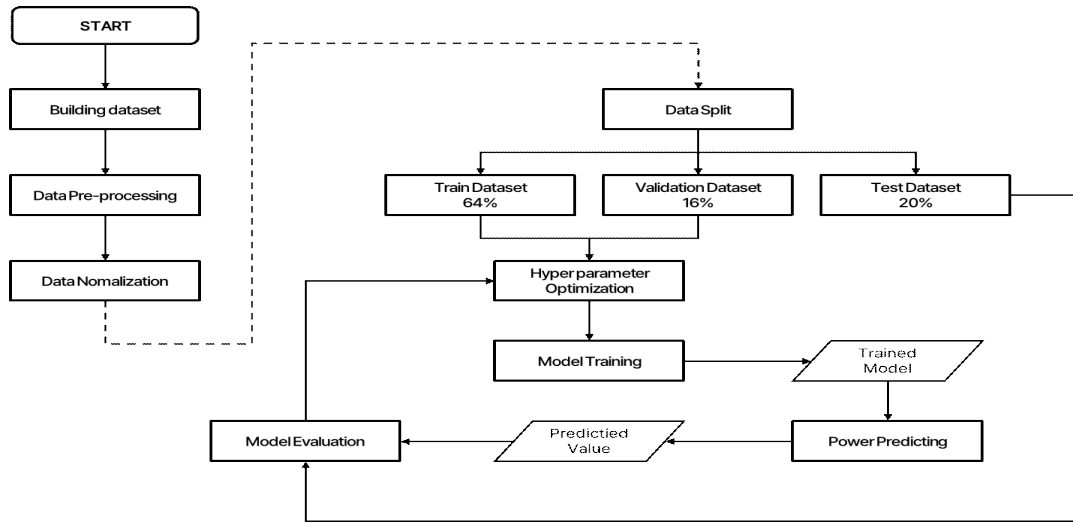
앞서 생성한 학습데이터를 이용하여 최적제어를 위한 데이터 기반 예측 모델을 개발하였다. 대표적인 데이터 기반 예측 모델인 인공신경망은 사람의 뉴런을 모사하여 만든 알고리즘으로 복잡하고 비선형적인 기기들의 연결로 이루어진 HVAC 시스템의 전력 소비량 예측을 위해 많이



[Fig. 2] DNN model structure.

사용되고 있다. 인공신경망은 DNN (Deep Neural Network), RNN (Recurrent Neural Network), CNN (Convolutional Neural Network) 등의 다양한 형태로 발전하였다. 본 연구에서는 입력층, 출력층, 다중의 은닉층을 가지는 DNN을 이용하여 예측 모델을 구축하였다.

학습데이터는 모델의 학습과 평가를 위해, Test set 20%, Train set 80%로 분류하였으며, Train set의 20%를 과대적합 및 과소적합 판단을 위해 Validation set으로 분류하였다. 학습데이터의 입력 변수들 간의 Scale 차이가 클 경우, 모델 학습 과정에서 경사하강법 적용 시 수렴하지 않고 발산하는 문제가 발생할 수 있다(Olu-Ajayi R et al., 2022). 따라서 MinMax scaler를 사용해 Train set을 0과 1 사이 범위의 공통 척도로 정규화 (Normalization)하였다. DNN 모델 학습에 사용한



[Fig. 3] Algorithm flowchart.

활성화 함수 및 옵티마이저는 Relu와 Adam이며 손실함수는 MSE이다. 학습 수는 Manual search 과정에서 과대, 과소적합이 발생하지 않았던 200 회로 하였다.

4. 하이퍼 파라미터 최적화

학습모델의 예측 성능 향상을 위해 베이지안 최적화 방법을 이용하여 하이퍼 파라미터를 최적화하였다. 하이퍼 파라미터는 연구자가 지정하여 학습 과정 중 변경되지 않는 값을 의미한다. 다양한 최적화 기법이 존재하나 본 연구에서는 베이지안 최적화를 적용하여 하이퍼 파라미터를 최적화하였다. 베이지안 최적화는 머신러닝, 데이터 분석, 시뮬레이션 등의 복잡한 최적화 문제를 효율적으로 해결하기 위해 많이 사용되고 있으며, 목적 함수의 함수값을 최소 또는 최대로 만드는 전역 최적해를 찾는 기법이다. 베이지안 최적화는 대체 모델(Surrogate model)과 획득 함수(Acquisition function)으로 구성된다. 대체 모델은 목적 함수의 근사치를 추정하기 위해 사용되고 획득 함수는 다음 평가 후보, 즉 입력값을 추천하기 위해 사용된다. 이 요소들을 통해 베이지안

최적화는 초기 입력값을 수집하고 대체 모델을 학습하여 획득 함수에 따라 다음 입력값을 추천 받는다. 이후 선택된 새 입력값에서 목적 함수를 평가하고 대체 모델을 정해진 반복 횟수나 종료 기준에 도달할 때까지 하이퍼 파라미터를 업데이트한다. 베이지안 최적화는 이 과정을 반복하며 최적의 하이퍼 파라미터 조합을 찾는다(Brochu E et al., 2010). 본 연구에서는 대체 모델로 Gaussian process(GP)를, 획득 함수로 Expected Improvement(EI)를 사용하였다.

III. 연구 결과

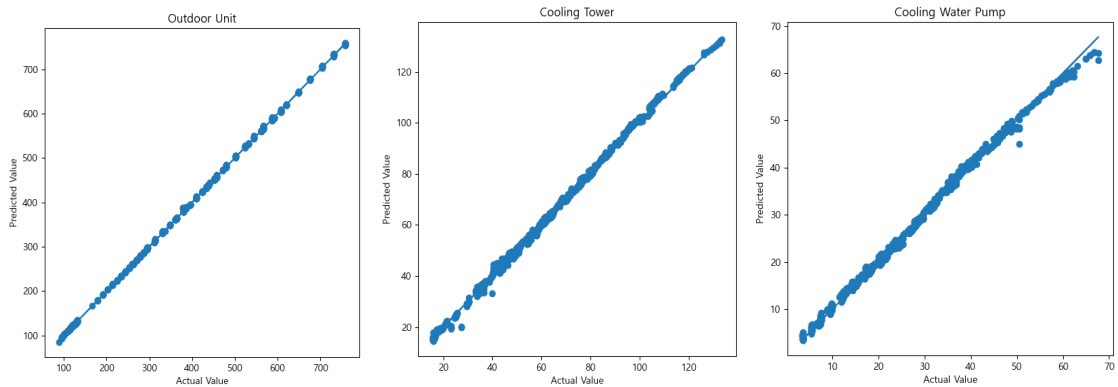
베이지안 최적화에 사용한 데이터는 앞서 분류한 train set과 validation set을 사용하였다. 베이지안 최적화한 하이퍼 파라미터 항목은 노드 수(Nodes), 은닉층 수(Hidden layers), 드랍 아웃(Drop out), 학습률(Learning rate)이며, 각 항목에 대한 하이퍼 파라미터 탐색 범위와 최적화 결과를 <Table 5>에 나타내었다. 은닉층 수의 범위는 2개 ~ 10개이며, 노드 수는 각 은닉층에서 16개 ~ 256개이다. 드랍 아웃은 0.0 ~ 0.3, 학습률은 0.0001 ~ 0.01이다. 베이지안 최적화를 적용한 결

<Table 5> Hyper parameter Optimization Range

	Range	Result
Hidden layers	2 ~ 10	3
Nodes	16 ~ 256	161, 150, 145
Drop out	0.0~0.3	0.0
Learning rate	0.0001 ~ 0.01	0.006159

<Table 6> CVMSE and R² Score in DNN model

	CVMSE [%]	R ² [-]
Outdoor Unit	0.42	0.99
Cooling Tower	1.99	0.99
Cooling Water Pump	3.24	0.99



[Fig. 4] Predictive Graph and Scatter Plot of Outdoor Unit, Cooling tower and Cooling water pump.

과 선정된 최적의 하이퍼 파라미터 조합은 은닉층 수 3개, 각 은닉층에 대한 노드 수 161, 150, 145개, 드랍 아웃 0.0, 학습률 0.006159이다. 이때, 예측 정확도 CVMSE와 R² 값을 <Table 6>와 [Fig. 4]에 나타내었다. DNN 모델의 예측 정확도는 CVMSE 0.42% ~ 3.24%, R² 값 0.99 ~ 0.99로, ASHRAE Guideline 14 기준을 모두 만족하였다.

IV. 결론

본 논문에서는 제어 설정값 최적화를 위한 데이터 기반 예측 모델 개발에 있어 학습데이터 부족 문제를 보완하는 방법을 제안하였다. 실 현장에서는 다양한 제어 설정값으로 운전된 데이터를 취득할 수 없어 비교적 간단히 공조기기의 성능

을 예측할 수 있는 MLR을 사용하여 열원시스템에 대한 시뮬레이션 모델을 개발하였다. 시뮬레이션 예측 정확도는 CVMSE 13.2% ~ 22.2%, R² 값 0.81 ~ 0.95로, ASHRAE Guideline 14에서 제시하는 hourly criteria 기준 CVMSE 30%와 R² 값 0.75 이상을 모두 만족하는 성능을 보였다. 시뮬레이션을 통해 모든 경계조건 및 설정값 조합에 대한 운전데이터를 생성하고 이를 학습데이터로 이용하여 DNN 모델을 개발하였다. 그리고 예측 정확도 향상을 위해 베이지안 최적화를 이용하여 하이퍼 파라미터를 최적화하였다. 결과, 은닉층 수 3개, 각 은닉층에 대한 노드 수 161, 150, 145개, 드랍 아웃 0.0, 학습률 0.006159의 하이퍼 파라미터 조합이 선정되었으며, 예측 정확도는 CVMSE 0.42% ~ 3.24%, R² 값 0.99로 ASHRAE Guideline 14 기준을 모두 만족하였다.

References

- A Aframa, Alan S Fung, F Janabi-Sharifi and K Raahemifar(2017). Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system, *Energy and Buildings*, 141, 96~113.
<https://doi.org/10.1016/j.enbuild.2017.02.012>
- Afram A and Janabi-Sharifi F(2014). Review of modeling methods for HVAC systems, *Appl. Therm. Eng.* 2, 507~519.
<https://doi.org/10.1016/j.applthermaleng.2014.03.055>
- Ahn YS and Kim BS(2022). Prediction of building power consumption using transfer learning-based reference building and simulation dataset, *Energy & Buildings*, 258, 111717.
<https://doi.org/10.1016/j.enbuild.2021.111717>
- BP(2022). 2021 at a glance. Bp Statistical Review of World Energy 2022 71st edition, 2~3.
- Brochu E, Cora V.M. and Freitas N.d(2010). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. arXiv preprint arXiv : 1012.2599
<https://doi.org/10.48550/arXiv.1012.2599>
- C Lu, S Li and Z Lu(2022). Building energy prediction using artificial neural networks: A literature survey, *Energy & Buildings*, 262, 111718.
- Ding Y, Yuan T and Zhang Q(2017) Research on short-term and ultra-short-term cooling load prediction models for office buildings, *Energy and Buildings*, 154, 254~267.
<https://doi.org/10.1016/j.enbuild.2017.08.077>
- Kang WH, Yoon YB, Lee JH, Song KW, Chae YT and Lee KH(2021). In-situ application of an ANN algorithm for optimized chilled and condenser water temperatures set-point during cooling operation, *Energy & Buildings*, 233, 110666
<https://doi.org/10.1016/j.enbuild.2020.110666>
- KEEI(2022) S. Korea's 2050 Carbon Neutral Scenario: Contents and Challenges, *Issues and Gaze*, 19~26.
- ME(Ministry of Environment) (2022). National Greenhouse Gas Provisional Emissions 2021 Disclosure. Press release from the General Greenhouse Gas Information Center, 1~12.
- NABO(National Assembly Budget Office) (2023). Climate, energy, and crisis: responding to the new international order. Analysis of economic issues for 2023, 153~177.
- Olu-Ajayi R, Alaka H, Sulaimon I, Sunmola F and Ajayi S(2022). Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques, *Building Engineering*.
<https://doi.org/10.1016/j.jobe.2021.103406>.
- Ra SJ, Kim JH and Park CS(2023). Real-time model predictive cooling control for an HVAC system in a factory building, *Energy & Buildings*, 285, (2023) 112860.
<https://doi.org/10.1016/j.enbuild.2023.112860>

-
- Received : 26 October, 2023
 - Revised : 23 November, 2023
 - Accepted : 29 November, 2023