



저작자표시 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.
- 이차적 저작물을 작성할 수 있습니다.
- 이 저작물을 영리 목적으로 이용할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.

- 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](#) 

工學碩士學位論文

딥러닝 기반 HVAC 시스템 최적제어
알고리즘에 대한 효과 검증 및
확장성 향상에 관한 연구

A Study on Effect Verification and Scalability Improvement of Deep
Learning-based HVAC System Optimal Control Algorithm

2025年 2月

國立釜慶大學校大學院

冷凍空調工學科

盧正賢

工學碩士學位論文

딥러닝 기반 HVAC 시스템 최적제어
알고리즘에 대한 효과 검증 및
확장성 향상에 관한 연구

A Study on Effect Verification and Scalability Improvement of Deep
Learning-based HVAC System Optimal Control Algorithm

指導教授 李 霽 憲

이 論文을 工學碩士 學位論文으로 提出함

2025年 2月

國立釜慶大學校大學院

冷凍空調工學科

盧正賢

盧正賢의 工學碩士 學位論文을 認准함

2025年 2月 21日

主 審 工學博士 鄭 碩 權 ①

委 員 工學博士 薛 成 勳 ①

委 員 工學博士 李 霽 憲 ①

목 차

Abstract	iv
List of figures	vi
List of tables	viii
제 1장 서 론	1
1.1 연구 배경	1
1.2 연구 동향	4
1.3 연구 목적 및 범위	7
제 2장 연구 방법	10
2.1 대상 건물 및 HVAC 시스템	10
2.2 열원시스템 운전 현황	15
2.3 제어 시스템 구축 및 효과 검증 방법	17
제 3장 HVAC 시스템 최적 제어 알고리즘 실증	19
3.1 최적 제어 알고리즘 개발	19
3.1.1 냉각수 알고리즘 개발	19
3.1.2 냉수 알고리즘 개발	22
3.2 열원시스템 시뮬레이션 모델	25
3.2.1 열원시스템 시뮬레이션 모델 개요	25

3.2.2	열원시스템 시뮬레이션 모델 개발	27
3.2.3	시뮬레이션 모델 정확도 검증 및 데이터 생성	31
3.3	DNN 기반 열원시스템 전력소비량 예측모델 개발	33
3.3.1	인공신경망	33
3.3.2	DNN 모델 개요	35
3.3.3	DNN 모델 개발	37
3.4	최적 제어 알고리즘 실증 연구	42
3.4.1	제어 설정값 비교	43
3.4.2	최적 제어 알고리즘 효과 검증 결과	46
3.4.3	실내 온열환경에 미치는 영향 분석	50
제 4장	전이학습 기반 알고리즘 확장성 개선	52
4.1	전이학습	53
4.1.1	전이학습 개요	53
4.1.2	전이학습 방법 종류	55
4.1.3	선행 연구 및 한계점	57
4.2	연구방법	58
4.2.1	대상 건물 및 HVAC 시스템	58
4.2.2	Target 시스템 운전 현황	61
4.2.3	열원시스템 시뮬레이션 모델	63
4.2.4	사전학습 Source 모델 개발	63
4.3	전이학습 기반 DNN 예측모델 개발	68

4.3.1 전이학습 모델 개발 개요	68
4.3.2 전이학습 모델 개발	69
4.3.3 전이학습 모델 평가	72
제 5장 결 론	76
참고문헌	78
Appendix	83
감사의 글	93



A Study on Effect Verification and Scalability Improvement of Deep Learning-based HVAC System Optimal Control Algorithm

Jeong-Hyun Noh

Department of Refrigeration and Air Conditioning Engineering,
Graduate School, Pukyong National University

Abstract

When developing energy prediction models or verifying the effects of optimal control algorithms in a simulation environment, it is difficult to accurately identify interactions between devices or changes in the indoor environment due to changes in control setpoints. In order to develop a machine learning model with high prediction accuracy for optimal control, it is necessary to secure operation data for various outdoor conditions, load conditions, and control settings. However, due to the unique characteristics of buildings and air conditioning systems, data acquisition for individual buildings is essential, and this process causes time and cost issues. Furthermore, developing a prediction model for optimal control is challenging as it is difficult to obtain actual operation data for all boundary conditions while varying the control setpoints.

In this study, a physics-based heat source system simulation model was developed using Matlab Simulink and calibrated using actual operation data to improve accuracy. After generating sufficient learning data for all control settings using the calibrated simulation model, a DNN-based heat source system power consumption prediction

model was developed using Python, and a highly accurate prediction model was secured through Bayesian optimization among hyperparameter optimization methods. Next, a cooling water temperature and flow rate control setting value optimization algorithm based on a DNN prediction model (hereinafter referred to as the cooling water algorithm) and a rule-based chilled water temperature control algorithm (hereinafter referred to as the chilled water algorithm) were developed. To verify the developed algorithm, it was applied to a target building located in Hanoi, Vietnam for a total of 244 days from October 27, 2023 to June 26, 2024, and the energy saving effect of the algorithm and its impact on indoor temperature and humidity were evaluated through comparative analysis of operation data before and after the application of the algorithm. The verified DNN prediction model was used as a source model to apply transfer learning to evaluate the possibility of expansion to other systems. At this time, the degree of improvement in prediction accuracy was derived and compared by focusing on fine tuning, a technique for relearning the weights of the source model among transfer learning methods.

List of figures

Fig 1.1 전 세계 에너지원별 공간 냉방을 위한 CO ₂ 방출량 (IEA)	3
Fig 1.2 1990-2050 전 세계 국가별 에어컨 예상 보유대수 (IEA)	3
Fig 1.3 석사 연구 개념도	9
Fig 2.1 대상 건물 조감도	14
Fig 2.2 대상 공조시스템 구상도	14
Fig 2.3 외기온도와 부하 추이	16
Fig 2.4 냉각수 온도 및 냉각탑 팬 운전상태	16
Fig 2.5 냉각수 온도차 및 냉각수 펌프 운전상태	17
Fig 2.6 알고리즘 실증을 위한 제어 시스템 구축	18
Fig 3.1 냉각수 알고리즘 흐름도	21
Fig 3.2 냉수 알고리즘 흐름도	24
Fig 3.3 열원시스템 시뮬레이션 흐름도	27
Fig 3.4 열원시스템 시뮬레이션 정확도 평가 결과	32
Fig 3.5 DNN 구조 & 가중치 최적화 알고리즘	34
Fig 3.6 DNN 예측 모델 개발 흐름도	36
Fig 3.7 DNN 모델 예측정확도 검증 결과	41
Fig 3.8 냉방부하에 따른 냉각수 온도 설정값 비교	44
Fig 3.9 냉방부하에 따른 냉각수 온도차 설정값 비교	45
Fig 3.10 냉방부하에 따른 냉수 온도 설정값 비교	45
Fig 3.11 냉방부하에 따른 열원시스템 전력소비량 비교	47

Fig 3.12 부하 구간 1,000 kWh ~ 1,500 kWh에서 전력소비량 비교	48
Fig 3.13 IPMVP 기반 알고리즘 효과 검증 결과	49
Fig 3.14 AHU 실내 및 급기 온도 비교	51
Fig 4.1 전통적인 머신 러닝(좌) vs 전이학습(우)	52
Fig 4.2 도메인과 작업에 따른 학습 분류	55
Fig 4.3 미세조정 & 특성추출기 구조	56
Fig 4.4 전이학습 대상 건물	59
Fig 4.5 Source 및 Target 시스템 전력소비량 비교	62
Fig 4.6 Target 시스템 운전상태	62
Fig 4.7 MLR 기반 열원시스템 시뮬레이션 흐름도	63
Fig 4.8 전이학습 모델 개발 흐름도	69
Fig 4.9 전이학습 모델 학습 방법 분류	71
Fig 4.10 Source 모델 예측정확도 검증 결과	73
Fig 4.11 모델 정확도 비교	75
Fig 4.12 냉각수 온도에 따른 실외기 전력소비량 변화	75
Fig. A.1 미세조정에 따른 전이학습 모델 예측정확도 결과	85
Fig. A.2 냉각수 온도에 따른 실외기 전력소비량 변화 (미세조정)	85
Fig. A.3 학습수에 따른 전이학습 모델 예측정확도 결과	88
Fig. A.4 냉각수 온도에 따른 실외기 전력소비량 변화 (학습수)	90
Fig. A.5 노드수에 따른 전이학습 모델 예측정확도 결과	92
Fig. A.6 냉각수 온도에 따른 실외기 전력소비량 변화 (노드수)	93

List of tables

Table 2.1 대상 건물 장비 사양	13
Table 3.1 물리식 시뮬레이션 모델 : 파라미터와 보정 계수 계산 결과 · 28	
Table 3.2 DNN 모델의 입력데이터, 출력데이터	38
Table 3.3 DNN 모델의 하이퍼 파라미터 최적화	40
Table 3.4 Baseline 운전의 시스템 전력소비량 회귀 계수 계산 결과	49
Table 4.1 Source 및 Target 도메인과 작업의 관계에 따른 학습 분류	54
Table 4.2 전이학습 대상 건물 장비 사양	60
Table 4.3 MLR 시뮬레이션 모델 : 기기 모델의 회귀 계수 및 보정 계수 계산 결과	65
Table 4.4 MLR 시뮬레이션 모델 : 정확도 평가 결과	65
Table 4.5 Source 모델의 입력데이터, 출력데이터	67
Table 4.6 Source 모델의 하이퍼 파라미터 최적화	67
Table A.1 미세조정에 따른 전이학습 모델 정확도 비교	86
Table A.2 학습수에 따른 전이학습 모델 정확도 비교	89
Table A.3 노드수에 따른 전이학습 모델 정확도 비교	92

제 1장 서론

1.1 연구배경

냉방 시스템은 더운 외기로부터 건물을 보호하고, 실내를 내부 활동이 원활하게 이루어질 수 있도록 쾌적한 환경으로 유지하기 데 필수적인 역할을 한다. 현대 사회에서 냉방 시스템은 필수 불가결한 요소로 자리 잡고 있다. IEA (International Energy Agency)의 ‘Space Cooling’ 및 ‘The Future of Cooling’ 보고서에 따르면, 쾌적한 실내 환경을 유지하기 위해 사용되는 전기 사용량은 꾸준히 증가하고 있으며, 이 중 냉방을 위한 전기 사용량은 전 세계 전기 사용량의 약 10%를 차지한다고 한다^{1,2)}. 전기 사용량이 증가하면 전기 생산 과정에서 석탄, 석유 등 화석연료의 연소로 인해 온실가스 배출량 역시 증가하게 된다. 온실가스 배출량을 측정하고 보고하는 국제 표준인 GHG Protocol (Greenhouse Gas Protocol)에서는 온실가스 배출량을 체계적으로 관리하기 위해 직접 배출량(scope 1 emission)과 간접 배출량(scope 2, 3 emission)으로 구분한다. 직접 배출량은 건물에서 직접 사용하는 연료 등에 의해 발생하는 온실가스를 포함하며, 간접 배출량은 건물에서 소비하는 전기, 스팀, 냉매 등 에너지를 외부에서 생산하고 운반하는 과정에서 발생하는 온실가스를 포함한다³⁾. 건물의 냉방 시스템이 배출하는 온실가스 배출량은 간접 배출량을 포함할 경우 전 세계 온실가스 배출량의 10% 이상을 달한다고 보고된다^{2,5,6)} (Fig. 1.1). 더불어, 인구 증가, 경제 성장, 도시화로 인한 건물 냉방 시스템 보급률의 증가를 고려할 때, 건물 냉방으로 인한 온실가스 배출량은 앞으로 더욱 가속화될 것으로 전망된다^{7,8,9,10)} (Fig. 1.2).

건물 냉방 시스템으로 인한 온실가스 배출량을 줄이기 위해서는, 건물 냉방을 담당하는 HVAC (Heating, Ventilation, & Air Conditioning) 시스템을 주목할 필요가 있다¹¹⁾. HVAC 시스템은 냉동기, 냉각탑, 보일러, 열교환기, 급배기 장치 등 냉난방과 화기를 담당하는 다양한 하위 기기로 구성되어 있다. 최근에는 에너지 절감과 쾌적한 실내 환경의 중요성이 부각되면서, 기존보다 더욱 복잡하고 정교한 HVAC 시스템이 요구되고 있다¹²⁾. 이와 함께, 중대형 건물을 중심으로 BEMS (Building Energy Management System)이 도입되어 HVAC 시스템의 효율적인 제어와 에너지 관리가 가능해졌다¹³⁾. 더불어, 컴퓨터 성능의 발전으로 데이터의 저장 및 전송이 보다 용이해짐에 따라 BEMS의 활용도 역시 지속적으로 증가하고 있다¹⁴⁾. 하지만, HVAC 시스템을 이루는 하위 기기들을 제어하기 위한 제어 설정값은 여전히 연간 최대 열부하 계산법이나 현장 관리자의 경험에 의존하여 결정되는 경우가 많다. 이는 시시각각 변동하는 외기 조건이나 부하 조건에 적절히 대응하지 못해, 실내 환경의 쾌적성이 저하되거나 에너지 사용의 비효율성 문제를 초래한다. 이러한 문제를 해결하기 위해, 실내 환경을 쾌적하게 유지하면서도 공조시스템의 운전 효율을 개선하기 위한 에너지 소비량 예측 및 제어 설정값 최적화(이하, 최적 제어)에 관한 연구가 활발히 진행되고 있다¹⁵⁾.

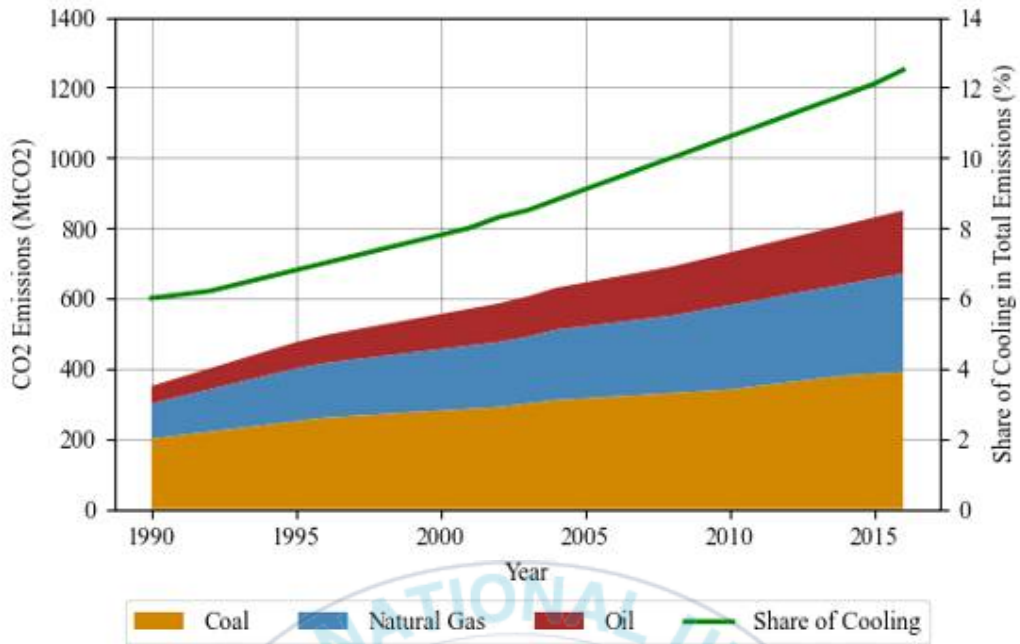


Fig. 1.1 전 세계 에너지원별 공간 냉방을 위한 CO₂ 방출량 (IEA)




Fig. 1.2 1990-2050 국가별 에어컨 예상 보유대수 (IEA)2)

1.2 연구 동향

박석민, 이제현 (2023)¹⁶⁾은 공조시스템 최적 제어를 위한 데이터 기반 예측 모델 개발 시 발생할 수 있는 데이터 부족 문제를 보완하기 위한 방법을 제시하였다. 비교적 간단하게 공조기기의 성능을 나타낼 수 있는 다중 회귀 분석 (MLR, Multi Linear Regression)을 사용하여 열원시스템 시뮬레이션 모델을 개발하여, 다양한 경계조건에 대해 학습 데이터를 확보하였다. 이후, 베이저안 최적화 (Bayesian Optimization)를 통해 DNN 모델의 은닉층 수, 은닉층 별 노드수, 드롭 아웃, 학습률을 최적화하였다. 그 결과, CV(RMSE) (Coefficient of Variation of the Root Mean Squared Error) 13.2% ~ 22.2%, R^2 score 0.81 ~ 0.95의 높은 정확도를 가진 예측 모델을 확보할 수 있었다.

문진우(2019)¹⁷⁾는 VRF (Variable Refrigerant Flow) 시스템이 적용된 건물을 대상으로 냉방 에너지사용량 절감을 위해 DNN (Deep Neural Network) 예측모델 기반의 최적 제어 연구를 진행하였다. 대상 제어 설정값은 실내 급기 온도와 냉각수온도, 냉각수 유량이다. Energy Plus와 MATLAB을 이용하여 대상 건물의 공조 시스템 시뮬레이션 모델을 구축하고 이를 통해 최적 제어 알고리즘의 성능을 분석하였다. 알고리즘 검증 결과, 실내 급기 온도 설정값이 기존과 유사하며 전체 28.4%의 에너지를 절감할 수 있었다.

Razak Olu-Ajayi 외 4인(2022)¹⁸⁾은 시뮬레이션 건물 데이터를 활용하여 연간 건물 에너지 소비량 예측에 대해 9가지(인공신경망 (ANN, Artificial Neural Network), 서포트 벡터 머신 (Support Vector Machine), 의사결정 트리 (Decision Tree), K-최근접 이웃 (K-Nearest Neighbour), 그래디언트 부스팅 (Gradient Boosting), 선형회귀 (Linear Regression), 딥 러닝 (Deep Learning), 스택킹 (Stacking), 랜덤 포레스

트 (Random Forest)) 머신 러닝 방법들을 R2 스코어, RMSE (Root Mean Squared Error), 학습시간을 기반으로 비교 분석하여, 이 중 DNN 모델이 건물 에너지 소비량 예측에 있어 가장 효율적임을 밝혔다.

Hyeon Jin Lee 외 4인(2023)¹⁹⁾는 EnergyPlus와 Matlab을 활용하여 ANN 기반의 수냉식 공조장치 시스템의 냉각수 온도 및 AHU (Air Handling Unit) 토출 공기 온도 설정값 최적제어 알고리즘 연구를 진행하였다. AHU 팬, 냉동기, 냉각탑, 펌프의 에너지 절감율을 시뮬레이션을 통해 확인할 결과, 알고리즘 적용 시 토출 공기 온도를 높게, 냉각수 온도를 낮게 설정함으로써 전체적으로 16%의 에너지를 절감할 수 있었다.

Guanyu Gao 외 2인(2020)²⁰⁾은 ASHRAE RP-884 데이터 베이스를 활용하여 인공신경망 기반의 학습모델을 개발하여 열쾌적 지표인 예측평균온열감 (Predicted Mean Vote, PMV)와 건물 에너지 사용량을 예측하고, 강화학습 방법 중 하나인 DDPG (Deep Deterministic Policy Gradients) 기반으로 AHU supply air의 온도와 습도를 제어하였다. DDPG는 제어 설정점을 불러와 연속적으로 변화시키면서 보상이 가장 큰 지점을 다음 설정값으로 지정한다. Transys를 활용한 시뮬레이션 환경에서의 제어 알고리즘을 구현한 결과, 쾌적성은 13.6% 향상되었고 에너지소비량은 4.3% 절감할 수 있었다.

Yuying Sun 외 6인 (2020)²¹⁾은 냉동기 입구 냉수 온도를 기준으로 ON/OFF 되는 Constant-speed air-cooled chiller을 사용하는 공조 시스템을 대상으로 시스템 성능 향상을 위해 냉동기 입구 냉수 온도를 최적화하였다. 물리식 기반 시뮬레이션 모델을 구축하여 학습데이터를 확보하고, 시뮬레이션 모델과 함수 근사에 사용되는 GRNN (General Regression Neural Network) 예측 모델을 기반으로 실시간 냉수 온도를 최적화하였다. 시뮬레이션 환경에서 알고리즘의 수치해

석 결과, 냉동기 입구 냉수 온도가 상승함에 따라 약 11%의 시스템 에너지소비량을 절감할 수 있었고, PMV는 94%가 -1 ~ 1 사이에 위치하여 ASHRAE Standard 55 기준을 만족하였다.

Jessica Granderson 외 4인 (2018)²²⁾은 기후 및 건물 유형에 따른 상용화된 MPC (Model Predicted Control) 기반 AHU 공급 공기 온도 및 덕트 정압 최적 제어의 장기적인 효과 검증에 관해 연구하였다. 최적화는 기상 데이터와 과거 운전 데이터를 사용하여 향후 24시간 후의 부하 프로필을 예측하는 모델을 기반으로 진행되었다. 기존의 시뮬레이션 환경에서의 MPC 최적제어 연구는 최대 60%까지의 에너지 절감 효과를 보였지만, 실제 현장에 적용된 결과 0% ~ 9% 정도의 절감 효과 밖에 얻지 못 하였다. 이는 최적화 대상 매개변수의 차이, 기존 건물의 제어 방법에 의한 것도 있지만, 실제 현장 환경이나 운전 상태에 따른 차이도 있다고 설명하였다.

강원희 외 5인 (2021)²³⁾은 터보 냉동기 기반의 중앙 공조 방식을 채택한 오피스 건물을 대상으로 DNN 기반의 냉각수 및 냉수 온도 최적 제어를 주제로 연구하였다. 예측 모델은 약 1달 가량의 실제 운전데이터를 이용해 개발하였고, 외기 조건과 최적화 대상 제어 설정값을 학습데이터로 사용하였다. 학습된 예측 모델 기반으로 최적 제어 알고리즘을 개발하고 실제 건물에 적용시켜, 이후 2달간의 데이터를 이용해 알고리즘의 성능을 평가하였다. 결과, 7% 시스템 에너지 절감율을 보였으나, 전력 소비량을 예측하는 과정에서 비정상적인 값을 예측하는 경향이 나타났다. 이는 실제 데이터를 활용에 따른 데이터 부족 문제에 기인한 문제라 설명하였다.

Chujie Le 외 2인 (2022)²⁴⁾은 건물 에너지 예측을 위해 ANN을 활용한 연구를 중심으로 최근 5년간 관련 출판물 324편을 선정하여 서지학적으로 분석하였다. ANN 구조 선택, 예측 성능 개선, 건물 에너지 데이터 부족 문제 해결에 대해 논의하였다. 그 중, 데이터 부

족 문제에 대한 해결 방안으로 전이학습 (Transfer Learning)을 제시하였다. 하지만, 성공적인 전이학습을 위해서도 source 모델에 대해 다양한 경계조건에 따라 제어 설정값을 변경하며 운전된 데이터를 확보하는 것이 중요하다.

1.3 연구 목적 및 범위

이처럼 건물 및 공조시스템의 에너지 효율 향상을 위한 최적 제어 연구가 활발히 진행되고 있지만, 선행 연구들에서 다음과 같은 한계점을 파악하였다. 대부분의 선행 연구가 시뮬레이션 환경에서 에너지 소비량 예측 모델 개발이나 최적 제어 알고리즘의 효과 검토에 비중을 두고 있으며, 이를 활용하여 실제 건물에 적용하거나 효과를 검증한 사례는 부족하다. 또한, 제어 설정값의 변화는 실내 온습도 등 실내 온열환경에 악영향을 미칠 가능성이 있으므로, 설정값 변화가 실내 환경에 미치는 영향을 평가가 필요하지만, 시뮬레이션 환경에서는 제어 설정값 변경에 따른 기기 간의 상호작용이나 실내 환경의 변화를 정확하게 파악하기는 어렵다. 최적 제어를 위해 높은 예측 정확도를 가진 머신 러닝 모델을 개발하려면 다양한 외기 조건, 부하 조건, 그리고 제어 설정값에 대한 운전 데이터를 확보해야 한다. 그러나, 건물과 공조 시스템의 고유한 특성 때문으로 인해 개별 건물에 대한 데이터 취득이 필수적이며, 이 과정에서 시간 및 비용 문제가 발생한다. 더욱이, 실제 시스템에서 제어 설정값을 변경하며 취득한 운전데이터를 활용하더라도, 일반적인 예측 경향을 벗어나는 등 데이터 부족에 따른 예측 정확도 저하 문제가 발생할 수 있다. 따라서 본 연구에서는 기존 공조 시스템 최적 제어 연구의 한계점을 보완하기 위해, 딥러닝 기반 HVAC 시스템 최적 제어 알고

리즘에 대한 실증 연구를 수행하고, 전이학습을 활용하여 최적 제어 알고리즘의 확장 가능성에 대해 검토하였다.

먼저, 딥러닝 기반 HVAC 시스템 에너지 소비량 예측 모델과 최적 제어 알고리즘을 개발하고, 실증 연구를 통해 알고리즘의 에너지 절감 효과 및 실내 온열환경에 미치는 영향에 대해 평가하였다. 또한, 전이학습을 활용하여 기존 최적 제어에서 발생하는 시간 및 비용 문제를 개선하고자 하였으며, 실 운전데이터를 활용했을 때 발생하는 문제점을 보완하기 위해 시뮬레이션 모델을 구축하고 이를 활용하여 다양한 경계조건에 대한 학습데이터를 생성하였다. 마지막으로, 본 연구를 통해 최적 제어를 위한 전이학습의 기본 방향성을 제시함으로써 향후 관련 연구와 실제 시스템 적용에서 활용할 수 있는 실질적인 가이드라인을 제공하고자 한다.

(Fig. 1.3) 이를 위해 본 연구에서는, 우선 Matlab Simulink를 활용하여 물리식 기반의 열원시스템 시뮬레이션 모델을 개발하고 정확도 향상을 위해 실 운전데이터를 이용하여 보정하였다. 보정한 시뮬레이션 모델을 활용하여 모든 제어 설정값에 대해서 충분한 학습데이터를 생성한 뒤, Python을 이용하여 DNN 기반의 열원시스템 전력소비량 예측모델을 개발하였고, 하이퍼 파라미터 최적화 방법 중 베이지안 최적화를 통해 정확도 높은 예측 모델을 확보하였다. 다음으로, DNN 예측 모델 기반의 냉각수 온도 및 유량 제어 설정값 최적화 알고리즘(이하, 냉각수 알고리즘)과 Rule 기반의 냉수 온도 제어 알고리즘(이하, 냉수 알고리즘)을 개발하였다. 개발된 알고리즘 실증을 위해, 베트남 하노이에 위치한 대상 건물에 23년 10월 27일부터 24년 6월 26일까지 총 244일 동안 적용하여, 알고리즘 적용 전과 후의 운전데이터 비교 분석을 통해 알고리즘의 에너지 절감 효과와 실내 온습도에 미치는 영향에 대해 평가하였다. 검증된 DNN 예측 모델을 source 모델로 활용하여 전이학습을 적용해 타 시스템

으로의 확장 가능성에 대해 평가하였다. 이때, 전이학습 방법 중 source 모델의 가중치를 재학습하는 기법인 미세조정 (Fine Tuning) 을 중심으로 예측 정확도 개선 정도를 도출하여 비교 분석하였다.

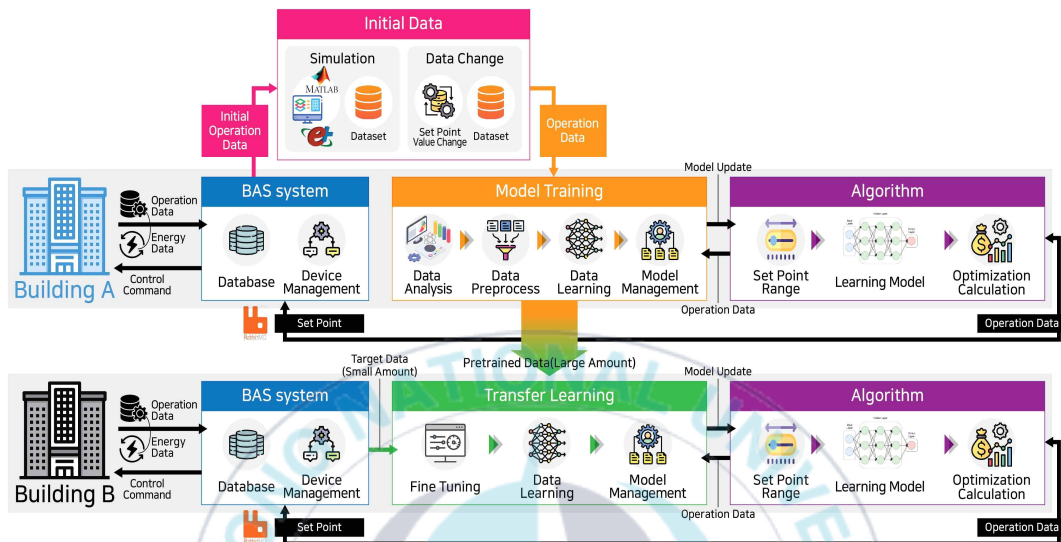


Fig. 1.3 석사 연구 개념도

제 2장 연구 방법

본 절에서는 연구 방법에 대해 설명한다. 먼저, 최적 제어 알고리즘이 적용된 대상 건물 및 HVAC 시스템을 소개하고, 열원시스템 운전 현황에 대해 설명한다. 이어서, 제어 시스템의 구축 과정과 알고리즘의 효과 검증 방법에 대해 상세히 기술한다.

2.1 대상 건물 및 HVAC 시스템

알고리즘 적용 대상 건물은 베트남 하노이에 위치한 사무용 건물로 선정하였다. 대상 건물의 내부는 지하 3층, 지상 16층에 연면적은 79,511 m²이고, 내부에는 소규모 매점, 식당, 서버실, 사무실, 도서관, 교육실 및 회의실 등으로 구성되어 있다 (Fig. 2.1). 공조 시스템은 수냉식 터보 냉동기를 사용하는 중앙 공조시스템을 채택하고 있으며, 대상 건물에 설치된 기기 사양을 Table 2.1에 나타낸다 (Fig. 2.2). 열원측 설비는 터보 냉동기, 개방형 냉각탑, 1차 냉수 펌프, 2차 냉수 펌프, 냉각수 펌프, 열교환기로 구성된다. 이 중 열교환기 2대, 2차 냉수 펌프 3대를 제외한 모든 기기는 스페어용 1대를 포함해 각각 4대씩 설치되어 있다. 또한, 압력 분산용 판형 열교환기에 의해 저층부 AHU와 고층부 AHU의 냉수 공급이 구분되어 있어, 1층 ~ 10층 저층부 AHU 11대의 냉수 공급은 1차 냉수 펌프가, 11층 ~ 15층 고층부 AHU 4대의 냉수 공급은 2차 냉수 펌프가 담당한다. 터보 냉동기는 냉매 R-514a를 사용하고 정격 냉각능력은 2,641 kW, 정격 소비전력은 402.4 kW이다. 1차 냉수펌프와 2차 냉수펌프의 정격유량은 각각 422.0 m³/h, 194.4 m³/h이며, 인버터가 탑재되어 변유

량 제어가 가능하다. 냉각탑은 정격 냉각능력이 4,077 kW이며, 풍량이 312,000 m³/h인 정속형 팬 3대가 설치되어 있다. 냉각수 펌프는 정격유량이 729.7 m³/h이며, 인버터가 탑재되어 변유량 제어가 가능하다. 열교환기는 냉수가 역방향으로 흐르는 향류형 판형 열교환기이며, 정격 냉각능력은 1,211 kW이다. 저층부를 담당하는 AHU 11대의 총 정격 냉방능력은 5,043 kW이다. AHU 7대는 지하 3층 ~ 지상 4층의 엘리베이터 홀, 로비, 교육실, 식당, 주방, 복도의 공조를 담당하며, CAV (Constant Air Volume) 방식을 채택하고 있다. 나머지 AHU 4대는 5층 ~ 10층 사무실의 공조를 담당하며, VAV (Variable Air Volume) 방식이다. 고층부를 담당하는 AHU 4대의 총 정격 냉방능력은 1,863 kW이며, 11층 ~ 15층 사무실의 공조를 담당하고 VAV 방식이다. 기기별 제어 사양은 아래와 같다.

- 기기의 운전대수 제어 : 외기조건 및 건물 운영 상황, 냉수 출수 온도를 고려하여 관리자에 의해 냉동기 운전대수가 결정되고 1차 냉수펌프, 냉각수 펌프, 냉각탑은 냉동기와 동일한 대수로 운전된다.
- 냉각탑 팬 운전대수 제어 : 냉각탑 출구 냉각수 온도가 “설정값 +2℃”보다 높으면 팬을 1대 기동하며, “설정값 -2℃”보다 낮으면 팬을 1대 정지한다. 팬의 최소 운전대수는 1대이다.
- 냉각수 펌프 유량 제어 : 냉각탑 입출구 냉각수 온도차가 설정값에 도달하도록 PI 제어를 통해 주파수를 조절하여 유량을 제어한다. 냉동기의 최소 냉각수 유량을 고려하여 냉각수 펌프의 주파수 제어 범위는 65% ~ 100%로 설정하였다.
- 1차 냉수 펌프 유량 제어 : 송수헤더와 환수헤더의 차압이 설정값에 도달하도록 PI 제어를 통해 주파수를 조절하여 유량을 제어한다. 냉동기의 최소 냉수 유량을 고려하여 1차 냉수 펌프의 주파수 제어 범위는 70% ~ 100%로 설정하였다.

제 2장 연구 방법

- 2차 냉수 펌프 운전대수 및 유량 제어 : 2차 냉수 펌프는 AHU 말단차압이 설정값에 도달하도록 운전대수와 PI 제어를 통한 유량제어를 실시한다. 2차 냉수 펌프의 주파수 제어 범위는 70% ~ 100%로 설정하였다.
- AHU 냉방 코일 밸브 개도 제어 : CAV 방식의 경우, 환기 온도가 실내온도 설정값에 도달하도록 비례제어를 통해 밸브 개도 제어를 실시한다. VAV 방식의 경우, 급기 온도가 급기온도 설정값에 도달하도록 비례제어를 통해 밸브 개도 제어를 실시한다.
- 열교환기 밸브 제어 : 2차 냉수 온도가 목표 온도에 도달하도록 비례제어를 통한 열교환기 밸브의 개도 제어를 실시한다.



Table 2.1 대상 건물 장비 사양

Equipment	Quantity (EA)	Specification
Turbo Chiller	4	Refrigerant : R-514a Cooling capacity : 2,461 kW Chilled water flow : 421.98 m ³ /h Chilled water inlet temperature : 12 °C Chilled water outlet temperature : 7 °C Power : 402.4 kW
Cooling Tower	4	Cooling capacity : 4,077 kW Cooling water flow : 729.66 m ³ /h Cooling water inlet temperature : 32 °C Cooling water outlet temperature : 37 °C Number of fans : 3 EA Air Volume per fan : 321,000 m ³ /h Fan rated power : 37 kW
Chiller Water Pump (Inverter)	4	Chilled water flow : 421.98 m ³ /h Head : 290 kPa, Motor : 60 kW, Frequency : 50 Hz
2 nd Chiller Water Pump (Inverter)	3	2 nd Chilled water flow : 194.4 m ³ /h Head : 280 kPa, Motor : 37 kW, Frequency : 50 Hz
Cooling Water Pump (Inverter)	4	Cooling water flow : 729.66 m ³ /h Head : 210 kPa, Motor : 110 kW, Frequency : 50Hz
Air Handling Unit	15	Total cooling capacity : 6,658 kW (B3F ~ 10F : 5,043 kW, 11F ~ 15F : 1,863 kW) Heat medium : Water
Heat Exchanger	2	Plate type, Count flow, Cooling capacity : 1,211 kW, Chilled water flow : 208.32 m ³ /h 2 nd Chilled water flow : 208.32 m ³ /h Chilled water inlet temperature : 12 °C Chilled water outlet temperature : 7 °C 2 nd Chilled water inlet temperature : 13 °C 2 nd Chilled water outlet temperature : 8 °C



Fig. 2.1 대상 건물 조감도

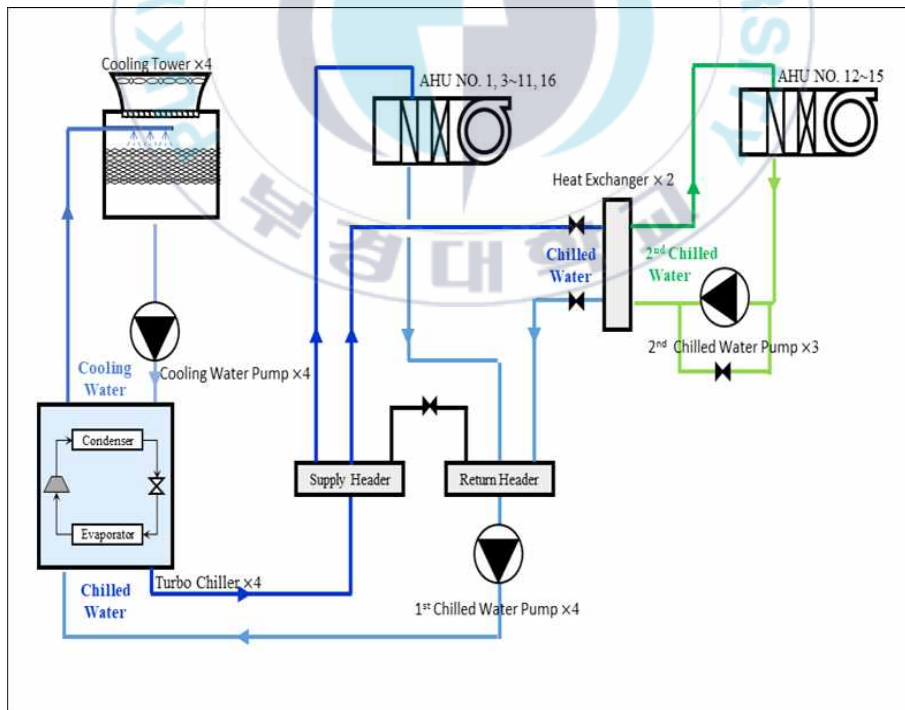


Fig. 2.2 대상 공조시스템 구상도

2.2 열원시스템 운전 현황

열원시스템 운전 현황 분석을 위해 대표일로서 2023년 6월 19일부터 6월 24일까지의 운전데이터를 이용하였다. 결과를 Fig. 2.3 ~ Fig. 2.5에 나타내었다. Fig. 2.3에서 외기온도 (T_{ao})는 건물 옥상의 백엽상 내에 설치된 온도센서를 통해 측정되었으며, 처리열량 (Q_{total})은 송수 헤더와 환수 헤더의 온도차와 냉수 유량을 이용하여 계산하였다. 외기온도는 $25^{\circ}\text{C} \sim 37^{\circ}\text{C}$ 정도로 낮과 밤의 기온차가 상당히 크게 나타났다. 처리열량은 약 $1,000 \text{ kWh} \sim 4,000 \text{ kWh}$ 범위에서 변동하였으며, 공조시스템을 기동하는 오전 5시 ~ 오전 6시에 주로 최대 부하가 발생하였으며 업무시간인 낮 시간대에 외기온도가 급격히 상승함에도 불구하고 부하 변동은 크지 않았다. 퇴근 시간인 오후 6시 이후에 부하가 급격히 감소하고, 오후 9시 ~ 오후 10시에 공조시스템이 정지되었다. Fig. 2.4에는 냉각탑 출구 냉각수 온도 (이하, 냉각수 온도, CWS)와 그 설정값 (CWS_{set}), 냉각탑 팬 운전대수 (CT_{Fan})을, Fig. 2.5에는 냉각탑 입출구 냉각수 온도차 (이하, 냉각수 온도차, $Diff_{CWS}$)와 그 설정값 ($Diff_{set}$), 냉각수 펌프 주파수 ($frequency$)를 나타내었다. 해당기간에는 냉동기 2대가 교차 운전되고 있어, 여기서는 주로 운전되고 있는 냉동기 1대와 그에 연결된 냉각탑, 냉각수 펌프에 대한 운전 상태를 표시하였다. Fig. 2.4를 보면, 외기온도와 처리열량이 시시각각 변화함에도 불구하고, 냉각수 온도 설정값은 관리자에 의해 설정된 고정 값으로 계속해서 운전되었다. 냉각수 온도는 “설정값 $\pm 2^{\circ}\text{C}$ ” 범위 내에서 유지되고 있었으며, 제어 위해 냉각탑 팬 3대가 계속해서 운전되었다. Fig. 2.5에서도 냉각수 온도차 설정값이 관리자에 의해 2°C 로 설정되어 변경없이 계속해서 운전되고 있는 것을 확인할 수 있다. 그리고 냉각수 온도차

가 설정값에 도달하지 못하는 것은 PI 제어의 게인값 튜닝이 제대로 이루어지지 않은 것으로 확인되었다.

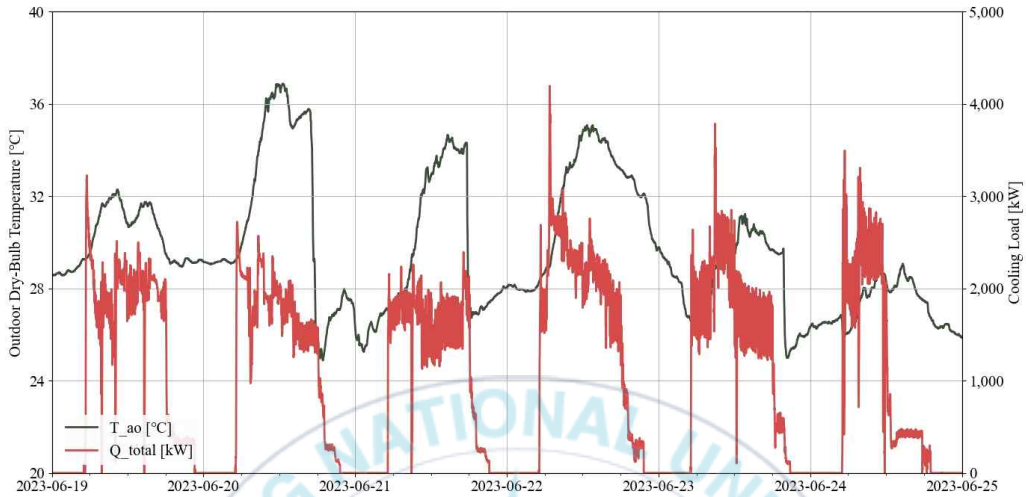


Fig. 2.3 외기온도와 부하 추이

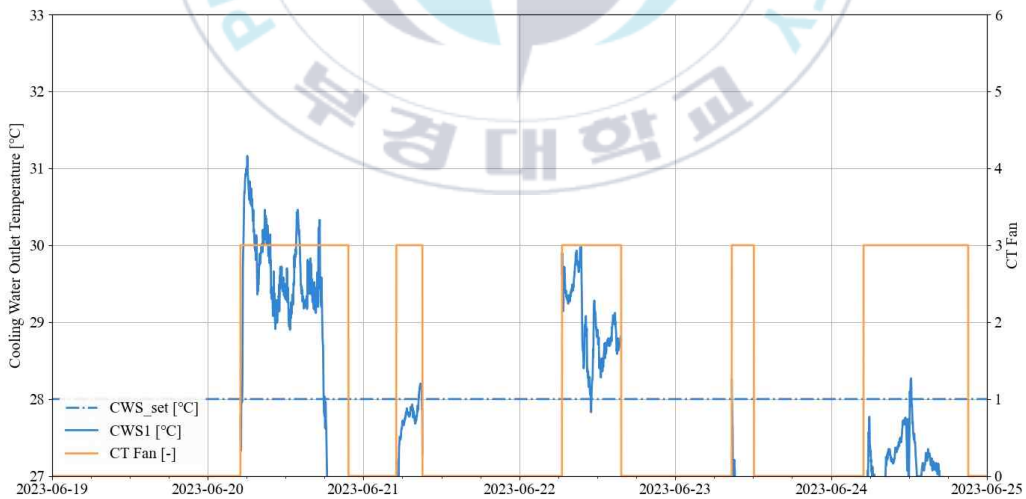


Fig. 2.4 냉각수 온도 및 냉각탑 팬 운전상태

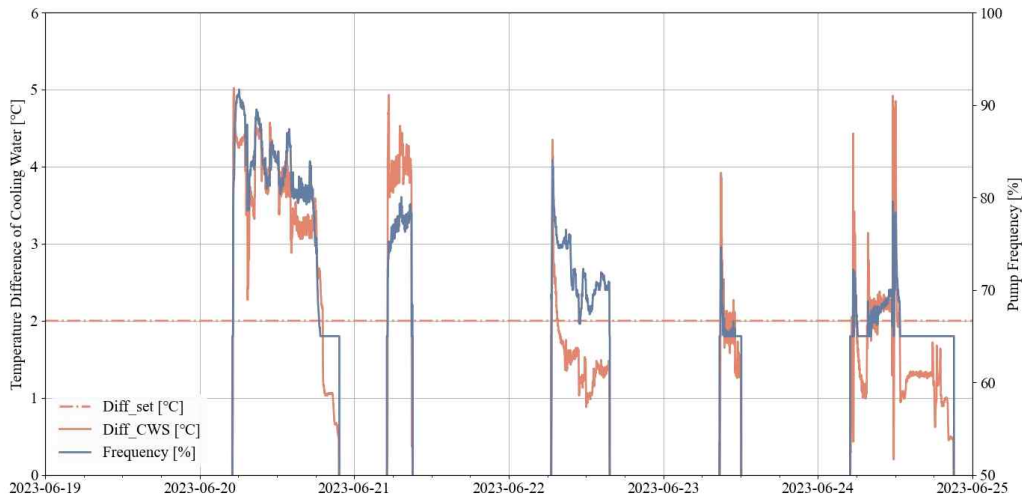


Fig. 2.5 냉각수 온도차 및 냉각수 펌프 운전상태

2.3 제어 시스템 구축 및 효과 검증 방법

본 연구에서는 개발한 알고리즘을 대상 HVAC 시스템에 적용하기 위해, BAS (Building Automation System)과 연동하도록 제어시스템을 구축하였다. Fig. 2.6는 구축한 제어시스템의 구성을 나타낸다. 알고리즘은 BAS의 data base에 저장된 1분 간격의 운전데이터를 읽어와서, 알고리즘을 실행하고 각 알고리즘의 목적에 맞게 최적화된 제어 설정값을 산출한다. 산출된 제어 설정값은 오픈 소스 메시지 브로커 소프트웨어인 Rabbit MQ를 통해 BAS의 Device Management에 전송된 후, 각 기기로 전달된다²⁵⁾. 이후, 다음 알고리즘 실행 전까지 열원시스템은 해당 제어 설정값에 따라 운전되며, 운전 데이터는 BAS에 저장되어 다음 알고리즘 실행 시 입력 데이터로 활용된다.

알고리즘의 효과를 분석하기 위해 알고리즘 적용 전과 후의 운전 데이터와 전력 소비량 데이터를 수집하여 비교 분석하였다. 그러나 실제 건물을 대상으로 한 알고리즘의 효과 검증은, 알고리즘 적용 전과 후의 외기 조건이나 건물 부하와 같은 경계조건의 차이로 인

해 에너지 절감 효과를 정량화하는 데에 어려움이 있다. 본 연구에서는 이러한 문제를 해결하기 위해 에너지 절감 효과 산출 방법으로 널리 사용되고 있는 IPMVP (International Performance Measurement and Verification Protocol)에서 제공하는 방법론을 채택하였다²⁶⁾. IPMVP의 Option C 검증 방법은 건물 전체에 대한 에너지 소비량을 분석하는 방법으로, 에너지 절감 방안이 적용되기 이전인 baseline 데이터를 기반으로 회귀분석을 통해 에너지 사용량을 예측하는 회귀식을 도출하고, 알고리즘 적용 후의 실제 에너지 사용량과 회귀식을 통해 산출한 에너지 소비량을 비교하여 효과를 정량화하는 방법이다.

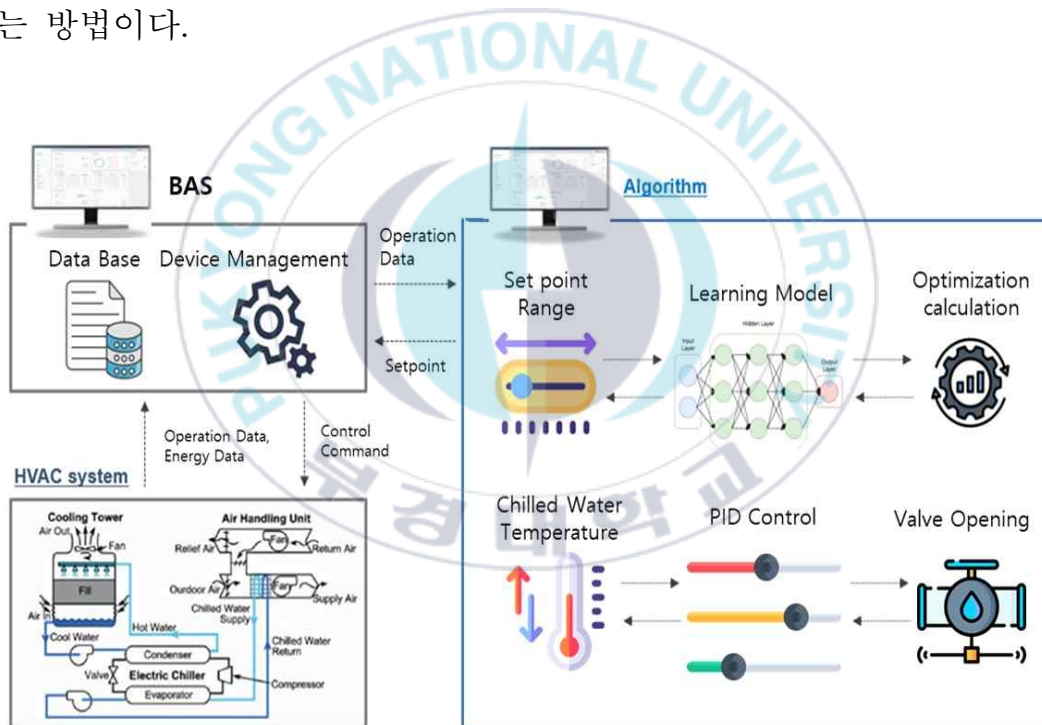


Fig. 2.6 알고리즘 실증을 위한 제어 시스템 구축

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

3.1 최적 제어 알고리즘 개발

본 연구에서는 공조시스템의 운전 효율 향상을 통한 에너지 절감을 위해 실시간으로 제어 설정값을 변경하는 최적 제어 알고리즘을 개발하였다. 최적 제어 알고리즘은 냉각수 알고리즘과 냉수 알고리즘으로 구분된다.

3.1.1 냉각수 알고리즘 개발

냉각수 알고리즘은 냉동기, 냉각탑, 냉각수 펌프를 대상으로 하며, 제어 설정값은 냉각수 온도와 냉각수 온도차이다. 냉각수 온도와 냉각수 온도차는 공조 시스템의 운전 효율성과 전력 소비량에 큰 영향을 미치는 주요 요소이다. 냉각수 온도를 높이면 냉각탑의 전력소비량은 감소하지만, 냉동기의 응축 압력이 상승하여 냉동기 전력소비량이 증가하게 된다. 반대로, 냉각수 온도를 낮추면 냉각탑의 전력소비량은 증가한, 냉동기의 응축압력이 감소하여 냉동기 전력소비량이 감소한다. 냉각수 펌프의 유량은 냉각수 온도차 설정값에 따라 제어된다. 냉각수 온도차를 크게 하면 냉각수 유량이 감소하여 냉각수 펌프의 전력 소비량이 줄어들지만, 이로 인해 냉동기의 열교환 성능이 저하되어 냉동기 전력소비량이 증가한다. 반대로, 냉각수 온도차를 작게 하면 냉각수 유량이 증가하여 냉각수 펌프 전력소비량은 증가하나, 냉동기의 전력소비량은 감소한다. 이렇게 냉각수 온도 설정값과 냉각수 온도차 설정값에 따라 기기의 전력소비량이 상충 (trade-off) 관계에 있어, 경계조건과 제어 설정값에 따라 공조기기의 전력소비량을 예측하여 최적의 제어 설정값을 선정함으

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

로써 공조시스템의 에너지 소비량을 절감할 수 있다. 본 연구에서는 DNN 기반 시스템 전력소비량 예측 모델과 최적화 계산을 통해 전력소비량이 최소가 되는 제어 설정값 조합을 탐색하는 알고리즘을 개발하였다.

Fig. 3.1은 냉각수 알고리즘의 흐름도를 나타낸다. 알고리즘 실행 주기는 실행시간 및 제어 추종 시간 등을 고려하여 5분 간격으로 하였다. 알고리즘은 실행 직전 5분 동안의 외기 습구온도와 냉동기 운전대수, 열원부하, 냉각수 온도와 냉각수 온도차를 입력하여 제어 변수인 냉각수 온도 설정값과 냉각수 온도차 설정값을 출력한다. 알고리즘은, 먼저 제어 설정값에 따른 열원시스템 전력소비량 예측을 위해 설정값 범위를 결정한다. 냉각수 온도 설정값 범위는 운전의 급격한 변동을 막기 위해 “기존 설정값 $\pm 1^{\circ}\text{C}$ ”로 결정하였다. 다만, 외기 습구온도와 냉각탑 사양을 고려하여 최저온도가 “외기 습구온도 + 3°C ”보다 작을 경우 해당 온도로 보정하였으며²⁷⁾, 냉동기 사양에 따라 최저온도 및 최고온도를 각각 24°C , 30°C 로 제한하였다. 냉각수 온도차 설정값 범위도 운전의 급격한 변동을 막기 위해 “기존 설정값 $\pm 1^{\circ}\text{C}$ ”로 결정하고, 최저온도 및 최고온도를 각각 2°C , 7°C 로 제한하였다. 이렇게 결정된 제어 설정값 범위를 통해 설정값 조합을 선정하고, DNN 예측 모델에 입력하여 모든 설정값 조합에 대한 열원시스템 전력소비량을 예측하였다. 최적화 계산에서는 예측된 열원시스템 전력소비량이 최소가 되도록 하는 제어 설정값 조합을 산출하였다. 열원시스템 전력소비량 예측에 사용된 DNN 모델 개발에 대해서는 3.3절에서 상세히 설명하였다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

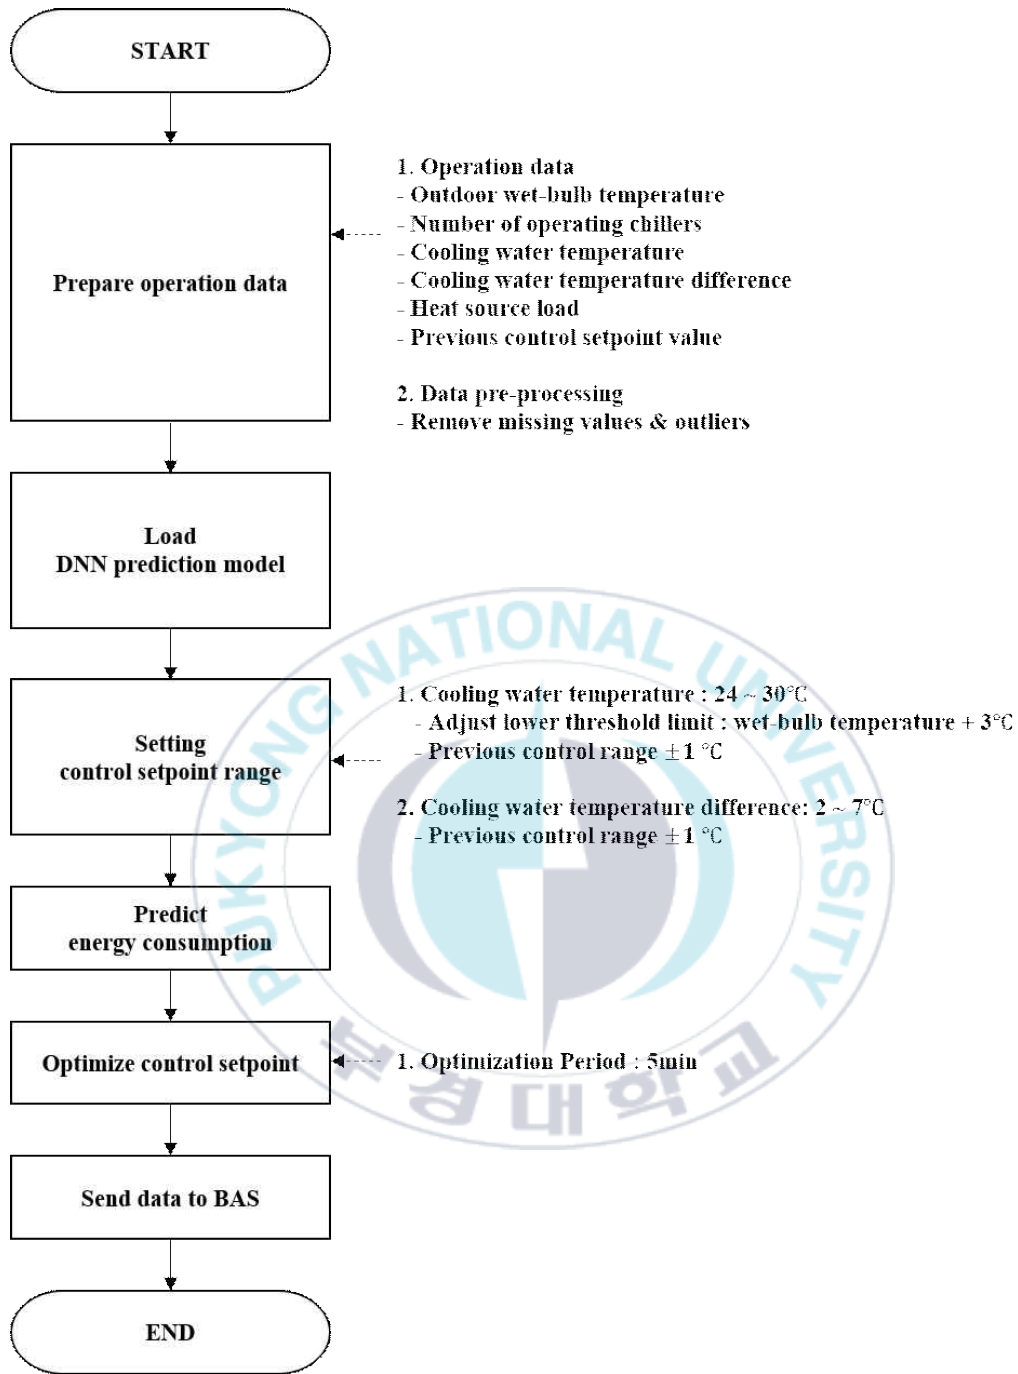


Fig. 3.1 냉각수 알고리즘 흐름도

3.1.2 냉수 알고리즘 개발

냉수 알고리즘은 냉동기, 냉수펌프, AHU를 대상으로 하며, 제어 설정값은 냉동기 출구 냉수 온도(이하, 냉수 온도)이다. 일반적으로 AHU 냉각 코일의 밸브 개도 제어를 통해, CAV 방식에서는 실내온도를, VAV 방식에서는 급기온도를 제어하며, 이 과정에서 냉수 온도는 고정된 값으로 운전된다. 저부하 구간에서는 코일 밸브 개도를 닫아 냉수 코일로 유입되는 냉수 유량을 줄여 실내온도와 급기온도를 제어한다. 하지만, 이 때 냉수 온도를 상승시키면 냉각 코일 밸브의 개도가 더 열리게 되어 냉수 유량이 증가하며, 동일한 실내 온도와 급기 온도를 유지할 수 있다. 에너지 효율 측면에서 보면, 변유량 시스템에서 냉수 유량이 증가하여 냉수 펌프의 에너지 소비량은 증가하나 냉수 온도 상승으로 인해 냉동기의 효율이 개선된다. 이로 인해 냉동기에서 소비되는 에너지가 줄어들어 전체적인 시스템 에너지 소비량이 감소하는 효과를 기대할 수 있다.

하지만, DNN 예측 모델은 시스템 전체의 전력소비량을 최소화하기 위해, 냉동기의 전력소비량 절감을 최우선으로 반영할 가능성이 높으며, 이에 따라 냉수 온도를 높게 설정하려는 경향이 있을 수 있다. 그러나 냉수 온도 설정값이 과도하게 높게 결정될 경우, 실내 온습도에 악영향을 미칠 수 있다. 따라서, 본 연구에서는 실내 환경을 안정적으로 유지하면서도 에너지 효율을 확보하기 위해, 앞서 설명한 원리를 기반으로 AHU의 냉각 코일 밸브 개도를 이용한 Rule 기반의 냉수 온도를 제어하는 알고리즘을 개발하였다.

Fig. 3.2는 냉수 알고리즘의 흐름도를 나타낸다. 알고리즘 실행 주기는 데이터 취득 및 전송 시간, 계산시간, 제어 추종시간, 설정값 변경에 따른 기기 부담 등을 고려하여 20분으로 하였다. 알고리즘은 냉각 코일 밸브 개도와 현재 냉수 온도를 입력하여 제어 변수인 냉

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

수 온도 설정값을 출력한다. 냉동기 기동 시에는 발생하는 최대 부하에 대응하기 위해 냉수 온도를 7°C로 설정한다. 이후, 모든 AHU의 냉각 코일 밸브 개도 중 최댓값(V_{max})과 현재 운전 중인 냉동기의 평균 냉수 온도($T_{chws,mean}$)을 계산하여, 밸브 개도 최댓값 V_{max} 가 목표 개도에 도달하도록 피드백 제어를 통해 냉수 온도를 결정한다. 식 3.1은 냉수 알고리즘에 사용된 피드백 제어를 이용한 냉수 온도 산출식이다.

$$T_{chws,set} = K_p \cdot e(t) + T_{chws,mean} \dots\dots\dots (3.1)$$

여기서, $T_{chws,set}$ 은 냉수 온도 설정값[°C], K_p 는 비례계인 [-], $e(t)$ 는 오차 [-]로 목표 개도와 현재 개도 V_{max} 간의 차이이고, $T_{chws,mean}$ 은 현재 운전 중인 평균 냉수 온도이다. 냉수 온도 제어로 인한 급기 온도 및 실내 온도 상승 문제를 방지하기 위해, 냉수 온도가 상승할 때와 하강할 때의 비례계인 K_p 값을 각각 -1.5, -5.0으로 달리 설정하여 상승 온도 폭은 비교적 작고 하강 온도 폭은 크게 하였다. 산출한 냉수온도는 냉동기 제어범위 7°C ~ 12°C를 만족하는지 확인 후 최종 설정값을 결정하고 BAS로 전송한다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

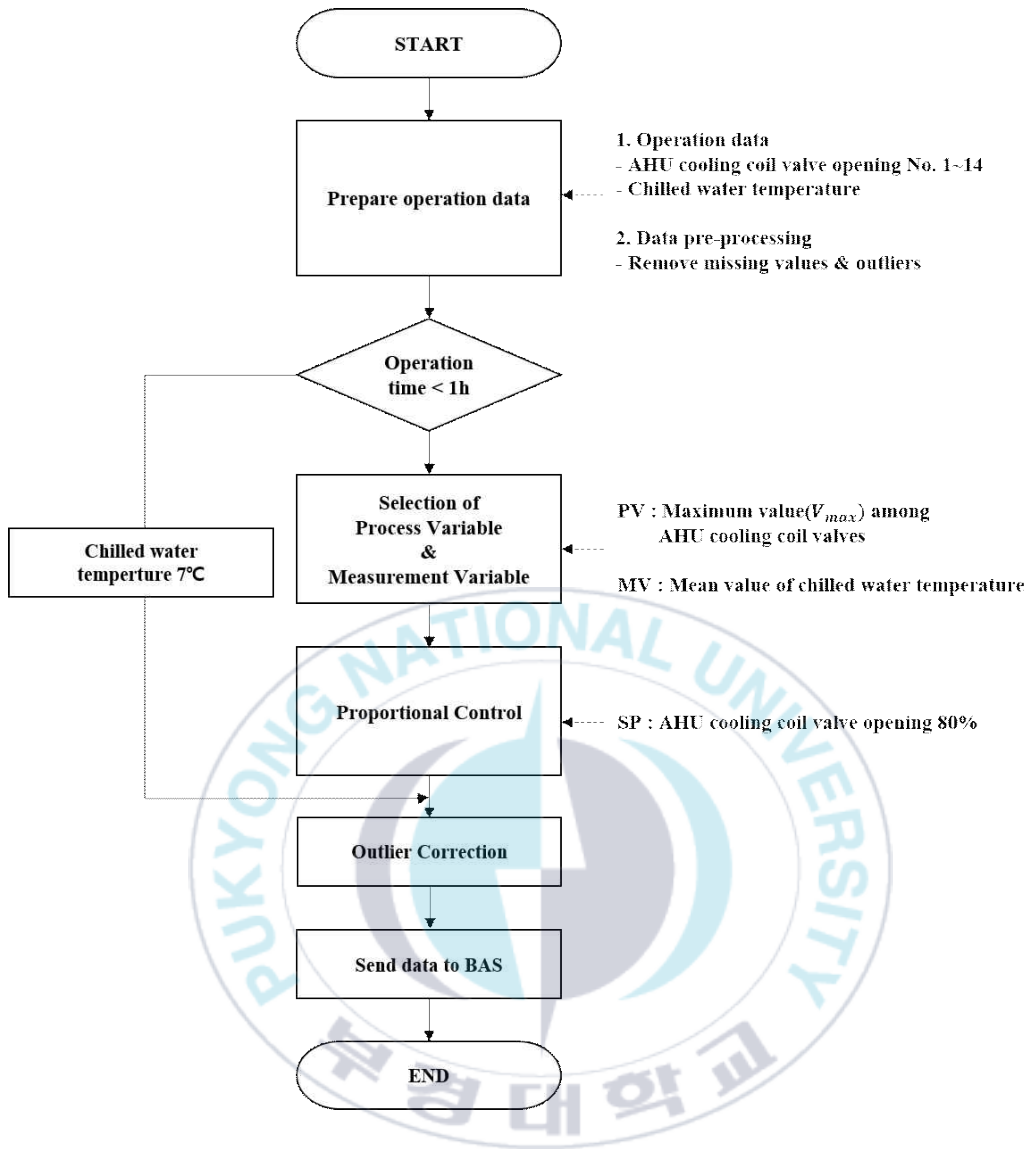


Fig. 3.2 냉수 알고리즘 흐름도

3.2 열원시스템 시뮬레이션 모델

공조시스템의 제어 설정값에 대한 최적화를 위해 데이터 기반 예측 모델을 개발하기 위해서는 상당 기간에 걸쳐 제어 설정값을 변경하면서 운전한 데이터가 필요하나, 앞서 2.2 절에서 분석했듯이, 제어 설정값을 변경하지 않고 일정한 값으로 운전하고 있어 유효한 운전데이터를 확보할 수 없었다. 또한, 충분하지 않은 실 운전데이터를 이용하여 모델을 개발할 경우, 일반적인 경향을 벗어나는 등 모델의 신뢰성을 잃을 수 있다. 따라서 본 연구에서는 학습 데이터 부족으로 인한 모델 신뢰성 저하 문제를 해결하기 위해 정확도 높은 시뮬레이션 모델을 구축하고 이를 이용하여 다양한 경계조건 및 설정값에 따른 양질의 학습데이터를 생성하였다.

3.2.1 열원시스템 시뮬레이션 모델 개요

Fig. 3.3은 열원시스템 시뮬레이션의 흐름도를 나타낸다. 흐름도의 좌측은 입력값을, 우측은 출력값을 나타낸다. 시뮬레이션은 냉동기의 열원부하, 냉동기 운전대수, 외기 습구온도, 제어 설정값인 냉각수 온도와 냉각수 온도차를 입력하여, 개별 기기의 전력소비량을 산출한다. 기기 모델인 터보 냉동기, 냉각수 펌프, 냉각탑 모델과 제어 모델인 냉각수 유량 제어, 냉각탑 팬 풍량 제어 모델을 각각 개발하고, 개별 모델을 상호 연결하여 열원시스템 전체를 모사할 수 있는 열원시스템 시뮬레이션 모델을 완성하였다.

시뮬레이션 모델의 정확도 검증에는 독립변수가 종속변수를 얼마나 잘 설명하는지를 나타내는 R^2 score와 오차의 상대적 크기를 나타내는 $CV(RMSE)$ 를 활용하였다. R^2 score와 $CV(RMSE)$ 의 계산식은 각각 식 3.2 ~ 3.4, 식 3.5 ~ 3.8과 같다. R^2 score는 1에 가까울수록

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

독립변수가 종속변수를 잘 설명함을 의미하며, CV(RMSE)는 0에 가까울수록 오차가 적음을 의미한다. 대표적인 M&V (Measurement and Verification Protocol) 가이드인 ASHRAE Guideline 14, IPMVP, FEMP 에서 제시하는 시간별 데이터 기준인 $R^2 \text{ score} > 0.75$, $CV(RMSE) < 30\%$ 을 만족하였을 시, 신뢰할 수 있는 모델 성능이라 판단하였다 (26,28,29).

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \dots\dots\dots (3.2)$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \dots\dots\dots (3.3)$$

$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \dots\dots\dots (3.4)$$

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST} \dots\dots\dots (3.5)$$

이때, y_i 는 관측값, \bar{y} 는 관측값의 평균, \hat{y}_i 는 예측값이다.

$$A_{period} = \frac{\sum_{period} M_{interval}}{N_{interval}} \dots\dots\dots (3.6)$$

$$RMSE_{period} = \sqrt{\frac{\sum (S - M)_{interval}^2}{N_{interval}}} \dots\dots\dots (3.7)$$

$$CV(RMSE)(\%) = \frac{RMSE_{period}}{A_{period}} \times 100 \dots\dots\dots (3.8)$$

이때, S 는 시뮬레이션에서 계산된 값, $M_{interval}$ 는 측정에 의한 관측 값, $N_{interval}$ 는 측정된 데이터 수이다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

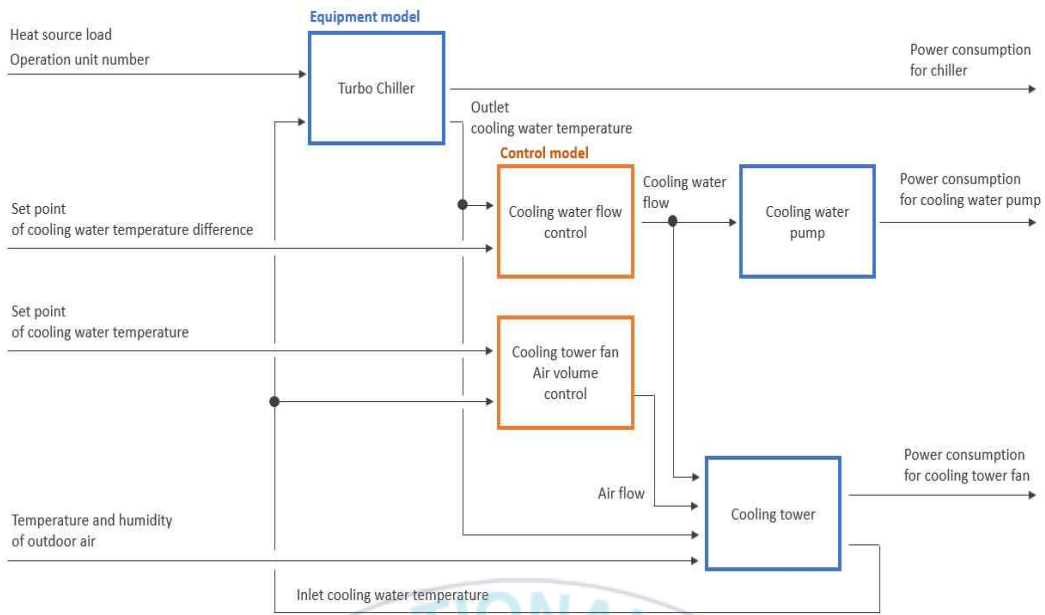


Fig. 3.3 열원시스템 시뮬레이션 흐름도

3.2.2 열원시스템 시뮬레이션 모델 개발

터보 냉동기 모델은 냉동기 열원부하와 냉각수 온도에 따른 전력 소비량 관계를 나타내는 성능곡선과 냉동사이클 이론을 기반으로 개발하였다. 냉동기 성능곡선을 나타내는 수식은 식 3.9와 같으며, 냉동사이클 이론을 바탕으로 한 냉동기 출구 냉각수 온도 계산식은 식 3.10와 같다.

$$Power_{chiller} = a_0 + a_1 \cdot Q + a_2 \cdot Q^2 + a_3 \cdot T_{CW,in} + a_4 \cdot T_{CW,in}^2 + a_5 \cdot Q \cdot T_{CW,in} \dots (3.9)$$

$$T_{CW,out} = C_{chiller} \cdot \frac{(Q + Power_{chiller})}{(m \cdot c)} + T_{CW,in} \dots (3.10)$$

여기서, $Power_{chiller}$ 는 냉동기 전력소비량 [kW], 이다. Q 는 냉동기 처리열량 [kW], $T_{CW,in}$ 는 냉동기 입구 냉각수 온도 [°C], m 는 냉각수

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

유량 [kg/h], c 는 물의 비열 [kg/(kg·K)], $a_0 \sim a_5$ 는 성능곡선 파라미터 [-], $C_{chiller}$ 는 보정 계수 [-]이다. 냉동기 모델의 입력데이터는 냉동기의 열원부하, 냉동기 운전대수, 냉동기 입구 냉각수 온도, 냉각수 유량이며, 출력데이터는 냉동기 전력소비량과 냉동기 출구 냉각수 온도이다. 이때, 처리열량은 냉수 펌프 유량 및 냉동기 입출구 냉수 온도차를 이용하여 계산하였다. 성능곡선의 파라미터($a_0 \sim a_5$)와 냉동기 출구 냉각수 온도의 정확도 향상을 위한 보정 계수($C_{chiller}$)는 23년 4월 1일부터 9월 5일까지의 20분 간격의 실 운전 데이터를 이용하여 최소자승법을 기반으로 산출하였으며, 그 결과는 Table 3.1에 나타내었다. 이때, 냉동기의 전력소비량은 전력량계를 통해 측정된 실제 데이터를 이용하였다. 냉동기 전력소비량의 예측 정확도는 R^2 score 0.94, CV(RMSE) 6.3%이며, 냉동기 출구 냉각수 온도의 예측 정확도는 R^2 score 0.99, CV(RMSE) 0.74%이다.

Table 3.1 물리식 시뮬레이션 모델 : 파라미터와 보정 계수 계산 결과

성능 곡선 파라미터						보정 계수
a_0	a_1	a_2	a_3	a_4	a_5	$C_{chiller}$
-289.275 7986783	-0.01845 87526	-0.00000 94459	26.30776 58951	-0.50222 54366	0.006311 2951	1.28

냉각탑은 냉각수와 외기가 역방향으로 흐르는 향류형이며, 충전재는 수막식이다. 냉각탑의 모델 식을 식 3.11 ~ 3.13에 나타낸다³⁰⁾. 식 3.11은 냉각탑의 열교환량에 대한 계산 식이며, 식 3.12는 향류형

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

냉각탑의 수막식 충전재에 대한 물질 전달 계수(coefficient of mass transfer) 실험식이며, 식 3.13는 대수 엔탈피 차에 대한 계산 식이다.

$$Q = C_{CT} \cdot (ka \cdot A \cdot Z \cdot LMED) \dots\dots\dots (3.11)$$

$$ka = 7.5 \cdot \left(\frac{\lambda_g}{d_e^2 \cdot C_s} \right) \cdot \left(\frac{L}{A} \cdot \frac{d_e}{\gamma_l \cdot \nu_l} \right)^{0.45} \cdot \left(\frac{G}{A} \cdot \frac{d_e \cdot C_s}{\lambda_g} \right)^{0.46} \cdot \left(\frac{d_e}{Z} \right)^{0.74} \dots\dots\dots (3.12)$$

$$LMED = \frac{(h_{w1} - h_2) - (h_{w2} - h_1)}{\log \left\{ \frac{(h_{w1} - h_2)}{(h_{w2} - h_1)} \right\}} \dots\dots\dots (3.13)$$

여기서, Q 는 냉각탑 열교환량 [kJ], C_{CT} 는 보정 계수 [-], ka 는 물질 전달 계수 [kcal/m³h (kcal/kg^o)], A 는 냉각탑 충전재 단면적 [m²], Z 는 냉각탑 충전재 높이 [m], $LMED$ 는 로그 평균 엔탈피차 (Logarithmic Mean Enthalpy Difference [kcal/kg^o], λ_g 는 공기 열전도율 [kJ/ms·K], d_e 는 냉각탑 충전재의 상당 지름 (Equivalent diameter of Cooling tower filler) [m], C_s 는 습공기 비열 [kJ/kg^o·K], L 은 수량 [kg/s], γ_l 는 물의 비중 [kg/m³], ν_l 는 물의 동점성 계수 (kinetic viscosity of water) [m²/s], G 는 냉각탑 팬 풍량 [m³/s]이다. 냉각탑 모델의 입력값은 냉각탑 입구 냉각수 온도, 냉각수 유량, 냉각탑 팬 풍량, 외기 온습도이며, 출력값은 냉각탑 처리열량과 냉각탑 출구 냉각수 온도이다. 냉각탑 전력소비량과 냉각탑 출구 냉각수 온도 예측 정확도 향상을 위한 보정 계수 (C_{CT})는 23년 4월 1일부터 9월 5일까지의 20분 간격의 실 운전 데이터를 이용하여 최소자승법에 의해 산출하였다. 이때, 냉각탑 전력소비량은 전력량계 고장으로 인해 냉각탑 팬 운전대수를 팬 정격 소비전력을 곱한 값을 사용하였고, 식 3.14에 나타낸다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

$$Power_{CT} = 37 \cdot N_G \dots\dots\dots (3.14)$$

여기서, $Power_{CT}$ 는 냉각탑 전력소비량 [kW], 37은 냉각탑 팬의 정격 소비전력 [kW], N_G 는 냉각탑 팬 운전대수 [-]이다. 그 결과, C_{CT} 는 0.85이며, 냉각탑 출구 냉각수 온도 예측 정확도는 R^2 score 0.83, CV(RMSE) 2.7%이다.

냉각수 펌프 모델은 축동력과 유량의 관계식으로부터 펌프의 전력소비량을 계산하였다. 펌프 모델 식을 식 3.15에 나타낸다.

$$Power_{pump} = \frac{Power_{pump,rated}}{\eta_{Pump}} \cdot \left(\frac{m_{rated} \cdot f}{m_{rated}} \right)^3 \dots\dots\dots (3.15)$$

여기서, $Power_{pump}$ 는 펌프 전력소비량 [kW], $Power_{pump,rated}$ 는 펌프 정격 소비전력 [kW], η_{Pump} 는 펌프 효율 [-], f 는 펌프 주파수 출력 [-], m_{rated} 는 펌프정격유량 [m^3/s]이다. 냉각수 펌프 모델의 입력값은 펌프 정격 소비전력, 펌프 효율, 정격 유량이며, 출력값은 냉각수 펌프의 전력소비량이다. 냉각수 펌프는 전력량계 고장으로 인해 전력 소비량을 측정하지 못하여 별도의 정확도 검증을 실시하지 못하였다.


제어 모델인 냉각수 유량 제어, 냉각탑 팬 풍량 제어 모델은 앞서 2.2 장에서 설명한 제어 사양에 따라 모델링을 진행하였다. 이렇게 개발한 기기 모델과 제어 모델을 연결하여 열원시스템 시뮬레이션 모델을 완성하였다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

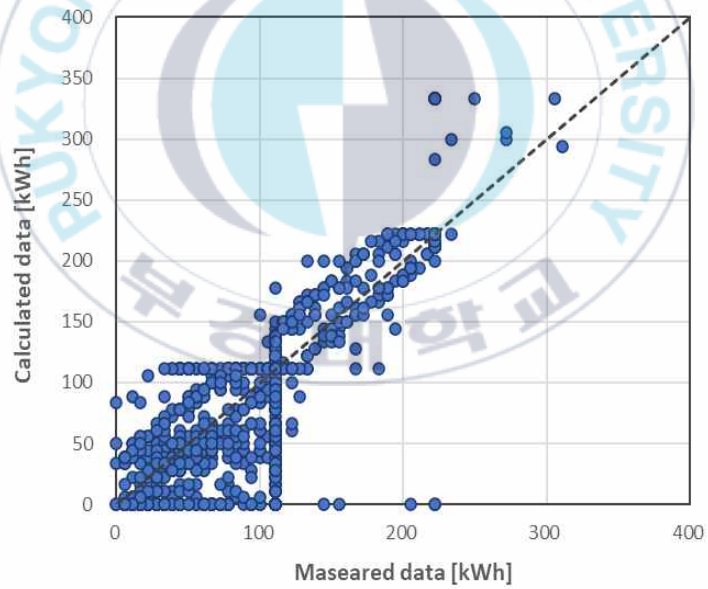
3.2.3 시뮬레이션 모델 정확도 검증 및 데이터 생성

23년 4월 1일부터 9월 5일까지의 실 운전데이터를 이용하여 열원 시스템 시뮬레이션에 대한 정확도를 검증하였다. 그 결과를 Fig. 3.4에 나타내었다. 냉동기 전력소비량의 예측 정확도는 R^2 score 0.96, CV(RMSE) 13.5%이며, 냉각탑의 전력소비량의 예측 정확도는 R^2 score 0.88, CV(RMSE) 15.1%이다. ASHRAE Guideline14와 IPMVP, FEMP (Federal Energy Management Program)에서 시간 간격으로 보정한 시뮬레이션의 오차 허용 기준 R^2 score 0.75 이상, CV(RMSE) 30% 이하를 모두 만족하였다^{26,28,29}. 개발한 시뮬레이션 모델을 이용하여 제어 설정값을 변경하면서 열원시스템의 전력소비량을 산출하였다. 냉각수 온도 설정값은 24°C ~ 30°C 범위 내에서 1°C 간격으로 변경하였으며, 냉각수 온도차 설정값은 2°C ~ 7°C 범위 내에서 1°C 간격으로 변경하였다. 이 때, 시뮬레이션 모델의 입력값인 열원 부하와 외기온습도는 23년 4월 1일부터 9월 5일까지의 실 운전데이터를 사용하였다. 설정한 모든 제어 설정값에 대해서 시뮬레이션을 실행하여 총 25,504개의 시간당 학습데이터를 생성하였다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증



(a) 터보 냉동기



(b) 냉각탑

Fig. 3.4 열원시스템 시뮬레이션 정확도 평가 결과

3.3 DNN 기반 열원시스템 전력소비량 예측모델 개발

3.3.1 인공신경망

HVAC 시스템은 다양한 하위 기기와 제어 요소 간의 복잡한 상호작용으로 인해 비선형적인 특성을 보인다. 본 연구에서는 데이터 기반 인공신경망을 활용하여 이러한 비선형 특성을 효과적으로 반영함으로써 에너지 소비량을 예측하고자 한다.

대표적인 데이터 기반 예측 모델인 ANN는 1943년 W. McCulloch와 W. Pitts가 제안한 사람의 신경계를 모사하여 만든 기계 학습 방법으로, 그 종류에는 다중 은닉층을 가지는 DNN, 합성곱층과 풀링층을 기반으로 2D 이미지 처리에 용이한 CNN (Convolutional Neural Network), 시퀀스 데이터를 다루는 RNN (Recurrent Neural Network) 등이 있다. 본 연구에서는 건물의 에너지 소비량 예측에 있어서 좋은 예측 성능을 보이는 다중 은닉층을 가지는 DNN 기반의 예측 모델을 구축하였다³¹⁾. Fig. 3.5와 같이, DNN은 입력층과 다수의 은닉층, 출력층으로 구성되며, 각 층에는 다수의 뉴런 (a)가 배치된다. 은닉층은 활성화 함수 (f)를 사용하여 각 뉴런의 가중치 (w)와 편향 (b)를 고려해 출력을 결정한다. 기본적으로 인공신경망은 순전파 알고리즘을 기반으로 각 층 별로 순차적인 계산을 통해 출력값을 도출하기 때문에, 목적함수를 줄이기 위해 역전파 알고리즘을 활용하여 각 뉴런의 가중치를 조정하는 방식으로 모델을 학습한다³²⁾.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

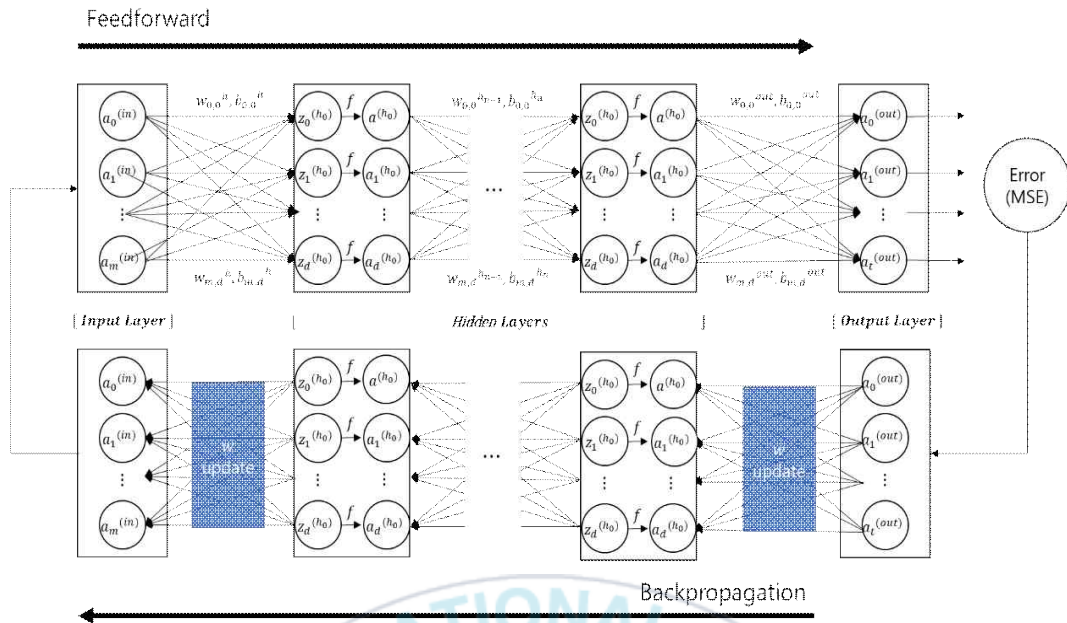


Fig. 3.5 DNN 구조 & 가중치 최적화 알고리즘

활성화 함수로는 다층 신경망에 주로 사용되는 ReLu (Rectified Linear Unit)을 사용하였다. ReLu 함수는 식 3.16과 같이 입력값이 양수인 경우 출력값의 기울기 (도함수)는 항상 1이므로, 다른 Tanh 함수나 Sigmoid 함수에서 모델 훈련과정 중 발생하는 기울기 소실 문제를 해결할 수 있다.

$$f(x) = \begin{cases} 0 & (x \leq 0) \\ x & (x > 0) \end{cases} \dots\dots\dots (3.16)$$

가중치 업데이트를 위한 옵티마이저 (Optimizer)는 Adam (Adaptive moment estimation)을 사용하였다. Adam은 AdaGrad (Adaptive Gradient)와 RMSProp (Root Mean Square propagation)을 결합한 함수로, 비교적 간단하지만 성능과 효율은 우수하다. 목적함수로는 MSE (Mean Squared Error), 모델 성능 평가지표 (metrics)로는 MAE (Mean Absolute Error)를 사용하였고, 식 3.17 ~ 3.18과 같이 나타낸다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \dots\dots\dots (3.17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots\dots\dots (3.18)$$

여기서, n 은 데이터의 총 개수, y_i 는 i 번째 실제값, \hat{y}_i 는 i 번째 예측값이다.

3.3.2 DNN 모델 개발 개요

본 연구에서는 HVAC 시스템의 에너지 소비량을 예측하기 위해 Python을 활용하여 예측모델을 개발하였다. Python은 데이터 분석을 위한 Pandas, Numpy, Matplotlib이나, 머신러닝을 위한 Tensorflow, Pythorch, Scikit-learn 등 다양한 라이브러리가 내장되어있으며, 코드가 비교적 간결하고 직관적이라 학습 모델 구축에 많이 사용된다.

DNN 기반 예측 모델 개발의 흐름도를 Fig. 3.6에 나타낸다. 개발 과정은 1) 데이터 세트 분류(Building dataset), 2) 하이퍼 파라미터 최적화 (Hyper parameter optimization, 3) DNN 모델 학습 (DNN model training), 4) 모델 정확도 평가 (Model Evaluation)로, 크게 4단계로 구성된다. 첫 번째 단계인 데이터 세트 분류에서는 열원시스템 시뮬레이션 모델을 통해 취득한 데이터들 중 학습에 필요한 데이터를 선정하고 정규화를 통해 데이터들 간의 크기를 조정하였다. 이후, 하이퍼 파라미터 최적화 및 예측 모델 학습을 위해 학습데이터를 학습용, 검증용, 테스트용 3 분류로 나누었다. 다음으로, 모델의 예측 정확도 향상을 위해 하이퍼 파라미터 최적화를 진행하였으며, 최적화 결과를 바탕으로 모델을 학습시켜 열원시스템 전력소비량을 예

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

측하였다. 마지막으로, 테스트용 데이터를 이용하여 R^2 score과 CV(RMSE) 지표를 기반으로 모델의 성능을 평가하였다. 아래에 각 단계에 대한 내용을 상세히 기술하였다.

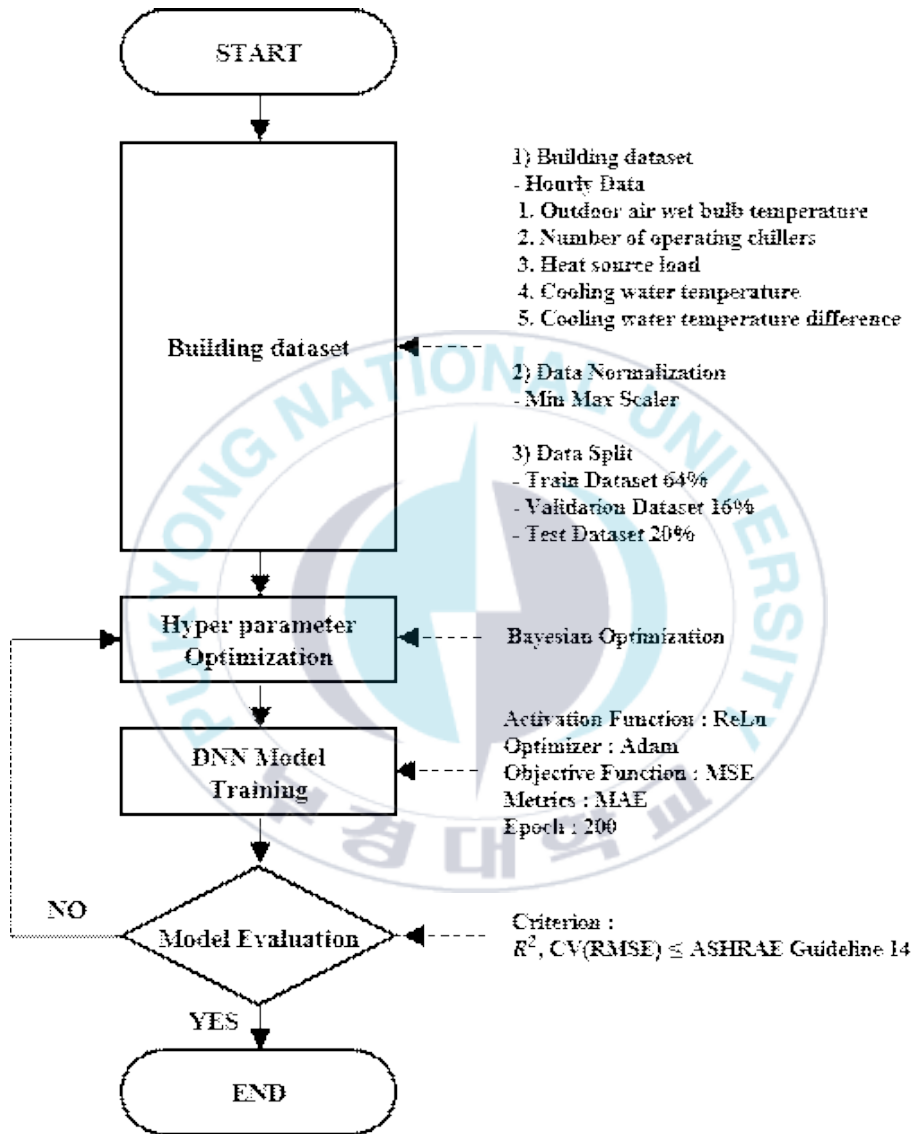


Fig. 3.6. DNN 예측 모델 개발 흐름도

3.3.3 DNN 모델 개발

1) 데이터 세트 분류

학습 데이터셋은 시뮬레이션을 통해 생성한 데이터 중 물리법칙에 의해 열원시스템 전력소비량에 영향을 미치는 항목을 선정하였다. 입력데이터는 외기 습구온도, 냉동기 운전대수, 열원부하, 그리고 제어 설정값인 냉각수 온도 및 냉각수 온도차이며, 출력데이터는 열원시스템을 구성하는 터보냉동기, 냉각탑, 냉각수 펌프의 전력소비량 합산값 (이하, 열원시스템 전력소비량)로, Table 3.2에 나타내었다. 데이터들 간의 스케일 차로 인한 모델 성능 저하를 방지하기 위해 데이터 정규를 진행하였다. 다양한 정규화 방법이 존재하지만, 본 연구에서는 Min-Max Normalization을 사용하였다 (식 3.19). 각 데이터의 최댓값을 1, 최소값을 0으로 지정하여, 나머지 값들을 그 사이 범위에 속하도록 데이터의 크기를 축소시키는 방법으로, 변환식은 Eqs (xxx)에 나타내었다. 정규화된 데이터는 예측 모델을 구축하기 위한 학습용과 모델의 일반화 성능을 테스트하기 위한 검증용, 그리고 모델의 최종 성능을 확인하기 위한 테스트용으로 분류된다. 본 연구에서는 각각의 데이터셋을 전체 데이터의 64%, 16%, 20%로 분류하였다.

$$Y_i = \frac{X_i - \min(X)}{\max(X) - \min(X)} \dots\dots\dots (3.19)$$

여기서, Y_i 는 정규화된 값, X_i 는 원본 데이터 값, $\min(X)$ 은 데이터 세트의 최솟값, $\max(X)$ 는 데이터 세트의 최댓값이다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

Table 3.2 DNN 모델의 입력데이터, 출력데이터

데이터 종류	변수
입력데이터	외기 습구온도 [°C]
	냉동기 운전대수 [-]
	열원부하 [kWh]
	냉각수 온도 [°C]
	냉각수 온도차 [°C]
출력데이터	열원시스템 전력소비량 [kWh] (터보 냉동기 + 냉각탑 + 냉각수 펌프)

2) 하이퍼 파라미터 최적화

하이퍼 파라미터는 모델 설계자가 결정하는 파라미터로서 모델의 예측 정확도와 학습 효율에 큰 영향을 미치는 인자이므로 최적화가 필요하다. 하이퍼 파라미터 최적화 방법에는 매뉴얼 서치, 그리드 서치, 랜덤 서치, 베이지안 최적화 등이 있다. 매뉴얼 서치는 사용자가 경험이나 개인 판단에 의존해 직접 값을 지정하는 방법으로, 임의의 값들을 이용해 최적 조합을 도출하기 위해서 여러 번 최적화 과정을 반복해야 한다. 그리드 서치는 사용자가 지정한 범위의 모든 하이퍼 파라미터에 대해서 계산한 후 최적화 값을 찾는 방법이다. 모든 값들을 다 계산하기 때문에 항상 우수한 성능을 보여주지만 최적화 시간이 오래 걸리는 단점이 있다. 랜덤 서치는 사용자가 범위를 지정하며 그 범위 내에서 무작위로 임의의 하이퍼 파라미터를 선정하여 최적의 값을 찾는 방법이다. 그리드 서치에 비해 시간 측면에서는 이득을 보지만, 중요도가 높은 파라미터를 지나칠 수 있다는 단점이 있다. 베이지안 최적화는 적은 시도로 전역 최적해를 찾기 위한 방법으로, 대체 모델과 획득 함수로 이루어져 있다. 대체 모델은 획득함수가 도출한 범위 (초기에는 임의의 범위)를 바탕으로

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

미지의 목적함수를 추정한다. 대체 모델은 목적함수를 효과적으로 모델링할 수 있고, 목적함수로의 근사화가 용이한 가우시안 프로세스가 사용된다. 획득 함수는 목적함수를 최소화하기 위해 추정된 이전 결과들을 기반으로 다음 범위, 즉 입력값을 도출한다. 획득 함수에는 이전 결과들 중 함수값이 최댓값을 가지는 지점 주변을 탐색하는 Exploitation과, 이전 결과들 중 표준편차가 최댓값을 가지는 지점 주변을 탐색하는 Exploration으로 나뉜다. 정확한 입력값을 도출하기 위해서는, Exploitation과 Exploration 간의 적절한 조절이 필요하다. 최근에는 이 두 방법을 적절하게 이용하는 EI (Expected Improvement)가 많이 사용되며, 식 3.20과 같이 나타낼 수 있다³³⁾.

$$E[I(\lambda)] = (f - \mu(\lambda))\Phi\left(\frac{f - \mu(\lambda)}{\sigma}\right) + \sigma\phi\left(\frac{f - \mu(\lambda)}{\sigma}\right) \dots\dots\dots (3.20)$$

여기서, E는 EI, $I(\lambda)$ 은 개선치, f 은 현재까지의 최댓값, $\mu(\lambda)$ 은 평균, Φ 은 누적 분포 함수 (cumulative distribution function), σ 은 분산, ϕ 은 확률 밀도 함수이다. $f - \mu(\lambda)$ 은 예상 개선 정도, $\Phi\left(\frac{f - \mu(\lambda)}{\sigma}\right)$ 는 개선될 확률, $\phi\left(\frac{f - \mu(\lambda)}{\sigma}\right)$ 는 개선의 밀도(혹은 정도)를 나타낸다. 따라서, EI는 목적함수를 최소화하기 위해 특정 변수보다 낮거나 같은 확률을 나타내는 누적 분포 함수와 확률밀도함수를 조정하여 기댓값을 계산한다. 즉, EI는 탐색하고자 하는 범위에서 개선할 수 있는 기대치를 계산하여, 다음 입력값으로 도출한다³⁴⁾. 따라서, 베이지안 최적화는 목적함수를 이전 결과들을 바탕으로 입력값을 추천하고, 이 입력값을 이용해 목적함수를 추정하며 대체 모델을 업데이트한다. 이전 결과를 반영하고 전역 최적해를 찾기 때문에, 앞선 방법들에 비해 시간적으로나 비용적으로 유용하여 본 연구에서는 베이지

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

안 최적화를 하이퍼 파라미터 최적화 기법으로 사용하였다. 하이퍼 파라미터 종류에는 은닉층 수, 각 은닉층 별 노드 수, 드랍아웃, 학습률, 배치 사이즈 등이 있지만, 본 연구에서는 은닉층 수, 각 은닉층 별 노드 수, 드랍아웃, 학습률, 이 4가지 항목을 최적화 대상으로 삼았다. 하이퍼 파라미터 범위 및 최적화 결과를 Table 3.3에 나타낸다. 각 항목의 최적화 범위는, 은닉층 수는 2개 ~ 10개, 각 은닉층 별 노드 수는 16개 ~ 256개, 드랍아웃은 0.0 ~ 0.5, 학습률은 0.0001 ~ 0.01이다. 베이지안 최적화 결과, 최적의 하이퍼 파라미터 조합은 은닉층 수 3개, 각 은닉층 별 노드 수는 156개, 173개, 87개, 드랍아웃 0.0, 학습률 0.0001로 선정되었다.

Table 3.3 DNN 모델의 하이퍼 파라미터 최적화

	범위	결과
은닉층 수	2개 ~ 10개	3개
각 은닉층 별 노드 수	16개 ~ 256개	156개, 173개, 87개
드랍아웃	0.0 ~ 0.3	0.0
학습률	0.0001 ~ 0.01	0.0001

3) DNN 모델 학습

하이퍼 파라미터를 최적화한 모델을 이용하여 모델 학습을 진행하였다. 이때, 학습 수는 200번으로 하였다. 학습용 데이터를 이용해 모델을 학습시키고, 모델 성능 평가 이전에 과적합과 같은 문제를 해결하기 위해 일반화 검증을 실시하였다. 교차검증과 같은 방법도 사용되지만, 본 연구에서는 학습에 사용되지 않은 데이터인 검증용 데이터를 이용해 Validation loss가 가장 낮은 모델로 지속적인 업데이트를 통해 일반화 문제를 해결하였다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

4) 모델 평가

학습 모델의 예측 정확도 결과를 Fig. 3.7에 나타낸다. 예측 모델의 정확도 평가에는 R^2 score와 CV(RMSE)를 활용하였다. 실측값과 예측값이 거의 일치하였으며, 예측 정확도는 R^2 값 0.99, CV(RMSE) 1.21 %으로, ASHRAE Guideline14, IPMVP, FEMP에서 제시하는 기준을 모두 만족하는 수치이다 [28][31][32].

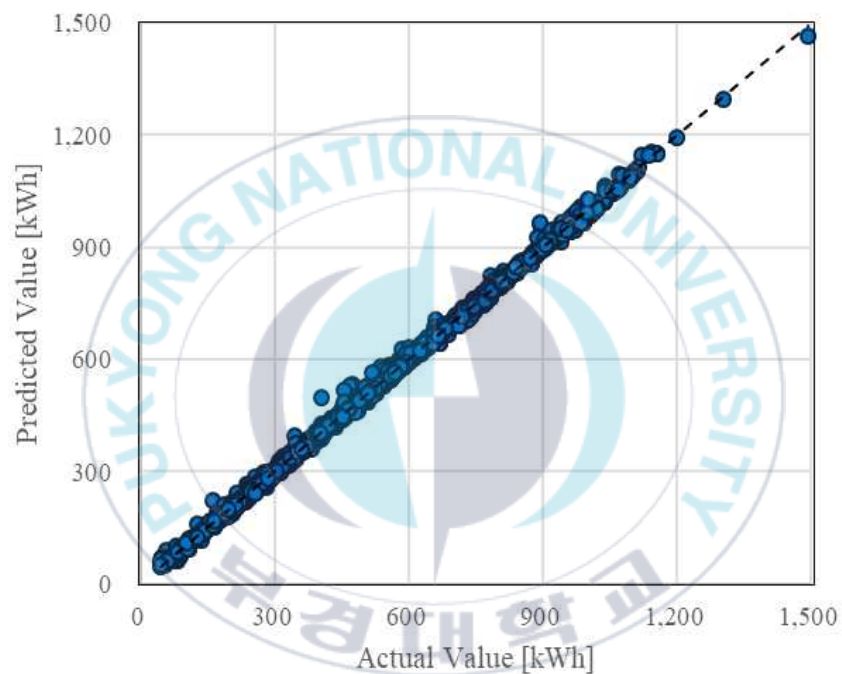


Fig. 3.7 DNN 모델 예측정확도 검증 결과

3.4 최적 제어 알고리즘 실증 연구

앞서 3.1장에서 개발한 최적 제어 알고리즘을 실제 건물에 설치된 열원시스템에 적용하여 그 효과를 검증하였다. Baseline 기간은 23년 4월 1일부터 ~ 9월 5일이며, Algorithm 적용 기간은 23년 10월 27일 ~ 24년 6월 26일이다. Baseline의 제어 설정값은, 냉각수 온도 28°C, 냉각수 온도차 2°C, 냉수 온도 7°C로 고정된 값으로 운전되었다. 이는 한국 건물 열원시스템에서 통상적으로 사용하는 설정값인, 냉각수 온도 32°C, 냉각수 온도차 5°C와 차이가 이으며, 이는 대상 건물이 한국보다 고온 다습한 아열대기후에 위치하였기 때문이라 판단된다. 최적 제어 알고리즘의 제어 설정값 탐색 범위는, 냉각수 온도 24°C ~ 30°C, 냉각수 온도차 3°C ~ 7°C, 냉수 온도 7°C ~ 12°C이다. 냉수 알고리즘은 AHU 냉각 코일 밸브 개도가 항상 100%에 가깝게 운전되는 엘리베이터 홀을 담당하는 AHU와 밸브 개도가 고정되어 운전되고 있는 주방을 담당하는 AHU를 제외한 13대를 대상으로 하였다. 그리고, Baseline 기간 중 냉동기 운전대수가 1대인 데이터만 효과 검증에 활용하였다. Baseline 기간 동안에는 부하에 관계없이 관리자의 판단에 의해 냉동기 운전대수 1대 ~ 2대로 운전하였으나, 알고리즘 적용 기간에는 냉동기 1대로 충분히 부하를 처리할 수 있어 대체로 1대로만 운전을 하였다. 냉동기 운전대수의 차이가 알고리즘 효과에 영향을 줄 수 있어 운전대수가 동일한 데이터만 효과 검증에 활용하였다.

3.4.1 제어 설정값 비교

알고리즘 적용 전과 후의 제어 설정값을 비교하였다. Fig. 3.8 ~ Fig. 3.10은 알고리즘 적용 전과 후의 경계조건에 따른 제어 설정값 변화를 나타낸다. Fig. 3.8은 냉방부하에 따른 냉각수 온도 설정값 변화로, 알고리즘 운전 시 냉방부하가 증가하면 냉각수 온도 설정값이 낮아지는 경향을 확인할 수 있다. 이때, 동일한 부하 구간에서 냉각수 온도 분포가 나뉘는 현상은, 냉각수 온도 설정값이 단순히 부하뿐만 아니라 습구온도와 같이 외기 조건에 영향을 받기 때문인 것으로 분석된다. 알고리즘 적용으로 인해 평균 냉각수 온도 설정값은 baseline 운전 28°C에서 algorithm 운전 29.4°C로, baseline 운전 대비 1.4°C 상승하였다. Fig. 3.9는 냉방부하에 따른 냉각수 온도차 설정값 변화로, 알고리즘 운전 시 냉방부하가 증가하면 냉각수 온도차 설정값이 증가하는 경향을 확인할 수 있다. 이는 최소 냉각수 유량으로 운전하였을 때 에너지 절감 효과가 극대화되는 시스템 특성이 반영된 결과로 판단된다. 특히 저부하 구간에서는 온도차 설정값과 관계없이 최소 유량 조건을 만족시키므로 동일 부하에서도 설정값의 편차가 크게 나타났다. 동일한 부하 구간에서 냉각수 온도 분포가 나뉘는 경향은, 냉각수 온도차 설정값이 부하뿐만 아니라 냉각수 온도 설정값과 같이 다른 조건에 영향을 받기 때문인 것으로 분석된다. 알고리즘 적용으로 인해 평균 냉각수 온도차 설정값이 baseline 운전 2°C에서 algorithm 운전 5.4°C로, baseline 운전 대비 3.4°C 증가하였다. Fig. 3.10은 냉방부하에 따른 냉수 온도 설정값 변화이다. 알고리즘을 적용하면 냉방부하가 적은 저부하 구간으로 갈수록 냉수 온도 설정값이 상승하는 경향을 보였다. 대상 시스템은 알고리즘 운전 기간 동안 대체로 11°C ~ 12°C로 설정되었다. 이외의

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

온도 분포는 냉동기 기동 시 설정한 냉수온도 7°C에서 알고리즘에 의해 서서히 상승하면서 발생한 것으로 확인되었다. 이때, 동일한 부하 구간에서 냉수 온도 분포가 나뉘는 경향은, 냉수 온도 설정값 역시 단순히 부하뿐만 아니라 기타 경계조건 및 시스템 운전 상태에도 영향을 받기 때문인 것으로 판단된다. 알고리즘 적용으로 인해 평균 냉수 온도 설정값이 baseline 운전 7°C에서 algorithm 운전 10.4°C로 3.4°C 증가하였다.

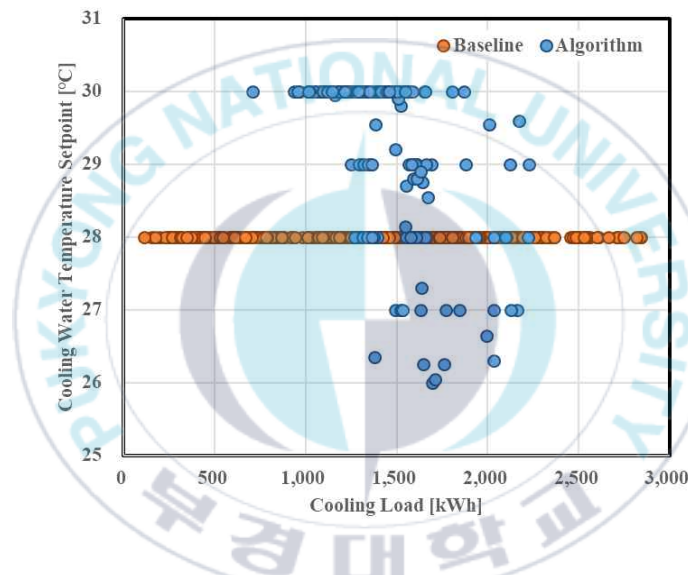


Fig. 3.8 냉방부하에 따른 냉각수 온도 설정값 비교

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

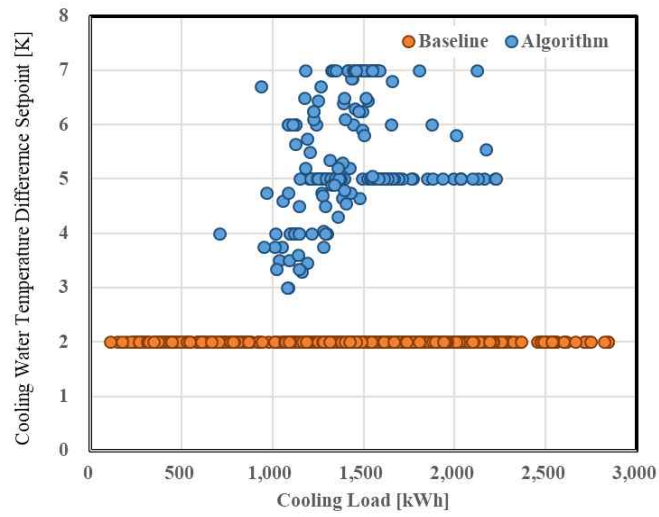


Fig. 3.9 냉방부하에 따른 냉각수 온도차 설정값 비교

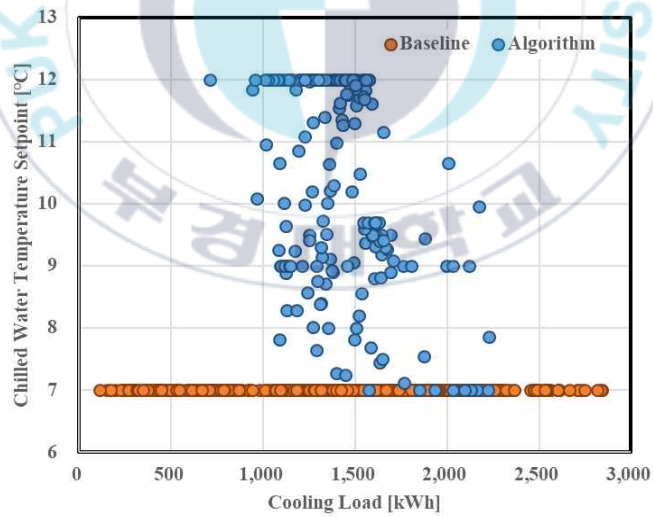


Fig. 3.10 냉방부하에 따른 냉수 온도 설정값 비교

3.4.2 최적 제어 알고리즘 효과 검증 결과

(1) 기기별 전력소비량 단순 비교

알고리즘 적용 전과 후의 냉방부하에 따른 시스템 전력소비량 비교를 Fig. 3.11에 나타낸다. 모든 냉방부하 영역에 있어 algorithm 운전이 baseline 운전에 비해 전력소비량이 감소하였음을 알 수 있다. 알고리즘에 의한 기기별 절감 효과를 분석하기 위해, 가장 많이 운전된 부하 조건인 1,000 kWh ~ 1,500 kWh 구간의 기기별 전력소비량을 비교하였다. 그 결과를 Fig. 3.12에 나타낸다. 동일한 부하 구간임에도 Baseline 운전의 평균 냉방 부하는 1,330.5 kWh이고, algorithm 운전의 평균 냉방 부하는 1178.7 kWh로, algorithm 운전이 약 11.4% 낮은 부하 조건이다. 이때, 냉동기의 전력소비량은, baseline 운전 239.1 kWh에서 algorithm 운전 194.4 kWh로, baseline 운전 대비 18.7% 절감되었다. 냉각탑의 전력소비량은, baseline 운전 107.6 kWh에서 algorithm 운전 58.9 kWh로, baseline 운전 대비 45.2% 절감되었다. 냉각수 펌프의 전력소비량은, baseline 운전 46.3 kWh에서 algorithm 운전 25.3 kWh로, baseline 운전 대비 45.5% 절감되었다. 결과, 열원시스템 전력소비량은 baseline 운전 393.1 kWh에서 algorithm 운전 278.6 kWh로, baseline 운전에 비해 algorithm 운전의 냉방부하가 11.4% 적은 것에 비하여 전력소비량의 절감율은 29.1%로 크게 감소하였다.

전력소비량 절감효과에 대한 원인을 분석하면, 냉동기는 냉수 온도 제어에 의하여 냉수 온도가 상승함으로써 냉동기의 효율이 향상되어 전력소비량이 감소하였다. 냉각탑은 baseline 운전에서는 외기 습구온도를 고려하지 않고 냉각수 온도를 28°C로 고정 운전하였기 때문에 냉각탑 팬이 과도하게 운전되었지만, algorithm 운전에서는

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

외기 습구온도를 고려하여 제어 설정값을 결정함으로써 냉각수 온도가 상승하고 불필요한 팬의 운전을 줄임으로써 전력소비량이 감소하였다. 또한, 냉수 온도 제어에 의해 냉동기의 전력소비량이 감소하여 냉각탑의 처리열량이 감소한 것 역시 냉각탑 전력소비량 감소에 영향을 미쳤다고 생각된다. 냉각수 펌프는 냉각수 온도차 설정값이 상승하여, 냉각수 유량이 감소함에 따라 전력소비량이 감소하였다.

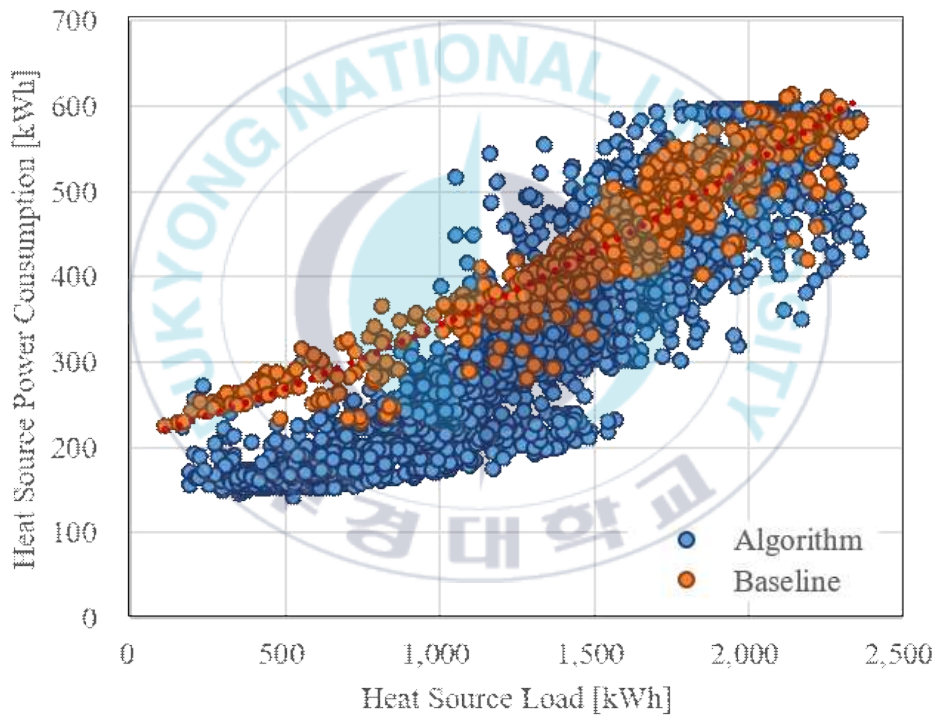


Fig. 3.11 냉방부하에 따른 열원시스템 전력소비량 비교

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

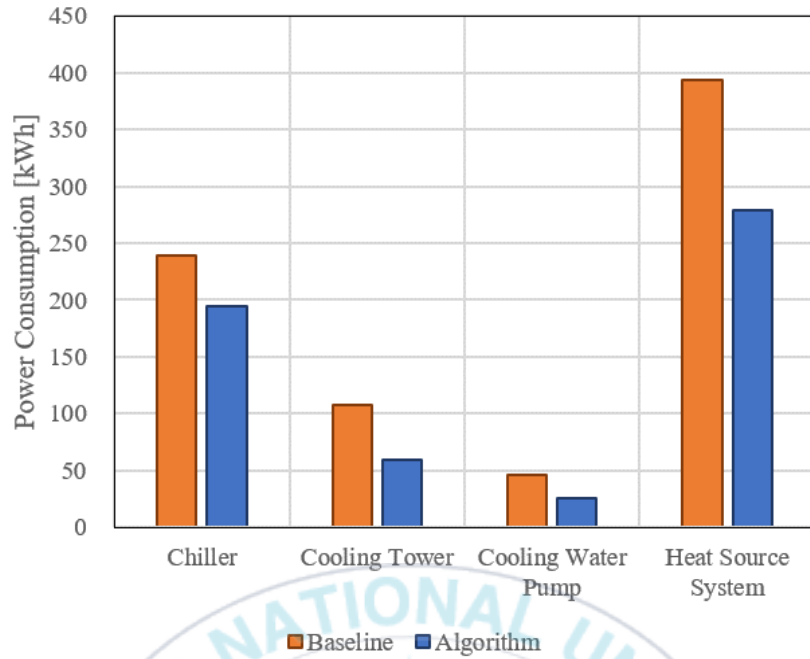


Fig. 3.12 부하 구간 1,000 kWh ~ 1,500 kWh에서 전력소비량 비교

(2) IPMVP에 의한 알고리즘 절감 효과 검증

알고리즘 적용 전과 후로 경계 조건 차이로 인해 동일한 경계 조건에서 효과 검증이 불가능하다. 동일한 냉방부하 조건에서 알고리즘 적용으로 인한 에너지 절감 효과를 분석하기 위해서, Baseline 운전데이터를 이용하여 독립변수가 열원시스템의 처리열량이고 종속변수가 열원시스템 전력소비량인 PR (Polynomial Regression) Model을 구축하였다. PR Model의 식과 회귀계수의 산출 결과를 식 3.21과 Table 3.4에 나타낸다.

$$P_{hs} = a_0 + a_1 \cdot Q_{total} + a_2 \cdot Q_{total}^2 \dots\dots\dots (3.21)$$

여기서, P_{hs} 는 열원시스템 전력소비량 [kWh], Q_{total} 은 열원시스템 처리열량, $a_0 \sim a_2$ 는 회귀계수 [-]이다. Baseline의 PR Model의 R^2 score

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

는 0.89로, IPMVP의 기준인 0.75 이상을 상회하는 성능을 보인다 [28]. PR Model에 알고리즘 운전 시의 열원시스템 처리열량을 입력 하여, 해당기간에 대한 Baseline 운전의 열원시스템 전력소비량을 산 출하였다. 그 결과를 Fig. 3.13에 나타낸다. 알고리즘 운전 시, 측정 한 열원시스템 전력소비량은 242.2 MWh이고, 동일한 냉방부하에서 의 Baseline 운전 열원시스템 전력소비량은 301.5 MWh로 산출되었 다. 결과, 검증기간 동안 알고리즘으로 인해 59.3 MWh, 약 19.7% 전 력소비량이 절감되었음을 확인하였다.

Table 3.4 Baseline 운전의 시스템 전력소비량 회귀 계수 계산 결과

회귀계수		
α_0	α_1	α_2
208.3805879668	0.1089605830	0.0000260089

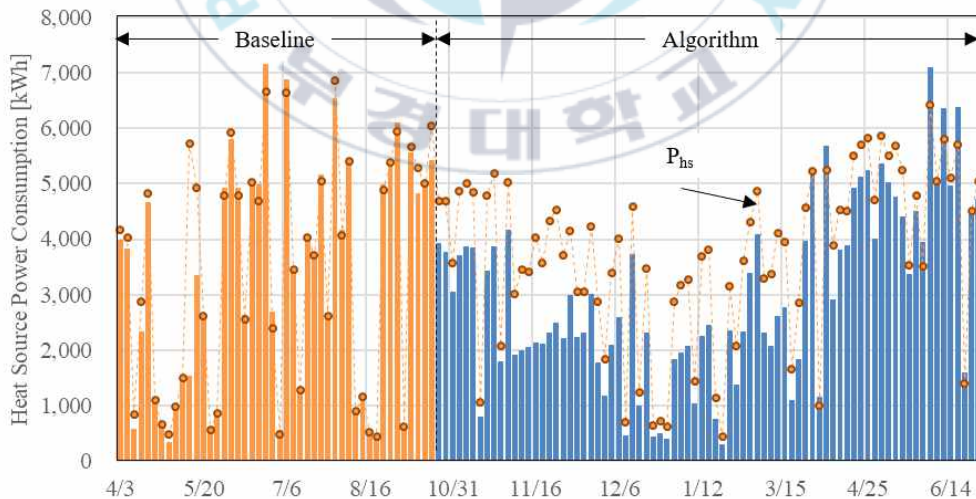


Fig. 3.13 IPMVP 기반 알고리즘 효과 검증 결과

3.4.3 실내 온열환경에 미치는 영향 분석

냉수 알고리즘 적용으로 인해 냉수 온도 설정값이 **baseline** 운전 대비 3.4°C 상승하였다. 이로 인해 CAV AHU의 경우 실내 온도 상승, VAV AHU의 경우 급기 온도 상승으로 인해 AHU 팬 전력소비량 증가 및 실내 온도 상승을 초래할 가능성이 있다. 따라서, 본 절에서는 냉수 온도 제어가 실내에 미치는 영향을 평가하기 위해, 냉수 알고리즘 적용 전과 후의 CAV AHU의 실내온도 (Tr3 ~ Tr7)과 VAV AHU의 급기온도 (Ts8 ~ Ts15)의 제어 정확도를 비교하였다. 결과인 실제값과 설정값의 차이를 Fig. 3.14에 나타낸다. CAV AHU의 실내 온도 제어 정확도 분석 결과, Tr7을 제외하고 **baseline** 운전 시 실제값과 설정값 차이의 분포가 **algorithm** 운전보다 좋아 보이나, **baseline**과 **algorithm** 모두 대부분 설정값 $\pm 1^{\circ}\text{C}$ 이내로 제어되었다. 그리고, **algorithm** 운전의 평균 실내온도가 **baseline**보다 $0.1^{\circ}\text{C} \sim 0.8^{\circ}\text{C}$ 낮게 제어되었다 (Table xxx). VAV AHU의 급기 온도 제어 정확도 분석 결과, **algorithm** 운전 시의 실제값과 설정값 차이의 분포 폭이 상당히 좁은 것을 통해 설정값에 따라 급기 온도가 안정적으로 제어되고 있음을 확인할 수 있다. 반면, **baseline**에서 Ts8, Ts9, Ts14, Ts15의 온도차 분포가 넓은 것은 다른 기기 대비 해당 기기의 급기 온도 설정값 변경이 빈번히 발생했기 때문이라 생각된다. 따라서, AHU 냉각 코일 밸브 개도를 이용한 냉수 온도 제어 알고리즘을 적용하여도 실내 온열환경에는 영향을 주지 않는다고 판단된다.

제 3장 HVAC 시스템 최적 제어 알고리즘 실증

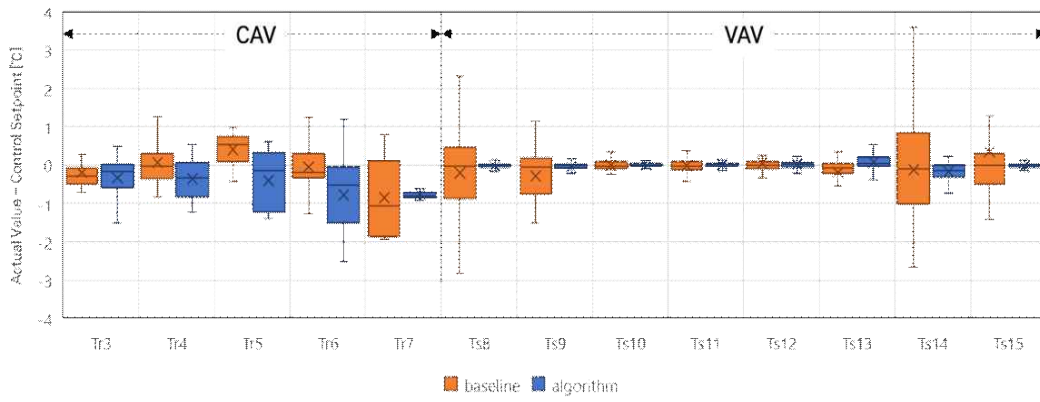


Fig. 3.14 AHU 실내 및 급기 온도 비교



제 4장 전이학습 기반 알고리즘 확장성 개선

앞선 최적제어 알고리즘 실증 연구를 통해, 전통적인 머신러닝 (Traditional Machine Learning)은 특정 과제나 문제에 국한해 개별 모델을 훈련해야 하는 한계점을 지니고 있음을 확인하였다. 그러나, 앞서 1장에서 설명했듯이 최적 제어 연구를 진행함에 있어, 정확도 높은 예측 모델 개발을 위해 개별 건물에 대해 설정값을 변경하며 데이터를 취득하거나 시뮬레이션 모델을 구축하여 데이터를 확보하는 데도 한계가 있다. 이러한 전통적인 머신러닝의 한계점을 극복하기 위해, 본 연구에서는 크고 양질의 데이터로 미리 사전 학습된 모델 (Source model)의 가중치를 데이터가 부족한 분야에 재사용하는 전이학습 (Transfer Learning)을 활용하였다 (Fig. 4.1).

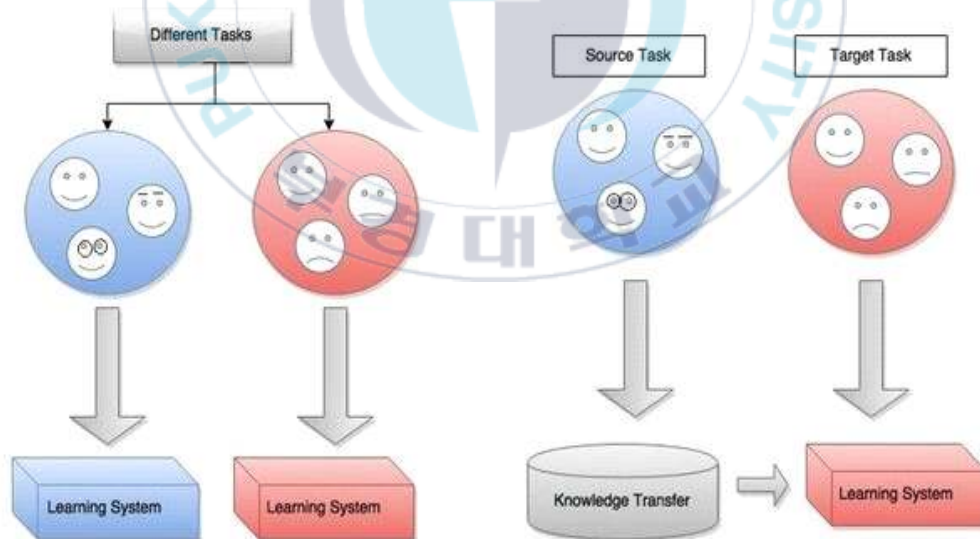


Fig. 4.1 전통적인 머신 러닝(좌) vs 전이학습(우)³⁵⁾

4.1 전이학습

4.1.1 전이학습 개요

전이학습은 1995년 NIPS-95 (Neural Information Processing Systems 1995) 워크숍에서 처음 구체적으로 논의된 기계 학습 방법론으로, 한 문제에서 얻어진 지식을 다른 새로운 문제에 적용한다는 개념에서 출발되었다³⁶⁾. 이를 이해하기 위해서는 도메인 (Domain)과 작업 (Task)에 대한 정의를 명확히 하는 것이 필요하다. Pan과 Yang의 연구에서 도메인과 작업을 기반으로 전이학습을 공식화하였다³⁷⁾. 도메인과 작업은 각각 식 4.1과 식 4.2로 나타낼 수 있다.

$$D = \{X, P(X)\} \dots\dots\dots (4.1)$$

$$T = \{Y|f(\cdot)\} \dots\dots\dots (4.2)$$

식 4.1에서, X는 모든 특징 벡터 공간을 의미하는 특징 공간 (feature space)으로 변수 혹은 데이터를 지칭하고, P(x)는 이 특징 공간 X에 대한 한계 확률 분포 (marginal probability distribution)로, 데이터의 분포를 나타낸다. 즉, 도메인은 데이터가 존재하는 공간 및 데이터의 특성을 의미한다. 식 4.2에서, Y는 특징 벡터 $X = \{x_1, x_2, \dots, x_n\}$ 에 할당된 출력을 나타내며, $f(\cdot)$ 는 목적함수이다. 작업은 주어진 목적함수 $f(\cdot)$ 를 통해 입력 X로부터 출력 Y를 예측하거나 생성하는 것으로, 수행해야 하는 목표를 의미한다. 이를 바탕으로, 학습에 사용되는 source와 학습에 사용될 target의 도메인 및 작업에 따라 학습의 분류를 Table 4.1, Fig. 4.2와 같이 나타낼 수 있다.

제 4장 전이학습 기반 알고리즘 확장성 개선

우선, source와 target의 도메인 및 작업이 같은 경우는 일반적인 머신 러닝에 해당한다. 이는 일반적인 머신 러닝에서는 모델 학습을 위한 훈련 및 테스트 과정에서 동일한 데이터를 사용하며 작업의 일관성을 유지하기 때문이다. 예를 들어, 회귀 문제라면 훈련과 테스트 모두 회귀 작업으로 이루어지고, 분류 문제라면 훈련과 테스트 모두 분류 작업으로 일관성을 유지한다. Source와 target의 도메인은 같지만 작업이 다른 경우는 귀납적 전이학습 (Inductive Transfer Learning)에 해당한다. 이는 동일한 도메인을 사용하지만 작업이 source는 분류이고 target이 회귀인 경우처럼 서로 다른 작업을 학습인 경우를 의미한다. Source와 target의 도메인과 작업이 모두 다른 경우는 비지도 전이학습 (Unsupervised Transfer Learning)에 해당한다. 이는 새로운 데이터로 학습하는 편이 예측 정확도면에서 좋을 수 있다. 마지막으로, target과 source의 도메인은 다르지만 작업이 같은 경우는 변환 전이학습 (Transductive Transfer Learning)에 해당한다. 이는 가장 일반적인 전이 학습을 의미한다.

Table 4.1 Source 및 Target 도메인과 작업의 관계에 따른 학습 분류

	$D_S = D_T, T_S = T_T$	$D_S = D_T, T_S \neq T_T$	$D_S \neq D_T, T_S \neq T_T$	$D_S \neq D_T, T_S = T_T$
분류	일반적인 전이학습	귀납적 전이학습	비지도 전이학습	변환 전이학습

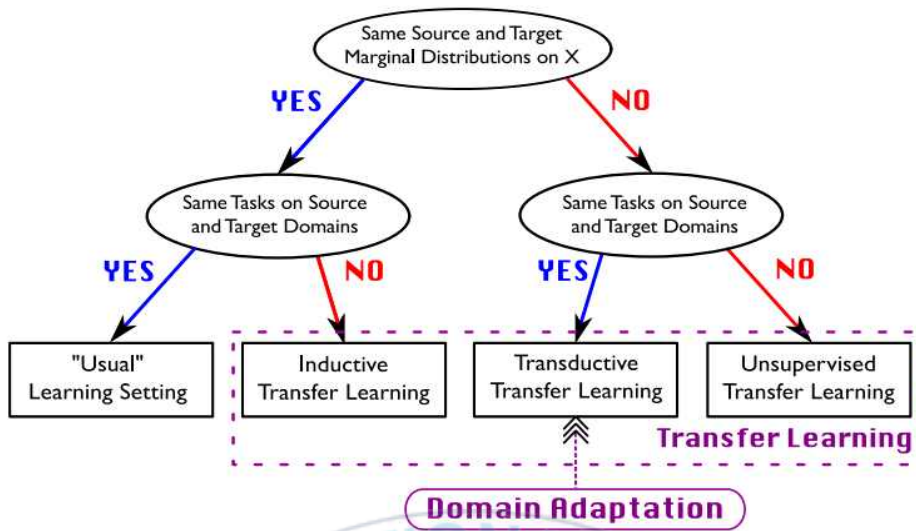


Fig. 4.2 도메인과 작업에 따른 학습 분류³⁸⁾

4.1.2 전이학습 방법 종류

대표적인 전이학습 방법론으로는 특성추출기 (Feature Extractor)과 미세조정 (Fine Tuning)이 있다 (Fig. 4.3). 딥러닝 모델은 서로 다른 레이어 (layer)에서 서로 다른 특성을 학습하는 구조를 가지며, 최종적으로 특정 작업에 적합한 출력을 생성하기 위해서는 출력층 (output layer)이 필요하다. 특성추출기는, 사전 학습된 source 모델의 출력층 대신, 전이학습 대상인 target 작업에 적합한 새로운 출력층을 연결한 방법이다. 이때, source 모델의 은닉층은 그대로 고정 (freeze)되어 가중치가 업데이트되지 않는다. 이를 통해, source 모델이 가진 특성을 활용하며, 새로운 학습을 필요로 하지 않기 때문에 학습 시간을 단축할 수 있고, 일반화된 특성을 활용하기 때문에 소규모 데이터셋에 유용하며, 과적합 방지에 탁월하다는 장점이 있다. 하지만, source 모델의 가중치를 고정하기 때문에, 모델의 유연성이

제 4장 전이학습 기반 알고리즘 확장성 개선

부족하며, target 데이터만의 특성을 충분히 반영하지 못 할 수 있으므로, target 작업에서 충분한 예측 성능을 보장하기 어려울 수 있다. 미세조정은 특성추출기와는 달리, 사전 학습된 source 모델의 가중치를 target 작업에 맞게 재학습하는 방법이다. 재학습 범위 및 정도는 사용자가 임의로 지정할 수 있으며, 전체 모델을 재학습하거나 특정 레이어만 재학습할 수도 있고, 새로운 레이어를 추가 학습할 수도 있다. 이는 source 도메인과 target 도메인의 유사성, target 데이터셋의 수 등에 따라 결정된다. Source 모델의 가중치를 재학습하거나 새로운 레이어를 추가함으로써, target 도메인과 작업의 특성을 더 효과적으로 반영할 수 있고, target 작업에서 특성추출기보다 더 나은 결과를 보장할 수 있다. 하지만, 재학습에 따라 특성추출기보다 학습 시간이나 계산 비용이 더 많이 소요될 수 있으며, target 데이터의 수가 부족하면 target 모델의 예측 성능이 저하되는 부정 전이(Negative Transfer)이 발생할 수 있다.

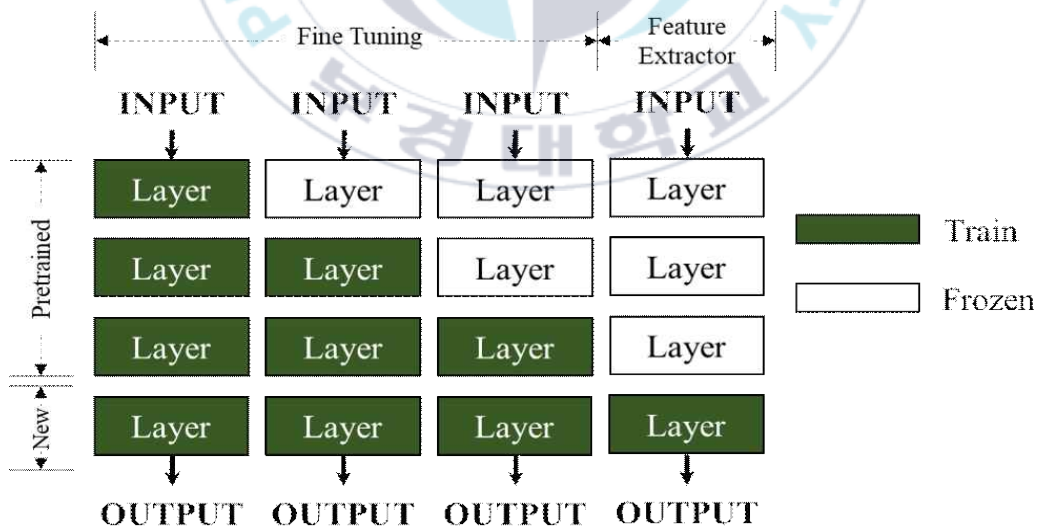


Fig. 4.3 미세조정 & 특성추출기 구조

4.1.3 선행 연구 및 한계점

안유선 외 3인(2020)³⁹⁾는 전이학습을 활용한 LSTM (Long Short Term Memory) 기반의 건물 에너지 소비량 예측 정확도 개선을 주제로 연구를 진행하였다. 전이학습 대상 건물은 전이학습에 활용된 Source 모델 대상 건물에 비해 낮은 부하 조건을 가지고 있었다. Source 모델은 총 5개의 층으로 이루어진 LSTM 기반의 예측 모델이고, 전이학습 모델은 source 모델의 5개의 레이어와 별도로 추가된 1개의 레이어로 구성되어 있다. 정확도 검증은, source 모델의 레이어를 하나 층씩 재학습한 모델의 예측 정확도를 대상 건물의 데이터만 사용한 모델의 정확도와 비교하였다. 그 결과, 전이학습 모델의 정확도는 source 모델의 레이어를 모두 재학습했을 때 가장 높았다. 예측 정확도 역시 CV(RMSE) 22.8%, MBE (Mean Bias Error) 1.35%로, 대상 건물의 데이터만 사용한 모델의 정확도 CV(RMSE) 45.1%, MBE 6.0%에 비해 개선되었다.

Miguel Lopez Santos 외 6인 (2023)⁴⁰⁾는 지역 에너지 공동체에서 에너지를 효율적으로 사용하기 위해, 데이터가 부족한 건물을 대상으로 전이학습을 적용하였다. Source 모델은 시계열 예측과 장시간 예측에 우수한 TFT (Temporal Fusion Transformer)을 활용하였다. 총 4개의 건물에 대한 TFT 모델을 개발하고, 이를 데이터가 부족한 2개의 대상 건물에 대한 전이학습에 활용하였다. 그 결과, 대상 건물의 데이터만 사용한 예측모델과 비교해서, CV(RMSE)는 최대 65%가 차이가 났으며, 이를 통해 전이학습의 효과를 입증하였다.

그 외에, 전이학습을 대상으로 하는 건물의 데이터 크기, source 모델과 target 모델 간의 유사성, 시뮬레이션 데이터를 활용한 전이학습 방안에 대한 연구는 활발히 진행되고 있다^{41,42,43)}.

하지만, 대부분의 선행 연구는 대체로 건물 부하나 에너지 소비

량 예측에 초점이 맞춰져 있으며, 에너지 절감에 직결되는 최적 제어를 위한 전이학습 연구나 실제 건물을 대상으로 효과가 입증된 예측 모델을 전이학습에 활용한 연구는 제한적이다.

4.2 연구 방법

선행 연구의 한계점을 극복하기 위해, 본 연구에서는 실제 건물에서 에너지 절감 효과가 검증된 예측 모델을 source 모델로 하여 타 시스템으로의 확장 가능성 및 최적 제어를 위한 전이학습 활용 방법에 대해 모색하고자 한다. 하지만, 앞선 실증 연구에서 대상으로 한 시스템과 적합한 시스템을 가진 건물을 확보하는 데 어려움이 있어, 우선적으로 다른 연구에서 최적 제어 알고리즘을 적용하여 25.2%의 시스템 전력소비량을 절감시켰던 시스템과 동일한 기기를 사용하는 시스템 간의 전이학습을 적용하여 전이학습의 효과를 검증하였다.

4.2.1 대상 건물 및 HVAC 시스템

전이학습 대상 건물은 수원에 위치한 사무용 건물로 선정하였다 (Fig. 4.4). 대상 건물의 내부는 지하 5층, 지상 27층의 2 개의 타워 (A동, B동)으로 이루어져 있으며 연면적은 309,980 m²이다. 대상 건물은 총 11개의 공조시스템으로 구성되어 있으나, 본 연구에서는 A동 및 B동의 외주부 공조를 담당하는 수냉식 VRF (Variable Refrigerant Flow) 공조시스템(Sys1, Sys2)을 대상으로 하였다. 이때, Sys1과 Sys2는 동일한 기기를 사용한다. Sys1은 실외기 17대, 밀폐형 냉각탑 2대, 냉각수 펌프 3대로 구성되어 있으며, 기기 사양을 Table 4.2에 나타낸다. 실외기는 냉매 R410A를 사용하고, digital scroll과

제 4장 전이학습 기반 알고리즘 확장성 개선

FVI scroll 압축기를 탑재하고 있다. 이때, 냉방능력은 116 kW(4대), 145 kW(5대), 174 kW(8대)이며, 각각의 소비전력은 23.2 kW, 29.0 kW, 34.8 kW이고, 모든 실외기의 EER (Energy Efficient Ratio)는 5.0이다. 냉각탑은 정격 냉각능력이 3,150 kW이며, 풍량이 6,444 m³/h인 정속형 팬 3대가 설치되어 있다. 냉각수 펌프의 정격 유량은 426 m³/h이며, 인버터가 탑재되어 변유량 제어가 가능하다. 이때, 냉각탑 팬 제어와 냉각수 펌프의 변유량 제어에 대한 방법은 아래와 같다.

- 냉각탑 팬 제어 : 냉각탑 출구 냉각수 온도가 설정값에 도달하도록 냉각탑 팬의 속도(high, low)와 대수를 제어한다.
- 냉각수 유량 제어 : 말단배관 압력이 설정값에 도달하도록 PI 제어를 통해 냉각수 펌프 주파수를 변경하여 냉각수 유량을 제어한다.



Fig. 4.4 전이학습 대상 건물

제 4장 전이학습 기반 알고리즘 확장성 개선

Table 4.2 전이학습 대상 건물 장비 사양

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) Power : 23.2 kW, 29.0 kW, 34.8 kW EER : 5.0 Cooling water flow : 22.8 m ³ /h, 28.5 m ³ /h, 34.2 m ³ /h
Cooling Tower	2	Cooling capacity : 3,150 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 : 490 kPa, Motor : 75 kW Frequency : 50 Hz

4.2.2 Target 시스템 운전상태 확인

Source 시스템 (Sys1)과 target 시스템 (Sys2)을 비교하였다. 비교 분석에는 대표일로서 2023년 8월 7일부터 8월 12일까지의 운전데이터를 이용하였다. 결과를 Fig. 4.5에 나타낸다. 그림에서 HVAC 시스템을 구성하는 각 기기의 전력소비량은 전력량계를 통해 측정된 실제 데이터를 이용하였다. Source 시스템과 target 시스템의 시스템 전력 소비량은 비슷한 전력 사용 패턴을 보이지만, target 시스템이 더 적은 시스템 전력을 소비하였다.

추가적으로, target 시스템의 제어 설정값 변화 상태를 분석하였다 (Fig. 4.6). 분석에는 2023년 6월 16일부터 8월 28일까지의 운전데이터를 이용하였다. 외기 조건이 시시각각 변화함에도 불구하고, 냉각수 온도 설정값은 관리자에 의해 설정된 고정값인 32°C로 계속 운전되었으며, 냉각수 온도는 “설정값 \pm 2°C” 범위 내에서 운전되었다. 반면, 차압 설정값은 관리자에 의해 2023년 7월 23일 이전에는 0.8 kg/cm²으로 운전되었으나, 이후에는 0.7 kg/cm²으로 변경되어 운전되었다. 대상 열원시스템의 운전상태를 통해 알 수 있듯이, 제어 설정값을 변경하지 않고 일정한 값으로 운전하고 있어 최적제어를 위한 학습모델 개발에 필요한 운전데이터를 확보할 수 없다. 이러한 문제의 해결방안으로, 본 절에서는 전이학습을 이용해서 양질의 데이터로 학습된 source 모델의 가중치를 활용해, 다양한 경계조건에서 제어 설정값을 변경한 데이터가 부족한 target 시스템의 학습 모델을 개발하고자 한다.

제 4장 전이학습 기반 알고리즘 확장성 개선

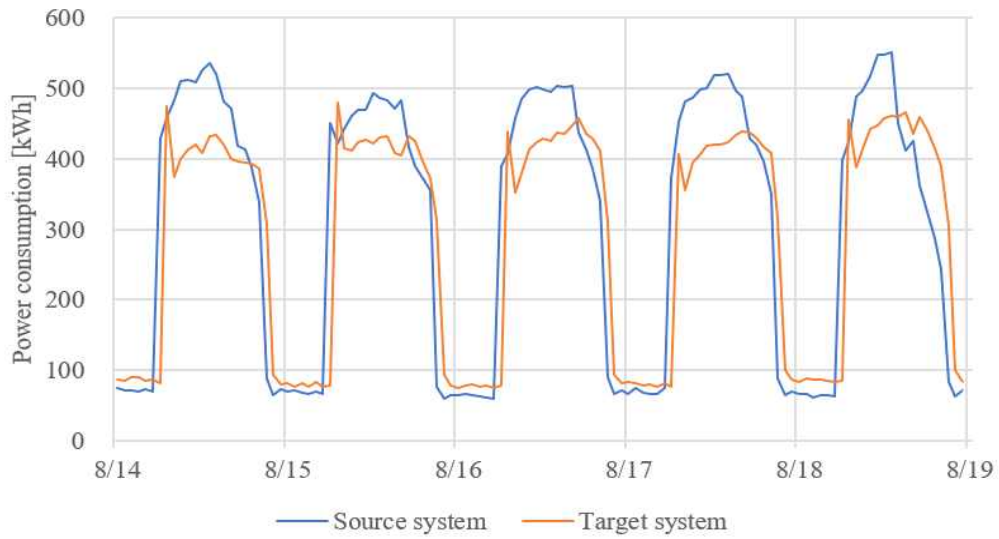


Fig. 4.5 Source 및 Target 시스템 전력소비량 비교

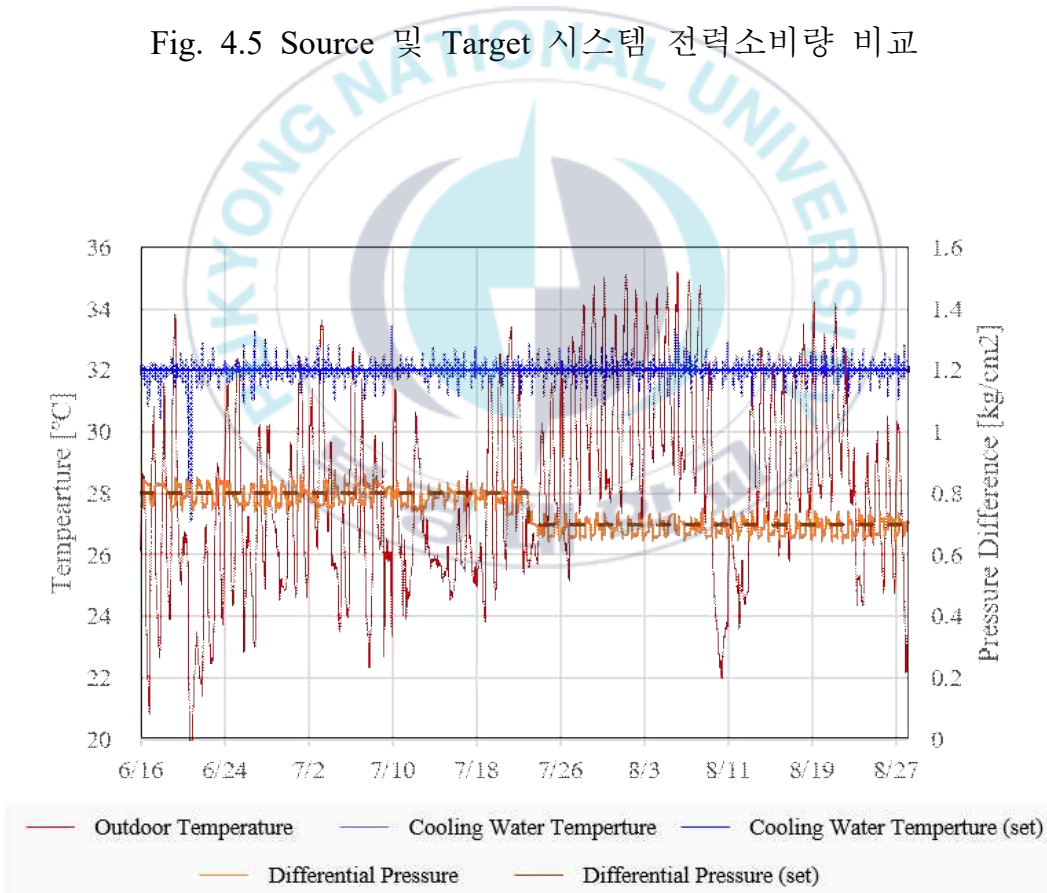


Fig. 4.6 Target 시스템 운전상태

4.2.3 열원시스템 시뮬레이션 모델¹⁶⁾

Source 모델을 개발에 필요한 초기 학습데이터를 생성하기 위해서, MLR 기반의 열원시스템 시뮬레이션 모델을 개발하였다. MLR는 비교적 단순한 구조를 가지고, 결과 해석이 용이하며, 적은 양의 데이터만으로도 모델 구축이 가능하다는 장점이 있다. Fig. 4.7은 시뮬레이션 흐름도를 나타낸다. 흐름도의 좌측은 입력값을, 우측은 출력값을 나타낸다. 시뮬레이션은 실외기가 처리하는 열량, 즉 실내 부하와 외기 습구온도, 그리고 제어 설정값인 냉각수 온도 및 냉각수 계통 배관 차압 (차압)을 입력하여 개별 기기의 전력소비량을 산출한다. 기기 모델인 실외기, 냉각탑, 냉각수 펌프 모델을 개발하고, 개별 모델을 상호 연결하여 열원시스템 전체를 모사할 수 있는 열원시스템 시뮬레이션 모델을 완성하였다.

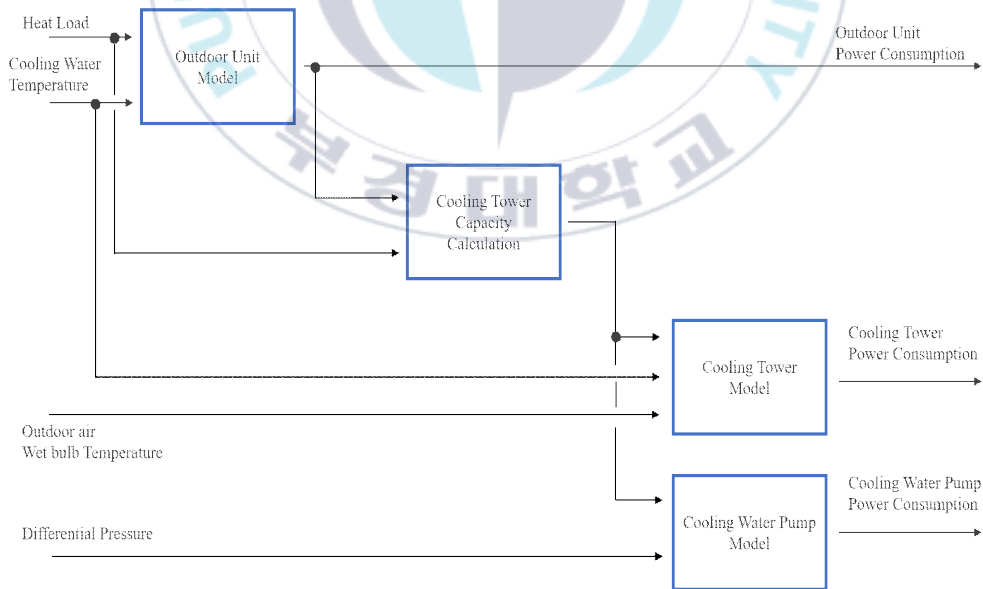


Fig. 4.7 MLR 기반 열원시스템 시뮬레이션 흐름도

각 기기 모델을 MLR 기반의 실험적 모델 (Empirical model)로 개

제 4장 전이학습 기반 알고리즘 확장성 개선

발하였다. 기기 모델 식의 형태는 식 4.3과 같다.

$$y(x_1, x_2) = c \cdot (\alpha_1 + \alpha_2 \cdot x_1 + \alpha_3 \cdot x_1^2 + \alpha_4 \cdot x_2 + \alpha_5 \cdot x_2^2 + \alpha_6 \cdot x_1 \cdot x_2) \dots \dots \dots (4.3)$$

이때, x_1, x_2 는 모델의 입력 변수로 물리 기반 모델을 참고하여 기기의 에너지 소비량에 영향을 미치는 경계 조건과 제어 설정값을 기준으로 선정하였다. 실외기 모델의 입력 변수는 실내 부하 및 냉각수 출구 온도이며, 냉각탑 모델의 입력 변수는 냉각수 출구 온도와 외기 습구온도의 차인 어프로치 온도 (Cooling approach temperature) 및 냉각탑 처리열량이고, 냉각수 펌프 모델의 입력 변수는 배관 차압 및 냉각탑 처리열량으로 선정하였다. $\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5, \alpha_6$ 은 회귀 계수 (Regression coefficient) [-]를, c 는 보정 계수 (Calibration coefficient) [-]를 의미한다.

회귀 계수는 2015년 실 운전 데이터를 이용하여 최소자승법을 기반으로 산출하였다. 그리고, 2015년과 현재의 기기 성능을 보정하기 위해 2022년 데이터를 이용하여 보정 계수를 산출하였다. 각 모델의 회귀 계수 및 보정 계수를 구한 결과를 Table 4.3에, 각 기기 모델의 정확도를 나타내는 CV(RMSE)와 R^2 score는 Table 4.4에 나타내었다. 보정 계수 계산 결과, 실외기가 1.34, 냉각탑이 1.19, 냉각수 펌프가 1.09로, 모든 기기가 1.0보다 큰 값이 산출되었다. 이는 동일한 경계 조건에서 2015년 대비 2022년 모든 기기의 전력 소비량이 증가했음을 의미한다. 실외기 모델의 예측 정확도는 CV(RMSE) 17.3%, R^2 스코어 0.89, 냉각탑 모델의 예측 정확도는 CV(RMSE) 22.2%, R^2 스코어 0.81, 그리고 냉각수 펌프 모델의 예측 정확도는 CV(RMSE) 13.2%, R^2 스코어 0.95로 ASHRAE Guideline 14, IPMVP, FEMP에서 시간 간격으로 보정한 시뮬레이션의 오차 허용 기준인 R^2 스코어

제 4장 전이학습 기반 알고리즘 확장성 개선

0.75 이상, CV(RMSE) 30% 이하를 모두 만족하였다 [20][21][22].

이렇게 개발한 기기 모델을 연결하여 열원시스템 시뮬레이션 모델을 완성하였으며, 입력데이터인 실내 부하, 외기 습구온도, 냉각수 온도 설정값, 차압 설정값에 대한 모든 구간에서의 기기 에너지 소비량을 산출하였다. 실내 부하의 범위는 실외기 정격능력의 20%인 381.0 kWh에서 100%인 1905.2 kWh로 하였으며 간격은 20%인 381.0 kWh로 하였다. 외기 습구온도의 범위는 18°C에서 31°C 범위 내에서 1°C 간격으로 변경하였다. 냉각수 온도 설정값은 20°C에서 33°C 범위 내에서 1°C 간격으로 변경하였으며, 냉각수 온도는 “외기 습구온도 + 어프로치 온도”보다 낮은 수 없으므로 외기 습구온도에 따라 냉각수 온도 범위를 설정하였다. 차압 설정값 범위는 0.4 mmAq에서 1.0 mmAq 범위 내에서, 0.1 mmAq 간격으로 변경하였다. 설정한 모든 경계 조건 및 제어 설정값에 대해서 시뮬레이션을 실행하여 총 3,675개의 시간당 학습데이터를 생성하였다.

Table 4.3 MLR 시뮬레이션 모델 : 기기 모델의 회귀 계수 및 보정 계수 계산 결과

	회귀 계수						보정 계수
	α_1	α_2	α_3	α_4	α_5	α_6	
실외기	-42.2598	4.9216	-0.1295	-0.0696	-0.000007	0.0098	1.34
냉각탑	28.4186	-7.6981	0.4233	0.0597	-0.000008	-0.0019	1.19
냉각수 펌프	40.1349	-0.07145	0.00002	-61.4801	17.9800	0.0644	1.09

Table 4.4 MLR 시뮬레이션 모델 : 정확도 평가 결과

	R^2 score [-]	CV(RMSE) [%]
실외기	0.89	17.3
냉각탑	0.81	22.2
냉각수 펌프	0.95	13.2

4.2.4 사전학습 Source 모델 개발

전이학습에 사용되는 사전학습 모델인 source 모델은 앞서 개발한 MLR 시뮬레이션 모델을 통해 생성한 시뮬레이션 데이터를 사용하여 학습한 DNN 기반의 열원시스템 전력소비량 예측 모델이다. 시뮬레이션을 통해 확보한 데이터들 중 물리법칙을 바탕으로 열원시스템 전력소비량과 밀접한 관련이 있는 데이터를 입력 데이터로 선정하였다. 선정한 입력데이터는 냉각탑 부하율, 외기 습구온도, 냉각수 온도, 차압, 어프로치 온도이며, 출력데이터는 HVAC 시스템을 구성하는 실외기, 냉각탑, 냉각수 펌프의 개별 전력소비량으로, Table 4.5에 나타내었다. 데이터들 간의 범위와 단위 차이로 인한 성능 저하 문제를 방지하기 위해 Min-Max Normalization을 통해 데이터 간의 scale을 0~1 사이로 통일시켰다. 정규화된 데이터는 무작위로 섞는 랜덤화를 거쳐, 모델 학습을 위한 학습용 데이터셋 64%, 모델의 일반화 검증을 위한 검증용 데이터셋 16%, 모델의 성능 확인을 위한 테스트용 데이터셋 20%로 분류하였다.

모델의 예측 정확도 향상을 위해 베이지안 최적화를 이용해 하이퍼 파라미터를 최적화하였다. Table 4.6는 하이퍼 파라미터 최적화 종류와 범위 및 결과를 나타낸다. 하이퍼 파라미터 종류에는 은닉층 수, 각 은닉층 별 노드 수, 드랍아웃, 학습률, 이 4가지 항목을 최적화 대상으로 삼았다. 하이퍼 파라미터 범위 및 최적화 결과를 Table. xxx에 나타낸다. 각 항목의 최적화 범위는, 은닉층 수는 2개 ~ 10개, 각 은닉층 별 노드 수는 16개 ~ 256개, 드랍아웃은 0.0 ~ 0.5, 학습률은 0.0001 ~ 0.01이다. 베이지안 최적화 결과, 최적의 하이퍼 파라미터 조합은 은닉층 수는 3개, 각 은닉층 별 노드 수는 161개, 150개, 145개, 드랍아웃 0.0, 학습률 0.006159로 선정되었다.

Source 모델의 활성화 함수는 ReLu, 가중치 업데이트를 위한 옵

제 4장 전이학습 기반 알고리즘 확장성 개선

티마이저는 Adam, 목적함수는 MSE, 모델 성능 평가지표는 MAE로 하였다.

Table 4.5 Source model 학습을 위한 입력데이터, 출력데이터

데이터 종류	변수
입력데이터	냉각탑 부하율 [-]
	외기 습구온도 [°C]
	냉각수 온도 [°C]
	차압 [mmAq]
	어프로치 온도 [°C]
출력데이터	실외기 총 전력소비량 [kWh]
	냉각탑 전력소비량 [kWh]
	냉각수 펌프 전력소비량 [kWh]

Table 4.6 Source 모델의 하이퍼 파라미터 최적화 결과

	범위	결과
은닉층 수	2개 ~ 10개	3개
각 은닉층 별 노드 수	16개 ~ 256개	161개, 150개, 145개
드롭아웃	0.0 ~ 0.3	0.0
학습률	0.0001 ~ 0.01	0.006159

분류된 학습데이터와 최적화된 하이퍼 파라미터 조합을 이용해 학습수 총 200회로 모델 학습을 진행하였다. Source model의 정확도 평가에 대해서는 4.3.3장에서 상세히 설명하였다.

4.3 전이학습 기반 DNN 예측모델 개발

4.3.1 전이학습 모델 개발 개요

전이학습 모델 개발의 흐름도를 Fig. 4.8에 나타낸다. 1) 데이터 세트 분류 (Building dataset), 2) baseline 모델 개발 (Baseline model), 3) 하이퍼 파라미터 최적화 (Hyper Parameter Optimization), 4) 전이학습 모델 학습 (Transfer Learning Model Training), 5) 모델 평가 (Model Evaluation)로, 크게 5단계로 구성된다. 첫 번째 단계인 데이터 세트 분류에서는 운전데이터들 중 학습에 필요한 입력 및 출력 데이터를 선정하였다. 이후, 전이학습 대상인 target 건물의 데이터만 사용하여 학습한 baseline 모델을 개발하였고, 최적 제어를 위한 전이학습 모델 개발을 위해, 하이퍼 파라미터 범위나 미세조정 정도에 따른 예측정확도 및 제어 설정값에 따른 예측 경향성을 분석하였다. 이를 통해, 최적 제어를 위한 전이학습 모델 최적화를 위한 기준점을 마련하고자 매뉴얼 서치 방법을 활용하였다. 최적화 결과를 바탕으로 모델을 학습시켜 HVAC 시스템의 전력소비량을 예측하였다. 마지막으로, 전이학습 모델이 baseline 모델의 예측정확도 대비 얼마나 개선되었는지, 그리고 source 모델의 제어 설정값에 따른 예측 경향을 얼마나 성공적으로 전이했는지를 평가하였다.

제 4장 전이학습 기반 알고리즘 확장성 개선

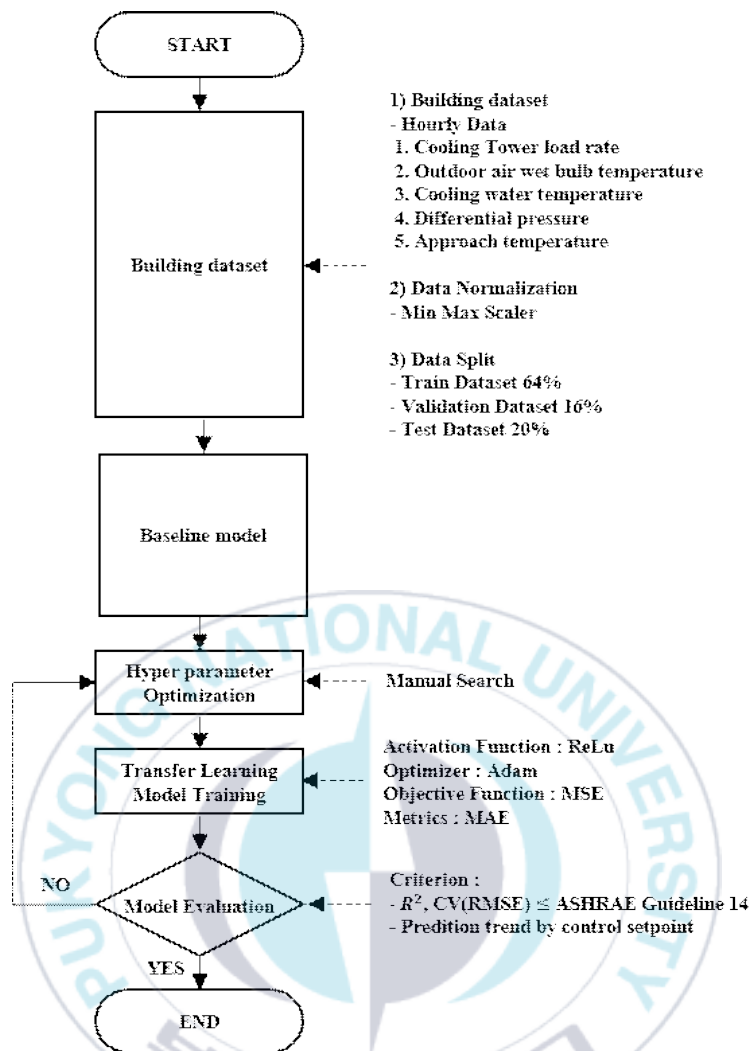


Fig. 4.8 전이학습 모델 개발 흐름도

4.3.2 전이학습 모델 개발

1) 데이터 세트 분류

전이학습 모델 개발을 위한 학습 데이터셋은 Source model의 입력데이터와 동일하다. 입력데이터는 냉각탑 부하율, 외기 습구온도, 냉각수온도, 차압, 어프로치 온도이며, 출력데이터는 HVAC 시스템을 구성하는 실외기, 냉각탑, 냉각수 펌프의 개별 전력소비량이다. 데이터들 간의 범위와 단위 차이로 인한 성능 저하 문제를 방지하

제 4장 전이학습 기반 알고리즘 확장성 개선

기 위해 Min-Max Normalization을 통해 데이터 간의 스케일을 0~1로 통일시켰다. 정규화된 데이터는 무작위로 섞는 랜덤화를 거쳐, 모델 학습을 위한 학습용 64%, 모델의 일반화 검증을 위한 검증용 16%, 모델 성능 확인을 위한 테스트용 20%로 분류하였다.

2) Baseline 모델 개발

Baseline 모델은 23년 7월 23일에서 8월 28일까지 Target 시스템의 시간당 실 운전데이터 870개를 사용하여 학습된 DNN 기반 에너지 소비량 예측 모델이다. 대상 기간 동안, 냉각수 온도 설정값은 32°C로, 차압 설정값은 0.7 kg/cm²로 설정되어 변경없이 계속해서 운전되었다. Baseline 모델의 하이퍼 파라미터는 은닉층 수 3개, 각 은닉층 별 노드 수는 50개, 드랍아웃 0.0, 학습률 0.001로 설정하였다. Baseline 모델의 활성화 함수는 ReLu, 가중치 업데이트를 위한 옵티마이저는 Adam, 목적함수는 MSE, 모델 성능 평가지표는 MAE, 학습 횟수는 200번으로 하였다. 이를 통해, 전이학습 모델의 성능을 평가하고 유효성을 검증하기 위한 기준으로 활용하였다.

3) 하이퍼 파라미터 최적화

최적 제어를 위한 전이학습에서는 단순히 예측 정확도 향상뿐만 아니라 source 모델의 제어 설정값에 따른 예측 경향이 성공적으로 전이되었는지를 평가하는 것도 중요하다. 따라서, 본 연구에서는 매 뉴얼 서치를 활용해서 미세조정 정도, target 작업에 맞게 추가된 은닉층의 노드 수, 그리고 모델 학습 횟수를 Fig. 4.9과 같이 분류하였다.

미세조정에 따라 재학습하는 source 모델의 레이어 수에 따라 정확도를 검증하였다. 첫 번째, 하나의 source 레이어를 재학습하는 방법, 두 번째, 두 개의 source 레이어를 재학습하는 방법, 세 번째, 모

제 4장 전이학습 기반 알고리즘 확장성 개선

은 source 레이어를 재학습하는 방법, 마지막으로 source 모델을 특성추출기로 활용하여 추가 학습 없이 사용하는 방법으로 분류하였다. 이때, 재학습하는 순서는 출력층에 가까운 순서이다. 추가한 은닉층의 노드 수는 7개, 9개, 11개, 13개로 분류하였고, 학습 수는 20번에서 100번까지 10번 간격으로 나누어 검증하였다. 또한, 급격한 노드 수 증가가 전이학습 효과에 미치는 영향을 확인하기 위해 학습 수를 50회로 고정한 상태에서 추가된 은닉층의 노드 수를 50개, 75개, 100개로 설정하여 별도로 분석하였다. 이와 같이 총 145개의 실험 케이스를 구성하여 전이학습 모델의 효과를 체계적으로 검증하였다. 매뉴얼 서치의 결과 도출 과정은 Appendix (A.1) ~ (A.2)에 자세히 기술하였다. 매뉴얼 서치 결과, source 모델 1개 층 재학습, 추가한 은닉층의 노드 수는 11개, 학습 수는 50회로 선정되었다.

	미세조정		노드수		훈련수
CASE 1	1개 층 재학습	CASE 1	7개	CASE 1	20
				CASE 2	30
CASE 2	2개 층 재학습	CASE 2	9개	CASE 3	40
				CASE 4	50
CASE 3	3개 층 재학습	CASE 3	11개	CASE 5	60
				CASE 6	70
CASE 4	0개 (특성추출기)	CASE 4	13개	CASE 7	80
				CASE 8	90



+ 추가 고려사항 3 Cases

Total : 145 Cases

Fig. 4.9 전이학습 모델 학습 방법 분류

제 4장 전이학습 기반 알고리즘 확장성 개선

4) 전이학습 모델 학습

하이퍼 파라미터를 최적화한 모델을 이용하여 모델 학습을 진행하였다. 학습용 데이터를 이용해 모델을 학습시키고, 모델 성능 평가 이전에 과적합과 같은 문제를 해결하기 위해 일반화 검증을 실시하였다. 본 연구에서는 학습에 사용되지 않은 검증용 데이터를 이용해 Validation loss가 가장 낮은 모델로 지속적인 업데이트를 통해 일반화 문제를 해결하였다.


4.3.3 전이학습 모델 평가

본 절에서는 개발한 Source 모델, Source 모델*, Baseline 모델, 전이학습 (TL) 모델의 예측 정확도를 비교하였다. 예측 모델의 정확도 평가에는 R^2 score 및 CV(RMSE)와 제어 설정값에 따른 예측 경향을 활용하였다.


(1) Source 모델 평가

우선 Source 모델의 예측정확도를 평가하였다 (Fig. 4.10). Source 데이터로 학습한 Source 모델의 예측정확도는 실외기 R^2 score 0.99, CV(RMSE) 0.21%, 냉각탑 R^2 score 0.99, CV(RMSE) 0.97%, 냉각수 펌프 R^2 score 0.99, CV(RMSE) 0.88%이지만, target 데이터로 학습한 source 모델*의 예측정확도는 실외기 R^2 score 0.19, CV(RMSE) 68.1%, 냉각탑 R^2 score 0.89, CV(RMSE) 21.5%, 냉각수 펌프 R^2 score -6.6, CV(RMSE) 101.0%이다. Target 데이터로 사용한 예측에서는, 전체적으로 예측 결과가 과소 평가하는 경향이 있었다. 이는, 동일한 기기를 사용하는 시스템이더라도, 운전 스케줄, 기기 노후화, 공조 구역에 따라 운전 조건이 상이할 수 있으며, 그에 따른 개별 시스템별 에너지 소비량 예측모델이 필요하다는 것을 보여준다.

제 4장 전이학습 기반 알고리즘 확장성 개선



(a) Source model



(b) Source model*

Fig. 4.10 Source 모델 예측정확도 검증 결과

(2) 전이학습 모델 평가

Baseline 모델, 전이학습 (TL) 모델의 예측 결과를 Fig. 4.11에 나타낸다. TL 모델의 예측정확도는 실외기 R^2 score 0.99, CV(RMSE) 7.5%, 냉각탑 R^2 score 0.93, CV(RMSE) 8.3%, 냉각수 펌프 R^2 score 0.93, CV(RMSE) 9.4%로 나타났다. 이는, Baseline 모델의 예측 정확도인 실외기 R^2 score 0.90, CV(RMSE) 22.1%, 냉각탑 R^2 score 0.87, CV(RMSE) 22.5%, 냉각수 펌프 R^2 score 0.65, CV(RMSE) 33.9%에 비해 R^2 score는 6.90 % ~ 43.08%, CV(RMSE)는 14.2 % ~ 24.5 % 개선되었다.

Source 모델, Baseline 모델, TF 모델 중 냉각수 온도 설정값에 따

제 4장 전이학습 기반 알고리즘 확장성 개선

른 실외기 전력소비량 변화를 Fig. 4.12에 나타낸다. 이때, 냉각수 온도 설정값은 24도에서 32도까지 2도 간격으로, 부하율은 0.2에서 1.0까지 0.2 간격으로 분석하였다.

Source 모델은 시뮬레이션 데이터를 기반으로 학습되었기 때문에, 동일한 부하 조건에서는 냉각수 온도가 24°C에서 32°C로 상승함에 따라 실외기 전력소비량이 점진적으로 감소하는 경향이 관찰되었다. 반면, baseline 모델은 냉각수 온도 설정값 32°C, 차압 설정값이 0.7 kg/cm²로 운전된 기간에서 취득한 데이터를 기반으로 학습되었기 때문에, 동일한 부하 조건에서 냉각수 온도가 24°C에서 32°C로 상승함에 따라 실외기 전력소비량이 점진적으로 감소하는 경향이 관찰되지 않았다. 그리고, 부하가 증가할수록 냉각수 온도 설정값에 따른 실외기 전력소비량의 차이가 더 커졌으며, 냉각수 온도 설정값이 24°C, 26°C일 때는 source 모델과 비교하여 전력소비량이 낮게 예측하였다. 이는 불균형한 데이터로 학습된 모델이 단순히 예측정확도가 낮을 뿐만 아니라, 부정확한 제어 설정값으로 최적화가 이루어질 수 있음을 보여준다. TL 모델은 source 모델의 가중치와 target 시스템의 운전데이터를 기반으로 학습되었기 때문에, source 모델과 유사하게 동일한 부하 조건에서는 냉각수 온도가 24°C에서 32°C로 상승함에 따라 실외기 전력소비량이 점진적으로 감소하는 패턴이 관찰되었다. 부하가 0.2 구간에서 예측이 역전되는 경향이 나타났으나, 실제 시스템 운전 시 해당 부하 구간으로 운전된 빈도가 적기 때문에 무시 가능한 수준이라 판단하였다.

제 4장 전이학습 기반 알고리즘 확장성 개선

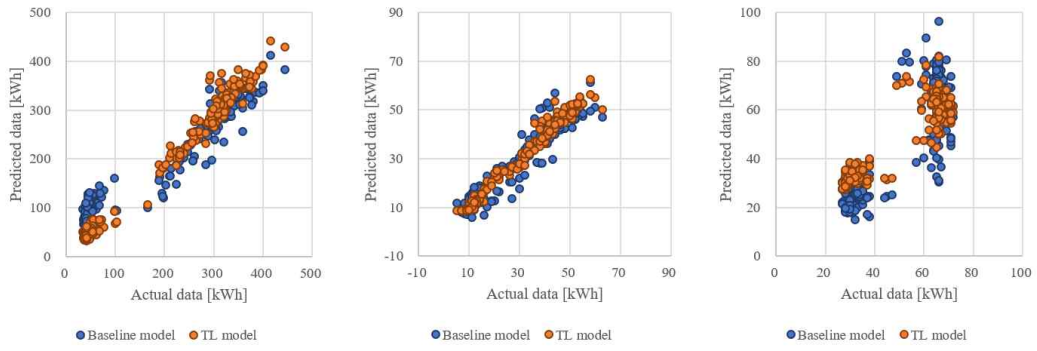


Fig. 4.11 모델 정확도 비교

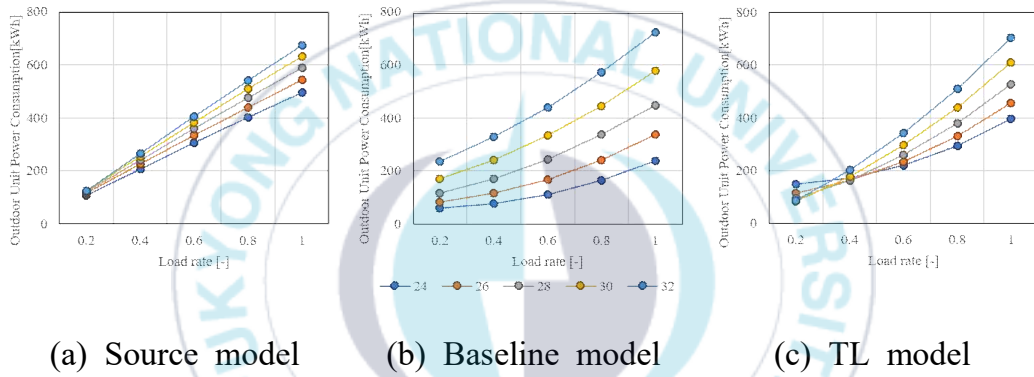


Fig. 4.12 냉각수 온도에 따른 실외기 전력소비량 변화

제 5장 결 론

본 연구에서는 실제 건물을 대상으로 DNN 예측모델 기반의 냉각수 온도 및 유량 제어 설정값 최적화 알고리즘과 Rule 기반의 냉수 온도 알고리즘을 개발하고 실증 연구를 진행한 뒤, 효과 검증이 끝난 모델을 source 모델로 사용하여 타 시스템으로의 확장 가능성 및 최적 제어를 위한 전이학습 활용 방법에 대해 연구하였다. 주요 연구 결과는 다음과 같다.

(1) 실 운전 데이터 부족 및 파생되는 정확도 문제를 해결하기 위해 물리식 기반의 열원시스템 시뮬레이션 모델을 구축하였다. 모델의 시스템 전력소비량에 대한 정확도는, R2 score 0.97, CV(RMSE) 16.5%로, ASHRAE Guideline 14, IPMVP, FEMP의 기준을 모두 만족하였다. 시뮬레이션을 이용하여 냉각수 온도와 냉각수 온도차 설정값을 변경하며 총 25,504개의 시간당 데이터를 확보하였다.

(2) 열원시스템 전력소비량 예측을 위한 DNN 예측모델의 정확도는 R2 score 0.99, CV(RMSE) 1.21%로, ASHRAE Guideline 14 기준을 만족하였다.

(3) 알고리즘 적용 전과 후의 제어설정값을 비교한 결과, 냉수 온도는 baseline 운전 7°C에서 algorithm 운전 10.4 °C로 3.4 °C 상승하였고, 냉각수 온도는 baseline 운전 28 °C에서 algorithm 운전 29.4 °C로 1.4 °C 상승하였으며, 냉각수 온도차는 baseline 운전 2 °C에서 algorithm 운전 5.4 °C로 3.4 °C 로 증가하였다.

(4) 알고리즘의 에너지 절감 효과는 IPMVP의 Option C 방법에 따라 검증하였다. 알고리즘 적용 후의 실제 열원시스템 전력소비량과 baseline 운전의 처리열량으로 환산된 전력소비량을 비교한 결과, 검증기간동안 약 18.8%의 열원시스템 전력소비량을 절감하였다.

(5) 냉수 온도 제어가 실내 온습도에 미치는 영향을 검증하기 위해, 알고리즘 적용 전과 후의 CAV AHU의 실내온도와 VAV AHU의 급기온도를 비교하였다. CAV AHU의 실내온도와 VAV AHU 모두 알고리즘 적용 여부와 상관없이 설정값에 의해 안정적으로 제어되었다. 따라서, 냉수 제어에 따른 실내 온열환경의 이상변화는 없을 것이라 판단된다.

(6) 데이터가 부족한 시스템의 최적 제어를 위해, 알고리즘 효과 분석이 끝난 source 모델을 활용해 전이학습을 적용하였다. 결과, 전이학습 모델은 전이학습 대상 건물의 데이터만 사용하여 학습한 baseline 모델과 비교해서 R2 score는 6.9 % ~ 43.1 %, CV(RMSE)는 14.2 % ~ 24.5 % 개선되었으며, 제어 설정값에 따른 예측 경향 역시 source 모델의 경향과 유사하였다.

참고문헌

1. Space Cooling, 2018, IEA
2. The Future of Cooling, 2018, IEA
3. GHG Protocol Scope 2 Guidance (GREENHOUSE GAS PROTOCOL), 2015, World Resources Institute and World Business Council for Sustainable Development
4. Climate Watch, 2023, WORLD RESOURCES INSTITUTE
5. Greenhouse Gas Emission from Energy Data Explorer, 2024, IEA
6. Yabin, D., Marney, C., Shelie, A. M. (2021). Greenhouse Gas Emission from Air Conditioning and Refrigeration Service Expansion in Developing Countries. Annual Review of Environment and Resources, Volume 46, 59-83
7. Net Zero by 2050 - A Roadmap for the Global Energy Sector, 2021, IEA, Paris: IEA
8. United Nations, 2022, World Population Prospects
9. Global Greenhouse Gas Emissions Data, EPA(United States Environmental Protection Agency)
10. Key measures could slash predicted 2050 emissions from cooling sector, UN environment programme
11. Pérez-Lombard, L., Ortiz, J., F. Connel, J., & R. Maestre, I. (2011). A review of HVAC systems requirements in building energy regulations. Energy and Buildings, Volume 43, Issues 2-3, Pages 255-268
12. Mckoy, D. R., Tesiero, R. C., Acquaah, Y. T., & Gokaraju, B. (2023). Review of HVAC Systems History and Future Applications. Energies, 16(17), 6109
13. 박상균. (2023). 건물에너지관리시스템(BEMS)의 경제성 평가에 대한 사례 분석. Magazine of the SAREK, 52(7), 28-34

14. Taheri, S., Hosseini, P., & Razban, A. (2022). Model predictive control of heating, ventilation, and air conditioning (HVAC) systems: A state-of-the-art review, *Journal of Building Engineering*, Volume 60, 105067
15. Afram, A., Janabi-Sharafi, F., S. Fung, A., & Raahemifar. K. (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*, Volume 141, Pages 96-113
16. 박석민, 이제현. (2023). HVAC 시스템 대상 제어 설정값 최적화를 위한 데이터 기반 예측 모델 개발에 대한 연구, *수산해양교육연구*, 35(6), 1071-1078
17. 문진우. (2019). 인공지능 기반 VRF 시스템 제어. (2019). *LHI Journal*, 10(3), 9-16
18. Olu-Ajayi, R., Alaka, H., Sulaimon, I., Sunmola, F., & Ajayi, S. (2022). Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques, *Journal of Building Engineering*, 45, 103406
19. Jee, H. J., Yeon, S. H., Park, J. W., Yoon, Y. B., & Lee, G. H. (2023). Machine learning based simultaneous control of air handling unit discharge air and condenser water temperatures set-point for minimized cooling energy in an office building, *Energy and Buildings*, Volume 297, 113471
20. Gao, G., Li, J., & Wen. Y. (2020). DeepComfort: Energy-Efficient Thermal Comfort Control in Buildings Via Reinforcement Learning, in *IEEE Internet of Things Journal*, vol. 7, no. 9, Pages 8472-8484
21. Sun, Y., Xue, H., Wang, W., Wu, S., Hong, Y., & Deng, S. (2020). Development of an optimal control method of chilled water

- temperature for constant-speed air-cooled water chiller air conditioning systems, *Applied Thermal Engineering*. 180. 115802
22. Granderson, J., Lin, G., Singla, R., Fernandes, S., & Touzani, S. (2018). Field evaluation of performance of HVAC optimization system in commercial buildings, *Energy and Buildings*, Volume 173, Pages 577-586
23. Kang, W. H., Yoon, Y., Lee, J. H., Song, K. W., Chae, Y. T., & Lee, K. H. (2021). In-situ application of an ANN algorithm for optimized chilled and condenser water temperatures set-point during cooling operation. *Energy and Buildings*, 233, 110666.
24. Lu, C., Li, S., & Lu, Z. (2022), Building energy prediction using artificial neural networks: A literature survey, *Energy & Buildings*. 262. 111718
25. Jones, B., Luxenberg, S., McGrath, D., Trampert, P., & Weldon, J. (2011). RabbitMQ performance and scalability analysis project on CS 4284
26. IPMVP Committee. International Performance Measurement and Verification Protocol: Concepts and Options for Determining Energy and Water Savings; Technical Report; Efficiency Valuation Organization: Washington, DC, USA, 2012; Volume I
27. Yeon, S. H., Yoon, Y. B., Kang. W. H., Lee. J. H., Song. K. W., Chae. Y. T., Choi. J. M., & Lee. K. H. (2023). Lower and upper threshold limit for artificial neural network based chilled and condenser water temperatures set-point control in a chilled water system, *Energy Reports*, Volume 9, Pages 6349-6361
28. ASHRAE. Guideline 14-2014, Measurement of Energy and Demand Savings; Technical Report; American Society of Heating, Ventilating, and Air-Conditioning Engineers.

29. Wester, L., Bradford, J., Sartor, D., Shonder, J., Atkin, E., Dunnivant, S., Frank, D., Franconi, E., et al. M&V Guidelines: Measurement and Verification for Performance-Based Contracts, version 4.0. Technical Report, U.S Department of Energy Federal Energy Management Program.
30. Buildings Services Commissioning Association WG, The Society of Heating, Air - Conditioning and Sanitary Engineers of Japan, HVACSIM+(J) user manual, 1998.04
31. Zhou, S. L., Shah, A. A., Leung. P. K., Zhu. X., & Liao, Q. (2023). A comprehensive review of the applications of machine learning for HVAC, Decarbon, Volume 2, 100023
32. Sze, V., Chen, Y., Yang, T., & Emer, J., Efficient Processing of Deep Neural Networks: A Tutorial and Survey, arXiv:1703.09039 [cs.CV]
33. Yu, T., Zhu, H., Hyper-Parameter Optimization: A Review of Algorithms and Applications, arXiv:2003.05689 [cs.LG]
34. Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A, Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization, arXiv:1603.06560 [cs.LG]
35. EXPLORING THE TRANSFER LEARNING ASPECT OF DEEP NEURAL NETWORKS IN FACIAL INFORMATION PROCESSING. (2015)
36. Pan, S. J, Yang, Q. A Survey on Transfer Learning, in IEEE Transactions on Knowledge and Data Engineering, vol. 22, pp. 1345-1359, Oct. 2010
37. Pan, S. J., Tsang I. W., Kwok, J. T., Yang. Q. Domain Adaption via Transfer Component Analysis, Proc. 21st Intl Joint Conf. Artificial Intelligence, 200

38. Ben-David, S., Luu, T., Lu, T., Pai, D. (2010). Impossibility Theorems for Domain Adaption. Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, PMLR 9:129-136
39. 안유선, 진경일, 이용준. (2020). 전이 학습 기반 고정된 레이어 수에 따른 건물 전력 소비량 예측 정확도 기준. 한국태양에너지 학회, Vol. 40(6), 151-160
40. Santos, M., Garcia, S., Garcia-Santiago, X., Ogando-Martinez, A., Camarero, F., Gil, G., & Ortega, P. (2023). Deep learning and transfer learning techniques applied to short-term load forecasting of data-poor buildings in local energy communities, Energy and Buildings, Volume 292, 113164
41. Gao, Y., Ruan, Y., Fang, C., & Yin. S. (2020). Deep learning and transfer learning models of energy consumption forecasting for a building with poorer information data, Energy and Buildings, Volume 223, 110156
42. Cho, S. K., Ra, S. J., Choi, S. H., Park, C. S. (2024). Application of transfer learning to overcome data imbalance and extrapolation for model predictive control: A real-life case. Energy and Buildings. Volume 258, 114135
43. Ahn, Y. S., Kim, B. S. (2022). Prediction of building power consumption using transfer learning-based reference buildings and simulation dataset. Energy and Buildings, Volume 258, 111717

Appendix


A.1 미세조정에 따른 전이학습 모델 정확도 비교

본 절에서는 미세조정에 따른 전이학습 모델의 정확도를 비교하는 과정을 총 4개의 Case로 나눠 기술한다. 첫 번째(Case 1)는, 하나의 은닉층만을 재학습하는 방법, 두 번째(Case 2)는, 두 개의 은닉층을 재학습하는 방법, 세 번째(Case 3)는, 세 개의 은닉층을 재학습하는 방법, 마지막(Case 4)은, 모든 은닉층을 고정하고 특성추출기만 활용하는 방법으로 분류하였다. 그 외 실험 조건은, 추가된 은닉층 노드 수 11개로 고정하고, 학습수는 100번으로 설정하였고, 데이터는 검증용 데이터를 활용하였다. Fig. A.1과 Table A.1은 각 Case에 따른 모델의 예측정확도 결과를 나타낸다. Case 1의 예측정확도는 실외기 R^2 score 0.98, CV(RMSE) 6.5%, 냉각탑 R^2 score 0.98, CV(RMSE) 7.5%, 냉각수 펌프 R^2 score 0.95, CV(RMSE) 7.4%로 ASHRAE Guideline 14 기준을 만족한다. Case 2의 예측정확도는 실외기 R^2 score 0.99, CV(RMSE) 6.6%, 냉각탑 R^2 score 0.96, CV(RMSE) 11.3%, 냉각수 펌프 R^2 score 0.94, CV(RMSE) 8.1%로 ASHRAE Guideline 14 기준을 만족한다. Case 3의 예측정확도는 실외기 R^2 score 0.99, CV(RMSE) 6.7%, 냉각탑 R^2 score 0.98, CV(RMSE) 8.0%, 냉각수 펌프 R^2 score 0.94, CV(RMSE) 8.2%로 ASHRAE Guideline 14 기준을 만족한다. Case 4의 예측정확도는 실외기 R^2 score 0.96, CV(RMSE) 13.5%, 냉각탑 R^2 score 0.81, CV(RMSE) 24.8%, 냉각수 펌프 R^2 score 0.78, CV(RMSE) 15.6%로 ASHRAE Guideline 14 기준을 만족한다. 이때, Case 1이 가장 우수한 성능을 보였으며, 특성추출기만 활용한 Case 4가 가장 낮은 성능을 보이며, R^2 score는 최소 0.03에서 최대 0.17, CV(RMSE)는 최소 7.0%에서 최대 17.3%까지 차이가 발생하였다.

Fig. A.2는 냉각수 온도 설정값과 부하율에 따른 실외기 전력소비

량 변화를 나타낸다. 이때, 냉각수 온도 설정값은 24도에서 32도까지 2도 간격으로, 부하율은 0.2에서 1.0까지 0.2 간격으로 분석하였다. Case 1 ~ 3은 부하율 0.2 구간을 제외하고 냉각수 온도 설정값이 낮아질수록 실외기 전력소비량이 감소하였으며, 모든 설정값에서 일정하게 감소하는 경향이 보였다. 반면, Case 4는 냉각수 온도 설정값 32°C일 때를 제외하고 실외기 전력소비량이 전반적으로 과소 평가되었으며, 설정값이 낮아질수록 이러한 경향은 더 두드러지게 나타났다.

이를 통해, 재학습하는 레이어의 개수와 전이학습 모델의 예측정확도가 반드시 비례하지 않음을 확인할 수 있었다. 예측정확도 및 제어 설정값에 따른 전력소비량 변화 경향을 종합적으로 고려했을 때, Case 1(1개 층을 재학습하는 방법)이 최적의 학습 방법이라 평가된다.



(a) 실외기

(b) 냉각탑

(c) 냉각수 펌프

Fig. A.1 예측정확도 결과

Table A.1 미세조정에 따른 전이학습 모델 정확도 비교

	Case 1		Case 2		Case 3		Case 4	
정확도	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]
실외기	0.98	6.5	0.99	6.6	0.99	6.7	0.96	13.5
냉각탑	0.98	7.5	0.96	11.3	0.98	8.0	0.81	24.8
냉각수 펌프	0.95	7.4	0.94	8.1	0.94	8.2	0.78	15.6




Fig. A.2 냉각수 온도에 따른 실외기 전력소비량 변화

A.2 하이퍼 파라미터에 따른 전이학습 모델 정확도 비교

본 절에서는 하이퍼 파라미터에 따른 전이학습 모델의 정확도를 다음과 같이 분류하여 비교하였다. 추가된 은닉층의 노드수는 7개, 9개, 11개, 13개로 변화시키며 모델 정확도를 평가하였고, 급격한 노드수 증가의 영향을 파악하기 위해 학습수는 50번으로 고정하고 추가된 은닉층의 노드수를 50개, 75개, 100개로 변화시키며 추가 분석하였다.

(1) 학습수

학습수에 따른 전이학습 모델의 정확도를 비교하기 위해 학습수를 20번부터 100번까지 10번 간격으로 변화시키며 모델(Case 1 ~ 9) 정확도를 평가하였다. 그 외 실험 조건으로는, 하나의 은닉층만 재학습하고, 추가된 은닉층의 노드수는 11개로 고정하였으며, 데이터는 검증용 데이터를 활용하였다. Fig. A.3과 Table A.2는 각 Case에 따른 모델의 예측정확도 결과를 나타낸다. 학습수가 20번과 100번인 Case 1과 Case 9에서 예측정확도가 상대적으로 낮았고, Case 1 ~ 3, 7 ~ 9에서는 냉각수 펌프 예측 시 실제값보다 과소 및 과대 평가하는 경향이 관찰되었다. 반면, 학습수가 50 ~ 80번인 Case 4 ~ 8에서는 예측정확도가 상대적으로 높았으며, Case 5는 실외기 R^2 score 0.98, CV(RMSE) 8.0%, 냉각탑 R^2 score 0.98, CV(RMSE) 7.6%, 냉각수 펌프 R^2 score 0.93, CV(RMSE) 9.0%로 가장 높았다.

Fig. A.4는 냉각수 온도 설정값과 부하율에 따른 실외기 전력소비량 변화를 나타낸다. 이때, 냉각수 온도 설정값은 24도에서 32도까지 2도 간격으로, 부하율은 0.2에서 1.0까지 0.2 간격으로 분석하였다. 모든 Case에서 냉각수 온도 설정값이 낮아질수록 실외기 전력소비량이 감소하는 경향이 나타났다. Case 1 ~ 8에서는 부하율 0.2 구간에서

역전되는 경향이 나타났지만, 실제 시스템 운전 시 해당 부하 구간으로 운전된 빈도가 적기 때문에 무시 가능한 수준이라 판단하였다. 전체적인 예측 경향은 유사하지만, 학습수가 증가할수록 냉각수 온도 설정값에 따른 실외기 전력소비량의 변화가 완만해지는 경향이 확인되었다.

이를 통해, 학습수와 전이학습 모델의 예측정확도가 반드시 비례하지 않음을 확인할 수 있었다. 예측정확도 및 제어 설정값에 따른 전력소비량 변화 경향을 종합적으로 고려했을 때, 학습수 50번에서 70번이 최적의 학습수라 평가된다.

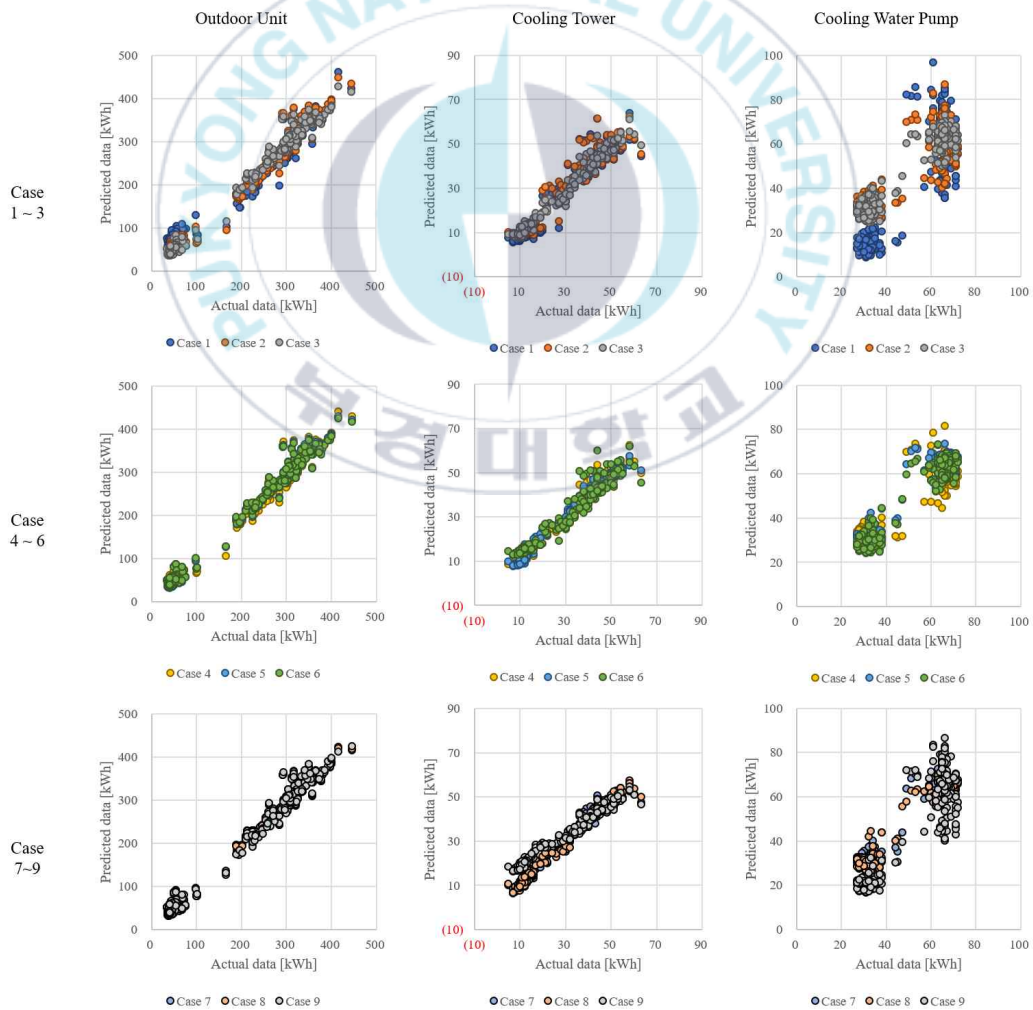


Fig. A.3 예측정확도 결과

Table A.2 학습수에 따른 전이학습 모델 정확도 비교

	Case 1		Case 2		Case 3	
정확도	R ² score [-]	CV(RMSE) [%]	R ² score [-]	CV(RMSE) [%]	R ² score [-]	CV(RMSE) [%]
실외기	0.98	12.1	0.97	13.1	0.98	11.6
냉각탑	0.87	25.2	0.94	14.8	0.96	10.9
냉각수 펌프	0.35	29.2	0.76	17.9	0.77	13.5
	Case 4		Case 5		Case 6	
정확도	R ² score [-]	CV(RMSE) [%]	R ² score [-]	CV(RMSE) [%]	R ² score [-]	CV(RMSE) [%]
실외기	0.99	7.5	0.98	8.0	0.98	7.9
냉각탑	0.93	8.3	0.98	7.6	0.94	14.7
냉각수 펌프	0.93	9.4	0.93	9.0	0.90	10.7
	Case 7		Case 8		Case 9	
정확도	R ² score [-]	CV(RMSE) [%]	R ² score [-]	CV(RMSE) [%]	R ² score [-]	CV(RMSE) [%]
실외기	0.98	7.7	0.98	10.8	0.98	8.4
냉각탑	0.98	8.7	0.96	12.5	0.85	22.8
냉각수 펌프	0.89	8.4	0.81	15.6	0.83	23.7

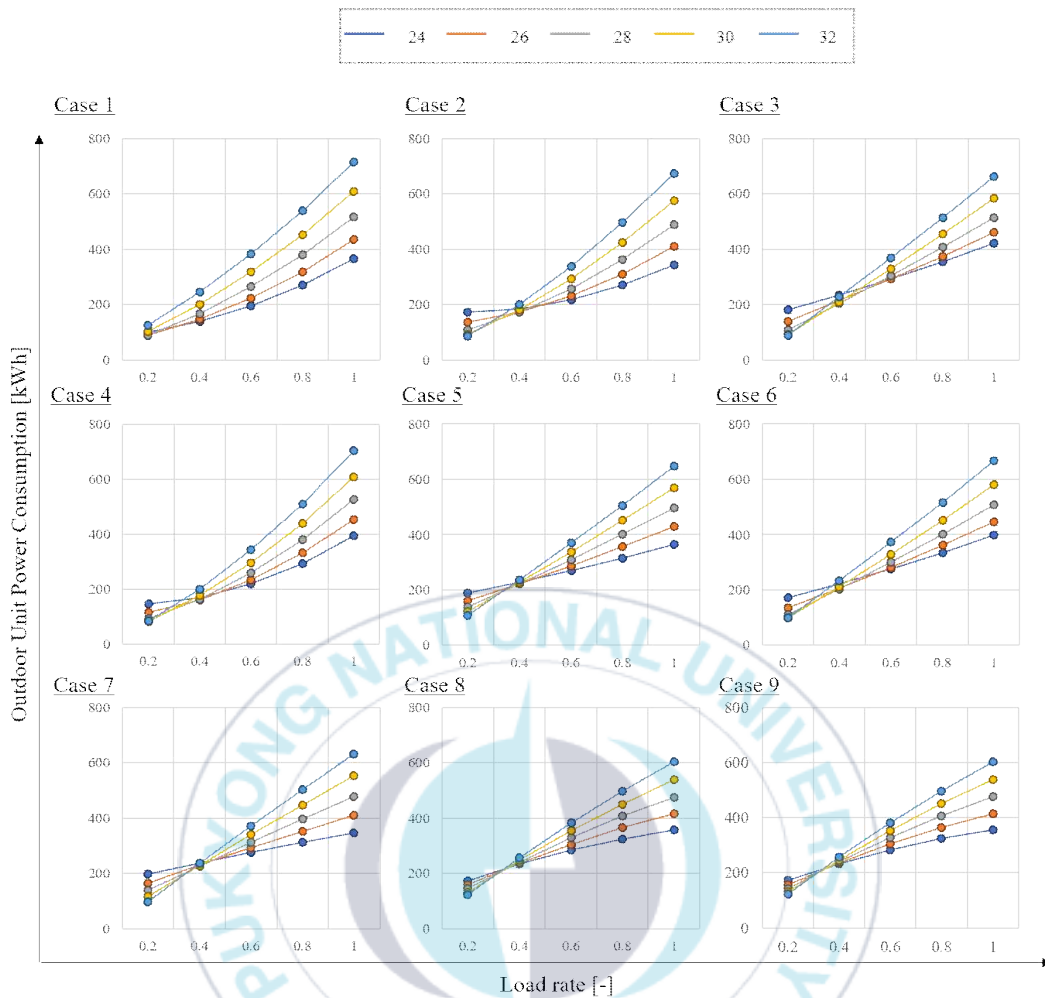


Fig. A. 4 냉각수 온도에 따른 실외기 전력소비량 변화

(2) 노드수

노드수에 따른 전이학습 모델의 정확도를 비교하기 위해 노드수를 7개, 9개, 11개, 13개, 50개, 75개, 100개로 변화시키며 모델 (Case 1 ~ 7) 정확도를 평가하였다. 그 외 실험 조건으로는, 하나의 은닉층만 재학습하고, 학습수는 50회로 고정하였으며, 데이터는 검증용 데이터를 활용하였다. Fig. A.5과 Table A.3는 각 Case에 따른 모델의 예측 정확도 결과를 나타낸다. 모든 Case의 예측정확도는 ASHRAE Guideline 14 기준을 만족하였다. 하지만, 노드수가 비교적 작은 Case 1 ~ 4에서 냉동기 예측 시에는 실제값과 비슷했지만, 냉각탑 및 냉

각수 펌프 예측 시 실제값보다 과소 및 과대 평가되는 경향이 관찰되었다. 반면, 노드수가 비교적 큰 Case 5 ~ 7에서는 모든 기기에 대한 예측정확도가 상대적으로 높았으며, 학습수가 100번인 Case 7은 실외기 R^2 score 0.99, CV(RMSE) 7.6%, 냉각탑 R^2 score 0.99, CV(RMSE) 6.4%, 냉각수 펌프 R^2 score 0.95, CV(RMSE) 7.9%로 가장 높았다.

Fig. A.6는 냉각수 온도 설정값과 부하율에 따른 실외기 전력소비량 변화를 나타낸다. 이때, 냉각수 온도 설정값은 24도에서 32도까지 2도 간격으로, 부하율은 0.2에서 1.0까지 0.2 간격으로 분석하였다. 모든 Case에서 냉각수 온도 설정값이 낮아질수록 실외기 전력소비량이 감소하는 경향이 나타났다. 일부 Case에서 부하율 0.2 구간에서 역전되는 경향이 나타났지만, 실제 시스템 운전 시 해당 부하 구간으로 운전된 빈도가 적기 때문에 무시 가능한 수준이라 판단하였다. 전체적인 예측 경향은 유사하지만, 노드수가 증가할수록 냉각수 온도 설정값에 따른 실외기 전력소비량의 변화가 완만해지는 경향이 확인되었다. 특히, 노드수가 급격히 증가하는 Case 5 ~ 7에서는, 설정값이 낮아질수록 앞선 경향이 두드러졌다.

이를 통해, 학습수와 전이학습 모델의 예측정확도가 반드시 비례하지 않음을 확인할 수 있었다. 예측정확도 및 제어 설정값에 따른 전력소비량 변화 경향을 종합적으로 고려했을 때, 노드수가 입력데이터 수의 $2n+1$ 개 부근이 최적의 노드수라 평가된다.

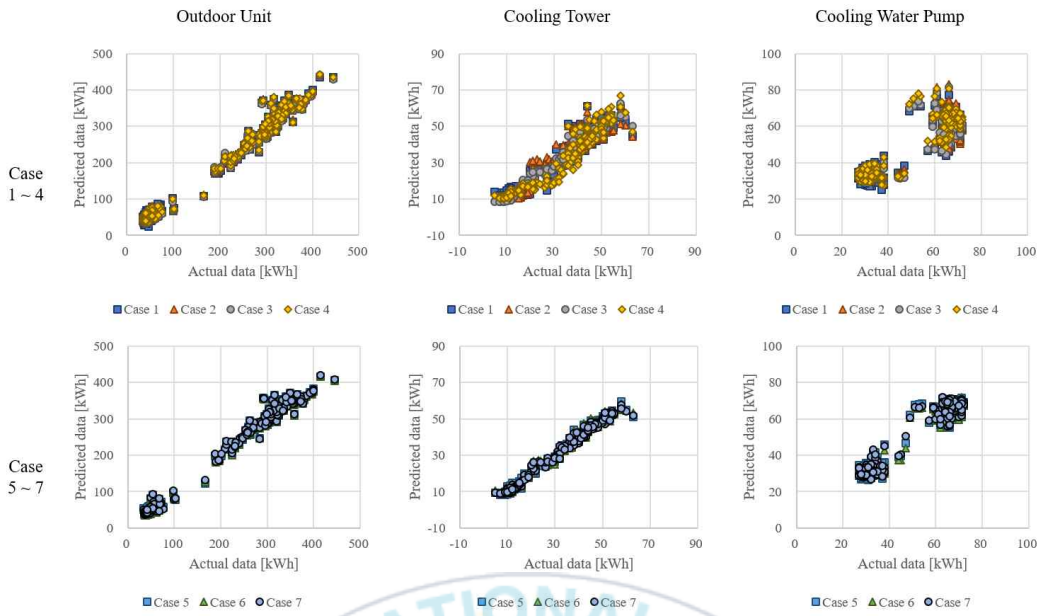


Fig. A.5 예측정확도 결과

Table A.3 노드수에 따른 전이학습 모델 정확도 비교

	Case 1		Case 2		Case 3		Case 4	
	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]
정확도	0.98	8.0	0.99	7.5	0.99	7.5	0.99	7.4
실외기	0.95	12.8	0.95	12.7	0.93	8.3	0.94	13.9
냉각탑	0.85	12.9	0.83	13.6	0.93	9.4	0.90	10.6
냉각수 펌프								
	Case 5		Case 6		Case 7			
	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]	R ² score [-]	CV(RMS E) [%]		
정확도	0.99	7.7	0.99	7.7	0.99	7.6		
실외기	0.99	6.4	0.99	6.9	0.99	6.4		
냉각탑	0.94	8.5	0.95	7.7	0.95	7.9		
냉각수 펌프								

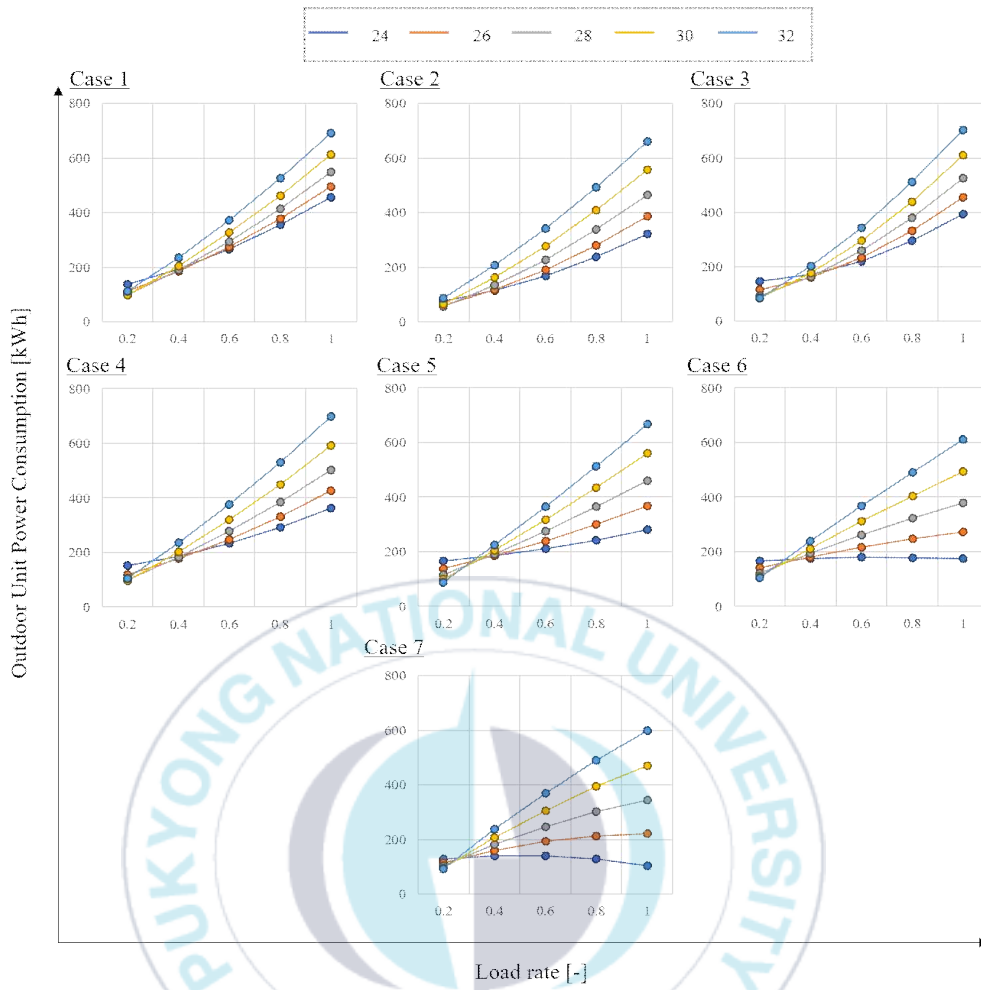


Fig. A. 6 냉각수 온도에 따른 실외기 전력소비량 변화

감사의 글

다사다난했던 6년이라는 세월이 지나 졸업을 앞두고 되었습니다. 그 시간 동안, 너무 멋진 사람들과 너무 훌륭한 것들을 배울 수 있었습니다. 2018년 봄, 기숙사에 부모님과 짐을 옮기던 게 기억과 2022년 봄, 연구실에 처음 출근했던 어색한 기운마저 아직 생생한 데, 저는 어느덧 새로운 봄을 맞이할 준비를 하고 있습니다. 이 자리를 빌려, 많은 분께 감사의 인사를 전하고자 합니다.

우선, 항상 열정적으로 가르쳐주시고, 진심 어린 조언과 많은 경험을 할 수 있게 도와주신 이제현 교수님께 깊은 존경을 표합니다. 어려움이 있으면 먼저 다가와 주시고, 단순히 전공지식을 넘어 깊이 공감하는 조언 덕분에 저는 오늘 이 자리까지 올 수 있었습니다. 퇴임 반년 전에 찾아가 연구실에 들어가고 싶다고 말했을 때, 선뜻 받아주셔서 이제현 교수님과의 인연을 이어가게 해주셨던 금종수 교수님께 감사드립니다. 그리고, 항상 최선을 다하시며 학생들이 어엿한 냉동공조인으로 나아갈 수 있게 도와주신 최광환 교수님, 윤정인 교수님, 김은필 교수님, 손창효 교수님께 감사드립니다. 학위 논문을 심사해주시며 많은 가르침과 조언을 아끼지 않으셨던 정석권 교수님과 설성훈 교수님께 특히 감사드립니다.

많은 시간을 함께 보내진 못했지만, 항상 학생들에게 편하게 다가와 주시며 아낌없는 조언을 해주신 김민수 박사님, 학부 시절부터 석사 과정까지 툭툭거리시지만 항상 온 마음 다 바쳐 알려주신 석민 선배님, 항상 웃는 얼굴로 연구실의 분위기를 이끌어주셨던 원호 선배님, 같은 아니지만 누구보다 마음 여린 세현이, 1학년 때부터

감사의 글

도움을 많이 받았던 다성이, 그리고 열심히 믿고 따라와 준 준원이랑 경민이, 마지막까지 장난 받아준 시원이, 새로 연구실에 들어와 열심히 하는 두형이, 영웅이, 정원이, 승훈이까지 너무나 든든하고 자랑스러운 친환경공조시스템 연구실 멤버들 덕분에 힘들었던 순간들마저 기쁨으로 느껴집니다. 학부 시절 함께 공부하고 웃으며 보냈던 경호, 동근이, 어진이, 희성이, 한울이형, 사람의 정을 알려준 동선이, 열정을 알려준 전통예술연구회 터 인원들, 그리고 항상 친절하게 알려주시던 채현욱 조교님, 박지연 조교님 모두에게 감사하다는 말을 전합니다. 마지막으로, 말없이 묵묵히 믿어주고 지원해주신 부모님, 누나, 할머니 모든 가족에게 감사의 인사들 남깁니다.

아직은 부족하지만, 부경대학교 냉동공조공학과에서 배운 지식, 경험들을 좀 더 다듬어서 더 나은 사람이 될 수 있도록 노력하겠습니다. 이 열정, 마음 그대로 살아가겠습니다. 다시 한번 저를 도와주고 응원해주고, 혹은 우연히 지나쳤던 모든 인연에게도 감사를 포함합니다.

2025년 1월 11일 노정현