



데이터센터 최적 열환경 제공을 위한 적응형 인공신경망 냉매 유량 예측 모델 개발

Development of Adaptive ANN Mass Flow Rate Prediction Model for Providing Optimal Thermal Environment in Data Center

최영재* · 박보람** · 최은지*** · 문진우****

Young Jae Choi* · Bo Rang Park** · Eun Ji Choi*** · Jin Woo Moon****

* Main author, School of Architecture and Building Science, Chung-Ang University, South Korea (chlyoungwo@gmail.com)

** Coauthor, School of Architecture and Building Science, Chung-Ang University, South Korea (pbr_1123@naver.com)

*** Coauthor, School of Architecture and Building Science, Chung-Ang University, South Korea (ejjchl77@gmail.com)

**** Corresponding author, School of Architecture and Building Science, Chung-Ang University, South Korea (gilerbert73@cau.ac.kr)

ABSTRACT

Purpose: The purpose of this paper is to develop an ANN model for predicting the refrigerant flow rate of the cooling system in order to provide optimal thermal environment in the data center as well as an adaptive control algorithm which allows the predictive model to adapt to the diverse data center environments. **Method:** Two data center models were consisted by using ANSYS Fluent CFD tool. Model A was used to obtain data for ANN model training and the adaptive control algorithm was tested on the Model B. After developing the ANN model, the optimization process was conducted and the optimized model was employed in the adaptive control algorithm. **Result:** A model consisted with 4 hidden layers and 11 hidden neurons presented the highest accuracy of CVRMSE 0.47%. In addition, the adaptation test of the control algorithm was conducted by changing the air flow rate and the setpoint temperature of supply air. When the setpoint temperature was set to 20°C and 25°C, the supply air temperature reached properly to the designated setpoint temperature in 3 cycles and 20 cycles, respectively. Each case presented maximum error of the temperature as much as 19.6% and 18.12%. After entering steady state, the ANN model adapted well on the setpoint temperature. In conclusion, the ANN model and the adaptive algorithm demonstrated a probability to be applied to the data center.

KEYWORD

데이터센터
인공신경망
냉매 유량 제어Data Center
Artificial Neural Network
Refrigerant Flow Control

ACCEPTANCE INFO

Received Nov. 6, 2019
Final revision received Nov. 19, 2019
Accepted Nov. 25, 2019

© 2019 KIEAE Journal

1. 서론

1.1. 연구의 배경 및 목적

데이터 기반 사업의 증가, 5세대 이동통신망 등 신기술 개발이 가속화되며 대용량의 데이터를 처리하고 저장할 수 있는 전문 데이터센터의 수요가 증가하고 있다. 2022년경의 대한민국 인터넷 통신량은 2015년 대비 두 배가 될 것으로 전망되며 모바일 인터넷 사용자는 2018년 36억 명에서 2025년 50억 명으로, IoT 연결망은 약 3배가 증가할 것으로 예측되었다[1]. 이러한 동향은 데이터센터의 중요성을 더욱 부각시키며 증가하는 IT 수요에 대한 효율적인 관리 방안 및 시스템의 구축을 요구한다.

데이터센터는 전 세계 전력 사용량의 2%를 차지하며 ICT 분야에서 CO₂ 배출 증가량이 가장 높게 나타났다[2]. 이에 따라 다양한 국가에서 데이터센터와 관련된 규제 및 가이드라인을 배포하고 있으며 국내 또한 2012년 방송통신위원회에서 데이터센터 구축지침을 배포하였다. 국내 지침의 경우 공조, 전기, IT 부문의 관리 방안 및 데이터센터 구축 시에 고려해야 할 권고사항을 제시하고 있다.

데이터센터 IT 장비와 냉방에너지 전력 소비량은 데이터센터 전

체 운영 에너지의 약 40%를 차지한다[3]. 데이터센터의 에너지 효율은 PUE (Power Usage Effectiveness)로 측정된다. PUE는 데이터센터 총 전력 소비량 대비 IT 장비의 전력 소비량으로써 1에 가까울수록 효율이 높은 것을 의미한다. 현재 국내 데이터센터의 경우 공공부분의 PUE는 3.13, 민간부분은 2.03으로 해외 데이터센터의 평균 PUE가 1.7, 선진국이 1.2인 것에 비하면 효율이 낮은 수준이다[4]. 선진국의 경우 한랭기후대에 데이터센터를 설치하고 외기도입 방식을 통해 냉방 에너지를 최소화 하지만 국내의 경우 사계절이 뚜렷한 기후로 인하여 외기도입이 제한적이다. IT 장비의 효율적 배치, 컨테이너 시스템 등의 적용만으로는 PUE 지표를 낮추는데 한계가 있으며 추가적인 PUE 절감을 이루기 위해서는 에너지 효율을 높이는 제어 시스템이 병행되어야 한다.

데이터센터 냉방에너지를 절감하기 위한 연구는 다양하게 진행되고 있으나 국내는 국외에 비하여 미비한 실정이다. 국내의 경우 합리적인 환경 제어를 위하여 에너지 소비에 미치는 환경 변수를 정량화하는 연구를 바탕으로 최적 냉각시스템 선정에 관한 연구[5], 합리적인 공조시스템 선정에 관한 설계 변수 정량화 및 요소 분석에 대한 연구가 이루어 졌다[6]. 실제 제어대상을 선정하여 냉방 에너지 절감을 이룬 사례로는 냉복도 차폐형의 컨테이너 시스템에 대해서 항온항습기에 가변풍량시스템을 적용하여 냉방에너지의 19.8%

를 절감한 연구[7], 모듈러 데이터센터의 CRAH (Computer Room Air Handling Unit) 풍량 제어를 실시한 연구가 있다[8].

국외의 관련 연구는 데이터센터 총 에너지 사용량 절감을 위한 통합 제어시스템 측면에서의 연구가 주를 이루고 있다. 물리적 환경의 수학적 모델링을 통하여 온도를 예측하는 연구가 진행되었으며 이를 실제 시스템에 적용하기 위해 반응속도를 향상 시키고 안정화 하는 연구가 진행되었다[9-11]. 온도 예측을 위한 가상 모델링 및 제어 시스템 구성으로는 MPC, 인공신경망 등의 기법이 적극 활용되었다[12-14]. 또한 적용 대상이 되는 데이터센터의 기존 제어 프로세스에서 각 제어 시스템의 최적 작동방안 도출을 통한 에너지 절감, 팬 속도 제어를 통한 에너지 절감 등의 연구가 진행되었다[15-17].

이와 같이 데이터센터 온도 제어에 관한 연구는 대부분 운영 및 관리 시스템 안에서 하나의 요소로서 진행되고 있다. 또한 팬의 속도 조절을 통한 온도 제어 방안은 연구되고 있으나 냉매 유량으로 직접 온도를 제어하는 방안은 연구가 미비하다. 냉매 유량 제어는 일정한 냉동 유동 시스템과 비교하여 에너지 효율적이고 IT 부하에 따라 조절이 유연하다는 장점이 있다[18]. 따라서 본 연구에서는 데이터센터 냉방 에너지 저감을 위한 최적 냉매 유량 제어 알고리즘 개발을 목표로 한다.

2. 데이터센터 개요

2.1. 데이터센터 개요

데이터센터는 서버 운영을 위한 IT 장비 및 소방, 전기, 보안 시설 등을 한 장소로 모은 시설을 의미한다. 서버는 랙(Rack)에 집적되어 관리되며 하나의 랙은 일반적으로 4~6 kW의 전력을 사용한다. 최근 IT 장비의 고밀화에 따라 2016년에는 12 kW/rack에 도달하였고 2020년에는 16.5 kW/rack에 도달할 것으로 예상된다. 이에 데이터센터 냉각 시스템 또한 그 중요성이 더욱 부각되고 있으며 과열점(Hot Spot)을 최소화하고 고밀도서버 부하를 감당 할 수 있는 CRAC(Computer Room Air Conditioning) 유닛에 대한 개발이 이루어지고 있다[19].

데이터센터는 랙의 배치 및 차폐 유무에 따라 전산실 개방형, 컨테이너, 모듈러 형태로 구분된다. 전산실 개방형은 별도의 차폐 구조 없이 랙이 나열되어 있는 형태이며 다수의 향온향습기가 전산실 전체를 냉각한다. 컨테이너는 랙의 전면부 혹은 후면부를 마주 보도록 배치하여 냉복도(Cold Aisle), 열복도(Hot Aisle) 혹은 모두를 차폐해 냉방의 효율을 극대화 한 구조이다. CRAC 및 전력 유닛이 컨테이너 내부에 포함된다. 모듈러는 IT 장비를 운용하기 위한 일련의 설비가 하나의 모듈 안에 집약된 형태이며 확장성 및 이동성의 장점이 있다.

본 연구에서는 냉복도 및 열복도가 모두 차폐된 컨테이너 구조를 대상으로 하며 컨테이너 내부의 최적 열환경 제공을 목표로 한다. 컨테이너 내부의 랙에서 배출되는 공기는 서버의 발열량에 따라 풍량이 변화하며 이는 CRAC으로 회수된다. CRAC은 회수된 공기를 설정 온도에 맞추어 재배출하며 이 공기는 외부 공기의 유입 없

이 컨테이너 내부에서 순환한다. 공급 공기의 온도 조절은 냉매 유량 조절을 통한 열교환에 의해 이루어진다.

2.2. 데이터센터 컨테이너 시뮬레이션 모델링

데이터센터 컨테이너 모델링은 ANSYS의 Fluent CFD 프로그램을 사용하여 총 2가지로 진행되었다. 모델 A는 일반적인 데이터센터 컨테이너를 모델링 한 것이며 실내 환경 동향 파악 및 냉매 유량 예측 모델의 학습 데이터 취득으로 활용된다. 모델 B는 개발된 냉매 유량 예측 모델의 적응성을 평가하기 위하여 랙의 개수에 변화를 주어 모델A와 상이한 실내 환경을 조성한 모델이다. 두 모델의 개요는 Table 1., Table 2.와 같다.

모델 A와 B는 랙의 후면을 공유하는 열복도형 컨테이너로 구성되었으며 각각 4개의 랙과 2개의 랙을 가진다. 컨테이너 내부의 공기는 냉복도와 열복도가 모두 밀폐되어 외부 공기와 혼합이 이루어지지 않아 외피조건의 경우 침기가 이루어지지 않고 완전 단열이 되는 것으로 가정한다. CRAC은 랙의 옆에 배치되고 개구부는 280mm × 840mm로 설정하였다. 서버 풍량은 IT 부하에 따라 2단계로 조절된다고 가정한다. 저속일 때는 0.0361 kg/s의 풍량이, 고속일 때는 0.0597 kg/s의 풍량이 랙의 후면으로 배출된다. 해당 풍량은 통상적인 데이터센터 온도분포에 따라 냉복도와 열복도의 온도차가 10~12 °C가 되도록 산출하였다. 서버의 발열량이 증가하면 배출 풍량이 증가하며 이에 따라 CRAC의 총 풍량은 회수되는 풍량의 합과 동일하도록 설정한다.

Table 1. Data Center Containment Model A

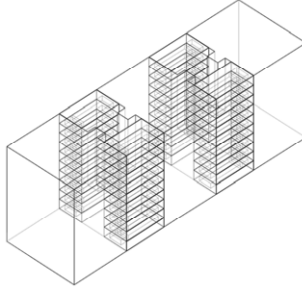
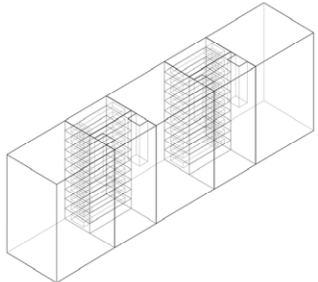
Figure of Model A		
		
Properties of Model A		
Containment Scale		1.8 m(L) × 6.2 m(W) × 2 m(H)
Rack	Number of Rack	4 EA/containment
	Number of Server	10 EA/rack
	Heat Value	4 kW/rack (Low IT Load) 6.6 kW/rack (High IT Load)
Interior Environment	Setpoint Temperature	24 °C
	Relative Humidity	50%
CRAC	Supply Air Temperature	24 °C
	Supply Air Flow Rate	0.722 kg/s

Table 2. Data Center Containment Model B

Figure of Model B		
		
Properties of Model B		
Containment Scale		1.2 m(L)×6.2 m(W)×2 m(H)
Rack	Number of Rack	2 EA/containment
	Number of Server	10 EA/rack
	Heat Value	4 kW/rack (Low IT Load) 6.6 kW/rack (High IT Load)
Interior Environment	Setpoint Temperature	24 °C
	Relative Humidity	50%
CRAC	Supply Air Temperature	24 °C
	Supply Air Flow Rate	0.361 kg/s

구축된 모델의 타당성을 평가하기 위하여 모델 A는 모든 서버가 저속에서 고속으로 변화하는 41가지의 경우, 모델 B는 21가지 경우에 대해 시뮬레이션을 시행하였다. 그 결과 Fig. 1.과 같이 공급 온도 24 °C 기준, 열복도의 온도가 34~36 °C 범위에 분포하는 모습을 확인할 수 있었다.




Fig. 1. Validation of data center models

3. 예측 모델 및 적응형 제어 알고리즘 개발

3.1. 인공신경망 및 딥러닝 개요

머신러닝은 기계가 알고리즘을 통해 데이터를 분석하고 이를 통해 일련의 규칙을 찾아내는 학습의 과정을 거친다. 학습된 모델은 새로운 데이터가 주입 되었을 시 이를 예측 및 판단하여 결과를 출력하며 추가되는 데이터로부터 스스로를 수정하는 동적인 특성을 가진다. 또한 학습되는 데이터의 규모가 클수록 불안정성이 감소한다 [20].

머신러닝은 크게 지도 학습(Supervised Learning)과 비지도 학습(Unsupervised Learning)으로 구분된다. 지도 학습은 입력되는 데이터에 정답이 포함되어 있으며, 선형 회귀, 로지스틱 회귀, 서포트 벡터 머신, 인공신경망 등이 이에 포함된다. 비지도 학습은 입력되는 데이터에 정답이 포함되어 있지 않으며, 클러스터링, 시각화와 차원 축소, 연관 규칙 학습이 있다[21].

1943년 Warren McCulloch와 Walter Pitts에 의해 처음 고안된 인공신경망(Neural Network)은 인간의 뇌신경망을 모사한 시스템으로써 입력층(Input Layer), 숨겨진층(Hidden Layer), 출력층(Output Layer)으로 구성된다. 숨겨진층의 개수가 많아질수록 인공신경망이 깊어졌다고 하며 이러한 구조로 학습을 진행하는 것을 딥러닝(Deep Learning)이라고 한다. 각 층의 뉴런(Neuron)은 주어지는 입력 값에 대해 가중치를 곱하고 활성화 함수(Activation Function)를 거쳐 임계값을 넘으면 값을 출력한다. 이 가중치는 역전파(Back Propagation) 과정을 통해 오차를 최소화 하는 방향으로 업데이트를 진행하며 반복을 통해 최적화가 이루어진다.

딥러닝은 다양한 분야에 적용되고 있다. 대표적으로 IT, 광고, 자동차, 서비스업 등이 있으며 건축 환경 분야에서는 제로에너지빌딩 이슈로 인해 공조, 열환경, 냉난방제어, 에너지 효율과 관련된 연구가 활발히 진행되고 있다. HVAC 시스템의 부하 예측을 통한 건물 에너지 절약에 대한 가능성 검토[22], 빅데이터를 기반으로 개별 건물의 속성, 환경 영향 분석 및 운영 시스템의 효율 등의 분석을 통한 에너지 수요 및 공급을 예측하는 시스템 개발[23] 등 주로 건축물 에너지 성능향상에 연구가 집중되어 있다.

데이터센터의 열환경은 다양한 환경 변수들이 독립 변수로 작용하며 지속적으로 변동하는 IT 부하로 인해 특정 상황을 규정 짓는 것이 어렵다. 따라서 본 연구에서는 딥러닝을 활용한 냉매 유량 예측 모델을 개발하여 다양한 환경에 대한 자가 학습을 통해 최적 열환경을 제공하고자 한다.

3.2. 모델 학습을 위한 데이터 구성

냉매 유량 예측 모델은 다양한 환경 변수를 입력 받아 최적의 냉매 유량을 도출한다. 입력 데이터는 설정 온도(Setpoint Temperature), 급기 온도(Supply Air Temperature), 회수 온도(Return Air Temperature), 회수 풍량(Return Air Flow Rate)으로 구성되며 출력 데이터는 냉매 유량(Refrigerant Flow Rate)으로 정의하였다. 각 요소는 (식 1)로부터 도출되었다.

$$Q = m_{air} \cdot c \cdot (T_{RA} - T_{SET}) = m_{ref} (h_{gas} - h_{liquid}) \quad (식 1)$$

여기서, m_{air} 와 m_{ref} 는 각각 공기, 냉매의 유량(kg/hr)이고 T_{RA} 와 T_{SET} 은 회수 공기 온도와 설정 온도(°C)이다. h_{gas} 와 h_{liquid} 는 냉매의 기체, 액체 상태의 엔탈피(kcal/kg)이며 Q 는 T_{RA} 가 T_{SET} 에 도달하기 위해 제거되어야 할 열량이다. 공기 비열 c 는 0.24 kcal/kg으로 고정 값이다. 냉매는 R134a를 사용하며 20 °C의 일정한 온도로 공급될 때 상변화에 의한 열교환만 이루어진다고 가정한다. 이때 엔탈피 차이는 43.57 kcal/kg으로 고정 값이다.

데이터 취득은 모델A의 CFD 시뮬레이션을 통하여 이루어졌다. ASHRAE (The American Society of Heating, Refrigerating and Air-Conditioning Engineers)에서 제시하는 데이터센터 권장 온도는 18~27 °C이며 이에 따라 설정 온도는 1°C씩 증가시켜 총 10가지로 설정하였다. 급기 온도 또한 같은 범위로 설정하였으며 이에 따라 CRAC의 회수 온도가 결정된다. 이를 다시 41가지 풍량의 경우의 수로 세분화 하고 한 가지 경우에 대해 10회의 시뮬레이션을 시행하였다.

급기 온도, 회수 온도, CRAC 토출부의 평균값을 사용하였으며 회수 풍량은 CRAC 회수부의 총 합으로 산정하였다. 모든 데이터는 전처리 과정을 거쳐 온도는 °C, 풍량은 kg/hr로 단위를 변경하였으며 정규화를 통하여 0과 1사이의 값을 가지도록 구성하였다. 최종 데이터셋 형태는 Fig. 2.와 같다.




Fig. 2. Data Set Composition for Developing ANN Model

3.3. 냉매 유량 예측 모델 개발

냉매 유량 예측모델을 개발한 후 이를 포함하여 적응형 제어 알고리즘을 개발하였다. 모델들은 Python과 Tensorflow를 이용하여 개발되었다. 전처리가 완료된 데이터셋에서 셔플 기능을 통해 90%는 학습 데이터(Train Data), 10%는 테스트 데이터(Test Data)로 분류하였다. 학습은 AdamOptimizer에 의해 Cost값을 최소화 하는 방식으로 진행되었으며 이때의 Learning Rate는 0.001로, 학습 횟수(Epoch)는 100회로 설정하였다. 뉴런의 활성화 함수로는 ReLu (Rectified Linear Unit)함수가 사용되었다. 기본 모델은 4개의 입력 뉴런, 9개의 숨겨진 뉴런과 1개의 출력 뉴런으로 구성되어 있으며 Fig. 3.과 같다.

학습된 모델의 정확도는 테스트 데이터의 입력 값에 대한 정답과 예측 값 간의 오차를 비교하였다. CVMSE (Coefficient of Variation of the Root mean Square Error)는 ASHRAE에서 실측데이터와 시뮬레이션 결과 값을 비교·평가하는 통계적 기준 중 하나로서 30% 이하를 적정기준으로 제시하고 있다.

값이 낮을 수록 정확도가 높음을 의미하며 본 모델은 CVMSE로 정확도를 측정 하였다. 그 결과 CVMSE 1.05%로 매우 높은 정확도를 나타냈다. 개발된 모델은 숨겨진 층과 숨겨진 뉴런의 수를 변

경하여 최적화를 진행한 후 사용된다.




Fig. 3. Structure of Optimized ANN Model

3.4. 적응형 제어 알고리즘 개발

일반적인 제어 시스템은 특정 상황 및 설비에 대해서 최적화가 되어 있으며 새로운 시스템에 해당 제어 시스템을 적용하였을 시에는 정확도가 떨어진다. 따라서 본 연구에서의 알고리즘은 자가 학습을 통해 새로운 환경에서도 최적 방안을 도출 할 수 있도록 적응형 알고리즘으로 개발되었다.

Fig. 4.는 냉매 유량 예측 모델이 새로운 데이터로 학습을 하는 과정을 보여준다. 환경 변수 $T_{SET(n)}$, $T_{SA(n)}$, $T_{RA(n)}$, $m_{air(n)}$ 은 각각 n번째 제어 사이클의 설정온도, 급기 온도, 회수 온도, 회수 풍량을 의미하여 m_{pred} 는 얻어진 데이터로부터 예측된 냉매 유량, m_{fixed} 는 최적 유량 도출 식인 (식 2)에 의해 보정된 냉매 유량이다.

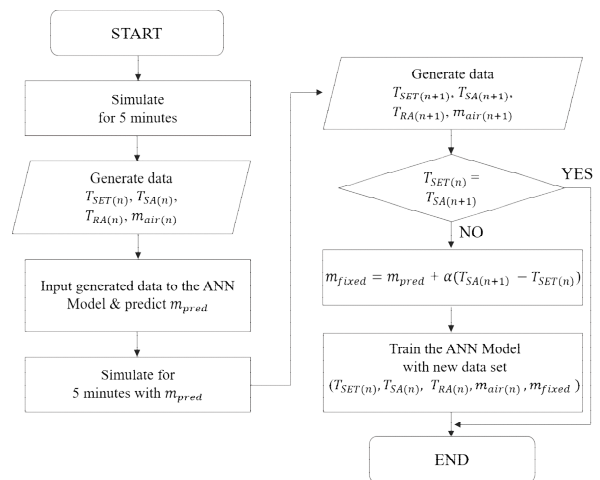


Fig. 4. Process of Adaptive Algorithm

$$m_{fixed} = m_{pred} + \alpha (T_{SA(n+1)} - T_{SET(n)}) \quad (식 2)$$

시뮬레이션으로 도출된 n번째 제어 사이클의 환경 변수는 냉매 유량 예측모델에 투입되며 도출된 냉매 유량 m_{pred} 은 다음 제어 사이클을 위한 변수로 작동한다. $T_{RA(n)}$ 은 m_{pred} 를 통해 $T_{SA(n+1)}$ 로 변화하여 다음 사이클을 위한 시뮬레이션이 진행된다. n+1번째 사이클에서 $T_{SA(n+1)}$ 는 $T_{SET(n)}$ 과 비교되어 온도가 동일할 시에는 시뮬레이션을 반복 운영한다. 온도가 같이 않을 시에는 m_{fixed} 를 도출

하여 n번째 사이클의 환경 변수와 함께 냉매 유량 예측모델을 학습한다. 이때 (식 2)에서의 α 는 상수로써 보정 인자로 작용하며 $T_{SA(n+1)}$ 와 $T_{SET(n)}$ 의 오차에 비례하여 m_{pred} 를 수정한다. 새로 학습된 모델은 다시 시뮬레이션에 사용되며 적응형 제어 알고리즘을 통해 지속적으로 수정된다.

4. 결과분석

냉매 유량 예측 모델의 최적화는 숨겨진 층과 숨겨진 뉴런의 수를 변경하여 최소의 CVRMSE를 갖도록 진행하였으며 결과는 Table 3과 같다. 숨겨진 층 1~5개, 숨겨진 뉴런 6~12개로 다양화 하여 최적화를 진행하였으며 숨겨진 층이 4개, 숨겨진 뉴런이 11개일 때 CVRMSE 0.47%로 가능 높은 정확도를 나타냈다. 숨겨진 층의 수가 5개 이상일 때는 Cost값이 수렴하지 않았으며 이는 데이터들의 관계에 비해 모델이 너무 복잡해진 것을 의미한다.

Table 3. ANN Model Optimization Result (%)

HN \ HL	1	2	3	4	5
6	2.44	2.08	1.55	0.94	-
7	0.91	0.61	0.51	0.79	-
8	2.64	1.24	0.89	1.00	-
9	1.05	0.80	0.66	1.64	-
10	1.07	2.18	0.50	0.91	-
11	2.57	1.41	0.50	0.47	-
12	2.54	0.62	0.75	-	-

* HL: Hidden Layer, HN: Hidden Neuron

최적화된 모델은 적응형 제어 알고리즘 모델에 사용되었다. 적응형 제어 알고리즘은 α 에 의하여 모델이 수정되며 실험 대상인 모델

B에 적합하도록 최적화를 진행하였다. 시뮬레이션은 24 °C로 운영되던 시스템의 설정온도를 20 °C로 변경했으며 매 5분마다 데이터를 취득하였다. α 는 1.0~2.0까지 0.2씩 증가시켰고 결과는 Fig. 5와 같다.

α 가 증가함에 따라 급기 온도 또한 증가하는 모습을 보였다. 이는 모델A와 다른 환경을 가진 모델B에 대하여 유량의 보정 값이 필요했다는 것을 의미한다. 모든 α 의 경우에 대해 대체적으로 잘 적응하는 모습을 보였으나 최종 데이터 취득 시간을 기준으로 했을 시 $\alpha = 1.8$ 일 때 시스템의 급기 온도는 20.02 °C로 설정온도에 가장 근접한 모습을 나타냈다.

냉매 유량 예측 모델의 적응성 실험을 위하여 모델B에서 환경 변수를 변경하여 시뮬레이션을 진행하였으며 결과는 Fig. 6과 같다. 풍량은 매 5분마다 임의로 서버대수 기준 0개, 5개, 4개, 9개, 13개, 7개, 10개, 10개, 3개, 8개, 15개, 15개를 고속으로 변경하였으며 설정온도는 24 °C에서 시작하여 첫 5분에 20°C로 변경하였고 이후 370분에 25 °C로 변경하였다. 설정온도 20°C에서 설정온도에 도달하는 시간은 15분, 즉 3번의 제어 사이클이었으며 과도응답에서 최소 온도 16.08 °C로 19.6%의 오차를 나타내며 설정온도에 적응하였다.

설정온도를 20°C에서 25°C로 변경하였을 때 첫 제어 사이클에서는 토출온도가 24.27°C에 도달하였으나 이후 10번의 제어 사이클 동안 감소하고 이후 증가하는 모습을 나타냈다. 과도응답에서 최저 온도는 20.47°C였으며 이때 설정온도 대비 오차는 18.12%였다. 최초로 설정온도에 도달하는 시간은 설정온도 변경 시간 기준으로 100분 후였으며 이는 20 제어 사이클에 해당된다. 이후 최대 온도 26.38 °C인 5.52% 오차로 오버슈트 현상을 나타낸 후 설정온도에 적응하는 모습을 나타냈다. 설정온도가 24°C에서 20°C로, 20°C에서 25°C로 변경되었을 때 공통적으로 토출온도가 급격하게 하강하였




Fig. 5. Optimization Process of ANN Model by Model B




Fig. 6. Adaptation Process of Adaptive Control Algorithm

다. 이는 큰 폭의 설정온도와 풍량 변화의 영향과 모델A에 의해 학습이 이루어진 예측모델이 모델B의 상이한 환경 변수의 조합을 입력으로 받았기 때문인 것으로 판단되며, 모델B에 대한 예측모델의 학습 시간이 추가적으로 필요한 것으로 사료된다.

5. 결론

본 연구는 데이터센터 최적 열환경 제공을 위하여 적응형 냉매 유량 예측모델 개발 및 성능평가를 목적으로 하였다. 데이터 취득 및 예측 모델의 적응성 평가를 위하여 CFD 시뮬레이션을 통해 2가지 컨테이너형 데이터센터를 모델링하였다. 적응형 냉매 유량 예측 모델의 개발과정 및 성능평가 결과는 다음과 같다.

- (1) 냉매 유량 예측모델의 학습에는 설정온도, 급기 온도, 회수 온도, 회수 풍량, 냉매 유량이 사용되었다. 학습된 모델의 예측 값은 정답 대비 CVRME 1.05%로 정확도가 매우 높았으며 최적화 결과 CVRME 0.47%의 숨겨진 층 4개, 숨겨진 뉴런 11개의 구조가 최종 모델로 채택되었다.
- (2) 적응형 제어 알고리즘은 개발된 냉매 유량 예측모델에 보정 인자를 추가하여 다양한 환경의 데이터센터에 적용하더라도 적용할 수 있도록 구축하였으며 모델B를 통해 성능평가를 실시하였다. 그 결과 설정온도 20 °C의 경우 과도응답에서 최저 온도 16.08°C로 19.6%의 오차를 나타냈고 설정온도 25 °C의 경우 과도응답에서 최저온도 20.47 °C로 18.12%의 오차를 나타냈다. 정상상태에서는 모든 경우에서 설정온도에 근접한 결과가 나오는 것을 확인하였다. 과도응답에서의 오차는 예측모델이 새로운 환경에 대해 학습이 진행되지 않은 상태이기 때문인 것으로 판단되며 추가적인 학습을 통해 더 빠른 응답과 적은 오차를 보일 것으로 사료된다.

추후 연구로는 기존 제어방식인 ON/OFF 제어와 PID 제어기와

의 비교를 통하여 성능평가를 진행할 예정이며 실제 데이터센터 컨테이너 모델에 적용하여 장시간 학습을 통한 적응성 평가를 실시할 예정이다.

Acknowledgement

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 20182010600010).

Reference

- [1] George Kamiya, Data centres and data transmission networks, <https://www.iea.org/tcep/buildings/datacentres/>, 2019.10.28.
- [2] Whitehead, B., et al., Assessing the environmental impact of data centres Part 1: Background, energy use and metrics, Building and Environment, Vol.82, 2014, pp.151-159.
- [3] X. Song, X. Zhang, C. Eriksson, Data center energy and cost saving evaluation, Energy Procedia, Vol.75, 2015, pp.1255-1260.
- [4] 최인식, [HVAC Korea] 데이터센터 냉각 트렌드, <https://www.kharn.kr/news/article.html?no=9902>, 2019.11.04. // (Choi, In Sik, [HVAC Korea] Trends of Data Center Cooling Systems, <https://www.kharn.kr/news/article.html?no=9902>, 2019.11.04.)
- [5] 조진균, 정차수, 김병선, 최적 IT 환경제어를 위한 데이터센터의 냉각(열원)시스템 선정에 관한 연구, 대한건축학회 논문집 - 계획계, 24(12), 2008, pp.313-320. // (Cho Jin-kyun, Jeong Cha-Su, Kim Byung-Seon, The Planning and Design of the Optimal Cooling System for IT Environments in (Internet) Data Centers, Journal of the Architectural Institute of Korea Planning & Design, 24(12), 2008, pp.313-320.)
- [6] 조진균, 차지형, 홍민호, 연창근, 데이터센터의 합리적인 환경제어를 위한 공기분배 시스템에 대한 연구, 대한설비공학회 학술발표대회논문집, 2008, pp.487-492. // (Jin-kyun Cho, Ji-hyoung Cha, Min-ho Hong, Chang-kun Yeon, A Study on Air-distribution method for the Thermal Environmental Control in the Data Center, Conference Journal of Air-Conditioning and Refrigeration Engineering, 2008, pp.487-492.)
- [7] 박병운, 정용호, 가변풍량제어시스템과 냉복도밀폐시스템의 적용에 의한 데이터센터의 냉방에너지 절감 효과 분석, 한국건축환경설비학회

- 논문집, 7(3), 2013, pp.185-192. // (Park Byung-Yoon, Jung Yong-Ho, Analysis of Cooling Energy Saving by Variable Air Volume System and Cold Aisle Containment System in Internet Data Center, Journal of Korean Institute of Architectural Sustainable Environment and Building Systems, 7(3), 2013, pp.185-192.)
- [8] 함상우, 김민휘, 윤동섭, 정재원, 컨테이너먼트가 적용된 모듈러 데이터 센터의 구조 팬 제어 방안에 관한 실험적 연구, 대한건축학회 학술발표대회 논문집, 34(2), 2014, pp.285-286. // (Ham, Sang-Woo, Kim, Min-Hwi, Yoon, Dong-Seob, Jeong, Jae-Woen, An experimental study on the fan control of computer room air handler in a modular data center with cold-aisle containment, Architectural Institute of Korea, Conference Journal of Architectural Institute of Korea, 34(2), 2014, pp.285-286.)
- [9] Jinzhu Chen, et al., A High-Fidelity Temperature Distribution Forecasting System for Data Centers, 2012 IEEE 33rd Real-Time Systems Symposium, 2012.
- [10] Mengxuan Song, Kai Chen, Jun Wang, Numerical Study on the Optimized Control of CRACs in a Data Center Based on a Fast Temperature-Predicting Model, Journal of Energy Engineering, 143(5), 2017.
- [11] Alessandro Beghi, et al., Modelling and control of a free cooling system for Data Centers, Energy Procedia, Vol. 140, 2017, pp.447-457.
- [12] Zhihang Song, Bruce T. Murray, Bahgat Sammakia, Airflow and temperature distribution optimization in data centers using artificial neural networks, International Journal of Heat and Mass Transfer, Vol. 64, 2013, pp.80-90.
- [13] Masaki Ogura, Jianxiong Wan, Shoji Kasahara, Model Predictive Control for Energy-Efficient Operations of Data Centers with Cold Aisle Containments, IFAC-PapersOnLine, Vol. 51, 2018, pp.209-214.
- [14] Xiaogang Zhao, et al., A smart coordinated temperature feedback controller for energy-efficient data centers, Future Generation Computer Systems, Vol. 93, 2019, 506-514.
- [15] Marina Zapater, et al., Leakage and temperature aware server control for improving energy efficiency in data centers, 2013 Design, Automaton & Test in Europe Conference & Exhibition, 2013.
- [16] Baptiste Durand-Estebe, Cedric Le Bot, Jean Nicolas Mancos, Eric Arquis, Simulation of a temperature adaptive control strategy for an IWSE economizer in a data center, Applied Energy, Vol. 134, 2014, pp.45-56.
- [17] Jinzhu Chen, Rui Tan, Guoliang Xing, Xiaorui Wang, PTEC: A System for Predictive Thermal and Energy Control in Data Centers, 2014 IEEE Real-Time Systems Symposium, 2015.
- [18] Paric, What is VRF System?, <https://www.refrigerationglobaltech.com/info/commercial-air-conditioning-26008583.html>, 2019.11.06.
- [19] Delta, 증가하는 랙 전력 밀도에 대비하는 데이터 센터 전력 및 냉각 전략, <https://www.deltapowersolutions.com/ko-kr/mcis/technical-article-data-center-power-and-cooling-strategies-for-increasing-rack-power-density.php>, 2019.10.31. // (Delta, Strategies for Data Center Power and Cooling System Preparing for Increasing Rack IT Load, <https://www.deltapowersolutions.com/ko-kr/mcis/technical-article-data-center-power-and-cooling-strategies-for-increasing-rack-power-density.php>, 2019.10.31.)
- [20] McCulloch, W. S., Pitts, W., A logical calculus of the ideas immanent in nervous activity, The bulletin of mathematical biophysics, 5(4), 1943, pp.115-133.
- [21] Aurelien Geron, Hands-On Machine Learning with Scikit-Learn and TensorFlow, United States of America: O'REILLY, 2017, pp.7-12.
- [22] Javier Rubio-Herrero, et al., A Learning Framework for Control-Oriented Modeling of Buildings, 2017 16th IEEE International Conference on Machine Learning and Applications(ICMLA), 2017.
- [23] 안주현, 이우영, 정대수, 이형진, 제로에너지 타운을 위한 딥러닝 에너지 수요/공급 예측 시스템 설계, 2018년도 한국통신학회 하계종합학술발표회 논문집, 2018, pp.573-574. // (Joohyun Ahn, Wooyoung Lee, Dae-su Chung, Hyungjin Lee, A Design of Deep Learning energy demand/supply prediction isystem for Zero Energy Town, Proceedings of Symposium of the Korean Institute of communications and Information Sciences, 2018, pp.573-574.)