



## 데이터센터 열환경 예측 및 적응형 제어알고리즘 개발

### *Development of a Prediction Model and an Adaptive Control Algorithm for the Data Center Thermal Environment*

조지현\* · 최윤경\*\* · 박보람\*\*\* · 최영재\*\*\*\* · 문진우\*\*\*\*\*

Ji Hyeon Cho\* · Yoon Kyung Choi\*\* · Bo Rang Park\*\*\* · Young Jae Choi\*\*\*\* · Jin Woo Moon\*\*\*\*\*

\* Main author, Graduate Student, School of Architecture and Building Science, Chung-Ang Univ., South Korea (selmainger326@gmail.com)

\*\* Coauthor, Professor, School of Architecture and Building Science, Chung-Ang Univ., South Korea (ykc@cau.ac.kr)

\*\*\* Coauthor, Graduate Student, School of Architecture and Building Science, Chung-Ang Univ., South Korea (pbr\_1123@naver.com)

\*\*\*\* Coauthor, Graduate Student, School of Architecture and Building Science, Chung-Ang Univ., South Korea (chlyoungwo@gmail.com)

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

#### ABSTRACT

**Purpose:** As cooling energy accounts for 50.5% of the data center total energy use, it is necessary to reduce cooling energy with optimal control method. Thus, this study aimed at developing an adaptive control algorithm for data center thermal environment based on Artificial Neural Network (ANN). **Method:** A data center thermal environment model was built to obtain variable data which is used to train and evaluate performance of the prediction model and algorithm. The thermal environment prediction model was developed using ANN and optimization process was conducted by the Bayesian Optimization Algorithm. The adaptive control algorithm, which embedded the prediction model, adopted the Sliding Windows method and was optimized to maximize the control performance. **Result:** The performance evaluation of the developed algorithm was conducted compared with non-adaptive algorithm. As a result, the adaptive algorithm presented better performance than the non-adaptive with 0.45 of RMSE. Therefore, the developed algorithm secured the stability and accuracy and will be applied to supervisory control platforms.

#### KEYWORD

데이터센터  
인공신경망  
적응형 제어알고리즘

Data Center  
Artificial Neural Network  
Adaptive Control Algorithm

#### ACCEPTANCE INFO

Received Nov. 16, 2020

Final revision received Nov. 19, 2020

Accepted Nov. 24, 2020

© 2020. KIEAE all rights reserved.

## 1. 서론

### 1.1. 연구 배경 및 목적

전 세계 전력 소비량의 1%를 차지하는 데이터센터의 전력 소비량은 IT 이용 증대로 인해 2030년에는 3~13%로 증가 될 것으로 예측되고 있어 데이터센터의 에너지소비량 절감은 필수적이다. 데이터센터의 전체 전력소비량 중 약 50%를 차지하고 있는 부문은 냉방 에너지로 이의 절감을 위한 시스템 개발, 에너지 관리 등의 연구가 활발히 진행되고 있다[1][2].

최근 기존 데이터센터 에너지절감을 위해 기존 개방형 배치 방식인 Room-Based 및 Rack-Based 방식의 단점을 보완한 In-Row 컨테이너먼트(Containment)의 사용이 증가하고 있는 추세이다[3]. 또한, 데이터센터 특성상 무중단운영, 설비 기기교체의 어려움 등으로 소프트웨어적 제어에 관심이 증가되고 있다.

Choi et al. (2020)에 따르면 최근 데이터센터 내 냉방 에너지 절감을 위한 시스템 개발, 에너지 관리 및 냉각 시스템 제어 등의 연구가 국내외로 활발히 진행되고 있다[4]. 데이터센터 및 HVAC 제어에 딥러닝(Deep Learning), 머신러닝(Machine Learning) 및 퍼지 제어(Fuzzy Control) 등 지능형 모델을 활용한 사례는 점차 증가하는 추세로 나타났다. 지능형 모델은 복잡한 수식에 의한 설계가 필요

하지 않고 Data-Driven 모델로써 입출력 데이터의 획득 및 학습에 따라 간편하게 예측을 실시할 수 있다는 장점이 있다[5]. 지능형 모델을 포함한 제어 방식은 실시간으로 학습에 따라 높은 정확도 확보에 용이한 장점이 있으며 어려운 프로그래밍이 필요 없이 양질의 데이터만으로도 높은 예측성능을 발휘할 수 있다.

따라서 본 연구에서는 In-Row 방식을 채택한 컨테이너먼트형 데이터센터의 실시간 최적 냉수 유량 제어를 위하여 기존 연구에서 개발된 예측모델을 기반으로 최적 적응형 제어알고리즘을 개발하고자 한다.

### 1.2. 연구 방법 및 범위

본 연구는 데이터센터 열환경의 적응형 제어알고리즘 개발을 목적으로 한다. 연구의 방법 및 절차는 다음과 같다.

첫째, 기초연구로써 데이터센터 열환경 제어와 관련된 문제점 파악을 위한 선행연구 분석을 실시한다.

둘째, 냉동기 냉수 유량에 따른 다양한 환경 변수 데이터 확보를 위해 열역학 법칙에 근거한 데이터센터 수직식 모델을 구축한다.

셋째, 데이터 획득 후 ANN을 활용하여 초기 예측모델을 개발하였으며 일반화 성능 개선을 위한 최적화를 실시한다.

넷째, 초기 제어알고리즘은 최적화가 완료된 열환경 예측모델을 포함한 비적응형 제어알고리즘으로 설계되었다. 이때 적응형 제어알고리즘의 제어성능을 검증하기 위하여 초기 알고리즘의 제어성능

및 외란(Disturbance)에 대한 안정성을 분석하였다. 외란은 시스템 플랜트에 삽입되는 잡음 혹은 불필요한 영향을 의미한다. 본 연구에서는 외란이 4°C에 근사한 난수값으로 CRAH 급기온도에 추가되는 것으로 가정하였다.

마지막으로, 최적 열환경 예측모델이 포함된 적응형 제어알고리즘을 개발하고 제어성능 개선을 위하여 학습 알고리즘의 초매개변수에 따른 제어성능을 최적화한다.

## 2. 선행연구 분석

최근 10년간(2010~2019) 데이터센터 연구 조사를 위해 Google Scholar, ScienceDirect에서 '데이터센터(Data Center)', '냉각(Cooling)', '예측제어(Model Predictive Control)' 등의 키워드를 통해 관련 선행연구 논문 총 16건이 검색되었으며 상세한 분석내용은 Table 1.과 같다.

국내 연구 논문을 조사한 결과 데이터센터의 냉각 시스템 개발 관련 논문은 전체 6건 중 4건이 해당되었으며 2건의 경우 예측제어와 관련된 것으로 조사되었다. 대다수 선행연구는 이코노마이저(Economizer) 등을 활용한 외기 공급 시스템 개발 및 에너지 효율 개선에 집중되어 있었다. 따라서 데이터센터 열환경 제어 및 통합적 관리에 대한 연구가 진행되어야 할 것으로 사료된다.

반면 국외 논문 10건 중 4건은 에너지 절감 및 효율 향상에 관한 논문으로 나타났으며 나머지 6건은 예측제어에 관한 연구로 나타났다. 기존의 예측제어는 플랜트 및 환경, 제어시스템을 수식적으로 모사한 예측모델과 제어알고리즘을 기반으로 실시되었다. 인공지능의 개발에 따라 국외에서는 지능형 모델을 포함한 제어알고리즘을 데이터센터 열환경 제어에 활발히 사용하고 있었다. 데이터센터의 열환경 제어가 Hard Control 중심에서 Soft Control, Hybrid Control을 시도하는 연구가 증가하는 추세로 확인되었으며 이러한 접근이 에너지 절감 및 안정적 열환경 제공에 우수한 성능을 보이는 것으로 나타났다. 그러나 다양한 데이터센터에 적용 가능한 알고리즘 개발과 실시간 안정성 확보에는 한계가 있었다.

선행연구 조사 및 분석결과 국외는 지능형 모델을 활용한 데이터센터 제어 연구가 점진적 증가하고 있는 추세이나 국내의 경우 지능형 모델을 포함한 제어가 활발히 시도되고 있으나 실시간 보정 및 자가튜닝(Self-Tuning)에 대한 연구는 미비한 것으로 나타났다. 따라서 데이터센터의 에너지 절감 및 효율적 운영을 위한 지능형 제어의 실시간 튜닝 등에 대한 연구가 추가적으로 진행되어야 할 것으로 판단된다.

Table 1. The Analysis of Prior Research Articles

| Category       | Author        | Content  |
|----------------|---------------|--|
| Cooling System | Lee et al.[6] | <ul style="list-style-type: none"> <li>• Economizer improvement for reducing cooling energy of data center</li> <li>• 7% of cooling energy is reduced by improved system.</li> </ul> |
|                | Kim et al.[7] | <ul style="list-style-type: none"> <li>• Applicability analysis of drying-evaporative cooling system</li> <li>• When hot water cooling and drying</li> </ul>                         |

| Category                 | Author                   | Content   |
|--------------------------|--------------------------|---|
| Cooling System           |                          | system is applied, the data center consumes 1.3 PUE less 0.5 PUE than CRAC.   |
|                          | Yoon et al.[8]           | <ul style="list-style-type: none"> <li>• Power reducing effect analysis on cold water and air economizer in a data center</li> <li>• cold water and air economizer reduced 15% of origin energy in data center.</li> </ul>  |
|                          | Kim et al.[9]            | <ul style="list-style-type: none"> <li>• MLC (Mechanical Load Component) analysis on Central chiller with an economizer according to a change of CRAH setpoint and air flow rate</li> <li>• The more air flow rate of CRAH is reduced, the more energy is reduced.</li> </ul>             |
|                          | Zhang et al.[10]         | <ul style="list-style-type: none"> <li>• Study on infrastructure management of air-cooled and water-cooled chiller</li> <li>• Hybrid solution can improve energy performance of a data center cooling</li> </ul>  |
|                          | Darehmeh et al.[11]      | <ul style="list-style-type: none"> <li>• An advantage and disadvantage analysis about outdoor air cooling including Heat pipe and an airside &amp; waterside economizer</li> <li>• Pulsating heat pipes (PHPs) was the most effective to outdoor air cooling of a data center.</li> </ul> |
| Cooling Energy           | Chen et al.[12]          | <ul style="list-style-type: none"> <li>• Building and integrative system of an IT equipment and cooling system management</li> <li>• 35% of energy consumption of IT equipment and 15% of cooling energy is reduced</li> </ul>  |
| Model Predictive Control | DengLiu et al.[13]       | <ul style="list-style-type: none"> <li>• Development of PID type Fuzzy Adaptive control which is available to auto-tuning PID coefficients.</li> <li>• That control method stably controls cooling system of data center.</li> </ul>  |
|                          | Gao[14]                  | <ul style="list-style-type: none"> <li>• PUE prediction based on Machine-Learning feed-forward model</li> <li>• Machine-Learning model presents better performance on prediction error</li> </ul>   |
|                          | Zapater et al.[15]       | <ul style="list-style-type: none"> <li>• Prediction model to thermal Environment is developed on Grammatical Evolution (GE) algorithm.</li> <li>• GE presents high performance on temperature error of CPU and server entry.</li> </ul>   |
|                          | Beghi et al.[16]         | <ul style="list-style-type: none"> <li>• Development of a CRAC control model when outside air cooling is on</li> <li>• Data-Driven model can minimize energy consumption of a data center.</li> </ul>   |
|                          | Bhattacharjee et al.[17] | <ul style="list-style-type: none"> <li>• Research on technologies for networks of green data center cloud to effectively manage resources of a data center</li> <li>• Possibility of motion prediction is verified using CPS and prediction model.</li> </ul>                             |
|                          | Huang et al.[18]         | <ul style="list-style-type: none"> <li>• Development of a model predicting temperature and energy in a data center using ANN</li> </ul>   |

| Category                 | Author          | Content  |
|--------------------------|-----------------|--|
| Model Predictive Control |                 | <ul style="list-style-type: none"> <li>• 19.6%, 23.4% of energy saving presents in Summer and Winter, respectively using the developed model.</li> </ul>   |
|                          | Fang et al.[19] | <ul style="list-style-type: none"> <li>• Development of an energy and temperature optimization model based on MPC for cooling of a server heat gain</li> <li>• energy consumption is reduced from 1.452 PUE to 1.401 PUE by the developed model.</li> </ul>  |
|                          | Choi[20]        | <ul style="list-style-type: none"> <li>• Development and performance evaluation of an adaptive control algorithm for optimal thermal environment of containment-type data center</li> <li>• Control error of refrigerant flow rate based on ANN presents 0.47 of RMSE and controllability of ANN control model is verified.</li> </ul> |
|                          | Song[21]        | <ul style="list-style-type: none"> <li>• Development of a draft for automatic control algorithm to a cooling system in a data center based on Machine-Learning algorithm using data acquisition from an own platform</li> <li>• more 30% of cooling energy is saved by the draft control algorithm.</li> </ul>                         |

### 3. 예측모델 및 제어알고리즘 개발

#### 3.1. 예측모델 개발

모델 개발을 위한 데이터의 획득은 열역학 법칙을 활용하여 냉동기 2개, 컨테이너 1개, Rack 10개, 그리고 CRAH 6개로 구성된 데이터센터 수식적 열환경 모델을 이용하였다. 적용성 확보를 위해 예측이 가능한 CRAH 환기 온도, Rack 발열 부하를 입력 변수로, 냉동기 출수 유량 및 CRAH 급기온도를 각각 조절 변수와 출력 변수로 선정하였다. IT 부하는 Rack 당 최대 6.6kW의 부분부하로 산정되었으며 자정에서 오전 8시까지 약 20%가 발생하고 4시간 간격으로 30%, 40%, 50%, 40%로 변경된다. 급기온도 설정점은 4시간 간격으로 1일 동안 22°C, 18°C, 22°C, 25°C, 27°C, 25°C로 진행되는 것으로 설정되었다.

열환경 예측모델은 초기 딥러닝 신경망 모델인 ANN을 활용하여 개발되었다. 수식적 모델을 이용해 총 2,254개의 데이터 세트가 취득되었으며 60%, 20%, 20% 비율로 학습 데이터(Train), 검증 데이터(Validation), 시험 데이터(Test)를 분류하였다. 초기 예측모델의 구조는 뉴런 10개로 구성된 은닉층 1개와 입력뉴런 3개, 출력뉴런 1개로 구성되었다. 학습 알고리즘으로는 타 솔버(Solver)보다 해에 대한 수렴속도가 빠른 Levenberg - Marquardt Algorithm이 사용되었다[22]. 일반적으로 데이터 전처리 방식은 데이터세트를 정규 분포에 근사하게 가공하는 표준화, 0~1 사이로 조정하는 정규화가 일반적으로 사용된다[23]. 그러나 각 전처리 방식에 따른 일반적인 성능이 객관적으로 정립되지 않았으며 다양한 데이터 유형에 각기 다른 성능을 보이는 것으로 알려져 있다. 따라서 전처리 방식 선정을 위하여 두 가지 전처리 방식에 따른 초기 예측모델의 성능을 비교분석하였다.

최적화 단계에는 가우시안 과정(Gaussian Process)에 따른 오차 추정을 기반한 확률론적 알고리즘인 베이저안 최적화(Bayesian Optimization) 알고리즘이 사용되었다[24]. 최적화는 예측모델의 초매개변수(Hyper-Parameter)를 조정하여 최적 예측 성능을 도출해내는 과정으로 모델 개발에 필수적으로 진행되는 단계이다. 일반적으로 최적화 알고리즘은 초매개변수의 최소, 최대 범위에서 일정한 간격을 두어 탐색하는 그리드 탐색(Grid Search), 임의 탐색(Random Search)이 사용된다. 두 알고리즘은 이전 탐색 스텝의 결과를 반영한 추정 과정을 수반하지 않으며 탐색 횟수가 목표 횟수에 도달할 경우 성능에 상관없이 종료된다. 베이저안 최적화는 이러한 단점을 보완한 알고리즘으로 비교적 시간 소모가 크나 안정적으로 최적 성능을 내는 초매개변수 값을 탐색한다는 장점이 있다.

Data-Driven 형 예측모델은 Black Box 모델이며 다양한 초매개변수값에 따라 예측 성능이 상이하다. 초매개변수 값의 범위는 일반적으로 사용자의 임의 설정이 가능하며 명시된 기준이나 이론은 부재한 실정이다. 따라서 본 연구의 열환경 예측모델의 최적화 변수는 신경망 구조인 은닉층의 개수 및 은닉층 당 뉴런 수로 선정하였으며 각 변수 범위는 뉴런수 9~20개, 은닉층 1~5개로 설정하였다.

#### 3.2. 적응형 제어알고리즘 개발

비적응형 제어알고리즘은 사용자의 주기적인 튜닝(Tuning)이 필요하다는 단점을 가지고 있다. 그러나 자가 튜닝이 가능한 지능형 예측모델을 토대로 개발된 온라인 학습(Online Learning)을 통해 튜닝의 번거로움이 감소하였다[25]. 이를 통해 예측모델 기반 제어알고리즘은 실시간 어플리케이션 단계에서 점진적으로 높은 정확성을 확보할 수 있다.

적응형 학습 알고리즘은 Sliding Windows 기법을 사용하였다[26]. Sliding Window 방식은 데이터 리스트에서 1번 데이터를 삭제하고 마지막 위치에 새로운 데이터를 입력하여 학습시키는 방식으로 기존 학습 데이터 배열의 크기 및 추세를 유지하며 새로운 정답 데이터의 특성을 신경망에 반영한다.

본 연구의 제어알고리즘 조절 변수는 냉동기 출수 유량이며 제어 변수는 CRAH의 급기온도이다. 최적 열환경 예측모델을 포함한 초기 제어알고리즘은 예측된 CRAH 급기온도와 설정온도의 오차가 0.05 미만을 만족하고 냉동기 처리 열량을 최소로 하는 냉수 유량을 탐색한다. 이때 탐색 알고리즘은 냉수 유량을 0 kg/hr에서 40,000 kg/hr로 20 kg/hr 씩 증가시키며 각 데이터 포인트에 대한 그리드 탐색을 채택하였다. 최소 냉수 유량이 선정되면 유량 및 환경변수를 데이터센터 열환경 모델에 입력하여 시뮬레이션을 실시한다. 이때 도출된 CRAH 급기온도와 예측된 CRAH 급기온도가 다를 경우 IT 부하, 최소 냉수 유량, CRAH 환기온도, 도출된 CRAH 급기온도를 Sliding Windows를 통해 열환경 예측모델에 재학습시킨다. Fig. 1. 은 자세한 적응형 제어알고리즘의 과정을 보여준다. Fig. 1. 내 Temp\_RA는 CRAH 환기온도 Temp\_SA는 CRAH 급기온도를 의미한다. Chilled\_MW, Predict\_Temp\_SA, True\_Temp\_SA는 각각 냉동기 출수 유량, 예측된 CRAH 급기온도, 냉동기 출수 유량과 환경변수 값에 따른 실제 CRAH 급기온도이다.

제어 성능 개선을 위해 데이터센터 열환경 모델과 제어알고리즘을 연동하여 1일간 5분 단위 타임스텝에 대해 제어성능 최적화를 실시하였다. 최적화 알고리즘으로 베이지안 최적화 알고리즘을 사용하였다.

제어성능 최적화를 위한 초매개변수는 Levenberg - Marquardt Algorithm 솔버의  $\mu$  (Mu),  $\mu$  증가인자 (Mu\_Inc),  $\mu$  감소인자 (Mu\_Dec), 최대관용도 (Max\_Fail)를 선정하였다.  $\mu$ 는 학습 진행에 따른 오차가 클 경우 경사하강법 (Gradient Descent Method)으로 모델을 학습시키고 오차가 작을 경우 가우스-뉴턴법 (Gauss-Newton Method)으로 학습을 실시한다[27]. 최대관용도는 학습과정 내에서 일정 횟수 이상 목표 성능을 만족시키지 못하거나 오차가 감소하지 않을 경우 학습을 조기에 중지하는 역할을 하며 예측모델의 과적합 (Overfitting)을 방지한다.

### 4. 예측 및 제어 성능평가

ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers) Guideline 14는 예측모델의 성능평가를 위해 Cv(RMSE)와 상관계수( $R^2$ )에 대한 기준을 제시하고 있다[28]. Cv(RMSE)는 최소자승오차 (Least Square Error)의 제곱근에 편차를 반영한 것으로 주로 예측의 정확도 (Accuracy)와 정밀도 (Precision) 도출에 사용된다.  $R^2$ 는 최소자승법 회귀분석의 결과로 예측값과 정답 데이터의 선형관계 판별에 이용된다. 해당 기준에 의하면 예측 결과가 Cv(RMSE),  $R^2$ 가 각각 30% 이하보다 낮을 수록, 0.8 이상보다 높을 수록 예측모델로써 적합하다고 간주한다.

#### 4.1. 데이터 전처리 방식에 따른 초기 예측모델 성능

일반적인 데이터 전처리 방식인 정규화 및 표준화에 따른 초기 열환경 예측모델의 성능은 Cv(RMSE)와  $R^2$  기준을 만족하였다. 데이터 전처리 방식에 따른 예측성능은 다음 Table 2.와 같다. 정규화의 경우 학습, 검증 및 시험 데이터에 대하여  $R^2$ 가 각각 0.93, 0.90, 0.89로 도출되었으며 Cv(RMSE)는 학습, 검증, 시험에 대해 각각 14.78%, 19.35%, 18.80%로 계산되었다. 표준화의 경우  $R^2$ 는 학습, 검증, 시험에 대하여 0.92, 0.88, 0.88로 정규화와 유사한 결과를 기록하였다. 반면 학습, 검증, 시험 데이터에 대한 Cv(RMSE)는 정규화보다 0.14~1.03% 높게 나타난 14.92%, 21.12%, 20.87%로 산출되었다. 따라서 데이터 전처리 방식은 정규화로 선정되었다.

#### 4.2. 인공신경망 구조 최적화 및 일반화 성능평가

베이지안 최적화에 따른 열환경 예측모델의 최적 구조는 은닉층 별 뉴런수 각 14개, 은닉층 2개인 모델로 도출되었으며 결과는 다음 Table 3.와 같다. 최적화의 목적함수는 예측모델의 시험 데이터에 대한 Cv(RMSE) 산출 함수로 선정하였다. 최적 열환경 예측모델의 Cv(RMSE)는 0.94%로 산출되었으며 두 번째로 우수한 모델은 은닉층 3개 각 뉴런 개수 13개인 구조를 갖는 신경망으로 나타났다. 은닉층 3개인 모델의 Cv(RMSE)는 시험 데이터에 대해 2.51%로 산출되었다. 반면 가장 얇은 구조 (은닉층 1개)나 비교적 깊은 구조 (은닉층 4개, 5개)는 시험 데이터에 대한 Cv(RMSE)가 7.19%, 8.60%,

7.72%로 도출되었다. 따라서 은닉층의 개수가 2개, 3개의 모델이 예측모델로써 적합성을 갖는 것으로 분석되었다.

### 4.3. 초기 제어알고리즘 성능평가

제어알고리즘 개발 시나리오는 1일간의 일반적인 데이터센터 냉각 사이클로 선행연구과정에서 진행된 데이터센터 열환경 모델을 이용하여 개발되었다[29]. 본 연구의 제어알고리즘은 모두 최적화

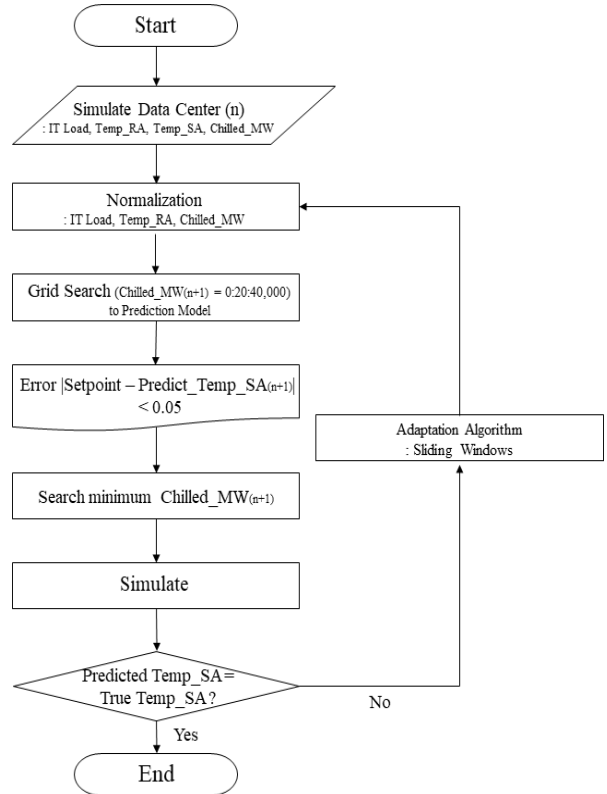


Fig. 1. Adaptive Control Algorithm

Table 2. Prediction Performance of Pre-processing Methods

| Method          | $R^2$        |            |       |
|-----------------|--------------|------------|-------|
|                 | Train        | Validation | Test  |
| Normalization   | 0.93         | 0.90       | 0.89  |
| Standardization | 0.92         | 0.88       | 0.88  |
| Method          | Cv(RMSE) [%] |            |       |
|                 | Train        | Validation | Test  |
| Normalization   | 14.78        | 19.35      | 18.80 |
| Standardization | 14.92        | 21.12      | 20.87 |

Table 3. Prediction Performance of The Optimized Model

| Layer | Neuron | $R^2$ | Cv(RMSE) [%] |
|-------|--------|-------|--------------|
|       |        | Test  | Test         |
| 1     | 13     | 0.93  | 7.19         |
| 2     | 14     | 0.94  | 0.94         |
| 3     | 13     | 0.94  | 2.51         |
| 4     | 11     | 0.95  | 8.60         |
| 5     | 9      | 0.95  | 7.72         |

가 완료된 열환경 예측모델을 포함한다. 초기 제어알고리즘의 성능 평가는 비적용 알고리즘으로 CRAH 급기온도에 외란을 적용하지 않은 경우와 외란을 적용한 경우로 나누어 실시되었으며 결과는 Fig. 2와 같다. 외란이 적용되지 않은 환경에서 초기 제어알고리즘의 제어오차(RMSE)는 2.22로 계산되었으며 최대 오차는 설정 급기온도보다 0.95℃ 높은 것으로 나타났다. 반면 외란이 적용된 상황에서 초기 제어알고리즘의 제어오차(RMSE)는 3.91로 도출되었으나 -10.2 ~ 9.02℃에 해당하는 큰 오차 진폭이 발생하였다.

#### 4.4. 적응형 제어알고리즘 성능 최적화

데이터센터 열환경 적응형 제어알고리즘은 개발 시나리오 데이터를 기반으로 매 스텝의 예측 오차가 Cv(RMSE) 기준 5% 이상 발생할 때 Sliding Windows 알고리즘을 실행한다. 외란에 대한 안정성 검증에 의해 제어성능 최적화가 완료되지 않은 적응형 제어알고리즘을 실시하였다. 그 결과, 제어오차(RMSE)는 1.75를 달성하였으며 급기온도 및 설정온도 그래프는 Fig. 3과 같다. 설정온도 대비 급기온도의 최대 오차는 0.84℃로 도출되었으며 비적용형 제어알고리즘보다 안정적으로 설정온도에 수렴하였다.

본 연구에서는 1일간의 데이터센터 냉각 시나리오에 대한 제어오차 산출함수를 최적화 목적함수로 사용하였다. 최적화의 경우 학습솔버의 초매개변수인  $\mu$  값,  $\mu$  증가인자,  $\mu$  감소인자, 최대관용도 중 가장 적은 제어오차를 발생하는 값을 탐색하는 것으로 실시되었다. 이때 각 초매개변수의 범위는  $\mu$  값이 0.0001에서 0.01,  $\mu$  증가인자가 1.1에서 100,  $\mu$  감소인자가 0.001에서 0.9로 설정되었다. 최대관용도의 경우 6에서 1,000회로 설정되었다.

최적화의 결과  $\mu$  값,  $\mu$  증가인자,  $\mu$  감소인자, 최대관용도가 각각 0.0099, 1.72, 0.89, 102회인 모델이 제어오차(RMSE) 0.45로 가장 우수하였다. 전체 데이터 세트에 대한 최대 제어오차는 약 0.91℃로, 외란이 발생하는 환경에서 Fig. 4와 같이 안정적인 제어를 수행하였다.

따라서 본 연구에서는 개발된 열환경 예측모델 및 적응형 제어알고리즘이 데이터센터 열환경 예측제어에 높은 적합성을 갖는 것으로 판단되었다.

### 5. 결론

최근 4차 산업혁명 선도 기술 중 하나인 LTE, 5G 등 초고속 통신망에 대한 수요의 증대로 원활한 데이터 송수신을 위해 데이터센터가 증설되고 있다. 이에 따라 데이터센터 에너지소비량이 증가하고 있는 추세이다. 선행연구 조사 결과 데이터센터 에너지절감 및 안정적 열환경 제공을 위한 시스템 개발과 효율 개선 등이 최근 10년간 활발히 시도되고 있으나 실시간 열환경 제어를 위한 최적 제어 알고리즘 개발은 미비한 상황이다. 따라서 본 연구에서는 ANN 기반의 열환경 예측모델을 포함하는 실시간 적응형 제어알고리즘을 개발하였으며 연구 결과는 다음과 같다.

초기 열환경 예측모델은 은닉층 1개에 뉴런수 10개 구조로 개발되었다. 데이터 전처리 방식은 정규화 방식이 사용되었다. 그 결과




Fig. 2. The temperature of non-adaptive control




Fig. 3. The temperature of adaptive control base model




Fig. 4. The temperature and mass flow rate of optimal adaptive control

정규화에 따른 성능인 상관계수( $R^2$ ) 값이 학습, 검증, 시험에 대해 각각 0.93, 0.90, 0.89로 도출되었으며 Cv(RMSE)는 14.78%, 19.35%, 18.80%로 우수하였다. 최적화를 실시한 결과 최적 열환경 예측모델은 은닉층 2개, 은닉층 당 뉴런 수 각 14개인 구조로 Cv(RMSE) 7.19%, 8.60%, 7.72%를 달성하였다. 이에 따라 얇은 구조의 신경망 모델이 데이터센터 열환경 제어에 대한 우수성과 적합성을 갖는 것으로 판단되었다.

초기 제어알고리즘은 그리드 탐색을 기반으로 구축되었으며 최적 열환경 예측모델을 포함한다. 성능평가 결과 비적용형 제어알고리즘은 외란이 적용되지 않은 상황에서 제어오차(RMSE)가 2.22, 최대 오차는 설정 급기온도보다 0.95℃ 높은 것으로 산출되었다. 그러나 외란이 추가되는 경우 설정온도와 급기온도의 오차가 -10.2 ~ +9.02℃로 크게 발생하였다.

Sliding Windows에 따른 적응형 제어알고리즘의 초기 모델은 외란이 추가될 때 최대 오차 0.84℃, 제어오차(RMSE) 1.75를 달성하

였으며 비적응 제어알고리즘보다 우수한 제어성을 내는 것으로 나타났다. 학습 초매개변수 최적화를 실시한 결과  $\mu$  값,  $\mu$  증가인자,  $\mu$  감소인자, 최대관용도가 각각 0.0099, 1.72, 0.89, 102회인 모델이 가장 우수한 모델로 선정되었다. 해당 모델의 제어오차 (RMSE) 및 최대오차는 각각 0.45, 0.91°C로 산출되었다.

상기 제어성능 및 오차분석 결과, 예측모델을 포함한 적응형 알고리즘은 예측 성능 및 안정적 열환경 제공을 할 수 있을 것으로 판단된다. 또한 자가튜닝 및 적응형 알고리즘에 기반하여 사용자의 편의성을 확보하였다. 이를 바탕으로, 예측모델 및 제어알고리즘은 추후 CPS 기반 데이터센터 제어분야에 적용될 것이다.

### Acknowledgement

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 2018 2010600010).

### Reference

[1] Research and Markets, "Data Center Colocation Market - Growth, Trends, and Forecast (2020 - 2025)", <https://www.businesswire.com/news/home/20200525005100/en/Global-Data-Center-Colocation-Market-2020-2025>, 2020.11.13.

[2] A.S.G. Andrae, T. Edler, On Global Electricity Usage of Communication Technology: Trends to 2030, challenges, 6, 2015, pp.117-157.

[3] K. Dunlap, N. Rasmussen, Choosing Between Room, Row, and Rack-based Cooling for Data Centers, White paper #130, Schneider Electric's Data Center Science Center, 2012.

[4] 최영재 외 3인, 컨테이너형 데이터센터 최적 제어알고리즘을 위한 열환경 예측모델 개발, 한국생태환경건축학회 논문집, 제20권 제5호, pp.159-164 // (Y.J. Choi et al., Development of Supply Air Temperature Prediction Model for Optimal Control Algorithm of Containment Data Center, KIEAE Journal 20(5), 2020.10, pp.159-164.)

[5] J. Nathan Kutz, Data-Driven Modelling & Scientific Computation : Methods for Complex Systems & Big Data, OXFORD, 2013

[6] 이승연 외 3인, 데이터센터의 냉방에너지 절감을 위한 외기냉방 시스템 개선에 관한 연구, 대한설비공학회 학술발표대회논문집, 2011.7, pp.810-814. // (S.Y. Lee et al., A Study on Free Cooling System for the Energy Saving in the Data Center, The Society Of Air-Conditioning And Refrigerating Engineers Of Korea, 2011.7, pp.810-814.)

[7] 김민휘, 박준영, 정재원, 데이터 센터 냉방을 위한 제습 증발냉각 시스템의 적용성 분석, 대한건축학회 학술발표대회 논문집, 33(1), 2013, pp.283-284. // (M.H. Kim, J.Y. Park, J.W. Jeong, Applicability of Desiccant and Evaporative Cooling System for Data Center Cooling Energy Savings, Architectural Institute of Korea 2013 Conference, 33(1), 2013, pp.283-284.)

[8] 윤정인 외 3인, 데이터센터의 외기냉수냉방 시스템에 대한 에너지 절감효과 분석, 한국동력기계공학회지, 18(3), 2014.6, pp.73-78. // (J.I. Yoon et al., Journal of the Korean Society for Power System Engineering, Vol. 18(3), 2014.6, pp.73-78.)

[9] 김지혜, 임태운, 정차수, 외기냉방시스템이 적용된 데이터센터 CRAH의 급기온도와 설계 풍량에 따른 에너지성능 분석, 대한건축학회 논문집 - 구조계, 35(11), 2019.11, pp.181-188. // (J.H. Kim, T.Y. Aum, C.S. Jeong, Energy Performance of Air-side Economizer System for Data Center Considering Supply Temperature and Design Airflow Rate of CRAH(Computer Room Air Handler), Journal of the Architectural Institute of Korea Structure & Construction, 35(11), 2019.11, pp.181-188.)

[10] W. Zhang et al., Towards Joint Optimization Over ICT and Cooling Systems in Data Center:A Survey, IEEE Xplore, 18(3), 2016,

pp.1596-1616.

[11] H.M. Daraghme, C.C. Wang, A review of current status of free cooling in datacenters, ATE, 114(5), 2017, pp.1224-1239.

[12] Y. Chen et al., Sharad Singhal, Integrated Management of Application Performance, Power and Cooling in Data Centers, IEEE Xplore, 2010, pp. 615-622.

[13] J. DengLiu, Y. Xinrong, C. W. Liu, Self-tuning PID-type Fuzzy Adaptive Control for CRAC in Datacenters, International Conference on Computer and Computing Technologies in Agriculture, 2014.L.

[14] J. Gao, Machine Learning Applications for Data Center Optimization, 2014.

[15] M. Zapater et al., Runtime data center temperature prediction using Grammatical Evolution techniques, Applied Soft Computing, 49, 2016, pp. 94-107.

[16] A. Beghi et al., Modelling and control of a free cooling system for Data centers, Energy Procedia, 140, pp.447-457, 2017.

[17] S. Bhattacharjee, S. Khatua, S. Roy, A review on Energy Efficient Resource Management Strategies for cloud, Advanced Computing and Systems for Security, 568, pp.3-15, 2017.

[18] Y.H. Huang, Multi-Objective Optimization of Energy Saving Control for Air Conditioning System in Data Center, Energies, 12(1474), 2019.

[19] Q. Fang et al., Optimization based resource and cooling management for a high performance computing data center, ISA Transactions, 90, 2019, pp.202-212.

[20] 최영재, 컨테이너형 데이터센터의 최적 열환경을 위한 적응형 제어알고리즘 개발 및 성능평가, 석사학위논문, 중앙대학교, 2020. // (Y.J. Choi, Development and Performance Evaluation of Adaptive Control Algorithm for Optimal Thermal Environment in the Containment-type Data Center, Chung-Ang University, Masters dissertation, 2020)

[21] 송석진, 머신러닝 기반 데이터센터 냉방 장치 자동제어 솔루션 개발 : 한전 사례를 중심으로, 대한전기학회 학술대회 논문집, 2019.7, pp.1793-1794. // (S.J. Song, Development of solution based on machine learning to control CRAC units in data centers : Focusing on KEPCO's case, Journal of The Korean Institute of Electrical Engineers Conference, 2019.7, pp.1793-1794.)

[22] M. Buscema, Back propagation neural networks. Substance use & misuse, 33(2), 1998, pp. 233-270.

[23] A. Geron, Hands-On Machine Learning with Scikit-Learn & Tensorflow, O'REILLY, 2017

[24] M. Pelikan, D.E. Goldberg, E. Cantú-Paz, BOA: The Bayesian optimization algorithm, In Proceedings of the genetic and evolutionary computation conference GECCO-99, Vol. 1, 1999, pp. 525-532.

[25] J.C. Schlimmer, R. H. Granger, Incremental Learning from Noisy Data, Machine Learning, 1, 1986, pp.317-354.

[26] 박보량, 최은지, 문진우, 셋백기간중 건물 냉방시스템 부하 예측을 위한 인공지능망모델 성능평가, 한국생태환경건축학회 논문집, 제17권 제4호, 2017.8, pp. 83-88. // (B.R. Park, E.J. Choi, J.W. Moon, Performance tests on the ANN model prediction accuracy for cooling load of buildings during the setback period, KIEAE Journal 17(4), 2017.8, pp.83-88.)

[26] J.J. Moré, The Levenberg-Marquardt algorithm: implementation and theory, In *Numerical analysis*, Springer, Berlin, Heidelberg, 1978, pp. 105-116.

[27] ASHRAE Guideline 14, Measurement of Energy and Demand Savings, 2002.

[28] ASHRAE, Green Tips for Data Centers, ASHRAE Datacom Series Series Book 10, 2010.