



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.


다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 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](#)

第 108 回 博士學位論文

指導教授 文 鎮 宇

데이터센터의 에너지 절약을 위한
인공신경망 기반 냉수 유량 제어알고리즘
개발

Development of an Artificial Neural Network based
Chilled Water Flow Control Algorithm to Improve the
Energy Saving of the Data Centers

中央大學校 大學院
建築學科 建築環境計畫專攻

朴 寶 琅

2021年 2月

데이터 센터의 에너지 절약을 위한
인공신경망 기반 냉수 유량 제어알고리즘
개발

Development of an Artificial Neural Network based
Chilled water flow Control Algorithm to Improve the
Energy Saving of the Data centers

이 論文을 博士學位論文으로 提出함

2021年 2月

中央大學校 大學院
建築學科 建築環境計畫專攻

朴 寶 琅

朴寶琅의 博士學位論文으로 認定함

審査委員長 _____ (印)

審査委員 _____ (印)

審査委員 _____ (印)

審査委員 _____ (印)

審査委員 _____ (印)

中央大學校 大學院

2021年 2月

목 차

제 1 장 서 론	1
1.1 연구의 배경 및 목적	1
1.2 연구범위 및 방법	9
1.2.1 연구의 범위	9
1.2.2 연구의 방법 및 구성	14
제 2 장 이론 고찰	16
2.1 데이터센터의 이해	16
2.1.1 정의 및 구성	16
2.1.2 데이터센터 형태	18
2.1.3 설계기준	23
2.1.4 열원에 따른 냉각 시스템 유형	27
2.1.5 에너지효율 평가 기준	31
2.1.6 데이터센터의 에너지 소비 현황	32
2.2 데이터센터 냉각 시스템 제어 선행연구 조사 및 분석	36
2.2.1 국내·외 데이터센터 환경 분석	36
2.2.2 데이터센터 공조제어 선행연구 분석	39
2.3 인공신경망 기반 제어의 이해	45
2.3.1 인공신경망 및 기계학습 정의	45
2.3.2 건축설비 분야 기계학습 적용 동향	52
2.3.3 인공신경망 기반 공조 제어알고리즘 개발 목적	55

제 3 장 냉수 유량제어를 통한 실내 열환경 예측모델 및 최적 제어알고리즘 개발	57
3.1 개발 방법 및 절차	57
3.2 대상 데이터센터 및 냉각 시스템 구성	59
3.2.1 컨테이너먼트형 데이터센터의 구성	60
3.2.2 중앙 냉수식 시스템 구성	62
3.3 수학적 모델에 의한 예측모델 데이터 취득	64
3.4 냉수 유량제어를 통한 실내 열환경 예측모델 개발	72
3.4.1 입출력 변수 선정 및 데이터 전처리	74
3.4.2 인공신경망 기반 초기 예측모델 구조설정	76
3.4.3 GPR, SVM, RF 초기 예측모델 설정	85
3.5 예측모델 기반 냉수 유량 최적 제어알고리즘 개발	86
3.6 제어알고리즘 성능평가를 위한 시뮬레이션 모델 구축	89
3.7 소결	93
 제 4 장 예측모델 및 제어알고리즘 성능평가 및 검증	 96
4.1 성능평가 개요	96
4.2 예측모델의 예측정확도 평가 및 최적화	97
4.2.1 초기 예측모델 성능평가	97
4.2.2 예측모델 최적화	101
4.3 제어알고리즘의 제어 정확성 · 안정성 · 적응성 평가	109
4.3.1 비적응 제어알고리즘 성능평가	111
4.3.2 적응형 제어알고리즘 최적화 및 성능평가	112
4.3.3 시뮬레이션을 통한 성능평가 결과 타당성 검증	121
4.4 제어알고리즘 적응성 검증	125

4.4.1 ON-OFF 제어	134
4.4.2 PID 제어	138
4.4.3 인공신경망 제어	142
4.5 소결	146
 제 5 장 결 론	 149
5.1 연구의 결론	149
5.2 연구의 활용성 및 향후 연구	151
 부록	 153
 참고문헌	 163
 국문초록	 173
 ABSTRACT	 176

표 목 차

Table 1. 데이터센터 세계 기술 발전 전망	6
Table 2. 규모에 따른 데이터센터 구분	17
Table 3. IT서버룸 구성에 따른 데이터센터의 범위	18
Table 4. 데이터센터 IT 장비 배치 별 분류	21
Table 5. CACS와 HACS 비교분석	22
Table 6. IT서버의 환경 설계 조건	23
Table 7. 데이터센터 IT 장비 배치 별 분류	26
Table 8. 국내·외 에너지효율화 데이터센터 개요 및 주요 적용기술	37
Table 9. 데이터센터 공조제어 선행연구 분석	41
Table 10. 예측모델에 적용한 4가지 기계학습 방법	51
Table 11. ASHRAE 권장 RACK 표준 사양	62
Table 12. 냉각시스템 구성 및 사양	64
Table 13. 냉각시스템 장비별 산출 데이터 리스트	70
Table 14. 냉각시스템 장비별 산출 데이터 일부 - CRAH	71
Table 15. 냉각시스템 장비별 산출 데이터 일부 - 냉동기, 냉각탑	72
Table 16. 데이터세트 구성	75
Table 17. 활성화 함수 종류 및 비교	79
Table 18. 인공신경망 기반 예측모델 적용 함수	81
Table 19. Train, Validation, Test Data set의 용도	83
Table 20. ANN 초기 예측모델 상세	84
Table 21. GPR, SVM, RF 예측모델의 초기 구조설정	85
Table 22. 초기 예측모델 성능	99
Table 23. GPR, SVM, RF 예측모델 하이퍼파라미터 최적화	108
Table 24. 제어알고리즘 적용을 위한 최종 예측모델 선정	109
Table 25. LM 알고리즘의 최적화 기술	114
Table 26. 적응형 제어알고리즘 하이퍼파라미터 최적화 결과	115
Table 27. 비적응·적응형 제어알고리즘 성능평가 결과	117

Table 28. 시뮬레이션 결과 타당성 검증용 시스템 소비전력 비교	123
Table 29. 시뮬레이션 모델의 타당성 확보를 위한 특성 검증	124
Table 30. 제어알고리즘 적응성 평가를 위한 시뮬레이션 개요	127
Table 31. 제어모델의 적응성능 비교분석 - Time step: 8,640 (One month) ..	132
Table 32. 제어 시나리오 구간당 Max error (°C) - Time step: 288 (One day) ..	132

그림 목차

Fig. 1 국내 데이터센터 증가 추이	2
Fig. 2 데이터센터 에너지 소비비율	4
Fig. 3 연구의 범위	9
Fig. 4 연구의 흐름도	15
Fig. 5 데이터센터의 구성 및 업무체계도	16
Fig. 6 중앙 냉수식 시스템 개념도	28
Fig. 7 수냉식(냉각수) 시스템 개념도	29
Fig. 8 클리콜 냉각시스템 개념도	29
Fig. 9 공랭식(직랭식) 냉각시스템	30
Fig. 10 데이터센터 에너지효율평가 기준 PUE	31
Fig. 11 데이터센터 보유 여부에 따른 에너지 원단위 비교	33
Fig. 12 데이터센터 일간 IT 서버 일일 가동율	34
Fig. 13 데이터센터 일간 시간대별 트래픽 현황	35
Fig. 14 데이터센터 주간 트래픽 현황	35
Fig. 15 글로벌 주요 데이터센터 에너지효율(PUE) 수준	38
Fig. 16 인공신경망 모델 개념 및 구조	48
Fig. 17 기계학습 분류	49
Fig. 18 예측·제어모델 개발 프로세스	58
Fig. 19 ANN 기반 예측·제어모델 개발 활용 도구 및 적용 범위	59
Fig. 20 컨테인먼트 데이터센터 및 냉각시스템 구조	60
Fig. 21 컨테인먼트 구성	61
Fig. 22 냉각시스템 구성	63
Fig. 23 예측모델 개발 순서도	73
Fig. 24 활성화 함수의 역할	78
Fig. 25 Levenberg-Marquardt 알고리즘 흐름도	80
Fig. 26 초기 인공신경망 예측모델 구조	81
Fig. 27 데이터 세트의 구성	83

Fig. 28 온라인 학습 개념도	86
Fig. 29 예측 · 적응 제어알고리즘	88
Fig 30 중앙 냉수 시스템의 시뮬레이션 모델화	91
Fig. 31 MATLAB 활용 냉각시스템 시뮬레이션 모델 시행 화면	91
Fig. 32 구조 최적화를 통한 예측모델 최종 구조	104
Fig. 33 인공신경망 예측모델 구조 최적화 Cv(RMSE) 결과 -	
① Hidden Layer change & Hidden Neuron fix	105
Fig. 34 인공신경망 예측모델 구조 최적화 Cv(RMSE) 결과 -	
② Hidden Layer fix & Hidden Neuron change	106
Fig. 35 비적응 제어알고리즘 - 설정 온도 대비 CRAH 공급공기 제어 온도 ...	111
Fig. 36 비적응 제어알고리즘 - 설정 온도에 따른 최소 냉수유량 및 냉방부하 ...	112
Fig. 37 Sliding Window - 설정 온도 대비 CRAH 공급공기 제어 온도 ...	118
Fig. 38 Sliding Window - 설정 온도에 따른 최소 냉수유량 및 냉방부하 ...	118
Fig. 39 Vector Augmentation - 설정 온도 대비 CRAH 공급공기 제어 온도 ...	119
Fig. 40 Vector Augmentation - 설정 온도에 따른 최소 냉수유량 및 냉방부하 ...	119
Fig. 41 Vector Adaptation - 설정 온도 대비 CRAH 공급공기 제어 온도 ...	120
Fig. 42 Vector Adaptation - 설정 온도에 따른 최소 냉수유량 및 냉방부하 ...	120
Fig. 43 제어알고리즘 적응성 평가용 컨테인먼트형 데이터센터 구성 ...	126
Fig. 44 제어 구간당 IT 서버 부분 부하율에 따른 최대 온도 오차	133
Fig. 45 제어기별 냉방부하 산출결과 - Case 1 기준, The 1st day	133
Fig. 46 Simulink 기반 ON-OFF 제어기	134
Fig. 47 ON-OFF 제어기 Case 1 결과	136
Fig. 48 ON-OFF 제어기 Case 2 결과	137
Fig. 49 Simulink 기반 ON-OFF 제어기	138
Fig. 50 Simulink PID Tuner 설정	138
Fig. 51 PID 제어기 Case 1 결과	140
Fig. 52 PID 제어기 Case 2 결과	142
Fig. 53 ANN 제어기 Case 1 결과	144
Fig. 54 ANN 제어기 Case 2 결과	145

부록 목차

1. ANN 예측모델 구조 최적화 R2 결과 - ① [Step 1] Hidden Layer change & Hidden Neuron fix	160
2. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ① [Step 1] Hidden Layer change & Hidden Neuron fix	161
3. ANN 예측모델 구조 최적화 R2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (1)	162
4. ANN 예측모델 구조 최적화 R2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (2)	163
5. ANN 예측모델 구조 최적화 R2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (3)	164
6. ANN 예측모델 구조 최적화 R2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (4)	165
7. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (1)	166
8. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (2)	167
9. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (3)	168
10. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (4)	169

제 1 장 서론

1.1 연구의 배경 및 목적

전 세계적으로 ‘에너지’가 주요 이슈로 대두됨에 따라 모든 분야에서 주요과제로 다뤄지고 있다. 우리나라에서 소비되는 전체 에너지의 약 1/4(25%)이 건축부문에서 사용되고 있으며¹⁾ 이 중 약 66.9%가 냉·난방, 사무기기 에너지로 사용되고 있는 것으로 나타났다.²⁾ 건물 에너지 관점에서 건물외피를 통한 열 획득 및 손실에 의해 발생하는 에너지가 주된 건물부하가 되는 외피부하 중심 건물과 건물 내부에서 발생하는 열이 주된 건물부하가 되는 내부부하 중심 건물로 구분할 수 있다.³⁾ 현재 고성능 건축외피에 대한 연구는 지속적으로 활발히 수행되고 있으나 내부부하 중심건물에 대한 연구는 미비하다. 내부부하 중심건물에 대한 발열원은 건물사용 환경에 따라 다양하므로 제어 및 감소가 쉽지 않다. 따라서 심각성은 인식하는 반면 그에 반해 활발한 연구가 이루어지지 않고 있다. 내부부하의 증가는 고사양의 장비들로부터의 발열이 차지하는 비중이 크며 이는 곧 쾌적한 실내환경 유지를 위한 에너지 소비의 증가로 연결될 수 있다.

최근 4차 산업혁명으로 인공지능(Artificial Intelligence, AI), 사물인터넷(Internet of Things, IoT), 이동통신 기술(Mobile Telecommunication), 가상현실(Virtual reality, VR) 등이 주도하는 첨단 정보기술(Information Technology, IT) 산업의 급속한 발전으로 IT

1) 광영훈, 실시간 건물 에너지 시뮬레이션 프레임워크 개발을 통한 냉방 시스템 예측 제어, 서울시립대학교 대학원, 건축공학과, 박사학위논문, 2014.

2) 에너지경제연구원, 2014 에너지 총조사 보고서, 2014.

3) 조진균, 정차수, 김병선, 고밀도 내부부하 중심 건물의 에너지 절약적 공조방식에 대한 연구, 대한설비공학회, 설비공학논문집, 22(8), pp.530-537, 2018.

장비는 점점 더 고사양 장비로 진화하며 발열 또한 급속히 증가하고 있다. IT 산업과 직접적으로 관련 있는 데이터센터는 고발열 IT 장비들로 이루어진 고밀도 내부부하 중심건물이다. 최근 국내에서도 IT 산업의 급속한 발전과 장비 성능 및 처리 능력이 기하급수적으로 발전함과 더불어 기업들의 사업변화에 따른 데이터센터 수요가 급증하고 있다. Data Center Map에 의해 2020년 기준 125개국에 4,657개의 대형 및 중형 데이터센터가 존재하는 것으로 조사되었으며⁴⁾ 국내는 정부·공공 및 민간산업 등 대·중·소규모의 임대 데이터센터와 전용 데이터센터의 총합은 2000년 53개 이후 매년 5.9% 증가하여 2019년 158개소에 달하는 것으로 한국데이터센터협회에서 보고하고 있어 지속적으로 증가할 것으로 예상된다.⁵⁾(Fig. 1)




Fig. 1 국내 데이터센터 증가 추이

4) Data Center Map, <https://www.datacentermap.com>, (accessed on 5 Aug 2020.)

5) 송준화, 송명호, Korea data center market 2020-2030, (사)한국데이터센터연합회, 2020.05.

이에 데이터센터 구축과 운영 활성화 촉진을 위해 건축법 시행령상 데이터센터의 용도 규정이 ‘방송통신용시설’로 신설(2018.9.4. 개정)⁶⁾ 되었다. 건축법에서 데이터센터는 정보통신서비스의 제공을 위해 다수의 정보통신기반을 일정한 공간에 집적시켜 전용건물에 구축하고 24시간 365일 무중단으로 통합 운영·관리하는 시설로 정의하고 있다.

데이터센터의 전력사용량 증가와 전기에너지 비용 상승으로 인한 비용 압박으로 인해 기존에 데이터센터에서 중시하던 안정성과 함께 에너지효율화가 관리의 주요 이슈로 대두되고 있다.⁷⁾ 전 세계 기업의 IT 관련 전력소비량은 한해 1,000억 kW로 전 세계 이산화탄소 배출량의 2%를 차지하고 있다.⁸⁾ 데이터센터의 IT 서버 수는 매년 약 13% 증가하고, 데이터 저장 요구량도 연평균 56% 증가해왔다. 이에 따라 전력소비량도 연 20% 증가하는 추세라고 보고되고 있다.⁹⁾ 데이터센터의 보편적인 에너지 소비비율은 냉각 시스템 50% > IT 장비 26% > 전력 장비 15% > 기타 9%로 서버의 냉각 에너지를 줄이는 것이 전체 에너지 소비를 줄이는 최선의 방안이 될 수 있다.(Fig 2)¹⁰⁾ 또한, 데이터센터 구축비용의 60% 이상을 전력, 공조 등 에너지 관련 설비가 차지하고 있어 IT 환경유지를 위한 공조설비 관리가 핵심 요소이다.

6) 건축법 시행령, 제3조 5, 별표 1, 용도별 건축물의 종류, 2018.09.04.

7) 이상학, 문성준, 그린데이터센터 구현기술 및 표준화 동향, 한국정보사회진흥원 국가정보사업단 녹색정보화지원부, 제2호, 2010.12.

8) Gartner, Green Data Centers: The six Key Attributes of Data Center Energy Efficiency Metrics, 2008.

9) Simon Mingray, Green IT: The New Industriy Shockwave, Gartner RAS Core Research Note G00153507, 2007.

10) Info-Tech Research Group, Top 10 Energy Saving Tip for Greener Data Center, Operate & Optimize Info-Tech Advisor Premium, 2007.




Fig. 2 데이터센터 에너지 소비비율

데이터센터의 에너지효율화를 위해 각종 관련 기준에 관한 연구는 미국을 중심으로 에너지성(Department of Energy), 국방성 등 정부기관과 ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers)의 T.C 99: Standard 90.4: Energy Standard for data centers¹¹⁾, BICSI (Building Industry Consulting Service International)의 BICSI 002: Data Center Design and Implementation Best Practices¹²⁾ 에서 활발하게 이루어지고 있다. 그러나 대부분 IT 장비의 발열량 및 방열 경향, 실내 열 관리와 공기분배, 열원 시스템에 대한 기초적인 기준에 국한되어 서버냉각을 위한 구체적인 공조시스템에 관한 연구는 활발하게 진행되지 않고 있다.¹³⁾ 이와 관련하여

11) ASHRAE, ASHRAE TC9.9: Data center Power Equipment Thermal Guidelines and Best Practices, 2016.

12) BICSI, BICSI 002: Data Center Design and Implementation Best Practices, 2019.

13) 조진균, 고밀도 데이터센터의 공조효율 및 에너지성능 개선을 위한 공조시스템 계획 방법 연구, 연세대학교 대학원, 박사학위논문, 2009.

연구기관에서 데이터센터 서버냉각 문제를 해결하려는 노력이 이뤄지고 있으나 주로 제품 또는 장비 단위 효율평가가 중점적으로 수행되었다.

국내에서도 데이터센터의 서버냉각 에너지소비량을 절감하기 위하여 데이터센터 유형별 구축 기술, 공조설비 장비 효율 개선 등 글로벌 기술 발전 동향에 맞도록 개발되고 있으나 세계 최고 수준과는 기술격차가 큰 실정이다. 최근 데이터센터는 고밀도·고발열 차세대 IT 장비의 등장으로 기존의 공조 및 냉각방식에서 이전에 경험하지 못한 발열량, 발열패턴 등의 예상하지 못한 다양한 상황이 발생하고 있다. 이에 따라 공조 및 냉각시스템 용량의 과설계, 비효율적 운영으로 인한 실제 필요한 냉각용량 예측 불가의 문제 해결을 위해 IT 서버 배치 유형 및 공조방식에 따라 룸(Room, Open Architecture), 구역(In-Row, Containment system) 단위의 냉각시스템을 개발·적용 중에 있다. 그러나 데이터센터는 연간 무중단 운영으로 리모델링 및 보수가 어렵고 설계 시 공간과 구조의 제약이 많으며 고비용이 소요되므로 기계 설비적 해결방안에는 한계가 존재한다. 또한, 서버냉각에 필요한 냉각 장비들의 설계가 효율적으로 되었다고 해도 시시각각 변화하는 서버 부하에 대응할 수 있는 제어가 제대로 되지 않으면 에너지 낭비가 발생할 수밖에 없다.

데이터센터는 규모나 운영 상황에 따라 각각 적용해야 할 냉각 솔루션이 상이하다. 이로 인해 에너지효율을 위한 공조설비들도 현장에 적합하게 변화되어야 하는데 이는 데이터센터의 무중단 운영과 빈번하게 변화하는 IT 서버 운영방식으로 이에 유동적으로 대응하기 어렵다. 따라서 고효율의 설비 장비와 같은 하드웨어적인 접근만으로는 더이상 데이터센터의 서버냉각을 효과적으로 해결할 수 없기에 이보다 효과적이고 경제적인 전략적 제어 방안 마련이 시급하다.

국외의 경우, 구글, 아마존, 페이스북, 마이크로소프트, 슈나이더일렉트릭

등 대표적인 데이터센터 보유 기관에서는 데이터센터 냉각 기술 개발 및 관리는 하드웨어에 국한되는 것이 아닌 소프트웨어적인 접근이 필수적임을 시사하며 다양한 소프트웨어적 솔루션을 적용하고 있다. 2019년 기준, 2013년 대비 데이터센터 세계 기술 발전 전망의 핵심적 변화는 ‘초고효율 저비용 빌딩 블록형 데이터센터’와 더불어 ‘최적화 자동제어 기반 인프라 기술’, ‘확장성을 고려한 연동 및 상호지원 서비스 기술’, ‘사용자 지향적 지능적 맞춤형 컴퓨팅’, ‘기능의 확장성’이라는 소프트웨어적 특징을 가진 기술 개발이 강조되고 있다.(Table 1) 14)

Table 1. 데이터센터 세계 기술 발전 전망

구분	2013	2014	2015	2016	2017	2018	2019
데이터 센터 인프라	친환경 고성능		고효율 고성능			최적화 자동제어 기반 초고효율	
IT 인프라	데이터센터 간 상호 백업 기술				급격한 서비스 확장을 고려한 데이터센터 간 연동 및 상호지원 서비스		
	사용자 지향적 컴퓨팅			사용자 지향적 지능적 맞춤형 컴퓨팅			
	빅데이터, 소셜·모빌리티 등 대용량 데이터를 위한 스토리지 클라우드			미래 서비스에 대비한 비용 효과적 용량, 기능의 확장성			

14) 한국네트워크산업협회, ICT 장비 산업 경쟁력 강화 전략 정책연구, 미래창조과학부 연구 보고서, 2013.

국내의 경우, 과학기술정보통신부는 ‘제1차 혁신성장전략회의’를 통해 데이터·인공지능 경제 활성화 계획을 발표하였다.¹⁵⁾ 데이터와 인공지능 분야에 대한 지원을 강화하여 2023년 30조원 규모로 성장시키는 것이 목표이다. 이를 위해 ‘빅데이터센터’ 100곳을 설립, 인공지능 기술 및 이를 활용한 서비스 개발을 지원하며 기초연구와 소프트웨어 기술 개발에 집중하고 R&D와 전문기업 기술 개발에도 집중적으로 지원할 것을 밝혔다.

소프트웨어적 제어기술은 4차 산업혁명이라는 흐름과 이에 대응하기 위한 정부 정책 기조에 따라 전 분야에 걸쳐 인공지능 기술 적용이 활발하다. 건축 분야에도 점차 활용의 폭이 확대되어 건축부문에서의 건축 도면작업의 지원 도구로 활용이 가능하며, 건축환경·설비 부문에서는 실내환경 제어, 에너지 수요예측 및 제어, 열원 및 설비시스템 최적화 제어, 운영기술 등에 활용 가능한 수준에 도달했다.

기존 및 신축 예정인 미래형 데이터센터 건물은 유연하고 높은 수준으로 제어되어야 하는 상황에서 변화되는 환경에 적응할 수 있는 제어의 필요성 및 중요성이 증대되고 있다.¹⁶⁾ 진화된 제어기술 도입으로 데이터센터의 냉각 에너지 효율화를 위해 즉각성, 자동성, 적응성, 확장성 등의 기술적 진보가 가미된 인공지능 솔루션으로 제어기술을 개발하고 적용하는 것이 필요하다.

따라서 본 연구의 목적은 최근 수요가 급증하고 있는 데이터센터의 고밀도 IT서버 발열을 고려하여 이에 적합한 실내 열환경을 제공하고 에너지효율 개선을 위한 에너지 절약적 냉각시스템 제어기술을 개발하는 것이다. 개발 기술은 인공지능을 기반으로 냉각시스템을 예측·제어하는 기술로, 이의 적용을 통해 다양하게 변화하는 데이터센터 환경을

15) 과학기술정보통신부, 관계부처 합동, 제 1차 혁신성장전략회의, 데이터·AI경제 활성화 계획(‘19~’23년), 제 1차 혁신성장전략회의, 2019.01.

16) IBM, 그린, 그린IT 그리고 그린데이터센터, 한국경제신문, 2009.

고려하여 사전 대응이 가능하고 숙련된 운전자·관리자 없이도 냉각시스템을 가장 효율적이며 경제적으로 자동 운전할 수 있도록 하는 최적 제어 방법을 제안하고자 하였다.

본 기술은 향후 다양한 유형의 데이터센터뿐만 아니라 여러 가지 용도의 건축물 냉각시스템에도 적용 가능한 적응성이 있는 솔루션으로써 건축물 에너지효율 개선에 기여하고자 한다. 주요 목적은 다음과 같다.

- 컨테이너먼트 방식 데이터센터의 IT 발열량 해소를 위해, 인공신경망(Artificial Neural Network, ANN) 기반 중앙 냉수 시스템의 냉수유량 제어를 통한 실내 열환경 & 냉방부하 예측모델 및 제어알고리즘 개발.
- 정확도 높은 예측을 통한 예측기반 제어의 합리적 결과 산출과 최적 냉수유량 제어를 통한 적절한 실내온도 공급으로 데이터센터의 에너지 절약 달성.
- 각종 환경에 적응 가능한 지능형 예측·제어 기술개발.

1.2 연구범위 및 방법

1.2.1 연구의 범위

IT 산업의 발달로 대량의 IT 서버 운영 및 실내환경 유지를 위한 냉방에너지를 소비하고 있는 전형적인 에너지 다소비 건물인 데이터센터가 증가하고 있다. 따라서 데이터센터 냉방에너지 절약을 위한 새롭고 혁신적인 연구가 필요하다.

본 연구는 데이터센터의 IT 서버에 대한 에너지효율을 제외한 냉각 시스템을 중심으로, 안정적이며 에너지 절약적으로 운영되도록 중앙 냉수식 시스템의 냉수 유량제어를 통한 열환경 및 냉방부하 예측·제어알고리즘을 개발하는 것으로 연구범위를 한정하였다. 본 논문의 부문별 연구범위는 Fig. 3의 회색 처리된 항목이며 상세내용은 다음과 같다.



Fig. 3 연구의 범위

(1) 본 연구는 컨테인먼트형 데이터센터를 연구의 대상으로 한정하였다. 컨테인먼트형 데이터센터는 IT 서버의 전력 밀도, 재배치, 증설 및 변경에 유연하게 대응하여 에너지효율 개선에 적합한 통합 제어 방식으로 최근 신설 데이터센터 및 리모델링을 진행하는 데이터센터에서 적용비율이 증가하는 추세이다. 컨테인먼트 1개소의 IT 서버 발열밀도는 92.4kW/Containment로 설정하였다. 실내환경 기준은 ASHRAE T.C 99에서 권고 기준에 따라 실내온도 유지 범위를 18℃~27℃로 설정하였다.

(2) 국내 중대형 건물의 냉방 시설 대부분은 전기를 주 에너지원으로 하는 중앙 집중식 냉각 시스템을 적용하고 있다. 데이터센터는 중대형 시설로 최근 급증하는 수요에 따라 점차 하이퍼스케일(Hyperscal)로 신설되는 추세이다. 이 같은 중규모 이상의 데이터센터는 냉각탑이 다수의 CRAC (Computer Room Air Conditioning) · CRAH (Computer Room Air Handling)를 담당할 수 있도록 냉각방식은 중앙 냉수식 시스템으로 구성 된다. 컨테인먼트형 데이터센터의 고밀도 IT서버 발열 냉각을 위한 전기에너지 절감에 효율적으로 대응할 수 있도록 중앙 냉수식 시스템을 대상으로 선정한다.

(3) 전기에너지를 과소비하고 있는 중대형 산업용·사무용 건물에서 전기에너지를 효율적으로 절감하기 위해서는 반드시 냉각 시스템의 최적 유량제어와 관리가 필수적이다. 최근 냉각 시스템의 운전 효율 개선 및 에너지 절감을 위한 다양한 연구들이 다수 진행되고 있는데 냉수 및 냉각수 계통 최적 유량제어를 통한 에너지 절감효과가 최대 약 46.7 %에 이른다는 연구 보고도 있다.¹⁷⁾

17) Young-hak, Song, Yasunori Akashi, Jung-Jae Yee, Energy performance of a cooling plant system using the inverter chiller for industrial building, Energy and

본 연구에서의 중앙 냉수식 시스템은 고밀도 IT 환경을 위한 컨테이너먼트형 냉각장치에 적용 가능한 초 고효율 서버냉각 기술로 냉각탑-냉동기 - 냉매분배기 - CRAH로 구성된다. 여기서, 냉매분배기는 R314a 냉매를 사용하며 해당 냉매는 상변화만 이루어질 뿐 온도는 동일한 특성을 가짐에 따라 열량에는 변화가 없고 과냉도를 고려하여 CRAH와 냉동기 사이에서 열을 전달하는 것으로 그 역할이 한정된다.

IT 서버 부하에 대응하는 냉각 시스템 각 장비로부터의 컨테이너먼트 실내 온도에 대한 영향성 평가를 목적으로 KS C 9306 (Air-conditioner)를 기준으로 실험이 수행되었다. 실험 결과, 냉동기의 냉수유량이 냉수온도 변화에 영향을 미치며 냉수온도는 컨테이너먼트 실내 열환경 유지를 위한 CRAH 공급공기 온도에 가장 많은 영향을 주는 것으로 확인되었다. 즉, 냉수유량과 냉수온도의 관계성과 이들의 CRAH 공급공기에 대한 영향성을 확인하였다. 단, 실제 데이터센터에 적용하여 운영할 시에는 냉수 공급온도가 7℃로 고정되어 공급되기 때문에 CRAH 공급공기 온도를 변화시킬 수 있는 요소는 냉수 유량으로 제한된다. 냉각시스템의 전력소비량 또한 냉동기의 압축기에서 가장 많이 소비하는 것으로 확인되어 대부분의 소비전력은 냉동기에서 발생함을 확인하였다. 반면에 냉각탑의 냉각수와 냉매분배기의 냉매유량 제어 시 CRAH 토출 공기온도 변화는 미비하여 실내환경에 영향을 주지 않는 것으로 확인되었다.

따라서 본 연구에서는 개발 시스템의 매커니즘과 실증 현장 상황 및 실험 결과 논리에 의해 중앙 냉수식 시스템의 냉수유량으로 제어범위를 한정하여 데이터센터의 최적 실내 열환경(CRAH 공급공기 온도) 개선을 통한 냉방에너지 절약성능을 평가한다.

Buildings, 2007, 39, pp. 289-297.

(4) 예측모델 및 제어알고리즘에 활용될 데이터는 수학적 모델에 의해 취득하는 것으로 한다. 본 연구의 대상 냉각 시스템 사양 및 경계조건을 충분히 고려하고, 열역학 제1법칙 (에너지 보존의 법칙)에 근거하여 열전달 수식을 활용한 총 12,929개의 데이터 세트를 산출하였다. 산출된 데이터 중 데이터센터에서 센서를 통해 일반적으로 측정되는 데이터를 위주로 예측·제어 모델에 적용하는 것으로 진행하였으며 해당 데이터들은 추후 실제 데이터로 교체하여 활용할 수 있도록 구성하였다.

(5) 본 연구에서 사용되는 ANN 기반 예측모델 및 제어알고리즘은 데이터 기반 모델로써 입력변수와 출력변수 데이터만을 사용하여 입출력 관계를 설명하는 모델로 구성하는 방법이다. 데이터 기반 모델링 방법을 이용할 경우 소수의 입력변수와 출력변수를 통해 모델을 구현 할 수 있으며 기존 건물 또는 새로이 개발되는 시스템과 같이 입력변수를 정확히 수집하거나 세밀한 수준의 물리적 모델을 수립하기 어려운 경우에 특히 유용한 방법이다.¹⁸⁾

따라서, 본 연구에서는 ANN을 기반으로 냉수유량 제어를 통한 실내 열환경 예측모델을 개발하고, 예측모델이 포함된 적응형 제어알고리즘을 개발한다. 예측모델 및 제어알고리즘은 인공지능 기술 구현이 가능하며 컴퓨터 프로그래밍이 가능한 소프트웨어인 MATLAB (Matrix Laboratory) 으로 개발된다.

(6) 인공지능 기술을 활용한 ANN 기반 예측모델 및 제어알고리즘의 성능을 평가하고 적절히 검증하기 위해서는 기존 동적 에너지 시뮬레이션보다 합리적이고 효율적인 시뮬레이션 모델이 필요하다고

18) 서원준, 박철수, 유진 프로그래밍과 BEMS 데이터를 이용한 실내온도 기계학습 모델, 대한건축학회 논문집, 2016, 23(6), pp.105-112.

판단하였다. 동적 시뮬레이션은 정밀한 건물에너지 및 시스템 성능분석이 가능하지만 많고 정교한 입력 값 선택이 필요하며 복잡한 입력구조와 확률적 미지의 변수들을 반영해야 한다.¹⁹⁾²⁰⁾ 이에 따라, 최근에는 시뮬레이션의 목적에 따라 유용하게 사용할 수 있는 시뮬레이션 Tool을 별도로 개발하여 사용하기도 한다.²¹⁾ 데이터센터에 적용되는 예측모델 및 제어알고리즘의 경우 데이터센터의 각종 환경변화에 대한 유연성, 확장성에 대응하여 목표값을 예측·제어하는 기능이 필수적이므로 이에 특화된 성능평가를 위한 별도의 시뮬레이션 모델이 필요하다고 판단되었다.

따라서 본 연구에서는 제어알고리즘의 입출력변수 평가를 위한 에너지 시뮬레이션 모델을 입력변수 조절 및 변환 가능하며, 수치해석과 프로그래밍 환경이 가능한 MATLAB 소프트웨어²²⁾로 개발하였다. 기존의 동적 에너지 시뮬레이션 프로그램에서 사용되는 이론을 차용하고 일반적으로 적용되고 있는 기본형 컨테이너먼트 데이터센터로 설정하여 대상 모델을 일반화하였다. 냉각 시스템은 본 연구의 대상 냉각 시스템인 중앙 냉수식 시스템 메커니즘을 적용하였다.

(7) 개발된 예측모델의 경우 입력 데이터에 의해 출력된 예측값과 실제 목표값의 오차 비교로 성능이 평가된다. ANN 기반 예측모델의 성능 우수성 및 타당성 확인을 위해 다양한 기계학습 기법 중 Gaussian process, Random Forest, Support vector machine로 예측정확도 및 연산시간을 통합 비교분석하는 과정을 수행한다. 예측정확도 성능 기준은 설정 온도와 예측온도의 오차평균 제곱근인 RMSE (Root Mean Square Error)와 평균

19) 라선중, 신한술, 서원준, 추한경, 박철수, 기존 건물 HVAC 시스템에 대한 다섯 가지 기계학습 모델 개발, 대한건축학회 논문집, 2017, 33(10), pp.69-77.

20) 박창봉, 사무소건물의 에너지절약형 냉방시스템 적용에 관한 연구, 박사학위논문, 중앙대학교, 2011.

21) 김석우, 에너지 시뮬레이션 기술 동향, 건축환경설비, 2015, 9(1), pp.22-30.

22) MathWorks, <https://kr.mathworks.com/>.

제곱근 오차의 변동계수인 $Cv(RMSE)$ (Coefficient of Variation of Root Mean Square Error)를 활용하여 예측 정밀도로 판단한다.

제어알고리즘은 예측모델이 기존 환경이 아닌 새로운 환경에 적용되었을 시 해당 환경에서 요구되는 실내 열환경을 제공하기 위해서 예측값에 대한 오차 수정 및 이에 적응하기 위한 재학습 과정이 포함되도록 구성된다. 제어의 안정성 및 정확성 평가 기준은 Max error와 RMSE로 판단한다. 제어알고리즘의 적응성 평가는 컨테이너먼트 규모에 변화를 준 새로운 시뮬레이션 모델에 다양한 설정 온도와 IT 발열 시나리오를 주어 CRAH 공급공기 온도가 설정 온도를 안정적으로 만족하게 하는지를 판단한다. 또한, 해당 상황에 대한 냉방부하를 확인한다. 여기서, 냉방부하는 냉각탑 제거 열량과 냉각 시스템에서 가장 많은 에너지소비량 비율을 갖는 냉동기에서의 제거 열량을 합산한 총 필요 제거 열량을 냉방부하로 대체하여 활용하는 것으로 한정한다.

최종적으로 ANN 기반 적응형 제어알고리즘의 적응성 및 확장성 검증에 위한 비교·분석 대상으로는 기존에 보편적으로 적용 중인 예측·제어 기술로 ON-OFF와 PID 모델로 설정하여 성능평가 및 검증을 수행하였다.

1.2.2 연구의 방법 및 구성

연구방법은 크게 5단계로, 데이터센터의 냉각 에너지 효율화에 대한 배경 및 중요성을 기술하고, 이에 따른 중앙 냉수 시스템이 적용된 컨테이너먼트형 데이터센터에서의 인공지능 기반 냉수유량 제어의 필요성을 1장에서 밝힌다. 이후 단계의 상세한 연구방법 및 본 논문의 구성은 다음과 같다.(Fig. 4)

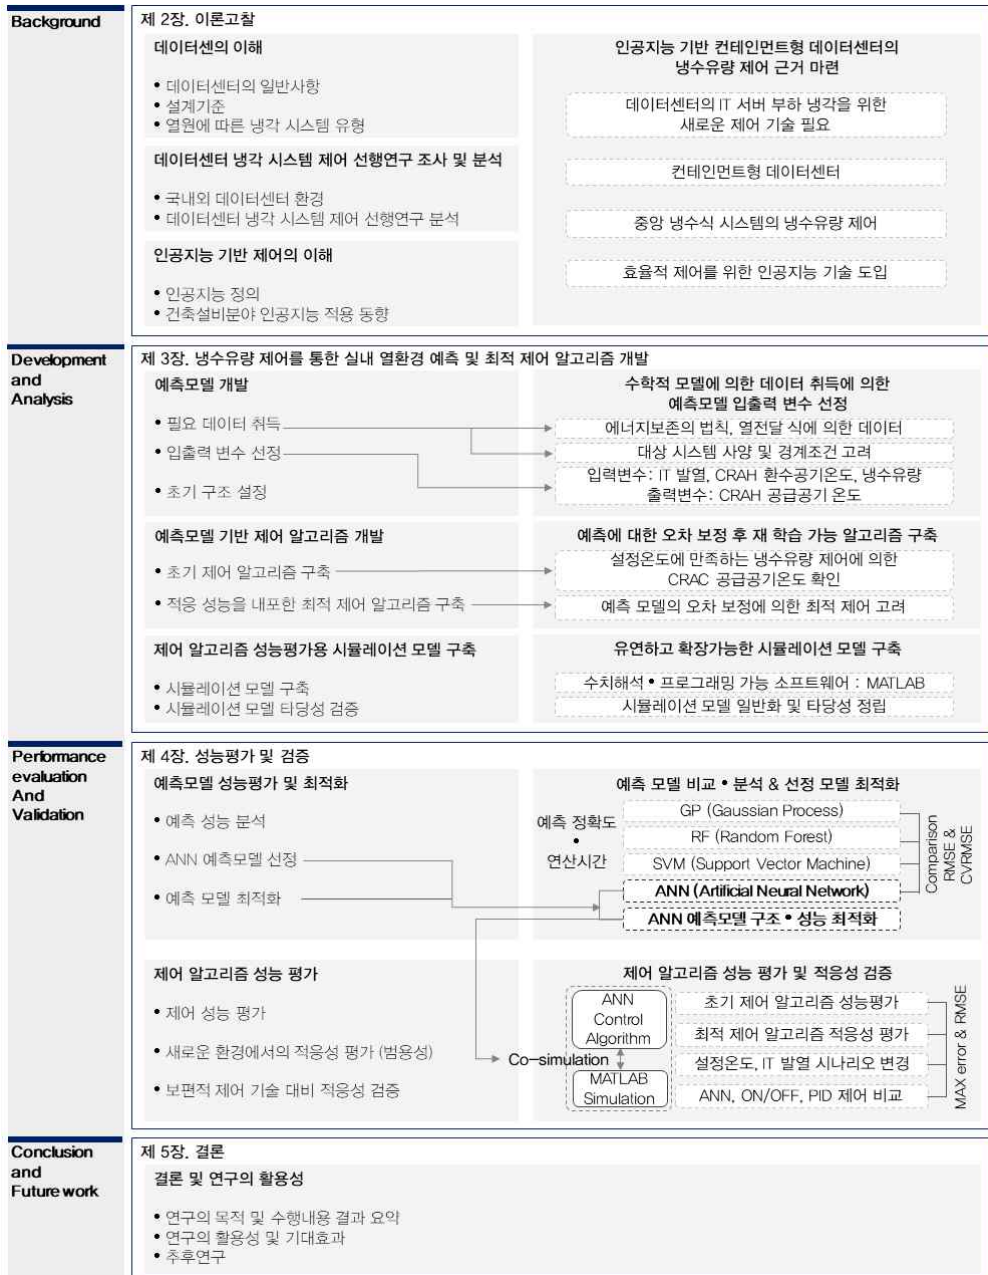


Fig. 4 연구의 흐름도

제 2 장 이론고찰

2.1. 데이터센터의 이해

2.1.1. 정의 및 구성

데이터센터는 해당 사업 분야의 컴퓨터, 네트워크, 스토리지, 그리고 비즈니스 운영 등 전자적 정보의 저장, 관리 및 보급을 위한 중앙 저장소이다. 한국 IT 서비스 산업협회는 ICT 장비를 집적시키고 통합·관리 가능한 솔루션, 시설, 인프라를 구축하여 24시간 365일 무중단으로 운영하는 시설을 데이터센터라 정의하고 있다.²³⁾ 데이터센터는 크게 서버, 스토리지, 네트워크 장비와 같은 IT 장비, UPS (Uninterruptible Power Supply System), 발전기 등의 전력시설, 항온항습기, 냉각탑 등의 공조 시설로 구성된다. Fig. 5는 데이터센터의 업무체계 개념이며 IT 서버의 운영환경을 유지 시키기 위한 설비시스템은 매우 중요한 부분이다.




Fig. 5 데이터센터의 구성 및 업무체계도

23) 데이터센터의 정의 및 분류체계, 한국IT서비스산업협회, 2008.



데이터센터는 사용 용도에 따른 공간 구분이 모호하기 때문에 데이터센터 전용으로 지어진 건물에 대해 전산장비가 사용하고 있는 IT 서버룸 면적을 바탕으로 전문 데이터센터와 일반 데이터센터로 구분된다. 또한 서버룸 면적, 서버룸 내부 IT장비 구성에 따라 규모가 크게 4개의 범위로 구분할 수 있다. Table 2는 규모에 따른 데이터센터의 구분이며 각각의 환경에 따라 적용되는 공기분배와 열원 시스템이 상이하다.

데이터센터 분류는 IT 서버룸이 차지하는 면적이 중요하지만 설비 시스템 관점에서는 일반 재실 공간과 운영시간 및 조건이 다른 IT 서버룸이 건물에서 차지하는 범위가 중요하다. Table 3과 같이 IT서버가 건물내 구성되는 범위에 따라서 설비시스템 방식이 달라진다. 본 연구의 대상은 대규모 데이터센터이기 때문에 서버냉각을 위한 설비시스템은 전용시설로 구성하는 것이 원칙이다.

Table 2. 규모에 따른 데이터센터 구분

구분	IT 서버룸 면적	서버룸 내부 IT장비 구성
소규모 전산실	-	• 랙 장비 1~5개 설치 • 또는 3~30 kW 전력소비 규모
소규모 데이터센터	93m ² (1,000ft ²)	• 랙 장비 5~20개 설치 • 또는 7~100 kW 전력소비 규모
중규모 데이터센터	93~465m ² (1,000~5,000ft ²) 이하	• 랙 장비 20~100개 설치 • 또는 28~500 kW 전력소비 규모
대규모 데이터센터	465m ² (5,000ft ²) 이상	• 랙 장비 100개 이상설치 • 또는 200 kW 이상 전력소비 규모

Table 3. IT서버룸 구성에 따른 데이터센터의 범위

IT 서버룸 구성	구성형태 및 구분	열원 시스템		비고
		개별	중앙	
	· 일반건물의 일부 공간에 서버룸 구성 · 소규모 전산실	우선 적용	불가능	일반건물내 컴퓨터실
	· 일반건물의 일부 층에 서버룸 구성 · 소/중규모 데이터센터	우선 적용	권장하지 않음	일반건물내 전산센터
	· 데이터센터 전용건물로 지원 시설을 제외한 나머지 모두 서버룸 구성 · 대규모 데이터센터	적용 가능	중앙식 적용시 반드시 전용 열원시스템 구성 요구	전용 데이터센터

2.1.2. 데이터센터 형태

데이터센터의 형태는 IT서버 배치 방식 및 관련시설과의 구성에 따라 룸단위(Open-Architecture), 구역단위(Containment), 모듈러(Modular) 세 가지로 Table 4와 같이 분류된다. 룸단위는 전산실 개방형으로 랙이 별도의 차폐시설 없이 전면과 후면이 마주보도록 열(Row)을 지어 배치된 형태이다. 일반적으로 이중마루 시스템에 구축되며 다수의 향온향습기(CRAC)가 서버룸의 환경을 통합적으로 제어한다. 난류에 의해 CRAC 회수공기 온도가 내려가 냉방 효율이 감소하며 서버실 환경의 구역별 제어가 불가능하여 IT 서버룸 전체의 공조·냉각에 대한 균일한 성능은 기대하기 어렵다. 룸단위 방식의 단점을 보완하고 냉각 효율을 높이기 위하여 구역 단위인 컨테인먼트 방식이 도입되었다. 컨테인먼트 방식은 냉복도(Cold Aisle)와 열복도(Hot Aisle)가 각각 분리된 공간으로

차폐 형태이다. 컨테인먼트 내부에는 CRAC 또는 CRAH가 함께 설치되며 내부 공기는 서버룸의 공기와 혼합되지 않아 데이터센터의 적정온도를 유지하며 냉각 효율을 극대화 시킬 수 있다. 모듈러 데이터센터는 컨테이너식 일체형 데이터센터로도 불리며 IT 장비, 전력, 냉각시스템이 하나의 모듈 안에 모두 집적된 형태이다. 단일 모듈로도 구동 가능하며 배치시간이 짧고 증설에 유리하다. 그러나 IT 용량 제한이 있고 제작비용이 고가이며, 각종 외부환경으로부터의 물리적 위험, 유지관리 시 보호받지 못하는 유해한 외부 요소에 노출되는 서비스 등에 대한 한계가 있다.

본 연구의 대상 데이터센터는 컨테인먼트 방식으로 냉복도, 열복도가 모두 차폐되며 열복도를 공유하는 구조이다. 데이터센터의 차폐구조 이점은 냉각시스템 온도를 높게 설정하여도 안전한 작동 온도로 부하를 제공할 수 있다는 점이다. 비차폐 주변 냉각시스템은 과열점을 방지하기 위해 IT 장비에서 필요한 수준보다 훨씬 낮게 온도가 설정되는데 과열점은 냉기가 냉각장치에서 토출되어 Rack 전면으로 이동하면서 생기는 열로 인해 발생한다. 차폐를 하면 냉각장치의 급기가 열기와 혼합되지 않고 IT 장비까지 갈 수 있다. 즉, 냉각장치의 급기 온도가 IT 장비에 이르는 온도와 동일하므로 IT 유입 공기의 온도를 일정하게 유지할 수 있다. 공기가 섞이지 않기 때문에 과열점을 걱정할 필요 없이 급기 온도를 높일 수 있으며 이에 따라 냉각시스템 효율성이 향상되어 에너지를 절약할 수 있다. 컨테인먼트 방식 차폐 구간별 이점은 Table 5 및 다음과 같다.²⁴⁾

24) John Niemann. Hot Aisle vs. Cold Aisle Containment, White Paper #135, Schneider Electric, 2008.

(1) 냉복도 차폐 (Cold Aisle Containment System, CACS)

CACS는 냉기 통로를 차폐함으로써 데이터센터 내부의 열기 흐름과 냉기 흐름이 분리된다. IT장비의 배출구에서 나오는 열기와 냉기가 섞이지 않도록 하여 IT 장비 입구의 온도를 일정하게 유지하도록 하는 역할을 하며 IT 장비의 급기구 온도는 CRAH에서 토출되는 냉기의 온도와 큰 차이를 보이지 않게 되어 CRAH의 토출구 온도를 장비의 급기온도와 비슷한 수준으로 설정하는 것이 가능한 장점이 있다. 이와 같은 방법으로 급기온도를 상향시키는 경우 CRAH의 냉각부하가 감소하고 외기냉각과 외기냉수냉각의 적용 가능 시간도 연장되며, 냉기의 손실 없이 급기가 가능하므로 실제적인 소요 풍량도 감소하여 공기 순환에 소요되는 송풍에너지도 감소하게 된다. 완전한 밀폐를 위해서는 랙과 랙 사이, 랙 내에 장착하는 서버 사이에서 냉기가 누출되지 않도록 하여야 한다.

(2) 열복도 차폐 (Hot Aisle Containment System, HACS)

HACS는 열기 통로를 차폐하여 IT 장비의 뜨거운 배기를 가두므로 데이터센터 내부의 열기 흐름과 냉기 흐름이 분리된다. HACS를 사용할 경우 Rack이 일관성있는 열기 통로/냉기 통로 배열로 구성되어야 한다. HACS는 고온의 열기가 열기 통로에만 갇혀 있기 때문에 비차폐 영역에서 근무하는 IT 직원들에게 영향을 주지 않는다. 또한 HACS에서는 보다 효율적으로 작동하는 CRAH를 사용할 수 있기 때문에 보다 높은 열기 통로 온도가 허용되는 점이 CACS와의 주요 차이점이다.

Table 4. 데이터센터 IT 장비 배치 별 분류


구 분	형태 및 특징
룸 단위 (Open-Architecture)	 • 서버룸에 열(Row)을 지어 랙이 배치된 형태 • 전면과 후면을 마주 보도록 배치 • 여러대의 CRAC 동시 서버룸 전체 공조
구역 단위 (Containment)	 • 냉복도(Cold Aisle)과 열복도(Hot Aisle)를 분리하여 차폐 • 내부에 랙, 항온항습기, UPS 등을 포함 • 전산실과 공기 혼합 없음
모듈러 (Modular)	 • ‘컨테이너식 일체형 데이터센터’로도 불리며 IT, 전력, 냉각시스템을 하나의 모듈 안에 모두 포함 • 짧은 배치시간, 확장성 높음 • IT 용량 제한으로 소규모 데이터센터에 유리

Table 5. CACS와 HACS 비교분석

항목	CACS	HACS	내용
효율성 향상	Yes	Yes	· HACS가 CACS보다 더 효율적임 · HACS는 일반적으로 실내의 나머지 부분에서 뜨거운 공기를 차단하기 때문에 더 높은 반환 온도에서 작동하기 때문
전체 데이터센터에 영향을 주지 않는 냉기 공급 설정온도 증가	No	Yes	· HACS의 냉각 설정온도는 편안한 작업 환경을 유지하면서 높일 수 있음 · CACS는 냉각 설정온도를 높이면 데이터센터 온도가 불편할 정도로 높아짐
외기냉방 사용 최대 이점 ²⁵⁾	No	Yes	· 냉각 설정온도 증가에 의한 외기냉방 증가에 기여 · 그러나, CACS의 설정온도를 높이면 외기냉방 관점에서 바람직하지 않은 실내온도가 증가 함
룸 중립 솔루션	No	Yes	· HACS의 배치는 'Drop in' (전용) 솔루션이며 CACS는 주변 데이터센터 인프라에 영향을 미침
실내 냉각을 위한 배치의 용이성	Yes	No	· CACS는 실내에서 반환 공기를 끌어들이는 자유 순환 시스템과 함께 실내냉각을 사용할 때 선호됨 · HACS는 특별한 반환 덕트 작업 또는 천장 플레넘이 필요함
고밀도를 위한 확장 능력	No	Yes	· CACS는 종종 2중바닥으로 구현되며 더 높은 밀도를 달성하기 위해 비효율적인 팬이 설치되는 바닥 타일이 필요함
룸 중립 설계	No	Yes	· HACS는 실내 중립적으로 컨테이너먼트 외부 온도에 영향을 주지 않음
Rack이 장착되지 않은 장비에 대한 악영향	No	Yes	· CACS를 적용하면 냉복도를 제외한 다른 공간은 온도가 높아 질 수 있음 · 차폐구역 외부의 장비가 고온에서 작동하는지 평가 필요함

25) 김세훈, 원종연, 이연구, 건물의 에너지 절약을 위한 외기냉수냉방 시스템에 관한 연구, 대한건축학회, 학술발표대회논문집, 2004, 24(1), pp.746-749.

2.1.3. 설계기준²⁶⁾

데이터센터의 IT서버는 연중 무중단으로 운전되기 때문에 고장 및 장비의 정지 등의 위험성을 내재하고 있다. 이러한 위험발생을 방지하기 위해 Table 6과 같이 ASHRAE TC 9.9에서는 IT서버를 사용하는 용도에 따라 환경기준을 구분하여 적용하고 있다. 실내 환경제어에 따른 등급구분은 온도, 습도를 위주로 적용수준과 적용용도에 따라 A1~A4, B, C로 6단계로 구분된다. IT서버 환경 조건은 등급이 높을수록 환경제어 수준이 엄격해진다. 이는 공조장비의 제어 및 운전이 더 정밀해야 된다는 것을 의미하기도 한다.

Table 6. IT서버의 환경 설계 조건

Class	Equipment Environmental Specifications for Air Cooling					
	Product Operations			Product Power Off		
	Dry-Bulb Temperature (°C)	Humidity Range (%), Non-Condensing	Maximum Dew Point (°C)	Dry-Bulb Temperature (°C)	Relative Humidity (%)	Maximum Dew Point (°C)
Recommended (Suitable for all 4 classes)						
A1-A4	18 - 27	60				
Allowable						
A1	15 - 32	20 - 80	17	5 - 45	8 - 80	27
A2	10 - 35	20 - 80	21	5 - 45	8 - 80	27
A3	5 - 40	8 - 85	24	5 - 45	8 - 85	27
A4	5 - 45	8 - 90	24	5 - 45	8 - 90	27
B	5 - 35	8 - 80	28	5 - 45	8 - 80	29
C	5 - 40	8 - 80	28	5 - 45	8 - 80	29

A1: 전형적인 데이터센터로 정밀한 제어 수행 요구. 기업 서버, 저장장치 등으로 구성.
A2: 사무실 또는 연구실로 A1 보다 제어의 정밀성 낮음. 소규모 서버, 저장장치, 개인 컴퓨터 등으로 구성.
A3: A1과 A2에 비해 온습도 기준이 완화됨. IT장비 구입 및 운영 중 발생 전력비용을 줄임.
A4: A1과 A2에 비해 온습도 기준이 완화됨. IT장비 구입 및 운영 중 발생 전력비용을 줄임.
B: 사무실 또는 가정으로 정밀성 떨어짐. 개인 컴퓨터, 워크스테이션, 노트북 및 프린터 등으로 구성.
C: 통신실, 사무실 등으로 통신장비, 라우터 등으로 구성.

26) ASHRAE TC 9.9, Thermal Guidelines for Data Center Processing Environments, 2011.

(1) 온도

IT장비가 냉각되지 못하고 높은 실내온도 또는 급격한 지속적으로 온도변화에 노출되면 에러(Error) 또는 셧다운(Shut down) 발생 가능성이 커진다. 냉각을 위해 IT장비로 유입되는 실내공기조건은 항상 관리되어야 하며 공조시스템 운전과 관련된 에너지 비용, IT 장비 유지관리, 교체비용 등 경제적인 측면을 고려하여 18~27℃의 범위로 권장되고 있다.

(2) 습도

높은 상대습도는 IT장비의 다양한 문제의 원인이 된다. 전도장애 및 먼지장애로 인하여 결로가 발생할 수도 있고 낮은 상대습도는 정전기 발생으로 인해 장비의 파손과 운영상 악영향을 준다. 그러나 대규모 데이터센터는 채실공간이 아니기 때문에 내부 수증기 발생원이 없고 외기도 소량이지만 완전히 처리하여 공급하기 때문에 습도에 대한 문제점은 거의 발생하지 않는다. 따라서 온도에 대한 관리를 더 중요하게 다룬다.

(3) 외피구성

데이터센터의 외피설계시 가압, 실 구획, 기밀유지와 결로 등 여러 설계변수들을 고려해야 한다. 데이터센터는 일반적으로 건물외피를 통해 외부의 오염된 공기가 유입되는 것을 방지하기 위해 가압을 한다. IT 서버룸의 출입구가 외부와 연결되는 경우 Air lock을 설치한다. 압력차 제어에 의한 변속 외기시스템은 침기를 최소화 할 수 있는 합리적인 방안이다. 데이터센터는 환경제어와 보안 등의 이유로 실 구획을 한다. 또한, IT 서버룸으로 공급되는 케이블과 배관의 인입구는 반드시 기밀을 유지하기 위해 내화재질로 매움작업을 실시한다. 한랭기후에서의 외부창호는 결로와 침기를 방지하기 위해 2중 또는 3중 유리 적용 및

출입구의 기밀을 철저히 유지한다. 대부분의 데이터센터는 결로 문제를 방지하기 위해서 무창형태로 설계 또는 리모델링을 한다.

(4) 소음

과거와 달리 최근 데이터센터 수요가 증가함에 따라 전력밀도와 발열의 증가로 IT 장비의 소음수준이 높아지기 때문에 데이터센터 설계자 및 장비 제조업체에 소음문제는 중요한 이슈가 되고 있다. 일반적인 데이터센터의 소음 수준은 청력에 영향을 줄 정도는 아니지만, 근무자의 수행능력, 생산성에 영향을 주기 때문에 적절한 조치가 필요하다. 이러한 목적으로 데이터센터에 설치되는 각각의 IT 장비 소음 기준을 정의하고 있다.

(5) 재실자 쾌적성

데이터센터는 일반적으로 재실 기간이 짧거나 일시적인 경우가 많이 때문에 실내 쾌적에 대해서는 특별한 설계기준은 없다. 그러나 장비의 발열에 의해 일부 구간은 높은 온도를 형성하는데, NIOSH²⁷⁾은 높은 실내온도에 대한 자세한 지침을 제시한다. 또 다른 관점은 IT 장비의 과열로 화재 등의 위험성을 두고 있다.

(6) 유연성

IT 기술이 변화함에 따라 데이터센터는 주어진 공간에서 장비의 신설 및 재배치가 빈번하게 발생한다. 이에 따라, HVAC 시스템은 반드시 이러한 조건에 대응할 수 있도록 유연성을 부여해야 한다. 또한 시스템 운전이 중단되지 않고 변경할 수 있도록 계획하는 것이 매우 중요하다.

27) Neil Rasmussen, Calculating Total Cooling Requirements for Data Centers, APC White Paper #25. 2003.

ASHRAE 기준 외에 국내의 한국IT서비스산업협회(ITSA)에서는 데이터센터의 에너지 사용 효율화를 지속적으로 유도하기 위해 2011년 11월 ‘그린 데이터센터 인증위원회’를 구성하여 그린 데이터센터 인증제를 추진하였다. 그린 데이터센터 인증 목적은 데이터센터의 지속적인 에너지 절감 활동 및 그린 활동 유도, 에너지사용량 및 운영경비 최소화, 에너지효율 향상을 위한 정책·운영체계·프로세스의 정립 도모, 경쟁력 강화이다. 인증 평가항목은 Table 7과 같다. 현재는 PUE 기반의 인증을 진행 중이나 점진적으로 PUE 이외의 다른 인증평가항목을 적용할 예정이다.²⁸⁾

Table 7. 데이터센터 IT 장비 배치 별 분류

평가항목	배점	평가내용	비고(참고사항)
DC 인프라 효율성	90	- PUE 점수	
DC 에너지효율관리 설비	3	- 전산전력량계로 모니터링 하는 비율 - 전력측정횟수 - 전산전력량 자료의 관리	- 전력관리 기능 및 HW/SW 도입 여부 - SW에 의한 절감효과
DC 그린활동	7	- 정부 및 공공기관의 인증이나 수상 이력 등 에너지 절감 활동에 대한 정성적 활동 반영 - 그린데이터센터 구축 지침에 따른 수준 진단 시행(KCS:KO-09.0082)	- 에너지위너상 등
IT 장비 효율성	-	- IT 장비의 에너지효율 등급 - 서버, 네트워크, 스토리지 등	- Energy Star - IDC 효율향상추진위의 그린 장비 인증 활용
건물의 친환경성	-	- 건물의 에너지효율성 - 건물의 친환경성	- LEED 인증평가항목 - 녹색인증제 등
DC 생산성	-	- 산출물/투입에너지	- 데이터센터 에너지 생산성

28) 정상진, 김문구, 그린 데이터센터 표준화 및 인증제 동향, TTA 저널, 2013, 145, pp. 76-82.

2.1.4. 열원에 따른 냉각시스템 유형²⁹⁾

데이터센터의 IT서버 발열을 제거하기 위한 설비시스템은 서버로의 냉각 공기의 공급 및 외부로 가열 공기를 방출시키는 공기분배시스템과 공기를 공기 냉각을 위한 CRAH 또는 CRAC에 열원을 공급하는 열원 시스템으로 구분된다. IT서버 발열을 외부환경으로 방출하는 냉각방식은 크게 5가지로 분류되며 각각의 방식은 냉동사이클을 이용하여 물 또는 냉매 등 열매체 순환을 포함한다.

(1) 중앙 냉수식 시스템

중앙 냉수식 시스템은 IT환경 내의 CRAH 또는 CRAC과 냉동기를 통해 순환된다. 냉동기는 냉수를 생산하여 CRAH·CRAC에 공급한다. 실내에 설치되는 CRAH는 CRAC과 외관상은 유사하나 기능에서 차이가 있다. 냉동기에서 공급된 냉수가 순환하는 냉수코일을 통해 IT환경의 가열된 공기를 냉각시키는 개념으로 CRAC과 같이 열교환기나 압축기를 포함하지 않는다.

- 장점: CRAH는 일반적으로 비용이 저렴하고 필요 부품 수가 적으며 열 제거 용량이 더 크다. 하나의 냉각장치에서 많은 IT환경에 냉각 서비스를 제공할 수 있으며 매우 안정적으로 설계할 수 있다. 외기온도가 시스템에 미치는 영향이 적어 안정적 운전이 가능하고 중앙 집중관리에 용이하여 대규모 데이터센터에 적합하다.
- 단점: CRAH는 일반적으로 CRAC 보다 데이터센터 공기에서 더 많은 수분을 제거하므로 여러 기후에서 실내 가습에 더 큰 비용을 투자해야 한다. 초기 투자비용이 크고 용량 증설에 제약이 따른다.

29) Tony Evans, The different types for air conditioning equipment for it environments, APC white paper #59, 2004.




Fig. 6 중앙 냉수식 시스템 개념도

<출처> Tony Evans, op. cit., pp. 8

(2) 수냉식(냉각수) 시스템

수냉식 시스템은 모든 냉동사이클 요소가 실내의 CRAC에 구성되며 냉각수 순환에 의해 냉각탑을 사용하여 IT환경 내 발열을 제거한다. 일반적으로는 IT환경 냉각을 위한 전용 시스템으로 적용되지 않으며 재실을 위한 공조시스템과 연계하여 사용한다.

- 장점: 하나의 냉각탑에서 많은 전산실의 냉각 및 기타 장치에 냉각 서비스를 제공한다. 외기온도가 시스템에 미치는 영향이 적어 안정적인 운전이 가능하다.
- 단점: 초기 투자비 및 유지관리비용이 많이 들고 압축기 내장형으로 소음이 증가하며 별도의 누수 시스템이 필요하다.




Fig. 7 수냉식(냉각수) 시스템 개념도

<출처> Tony Evans, op. cit., pp. 7

(3) 글리콜 냉각시스템

글리콜 냉각시스템은 열교환기가 적용되며 냉동사이클 부속장치가 CRAC에 모두 구성된다. 서버발열은 수냉식 응축기에 전달되고 글리콜용액은 응축기를 통해 순환되며 드라이쿨러를 통해 열을 제거한다. 글리콜용액은 공기에 비해 열전달 능력이 우수하기 때문에 열교환기 및 글리콜배관은 공랭식 시스템의 응축코일 보다 작다.

- 장점: 배관거리에 제약이 적고 수리 및 점검이 용이하다. 하나의 냉각기 및 펌프 패키지에서 여러 전산실의 냉각장치에 서비스를 제공 할 수 있다.
- 단점: 다른 냉각시스템과는 달리 이코노마이저 시스템 적용에 제약이 따른다. 추가로 필요한 펌프 및 밸브 패키지는 공랭식 직팽식 시스템과 비교할 때 설치비용을 증가시키고 글리콜의 양과 품질이 중요하다.




Fig. 8 글리콜 냉각시스템 개념도

<출처> Tony Evans, op. cit., pp. 6

(4) 공랭식(직팽식) 냉각시스템

공랭식(직팽식) 시스템은 중, 소규모 데이터센터에 가장 많이 적용된다. 냉동사이클은 CRAC과 실외기에서 이루어진다. 실내기와 실외기 사이의 냉매순환은 배관을 통해 구성되며 열펌프 원리에 의해 실외로 열을 방출한다.

- 장점: 냉각시스템 중 가장 낮은 설치 및 운영비용이 소요되며 유지관리가 쉽다.
- 단점: 초기 투자비용이 높다. 현장에 냉매 배관이 설치되어야 하며 IT현장과 실외환경 사이의 거리와 높이 변화를 신중하게 고려하여야 한다. 하나의 공랭식 응축기에 여러 전산실에 냉각 서비스를 제공할 수 없다.




Fig. 9 공랭식(직팽식) 냉각시스템

<출처> Tony Evans, op. cit., pp. 4

(5) 일체형 공랭식 냉각시스템

공랭식 냉각시스템은 냉각 사이클에 필요한 모든 요소가 실내유닛에 포함된다. 실내 발열은 응축코일을 통과한 공기의 배출로 제거되며 응축을 위한 공기의 유입과 배출은 덕트로 이동된다. 응축을 위한 공기유입 덕트 면적 및 길이증가에 한계가 있어 최대 냉각용량은 15 kW미만, 국내에서는 거의 적용되지 않는 시스템이다.

- 장점: 초기 투자비용이 낮고 별도의 기계실이 불필요하다.
- 단점: 배관 거리에 제약이 있고 다른 냉각시스템보다 장비 당 열 제거 용량이 적다.

2.1.5. 에너지효율평가 기준

데이터센터의 에너지효율을 측정하기 위해 많은 방법론이 대두되었지만, 현재로서는 미국 Green Grid에서 2008년 초 공표한 PUE (Power Usage Effectiveness)를 지표로 보편적으로 사용되고 있다. PUE는 Fig. 10³⁰⁾과같이 데이터센터 전체가 사용하는 에너지와 IT 장비가 사용하는 에너지의 비율로 표시되며, 데이터센터 설비의 에너지효율을 평가하는 데 주요 목적이 있다. PUE의 값이 1에 가까이 갈수록 데이터센터의 에너지효율이 높다고 할 수 있다.³¹⁾ PUE를 낮추려는 방법으로 고효율 서버 장비 도입, 장비 배치의 최적화, 공조시스템의 효율화, 배터리 측정 시스템의 운영, 가상화 기술 등이 있다.




Fig. 10 데이터센터 에너지효율평가 기준 PUE

30) The Green Grid, Technical Committee White Paper, 2010.

31) 정상진, op. cit., pp. 78.

2.1.6. 데이터센터의 에너지 소비 현황

데이터센터의 수요는 인터넷 사용 증가 및 IT 산업 활성화에 따라 지속적으로 증가하고 있다. 데이터센터의 전기소비량은 2010년 전 세계 전기에너지 소비량의 약 1%를 차지하였으며 2030년에는 3~13%까지 확대될 것으로 예측되고 있다.³²⁾ 국내 데이터센터는 매년 5.9% 증가하여 2019년 기준 158개소에 달한다.³³⁾ 2015년 기준 국내 데이터센터에서 소비한 전력량은 26.5억 kWh로 추정되며, 이는 국내 총 전기 소비량(483,655GWh)의 0.55%에 달한다.³⁴⁾ 한국전자통신연구원(ETRI)의 ‘데이터센터 지속 가능성 표준화 이슈 현황’에 따르면, 데이터센터는 정보통신(ICT) 부문 전체 전력사용량의 약 20%를 차지한다.

미국에서는 건물 내에 데이터센터 구축 여부에 따른 건물에너지 사용량을 비교하였는데, EIA (미국 에너지 관리청, Energy Information Administration) 가 상업용 빌딩 대상 에너지 소비 조사의 결과를 분석한 자료에 따르면 데이터센터를 갖추고 있는 빌딩이 더 많은 에너지를 소비하는 것으로 나타났다. (Fig. 11)³⁵⁾ 데이터센터를 보유한 건물이 미보유 건물보다 에너지 원단위가 최대 87%가량 더 큰 것으로 나타났다. 데이터센터 특성상 24시간 무중단 운영이며 서버과열 방지를 위한 냉방이 동시에 이루어지기 때문에 상당한 전력이 소비되기 때문이다.

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

33) 송준화, 송명호, op. cit., pp. 10.

34) 한국에너지공단, 데이터센터가 건물부문 에너지 원단위에 미치는 영향, 주간 에너지 이슈브리핑, 2016, 151.

35) Commercial Buildings Energy Consumption Survey (EIA).




Fig. 11 데이터센터 보유 여부에 따른 에너지 원단위 비교

데이터센터의 전체 전력소비량 중 서버의 발열을 식히는 냉각 시스템에서 약 50%가량의 가장 많은 전기를 소모하고 있다. 따라서 서버냉각 에너지를 줄이는 것이 전체 에너지 소비를 줄이는 최선의 방안이 될 수 있다. 미국 기업 Intel에 따르면 데이터센터 실내 설정 온도가 1℃ 상승하면 냉각비용은 4% 감소하는 효과를 가져온다. 실내 설정 온도를 5℃ 상승하여 운영할 경우 연간 21억 6천만 달러의 전력비용을 줄일 수 있다. 즉, 전력소비량의 8%가 감소하여 243억 kWh를 절약할 수 있다. 이는 스페인, 남아프리카, 호주, 대만의 1개월 에너지소비량을 모두 합친 것보다 많으며 탄소 절감효과는 170만 Metric Ton (M/T)에 달하고 4천 300만 그루의 나무가 10년 동안 흡수할 수 있는 이산화탄소이다.³⁶⁾

데이터센터의 냉방부하 발생에 가장 큰 부분을 차지하는 IT 서버의 발열량이 증가하면 데이터센터의 환경유지를 위한 냉각 시스템의 용량 및 기준이 변하게 된다. 따라서, IT 서버의 부하 특성을 고려하여 냉각

36) ZD Net Korea, 세계 데이터센터 온도가 5도 올라가면?, 2011. <https://zdnet.co.kr/>, (access: 2020.09.07.).

시스템을 계획하여야 한다. 미국의 데이터센터용 장비 및 서비스 제공업체인 Emerson Network Power³⁷⁾의 보고서에 의하면 Fig. 12와 같이 대표적인 업무용 데이터센터의 일일 IT서버 가동률은 대략 오전 5시부터 오전 11시까지 점차 증가하다가 오후 5시부터는 떨어지기 시작한다. IT서버와 네트워크 장비 간의 사용패턴은 일간 및 주간별 트래픽으로 보면 Fig. 13과 같이 야간 시간대인 오전 1시부터 다음날 오전 9시에는 주간 시간대에 비해 현저히 낮아짐을 볼 수 있다. 네트워크 트래픽은 IT 서버의 가동률과 비례하기 때문에 저녁 시간에 증가하여 피크가 되는 부분을 제외하고는 비슷한 경향을 보인다고 할 수 있다. 트래픽이 낮아지면 서버의 가동률이 상대적으로 피크때에 비해 줄어들어 발열 부하가 감소하게 된다. 주간 사용패턴은 주말에 다소 낮아지기는 하나 전체적으로 일정한 패턴으로 균일한 부하가 발생하는 것으로 나타났다. (Fig. 14)³⁸⁾




Fig. 12 데이터센터 일간 IT 서버 일일 가동률

37) Emerson Network Power, Energy Logic: Reducing Data Center Energy Consumption by Creating Savings that Cascade Across Systems, A White Paper from the Experts in Business-Critical Continuity, 2008.

38) 조진균, op. cit., pp. 49.




Fig. 13 데이터센터 일간 시간대별 트래픽 현황




Fig. 14 데이터센터 주간 트래픽 현황

데이터센터의 냉각 에너지 효율화를 위해서는 데이터센터의 용도 특성상 IT 서버발열량 조절은 불가능하므로 전산장비 배치 최적화, 냉각 설비시스템 최적화, 최적 온도 기준 설정을 통한 냉방 효율화 등의 방법을 활용해야 한다. 그러나 데이터센터의 무중단 운영의 특성상 리모델링 및 보수가 어렵고 설계 시 공간과 구조의 제약이 많으며 고비용이 소요되므로 기계 설비적 해결방안에는 한계가 존재한다. 그뿐만 아니라 서버냉각에 필요한 냉각 장비들의 설계가 효율적으로 실시 되어도 서버부하 변화에 대응할 수 있는 제어가 적절하게 되지 않으면 에너지

낭비가 발생할 수밖에 없다. 따라서, 고효율 설비 장비와 같은 하드웨어적 접근만으로는 더이상 데이터센터의 서버냉각을 효과적으로 해결할 수 없기에 이보다 효율적인 제어 방안 마련이 필요하다.

2.2. 데이터센터 냉각시스템 제어 선행연구 조사 및 분석

2.2.1. 국내·외 데이터센터 환경 분석

데이터센터의 냉각시스템 에너지효율화 연구를 위해 국내·외 데이터센터의 실제 적용사례를 분석하였다. 데이터센터는 보안상의 문제로 사례의 상세정보는 공개하지 않고 있어 본 논문에서의 사례는 문헌 및 통계자료를 참고하여 상세정보가 공개되어있는 일부 데이터센터에 한하여 분석하였다. 주요 조사내용은 실내 온·습도 등 주요 IT 환경 조건과 열원 시스템의 설비시스템을 중심으로 정리하였다.(Table 8)

국내 데이터센터의 열원 시스템은 중앙 냉수식을 가장 많이 적용하고 있는 것으로 조사되었다. 또한, 컨테이너먼트 방식으로 구축되고 있는 흐름을 확인할 수 있었다. 조사된 데이터센터는 에너지 절감형의 대표적인 사례로 대체로 PUE가 낮지만 Fig. 15와 같이 국내 평균 PUE는 정부, 공공, 민간 통합 2.03으로 특히 공공, 지자체의 PUE가 3.13으로 국외 PUE 1.70 대비 에너지효율이 낮은 것이 현실이다.³⁹⁾⁴⁰⁾ ‘NHN DC’의 경우 국내에서 최대 에너지효율을 보이는 최신 데이터센터로 외기냉방시스템에 고압수 분무 기능을 추가하여 증발냉각을 통한 냉각 및 가습을 통해 시스템의 장점을 극대화 시켜 PUE 절감을 달성한 사례이다.⁴¹⁾

39) 배용진, 한국은 데이터센터 각축장, 글로벌 기업 속속 들어오는 이유, 2019.

40) 한국건설생활환경시험연구원, PUE 1.3x급 구현을 위한 에너지 절감 통합 솔루션 및 설비 모듈 개발, 산업기술혁신사업 계획서, 2018.

국외 데이터센터는 국내와는 달리 지리적으로 한랭지역에 위치한 데이터센터는 외기냉방 시스템을 적극적으로 적용하였고 기계적 열원 시스템을 보조 냉각기로 가동 중이다. 조사된 데이터센터 외에 페이스북, 구글 등 대표적인 세계기업들은 핀란드, 노르웨이 등 한랭기후 데이터센터를 지속해서 신설해오고 있다. 100% 외기냉방으로 냉동기가 없는 데이터센터는 PUE 1.2 이하로 유지하고 있다. 페이스북 데이터센터가 PUE 1.07로 국외 최대 효율을 가지며 구글은 해수를 이용한 냉각방식과 외기냉방을 겸용으로 운영하는 등 다양한 신기술이 적용되고 있다. 국내에서는 2025년까지 32개의 데이터센터를 신규 구축할 전망이다. 신축 데이터센터는 PUE 1.4 수준으로 계획되고 있으며 정부·공공 데이터센터 5개, 민간 데이터센터 27개 신규 구축 예정이다. 이 가운데 3개는 자사 서비스 제공을 위해, 24개는 상업용 목적으로 데이터센터를 설립할 예정이다.⁴²⁾

Table 8. 국내·외 에너지효율화 데이터센터 개요 및 주요 적용기술

구분	PUE	연면적 (㎡)	준공 년도	주요 적용기술 (공조냉각)						비고
				실내조건 완화		컨테인 먼트	외기냉방		외기 냉수 냉방	
				온도	습도		직접	간접		
IBM RTP (Carolina, 미국)	1.40	9,300	2009	●	●	●	●		인버터 냉동기	
Citi FF (Frankfurt, 독일)	1.30	20,000	2009	●	●	●			●	
HP (Wynyard, 영국)	1.20	33,500	2009	●	●	● (Hot)	●			한랭 기후 냉동기 X
Micro Soft (Dublin, 아일랜드)	1.25	49,500	2009	●	●	● (Cold)	●			한랭 기후
Facebook (Oregon, 미국)	1.07	31,000	2011	●	●	● (Hot)	●			한랭 기후 냉동기 X

41) 연창근, 이진영, 네이버 데이터센터 ‘각’, 건축환경설비, 2019, 10(3), pp.51-57.

42) 김지선, 이슈분석, 2025년 아태지역 IDC 2위 시장으로 부상, 2020.

Google (Hamina, 핀란드)	1.22	8,000	2011	●	●	● (Cold)	●			한랭 기후 (해수활용)
Sakura Internet (Hokkaido, 일본)	1.11	11,400	2011	●	●	● (Hot)	●			한랭 기후 냉동기 X
NTT TK N5 (Tokyo, 일본)	1.45	13,300	2011	●	●	● (Cold)				공랭식 CARC
롯데정보통신 (가산, 한국)	1.79	10,800	2007	○	●	●	● 일부			수냉식 CARC
LG CNS (상암, 한국)	1.78	43,800	2007	○	○					지역 냉수 사용
KT (목동, 한국)	1.68	63,000	2008	○	●				●	중앙 냉수식
교보/IBM (송도, 한국)	1.70	11,000	2009	○	●				●	수냉식 CARC
SK C&C (일산, 한국)	1.70	30,700	2010	○	●	●			●	중앙 냉수식
KT 클라우드 (천안, 한국)	1.40	3,000	2010	●	●	● (Cold)	● 일부			
LG CNS (부산, 한국)	1.40	32,400	2013	●	●	●	●			중앙 냉수식
NHN DC (춘천, 한국)	1.30	47,800	2013	●	●	● (Hot)	●			중앙 냉수식
삼성 SDS DC (상암, 한국)	1.38	82,000	2015	●	●	● (Cold)		●	●	지역 냉수 사용

●: 정확한 기준 및 범위 적용 / ○: 한정적 범위 적용




Fig. 15 글로벌 주요 데이터센터 에너지효율(PUE) 수준

2.2.2. 데이터센터 공조제어 선행연구 분석

데이터센터는 IT 장비 기술이 발전함에 따라 새로운 기준 정립이 필요하게 되었다. 최근 대규모 고밀도 데이터센터 관련 기준 연구로 미국을 중심으로 활발하게 진행되고 있다. 에너지성, 국방성 등의 정부 기관과 ASHRAE (미국공조냉동협회), USTC (미국열관리협회), Green Grid, The Uptime institute 등 일반 단체에서 활발하게 이루어지고 있다. 그러나 대부분 IT 장비를 중심으로 연구되었으며 서버의 냉각을 위한 공조시스템의 구체적인 연구는 활발히 진행되지 않았다. 이 외에도 장비회사 중심으로 지속적으로 발간되고 있는 백서에서 공기분배 시스템, 열원 시스템에 대한 부분까지 다루어지고 있지만 한정적이다.⁴³⁾

IT장비가 데이터센터 대부분을 차지하고 있으므로 IT 장비에 대한 특성 및 발열 연구는 다수 진행되었지만, 서버냉각을 위한 관련 공조시스템 연구는 필요에 따라 부분적으로 연구되어 현재까지는 IT 장비 연구 대비 연구의 성과가 다양하지 못한 것으로 판단된다. 따라서, 본 논문의 주요 목적에 밀접한 관련이 있는 선행연구 분석이 필요하다. 선행연구 분석을 통해 이론적 지식을 습득하고 연구 동향 파악 및 본 논문의 연구 방향을 설정에 활용하고자 하였다.

데이터센터 공조제어 관련 선행연구 분석내용은 Table 9와 같다. 선행연구 분석 시 주제별로 크게 세 가지로 냉각시스템, 냉각 에너지, 예측·제어로 나누어 분류하였다. 국내의 경우 냉각시스템 연구 분야에 비중이 높았다. 주로 외기냉방 시스템 개선을 통한 냉방에너지 절감 도모를 다루며 기존 데이터센터 대비 7%부터 최대 90% 이상의 절감을 확인하였다. 냉각 에너지 부문에서는 데이터센터 부하 패턴 분석 및 에너지소비량을 산정하는 연구와 열성능에 대한 시뮬레이션 연구가

43) 조진균, op. cit., pp. 4.

조사되었다. 예측·제어 분야에서는 컨테인먼트형 데이터센터에서의 냉매유량 예측·제어에 의한 온열환경 분석 연구가 최근 수행된 것으로 분석되었으나 타 분야에 비해 극히 적은 연구 건수로 확인되어 데이터센터의 냉방에너지 절감 연구는 많이 부족한 것으로 판단된다.

국외 선행연구의 경우 모든 분야에서 국내대비 다수의 연구가 진행되고 있었으며 특히, 예측·제어 분야에서 확연히 높은 비중으로 연구가 수행되고 있는 것으로 조사되었다. 데이터센터의 열환경 및 에너지 예측·제어 기술로 ANN, Fuzzy 등 머신러닝 모델 적용을 통해 에너지소비량 또는 PUE 절감 달성을 목표로 하는 연구가 다수 분석되었다. 해당 연구들로부터 기존 데이터센터에 제어기술로 적용되던 PID 모델 대비 기계학습 모델 적용 시 안정적으로 설정온도에 적응해나가는 제어 가능성을 확인하였다. 그러나, 다양한 예측·제어 모델의 모든 데이터센터에 적용 가능한 일반화 및 적응성에 대해 심도있게 다룬 연구는 부족한 것으로 사료된다.

선행연구 조사결과 국내의 경우 국외에 비해 연구 주제가 다양하지 못하고 냉각시스템 분야에 치중되어 연구가 진행되고 있음을 확인하였다. 또한, 제어방법에 있어서 신기술 접목이 약하고 대부분 동적 시뮬레이션에 의한 실험적 연구에 그쳤다. 반면 국외의 경우 다양한 분야에서 데이터센터의 에너지 절감을 목표로 연구가 진행되고 있으며 기계학습, MPC, 인공지능경망 등의 최신 기술을 적용하여 하드웨어적인 솔루션 제공에서 나아가 소프트웨어적인 접근으로 연구가 진행되는 추세로 확인되었다. 지금까지는 국내·외 많은 기관에서 데이터센터의 공조제어와 관련된 문제를 해결하기 위한 노력이 진행중에 있으나 냉각 장비단위와 일부 데이터센터에 국한되어 평가가 이루어지고 있기 때문에 다양한 데이터센터에 적용 가능한 적응성을 가진 솔루션으로의 접근은 한계가 있었다.

따라서, 건축환경 및 설비, 건물 예측·저용 제어 분야에서 데이터센터의 공조효율 및 에너지 성능개선을 주제로 수행한 연구는 한정적인 것으로 나타나 ‘데이터센터의 에너지 성능향상을 위한 지능형 공조제어알고리즘 개발’이 목적인 본 논문의 시의성 및 중요도가 매우 높다고 사료된다. 또한, 본 논문은 선행연구결과에서 나타난 예측·제어기술의 일반화 및 적응성의 한계를 보완하여 연구를 진행하고자 하였다.

Table 9. 데이터센터 공조제어 선행연구 분석

대분류	저자	내용
냉각시스템	Jin-kyun J. et al. 2009. ⁴⁴⁾	- 고밀도 데이터센터의 공조효율 및 에너지성능 개선을 위한 공조시스템 계획방법 연구. - CFD 시뮬레이션 활용 다양한 계획방법에 대한 공조효율 개선 확인.
	Sung Woo P, et al. 2009. ⁴⁵⁾	- 데이터센터에서의 에너지 절약을 위한 유비쿼터스 센서 네트워크 기반의 적응적 분산 냉각 전략 연구. - 제안 전략에 의해 최대 22.8% 에너지 절약 확인.
	Seung-yeon L. et al. 2011. ⁴⁶⁾	- 데이터센터 냉방에너지 절감을 위한 외기냉방 시스템 개선. - 개선된 외기냉방 시스템에 의한 7% 냉각 에너지 절감 확인.
	Min-Hwi K. et al. 2013. ⁴⁷⁾	- 데이터센터 냉방을 위한 제습 증발냉각시스템의 적용성 분석. - 증발냉각 및 고온수 냉각시스템 적용 시 기존 데이터센터 대비 냉방에너지 보시전력 90% 이상 절감 확인.
	Jung In Y. et al. 2014. ⁴⁸⁾	- 데이터 센터의 외기냉수냉방 시스템에 대한 에너지 절감효과 분석. - 드라이쿨러를 적용한 외기냉수냉방 시스템으로 기존 데이터센터 대비 약 15% 에너지 절감 확인.
	Je Young K. et al. 2014. ⁴⁹⁾	- 멀티 외기냉방을 이용한 데이터센터의 에너지절약 시스템 개발. - 시뮬레이션에 의한 멀티 외기냉방 시스템 적용 시 26.7% 에너지절약 효과 확인.
	Alkharabsheh,	컨테이너먼트 시스템, 이코노마이저, 하이브리드

	et al. ⁵⁰⁾ 2015.	냉각시스템 수냉식 냉각 기술 등 최신 기술 검토. • 데이터센터 열환경 관리에 직면한 문제 확인. 에너지 절약을 위해서는 스마트 제어시스템 적용 및 부하 예측 등 통합 제어 필요성 확인.
	Zhang. et al ⁵¹⁾ . 2016.	• 공랭식, 수냉식 냉각시스템 인프라 관리. • 데이터센터 냉각 기술의 하이브리드 솔루션 통합은 에너지효율을 향상시키는 방법임을 확인.
	Darehmeh, et al. ⁵²⁾ 2017.	• 데이터센터의 Airside & Waterside 이코노마이저 및 히트 파이프 기술을 포함한 외기냉방의 장단점 비교. • Pulsating heat pipes(PHPs)가 데이터센터 외기냉방에 가장 효과적인 것으로 확인됨.
	Ni, et al. ⁵³⁾ 2017.	• 데이터센터 100곳의 공조 에너지 성능 분석. • PUE 평균 1.44로 조사되며, 데이터센터의 냉각시스템 절반 이상이 비효율적인 것으로 분석 됨.
냉각 에너지	C.B. Bash, et al. ⁵⁴⁾ 2006.	• 기존 CRAC의 분산된 센서 네트워크 설치로 데이터센터 실내환경 개선. • CRAC 토출온도 및 풍량 제어로 냉방 에너지 50% 절감.
	Monem H. Beitelmal, et al. ⁵⁵⁾ 2006.	• 중앙냉수시스템의 모델링 실시, 에너지 사용량 및 COP 도출. 정유량 및 변유량 냉동기 사용 에너지 비교로 관리자가 선택할 수 있음. • 정유량 대비 변유량 냉동기가 부분부하에 대응 가능하여 데이터센터에 유리함.
	Jin-kyun J. et al. 2007. ⁵⁶⁾	• 최적 IT 환경제어를 위한 데이터센터 부하패턴 분석 및 에너지소비량 산정. • IT 서버의 발열량이 대부분의 내부부하를 발생시키므로 외기온도 변화는 실내부하변동에 큰 요소가 되지 않음. 단위면적당 서버 구성에 따라 연간 부하발생량은 5,800~17,800 kWh/m².
	Yuan Chen, et al. ⁵⁷⁾ 2010	• 데이터센터 에너지 절감을 위한 IT장비 관리와 냉방 시스템 통합 관리 시스템 구축. • IT부문 35%, 냉방 부문 15% 에너지 절감 달성.
	Sang Woo H. et al. 2015. ⁵⁸⁾	• 컨테이너먼트가 적용된 데이터센터의 CFD 모델링 기법 및 열 관리 성능평가. • 컨테이너먼트 적용만으로는 열성능이 우수하다고 할 수 없으며 누기 혹은 급기 타일과 같은 실내 중요 물리적 특성이 충분히 고려되어야 할 것임.
예측·제어	Zhihang. et al. ⁵⁹⁾ 2013.	• 데이터센터 열환경 예측을 위한 ANN 온도 예측모델 개발. 유전알고리즘에 탑재 후 최적 온도 산출 • ANN 모델은 변경된 조건에 대해서 적응

		해나가며 안정적으로 온도를 예측 함.
Junwen. et al. ⁶⁰⁾ 2014.		• Fuzzy 제어 활용 PID 계수를 자가보정이 가능한 PID type Fuzzy Adaptive Control 모델 개발. • 기존 모델 대비 개발 모델이 안정적으로 제어 함.
Jim ⁶¹⁾ , 2014.		• 머신러닝의 순전파 학습을 통한 PUE 예측. • PUE 예측 오차 0.4% 이내로 달성 함.
Baptiste ⁶²⁾ , 2014.		• 데이터센터 냉방 시스템에서 에너지에 영향을 줄 수 있는 다양한 인자를 종합적으로 고려하여 온도 제어알고리즘 개발 • 최적 설정온도 설정에 대한 중요성 확인
Dong. et al. ⁶³⁾ 2016.		• 냉각수 환수온도 예측에 의한 외기냉방시스템 제어. • 냉각수 환수온도 예측 방법이 이코노마이저 모드 가동 시간을 증가시켜 에너지소비량 절감.
Marina. at al. ⁶⁴⁾ 2016.		• Grammatical Evolution 기법 활용 열환경 예측모델 개발. • CPU와 서버 입구 온도 각각 2℃, 5℃미만의 예측 오류로 높은 예측성능을 확인함.
Dayarathna. et al. ⁶⁵⁾ 2016.		• 데이터센터 에너지소비 모델링 분석. 전반적인 데이터센터 부문에서의 에너지소비 비율 조사. 기계학습을 이용한 에너지소비 모델링 설문조사. • 200곳 이상의 데이터센터 모델 조사 결과, 고밀도 데이터센터에 대한 연구는 극히 적은 편. 대부분 연구의 정확성, 일반성, 실용성은 여전히 연구대상임.
Alessandro. et al. ⁶⁶⁾ 2017.		• 외기냉방시 CRAC 제어 모델 개발 • 데이터트리븐 방식 모델링 실시. 예측모델 적용시 전력소비량 최소화 달성.
Bhattacharjee. et al. ⁶⁷⁾ . 2017.		• 데이터센터의 효율적 자원 관리를 위한 그린 클라우드 네트워크 구축을 위한 기술 조사. • 예측모델과 CPS를 활용하여 데이터센터 운영 기록 분석 및 향후 동작 예측의 가능성 확인.
Leehter. et al. ⁶⁸⁾ 2019.		• 인공지능경망 활용 온도 & 에너지 예측모델 개발. • 개발 모델에 의해 여름, 겨울 각각 19.6%, 23.4% 에너지 절감 달성.
Qui. et al. ⁶⁹⁾ 2019.		• 서버 발열 냉각을 위한 MPC 기반 CRAC 온도 및 에너지 최적화 모델개발. • 개발 모델에 의해 PUE 1.452에서 1.401로 감소. 고전적인 수법으로 데이터센터 모델링의 한계.
Young Jae C. ⁷⁰⁾ 2020.		• 컨테이너먼트형 데이터센터의 최적 열환경을 위한 적응형 제어알고리즘 개발 및 성능평가. • ANN 기반 냉매유량 제어모델 적용에 의한 예측 오차 0.47로 제어 가능성 확인.

-
- 44) 조진균, op. cit., pp. 11.
 - 45) 박성우, 이동욱, 오상윤, 김재훈, 데이터센터에서의 에너지 절약을 위한 유비쿼터스 센서 네트워크 기반의 적응적 분산 냉각 전략, 한국정보과학회 학술발표논문집, 36(18), 2009, pp.266-271.
 - 46) 이승연, 김민호, 이성구, 연창근, 데이터센터의 냉방에너지 절감을 위한 외기냉방 시스템 개선에 관한 연구, 대한설비공학회 학술발표대회논문집, 2017. pp.810-814.
 - 47) 김민희, 박준영, 정재원, 데이터센터 냉방을 위한 제습 증발냉각시스템의 적용성 분석, 대한건축학회 학술발표대회 논문, 2013. pp.283-284.
 - 48) 윤정인, 손창효, 허정호, 김영민, 데이터센터의 외기냉수냉방 시스템에 대한 에너지 절감효과 분석. 한국동력기계공학회지, 18(3), 2014. pp.73-78.
 - 49) 김제영, 장현재, 정용호, 멀티 외기냉방을 이용한 데이터센터의 에너지절약 시스템 개발에 관한 연구, 대한건축학회 학술발표대회논문집, 34(2), 2014. pp.267-268.
 - 50) Sami Alkharabsheh, John Fernandes, Betsegaw Gebrehiwot, Dereje Agonafer, Kanad Ghose, Alfonso Ortega, Yogendra Joshi, Bahgat Sammakia, A Brief Overview of Recent Developments in Thermal Management in Data Centers, Journal of Electronic Packaging, 137(4), 2015. pp.19
 - 51) Weiwen Zhang, Yonggang Wen, Yew Wah Wong, Kok Chuan Toh, Chiu-Hao Chen, Towards Joint Optimization Over ICT and Cooling Systems in Data Centre: A Survey,
 - 52) Harfiz M. Daraghmeh, Chi-Chuan Wang, A review of current status of free cooling in datacenters, ATE, 114(5), 2017, pp.1224-1239.
 - 53) Jiacheng Ni, Xuelian Bai, A review of air conditioning energy performance in data centers. Renewable and Sustainable Energy Reviews, Vol.67, 2017, pp.625-640.
 - 54) C.B. Bash, C.D. Patel, R.K. Sharma, Dynamic thermal management of air cooled data centers, IEEE Xplore, 2006.
 - 55) Monem H. Beitelmal, Chandrakant D. Patel, Model-Based Approach for Optimizing a Data Center Centralized Cooling System, hp invent, 2006.67,
 - 56) 조진균, 정차수, 김병선, op. cit., pp. 209.
 - 57) Yuan Chen, Daniel Gmach, Chris Hyser, Zhikui Wang, Cullen Bash, Christopher Hoover, Sharad Singhal, Integrated Management of Application Performance, Power and Cooling in Data Centers, IEEE Xplore, 2010.
 - 58) 함상우, 정재원, 컨테이너먼트가 적용된 데이터센터의 CFD 모델링 기법 및 열 관리 성능 평가. 2015. 31(1), pp.159-166.
 - 59) Weiwen Zhang, Yonggang Wen, Yew Wah Wong, Kok Chuan Toh, Chiu-Hao Chen, Towards Joint Optimization Over ICT and Cooling Systems in Data Center: A Survey, IEEE Xplore, 2016. 18(3), pp.1596-1616.
 - 60) Junwen DengLiu YangXinrong ChengWu Liu, Self-tuning PID-type Fuzzy Adaptive Control for CRAC in Datacenters, International Conference on Computer and Computing Technologies in Agriculture, 2014.
 - 61) Jim Gao, Machine Learning Applications for Data Center Optimization, Google, 2014.
 - 62) 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, 134, 2014. pp.45-56.
 - 63) Dong WEI, Baiyu LI, Yancai SHI, Zhuangju LI, Energy-Efficient Mode Transition Strategies of Data Center Cooling Systems, 2016.

2.3. 인공신경망 기반 제어의 이해

2.3.1. 인공신경망 및 기계학습 정의

인공신경망은 1943년 Warren McCulloch와 Walter Pitts에 의해 제안된 개념으로써 인간 두뇌의 신경망을 모사한 시스템이다.⁷¹⁾ 일반적인 수학적 알고리즘을 통해 복잡한 관계의 표현, 불확실한 결과 예측 등 명확하지 않은 문제를 해결하는 과정은 천문학적인 시간과 작업이 소요되어 비효율적인 경우가 많으나 인공신경망은 데이터를 스스로 학습하여 미래를 예측하며 연산의 병렬 및 분산 처리가 가능하여 다량의 연산을 적은 부하로 안정적으로 처리할 수 있는 장점이 있다.⁷²⁾ 또한, 인공신경망은 모델 구조가 단순하며, 모델 개발 속도가 빠르고 일반화 성능이 우수한 것이 장점이다. 즉, 인공신경망은 생물학적 신경망에서

64) Marina Zapater, Jose L. Risco-Martin, Patricia Arroba, Jose L. Ayala, Jose M. Moya, Roman Hermida, Runtime data center temperature prediction using Grammatical Evolution techniques, Applied Soft Computing, 2016, 49, pp. 94-107.

65) Dayarathna, M., Wen, Y., Fan, R., Data center energy consumption modeling: A survey, 2016, 18(1), pp. 732-794.

66) Alessandro Beghi, Lica Cecchinato, Giuseppe Dalla Mana, Nirco Rampazzo, Enrico Sisti, Modelling and control of a free cooling system for Data centers, Eenergy Procedia, 2017, 140, pp.447-457.

67) Srimoyee Bhattacharjee, Sunirmal Khatua, Sarbani Roy, A review on Energy Efficient Resource Management Strategies for cloud, Advanced Computing and Systems for Security, 2017, 568, pp.3-15.

68) Leehter YaoJin-Hao Huang, Multi-Objective Optimization of Energy Saving Control for Air Conditioning System in Data Center, Energies, 2019, 12(8), pp.1474.

69) Qui Fang, Qi Gong, jun Wang, Yaonan Wang, Optimization based resource and cooling management for a high performance computing data center, ISA Transactions, 2019. 90, pp.202-212.

70) 최영재, 컨테이너먼트형 데이터센터의 최적 열환경을 위한 적응형 제어알고리즘 개발 및 성능평가, 석사학위논문, 중앙대학교, 2020.

71) McCulloch, W. S., & Pitts, W. A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 1943, 5(4), 115-113.

72) 안기연, Deep Q-learning의 강화학습 기반 건물 에너지 시스템의 model-free 최적 제어, 박사학위논문, 성균관대학교, 2018.

영향을 받은 기계학습(Machine learning) 알고리즘 중 하나로 정의할 수 있다. 인공지능망은 타 기계학습보다 비선형 시스템을 높은 수준의 정확성으로 예측 및 표현할 수 있기 때문에 건물에너지 시뮬레이션 분야에서 가장 대표적으로 활용되는 모델이기도 하다.⁷³⁾

인간의 뇌 신경체계를 모방하여 유사한 구조적 특징을 가지는 인공지능망의 대표적인 모델로 1957년 Frank Rosenblatt은 퍼셉트론(Perceptron)을 고안하였다.⁷⁴⁾ 퍼셉트론은 각 뉴런(Neuron)에서 입력 값과 가중치(Weight)를 곱하여 모두 합한 값이 활성화 함수(Activation Function)에 의해 판단되어 이 값이 임계치보다 높으면 출력하는 방식으로 작동한다. 퍼셉트론은 Fig. 16과 같이 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer)의 구조를 가지며 은닉층의 층수에 따라 단층 퍼셉트론(Single-Layer Perceptron)과 다층 퍼셉트론(Multi-Layer Perceptron)으로 나뉜다. 각 층은 다수의 뉴런으로 구성되어 있고 뉴런은 수정 가능한 연결 가중치(w_{ij}, w_{jk})로 다른 층의 뉴런과 연결되어 있다. 여기서, 은닉층의 수와 은닉층을 구성하는 뉴런의 수는 개발자의 주관적 판단 혹은 시행착오의 방법으로 결정한다.⁷⁵⁾ 은닉층에 속한 각 뉴런의 출력 값을 결정하는 수식은 식(1)과 같다. x_i 가 입력층의 뉴런일 때, w_{ij} 는 입력층의 i 번째 뉴런과 은닉층의 j 번째 뉴런 사이의 가중치로 학습을 축적하기 위해 사용된다. φ 는 주로 기본 함수나 시그모이드(Sigmoid) 함수를 모델링 하는 활성화 함수이며 상수인

73) A.Afram, F. Janabi-Sharifi, A.S. Fung, Raahemifar, Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems; Astate of the art review and case study of a residential HVAC system, Eenergy Buildings, 2017, 141, pp.96-113.

74) Rosenblatt, F., The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. Cornell Aeronautical Laboratory, Psychological Review. . 1985, 56(6), pp.386-408.

75) 권한술, 인공지능망을 이용한 부하 예측 기반 대형 건물의 복합 냉동기 최적운영 방안, 박사학위논문, 서울시립대학교, 2013.

편향은(bias, b)뉴런이 얼마나 쉽게 활성화되느냐를 조정하는 매개변수이다. 이와 같은 방법으로 출력층의 뉴런이 모델링 된다.

$$y_j = \varphi\left(\sum_{i=1}^N w_{ij}x_i + b\right) \quad \text{식(1)}$$

각 뉴런은 독립적으로 동작하는 처리기의 역할을 하며 수많은 연결선에 정보가 분산되어 있으므로 몇몇 뉴런에 문제가 발생하더라도 전체 시스템에 큰 영향을 주지 않는 결함 허용(Fault Tolerance) 능력이 있으며 주어진 환경에 대한 학습 능력이 뛰어나다.⁷⁶⁾ 학습은 인공신경망의 순전파(Feed-Forward)를 통해 출력된 값을 정답 값과 비교하고 역전파(Back-Propagation) 알고리즘을 통해 오차를 최소화하는 방향으로 가중치를 수정하며 수행된다.

인공신경망은 학습 방법에 따라 Fig. 17과 같이 지도학습(Supervised Learning), 비지도학습(Unsupervised Learning), 강화학습(Reinforced Learning)으로 구분된다.⁷⁷⁾ 지도학습은 정답이 있는 데이터를 활용하여 데이터를 학습시키는 것으로 대표적으로 분류(Classification), 회귀(Regression)등에 사용된다. 비지도학습은 학습 데이터에 정답이 포함되어 있지 않은 형태로 스스로 입력값에 대한 규칙을 학습하여 군집화(Clustering), 차원축소(Dimensionality Reduction) 등에 활용된다. 강화학습은 과거의 정보가 충분하지 않은 상태에서 수많은 시뮬레이션을 통해 현재의 선택으로 미래의 보상이 최대가 되도록 학습하는 방식이다.⁷⁸⁾

76) 문지훈, 전상훈, 박진웅, 최영환, 황인준, 인공 신경망과 지지 벡터 회귀분석을 이용한 대학 캠퍼스 건물의 전력 사용량 예측 기법, 정보처리학회 논문지, 컴퓨터 및 통신 시스템, 2016, 5(10), pp. 293-302.

77) Sanchit Tanwar, Introduction to machine learning and deep learning, 2019.




Fig. 16 인공신경망 모델 개념 및 구조

78) 최영재, op. cit., pp. 46.




Fig. 17 기계학습 분류

Fig. 17에서 확인되듯이 인공신경망 외에도 학습 방법 및 목적에 따라 기계학습에는 다양한 알고리즘이 있다. 본 논문에서는 앞서 개념을 정리한 인공신경망을 포함, 회귀에 사용되는 대표적인 4가지 학습 알고리즘을 사용한 예측모델을 개발하고 그 중 예측성능이 우수한 모델을 선정하여 제어알고리즘에 활용하고자 한다. 개발에 사용될 인공신경망 외 3가지 알고리즘의 개념을 Table 10. 및 다음과 같이 서술하였다.

(1) 가우시안 프로세스 회귀(Gaussian Process Regression, GPR)

가우시안 프로세스 회귀는 공분산 함수(Covariance Function), 평균 함수(Mean Function), 가우시안 분포(Gaussian Distribution) 및 베이저안 확률론(Bayesian Probability)에 기반을 둔 지도학습 알고리즘으로 비모수적(Non-parameter) 추론을 구현한다.⁷⁹⁾ 가우시안 프로세스 회귀는

79) 김영진, 박철수, 가우시안 프로세스 모델과 냉동기 실시간 최적 제어, 대한건축학회 논문

다변량 정규분포를 무한차원으로 확장하고 공분산 함수에 의해 입출력 값의 공분산을 정의, 그 값에 따라 임의의 차원을 가지는 가중치 사후분포를 결정한다. 결정된 모델의 가중치에 의하여 새로운 입출력 데이터에 대해 결과를 예측하며 예측값에 대한 변화율을 확인할 수 있는 장점이 있다.

(2) 서포트 벡터 머신 (Support Vector Machine, SVM)

서포트 벡터 머신은 선형 및 비선형 분류와 회귀 등에 사용되는 다목적 기계학습 알고리즘이다.⁸⁰⁾ 서포트 벡터와 마진(Margin)을 이용하여 관측 데이터가 가장 많이 포함되는 최대 마진 분포를 형성하여 회귀를 실시한다. 이때, 최대 마진 및 서포트 벡터를 찾아가는 과정은 쿤터커(Karush-Kuhn-Tucker) 조건과 라그랑지(Lagrange) 방법을 사용하여 완성된다.⁸¹⁾ 서포트 벡터 머신은 과적합(Overfitting)이 적고 타 기계학습 알고리즘 대비 사용하기 용이한 장점이 있으나 입력 데이터가 많을수록 학습 속도가 느리며 최적 모델 선정을 위한 커널(Kernel) 및 다양한 매개변수의 조합이 필요하다. 또한, 주어진 문제의 정의 및 형태에 대해 개발자의 추론이나 견해가 반영되어야 하며 이에 따라 모델 성능이 크게 좌우될 수 있다.⁸²⁾

(3) 랜덤 포레스트(Random Forest, RF)

랜덤 포레스트는 의사결정 트리(Decision Tree)를 기반으로 하는

문집 - 계획계, 2014, 30(7), pp.221-220..

80) Aurellen Geron, Hands-On Machine Learning with Scikit-Learn & TensorFlow, Oreilly

81) J.A. Suykens, J. Vandewalle, Least squares support vector machine classifiers, Neural Processing letters, 1999, 9(3), pp.293-300.

82) M. Martin, On-line support vector machine regression, In European Conference on Machine Learning, Springer, Berlin, Heidelberg, 2002, 2430, pp.282-294.

앙상블(Ensemble) 기계학습 알고리즘이다. 랜덤 포레스트는 데이터의 특성을 임의로 추출하는 배깅(Bagging) 혹은 기타 방법을 통해 다수의 의사결정 트리를 생성하고 트리로 구성된 포레스트를 형성한다. 입력값에 대하여 여러 예측값이 도출되며, 회귀의 경우 최종 예측값은 각 트리의 앙상블 시뮬레이션을 통해 예측값들의 평균으로 결정된다.⁸³⁾ 랜덤 포레스트는 단일 의사결정 트리보다 예측 변동성이 줄어들고 과적합을 방지한다. 또한 대량의 데이터에 적용 가능하며 일반화 및 예측성능이 우수하고 데이터의 스케일 변환이 불필요한 장점이 있다. 그러나 데이터의 수에 비례하여 의사결정 트리 개체 생성에 많은 시간이 소요되며 이에 따라 예측 속도가 크게 떨어지고 예측 결과에 대한 해석이 단일 의사결정 트리보다 복잡한 단점이 있다.

Table 10. 예측모델에 적용한 4가지 기계학습 방법

구분	개념	학습원리	장점
ANN	입출력 변수의 상관관계를 학습하여 각 뉴런 사이의 가중치를 갱신하는 모델	$y_j = \varphi(\sum_{i=1}^N w_{ij}x_i + b)$ x_i =입력뉴런, w_{ij} =가중치 b =편향, y_j =출력뉴런	다른 기계학습 방법에 비해 연산속도가 빠르고 일반화 성능 우수
GPR	예측값이 측정값과 비교해 정규분포의 오차를 갖는 모델	$y = f(x) + \varepsilon$ $f(x)$ =예측값, y_n =측정값 ε =오차	예측값을 확률적으로 표현하고, 설비 진단·효율에 활용
SVM	허용 가능한 오차범위에서 마진을 최대화하는 모델	$\min 1/2 \ w\ ^2 + C \sum_{i=1}^n (\xi_k + \xi_k^*)$ $2 \ w\ $ =마진, $\pm \varepsilon$ =오차범위	학습 데이터에 대한 과적합 방지 가능
RF	Impurity 함수에 따라 최적 분할기준을 찾고, 이를 성장시킨 다수의 의사결정 나무로 이루어진 모델	$\Delta i(s, t) = i(t) - p_R i(t_L) - p_R i(t_R)$ $i_R(t) = 1 - p(\hat{y}_t t) = 1 - \max p(d t)$ t =노드, $i(x)$ =Impurity 함수	비선형 시스템에 대해 예측력이 뛰어나

83) 최영재, 박보량, 조지현, 문진우, 컨테이너먼트형 데이터센터 최적 제어알고리즘을 위한 열환경 예측모델 개발. 한국생태환경건축학회 논문집, 2020, 20(5), 159-164.

2.3.2. 건축설비 분야 기계학습 적용 동향

최근, 급격한 산업의 발달과 더불어 인공지능으로 불리는 기계학습에 대한 관심이 증가하고 있다. 기계학습은 지능형 제어에 필수적인 기반 기술로써 다방면에서 연구 및 적용되고 있다. 본 논문에서는 건축설비 분야에서의 기계학습 적용 동향을 분석하고 기계학습 활용의 트렌드 및 중요성을 판단하고자 하였다.

Kang(2017)⁸⁴⁾에 따르면 기계학습을 적용한 건축설비 분야의 국내·외 연구논문은 2000년 기준 2016년도까지 국내 13배, 국외 4배 증가하여 통합 약 246편으로 조사되었다. 조사된 연구의 주제는 크게 냉난방시스템 최적 운전, 건물에너지 최적화, 실내환경개선, 환기 시스템 등으로 분류되었으며 전체 논문 중 건물에너지 최적화에 관한 연구가 17%로 가장 높은 비율을 차지하고 있었다. 건축설비 분야에서 주로 적용한 기계학습 방식은 인공신경망이 50.8%로 가장 큰 비중을 차지하는 것으로 분석되었다. 건축설비 분야 논문은 국내의 경우 37건, 국외의 경우 209편으로 국내대비 국외의 연구 수가 확연히 높게 나타났다. 조사된 연구논문 중 본 논문과 관련도가 높은 건물 및 설비시스템의 에너지 사용량 예측 및 제어한 주요 논문을 정리하면 다음과 같다.

Kwon(2013)⁸⁵⁾은 대형건물의 냉방부하 예측을 인공신경망을 통해 안정적인 매칭률로 할 수 있음을 입증하였고 예측한 냉방부하를 기반으로 실제 대형건물의 냉방에너지 생산을 위한 복합 냉동기에 적용하여 냉방에너지와 생산비용을 절감할 수 있음을 확인하였다. Kwak(2009)⁸⁶⁾은

84) 강인성, 문진우, 박진철, 최근 건축분야의 인공지능 기계학습 연구동향, 대한건축학회, 논문집, 2017, 33(4), pp.63-68.

85) 권한솔, op. cit., pp. 8.

86) 광영훈, 데이터 피드백을 통한 사무소 건물의 에너지 수요예측기법 개발, 한국건축친환경설비학회, 추계학술발표대회, 2009, pp.55-58.

인공신경망 모델을 사용하여 사무소 건물 전기에너지 데이터를 기반으로 에너지 수요예측을 적용하여 높은 성능을 확인하였다. 축적된 데이터에 새로운 데이터를 피드백하여 재학습시킬수록 오차율이 줄어든다고 밝혔다. Choi. et al.(2009)⁸⁷⁾은 전력계통 단기 부하를 요일 및 특수한 날의 패턴을 분석하고 RF를 이용한 예측방법을 제시하여 기존의 전력거래소에서 예측하는 값보다 좀 더 정확한 값을 얻었다. Kong. et al.(2009)⁸⁸⁾은 데이터베이스를 이용한 에너지 수요예측 기법개발을 위해서 데이터베이스를 구축하고 인공신경망을 이용한 에너지 수요예측 기법을 개발하여 예측값과 실제 부하와의 상관성에서 매우 유효한 결과를 확인하였다. Seo. et al.(2017)⁸⁹⁾은 기계학습 기법과 BEMS 데이터를 이용하여 기계학습 모델을 개발하고 건물의 각 설비에 적용하여 예측성능을 비교하였다. 기계학습은 ANN, SVM, GPE (Gaussian Process Emulator), RF, GP (Genetic Programming)을 활용하였으며 그 결과 입력과 출력변수 데이터의 관계가 명확할수록 예측성능이 향상되기 때문에 관련성 높은 데이터를 입력변수로 선정하는 것이 중요한 것을 확인하였고 모든 모델에서 예측 정확도가 평가 기준에 만족하였으며 ANN이 가장 우수한 것으로 나타났다. Seong. et al.(2017)⁹⁰⁾은 인공신경망을 이용한 건물에너지 모델을 최적화하는 알고리즘을 개발하여 실제 건물에너지 측정값과 예측값의 정확도가 적절한 것을 검증하였다. Kang. et al.(2017)⁹¹⁾은 인공신경망을 활용하여 VRF 시스템의 냉방에너지

87) 최상열, 김형중, 데이터마이닝을 이용한 단기부하예측, 한국조명전기설비학회, 21(10), 2009, pp.126-133.

88) 공동석, 광영훈, 이병정, 허정호, 인공신경망을 이용한 데이터베이스 기반의 광역단지 에너지 수요예측 기법 개발, 한국태양에너지학회 학술대회논문집, 2009, 29(1), pp.184-189.

89) 김영민, 김용세, 안기연, 박철수, 에너지 실시간 모델 예측 제어를 위한 인공신경망 변수 최적화, 한국건축친환경설비학회, 학술발표대회논문집, 2015, pp.159-160.

90) 성남철, 김지현, 최원창, 윤상천, Nabil Nassif, 인공신경망을 이용한 건물의 에너지 모델 최적화 알고리즘 개발 및 검증에 관한 연구, 한국생활환경학회 논문집, 2017, 24(1), pp.29-36.

사용량을 예측하는 ANN모델을 개발하고 성능평가를 통하여 예측모델의 예측 정확도가 평가 기준에 만족하는 것을 확인하였다. Chirage Deb() 은 인공신경망을 활용하여 세 가지 유형 건물의 냉방에너지 사용량을 예측하였으며 요일별 및 단계별로 건물에너지 사용량을 분석하였다. 그 결과, 예측성능($R^2=0.98$)이 높은 모델이 도출되었다. Radu Rlaton. et al.(2015)⁹²⁾은 인공신경망과 사례기반 추론법을 활용하여 건물의 시간당 냉방에너지 사용량 예측모델을 개발하여 두 가지 예측모델의 성능을 비교 분석하였다. Pedro A. Gonzalez. et al.(2005)⁹³⁾는 인공신경망을 활용하여 시간별 단기 건물에너지 예측모델을 개발하여 실제 건물에너지와 예측값을 비교평가 하였다. 이들 외에도 Garnier et al.(2015)⁹⁴⁾, Kusiak et al.(2014)⁹⁵⁾ 등 건물에너지 소비 최소화 및 실내 열쾌적 유지를 위한 연구에도 활발히 적용되고 있다.

건축설비 분야 기계학습 연구 동향분석 결과 다양한 기계학습 중 인공신경망의 활용 빈도수가 가장 높았으며 건물에너지 사용량을 예측하거나 일반적인 공조시스템 운전 알고리즘 개발 연구가 다수 진행되고 있었다. Afram et al.(2017)⁹⁶⁾은 기계학습 모델 중 인공신경망은

91) 강인성, 양영권, 이효은, 박진철, 문진우, 건물 냉방시스템의 예측제어를 위한 인공신경망 모델개발, 한국생태환경건축학회 논문집, 2017, 17(5), pp.69-76.

92) Radu Platon, Vahid Raissi Dehkordi and Jacques Martel, Hourly Prediction of a Building's Electricity Consumption using Case-based Reasoning, Artificial Neural Networks and Principal Component Analysis, Energy and Buildings 92, 2015.

93) Pedro A. Gonzalez and Jesus M. Zamarreno, Prediction of Hourly Energy Consumption in Buildings based on a Feedback Artificial Neural Network, Energy and Buildings 2005, 37.

94) A. Garnier, J. Eynard, M. Caussanel, S. Grieu, Predictive control of multizone heating, ventilation and air-conditioning systems in non-residential buildings, Appl Soft Comput, 2015, 37, pp. 847-862.

95) A. Kusiak, G.L. Xu, Z.J. Zhang, Minimization of energy consumption in HVAC systems with data-driven models and an interior-point method, Energ Convers Manage, 2014, 85, pp. 146-153.

96) A. Afram, F. Janabi-Sharifi, Theory and applications of HVAC control systems - A review of model predictive control (MPC), Build Environ, 2014, 72, pp. 343-355.

다른 모델과 비교하여 비선형 시스템을 높은 수준의 정확성으로 예측 및 표현할 수 있기 때문에 건물에너지 시뮬레이션 분야에서 가장 대표적으로 활용되는 모델이라고 하였다. 그러나, 해당 분야에서 기계학습을 활용한 연구 수는 국외보다 국내가 현저하게 낮은 것으로 확인되었다. 또한, 대상 건물이 업무시설에 국한되어 다뤄지고 있어 다양한 건물 용도에 대한 기계학습 적용 연구가 활발히 진행되지 않은 것으로 나타났다. 향후 국내 인공지능 산업의 강력한 경쟁력을 갖추기 위하여 건축설비 분야에서도 다양한 건물 용도를 대상으로 한 기계학습을 활용한 연구가 더욱 활발하게 이루어져야 할 것으로 사료 된다.

2.3.3. 인공지능 기반 공조 제어알고리즘 개발 목적

기존에는 건물 자동화와 더불어 설비 장비의 정상가동 여부 상태 감시와 에너지 관리 등 중앙 관제실에서의 단순 모니터링 및 수동적 제어가 중심이었는데 점차 방대해지는 건물 정보처리로 인하여 기존 제어 방법만으로는 한계가 따른다. 이러한 한계점 극복을 위해서는 건물 특성에 따른 분석과 에너지 절약을 위한 최적화 제어를 위해 최근 최신기술로 급부상 중인 ICT 기술이 접목된 건물제어로 차별성을 가져야 한다.

ICT 기술이 발달함에 따라 기계학습 등 포괄적 의미를 내포하는 인공지능 등 최신 솔루션이 건물에너지 및 공조제어 분야에도 적극적으로 적용되고 있다. 호주의 Building IQ, 일본의 다이킨공업, 구글, 인텔은 이미 빅데이터를 활용한 예측제어를 통해 건물에너지를 관리하고 있다. 일본의 신흥 전력 대기업인 에넷토에서도 호주의 벤처기업 Cozero Holdings와 협력하여 인공지능을 활용한 건물에너지 절약 서비스를 제공하고 있으며 공조제어 기술을 보유한 다이킨공업과 NEC의 인공지능

기술의 협력으로 공조제어와 건물에너지 절감 기술의 결합한 공동 연구를 시작하였다. 국내에서도 대기업을 선두로 건물에 인공지능을 접목한 연구가 진행되고 있으나 적용률이 활발한 국외와 비교하여 아직 도입단계에 그치고 있다.

건물에너지 및 공조시스템에 인공지능 기술 활용 시 다량의 데이터 수집 및 고속의 실시간 피드백이 가능하고 새로운 상황에 따른 입출력 데이터의 조정이 유연하여 예측제어의 성능개선에 뛰어나다. 또한, 건물 및 설비 장비에 대응방법이 사후 처리가 아닌 사전 대응이 가능하며 자동 운전으로 인한 새로운 설비의 투자가 줄어들고 24시간 운영됨에 따라 관리자의 업무시간 외에도 문제 발생에 대해 관리자의 경험에 기반을 둔 지능적 학습으로 자동 해결이 가능해진다. 따라서, 본 논문에서는 인공지능을 활용한 공조시스템 및 건물에너지 예측·제어를 위한 알고리즘을 개발하고자 하며 적용 건물은 ICT 발전에 따라 중요도가 높아지고 그 수가 급격히 증가하고 있는 데이터센터를 대상으로 선정하였다. 개발 알고리즘은 데이터센터 냉각시스템의 냉수 유량을 예측하여 실내 설정온도에 만족하도록 냉각시스템을 제어하여 최적 실내열환경 및 냉방에너지 절감을 실현하고자 하였다.

제 3 장 냉수 유량제어를 통한 실내 열환경 예측모델 및 최적 제어알고리즘 개발

3.1. 개발 방법 및 절차

데이터센터의 최적 실내 열환경 제어 및 에너지효율 개선을 위해 예측모델 및 제어알고리즘을 개발하였다. 제어알고리즘은 개발된 예측모델을 내포하며 다양한 유형의 데이터센터 환경에 적용 가능한 지능형 제어 솔루션으로 구축하였다. 예측모델은 냉수유량 제어를 통한 CRAH 공급공기 온도를 예측하는 역할을 담당하며 이를 기반으로 설정온도에 만족하는 CRAH 공급공기 온도 및 최소 에너지소비량 산출을 위한 최적 냉수유량을 적용하는 역할이 제어알고리즘이다.

ANN 기반의 예측모델과 제어알고리즘은 인공지능 기술 구현, 정교한 수치계산이 가능하고 범용 프로그래밍 환경을 제공하는 소프트웨어인 Mathworks사에서 개발한 MATLAB을 활용하여 개발된다. 예측모델은 입·출력변수 선정 후 이를 활용하여 초기모델을 구축한다. 이때 입·출력변수는 Excel 기반의 수학적 모델에 의해 구축된 전체 냉각시스템 메커니즘을 포함하는 데이터를 활용하여 예측에 필수적인 변수를 활용한다. 초기예측모델은 최적화 과정을 통해 예측 정확도가 최대치로 보완되어 최종 예측모델이 확립된다. 최종 예측모델이 내포된 제어알고리즘은 예측모델이 IT 부하에 따른 적정 냉수유량에 의해 예측한 CRAH 공급공기 온도의 적정성을 판단하고 그 결과에 따라 재학습 과정을 거친 오차 보정에 의해 최적 제어를 실시하도록 구성된다.

제어알고리즘의 성능평가는 MATLAB으로 구현된 시뮬레이션 모델로

수행되며 제어 정확도 및 안정성을 확인하고 향후 제어 환경이 다른 각종 데이터센터에서의 적응성을 검증한다. 본 연구에서 개발하는 제어알고리즘의 경우 각종 환경변화에 대응하여 목표 값을 예측하고 제어하는 것을 목적으로 하고 있어 이에 특화된 별도 시뮬레이션 모델을 구축하였다. 입력변수 조절 및 변환을 할 수 있고 수치해석과 프로그래밍이 가능한 MATLAB을 활용하여 대상 냉각시스템과 유사한 가상의 냉각시스템 시뮬레이션 모델을 개발하였다.

본 장에서는 수학적 데이터 취득용 모델, 예측모델, 제어알고리즘, 성능평가용 시뮬레이션 모델개발에 관한 내용을 다루며 각 모델의 성능평가는 제4장에서 상세히 기술한다.




Fig. 18 예측·제어모델 개발 프로세스




Fig. 19 ANN 기반 예측·제어모델 개발 활용 도구 및 적용 범위

3.2. 대상 데이터센터 및 냉각시스템 구성

데이터센터는 Rack 배치 및 장비구성 방법에 따라 개방, 컨테이너먼트, 모듈형으로 나뉜다. 컨테이너먼트 방식은 최근 데이터센터 신설 및 리모델링시 적용비율이 증가하고 있으며 하이퍼스케일 데이터센터(10만 대 이상의 서버를 운영할 수 있는 초대형 데이터센터)의 증가에 따라 냉각시스템으로 중앙 냉수식을 채택하고 있다.

이에 따라 본 논문에서의 대상 데이터센터는 Hot Aisle형 컨테이너먼트 방식으로 선정하였다. 컨테이너먼트 방식은 냉각수 공급온도를 증가시켜 최적의 냉각 효율을 보장하는 에너지효율적인 데이터센터 방식이다. 컨테이너먼트에 연결되는 냉각시스템은 중앙 냉수식 시스템이 적용되며 냉각탑-냉동기-냉매분배기-CRAH로 구성된다.(Fig. 20)




Fig. 20 컨테인먼트 데이터센터 및 냉각시스템 구조

3.2.1. 컨테인먼트형 데이터센터의 구성

컨테인먼트 1개소는 14개의 Rack이 설치되며 7개의 Rack이 1Row로 배치된다. 서버 발열로 데워진 공기가 토출되는 Rack의 후면과 CRAH로 순환되는 공기를 공유하는 Hot Aisle이 중심부에 위치하며, CRAH이 공급하는 차가운 공기와 이를 끌어들이는 Rack 전면은 컨테인먼트의 양 외측에 Cold Aisle로 위치한다. 일반적으로 전산실 내부 공기는 연중 일정하게 유지되도록 별도의 공조가 시행되어 온습도 측면에서 외기의 영향이 없는 것으로 가정한다. 또한, 컨테인먼트는 전면 차폐구조로 내부의 발열은 외부와 열교환은 발생하지 않는 것으로 가정한다. (Fig. 21)

ASHRAE에서는 데이터센터에 적용되는 Rack의 표준 사양을 제공하고 있다.(Table 11)⁹⁷⁾ ASHRAE가 제공하는 사양 범위에 만족하도록 설정하여 대상 모델을 일반화하여, 대상 컨테이너먼트에서의 Rack은 최대 6.6kW (6,600W)의 발열량을 가지는 것으로 설정하였으며 실제 운영 시에는 대부분 부분 부하로 가동된다. 본 연구에서는 최대발열을 92.4kW에서 기타 장비에서 생성되는 발열을 감안하여 100kW로 설정하였다. Rack에 내장된 팬은 서버부하량에 대응하여 제어되며 이에 따른 일반적인 서버의 입·출구의 온도 차는 10~15℃로 가정하며⁹⁸⁾ 본 논문에서는 11℃로 설정한다




Fig. 21 컨테이너먼트 구성

97) ASHRE, Green Tips for Data Centers, ASHRAE Datacom Series Series Book 10, 2010.

98) 조진균, op. cit., pp. 97.

Table 11. ASHRAE 권장 RACK 표준 사양

Configuration	Condition				
	Typical Heat Release (W)	Airflow		Weight (kg)	Dimensions (W*D*H) (mm)
		Nominal (m ³ /h)	Maximum (m ³ /h)		
Minimum	1,765	680	1,020	406	762*1,016*1,828
Typical	5,040	943	1,415	472	762*1,016*1,828
Full	10,740	1,275	1,913	693	1,549*1,016*1,828

3.2.2. 중앙 냉수식 시스템 구성

대상 컨테인먼트에 적용된 냉각시스템은 중앙 냉수식이다. 중앙 냉수식 시스템의 냉동사이클은 일반적으로 CRAH와 냉동기, 냉각탑을 통해 순환된다. 대규모 시설에 적용 시 전력당 냉각비용이 다른 시스템과 비교할 때 가장 적지만 배관, 냉각탑, 펌프 등의 설비가 필요하므로 다른 방식에 비해 초기 구축비용은 가장 높다. 중소 규모 이하의 데이터센터에 적용 시 비용 대비 효율이 낮으므로 고가용성이 요구되고 장비의 전력밀도가 높은 대규모 데이터센터에 적용된다.⁹⁹⁾

본 논문에서는 CRAH와 냉동기 사이에 냉매분배기가 추가된 시스템으로 구성된다. 냉각탑은 여러 대의 냉동기에 연결되어 냉각수를 공급하고 실내 냉방부하를 실외로 배출하는 역할을 한다. 냉각수는 32±5℃로 공급되고 본 논문에서는 2대의 냉동기와 연결되거나 보편적으로는 중앙 집중형으로 2대 이상의 냉동기와 연결될 수 있다. 냉동기는 냉각탑에서 1차로 냉각된 냉각수를 받아 냉수(7℃)로 전환하여

99) 박현규, 김용주, 신상용, 김진환, 최지혜, 류은경, 그린, 그린IT 그리고 그린데이터센터, 한국경제신문, 2009.

냉매분배기를 거쳐 CRAH에 냉기를 공급한다. 판형열교환기를 통해 냉매와 열교환을 일으키며 입·출구 온도의 $\Delta 5^{\circ}\text{C}$ 를 기준으로 작동한다. 2N의 구조로 1대의 냉동기가 고장이 나도 컨테인먼트에서 발생하는 모든 열량을 제거할 수 있는 용량을 가진다. 냉매분배기는 냉매 액펌프에 의해 R134a 냉매(20°C)를 순환시키는 장비로써 컨테인먼트 내에 결로를 발생시킬 가능성이 있는 냉수의 출입을 배제하기 위한 열전달 수단이다. 2N의 구조로 하나의 액펌프에 문제가 생겨도 나머지 1대로 6대의 CRAH에 냉매공급이 가능하다. CRAH는 냉각을 위한 압축기와 열교환기를 포함하지 않으며, 냉동기에서 공급된 냉수가 냉수 코일을 순환하여 IT 장비에서 온도가 상승된 열기를 냉각시키는 개념이다. CRAH는 30kW의 용량으로 Row 당 N+1로 구성되었다. Row당 최대 서버발열량은 50kW이며 CRAH 1대가 고장이 나더라도 나머지 2대의 CRAH가 최대 부하를 감당할 수 있도록 운영된다. (Fig. 22), (Table 12)




Fig. 22 냉각시스템 구성

Table 12. 냉각시스템 구성 및 사양

Configuration	EA	Summary
CRAH	6 (3 per row)	Capacity : 30kW Redundancy : N+1 Mass Flow Rate : Equals to total rack supply air mass flow rate
Refrigerant Distributor	2 (1 per row)	Capacity : 100kW Redundancy : 2N 2 phase heat transfer by R134a without compressor
Refrigerator	2 (1 per row)	Capacity : 120kW Redundancy : 2N Setpoint Temperature : 7℃ Temperature Difference : $\Delta 5^{\circ}\text{C}$
Cooling Tower	1	Capacity : Enough RT to handle more refrigerators Setpoint Temperature : 32℃ Temperature Range : $\Delta 5^{\circ}\text{C}$

3.3. 수학적 모델에 의한 예측모델 데이터 취득

본 연구에서의 ANN 기반 예측모델은 데이터 기반 모델로서 충분한 양과 유의미한 품질의 데이터 취득이 중요하다. 정확도 높은 예측모델 구현의 필수요소인 고품질의 학습 데이터는 가공단계부터 시작되어야 한다.

본 논문의 대상 데이터센터에 적용되는 중앙 냉수식 냉각시스템은 현재 개발단계로 실증 전 시스템 성능 테스트를 진행하고 있어 실측 데이터 확보 한계가 존재함에 따라 수치해석으로 얻어진 데이터를 예측모델에 활용하였다. 데이터는 Excel을 활용하여 생성하였고 실제 데이터센터에서

센서를 활용하여 측정되고 있는 요소를 위주로 선정하였다. 실측 데이터와의 유사도 확보를 위하여 대상 냉각시스템의 상세사양 및 경계조건을 고려하고, 건물에너지 분석에 사용되는 물리적 기본원리인 에너지보존의 법칙(열역학 제1 법칙)에 근거한 열전달 수식 차용으로 총 20,200개의 데이터 세트를 산출하였다.

열역학 제1 법칙에 근거한 실내공간의 내부에너지 변화량은 식(2)과 같이 나타난다. 본 논문에서의 Q_{loss} 는 컨테이너먼트에서 외부 전산실로 배출되는 열이며 Q_{gain} 은 컨테이너먼트 내부 서버 발열, U 는 내부에너지, t 는 시간으로 감안할 수 있으며 결론적으로 식(2)은 내부에너지의 시간에 대한 변화량은 열의 출입에 대한 총합과 같다는 것을 의미한다. Q_{loss} 는 데이터센터 벽체의 열전달을 고려하면 식(3)과 같다. Q_{gain} 은 풍량과 엔탈피 값을 통해 계산되며 발생한 열의 외부에 대한 일이 없다고 가정하여 식(4)과 같다. 본 연구에서는 컨테이너먼트 외부 전산실은 항상 일정한 온도(약 26℃)로 유지되고 완전히 차폐된 내부에서는 Cold Aisle의 CRAH 토출 공기가 곧바로 서버로 유입되는 것으로 가정하여 Q_{loss} 를 0으로 계산하였으므로 식(5)와 같이 서버 입구 풍량은 CRAH 입구 풍량과 같고 이는 CRAH 출구 풍량과 같다고 가정할 수 있다. 풍량과 엔탈피의 관계로 나타낸 Q_{gain} 은 내부에너지와 온도로써 식(6)-(8)과 같이 표현할 수 있다. 이에 따라 내부에너지 변화는 식(9)-(10)와 같이 정리된다.

수치해석 과정은 다음의 가정을 바탕으로 한다.

- 차폐구조로써 주변과의 열손실 고려하지 않음
- 냉수 온도 고정 값
- 냉매분배기 열전달 역할
- 서버 풍량과 CRAH 출구 풍량 동일

$$Q_{loss} + Q_{gain} = \frac{dU}{dt} \quad \text{식(2)}$$

여기서,

Q_{loss} : 컨테이너먼트에서 외부 전산실로 배출되는 열

Q_{gain} : 컨테이너먼트 내부 서버 발열

U : 내부에너지

t : 시간

$$R = \frac{1}{h_{out} \times A} + \frac{D}{k \times A} + \frac{1}{h_{in} \times A} \quad \text{식(3)}$$

여기서,

h_{out}, h_{in} : 입·출구 열전달계수(Heat transfer coefficients)

k : 열관류율

A : 열 전달 면적

D : 벽체의 두께

$$Q_{gain} = \dot{m}_{in} \times h_{in} - \dot{m}_{out} \times h_{out} \quad \text{식(4)}$$

여기서,

m_{in}, m_{out} : CRAH 입출구 풍량

h_{in}, h_{out} : 입출구 엔탈피

$$\dot{m}_{in} = \dot{m}_{out} = \dot{m}_{rack} \quad \text{식(5)}$$

여기서,

$\dot{m}_{rack}$: 서버 입출구 풍량

$$Q_{gain} = \dot{m}_{rack} \times C_p \times (T_{RA} - T_{SA}) \quad \text{식(6)}$$

$$C_p = \frac{\Delta h}{\Delta T} \quad \text{식(7)}$$

$$C_v = \frac{\Delta U}{\Delta T} \quad \text{식(8)}$$

여기서,

T_{RA} : 순환 공기 온도

T_{SA} : 공급 공기 온도

C_p : 정압비열

C_v : 정적비열

$$\frac{\Delta U}{\Delta T} = \dot{m}_{rack} \times C_v \times \frac{dT_{containment}}{dt} \quad \text{식(9)}$$

$$\frac{dT_{containment}}{dt} = \frac{1}{\dot{m}_{rack} \times C_v} \times \frac{dU}{dt} = \frac{1}{\dot{m}_{rack} \times C_v} \times (Q_{gain} + Q_{loss}) \quad \text{식(10)}$$

여기서,

$T_{containment}$: 컨테인먼트 내부 온도

냉각시스템 구성에 따라 데이터는 공기측의 CRAH, 냉수 및 냉각수 측의 냉동기, 냉각탑 부문으로 나뉜다. 식(2)-식(10)를 바탕으로 생성된 열전달 식 (11)을 활용하여 CRAH 에서는 설정온도(Tset), CRAH 공급공기 온도와 회수공기 온도(CRAH_Tsa, CRAH_Tra), Rack 단위 IT 발열(IT Load), CRAH의 풍량(CRAH_Mair), 공기비열(Cair), CRAH_Q(공기측 제거 열량), 설정온도와 CRAH 공급공기 온도의 차를 요소로 활용하여 산출하고 데이터 세트로 구축된다. 냉동기에서는 공급냉수 온도(CH_Tsa_W), 환수냉수 온도(CH_Tra_W), 환수냉수와 공급냉수의 온도 차(CH_Tra_W - CH_Tsa_W), 물의 비열(C_water), 냉수유량(CH_Mw) 그리고 냉동기 에너지소비량을 대체할 냉동기에서의 제거 열량(CH_Q)이 계산되어 데이터가 생성된다. 냉각탑에서는 에너지소비량을 대체할 제거열량(CT_Q)만을 데이터로 선정한다.

데이터센터의 컨테이너 내부 설정온도는 ASHRAE TC 9.9 기준 18~27℃로 설정하였다. CRAH의 공급·회수공기 일반적인 온도차는 10~15℃로 본 논문에서는 11℃로 설정하였으며 냉동기의 공급·환수 냉수 온도차는 KS B 6270 냉동능력 표준 정격 조건을 기준으로 5℃로 설정하여 데이터 산출에 활용하였다. 산출된 데이터 항목 및 사용 수식과 생성된 데이터는 Table 13 ~ Table 15와 같다.

$$\begin{aligned} Q &= CRAH_{Mair} \times C_{air} (CRAH_{Tra} - CRAH_{Tsa}) \\ &= CH_{Mw} \times C_{water} (CH_{TraW} - CH_{TsaW}) \end{aligned} \quad \text{식(11)}$$

여기서,

Q : 회수공기 온도가 공급공기 온도가 되기 위해 제거되어야 할 열량

[kcal/hr] = 냉방부하

CRAH_Mair : CRAH 회수공기 풍량 [kg/hr]

C_{air} : 공기 비열 [kcal/kg℃]

$CRAH_{Tra}$: CRAH 회수공기 온도 [℃]

$CRAH_{Tsa}$: CRAH 공급공기 온도 [℃]

CH_{Mw} : 냉수유량 [kcal/hr]

C_{water} : 물 비열 [kcal/kg℃]

CH_{Tra_W} : 냉수 환수 온도 [℃]

CH_{Tsa_W} : 냉수 공급 온도 [℃]

Table 13. 냉각시스템 장비별 산출 데이터 리스트

구분	산출 데이터 항목	계산 수식 및 변수	
CRAH	Tset [℃] : 설정온도	범위	18~27
		수식	ASHRAE 기준 설정
	CRAH_Tsa [℃] : CRAH 공급공기온도	범위	18~27
		수식	$CRAH_Tra - CH_Q \div CRAH_Mair \div C_air$
	CRAH_Tra [℃] : CRAH 회수공기온도	범위	29~38
		수식	Tset range + 11℃
	ΔT [℃] : 공기 온도 오차	범위	-20~500
		수식	Tset - CRAH_Tsa
	IT Load [kW] : IT 서버 발열량	범위	5~100
		수식	Rack 14개 부분 부하로 설정
	CRAH_M_air [kg/hr] : CRAH 풍량	범위	32,570.08~1,628.50
		수식	$Rack_Total_Qit \div C_air \div \Delta 11^\circ C$ (Rack 발열에 따른 $\Delta 11^\circ C$ 를 만족하는 풍량)
냉동기	CH_Tsa_W [℃]: 공급냉수 온도	범위	7
		수식	고정
	CH_Tra_W [℃]: 환수냉수 온도	범위	12
		수식	고정
	Tra_W - Tsa_W [℃]: 냉수 온도 차	범위	5
		수식	고정
	C_water [kcal/kg℃]: 물 비열	범위	1
		수식	고정
	CH_Mw [kcal/hr]: 냉수유량	범위	0~40,000
		수식	Tset기준 IT발열 제거 가능한 범위로 설정
	CH_Q [kcal/hr]: 냉동기 제거 열량	범위	0~233
		수식	$C_water * CH_Mw * (CH_Tra_W - CH_Tsa_W)$
냉각탑	CT_Q [kcal/hr]: 냉각탑 제거 열량	범위	1~234
		수식	$CH_Q + 1kW$ (1kW = 압축기 소요동력)

Table 14. 냉각시스템 장비별 산출 데이터 일부 - CRAH

CRAH							
ΔT	Tset	Tsa	Tra	M _{air}	C _{air}	IT Load	Q
-11.00	18	29.00	29	32,570.08	0.24	100	-
-10.74	18	28.74	29	32,570.08	0.24	100	2,000
-10.49	18	28.49	29	32,570.08	0.24	100	4,000
-10.23	18	28.23	29	32,570.08	0.24	100	6,000
-9.98	18	27.98	29	32,570.08	0.24	100	8,000
-9.72	18	27.72	29	32,570.08	0.24	100	10,000
-9.46	18	27.46	29	32,570.08	0.24	100	12,000
-9.21	18	27.21	29	32,570.08	0.24	100	14,000
-8.95	18	26.95	29	32,570.08	0.24	100	16,000
-8.70	18	26.70	29	32,570.08	0.24	100	18,000
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
-11.00	18.00	29.00	29.00	24,427.56	0.24	75	-
-10.66	18.00	28.66	29.00	24,427.56	0.24	75	2,000
-10.32	18.00	28.32	29.00	24,427.56	0.24	75	4,000
-9.98	18.00	27.98	29.00	24,427.56	0.24	75	6,000
-9.64	18.00	27.64	29.00	24,427.56	0.24	75	8,000
-9.29	18.00	27.29	29.00	24,427.56	0.24	75	10,000
-8.95	18.00	26.95	29.00	24,427.56	0.24	75	12,000
-8.61	18.00	26.61	29.00	24,427.56	0.24	75	14,000
-8.27	18.00	26.27	29.00	24,427.56	0.24	75	16,000
-7.93	18.00	25.93	29.00	24,427.56	0.24	75	18,000
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
-11.00	18.00	29.00	29.00	16,285.04	0.24	50	-
-10.49	18.00	28.49	29.00	16,285.04	0.24	50	2,000
-9.98	18.00	27.98	29.00	16,285.04	0.24	50	4,000
-9.46	18.00	27.46	29.00	16,285.04	0.24	50	6,000
-8.95	18.00	26.95	29.00	16,285.04	0.24	50	8,000
-8.44	18.00	26.44	29.00	16,285.04	0.24	50	10,000
-7.93	18.00	25.93	29.00	16,285.04	0.24	50	12,000
-7.42	18.00	25.42	29.00	16,285.04	0.24	50	14,000
-6.91	18.00	24.91	29.00	16,285.04	0.24	50	16,000
-6.39	18.00	24.39	29.00	16,285.04	0.24	50	18,000
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
-11.00	18.00	29.00	29.00	8,142.52	0.24	25	-
-9.98	18.00	27.98	29.00	8,142.52	0.24	25	2,000
-8.95	18.00	26.95	29.00	8,142.52	0.24	25	4,000
-7.93	18.00	25.93	29.00	8,142.52	0.24	25	6,000
-6.91	18.00	24.91	29.00	8,142.52	0.24	25	8,000
-5.88	18.00	23.88	29.00	8,142.52	0.24	25	10,000
-4.86	18.00	22.86	29.00	8,142.52	0.24	25	12,000
-3.84	18.00	21.84	29.00	8,142.52	0.24	25	14,000
-2.81	18.00	20.81	29.00	8,142.52	0.24	25	16,000
-1.79	18.00	19.79	29.00	8,142.52	0.24	25	18,000

Table 15. 냉각시스템 장비별 산출 데이터 일부 - 냉동기, 냉각탑

냉동기						냉각탑
Tsa_W	Tra_W	Tra_W-Tsa_W	CH_Mw	C_water	CH_Q	CT_Q
7	12	5	-	1	-	859.85
7	12	5	400	1	2,000	2,859.85
7	12	5	800	1	4,000	4,859.85
7	12	5	1,200	1	6,000	6,859.85
7	12	5	1,600	1	8,000	8,859.85
7	12	5	2,000	1	10,000	10,859.85
7	12	5	2,400	1	12,000	12,859.85
7	12	5	2,800	1	14,000	14,859.85
7	12	5	3,200	1	16,000	16,859.85
7	12	5	3,600	1	18,000	18,859.85
.	.	.	.	.	.	.
.	.	.	.	.	.	.
.	.	.	.	.	.	.

3.4. 냉수유량 제어를 통한 실내 열환경 예측모델 개발

본 장에서는 예측모델 개발을 다룬다. 예측모델은 초기모델 설정 후 최적화를 통해 최적 성능 확보 후 완료된다. 본 논문에서의 인공신경망 기반 예측모델은 프로그래밍이 가능한 MATLAB을 활용하며 냉수 유량제어에 따른 CRAH의 공급공기 온도를 예측하는 역할을 담당한다.

입출력 변수 설정 후 데이터의 일반화를 위해 전처리를 시행 후 신경망의 학습 지표 및 출력 값을 결정하는 손실함수(Loss Function)와 활성화 함수(Activation Function), 손실함수를 최소화시키는 파라미터(Parameter)를 찾는 최적화 알고리즘(Optimization Algorithm)을 설정한다. 초기 설정된 변수 및 함수를 기반으로 초기 구조를 설정한다. 인공신경망의 초기 구조설정에는 정해진 기준이 없어 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer), 은닉뉴런 개수를 임의로 설정하였다. 초기 인공신경망 구조로 학습 후 예측정확도를 개선하기 위하여 최적화 함수의 적용으로 예측성능을 개선하여

최종적으로 제어알고리즘에 내포된다.(Fig. 23)

예측모델 개발 과정에서 본 논문의 예측모델 및 제어알고리즘이 인공신경망(ANN)으로 선택되어 개발된 타당성 마련을 위하여 타 기계학습 세 가지 예측모델을 구축하여 총 네 가지의 초기모델 예측성능 및 최적화 후 결과를 비교·분석하여 ANN 예측모델의 예측성능 우수성을 입증하고자 하였다. 기계학습에서는 연속형 데이터를 학습하는 경우 입·출력의 관계를 도출하는 것을 회귀의 방식으로 구분한다. 건물 시스템에 적용 가능하고 학습 방식에서 정답 데이터를 함께 학습시키는 지도학습 방식과 회귀를 동시 사용하는 대표적인 세 가지 학습 알고리즘으로 가우시안 프로세스 회귀(Gaussian Process Regression, GPR), 서포트 벡터 머신(Support Vector Machine, SVM), 랜덤 포레스트(Random Forest, RF)을 선정, MATLAB에서 제공하는 각 모델의 기본 구조를 사용하여 예측모델을 개발하였다.




Fig. 23 예측모델 개발 순서도

3.4.1. 입출력 변수 선정 및 데이터 전처리

예측모델은 입력되는 데이터를 통해 학습을 진행하여 예측을 수행하므로 활용 데이터의 양 및 질이 중요하다. 보편적으로 입력 데이터 선별에 회귀분석(Regression), 유전자 알고리즘(Genetic Algorithm), 상호 정보량(Mutual Information)등의 방법이 사용된다.¹⁰⁰⁾ 각각의 모델 모두 선정 데이터의 적합도 평가 지표로 사용되고 있으며 종속변수와 독립변수의 관계가 낮은 데이터는 입력데이터에서 제외시키는 과정을 거친다. 그러나 본 논문에서는 열역학 제1법칙에 근거한 열전달 수식을 사용하여 필요 냉수 유량을 산정하였으며 입력데이터는 실제 데이터센터에서 주로 센싱하여 얻는 데이터 목록과 수식에 필요한 변수를 위주로 선정, 최소화하여 구성하였다.

입력데이터는 3.2장에서 수치해석에 의해 생성한 20,200개의 데이터 중 CRAH의 공급공기 온도가 영하가 되는 데이터 세트를 제외하여 유의미한 데이터 12,930세트를 활용하였다. 냉수유량 제어를 통한 데이터센터의 실내 열환경 및 에너지 예측모델 개발을 위해 Table 16과 같이 입력 및 출력변수를 선정하였다. 예측모델은 IT 발열량에 의해 뜨거워진 CRAH 회수공기의 열 제거를 위해 냉수 유량을 제어하여 산출되는 CRAH 공급공기 온도를 예측하는 메커니즘을 갖는다. IT 발열량은 Rack당 최대 발열 6.6kW로 14개 Rack의 부분부하로 최대, 최소값으로 산정하였다. CRAH 회수공기 온도는 CRAH 공급공기가 IT 발열로 인해 뜨거워진 공기가 Hot Aisle로 토출되는 방식으로 CRAH 공급공기 온도와 $\Delta 11^{\circ}\text{C}$ 의 관계성을 갖게 산출된다. 냉수 유량은 IT 발열량에 의해 데워진 CRAH의 회수공기 온도를 $18\sim 27^{\circ}\text{C}$ 기준에 맞게 CRAH 공급공기 온도를

100) 강인성, 오피스건물 공조시스템의 인공지능경망 기반 에너지사용량 예측모델 개발, 석사학위논문, 중앙대학교, 2017.

냉각 시기기 위한 값으로 산출되었으며 400단위로 0~40,000 kcal/hr 범위로 설정하였다. 출력값인 CRAH 공급공기 온도는 ASHRAE 기준으로 데이터센터 허용 실내온도인 18~27℃로 설정하여 데이터 세트를 구성하였다.

Table 16. 데이터세트 구성

입력 변수	출력 변수
IT 발열량	CRAH 공급공기 온도 18~27℃, 10cases
5~100 kW, 5Unit, 20cases	
CRAH 회수공기 온도	
29~38℃, 10cases	
냉수유량	
0~40,000 kcal/hr, 400Unit, 101cases	

구성된 데이터세트를 인공신경망 학습은 데이터가 가진 특성(Feature)들을 비교하여 데이터의 패턴을 찾는다. 데이터가 가진 특성의 스케일이 심하게 차이나는 경우 과적합(Overfitting), 샘플링 잡음(Sampling noise) 및 샘플링 편향(Sampling bias)과 같은 문제가 발생할 수 있다. 과적합은 모델이 학습 데이터를 과하게 잘 학습하는 것을 뜻하는 것을 뜻한다. 일반적으로 학습 데이터는 실제 데이터의 부분집합인 경우가 대부분이기에 오차를 증가시키는 원인으로 작용한다. 샘플링 잡음은 데이터가 적어 대표성 없는 학습 데이터가 생기는 현상이며 샘플링 편향은 매우 많은 데이터도 표본 추출 방법이 잘못되면 대표성을 띠지 못할 경우를 의미한다. 따라서 데이터가 인공신경망에 학습되기 이전에 과적합 등의 문제 방지를 위해 모든 데이터가 동일한 정도의 중요도(Scale)로 반영되도록 하는 전처리 과정이 필요하다.

데이터 전처리에는 이외에도 다른 방법이 있겠으나 일반적으로 가장 널리 사용되는 방법은 정규화(Normalization)과 표준화(Standardization)이다. 정규화는 데이터의 구간을 0~1 범주로 변환하여 데이터 분포를 조정하고 표준화는 데이터들을 0의 평균, 1의 표준편차를 갖도록 변환해 준다.¹⁰¹⁾ 정규화와 표준화의 수식은 식 (12)~(13)과 같다.

$$\text{Normalization : } X = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad \text{식(12)}$$

$$\text{Standardization : } X = \frac{x - x_{\text{mean}}}{\sigma} \quad \text{식(13)}$$

3.4.2. 인공신경망 기반 초기 예측모델 구조설정

(1) 인공신경망 함수 설정

예측모델 개발을 위해 손실함수 및 활성화 함수가 필요하다. 손실함수는 정답에 대한 오류를 나타내는 것으로 정답에 가까울수록 작은 값이 나오고, 오답에 가까울수록 큰 값이 나온다. 손실함수를 줄이기 위해 사용하는 방법으로 평균제곱오차(Mean Squared Error, MSE)와 교차 엔트로피 오차(Cross Entropy Error, CEE)가 있다. 평균제곱오차는 식(14)와 같이 예측값과 실제값의 오차를 제곱하여 평균을 구한 값이며 일반적으로 회귀에서 사용되고 실제 정답에 대한 정답률의 오차뿐만 아니라 오답들에 대한 정답률 오차 또한 포함하여 계산한다는 것이

101) Yann LeCun, Leon Bottou, Genevieve B. Orr and Klaus-Robert Müller, Efficient BackProp, Neural Networks: Tricks of the Trade, Springer, 1998, pp. 9-50.

특징이다. 식(15)와 같은 교차 엔트로피 오차는 평균제곱오차와는 달리 오직 실제 정답과의 오차만을 파악하는 손실함수이다. 본 논문에서는 평균제곱오차를 선정하여 손실함수로 적용하였다.

$$MSE = \frac{1}{N} \sum_{i=1}^n (y_i - t_i)^2 \quad \text{식(14)}$$

$$CEE = - \sum_{i=0}^n t_i \log_e (y_i) \quad \text{식(15)}$$

여기서,

N: 표본의 개수

y_i : 실제값(정답)

t_i : 신경망의 출력(예측값)

I: 데이터 수

활성화 함수는 뉴런의 입력에 대해 출력을 결정하는 함수이다. 각 뉴런은 가중치(Weight)를 가지고 있으며 이것은 입력 데이터와 곱해져 다음 레이어로 전달하게 된다. 이때, 활성화 함수는 현재 뉴런의 입력 데이터를 전달하여 생성된 출력값에 다음 레이어로 전해지는 과정 중 역할을 수행하는 수학적인 게이트(Gate)라고 할 수 있다. 이 함수들은 신경망의 각 뉴런에 붙어 있으며 뉴런의 입력이 모델의 예측과 관련이 있는지 없는지를 근거로 활성화 시행 여부를 결정한다. (Fig. 24)








Fig. 24 활성화 함수의 역할

일반적으로 사용되는 활성화 함수는 계단함수(Step Function), 시그모이드 함수(Sigmoid Function), Tanh 함수(Tanh Function), ReLu 함수(Rectified Linear Unit Function)가 있으며 Table 17과 같다. 계단함수는 입력이 양수일 때는 1을 출력하고 음수일 때는 0을 출력하는 이진적 함수이다. 출력 사이에 값이 없어 미분이 불가능하여 미분을 활용한 최적화 함수에서 쓸 수 없다는 단점이 있다. 시그모이드 함수는 Logistic 함수라고도 불리기도 하며 x 값에 따라 0~1의 값을 출력하는 S자형 함수이다. 미분 결과가 간결하고 사용하기 용이하기 때문에 초기 단계에서 꼭 다루는 함수이다. Tanh 함수는 시그모이드 함수를 개선하고자 도출된 함수이며 입력 신호를 -1~1로 정규화 한다. 미분 함수에 대해 일정 값 이상에서의 미분 값이 소실되는 Vanishing Gradient Problem 한계가 있다. ReLu 함수는 경사 함수로 가장 많이 사용되는 활성화 함수 중 하나이다. x 가 0보다 크면 기울기가 1인 직선, 0보다 작으면 함수값이 0이 된다. 이는 0보다 작은 값들에서 뉴런이 줄을 수 있는 단점을 일으킨다. 본 논문에서는 시그모이드 함수를 활성 함수로 활용한다.

Table 17. 활성화 함수 종류 및 비교

함수	수식 및 그래프	함수	수식 및 그래프
Step Function	 $f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	Tanh Function	 $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Sigmoid Function	 $f(x) = \frac{1}{1 + e^{-x}}$	ReLU Function	 $f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$

최적화 알고리즘은 손실함수를 최소화시키는 파라미터(Parameter)들을 찾는 과정을 의미한다. 인공지능망의 초기 최적화 알고리즘으로 경사 하강법(Gradient Descent)으로 모멘텀(Momentum) 및 학습률(Learning Rate), 조기 중지 및 정규화 등이 추가된 알고리즘들이 개발되었다. 이후 최적화 증대를 위해 개발된 학습 알고리즘에는 대표적인 모델로 역전파 알고리즘(Backpropagation)이 있다. 역전파 알고리즘이란 학습 과정 및 반복(Iteration)마다 이전 반복의 오차를 반영하여 이전 단계의 신경층으로 신호를 전달하는 학습법으로, 입력-은닉-출력층 순으로 데이터가 순전파(Feedforward) 전개될 때의 신경망 학습 결과와 출력 데이터의 오차를 역전파(Backpropagation)으로 전달하여 가중치를 갱신한다.¹⁰²⁾

오차 역전파 알고리즘에는 대표적으로 사용되는 Levenberg-Marquadt

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

(LM) 알고리즘이 있다. (Fig. 25)¹⁰³⁾ LM 알고리즘은 학습의 반복 및 진행 상황의 오차에 따라 학습 오차가 클 때 경사하강법(Gradient Descent Method)을 사용하여 오차의 기울기가 최소화가 되는 영역을 찾으며, 학습 오차가 작을 때에는 가우스-뉴턴법(Gauss-Newton Method)을 사용하여 최소 오차가 발생하는 방향으로 빠르게 학습을 진행 시킨다.¹⁰⁴⁾ LM 알고리즘은 인공신경망의 다양한 최적 학습 알고리즘 중 비교적 빠르고 안정적으로 정답을 예측하는 것으로 평가되고 있어 본 논문에서 최적 알고리즘으로 LM을 적용하였다. 본 논문의 예측모델에 적용한 최종 함수 및 알고리즘은 Table 18과 같다.




Fig. 25 Levenberg-Marquardt 알고리즘 흐름도

103) T. Y. Liu., P. Zhang., J. Wang., Y. Ling., Compressive Strength Prediction of PVA Fiber- Reinforced Cementitious Composites Containing Nano-SiO₂ Using BP Neural Network, Materials, 2020, 13(521), pp.1-25.

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

Table 18. 인공신경망 기반 예측모델 적용 함수

항목	함수
손실함수 (Loss Function)	평균제곱 오차(Mean Squared Error, MSE)
활성화 함수 (Activation Function)	시그모이드 함수(Sigmoid)
최적화 알고리즘 (Optimization Algorithm)	LM 알고리즘(Levenberg-Marquardt)

(2) 인공신경망 구조설정

인공신경망의 초기 구조설정에는 정해진 기준이 없어 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer), 은닉 뉴런 개수를 임의로 설정하였다. 입력층, 은닉층, 출력층은 각각 1개의 층이다. 입력 뉴런의 개수는 입력층의 경우 입력 데이터인 IT 발열량, CRAH 회수공기 온도, 냉수 유량에 따라 3개, 출력층 뉴런의 개수는 CRAH 공급공기 온도 1개, 은닉층의 뉴런은 10개로 설정하였다. (Fig. 26)




Fig. 26 초기 인공신경망 예측모델 구조

(3) 학습 데이터 설정

학습 데이터는 3.10.1에서 언급한 12,930개의 데이터 세트를 사용한다. 개발된 예측모델이 새로운 환경에 얼마나 잘 일반화될지 그 성능을 아는 방법은 새로운 샘플에 실제로 적용해 보는 것이다. 그 전에 미리 성능을 평가해 볼 방법은 데이터를 Train set, Validation set, Test set으로 분리하여 학습시키는 것이다. 일반적으로 Train, Validation, Test를 Simple Validation 방법을 사용하여 60:20:20의 비율로 나누는 것이 적합하다.¹⁰⁵⁾ Train set은 분석 모델을 만들기 위한 학습용 데이터이고 Validation set은 Train set의 일부 활용으로 여러 분석 모델 중 어떤 모델이 적합한지 선택하기 위한 검증용 데이터이다. Test set은 최종적으로 선택된 분석 모델이 얼마나 잘 작동하는지 확인하기 위한 결과용 데이터로 Training 과정에 관여하지 않는다.

일반적으로 Validation set이 간과되는 경우가 많은데 학습 모델의 성능을 평가하기 위해서 매우 중요하다. 인공신경망 기반 예측모델의 목적은 결국 Test set에 대해 좋은 성능을 내는 것인데, 이를 위해 Train set의 일부를 활용하여 해당 예측모델이 확인되지 않는 데이터에 대해 얼마나 잘 동작할지에 대해서 반드시 확인이 필요하다. 예를 들어 Train 정확도는 높는데 Validation의 정확도가 낮다면 데이터가 Train set에서 과적합이 일어났을 가능성이 있다. 그렇다면 과적합을 방지하여 Train의 정확도를 희생하더라도 Validation 정확도와 비슷하게 맞춰줄 필요가 있다. 즉, Validation set에 대한 정확도가 중요한 이유는 학습 과정에서 과적합에 빠지지 않고 확인되지 않는 데이터에 대한 좋은 성능을 낼 수 있게 하는 핵심적인 역할을 하기 때문이다. 본 논문에서는 랜덤으로 난수를 생성하는 Mersenne Twister를 활용하여 Train set, Validation set,

105) Aurelien Geron, Hands-On Machine Learning with Scikit-Learn & Tensorflow, OREILLY, 2017.

Test set을 60:20:20로 분리하여 학습에 적용하였다. (Fig. 27), (Table 19)

개발된 초기 인공신경망 예측모델의 상세는 Table 20과 같다. 초기 예측모델은 통계적 기법에 따라 예측정확도 및 타당성을 평가한 후 최적화를 진행한다. 최적화는 은닉층 수 및 뉴런 개수와 기타 LM 알고리즘의 다양한 최적화 기술에 대해 수행되며 ANN의 예측정확도 우수성 확인을 위하여 세 가지의 기계학습 모델과 최적화 성능을 비교·분석하게 된다.




Fig. 27 데이터 세트의 구성

Table 19. Train, Validation, Test Data set의 용도

구분	Train	Validation	Test
학습 과정에서 참조	O	O	X
모델의 가중치 설정에 인용	O	X	X
모델의 성능평가에 이용	X	O	O

Table 20. ANN 초기 예측모델 상세

구분		내용
Function	Loss	• Mean Squared Error
	Activation	• Sigmoid
	Optimization Algorithm	• Levenberg-Marquardt
Structure	Input Layer	• Number of Layer: 1 • Number of Neuron: 3 - IT Load - CRAH Return air Temperature - Chiller water mass flow
	Hidden Layer	• Number of Layer: 1 • Number of Neuron: 10
	Output Layer	• Number of Layer: 1 • Number of Neuron: 1 - CRAH Supply air Temperature
Training Method		• Time step: 3,000 • Max fail: 200

3.4.3. GPR, SVM, RF 초기 예측모델 설정

세 가지 유형 기계학습 모델의 입·출력변수 및 데이터 전처리, 학습 데이터 설정은 ANN 모델 설정과 같다. GPR, SVM, RF 학습 모델의 구조는 회귀 모델 형태로 ANN 모델 개발과 같이 별도의 함수 및 구조설정 과정은 필요치 않다. 각 모델은 MATLAB에서 제공하는 Default 값으로 함수값 및 구조로 설정하여 자동으로 설정되는 변수들로 예측을 수행한다. 개발된 세 가지 초기모델의 상세 값은 Table 21과 같다.

Table 21. GPR, SVM, RF 예측모델의 초기 구조설정

학습 알고리즘	Hyperparameters (초매개변수)	Value
GPR	Sigma	6.7743
	Basis Function	pureQuadratic
	Kernel Function	Squared Exponential
SVM	Epsilon	1.1739
	Box Constraint	11.7388
	Kernel Scale	1
RF	Method	LSBoost
	Learning Rate	1
	NumCycling	100

3.5. 예측모델 기반 냉수 유량 최적 제어알고리즘 개발

냉수 유량 최적 제어알고리즘은 최적화된 예측모델이 내재 되며 예측모델 재학습 과정을 포함하도록 개발되었다. 재학습 과정은 예측모델이 새로운 제어시나리오를 받아들이거나 새로운 시스템 환경에 적응시키며 최적 공조제어를 통해 데이터센터의 에너지 성능을 향상하기 위하여 본 과정을 지속해서 반복하게 된다.

최근 능동적 학습이 가능한 예측모델의 개발을 통해 실시간 학습 및 제어 가능한 온라인 학습(Online Learning)의 개념이 등장하였다. (Fig. 28)¹⁰⁶⁾ 온라인 학습은 예측모델의 예측 오차를 실시간으로 평가하고 줄여나가기 위한 실시간 학습을 의미한다.




Fig. 28 온라인 학습 개념도

본 논문에서는 인공신경망 기반 예측·적응 제어를 온라인 학습 알고리즘에 기반을 두어 Vector Augmentation, Vector Adaptation, Sliding Window 세 가지로 선정하여 적응 제어를 시행하였다.

106) J.C. Schlimmer, R.H. Granger, JR, Incremental Learning from Noisy Data, Machine Learning, 1986, 1, pp.317-354.

Vector Augmentation은 초기 학습 이후 각 제어 단계마다 도출되는 정답 데이터를 배열 형태로 늘려가며(Augmentation) 학습시키는 방식으로 제어 단계에서 발생하는 정답 데이터들을 초기 학습된 신경망에 지속해서 반영하여 단계마다 새로운 데이터를 신경망에 학습시킨다. 제어가 시행될수록 배열 크기가 증가하여 학습 시간이 증가한다는 단점이 있으나, Vector Adaptation과 Sliding의 중간적인 성질을 갖는다.

Vector Adaptation은 예측모델의 초기 학습 이후 정답 데이터를 배열이 아닌 벡터(Feature 1개)로 학습시키는 방식으로 제어 단계에서 신속하게 적응 학습을 한다. 새로운 데이터 벡터에 대해 빠르게 학습하고 가중치와 편향치를 새로운 데이터에 적합하게 급격히 변화시킨다. 그러나 학습 데이터 크기가 벡터이므로 이전 데이터에 대한 추세와 입출력 관계성이 제거될 수 있는 우려가 있다.

Sliding Window는 학습 시작부터 이전 데이터를 한 개씩 삭제하고 마지막 위치에 새로운 데이터를 입력하여 학습시키는 방식으로 기존 학습 데이터 배열의 크기 및 추세를 유지하며 새로운 정답 데이터의 특성을 신경망에 반영한다. 제어 환경이 학습 데이터의 범위 내에서 크게 변동하지 않을 것이라는 가정하에 가중치와 편향치를 갱신해나간다. 제어가 수행될수록 입력되는 새로운 정답 데이터의 수가 늘어나지만, 초기 학습 시 가중치 및 편향치를 급격히 갱신시키지는 않는다. 제어 단계가 늘어나도 일정한 학습 시간을 유지하는 특성을 갖는다.

제어는 5분 단위로 수행된다. n 번째(현재) 사이클의 IT 서버 발열($IT\ Load_{(n)}$), CRAH 회수공기 온도($CRAH_Tra_{(n)}$), CRAH 공급공기 온도($CRAH_Tsa_{(n)}$) 취득하여 $n-1$ 번째(과거 5분 전) 사이클에서 예측되었던 CRAH 공급공기 온도($Predict\ CRAH_Tsa_{(n-1)}$)와 현재의 CRAH 공급공기 온도를 비교한다. 두 값이 같지 않으면 $IT\ Load_{(n-1)}$,

CRAH_Tra_(n-1), CRAH_Tsa_(n), 현재의 최적 냉수 유량(Optimal CH_Mw_(n))으로 예측모델을 재학습 시킨다. 두 값이 같을 경우에는 IT Load_(n), CRAH_Tra_(n), 최저~최고 냉수 유량인 1000개의 냉수 유량 데이터(CH_Mw_(0:40:40,000))로 구성된 입력 데이터를 생성한다. 생성된 데이터를 ANN 예측모델에 대입하여 n+1번째(미래 5분 후) 사이클의 CRAH 공급공기 온도(Predict CRAH_Tsa_(n))를 예측한다. Predict CRAH_Tsa_(n)과 설정온도(Tset)을 비교하여 오차가 0.1℃ 미만일 때의 냉수 유량을 최적 유량 (Optimal CH_Mw_(n+1))으로 선정한다. 선정된 최적 유량으로 n+1번째 냉각 시스템을 운전하게 된다. 해당 적응형 제어알고리즘을 통해 예측모델은 지속해서 수정·개선되며 새로운 환경에 적응해 나갈 수 있다. 언급한 제어 사이클로 도출된 제어알고리즘은 Fig. 29와 같다.




Fig. 29 예측·적응 제어알고리즘

3.6. 제어알고리즘 성능평가를 위한 시뮬레이션 모델 구축

본 논문에서의 예측기반 적응 제어알고리즘은 인공지능망 기술을 활용하여 개발되었다. 인공지능기술 기반 제어알고리즘의 성능을 적절히 검증하기 위해서는 기존 동적 시뮬레이션보다 합리적이고 효율적인 시뮬레이션이 모델이 필요하다. 여기서 시뮬레이션 모델이란 제어알고리즘의 해석 모델이라고도 할 수 있다.

현재 보편적으로 사용되고 있는 EnergyPlus, Transys, ESP-r, eQuest, Designbuilder 와 같은 동적 시뮬레이션 프로그램을 이용한 건물에너지 해석¹⁰⁷⁾은 사용자 인터페이스의 발전에 힘입어 건물 현상의 사실적 묘사가 가능하며 다양한 현상에 대한 면밀한 비교와 분석을 할 수 있다. 그러나 이와 같은 장점에도 동적 시뮬레이션 프로그램을 사용하기 위해서는 방대하고 정교한 입력 값 선택을 요구하며 복잡한 입력구조와 확률적 미지의 변수들을 반영해야 하는 어려움이 시뮬레이션의 한계나 단점으로 언급되기도 한다.¹⁰⁸⁾

최근에는 시뮬레이션의 목적에 따라 유용하게 사용할 수 있는 Tool을 별도로 개발하여 사용하기도 한다.¹⁰⁹⁾ 데이터센터에 적용되는 냉각시스템의 예측·적응 제어알고리즘 모델의 경우 데이터센터의 각종 환경 변화에 대한 유연성, 확장성에 대응하여 목표값을 예측·제어하는 기능이 필수적이다. 본 논문에서는 데이터센터의 냉각시스템 예측 및 제어모델 개발을 목표로 하며 이에 특화된 성능평가를 위한 별도의 시뮬레이션 모델이 필요하다고 판단하였다.

따라서 본 연구에서는 제어알고리즘의 입출력 변수 평가를 위한 시뮬레

107) 현석균, 건물냉난방에너지의 동적성능시뮬레이션, 석사학위논문, 경희대학교, 2003.

108) 라선중, 신한술, 서원준, 추한경, 박철수, 기존 건물 HVAC 시스템에 대한 다섯 가지 기계학습 모델 개발, 대한건축학회 논문집, 2017, 33(10), pp.69-77.

109) 김석우, 에너지 시뮬레이션 기술 동향, 건축환경설비, 2015, 9(1), pp. 22-30.

이선 모델을 입력변수 조절 및 변환을 할 수 있으며, 수치해석과 프로그래밍 환경이 가능한 MATLAB 소프트웨어¹¹⁰⁾를 선정하여 개발하였다. 기존의 동적 시뮬레이션 프로그램에서 사용되는 이론을 활용하고 일반적으로 적용되고 있는 기본형 컨테인먼트 데이터센터로 설정하여 대상 모델을 일반화하였다. 냉각시스템은 본 논문의 대상 냉각시스템인 중앙 냉수식 시스템의 메커니즘을 적용하였다. Fig. 30 ~ Fig. 31은 MATLAB을 이용한 시뮬레이션 모델을 보여준다.

구축된 시뮬레이션 모델은 3.2장에서 언급한 냉각시스템과 동일한 구조로 냉각탑 및 냉동기, CRAH, Rack으로 구성되며 실제 냉각시스템을 모사한 메커니즘을 따른다. RACK으로부터 발생하는 열량에 의해 뜨거워진 Hot Aisle 측의 CRAH 순환공기 온도 냉각을 위해 냉동기에서 냉수 유량 제어가 시행되며 이를 통하여 Cold Aisle 측의 CRAH 공급공기 온도가 산출되는 방식으로 구축되었다. 또한, 제어된 냉수유량에 따른 냉동기 및 냉각탑에서 제거해야 할 열량인 냉방부하를 산출한다.

구축된 시뮬레이션 모델의 타당성 분석은 4장 ‘성능평가 및 검증’에서 Hot Aisle과 Cold Aisle의 온도 분포와 냉방에너지 소비량을 대상 데이터센터와 유사한 실제 데이터센터와의 실내 환경 및 냉방에너지 소비량 유사도로 같음을한다. 이에 따라 구축된 시뮬레이션 모델이 실제 데이터센터의 실내환경 모사 정도를 판단하여 제어알고리즘의 성능평가용으로서의 타당성을 입증한다.

110) MathWorks, <https://www.mathworks.com/> (access: 2020.09.11.)




Fig 30 중앙 냉수 시스템의 시뮬레이션 모델화

```

Editor - DWDC_Cooler.m
DCC_CRAH.m  DCC_Rack.m  DCC_Cooler.m  +
1 function [Chl_Wv,Chl_Tra] = DCC_Cooler(Chl_Wv)
2
3     %냉동기 1A [Row1]
4     Chl_Tsa = 7;           %냉동기 출수 온도 [C]
5     Chl_Tra = 12;         %냉동기 흡입 온도 [C]
6     Chl_Wv = Chl_Wv/2;    %냉수 유량 [kg/hr]
7     Chl_Qc = 1;           %냉수 비열 [kcal/kg C]
8
9     %냉동기 1B [Row2]
10    Chl_Tsa = 7;           %냉동기 출수 온도 [C]
11    Chl_Tra = 12;         %냉동기 흡입 온도 [C]
12    Chl_Wv = Chl_Wv/2;    %냉수 유량 [kg/hr]
13    Chl_Qc = 1;           %냉수 비열 [kcal/kg C]
14
15    %냉각탑
16    Cl_Tsa = 32;           %냉각탑 출수 온도 [C]
17    Cl_Tra = 37;          %냉각탑 흡입 온도 [C]
18    end
  
```

(a) Cooling tower and refrigerator

```

Editor - D:\DCC_CRAH.m
1 DCC_CRAH.m  DCC_Rack.m  DCC_Chiller.m  +
2 function CRAH_Mair = DCC_CRAH(Row1_Mair, Row2_Mair, CRAH_Tsa)
3
4 %CRAH_A (Computer Room Air Handling Unit) [Row1]
5 CRAH_A_Tsa = CRAH_Tsa; %CRAH 출구 온도
6 CRAH_A_Tra = CRAH_A_Tsa+11; %CRAH 입구 온도
7 CRAH_A_Mair = Row1_Mair/3; %공기 풍량 [kcal/hr]
8 CRAH_A_Cair = 0.24; %공기 비열 [kcal/kg C]
9
10 %CRAH_B (Computer Room Air Handling Unit) [Row1]
11 CRAH_B_Tsa = CRAH_Tsa; %CRAH 출구 온도
12 CRAH_B_Tra = CRAH_Tsa+11; %CRAH 입구 온도
13 CRAH_B_Mair = Row1_Mair/3; %공기 풍량 [kcal/hr]
14 CRAH_B_Cair = 0.24; %공기 비열 [kcal/kg C]
15
16 %CRAH_C (Computer Room Air Handling Unit) [Row1]
17 CRAH_C_Tsa = CRAH_Tsa; %CRAH 출구 온도
18 CRAH_C_Tra = CRAH_Tsa+11; %CRAH 입구 온도
19 CRAH_C_Mair = Row1_Mair/3; %공기 풍량 [kcal/hr]
20 CRAH_C_Cair = 0.24; %공기 비열 [kcal/kg C]
21
22 %CRAH_D (Computer Room Air Handling Unit) [Row2]
23 CRAH_D_Tsa = CRAH_Tsa; %CRAH 출구 온도
24 CRAH_D_Tra = CRAH_Tsa+11; %CRAH 입구 온도
25 CRAH_D_Mair = Row2_Mair/3; %공기 풍량 [kcal/hr]
26 CRAH_D_Cair = 0.24; %공기 비열 [kcal/kg C]
27
28 %CRAH_E (Computer Room Air Handling Unit) [Row2]
29 CRAH_E_Tsa = CRAH_Tsa; %CRAH 출구 온도
30 CRAH_E_Tra = CRAH_Tsa+11; %CRAH 입구 온도
31 CRAH_E_Mair = Row2_Mair/3; %공기 풍량 [kcal/hr]
32 CRAH_E_Cair = 0.24; %공기 비열 [kcal/kg C]
33
34 %CRAH_F (Computer Room Air Handling Unit) [Row2]
35 CRAH_F_Tsa = CRAH_Tsa; %CRAH 출구 온도
36 CRAH_F_Tra = CRAH_Tsa+11; %CRAH 입구 온도
37 CRAH_F_Mair = Row2_Mair/3; %공기 풍량 [kcal/hr]
38 CRAH_F_Cair = 0.24; %공기 비열 [kcal/kg C]
39

```

(b) CRAH

```

Editor - D:\DCC_Rack.m
1 DCC_CRAH.m  DCC_Rack.m  DCC_Chiller.m  +
2 Rack 17개의 세그먼트로 IT 부하는 [kW]로 받아 kcal/hr로 변환
3 후 1kW = 860 kcal/hr로 계산
4 function [Rack_total_Qit, Row1_Mair, Row2_Mair] = DCC_Rack(s, Rack)
5
6 %RACK_A [Row1]
7 RACK_A_Qit = Rack(s,1);
8 RACK_A_Mair = RACK_A_Qit+860/((11*0.24));
9
10 %RACK_B [Row1]
11 RACK_B_Qit = Rack(s,2);
12 RACK_B_Mair = RACK_B_Qit+860/((11*0.24));
13
14 %RACK_C [Row1]
15 RACK_C_Qit = Rack(s,3);
16 RACK_C_Mair = RACK_C_Qit+860/((11*0.24));
17
18 %RACK_D [Row1]
19 RACK_D_Qit = Rack(s,4);
20 RACK_D_Mair = RACK_D_Qit+860/((11*0.24));
21
22 %RACK_E [Row1]
23 RACK_E_Qit = Rack(s,5);
24 RACK_E_Mair = RACK_E_Qit+860/((11*0.24));
25
26 %RACK_F [Row1]
27 RACK_F_Qit = Rack(s,6);
28 RACK_F_Mair = RACK_F_Qit+860/((11*0.24));
29
30 %RACK_G [Row1]
31 RACK_G_Qit = Rack(s,7);
32 RACK_G_Mair = RACK_G_Qit+860/((11*0.24));
33
34 %RACK_H [Row2]
35 RACK_H_Qit = Rack(s,8);
36 RACK_H_Mair = RACK_H_Qit+860/((11*0.24));
37
38 %RACK_I [Row2]
39 RACK_I_Qit = Rack(s,9);
40 RACK_I_Mair = RACK_I_Qit+860/((11*0.24));
41

```

(c) Rack

Fig. 31 MATLAB 활용 냉각시스템 시뮬레이션 모델 시행 화면

3.7. 소결

본 장에서는 대상 데이터센터 및 냉각시스템의 구성 및 구조를 밝히고, 예측모델에 적용될 데이터 생성과 예측모델 및 제어알고리즘을 개발하였다. 또한, 인공신경망 기반 제어알고리즘 성능평가용 시뮬레이션 모델을 별도로 개발하였다.

학습용 데이터 세트는 냉수 유량제어를 통한 CRAH 공급공기 온도 예측모델의 학습에 이용되고 예측모델은 적응형 제어알고리즘에 내포된다. 개발된 제어알고리즘은 MATLAB을 사용하여 개발된 시뮬레이션 Tool로 성능평가를 수행하게 된다. 상세내용은 다음과 같다.

(1) 본 논문의 대상 데이터센터는 Hot Aisle형 컨테인먼트 방식으로 선정하였다. 컨테인먼트 1개소는 14개의 Rack이 7개씩 1Row로 배치된다. Rack의 후면부를 공유하는 Hot Aisle이 중심부에 위치하고 양 외측으로 Cold Aisle이 위치 한다. 전면차폐 구조로 내부발열은 외부와 열교환은 발생하지 않는 것으로 가정한다. Rack은 최대 6.6kW의 발열, 부분 부하로 운영된다. 일반적인 서버의 입·출구 온도차는 10~15℃로 가정하며 본 논문에서는 11℃로 설정하였다.

컨테인먼트에 연결되는 냉각시스템은 중앙 냉수식 시스템이며 냉각탑-냉동기-냉매분배기-CRAH로 구성된다. 냉각수는 32±5℃로 공급되며 냉동기는 7℃의 냉수를 냉매분배기를 거쳐 CRAH에 냉기를 공급한다. 냉수는 입·출구 온도 Δ5℃를 기준으로 작동한다. 냉매분배기는 냉매 액펌프에 의해 R134a 냉매(20℃)를 순환시키는 장비로써 컨테인먼트 내에 결로를 발생시킬 가능성이 있는 냉수의 출입을 배제하기 위한 열전달 수단이다. CRAH는 30kW의 용량으로 Row 당 최대 서버발열량은 46.2kW로 설정하였다.

(2) 예측모델 및 제어알고리즘에 적용될 입력데이터는 수학적 모델에 의하였으며 열전달 수식을 사용하여 총 20,200개를 생성하였다. CRAH에서는 설정온도(T_{set}), CRAH 공급공기 온도와 순환공급공기 온도($CRAH_{Tsa}$, $CRAH_{Tra}$), Rack 단위 IT 발열($Rack_Total_Q_{it}$), CRAH의 풍량($CRAH_M_{air}$), 공기비열(C_{air}), CRAH_Q(공기측 제거 열량), 설정온도와 CRAH 공급공기 온도의 차를 요소로 활용하여 산출, 데이터로 생성된다. 냉동기에서는 공급냉수 온도(CH_{Tsa_W}), 환수냉수 온도(CH_{Tra_W}), 환수냉수와 공급냉수의 온도 차($CH_{Tra_W} - CH_{Tsa_W}$), 물의 비열(C_{water}), 냉수 유량(CH_M_w) 그리고 냉동기 에너지소비량을 대체할 냉동기에서의 제거 열량(CH_Q)이 계산되어 데이터가 생성된다. 냉각탑에서는 에너지소비량을 대체할 제거 열량(CT_Q)만을 데이터로 선정하였다.

(3) 인공신경망 기반 예측모델은 프로그래밍이 가능한 MATLAB을 활용하며 냉수 유량제어에 따른 CRAH의 공급공기 온도를 예측하는 역할을 담당한다. 입력변수는 IT 발열량, CRAH 회수공기 온도, 냉수 유량이며 출력변수는 CRAH 공급공기 온도이다. CRAH 공급공기 온도는 ASHRAE 기준으로 데이터센터 허용 실내온도인 18~27℃로 산정하였으며 전처리 과정을 거친다. 초기 예측모델의 구조는 입력층, 은닉층, 출력층은 각각 1개의 층이다. 입력 뉴런의 개수는 입력층의 경우 입력 데이터인 IT 발열량, CRAH 회수공기 온도, 냉수 유량에 따라 3개, 출력층 뉴런의 개수는 CRAH 공급공기 온도 1개, 은닉층의 뉴런은 10개로 설정하였다.

(4) 예측모델 기반 냉수 유량 최적 제어알고리즘은 초기 예측모델에서 Sliding Window, Vector Adaptation, Vector Augmentation의 세 가지

재학습 과정이 추가되어 새로운 제어 시나리오를 받아들여서 새로운 시스템 환경에 적응시키며 최적 공조제어를 통해 데이터센터의 에너지 성능을 향상한다. 제어는 5분 단위로 수행되며 IT 발열량 제거를 통해 설정 CRAH 공급공기 온도에 만족하기 위한 최소 냉수 유량을 예측한다. 예측한 냉수 유량 적용 시 5분 후 설정 온도에 만족하는 CRAH 공급공기 온도로 제어되는지에 따라 재학습 또는 제어 사이클을 반복한다. 해당 제어알고리즘을 통해 예측모델은 지속해서 수정하고 개선되며 새로운 환경에 적응해 나갈 수 있다. 제4장에서는 세 가지 재학습 알고리즘 중 가장 우수한 제어성능을 나타내는 알고리즘을 최종 제어알고리즘으로 선정하여 적응성을 검증한다.

(5) 제어알고리즘의 성능 확인을 위해 데이터센터의 각종 환경변화에 대한 유연성, 확장성에 신속하게 대응 가능한 별도의 시뮬레이션 모델을 개발하였다. 제어알고리즘의 입출력변수 평가를 위한 시뮬레이션 모델로, 입력변수 조절 및 변경 가능하며 수치해석과 프로그래밍 환경이 가능한 MATLAB을 활용하여 개발하였다. 냉각 시스템은 대상 컨테이너먼트형 데이터센터에 연결되는 메커니즘을 따른다. RACK으로부터 발생하는 열량에 의해 뜨거워진 Hot Aisle 측의 CRAH 회수공기 온도 냉각을 위해 냉동기에서 냉수 유량제어가 시행되며 이를 통하여 Cold Aisle 측의 CRAH 공급공기 온도가 산출되는 방식으로 구축되었다. 또한, 제어된 냉수 유량에 따른 냉동기 및 냉각탑에서 제거해야 할 냉방부하를 산출한다.

시뮬레이션의 타당성 분석은 Hot Aisle과 Cold Aisle의 온도 분포에 대하여 실제 데이터센터 실내 환경과 산출된 냉방부하를 활용한 냉방 에너지소비량의 유사도로 판단하여 제어알고리즘의 성능평가용으로 타당성을 입증하는 것으로 한다. 개발모델 및 시뮬레이션 타당성능 평가는 제4장에서 수행된다.

제 4 장 예측모델 및 제어알고리즘 성능평가 및 검증

4.1. 성능평가 개요

본 장에서는 개발된 예측모델 및 제어알고리즘의 성능평가를 실시하였다. 냉수 유량제어를 통한 CRAH 공급공기 온도 예측모델은 Test 데이터 세트에서 입력변수를 받아 CRAH 공급공기 온도를 예측하며 예측값은 정답과 비교된다. 결과는 통계적 기법으로 예측 정확도를 산출하여 타당성 평가가 시행된다. 예측모델의 최적화는 구조 및 최적화 매개변수를 변경하여 진행되며 가장 예측정확도가 우수한 모델이 최종 예측모델로 선정되어 제어알고리즘에 내장된다. 시뮬레이션을 활용한 제어알고리즘 성능평가에 대해 대상 데이터센터와 유사한 실제 데이터센터의 실내환경 및 냉방 에너지소비량의 유사도를 비교·분석하여 타당성을 검증한다.

타당성이 확보된 제어알고리즘모델은 새로운 환경에서의 적응성능이 우수해야 한다. 적응성능 평가를 위해 비적응형 제어알고리즘과 오차 재학습 알고리즘을 내포한 지능형 제어알고리즘의 비교·평가한다. 예측기반 제어알고리즘의 적응성 평가는 컨테이너먼트 규모 변경, IT 부하 및 실내 설정온도를 변경한 시뮬레이션을 통해 최소의 냉수 유량으로, 최소의 냉방부하를 산출하는 CRAH의 공급공기 온도가 설정온도에 가장 적합한 값을 채택한다. 이후, 실시간 시뮬레이션을 통해 입력되는 데이터를 바탕으로 자가 학습을 통해 지능적으로 예측모델을 수정하며 상황에 맞는 제어 값을 도출한다.

인공신경망 기반의 지능형 제어알고리즘의 최종 적응성 검증은 기존에 일반적으로 적용되고 있는 제어 기법인 ON/OFF, PID와 비교분석 되어 인공신경망 제어알고리즘의 제어 안정성과 적응성의 우수성을 입증하고자 한다.

4.2. 예측모델의 예측정확도 평가 및 최적화

4.2.1. 초기 예측모델 성능평가

(1) 예측성능 평가 기준 설정

예측모델의 예측정확도는 예측값과 정답의 오차에 의해 비교 평가된다. ASHRAE 에서는 예측 결과와 정답 값에 대한 평가 기준으로 0.8 이상의 결정계수(R-Squared, R^2)와 30% 이하의 평균 제곱근 오차의 변동계수 $Cv(RMSE)$ (Coefficient of Variation of the Root-Mean)을 제시하고 있다.¹¹¹⁾ 결정계수 R^2 는 선형 회귀 모델의 직선 적합도를 평가할 때 사용한다. 즉, 실제 정답과 예측값이 얼마나 일치하는지, 상관관계를 의미하며 예측성능이 얼마나 정확한지를 나타내는 값이다. 계산은 정답과 예측값 간의 오차를 제곱하면 된다. $Cv(RMSE)$ 는 실제 값과 예측값의 차이를 파악하는 척도로 R^2 보다 평가 기준으로 비중 있게 사용되며 예측 데이터와 정답 데이터 간의 정밀도를 의미한다. 두 계수의 계산 방법은 식(16)~(18)과 같다.

$$R^2 = \frac{Q - Q_e}{Q} \quad \text{식(16)}$$

여기서,

Q : 전체 데이터의 편차들을 제곱하여 합한 값

Q_e : 전체 데이터의 잔차들을 제곱하여 합한 값

111) ASHRAE, ASHRAE Guideline 14-2014, Measurement of Energy and Demand, and Water Savings, 2014.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum (y_i - t_i)^2}{n}}$$

식(17)

$$Cv(RMSE) = \frac{RMSE}{A} \times 100(\%)$$

식(18)

여기서,

N: 표본의 개수

y_i : 실제값(정답)

t_i : 신경망의 출력(예측값)

I: 데이터 수

A: 정답 CRAH 공급공기 온도의 평균

(2) 초기 예측모델 성능평가

초기 예측모델은 IT 발열량, CRAH 회수공기 온도, 냉수 유량을 입력데이터로 하며, CRAH 공급공기 온도를 출력 데이터로 하는 은닉층 1개, 은닉 뉴런 10개의 구조를 가진 인공신경망 모델로 구축되었다. 본 논문에서 예측모델 개발에 인공신경망을 선택한 타당성 입증을 위하여 타 기계학습 세 가지를 사용하여 별도의 예측모델을 개발하여 인공신경망 초기 모델 성능 및 최적화 성능을 비교·분석하였다. 예측모델의 성능은 실제 학습된 모델을 평가하는데 사용되는 Test 데이터를 예측모델에 입력하여 예측된 CRAH 공급공기 온도와 정답 CRAH 공급공기 온도의 비교를 통해 R^2 와 $Cv(RMSE)$ 그리고 Train 연산시간을 기준으로 평가한다.

성능평가 결과 Table 22와 같이 R^2 의 경우 정규화를 Min-Max로 진행한 인공신경망 예측모델이 0.89로 가장 높았고 그다음으로 GPR (0.84), RF (0.83), SVM (0.55) 순으로 나타났다. SVM의 경우 두 가지 정규화 모델에서 모두 ASHRAE 의 R^2 기준인 0.8 초과에 대해 만족하지 못하는 것으로 나타났다. Cv(RMSE)는 정규화를 Min-Max로 진행된 RF 모델이 17.85%로 예측정확도가 가장 높았고 ANN (18.8%), SVM (39.1%)로 나타났다. GPR의 경우 Min-Max (23.5%) 보다 Standardization (23.12%) 정규화에서 조금 더 높게 나타났다. SVM 예측모델은 ASHRAE 기준 Cv(RMSE)인 30% 이하에 만족하지 못해 예측정확도가 낮은 것으로 분석되었다.

실시간으로 제어되어야 하는 환경에 대한 예측모델의 학습 연산시간은 예측정확도와 함께 고려돼야 할 중요한 사항이다. 인공신경망의 경우, 실제 값과 예측값 사이의 오차를 나타내는 SSE (Sum of Squared Errors)와 SSW (Sum of Weights)가 일정 수준에 도달했을 때, 연산을 종료한다. 각 모델의 Train 연산시간의 경우 두 가지 정규화 모델 모두에 대해 RF가 가장 짧았고 SVM < ANN < GPR로 나타났다. 네 가지 모델 모두 1분 이내로 학습이 종료되므로 실시간 예측에 무리가 없다고 판단되어 최적화에 활용할 수 있을 것으로 사료 된다. 초기 예측모델의 성능은 구조 및 매개변수 최적화를 통해 개선된다.

Table 22. 초기 예측모델 성능

a) 각 예측모델의 Train, Validation, Test 데이터 세트 R^2 & Cv(RMSE) 성능

Learning Algorithm	R2						Cv(RMSE) [%]					
	Train		Validation		Test		Train		Validation		Test	
	MM ¹⁾	Std ²⁾	MM	Std	MM	Std	MM	Std	MM	Std	MM	Std
ANN	0.93	0.92	0.90	0.88	0.89	0.88	14.78	14.92	19.35	21.12	18.80	20.87
RF	0.95	0.95	0.85	0.85	0.83	0.83	13.03	18.25	18.75	23.11	17.85	23.12
GPR	0.89	0.90	0.84	0.84	0.84	0.85	18.42	18.25	23.26	23.11	23.50	23.12
SVM	0.56	0.77	0.55	0.58	0.55	0.08	36.01	26.98	37.82	42.01	39.10	52.03

1) MM : Min-Max

2) Std : Standardization

b) 각 예측모델의 Train 데이터 세트의 연산시간

Learning Algorithm	Normalization	Train Time [sec]
RF	Min-Max	1.43
	Standardization	0.84
SVM	Min-Max	2.63
	Standardization	6.64
ANN	Min-Max	18.19
	Standardization	11.33
GPR	Min-Max	32.51
	Standardization	30.02

4.2.2. 예측모델 최적화

초기 예측모델은 기본으로 제공되는 값을 토대로 개발되었다. 학습 알고리즘은 데이터의 특성 및 구조와 알고리즘의 메커니즘에 따라 내장된 매개변수로도 불리는 하이퍼파라미터의 설정에 따라 성능이 달라진다. 예측성능의 고도화를 위해 구조와 하이퍼파라미터의 최적 선정은 필수적이며 이에 따라 초기 예측모델의 성능을 개선 시킬 수 있다. 베이지안 최적화(Bayesian Optimization)는 미지의 목적함수를 최대 혹은 최소로 만들어주는 해를 찾는 기법으로 반복 탐색을 통해 최적의 하이퍼파라미터를 산출한다.¹¹²⁾

(1) 인공신경망 예측모델 최적화

인공신경망 예측모델은 구조에 변화를 주어 베이지안 최적화를 수행하였다. 인공신경망은 공통적으로 입력층, 은닉층, 출력층의 구조를 가지며 은닉층의 수(Hidden Layer, HL), 은닉층의 뉴런 수(Hidden Neuron, HN)에 따라 학습 정도가 변경된다. 은닉층의 개수가 많아질수록 인공신경망이 ‘깊어졌다(Deep)’고 부른다. 입·출력이 단순한 관계의 경우 은닉층과 뉴런의 수가 적더라도 높은 학습 성능 발현이 가능하지만, 입·출력의 관계가 단순함에도 은닉층과 뉴런수가 많으면 예측모델이 복잡해져 오히려 학습 성능이 저조해질 수 있다.¹¹³⁾ 따라서 예측모델의 적절한 수의 은닉층과 뉴런수를 선정하는 것이 중요하다. 구조의 최적화에는 정해진 기준은 없으며 개발자의 경험적 방법에 의해 결정된다.

112) 윤상웅, 곽하늬, 한철호, 심문보, 장병탁, 베이지안 최적화 기반 능동 학습 통한 효율적 유기 분자 탐색, 한국정보과학회 학술발표논문집, 2015, pp.772-774.

113) 최영재, op. cit., pp. 67.

본 논문에서는 두 가지의 구조 변화를 주어 최적화를 시행하였다. ① 첫 번째는 은닉층을 1~5개의 범위로 1개씩 증가시켜 변화를 주면서 뉴런수는 고정한 구조로부터 가장 성능 우수한 은닉층을 도출하고, ② 두 번째로 앞서 도출된 최적 은닉층 개수를 활용하여 뉴런수를 4~20개로 변화를 주어 최종 인공신경망 예측모델의 구조를 선정하였다. 이때 예측정확도 성능은 예측값과 정답 간의 비교를 통해 최소의 $Cv(RMSE)$ 로 평가하였다.

① [Step 1] Hidden Layer change & Hidden Neuron fix

은닉층을 1개부터 5개까지 증가시키고 각 은닉층에 대해 뉴런수는 4개~20개로 늘려가며 고정하여 Train, Validation, Test data 각각에 대해 R^2 와 $Cv(RMSE)$ 성능을 분석하였다. R^2 의 경우 [부록] 1과 같이 대부분의 구조조합에서 ASHRAE 기준값인 0.8을 초과하는 것으로 도출되었다. 은닉층 4개와 5개의 구조에서 0.8 이하로 떨어지는 현상이 나타났다. 이는 입·출력 관계 대비 은닉층 4개 이상의 층에서는 오히려 구조가 복잡해져 입·출력의 상관관계가 저조해진 것으로 사료된다.

$Cv(RMSE)$ 의 경우 [부록] 2, Fig. 33과 같이 모든 조합의 구조에서 30%를 초과하는 나타나지 않았다. 은닉층 2개가 가장 우수한 $Cv(RMSE)$ 성능을 보였고 다음으로 3개 < 1개 < 5개 < 4개 순으로 낮게 나타났다. 이 결과는 1개 층일 때 제대로 학습되지 못하다가 2개일 때 학습률이 높아지며 3개부터는 다시 낮아지는 흐름으로, 예측 데이터와 정답 데이터 간의 정밀도가 은닉층 2개일 때 가장 높은 것으로 판단된다. 은닉층 2개에서 가장 높은 성능의 $Cv(RMSE)$ 는 뉴런수가 14개일 때 Train (0.989%), Validation (3.649%), Test (0.987%)인 것으로 나타났다.

② [Step 2] Hidden Layer fix & Hidden Neuron change

①에서 도출된 최적 Cv(RMSE) 성능을 보여준 은닉층 2개에 대하여 각 층별 상이한 뉴런수로 변경하여 예측성능을 분석하였다. 뉴런수는 ①과 동일하게 4~20개로 1개씩 늘려가며 2개 층에 적용하여 Train, Validation, Test data 각각에 대해 R^2 와 Cv(RMSE) 성능을 분석하였다. R^2 의 경우 [부록] 3 ~ [부록] 6과 같이 대부분 0.8을 초과하였으나 부분적으로 0.8에 만족하지 못하는 것으로 나타나는데 그 중 은닉층 1, 2번째 층의 뉴런수가 각각 15, 17개 일 때 Test data의 R^2 가 0.254로 입·출력 상관관계가 가장 낮은 구조로 확인되었다. Cv(RMSE)의 경우 [부록] 7 ~ [부록] 10, Fig. 34와 같이 은닉층 두 개 층에 대해 11-5 조합일 때 Train, Validation, Test에서 각각 2.295%, 33.182%, 0.833%로 Test 값이 여러 가지 구조조합 중 가장 높은 성능으로 산출되었다. 그러나 여러 Train 된 모델 중 어떤 모델이 적합한지를 선택하는 역할인 Validation의 Cv(RMSE)가 ASHRAE 기준인 30%를 초과하는 것으로 나타났다. 또한 R^2 가 Test에 대해서는 0.817로 기준에 만족하나 Train과 Validation은 0.687로 만족하지 못하는 것으로 나타나 예측모델에 활용하기 어려운 구조인 것으로 판단된다.

결론적으로, 예측모델이 은닉층이 2개이고 뉴런수는 2개 층에서 동일한 14개의 구조일 때 Train, Validation, Test에 대한 R^2 가 1.000, 0.954, 0.942, Cv(RMSE)는 0.989%, 3.649%, 0.987%로 가장 높은 예측성능을 나타내는 것으로 확인되었다. 따라서 해당 구조를 인공지능망 예측모델의 최적화 모델로 선정하여 제어알고리즘에 적용하였다. (Fig. 32)




Fig. 32 구조 최적화를 통한 예측모델 최종 구조




Fig. 33 인공신경망 예측모델 구조 최적화 Cv(RMSE) 결과 - ① Hidden Layer change & Hidden Neuron fix




Fig. 34 인공신경망 예측모델 구조 최적화 Cv(RMSE) 결과 - ② Hidden Layer fix & Hidden Neuron change

(2) RF, GPR, SVM 예측모델 최적화

ANN을 제외한 RF, GPR, SVM 기계학습 모델의 최적화는 하이퍼파라미터에 변화를 주어 최적화하였다. 하이퍼파라미터는 MATLAB에서 Default option으로 제공하는 값들로 선정하여 베이지안 최적화를 통해 Table 23과 같이 최적의 하이퍼파라미터를 산출하였다.

GPR 예측모델은 Sigma, Basis Function, Kernel Function으로 최적화한다. Sigma는 공분산 함수로 학습 노이즈의 표준 편차를 최적화 하며 최적값은 28.4274로 산출되었다. Basis Function은 기저함수로 GPR의 사전 평균 함수의 형식을 지정한다. 각 예측 변수에서 순진히 2차인 상수항을 사용하여 모델을 학습하는 Pure Quadratic으로 적용한다. Kernel Function은 예측 변수 간의 거리 함수로써 상관관계를 결정하는 역할로 각 예측 변수에 대해 별도의 거리 척도를 가지는 ARD Squared Exponential로 설정하여 최적화 한다.

RF 예측모델 최적화는 세 가지 하이퍼파라미터 Method, Learning Rate, NumLearningCycling을 활용한다. Method는 앙상블회귀의 구조를 최적화하는 하이퍼파라미터로 주요 알고리즘은 Bagging과 Boosting으로 나뉜다. 본 논문에서는 Boosting 계열의 알고리즘인 AdaBoost를 사용하였다. AdaBoost는 분류 또는 회귀에서 사용할 수 있는 RF의 학습 알고리즘이며 학습하는 동안 가중치 벡터가 조정되어 이전에 잘 못 예측된 데이터에 초점을 맞추어 정확도를 높인다. AdapBoost는 LogitBoost, Gentle AdaBoost, RobusBoost, LSBoost, LPBoost, RUSBoost, TotalBoost와 같은 알고리즘이 포함된다. 본 논문에서는 회귀 앙상블에 사용되는 LSBoost (Least Square Boosting)을 사용하였다. Learning Rate는 학습 1회마다 학습하는 양을 의미하며 본 논문에서는 0.9629로 설정하였다. NumLearningCycling은 앙상블의 학습 사이클 수로 336번으로 산출되었다.

SVM 예측모델은 Epsilon, Box Constraint, Kernel Scale로 최적화한다. Epsilon은 마진의 정도를 결정짓는 역할로 7.7074, 데이터 분포에 따라 경계의 모양을 결정하는 Kernel은 13.6945로 산출되었다. Box Constraint는 Epsilon 마진 외부에 있는 관측치에 부과되는 패널티를 제어하고 과적합을 방지하는 데 도움을 주는 역할이며 최적값은 399.0687로 산출되었다. 산출된 최적화 값을 적용한 최적 예측모델 성능평가 결과, Table 24과 같이 나타났다. R^2 는 RF, GPR, SVM이 각각 0.82, 0.77, 0.51로 RF가 가장 높은 수치로 밀접한 입·출력의 상관관계로 확인되었고 Cv(RMSE)는 GPR, SVM, RF 순으로 각각 4.08%, 5.31%, 15.53%로 GPR이 가장 예측정확도가 높았고 3가지 모델 모두 기준치인 30% 이하를 만족하였다.

ANN, GPR, SVM, RF 총 4가지의 예측모델 최적화 결과 예측성능은 Test data 기준 ANN 예측모델이 R^2 0.94, Cv(RMSE) 0.98%로 입·출력 상관관계 및 예측정확도가 가장 우수한 것으로 확인되었다. 따라서, 인공지능망 예측모델을 데이터센터의 실내환경 및 에너지 성능 제어알고리즘에 적용하여 제어성능을 평가한다.

Table 23. GPR, SVM, RF 예측모델 하이퍼파라미터 최적화

Learning Algorithm	Hyperparameters	Values	Preprocessing
GPR	Sigma	28.4274	Standardization
	Basis Function	Pure Quadratic	
	Kernel Function	ARD Squared Exponential	
RF	Method	AdaBoost-LSBoost	Min-Max
	Learning Rate	0.9629	
	NumLearning	336	
	Cycling		
SVM	Epsilon	7.7074	Min-Max
	Box Constraint	399.0687	
	Kernel Scale	13.6945	

Table 24. 제어알고리즘 적용을 위한 최종 예측모델 선정

Learning Algorithm	R ²			Cv(RMSE) [%]		
	Train	Val ¹⁾	Test	Train	Val	Test
ANN	1.00	0.95	0.94	0.98	3.64	0.98
GPR	0.99	0.79	0.77	6.41	9.83	4.08
SVM	0.53	0.51	0.51	13.33	8.19	5.31
RF	0.97	0.86	0.82	10.47	17.33	15.53

1) Val : Validation

4.3. 제어알고리즘의 제어 정확성 · 안정성 · 적응성 평가

4.2장에서 최적화가 완료된 인공신경망 예측모델을 적용한 제어알고리즘 성능평가를 수행하였다. 지능형 제어알고리즘은 예측모델이 새로운 제어 시나리오를 받아들이거나 새로운 시스템 환경에 적응해나가는 오차 보정이 가능한 재학습 과정을 포함하여야 한다. 재학습 과정에서는 발생한 오차에 기반을 두어 정답 값에 만족하기 위한 필요 가중치를 업데이트하게 된다. 재학습 기능을 포함하지 않는 비적응 제어알고리즘의 경우 고정된 환경 및 단일 제어 시나리오에만 적용 가능한 제어로 결과적으로 수시로 변화하는 데이터센터의 IT 부하에 대응하기 어렵다. 본 논문에서의 제어알고리즘은 재학습 과정을 포함한 적응형 제어알고리즘으로 개발되었으며 제어 절차는 다음과 같다.

제어알고리즘은 피드백 제어에 기반하며 미래 Time step의 CRAH 공급공기 온도(CRAH_Tsa)를 예측한다. n번째 시뮬레이션이 진행된 후 CRAH 회수공기 온도(CRAH_Tra (n)), IT 부하(IT Load (n)), 냉수유량(CH_Mw (n))은 제어알고리즘에 내포된 예측모델에 입력변수로 적용된다. 예측모델로부터 출력된 n+1번째 Time step의 CRAH 공급공기 온도 CRAH_Tsa (n+1)은 설정온도와 비교된다.

해당 과정에서 냉수 유량은 0~40,000 kg/hr 사이 값을 40 kg/hr 단위로 변화하며 입력되고 이에 따라 예측모델에서 출력된 CRAH_Tsa (n+1)은 1,001가지의 값을 출력하게 된다. 설정온도와 예측값의 차이는 Error로 정의되며 $|\text{Error}| < 0.1$ 을 만족하는 최소 냉수 유량으로 n+1번째 Time step에 대한 시뮬레이션이 진행된다. n+1번째 Time step에서 CH_Nw(n+1)에 의해 도출된 예측 CRAH 공급공기 온도 CRAH Tsa_{New}와 설정온도의 오차를 $\text{RMSE} \leq 1$ 을 만족하면 시뮬레이션은 종료된다. IT 부하는 실제 데이터센터 부하 발생 추이를 반영한 약 50%의 부분부하로 난수를 생성하여 적용하였다. 설정온도는 18℃로 고정하였다. 데이터센터의 실제 운영상황과 유사한 환경을 위해 CRAH 공급공기 온도가 IT 부하에 의한 열기를 얻어 토출되는 CRAH 회수공기 온도에 가우시안 오차로 $\pm 4^\circ\text{C}$ 를 부여하였다.

제어알고리즘은 RMSE 기준에 만족하기 위해 필요에 따라 재학습 과정을 거치게 된다. RMSE는 제어알고리즘이 제어한 CRAH 공급공기 온도와 설정온도간의 오차를 다룰 때 흔히 사용하는 척도로 정밀도를 표현하는데 적합한 기준으로써 본 논문에서 제어알고리즘의 성능평가 기준으로 선정하였다. 성능평가는 재학습 과정을 포함하지 않는 비적응 제어와 재학습 과정을 포함하는 적응형 제어알고리즘으로 나누어 예측·제어 성능평가를 수행하고 이를 통해 비적응과 적응형의 제어 정확도 차이를 확인한다.

재학습 기능을 내포한 적응형 제어알고리즘의 성능평가는 구조 최적화가 완료된 예측모델에 대하여 세 가지 재학습 기능이 추가된 알고리즘에 대해 주요 최적화 함수를 선정하여 각 하이퍼파라미터 최적화 작업을 추가로 진행하였다. 해당 과정을 통해 최종적으로 가장 RMSE 성능이 우수한 재학습 알고리즘을 최적 적응형 제어알고리즘으로 선정한다.

4.3.1. 비적응 제어알고리즘 성능평가

비적응 제어알고리즘은 CRAH 공급공기 온도를 설정 온도인 18℃로 제어하지 못하였다. Fig. 35과 같이 5분 단위로 4시간 동안 시시각각 변화하는 IT 부하에 전혀 대응하지 못하며, 설정 온도에 수렴하지 않고 CRAH 공급공기 온도가 20℃~24℃ 사이로 출력되어 Max Error가 5.94℃인 것을 확인하였다. 제어성능의 평가 기준으로 가장 중요한 RMSE의 경우 12.37℃로 산출되어 가우시안 오차로 부여해준 외란에 대해 거의 적응해나가지 못한다는 것을 확인할 수 있다. 따라서 외란에 대응할 수 있는 적응형 제어알고리즘이 필요하다고 판단되었다. Fig. 36는 IT 부하 변동에 따라 온도 예측값을 산출하는데 결정된 냉수 유량과 이때 발생하는 냉방부하이다. 냉방부하는 6,278.53 kWh로 산출되었으며 냉수 유량은 IT 부하와 비례하는 것으로 분석되었다. 이는 예측모델에 입력변수와 출력변수의 열역학적 관계가 잘 반영되었음을 의미한다.




Fig. 35 비적응 제어알고리즘 - 설정 온도 대비 CRAH 공급공기 제어 온도




Fig. 36 비적응 제어알고리즘 - 설정 온도에 따른 최소 냉수유량 및 냉방부하

4.3.2. 적응형 제어알고리즘 최적화 및 성능평가

비적응 제어알고리즘이 제어하지 못한 CRAH 공급공기 온도 제어 성능 개선을 위하여 3.5장에서 언급한 세 가지 적응 제어 학습인 Sliding Window, Vector Augmentation, Vector Adaptation을 적용하여 각 알고리즘의 최적화와 성능평가를 진행하였다.

(1) 제어알고리즘 최적화

비적응 제어알고리즘이 제어하지 못한 CRAH 공급공기 온도 제어를 위하여 3.5장에서 언급한 세 가지 적응 제어 학습인 Sliding Window, Vector Augmentation, Vector Adaptation을 적용하여 적응형 제어 각각 알고리즘의 하이퍼파라미터 최적화를 실시하였다.

본 논문에서 활용한 LM (Levenberg-Marquardt) 알고리즘은 최적화 기법으로 다양한 하이퍼파라미터의 가중치 및 편향을 업데이트한다. Table 25는 LM의 최적화 함수의 항목 및 기본 학습 매개변수와 최적화

학습 매개변수의 범위를 나타낸다. LM의 각 하이퍼파라미터 최적화는 정해진 기준이 없어 사용자의 선택사항으로 결정된다. 본 논문에서는 총 12개의 함수 중 최적화에 주요한 항목으로 판단되는 max_fail, mu, mu_dec, mu_inc로 네 가지를 선택하여 알고리즘 최적화에 활용하였다. max_fail은 최대 유효성 검사 실패 횟수로 훈련 중지 시점을 의미하며 기본 6회로 설정되나 100~500회로 범위를 증가시켰다. mu는 학습 시 발생하는 오차 기울기 보정의 역할로 기본 0.001이며 최적화는 0.001~0.01로 설정하였다. mu_dec와 mu_inc는 mu의 감소·증가 인자로 각각 기본 설정값은 0.1, 10이며 최적화 시 0.01~0.9와 1.01~20으로 설정하였다.

세 가지 적응형 제어알고리즘에 각각에 대해 LM이 가지는 네 가지 하이퍼파라미터의 최적화 결과는 Table 26과 같다. 최적화 결과 중 각 알고리즘에 대한 상위 10가지의 결과를 보여준다. 세 가지 알고리즘 중 Sliding Window 재학습 방법을 적용한 알고리즘이 최소의 RMSE가 0.038로 가장 우수한 제어성능을 보였다. 이때의 선정된 하이퍼파라미터 값은 max_fail 304, mu 0.005, mu_dec 0.466, mu_inc 4.829로 선정되었다. Vector Augment와 Vector Adaptation에는 각각 최소의 RMSE가 0.090, 0.537로 나타나 Sliding Window보다 제어성능이 떨어지는 것으로 나타났다.

Table 25. LM 알고리즘의 최적화 기술

함수	개념	기본 매개변수	최적화 매개변수
net.trainParam. epochs	최대 훈련 학습 횟수	1,000	-
net.trainParam. goal	성능 목표	0	-
net.trainParam .max_fail	최대 유효성 검사 실패 횟수	6	100~500
net.trainParam. min_grad	최소 성능 기울기	1.00E-7	-
net.trainParam .mu	오차의 크기에 따른 경사 하강법 및 가우스-뉴턴법 적용으로 오차 기울기 보정	0.001	0.0001~ 0.01
net.trainParam .mu_dec	mu 감소 인자	0.1	0.01~0.9
net.trainParam .mu_inc	mu 증가 인자	10	1.01~20
net.trainParam. mu_max	최대 mu	1.00E+10	-
net.trainParam. show	디스플레이 간의 epoch	25	-
net.trainParam. showCommand Line	명령 줄 출력 생성	FALSE	-
net.trainParam. showWindow	학습 GUI 표시	TRUE	-
net.trainParam. time	최대 훈련 시간(초)	inf	-

Table 26. 적응형 제어알고리즘 하이퍼파라미터 최적화 결과

알고리즘	순위	LM 하이퍼파라미터				RMSE (℃)
		max_fail	mu	mu_dec	mu_inc	
Sliding Window	1	304	0.005	0.466	4.829	0.038
	2	181	0.010	0.790	8.660	0.229
	3	334	0.006	0.891	15.345	0.236
	4	215	0.010	0.454	3.201	0.240
	5	428	0.009	0.882	9.191	0.252
	6	423	0.005	0.033	19.815	0.268
	7	499	0.006	0.571	1.949	0.272
	8	226	0.003	0.582	19.881	0.291
	9	113	0.002	0.671	18.069	0.315
	10	381	0.003	0.853	13.451	0.315
Vector Augment	1	116	0.001	0.076	5.294	0.090
	2	413	0.007	0.884	16.465	0.293
	3	201	0.009	0.887	6.724	0.361
	4	100	0.000	0.016	16.509	0.368
	5	464	0.005	0.145	19.865	0.916
	6	466	0.007	0.017	6.823	0.969
	7	454	0.001	0.853	4.794	1.107
	8	113	0.000	0.325	14.693	1.137
	9	422	0.005	0.858	18.732	1.182
	10	361	0.008	0.772	4.398	1.238
Vector Adaptation	1	252	0.010	0.803	13.653	0.537
	2	489	0.000	0.622	12.976	0.790
	3	494	0.000	0.027	8.572	0.927
	4	303	0.001	0.031	19.811	0.930
	5	174	0.003	0.603	13.163	0.931
	6	497	0.001	0.204	7.319	0.973
	7	109	0.001	0.631	8.073	1.005
	8	500	0.002	0.250	3.067	1.021
	9	411	0.001	0.898	17.312	1.037
	10	194	0.002	0.655	9.480	1.259

(2) 성능평가

(1)에서 산출된 결과에 따라 각 적응형 제어알고리즘의 하이퍼파라미터 최적화에 대한 설정온도 대비 CRAH 공급공기 온도 제어 결과는 Table 27, Fig. 37 ~ Fig. 42와 같다. 평가 기준은 RMSE와 Max Error로 선정하였다.

설정온도 18℃로 5분 단위의 총 4시간 동안 예측·제어를 수행한 결과 RMSE와 Max Error가 각각 Sliding Window (0.038℃, 0.397℃), Vector Augmentation (0.0900℃, 5.633℃), Vector Adaptation (0.537℃, 5.653℃) 순으로 Sliding Window가 가장 적은 오차로 정확하게 제어하는 것으로 계산되었다. 냉동기와 냉각탑에서의 제거 열량으로 대체하는 냉방부하 또한 Sliding Window가 6,066.73 kWh로 Vector Augmentation 6,316.21 kWh, Vector Adaptation 6,330.17 kWh 대비 낮게 나타나 에너지 절약 측면에서도 가장 우수한 제어알고리즘이라고 판단할 수 있다. 비적응 제어와 비교 시 Sliding Window 제어가 RMSE, Max Error, 냉방부하 모든 측면에서 상당히 개선된 것을 확인할 수 있었다.

또한, 제어의 안정도 측면에서도 Sliding Window 모델이 전체 제어 기간 동안 설정 온도에 안정적으로 수렴되는 것을 확인할 수 있었다. 타 모델의 경우 제어의 시작점에서 약 60분가량의 학습 과정 동안 설정 온도에 수렴하지 못하고 제어 값이 과도하게 상승 또는 하락하는 오버슈트와 언더슈트가 발생하게 되는데, 이는 설정 온도에 적응과정에서의 과도상태에 의한 것이며 이후에는 정상상태로 변화하는 현상이 확인된다.

과도상태에 있어 오버슈트 및 언더슈트는 제어 과정에서 흔하게 발생하는 현상으로 초기 CRAH 공급공기 온도의 증·절감은 제어 환경에 대한 학습이 이루어지지 않은 상태를 의미한다. 데이터센터에서의 IT부하

변동은 필수불가결의 상황이며 실시간으로 이에 대응하지 못할 시 서버가 과열됨으로 인해 셧다운(Shut down) 현상이 발생하여 막대한 피해가 발생할 수 있다.

따라서, 4.3장까지의 제어성능 결과를 토대로 4.4장에서는 최종적으로 Sliding Window가 적용된 적응형 제어알고리즘을 활용하여 알고리즘의 적응성 검증을 수행하고자 하였다. 이를 위해 다양한 설정 온도 및 IT 부하 시나리오를 설정하고, 예측에 활용된 컨테이너먼트 규모를 변경하여 새로운 환경에서의 시뮬레이션을 시행하였다.

Table 27. 비적응·적응형 제어알고리즘 성능평가 결과

Item \ Algorithm	적응 제어			비적응 제어
	Sliding Window	Vector Augmentation	Vector Adaptation	
Cooling Load (kWh)	6,066.738	6,316.209	6,330.175	6,278.538
Max_error [℃]	0.397	5.633	5.653	5.936
RMSE [℃]	0.038	0.090	0.537	12.374




Fig. 37 Sliding Window - 설정 온도 대비 CRAH 공급공기 제어 온도




Fig. 38 Sliding Window - 설정 온도에 따른 최소 냉수유량 및 냉방부하




Fig. 39 Vector Augmentation - 설정 온도 대비 CRAH 공급공기 제어 온도




Fig. 40 Vector Augmentation - 설정 온도에 따른 최소 냉수유량 및 냉방부하




Fig. 41 Vector Adaptation - 설정 온도 대비 CRAH 공급공기 제어 온도




Fig. 42 Vector Adaptation - 설정 온도에 따른 최소 냉수유량 및 냉방부하

4.3.3. 시뮬레이션을 통한 성능평가 결과 타당성 검증

실험이 곤란하거나 불가능 또는 위험한 경우 여러 가지 선택조건을 사전에 검증하기 위해서는 실제 현상의 특징요소를 간략하게 하여 검증할 필요가 있다. 시뮬레이션 수행에는 실제 현상을 논리적으로 단순화한 모델, 모형, 컴퓨터프로그램 등이 사용된다. 일반적으로 시뮬레이션은 실제 현상의 모든 요소를 시행요소로 하지 않고 대상요소를 좁혀서 요소가 현상에 주는 영향을 검증하는 것이 주목적이다.

시뮬레이션기술이 폭넓게 보급 및 활용됨에 따라 그 신뢰성을 어떻게 확보하느냐에 관심이 높아지고 있다. 신뢰성 확보를 위한 시뮬레이션 기반 건물 실내환경 및 에너지 성능평가 방법은 다음과 같은 특성들을 고려해야 한다.¹¹⁴⁾

- 정확성: 평가된 성능은 실제와 근사해야 한다.
- 투명성: 성능평가를 위한 계산과정에서 사용된 가정들, 입력변수들이 결과에 미치는 영향 등은 성능평가 수행자뿐만 아니라 사용자에게 투명해야 한다.
- 명확성: 성능평가에서 사용되는 용어의 정의, 평가 방법에 대한 설명과 절차들은 모호하지 않아야 한다.
- 신뢰성: 입력변수의 불확실성 등을 이용하며, 성능평가 수행자가 임의로 결과를 조작하거나 원하는 결과를 의도적으로 도출할 가능성을 배제할 수 있어야 한다.
- 사용성: 성능평가 방법은 큰 노력과 시간, 비용을 들이지 않는 방법이어야 한다.

114) 박철수, 건물에너지 성능 시뮬레이션의 불확실성과 표준적 접근, 대학교수 해외 방문연구자 결과보고서, 성균관대학교, 2010.

- 객관성: 성능평가 절차와 방법에는 평가자의 주관적인 판단이나 편견이 배제되어, 평가결과가 충분히 객관적이어야 한다.

본 논문에서 개발한 데이터센터의 에너지 성능향상을 위한 지능형 공조제어알고리즘은 보안에 대한 민감성, 서버 운영 중단의 부담 등 용도 특성상 실제 적용 실험 전 고려해야 할 사항이 다수 존재한다. 따라서, 본 논문에서는 실제 실험 전 단계로 지능형 제어알고리즘의 성능평가를 통한 실현 가능성 확인이 주목적이다. 성능평가는 시뮬레이션을 활용하였으므로 해석 결과에 대한 합리성 및 타당성 검증이 필요하다. 따라서, 앞서 언급한 시뮬레이션 기반 성능평가의 특성들을 고려하여 본 논문에서 대상지로 선정한 데이터센터 방식 및 냉각시스템과 유사하고 에너지소비량 실측 데이터가 존재하는 실제 데이터센터를 활용하여 결과 값의 유사 정도를 분석하여 개발 모델의 에너지소비량에 대한 타당성 검증을 실시하였다. 유사 데이터센터는 컨테이너형 데이터센터의 Non-IT 부문 에너지 베이스라인 산출을 위해 실측 값을 분석한 연구로 본 논문에서 대상으로 설정한 컨테이너형 데이터센터 에너지소비량의 베이스라인으로 활용할 수 있다. 유사 데이터센터와 본 논문에서의 대상 데이터센터 상세는 Table 28과 같다.

Table 28. 시뮬레이션 결과 타당성 검증용 시스템 소비전력 비교

Item		대상 데이터센터	유사 데이터센터 115)
이미지			
데이터센터 유형		• 컨테이너먼트 방식 1대 • 냉복도·열복도 전면차폐	• 컨테이너먼트 방식 1대 • 열복도 차폐
IT 장비 현황		• Rack 14대 • 최대발열: 100 kW	• Rack 20대 • 최대발열: 51.05kW
기준온도(℃)		• 설계기준: 급기와 환수 공기온도 차 $\Delta 11$ • 냉복도: 18 • 열복도: 29	• 설계기준: 급기와 환수 공기온도 차 $\Delta 11$ • 냉복도: 15 • 열복도: 26
냉각 시스템	방식	• 중앙 냉수식	• 중앙 냉수식
	냉동기	• 용량: 240 kW • COP: 5.96	• 용량: 77.37 kW (22RT) • COP: 5.96
	CRAH	• 용량: 180 kW	• 용량: 69.76 kW
연간 냉방 소비 전력 (kWh)	총합	6,066.738 *Table 37. Sliding Window 의 Cooling Load 결과 기준	1,082,880
	Rack 당	21,986.81	21,212.14

일반적으로 컨테이너먼트 데이터센터의 실내온도는 Hot Aisle과 Cold Aisle이 약 10~15℃ 차이 나는 것으로 가정한다.¹¹⁶⁾ 본 논문에서는 11℃로 가정하며, 시뮬레이션 구동 시 3.3장에서 밝힌 바와 같이, Hot Aisle과 Cold Aisle의 온도차가 11℃로 생성된 데이터 세트를 활용하였다. 유사

115) 조진균, 홍원표, 기준 데이터센터의 구역단위 에너지효율평가 방법 및 PUE 기반 M&V 베이스라인 모델 개발, 대한설비공학회 논문집, Vol.32, No.2, pp.88-99, 2020.

116) 조진균, op. cit., pp. 121

데이터센터의 Hot Aisle과 Cold Aisle의 온도차는 10℃로 실측된 것을 확인할 수 있다. 따라서, 구축된 시뮬레이션 모델은 실제 컨테이너형 데이터센터의 실내환경을 잘 모사한 것으로 판단된다.

냉방 에너지소비량의 경우 대상 시스템과 타당성 검증용 유사 시스템은 동일한 컨테이너방식이나 차폐구역에 차이가 있다. 대상 데이터센터는 전면차폐이고 유사 데이터센터는 열복도(Hot Aisle Containment)만 차폐인 방식이다. IT 부하, 기준온도, 냉각시스템 용량에서 완벽하게 동일하지 않지만 유사한 시스템으로 구성된다. 이를 감안하여 냉방 에너지소비량은 Rack당 소비전력으로 조정하여 비교하였다. 그 결과, 연간 Rack당 냉방 소비전력은 3.52% 차이로 산출되어 실제 컨테이너방식 데이터센터 1대에서 소비되는 수치와 유사한 것을 확인하였다. 따라서, Table 29와 같이 본 논문에서 활용한 데이터센터의 전산모사 모델은 실제 데이터센터 환경을 잘 모사한 것으로 판단된다.

Table 29. 시뮬레이션 모델의 타당성 확보를 위한 특성 검증

구분	검증내용
정확성	실제 데이터센터 환경과 근사함
투명성	계산과정에 사용된 입력변수의 투명성 확보
명확성	용어의 정의, 평가 방법에 대한 절차의 명확성 확보
신뢰성	임의의 결과 조작 가능성을 배제함
사용성	적은 입력변수와 손쉬운 입력이 가능한 소프트웨어를 활용함
객관성	성능평가 절차와 방법에 평가자의 주관적인 판단을 배제하였으며 평가결과가 객관적임

4.4. 제어알고리즘 적응성 검증

본 논문에서 개발한 제어알고리즘은 새로운 환경의 다양한 데이터센터 및 유사 냉각시스템에서의 다양한 제어변수로 적용 가능한 적응성을 내포한 것에서 기존 제어기술과 차별성을 가지도록 설계되었다.

4.3장에서 확보된 최종 제어알고리즘의 적응성 검증을 위하여 앞서 적용한 컨테이너먼트 규모를 변경하여 알고리즘을 적용하였다. 3.2장에서 소개한 대상 컨테이너먼트형 데이터센터 구성에서 RACK이 4개 줄어든 10개로 컨테이너먼트 규모를 조정하였고 냉각시스템 구성은 3.2장의 Table 12와 동일하다. 제어알고리즘은 제어시나리오에 따라 두 가지 유형으로 나누어 제어의 정확성·안정성·에너지 절약성·적응성능 평가를 통해 최종 적응성 검증을 진행하였다.

Case 1은 IT부하를 변경하고 설정온도는 23℃로 고정한다. Case 1의 시뮬레이션 목적은 컨테이너먼트의 규모를 변경하였을 때 인공신경망 예측제어알고리즘의 새로운 환경에서의 적응성과 예측제어 성능을 확인하고자 하는 것이 주요 목적이며 이때 두 가지의 일반 제어기와 비교 평가하여 제어성능을 확인한다. 규모 변경에 대한 적응성 확인 후 Case 2에서 해당 규모에서 제어시나리오 변경을 주었을 때의 지능적 적응 제어알고리즘의 성능을 검증하고자 하였다. Case 2는 IT 부하 변경과 설정온도를 4시간 단위로 변경하여 제어를 실시하였다. 시뮬레이션 기간은 30일로 설정하여 5분 단위로 Time step 8,640번 운전된다. 적응성 평가에 활용된 대상 데이터센터 및 냉각시스템 상세는 Fig. 43, Table 30과 같다.

현실성 있는 적응성 평가를 위해서 본 장에서는 2.6.1장의 Fig. 12 ~ Fig. 13을 토대로 IT 부하 설정을 실제 데이터센터 IT 서버 발열 패턴을 반영하였다. 데이터센터 IT 서버 발열 패턴 조사결과에 따라

제어알고리즘 적용성 평가시 IT 서버 발열량을 Table 30과 같이 반영하였다. 0시부터 24시까지 4시간 단위로 IT 서버의 발열량을 20%, 10%, 30%, 40%, 50%, 40%의 부분 부하율로 설정하고, 이에 따라 냉각 설정온도 시나리오를 Case 1, Case 2와 같이 부여하였다. Case 2의 설정온도 시나리오는 IT 서버 발열 설정 패턴에 따라 적정온도로 부여하였다. Case 1과 Case 2에 대한 적용성 평가는 인공지능망 활용 예측·제어 모델의 성능을 입증하기 위하여 제어에서 일반적으로 적용되고 있는 ON-OFF, PID 제어기와 비교분석을 수행하였다.




Fig. 43 제어알고리즘 적용성 평가용 컨테인먼트형 데이터센터 구성

Table 30. 제어알고리즘 적응성 평가를 위한 시뮬레이션 개요

Item	Contents						
Containment Size	Rack 10 EA CRAH 6 EA						
Simulation Time	30 Days						
Control Cycle	5 min						
Time Step	8,640						
Control Scenario	Case 1	● IT부하 변경, 설정온도 고정					
		Set-point Temperature (℃)		0~24 hr	23		
	Case 2	● IT부하 변경, 설정온도 변경					
		Set-point Temperature(℃)		0~4hr		22	
				4~8hr		18	
				8~12hr		22	
				12~16hr		25	
				16~20hr		27	
				20~24hr		25	
IT Load	Load (kW)	Max 6.6/Rack (Rack 10 EA: 66 kW)					
	Partial [%]	● 부분 부하율 반영, 5분 단위 랜덤 설정 : 부분 부하율 ± $\sqrt{0.05}$ [Gaussian Noise]					
		0~4hr	4~8hr	8~12hr	12~16hr	16~20hr	20~24hr
		20	20	30	40	50	40

단순 ON-OFF 제어는 구성이 간단하고 비용이 저렴한 장점이 있으나 제어의 목표값 유지를 위해 제어 조작량을 0%와 100% 사이를 ON, OFF로 왕래하는 방식으로 조작량의 변화가 너무 크고, 실제 목표값에 대해 지나치게 반복하는 제어로 되고 만다. 반복제어 동작으로 인해 실제 제어변수가 일정하게 상하로 변동하는 것을 헌팅(Hunting) 이라고 하는데, 헌팅을 없앨 수 없는 것이 단점이다. 이러한 제어는 설비기계적으로나 에너지소비 측면에서도 효율적이지 못하다.

ON-OFF 제어의 단점을 개선하기 위해 도입한 방식이 정밀제어가 가능하고 응답속도가 빠른 PID (Proportional Integral Differential Controller, 비례-적분-미분 제어기) 제어이다. 비례제어(P)는 PID 제어기에서 반드시 사용하는 가장 기본적인 제어이며 구현하기가 쉽다. 조작량을 목표값과 현재 위치와의 오차에 비례한 크기가 되도록 하며 이 제어만으로는 적분기가 없을 경우 정상상태 오차가 발생할 수 있다. 적분제어(I)는 정상상태 오차를 제거하는데 사용, 계수조정이 제대로 되지 않으면 시스템이 불안해지고 반응 속도가 느려진다. 미분제어(D)는 출력값의 급격한 변화에 제동을 걸어 오버슈트를 줄이고 안정성을 향상시킨다.

PID 제어는 경우에 따라 PI, PD 제어기로도 사용한다. PI제어는 정상상태 오차를 개선 시키지만 상승시간이 느려지는 등 과도응답에 불리하며 PD제어는 시스템의 작동비를 증가시켜 과도응답특성을 개선 시키지만 정상상태 응답을 개선하는 데는 효과가 없다. 따라서 정상상태 응답과 과도상태 응답을 모두 개선하기 위한 목적으로 제안된 제어기가 PID 제어이다. PID 제어는 P, I, D 제어 방식을 동시에 적용하는 제어방법으로 비례제어에서 발생하는 오차를 적분제어가 자동으로 수정하여 목표값에서 안정된 제어를 하도록 하고, 급격한 외란에 대해서는 미분제어를 통해 제어변수 변화의 기울기에 비례하는 조작량으로 수정제어를 시행한다.

PID제어의 최적 제어 계수는 시스템 상태 및 환경에 따라 달라진다. 이는 사용 시스템에 적합한 개별 제어 특성을 고려하여 잦은 계수조정이 필요한 것을 의미한다. 즉, 자동으로 시스템이 특성이 반영되지 않기 때문에 최적 제어 솔루션이 될 수 없으며 비선형 시스템에서는 성능이 일정하지 않고 노이즈 및 외란에 민감하여 예상하지 못한 돌발상황에 취약하다는 것이 단점이다.

ON-OFF, PID 제어기는 MATLAB 기반의 그래픽 프로그래밍 환경에서 시스템을 모델링하는 Simulink (Version. R2020a) 를 활용하여 구현하였다. Simulink는 MATLAB 환경과 긴밀한 통합이 가능하여 연계하여 구동하거나 코드 스크립트를 작성할 수 있으며 타사 하드웨어 및 소프트웨어 제품과도 연동이 가능하여 시뮬레이션 및 모델 기반 설계를 위한 자동 제어 및 디지털 신호 처리에 널리 사용 중이다.¹¹⁷⁾

세 가지 제어모델의 적응성 평가결과는 Table 31 ~ Table 32와 같다. Case 1과 Case 2 모두에서 ON-OFF, PID, ANN 세 가지 제어모델 중 ANN이 제어의 정확성, 안정성, 에너지 절약성, 적응성을 종합하였을 때 가장 우수한 것으로 나타났다. 이는 컨테인먼트 규모가 변경된 상황에 대해서도 ANN 예측기반 제어알고리즘이 적응성을 갖는다는 것을 의미한다.

(1) 정확성

제어의 정확성 평가 기준은 RMSE로 선정한다. Case 1에서는 RMSE가 ANN 0.23°C < PID 1.88°C < ON-OFF 6.89°C 로 나타나 ANN이 가장 정확도가 높았다. Case 2 에서도 ANN이 0.24°C 로 가장 우수한 정확도를 보였고 PID 1.86°C , ON-OFF 6.92°C 순으로 나타났다. 제어의 정확도는 예측모델에서의 CRAH 공급공기 온도의 정확한 예측과 제어모델에서의 설정온도에 만족하는 CRAH 공급공기 온도로 정확하게 제어되는 상황으로 평가된다. 본 논문에서 개발한 ANN 예측·제어모델은 정확한 CRAH 공급공기 온도 제어성능을 확보함에 따라 컨테인먼트형 데이터센터의 열환경이 우수하게 제어되는 것을 확인하였다. 설정온도에 정확하게 제어할 수 있는 ANN 예측·제어모델은 결과적으로 컨테인먼트형 데이터센터의 냉방에너지 절감에 기여 할 수 있을 것으로 판단된다. 냉방에너지 절감 평가는 ‘(3) 에너지 절약성’ 에서 확인할 수 있다.

117) MathWorks, <https://www.mathworks.com/> (access: 2020.10.30.)

(2) 안정성

제어의 안정성 평가는 설정온도와 제어기로부터 산출된 제어온도의 오차로 분석할 수 있다. Max-error는 제어의 전과정에서 발생한 온도 오차 중 최대 온도 오차로 각 제어모델의 제어 안정성을 의미한다. Case 1의 경우 Max-error가 ANN 0.98℃>PID 2.22℃>ON-OFF 2.78℃로 ANN이 가장 안정적인 제어기로 나타났으며 Case2 역시 ANN이 1.02로 PID, ON-OFF 제어기보다 낮게 나타나 안정적인 제어양상을 보였다. Case 2는 Case 1과 달리 컨테인먼트 규모변경 뿐만 아니라 설정온도가 4시간 단위로 변경되는 시나리오가 추가로 설정됨에 따라 적응성이 제어의 핵심이 된다. Table 32, Fig. 44에 의하면 한 달의 제어 기간 중 Max-error에서만 ANN 모델이 가장 낮은 것이 아닌 하루 기준 설정온도가 변경되는 전 구간에서의 제어온도 오차도 ANN이 가장 낮은 것으로 나타나 열환경 측면에서 안정적인 제어임이 확인되었다.

(3) 에너지 절약성

에너지 절감형 제어인지를 가늠할 수 있는 냉방부하 산출결과 Table 31, Fig. 45와 같이 확인된다. ON-OFF 제어는 세 가지 제어기 중 가장 높은 2,520,267.91 kWh로 두 Case에서 동일하게 계산되었다. 제어기 설계시 ON-OFF 제어는 초기 설정 값에 의해 발생할 수 있는 모든 상황에 대하여 제어 가능해야 한다. 즉, 최대 IT 서버 발열량에서 설계기준 온도인 18~27℃ 전체 범위에서 제어할 수 있는 냉수 유량으로 고정값이 입력되어 테드밴드 $\pm 1^{\circ}\text{C}$ 을 기준으로 단순 ON, OFF 동작을 반복하게 된다. 따라서, 제어 시나리오의 변화에 따른 최적 냉수 유량 산출의 기능이 없어 에너지 절약적 제어기와는 거리가 멀다.

PID 제어는 초기 제어기 설계시 제어 환경에 적합한 P, I, D 각각의 최적

매개변수로 입력되어 운전한다. 본 논문에서는 실제 데이터센터 운영 환경과 유사한 모사를 위하여 제어 중 IT 서버 발열과 CRAH 공급공기 온도에 외란을 발생포함하는데, PID는 최적 매개변수 설정시 존재하지 않았던 외란이 입력되는 순간마다 적정 냉수유량을 찾지 못하여 과도응답이 발생에 따른 불필요한 냉방부하를 발생시킨다. PID 제어기는 외란 적거나 없는 일정한 제어 상황에서는 현재 결과보다 우수한 제어성능을 나타낼 수 있으나, 변화하는 환경에 스스로 적응하는 기능의 부재로 인해 에너지 절약적인 제어기로 판단하기는 어렵다. ANN 제어모델은 알고리즘 구동 시 설정온도에 적합한 CRAH 공급공기 온도 산정에 필요한 냉수 유량의 적정 범위에서 최소 냉수 유량을 선정하여 냉각 시스템을 가동하게 된다. 이에 따라 에너지 측면에서, 다양한 제어 상황에 적합한 제어를 수행하여 불필요한 과냉방을 방지하므로 ON-OFF, PID 제어기보다 에너지 절약적인 모델이라 판단할 수 있다.

(4) 적응성

본 논문의 ‘적응성’이 갖는 의미는 ‘확장성’ 또는 ‘범용성’으로도 해석할 수 있다. 본 논문에서 개발한 ANN 제어모델은 Case1과 Case2와 같이 대상 데이터센터의 규모가 변경되고, 각기 다른 제어 상황에서 일반적으로 사용중인 PID, ON-OFF 제어모델보다 월등하게 정확하고 안정적으로 제어되는 것을 확인하였다. 특히, ANN 제어모델은 재학습 기능을 갖는 Sliding Window 기법에 의해 새로운 환경에 대한 적응력이 뛰어난 것으로 판단된다. 즉, ANN 제어모델이 ON-OFF, PID 제어기보다 새로운 환경에 대한 적응성 및 확장성이 매우 뛰어난 제어모델이라고 판단할 수 있다. 각 제어모델의 상세 성능분석은 4.4.1 ~ 4.4.3장에 정리하였다.

Table 31. 제어모델의 적응성능 비교분석 - Time step: 8,640 (One month)

Case	Item		Controller		
			ANN	PID	ON-OFF
Case 1	RMSE (℃)		0.23	1.88	6.89
	Max-error (℃)		0.98	2.22	2.78
	Cooling load	Value (kWh)	527,826.37	737,392.92	2,520,267.91
		Variation (%)	-79.06	-70.74	Standard
Case 2	RMSE (℃)		0.24	1.86	6.92
	Max-error (℃)		1.02	2.22	2.59
	Cooling load	Value (kWh)	527,487.94	737,931.38	2,520,267.91
		Variation (%)	-79.07	-70.72	Standard
종합 성능	정확성		○	△	×
	안정성		○	△	×
	에너지 절약성		○	△	×
	적응성		○	△	×

○ : 우수 △ : 보통 × : 낮음

Table 32. 제어 시나리오 구간당 Max error (℃) - Time step: 288 (One day)

Controller	Section (The 1st day)						
	IT Load Case						
		20%	20%	30%	40%	50%	40%
ANN	Case1	0.50	0.56	0.62	0.77	0.56	0.96
	Case2	0.73	0.57	0.56	0.92	0.69	0.77
ON-OFF	Case1	1.20	2.03	1.00	1.51	1.26	1.86
	Case2	1.09	2.73	2.19	1.96	1.00	1.82
PID	Case1	1.13	1.07	0.77	0.99	0.76	1.05
	Case2	1.13	2.00	1.50	1.00	0.76	1.05




Fig. 44 제어 구간당 IT 서버 부분 부하율에 따른 최대 온도 오차 (Max error) - The 1st day




Fig. 45 제어기별 냉방부하 산출결과 - Case 1 기준, The 1st day

4.4.1. ON-OFF 제어

ON-OFF 제어기 구현모델은 Fig. 46와 같다. 데드밴드 오차는 설정 온도로부터 $\pm 1^{\circ}\text{C}$ 로 부여하였으며 시스템 가동 시 냉수유량은 설정온도 범위 $18\sim 27^{\circ}\text{C}$ 중 가장 최고수준인 18°C 를 기준으로 열전달 수식인 식(11)에 의해 도출된 $25,000\text{ kcal/hr}$ 로 설정하였다. 설정된 냉수유량은 IT 서버 발열량이 최대이고 설정 CRAH 공급공기 온도가 18°C 로 요구되는 가장 엄격한 상황에 대해서도 제어가 가능한 값으로 해석할 수 있다.






Fig. 46 Simulink 기반 ON-OFF 제어기

각 Case의 시뮬레이션 결과는 Case 1 Fig. 47-(a),(b),(c), Case 2 Fig. 48-(a),(b),(c)와 같다. Case 1과 Case 2에서 RMSE는 각각 6.89℃, 6.92℃로 세 가지 제어기 중 가장 높게 나타나 정확도가 낮은 것으로 확인되었다. Max-error는 2.78℃, 2.59℃로 테드밴드가 $\pm 1^\circ\text{C}$ 이나, 이보다 높은 수치의 오차는 불규칙적으로 발생하는 과도응답에 의한 것으로 확인된다. 냉방부하는 2,520,267.91 kWh로 Case 1과 Case 2에서 동일하게 산출되었다. $\pm 1^\circ\text{C}$ 에 의해 운전의 ON-OFF를 반복하는 제어이므로 제어 시나리오에 크게 영향을 받지 않는다. 즉, Fig. 47-(b), Fig. 48-(b)의 확대


이미지에서 확인되듯이 설정온도에 만족하기 위해 ON-OFF를 반복하게 된다. 이와 같은 제어 패턴으로 동작하는 ON-OFF 제어는 목표값에 도달하기 위한 조작량이 많아 과도한 냉방부하를 발생시키며 이런 현상은 설비 기계적으로도 효율적이지 못한 것으로 사료 된다.



(a) Time step 8,640 - 한 달 제어결과




(b) Time step 288 - 하루 제어결과




(c) Time step 578 - 이틀간 제어결과


Fig. 47 ON-OFF 제어기 Case 1 결과



(a) Time step 8,640 - 한 달 제어결과




(b) Time step 288 - 하루 제어결과




(c) Time step 578 - 이틀간의 제어결과

Fig. 48 ON-OFF 제어기 Case 2 결과


1.86℃로 산출되었다. Max-error의 경우 Case 1, Case 2에서 동일하게 2.22℃로 계산되었다. ON-OFF 제어기보다 대부분의 제어 포인트에서 설정온도에 수렴하지만 Fig. 51-(b), Fig. 52-(b)와 같이 약 30분마다 잦은 과도응답이 발생한다. 과도응답의 순간에 IT 부하에 의한 발열의 냉각이 이루어지지 않을 경우 셧다운(Shut down)이 일어날 우려가 있으며 과도응답에 의해 불필요한 냉방부하가 발생할 수 있다. 냉방부하는 Case 1은 737,392.92 kWh, Case 2는 737,931.38 kWh로 산출되었다. PID 제어기에서 P, I, D의 매개변수가 최적값이 되기 위해서는 환경이 변할 때 마다 재조정 되어 입력되어야 한다. 그러나 본 논문에서는 Case 1의 매개변수와 Case 2의 매개변수가 동일하게 적용되어 Case 1보다 제어 설정온도 시나리오가 새롭게 적용된 Case 2에서 냉방부하가 538.46 kWh가 증가한 것으로 사료된다. 즉, PID 제어는 새로운 환경에 대한 자동 적응 기능이 없어 경험에 의한 별도의 매개변수 조정과정을 거쳐야 하는 번거로움 및 한계점이 있다.



(a) Time step 8,640 - 한 달 제어결과




(b) Time step 288 - 하루 제어결과




(c) Time step 576 - 이틀간의 제어결과


Fig. 51 PID 제어기 Case 1 결과



(a) Time step 8,640 - 한 달 제어결과



(b) Time step 288 - 하루 제어결과




(c) Time step 576 - 이틀간의 제어결과

Fig. 52 PID 제어기 Case 2 결과


4.4.3. 인공신경망 제어

인공신경망 제어기는 4.3장에서 최적화가 완료된 최종 제어모델을 활용하여 적응성 검증을 위한 시뮬레이션을 진행하였다. 결과는 Case 1 Fig. 53-(a),(b),(c) ~ Case 2 Fig 54-(a),(b),(c)와 같다. Case 1, Case 2에서 각각 RMSE는 0.23°C , 0.24°C 로 도출되어 세 가지 제어모델 중 확연히 낮아 정확도가 월등히 우수한 것으로 확인되었다. Max-error는 0.98°C , 1.02°C 로 확인되어 과도응답 구간이 거의 발생하지 않아 ON-OFF, PID 제어기보다 안정적인 제어기라고 볼 수 있다. 냉방부하의 경우 Case 1에서는 527,826.37 kWh, Case 2는 527,487.94 kWh로 산출되어 세 가지 제어모델 중 가장 낮았다. ANN 제어모델은 설정온도에 만족하기 위한 최소 냉수유량을 도출하여 제어에 적용하도록 설계되었기 때문에 가장 에너지 효율적인 제어기라 할 수 있다. 두 가지 제어기와 달리 ANN 제어모델은 Case 1보다 Case 2의 냉방부하가 338.43 kWh 절감되었다.


ANN 제어모델은 새로운 환경에 적응하여 재학습을 통한 제어 기능을 포함하였기에 Case 2의 변화하는 설정온도 시나리오에 적응하여 최소 냉수 유량으로 제어함에 따라 최적 냉방부하를 도출하는 것이 가능하다. 즉, ANN 제어모델은 ON-OFF와 PID의 한계점인 과한 조작량, 제어 환경에 따른 매개변수의 수동적 조절이 보완된 지능적인 에너지 효율적 제어기라 판단할 수 있다.



(a) Time step 8,640 - 한 달 제어결과




(b) Time step 288 - 하루 제어결과




(c) Time step 576 - 이틀간의 제어결과


Fig. 53 ANN 제어기 Case 1 결과



(a) Time step 8,640 - 한 달 제어결과



(b) Time step 288 - 하루 제어결과



(c) Time step 576 - 이틀간의 제어결과

Fig. 54 ANN 제어기 Case 2 결과

4.5. 소결

본 장에서는 3장에서 개발한 CRAH 공급공기 온도 예측 및 제어알고리즘의 제어 정확도와 새로운 환경에서의 적응성 평가와 더불어 시뮬레이션을 활용한 성능평가의 타당성 검증을 실시하였다. 수행 결과는 다음과 같다.

(1) 예측모델에 대한 성능평가는 두 가지로 진행하였다. 초기모델의 예측성능과 이를 개선하기 위한 최적화 예측모델의 예측성능을 평가하여 제어알고리즘에 활용될 최적 예측모델을 도출하였다.

초기 예측모델은 ANN, RF, GPR, SVM 중 Test 데이터에 대한 R^2 는 ANN이 0.89로 가장 높았고, Cv(RMSE)와 연산시간은 RF가 17.85(%), 0.84초로 가장 우수하게 나타났다. 초기 예측모델의 성능개선을 위하여 ANN은 베이지안 최적화를 적용하여 신경망 구조 최적화를 실시하였고 매개변수 최적화는 최종 선정된 최적 구조의 ANN 모델에 대해 4장에서 수행된다. RF, GPR, SVM 모델에 대해서는 매개변수를 최적화하였다. 그 결과, Test 데이터 기준 R^2 가 ANN (0.94) > RF (0.82) > GPR (0.77) > SVM (0.51)로 산출되었으며, Cv(RMSE)는 RF (15.53%) > SVM (5.31%) > GPR (4.08) > ANN (0.98%)로 산출되어 ANN의 예측성능이 가장 우수한 것으로 확인되었다. 이에 따라, ANN 최적 예측모델을 데이터센터 공조제어알고리즘에 활용하였다.

(2) 구조 최적화가 완료된 제어알고리즘의 성능평가는 재학습 기능 포함 여부에 따라 비적응 제어, 적응 제어로 나누어 예측·제어 성능을 비교·평가를 수행하고 이를 통해 비적응과 적응형의 제어 정확도 차이를

확인하였다. 적응형 제어알고리즘은 비적응 제어알고리즘에 재학습 기능이 추가된 것으로 세 가지 재학습 알고리즘에 대해 하이퍼파라미터 최적화를 통한 성능개선을 추가로 실시하여 가장 성능이 우수한 재학습 알고리즘을 최적 적응형 제어알고리즘으로 선정하였다.

비적응 제어는 RMSE, Max Error, 냉방부하 결괏값에서 모두 적응 제어보다 낮은 성능을 보였다. 적응 제어의 경우 세 가지 재학습 알고리즘 성능평가 결과 RMSE와 Max Error는 각각 Vector Adaptation (0.537, 5.65) > Vector Augmentation (0.090, 5.63) > Sliding Window (0.038, 0.39) 순으로 높게 나타나 가장 적은 값으로 산출된 Sliding Window의 제어성능이 매우 우수한 것으로 확인되었다. 냉방부하의 경우에서도 Vector Adaptation (6,330.17) > Vector Augmentation (6,316.21) > Sliding Window (6,066.73)으로 Sliding Window 제어에서의 냉방부하가 가장 적게 산출되어 에너지 절약형 제어알고리즘이라 판단할 수 있었다.

(3) 제어알고리즘의 성능평가를 본 논문에서는 시뮬레이션을 통해 수행하였다. 시뮬레이션은 개발 모델에 대한 실험이나 실증평가의 상황 이외의지 않을 때 사전 검증을 위한 방법으로 결과에 대한 합리성 및 객관적인 타당성 검증이 필수적이다. 이를 위해 본 논문에서 제어 시뮬레이션 대상 데이터센터와 유사한 실제 데이터센터와 실내환경 및 에너지소비량에 대한 유사 정도를 분석하여 개발 시뮬레이션 모델의 타당성 검증을 실시하였다. 그 결과 시뮬레이션을 통해 산출된 실내환경 및 에너지소비량이 실제 데이터센터의 실측 데이터와 3.52% 차이로 흡사하게 산출되어 실제 데이터센터 환경을 잘 모사한 것으로 판단되었다.

(4) 합리적인 시뮬레이션으로부터 제어의 정확도가 확보된 적응형 제어알고리즘은 본 논문에서 설정한 컨테인먼트형 데이터센터의 중앙 냉수식 시스템에 한정적으로 적용되는 것이 아닌 다양한 유형의 데이터센터와 유사 냉각 시스템 등 새로운 환경에서도 적용 가능한 점이 특징이다. 이에 따라, 개발 제어알고리즘의 적응성 검증을 위하여 앞서 활용한 데이터센터의 규모를 변경하고 IT 서버 발열량과 설정온도 시나리오를 두 가지 Case로 설정하여 기존에 제어 분야에서 보편적으로 사용 중인 ON-OFF, PID 제어기와 비교하여 적응성 비교·평가를 실시하였다.

적응성 평가결과, 새로운 환경에 대한 제어 정확성, 안정성, 에너지 절약성, 적응성의 모든 측면에서 ANN 제어모델이 현저히 우수한 것으로 나타났다. ANN 제어모델의 정확성인 RMSE와 안정성을 나타내는 Max-error의 우수성은 ON-OFF와 PID 대비 각각 RMSE 87.77%, 96.66%, Max-error 55.86%, 67.75% 향상되어 열환경 개선의 우수성을 입증할 수 있다. 에너지 절약성은 IT 부하와 설정온도 시나리오가 모두 변경되어 새로운 환경에 대한 강한 적응성이 필요한 Case 2에서 냉방부하 발생량이 ON-OFF, PID 제어기 대비 각각 79.07%, 28.52% 감소하여 현저하게 낮게 나타났다. 즉, ANN 제어모델이 ON-OFF, PID 제어기보다 에너지 측면에서 절약적 제어를 수행하며 새로운 환경에 대한 적응성 및 확장성이 매우 뛰어난 제어모델이라고 판단할 수 있다.

제 5 장 결론

5.1. 연구의 결론

본 연구에서는 데이터센터의 실내환경 개선 및 냉방에너지 절약을 위해 최적 예측기반 공조제어알고리즘을 개발하였다. ANN을 활용하여 예측모델 및 제어알고리즘을 개발하였고 적응형 제어를 위해 재학습 알고리즘을 적용하였다. 개발된 모델은 시뮬레이션을 통해 제어성능을 평가하였다. 또한, 제어알고리즘의 새로운 환경에서의 적응성 검증을 위하여 대상 데이터센터의 규모와 IT 서버 발열 부하, 설정온도 시나리오를 변경하여 적응성을 평가하였다.

성능평가 결과 ANN 제어모델은 제어의 정확도, 안정성, 에너지 절약성, 적응성(확장성) 측면에서 모두 우수한 성능을 보였다. 따라서, ANN 기반 예측·제어알고리즘은 데이터센터의 공조제어를 통해 실내 열환경을 개선하고 냉방에너지 절약성의 신뢰도가 확보된 제어알고리즘임이 확인되었다. 특히, 다양하고 새로운 환경에 적응 및 확장 가능한 제어 솔루션임이 확인되었다. 상세 연구수행 결과는 다음과 같다.

(1) 개발된 ANN 초기예측모델의 성능은 타 기계학습인 SVM, RF, GPR과 비교하여 분석되었다. 초기 예측모델의 예측정확도는 Cv(RMSE) 기준 RF 17.85% < ANN 18.80% < GPR 23.50% < SVM 39.10%로 초기 예측모델에 설정되는 매개변수들의 값에 따른 결과로 RF가 가장 높게 나타났으나 최적화 결과, 각 예측모델의 구조 및 최적화가 수행된 하이퍼파라미터들이 가진 특성에 의해 ANN 0.98% < GPR 4.08% < SVM 5.31% < RF 15.53%로 ANN이 가장 우수한 것으로 확인되었다.

(2) 예측성능이 가장 우수한 것으로 확인된 ANN 최적 예측모델을 내재한 제어알고리즘은 재학습 기능을 가진 알고리즘 세 가지를 반영하여 설계되었다. 제어는 5분단위로 수행되며 예측된 CRAH 공급공기 온도에 대해 설정온도와의 오차가 0.1 이하일 경우 최소 냉수유량을 산출한다. 산출된 냉수유량과 예측 CRAH 공급공기 온도로 5분간의 시뮬레이션을 진행하며 5분 후 설정온도와 CRAH 공급공기 온도 오차가 1 이하이면 지속하여 시뮬레이션을 진행하고 1 이상일 경우 재학습 알고리즘을 활용하여 재학습을 진행하도록 개발하였다.

제어 성능평가 결과, Sliding Window, Vector Adaptation, Vector Augmentation의 세 가지 재학습 알고리즘 중 Sliding Window의 제어성능이 RMSE 0.038 °C, Max-error 0.397 °C, 냉방부하 6,066.73 kWh로 제어 오차에 대해 뛰어난 재학습 기능을 가짐에 따라 제어의 정확성, 안정성, 에너지 절약성 측면에서 모두 가장 우수한 것으로 확인되었다.

(3) 개발된 제어알고리즘은 다양한 환경 및 새로운 제어 시나리오에 대한 적응성을 내재한 기술로 기존 제어기술과 차별성을 가지도록 설계되었다. 적응성 검증을 위해 컨테이너먼트 규모를 변화시키고 IT 부하, 설정온도 시나리오 변경 조합에 따라 설정온도 고정 & IT 부하 변화를 준 Case 1 과 설정온도 IT 부하 모두 변화를 준 Case 2로 설정하여 제어의 적응성을 평가하였다. ANN 제어모델의 적응성 평가를 위하여 일반적으로 제어에 사용 중인 ON-OFF, PID 제어기와 비교 분석하였다.

그 결과, Case 1, Case 2 모두에서 ANN 제어모델의 제어 정확성, 안정성, 에너지 절약성, 적응성의 모든 평가 기준에서 우수한 것으로

확인되었다. 즉, ANN 제어모델이 ON-OFF, PID 제어기보다 에너지 절약적 제어를 수행하며 새로운 환경에 대한 적응성 및 확장성이 뛰어난 것으로 검증되었다.

5.2. 연구의 활용성 및 향후 연구

본 논문에서 개발한 ANN 기반 데이터센터 최적 공조제어알고리즘은 데이터센터의 효율적 냉각 시스템 운영을 가능하게 하여 냉방에너지 절감 및 CO₂ 배출량 감소에 도움을 주어 그린 데이터센터 구현의 핵심 기능을 제공할 수 있을 것으로 기대된다. 또한, 개발 기술은 활용 데이터의 교체가 쉽고 방대하고 복잡한 변수 입력 없이 최소한의 주요 변수만으로도 충분한 예측·제어 정확도를 산출해내므로 냉각 시스템의 효율적 운영 및 에너지 성능향상 등 사전대비가 필요한 분야에서 손쉽게 적용할 수 있다. 특히, 확장성을 확보한 제어 솔루션으로써 여러 가지 유형의 데이터센터 외에도 다양한 건물 용도의 냉각 시스템 제어에 활용될 수 있을 것으로 판단된다.

개발 기술의 우수한 제어성능 및 적응성 검증 완료에도 불구하고 예측·제어알고리즘의 성능평가를 시뮬레이션으로 진행하여 실제 적용에는 한계가 있다. 실제 현장에 적용 시 여러 입·출력 변수나 외부요인들에 의하여 오차가 발생할 수 있으므로 추후 실제 데이터센터에 적용하여 실측 데이터들을 활용한 연구를 통해 보완과 검증과정이 필요하다.

실제 적용 가능성 검증이 완료된 예측·제어모델에 대해서는 실시간 사용성 증대를 위해 시각화하는 것이 중요하다. 소프트웨어의 시각화 및 활용 분야에서는 CPS (Cyber-physical System) 기술이 주목받고 있다. 향후 본 논문에서 개발 한 기술의 활용성 증대를 위해 응용 연구로써

실내 열환경 및 에너지 예측·제어, 효율적 시스템 운영 등을 목표로 단순 모니터링을 넘어 결과 데이터 분석 및 대안 제시를 통해 관리자의 의사결정에 도움을 줄 수 있는 에너지 절약적 데이터센터 공조제어 CPS 구축연구도 수행되어야 할 것으로 사료된다.

[부 록] ANN 예측모델 구조 최적화

1. ANN 예측모델 구조 최적화 R^2 결과 - ① [Step 1] Hidden Layer change & Hidden Neuron fix

HL HN	1			2			3			4			5		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	0.892	0.851	0.858	0.988	0.982	0.983	0.857	0.832	0.807	0.935	0.910	0.897	0.933	0.914	0.904
5	0.891	0.849	0.855	0.989	0.983	0.975	0.998	0.996	0.991	0.757	0.733	0.735	0.913	0.883	0.858
6	0.896	0.854	0.859	0.994	0.972	0.978	0.996	0.969	0.970	0.825	0.769	0.765	0.873	0.832	0.836
7	0.901	0.859	0.863	0.997	0.980	0.988	0.985	0.964	0.962	0.900	0.859	0.863	0.879	0.830	0.814
8	0.928	0.897	0.898	0.985	0.947	0.955	0.976	0.943	0.944	0.995	0.951	0.967	0.988	0.933	0.943
9	0.927	0.900	0.892	0.991	0.963	0.969	0.997	0.962	0.977	0.924	0.868	0.869	0.993	0.951	0.946
10	0.931	0.893	0.898	0.999	0.977	0.971	0.928	0.898	0.891	0.945	0.881	0.879	0.983	0.912	0.917
11	0.938	0.932	0.918	0.919	0.898	0.888	0.981	0.932	0.931	0.988	0.929	0.953	0.894	0.807	0.814
12	0.943	0.939	0.922	0.999	0.974	0.977	0.897	0.846	0.854	0.969	0.842	0.858	0.964	0.879	0.888
13	0.944	0.929	0.926	0.996	0.976	0.982	1.000	0.954	0.937	0.780	0.731	0.726	0.975	0.889	0.874
14	0.941	0.919	0.914	1.000	0.954	0.942	1.000	0.972	0.981	0.964	0.913	0.920	0.940	0.827	0.823
15	0.938	0.896	0.902	1.000	0.978	0.969	0.988	0.935	0.942	0.987	0.927	0.922	0.973	0.876	0.902
16	0.959	0.951	0.941	0.998	0.978	0.987	0.907	0.853	0.856	0.921	0.860	0.863	0.961	0.855	0.841
17	0.959	0.941	0.935	0.999	0.967	0.965	0.905	0.855	0.861	0.996	0.894	0.930	0.950	0.871	0.862
18	0.962	0.946	0.937	1.000	0.930	0.926	0.938	0.882	0.896	0.798	0.709	0.703	0.964	0.868	0.858
19	0.963	0.948	0.949	1.000	0.937	0.969	0.994	0.966	0.958	0.795	0.707	0.721	0.930	0.798	0.817
20	0.963	0.946	0.948	0.997	0.970	0.972	0.949	0.859	0.876	0.908	0.837	0.845	0.993	0.876	0.918

1) Val : Validation

2. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ① [Step 1] Hidden Layer change & Hidden Neuron fix

HN \ HL	1			2			3			4			5		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	17.514	22.187	22.889	5.765	5.289	9.776	19.681	23.007	25.351	13.619	15.666	17.097	13.707	15.824	17.144
5	17.591	22.211	22.373	5.478	7.219	7.064	2.651	1.372	6.406	26.276	28.473	28.364	15.706	19.385	19.952
6	17.190	22.323	22.138	4.050	2.511	4.422	3.314	9.778	9.099	22.361	26.358	25.577	19.009	24.232	24.323
7	16.771	21.439	21.257	2.994	7.552	6.744	6.593	8.452	10.096	16.818	21.393	20.995	18.791	21.598	23.455
8	14.341	19.213	19.752	6.509	3.777	3.393	8.259	10.171	10.034	4.669	10.548	11.166	6.159	11.670	11.439
9	14.492	18.727	18.531	4.841	2.393	3.826	2.822	7.222	10.762	14.663	19.384	19.103	4.371	5.700	7.719
10	13.961	19.910	19.313	1.765	3.230	10.395	14.583	19.947	18.866	12.525	16.498	16.969	7.060	13.005	14.053
11	13.335	17.327	18.531	15.918	19.240	20.153	7.835	12.511	8.223	6.793	10.711	8.605	17.418	21.270	20.894
12	12.800	12.861	14.305	1.991	5.757	3.404	16.833	21.637	21.888	9.545	19.625	17.638	10.645	18.160	17.914
13	4.721	11.817	7.195	3.465	4.637	1.994	0.559	7.678	2.510	25.209	27.276	28.134	8.765	15.635	14.271
14	12.992	17.040	15.347	0.989	3.649	0.987	1.247	6.743	5.158	10.777	15.749	14.124	12.737	20.546	22.035
15	13.254	19.233	16.699	0.696	4.897	3.653	6.024	12.044	11.432	6.304	14.176	12.610	9.371	17.140	15.412
16	10.740	12.046	10.474	2.324	4.210	2.358	16.346	22.078	20.173	15.332	21.360	19.593	11.304	18.034	18.527
17	10.820	11.588	11.758	1.800	3.169	3.368	16.353	22.170	20.810	3.635	10.239	13.877	12.143	19.515	15.888
18	10.436	11.387	10.802	0.518	3.687	3.259	13.636	20.370	17.829	24.360	29.295	28.867	10.246	17.488	16.678
19	10.297	13.680	11.235	0.275	5.172	7.634	4.364	4.744	9.559	24.367	27.238	25.282	14.293	19.820	19.880
20	10.346	13.233	13.948	2.887	6.174	9.437	12.188	17.262	16.168	16.356	22.092	19.232	4.901	17.182	14.056

1) Val : Validation

3. ANN 예측모델 구조 최적화 R^2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (1)

HL 2 Neuron HL 1 Neuron	4			5			6			7			8		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	0.988	0.982	0.983	0.966	0.960	0.958	0.995	0.978	0.966	0.981	0.953	0.953	0.953	0.975	0.979
5	0.996	0.979	0.976	0.989	0.983	0.975	0.994	0.984	0.986	0.991	0.982	0.982	0.982	0.951	0.535
6	0.993	0.980	0.981	0.992	0.976	0.980	0.994	0.972	0.978	0.996	0.981	0.981	0.981	0.932	0.945
7	0.958	0.941	0.945	0.996	0.971	0.973	0.997	0.970	0.984	0.997	0.980	0.988	0.973	0.978	0.991
8	0.997	0.969	0.972	0.998	0.965	0.987	0.999	0.809	0.959	0.996	0.973	0.973	0.985	0.947	0.955
9	0.973	0.973	0.977	0.980	0.980	0.981	0.901	0.901	0.962	0.979	0.979	0.979	0.979	0.791	0.847
10	0.978	0.978	0.977	0.979	0.979	0.985	0.855	0.855	0.862	0.981	0.981	0.981	0.981	0.974	0.986
11	0.967	0.967	0.965	0.687	0.687	0.817	0.969	0.969	0.961	0.978	0.978	0.978	0.978	0.985	0.977
12	0.964	0.964	0.979	0.986	0.986	0.987	0.974	0.974	0.984	0.971	0.971	0.971	0.971	0.988	0.986
13	0.972	0.972	0.965	0.976	0.976	0.977	0.976	0.976	0.937	0.963	0.963	0.963	0.963	0.975	0.983
14	0.755	0.729	0.732	0.998	0.976	0.949	0.995	0.969	0.972	0.998	0.980	0.980	0.980	0.976	0.961
15	0.998	0.973	0.971	0.994	0.958	0.782	0.998	0.976	0.970	0.999	0.974	0.974	0.974	0.823	0.847
16	0.996	0.964	0.961	0.990	0.980	0.979	1.000	0.977	0.957	1.000	0.977	0.977	0.977	0.983	0.977
17	0.998	0.974	0.949	0.999	0.974	0.954	1.000	0.971	0.972	0.997	0.975	0.975	0.975	0.947	0.944
18	0.998	0.968	0.933	0.996	0.958	0.970	0.999	0.956	0.957	0.985	0.955	0.955	0.955	0.981	0.971
19	0.996	0.976	0.975	0.999	0.968	0.946	0.999	0.969	0.959	1.000	0.976	0.976	0.976	0.946	0.954
20	0.960	0.936	0.937	0.997	0.978	0.982	0.998	0.963	0.959	1.000	0.925	0.925	0.925	0.980	0.957

1) Val : Validation

4. ANN 예측모델 구조 최적화 R^2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (2)

HL 2 Neuron HL 1 Neuron	9			10			11			12			13		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	0.984	0.970	0.977	0.997	0.972	0.988	0.994	0.971	0.987	0.994	0.972	0.986	0.996	0.981	0.966
5	0.998	0.973	0.992	0.998	0.937	0.975	0.992	0.973	0.968	0.999	0.981	0.965	0.999	0.979	0.986
6	0.996	0.964	0.990	0.996	0.953	0.970	0.996	0.979	0.978	0.998	0.979	0.984	0.998	0.690	0.765
7	0.998	0.973	0.963	0.999	0.988	0.978	0.996	0.980	0.982	0.998	0.912	0.946	0.999	0.981	0.985
8	0.999	0.968	0.975	0.977	0.953	0.960	0.999	0.977	0.985	1.000	0.965	0.935	0.998	0.928	0.585
9	0.991	0.963	0.969	0.981	0.981	0.983	0.958	0.958	0.942	0.975	0.975	0.981	0.977	0.977	0.976
10	0.982	0.982	0.979	0.999	0.977	0.971	0.844	0.844	0.973	0.923	0.923	0.976	0.975	0.975	0.978
11	0.970	0.970	0.978	0.973	0.973	0.975	0.919	0.898	0.888	0.961	0.961	0.967	0.961	0.961	0.889
12	0.967	0.967	0.966	0.973	0.973	0.963	0.883	0.883	0.914	0.999	0.974	0.977	0.973	0.973	0.988
13	0.980	0.980	0.977	0.948	0.948	0.972	0.945	0.945	0.940	0.971	0.971	0.973	0.996	0.976	0.982
14	1.000	0.971	0.985	0.960	0.927	0.936	1.000	0.921	0.931	1.000	0.974	0.962	0.998	0.983	0.962
15	1.000	0.629	0.894	1.000	0.223	0.375	1.000	0.932	0.910	0.908	0.865	0.866	1.000	0.879	0.863
16	0.924	0.888	0.888	0.999	0.980	0.980	1.000	0.959	0.959	1.000	0.968	0.956	1.000	0.848	0.695
17	1.000	0.954	0.338	1.000	0.961	0.950	0.999	0.739	0.949	1.000	0.825	0.864	1.000	0.965	0.953
18	1.000	0.959	0.951	1.000	0.967	0.960	1.000	0.959	0.939	1.000	0.976	0.969	1.000	0.961	0.972
19	1.000	0.855	0.728	1.000	0.973	0.961	0.997	0.971	0.977	1.000	0.974	0.958	0.997	0.965	0.939
20	1.000	0.813	0.950	1.000	0.956	0.960	1.000	0.923	0.896	0.998	0.977	0.942	1.000	0.345	0.553

1) Val : Validation

5. ANN 예측모델 구조 최적화 R^2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (3)

HL 2 Neuron HL 1 Neuron	14			15			16			17			18		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	0.997	0.978	0.993	0.998	0.956	0.975	0.993	0.982	0.986	0.997	0.968	0.965	0.998	0.975	0.981
5	0.998	0.979	0.979	0.999	0.977	0.982	0.998	0.937	0.961	0.998	0.981	0.968	0.999	0.981	0.986
6	0.987	0.936	0.922	0.999	0.895	0.863	0.999	0.981	0.978	0.998	0.962	0.956	0.999	0.977	0.964
7	0.999	0.980	0.985	0.997	0.970	0.871	0.999	0.975	0.966	0.999	0.966	0.989	0.999	0.979	0.978
8	1.000	0.890	0.938	0.999	0.960	0.967	0.999	0.978	0.989	0.999	0.977	0.965	1.000	0.944	0.973
9	0.935	0.935	0.934	0.891	0.891	0.890	0.939	0.939	0.977	0.987	0.987	0.964	0.988	0.988	0.981
10	0.971	0.971	0.956	0.981	0.981	0.955	0.983	0.983	0.975	0.977	0.977	0.982	0.968	0.968	0.859
11	0.777	0.777	0.903	0.962	0.962	0.962	0.979	0.979	0.984	0.987	0.987	0.983	0.795	0.795	0.767
12	0.959	0.959	0.976	0.907	0.907	0.953	0.980	0.980	0.932	0.388	0.388	0.801	0.959	0.959	0.940
13	0.943	0.943	0.969	0.949	0.949	0.960	0.969	0.969	0.962	0.881	0.881	0.927	0.557	0.557	0.489
14	1.000	0.954	0.942	1.000	0.975	0.974	1.000	0.976	0.961	1.000	0.954	0.956	1.000	0.966	0.945
15	1.000	0.957	0.976	1.000	0.978	0.969	1.000	0.952	0.961	1.000	0.956	0.254	0.999	0.974	0.979
16	1.000	0.807	0.745	1.000	0.960	0.960	0.998	0.978	0.987	0.999	0.965	0.972	0.995	0.971	0.984
17	1.000	0.816	0.887	1.000	0.973	0.941	0.997	0.981	0.978	0.999	0.967	0.965	1.000	0.923	0.965
18	1.000	0.927	0.957	1.000	0.958	0.951	1.000	0.973	0.977	0.856	0.806	0.812	1.000	0.930	0.926
19	1.000	0.953	0.954	1.000	0.963	0.966	0.926	0.890	0.896	1.000	0.387	0.402	1.000	0.892	0.744
20	1.000	0.911	0.851	1.000	0.952	0.954	1.000	0.949	0.961	1.000	0.944	0.913	1.000	0.904	0.913

1) Val : Validation

6. ANN 예측모델 구조 최적화 R^2 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (4)

HL 2 Neuron HL 1 Neuron	19			20		
	Train	Val ¹⁾	Test	Train	Val	Test
4	0.999	0.668	0.847	0.999	0.963	0.986
5	0.999	0.974	0.979	0.996	0.968	0.979
6	1.000	0.977	0.986	0.999	0.974	0.957
7	0.999	0.935	0.954	1.000	0.983	0.986
8	1.000	0.984	0.975	1.000	0.960	0.968
9	0.979	0.979	0.980	0.971	0.971	0.950
10	0.969	0.969	0.985	0.822	0.822	0.807
11	0.918	0.918	0.791	0.959	0.959	0.941
12	0.955	0.955	0.949	0.951	0.951	0.965
13	0.949	0.949	0.974	0.963	0.963	0.964
14	1.000	0.981	0.982	1.000	0.974	0.975
15	1.000	0.873	0.839	1.000	0.942	0.978
16	1.000	0.922	0.858	1.000	0.951	0.981
17	1.000	0.976	0.961	0.995	0.978	0.987
18	1.000	0.951	0.979	1.000	0.800	0.783
19	1.000	0.937	0.969	1.000	0.955	0.945
20	1.000	0.915	0.838	0.997	0.970	0.949

1) Val : Validation

7. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (1)

HL 2 Neuron HL 1 Neuron	4			5			6			7			8		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	5.765	5.289	9.776	9.629	15.110	7.802	3.784	4.372	7.103	7.372	10.962	11.411	4.110	9.079	10.222
5	3.214	6.967	14.411	5.478	7.219	7.064	4.139	6.140	11.781	4.997	5.885	11.193	8.534	7.861	5.562
6	4.435	1.616	10.781	4.757	3.405	9.688	4.050	2.511	4.422	3.346	7.402	6.421	9.528	12.707	9.507
7	10.877	15.027	13.746	3.259	7.175	3.730	2.740	5.141	7.857	2.994	7.552	6.744	1.738	5.338	8.771
8	3.023	9.432	5.883	2.393	9.118	40.443	2.042	21.035	10.742	3.419	8.896	6.919	6.509	3.777	3.393
9	4.403	5.266	8.678	2.997	8.457	6.147	3.085	8.853	5.449	3.750	5.367	12.284	4.006	17.316	9.641
10	3.007	1.951	8.041	4.025	4.892	9.638	17.062	21.552	5.892	2.078	5.932	7.439	2.878	3.854	11.534
11	3.980	7.822	8.258	2.295	33.182	0.833	2.689	2.246	8.369	3.036	7.620	4.587	1.938	3.631	5.355
12	3.418	2.544	9.984	3.014	5.988	10.858	2.877	7.301	5.494	2.257	4.441	8.454	1.126	6.304	3.474
13	1.794	7.969	10.195	1.576	5.499	9.065	1.392	9.921	24.454	1.106	4.918	4.219	2.615	9.729	41.151
14	26.371	28.276	7.983	2.135	7.647	9.513	3.639	7.168	2.268	2.483	5.247	5.861	1.101	2.566	15.251
15	2.621	7.585	8.608	4.243	6.190	8.435	2.365	0.864	23.350	1.768	6.275	15.699	17.146	24.500	5.683
16	3.467	6.597	6.265	5.465	4.571	7.366	1.190	5.533	7.663	1.506	8.495	3.902	1.688	6.324	4.462
17	2.256	7.259	7.927	1.220	7.555	11.260	1.084	8.647	12.697	3.371	7.262	5.839	1.501	10.082	7.257
18	2.338	5.825	9.525	3.405	5.357	6.003	1.599	4.250	13.023	6.430	1.874	7.660	1.000	5.896	9.130
19	3.479	6.287	11.636	1.243	4.091	3.280	1.916	7.532	6.919	1.478	5.510	7.886	5.568	6.233	7.706
20	10.685	11.738	6.896	2.794	7.463	5.703	2.564	4.755	6.793	0.687	7.428	6.751	3.462	7.355	10.125

1) Val : Validation

8. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (2)

HL 2 Neuron HL 1 Neuron	9			10			11			12			13		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	6.786	5.916	4.869	3.126	1.471	4.044	2.937	4.207	2.925	3.990	5.293	6.890	3.562	4.771	7.603
5	2.482	5.069	7.592	2.437	15.442	6.381	4.687	5.312	27.892	1.941	2.468	4.030	1.849	6.687	8.261
6	3.372	8.458	7.050	3.211	11.334	21.319	3.361	10.118	8.702	2.158	2.666	5.296	2.412	30.286	16.227
7	2.103	4.931	5.162	1.226	6.407	4.600	3.402	6.352	8.541	2.565	10.741	7.729	1.714	5.070	11.403
8	1.584	4.778	23.785	8.180	14.343	8.443	1.607	4.914	5.933	1.229	6.027	7.994	2.080	10.760	6.244
9	4.841	2.393	3.826	1.593	5.521	8.201	0.656	1.855	9.677	2.772	8.465	2.849	2.768	7.187	7.108
10	1.897	6.168	7.144	1.765	3.230	10.395	1.557	24.114	10.526	1.211	13.555	4.562	3.414	6.261	7.520
11	4.255	10.160	5.968	4.016	6.616	8.154	15.918	19.240	20.153	8.749	3.199	12.970	0.805	3.970	12.201
12	2.739	9.193	8.636	1.335	4.017	8.867	3.843	13.522	8.230	1.991	5.757	3.404	1.361	4.494	12.235
13	2.818	8.856	6.856	0.796	3.840	5.096	9.838	12.234	15.377	1.799	4.073	4.851	3.465	4.637	1.994
14	1.148	5.143	14.961	10.618	16.276	8.223	0.319	8.703	9.014	0.809	3.626	5.296	2.408	3.490	8.637
15	0.809	38.259	19.001	0.665	107.252	2.423	0.948	7.228	9.249	16.168	20.651	2.666	0.440	16.567	6.649
16	14.784	20.188	1.071	1.938	7.605	2.752	0.661	1.614	8.484	0.479	9.131	9.731	0.656	17.026	7.629
17	0.962	6.891	8.426	0.886	3.484	2.092	1.352	23.664	5.512	0.998	25.476	26.082	0.448	7.198	7.839
18	0.722	7.899	6.727	0.689	9.887	24.681	0.545	5.610	19.586	0.380	5.897	8.476	0.341	9.199	46.622
19	0.825	10.680	8.990	1.572	7.729	7.187	3.000	8.442	18.245	0.616	6.034	4.078	2.991	4.900	6.789
20	0.433	18.650	7.573	1.000	7.454	26.168	1.239	9.243	13.765	2.312	2.762	7.945	0.028	63.713	6.679

1) Val : Validation

9. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (3)

HL 2 Neuron HL 1 Neuron	14			15			16			17			18		
	Train	Val ¹⁾	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test	Train	Val	Test
4	2.735	2.923	28.193	2.275	12.482	7.905	4.982	7.516	7.322	3.874	6.532	9.938	2.122	1.655	4.281
5	2.225	8.550	12.071	0.427	4.713	19.762	2.283	10.701	6.333	2.179	1.283	9.956	1.624	0.436	6.833
6	6.154	12.299	9.109	1.900	18.890	9.106	1.542	1.537	9.321	2.479	6.731	5.938	1.600	3.057	4.596
7	1.458	0.521	8.829	3.212	6.687	8.092	1.805	5.991	9.096	1.317	7.800	6.103	1.785	0.347	11.274
8	0.895	21.525	8.633	1.304	5.129	21.781	0.645	5.681	9.783	1.688	5.652	9.718	0.984	6.844	6.762
9	9.232	15.138	7.305	15.067	21.908	15.563	0.607	11.913	19.064	1.088	3.955	61.594	0.597	2.802	9.730
10	0.792	5.895	15.828	0.937	6.767	72.432	0.778	6.368	7.096	0.902	7.173	10.581	0.483	8.491	11.225
11	0.785	27.212	3.048	1.014	7.720	11.515	0.182	6.306	7.462	0.443	3.955	7.325	0.798	19.875	5.748
12	0.577	7.987	9.627	0.487	9.214	20.385	0.638	2.434	9.209	0.171	65.760	20.768	2.046	5.725	9.702
13	1.691	7.012	5.245	0.933	9.027	9.094	0.511	5.338	35.316	0.694	20.774	1.964	0.983	47.884	9.981
14	0.999	3.649	0.987	0.588	2.816	11.155	1.205	1.203	27.880	0.746	9.516	19.843	1.136	4.775	10.877
15	0.533	5.608	7.516	0.636	4.897	3.653	0.218	9.135	5.477	0.863	5.658	10.439	1.254	6.154	3.789
16	0.251	23.348	11.398	0.410	2.532	8.992	2.324	4.210	2.358	1.221	10.255	8.041	3.811	8.006	3.337
17	3.112	18.305	7.712	0.818	7.433	93.080	2.831	7.583	5.366	1.800	3.169	3.368	0.395	5.383	25.986
18	0.338	10.056	1.369	0.348	4.147	7.004	0.844	6.908	8.313	20.255	23.378	4.519	0.518	3.687	3.259
19	0.274	4.768	6.011	0.316	1.971	23.747	14.481	19.553	20.748	0.213	76.739	6.414	0.215	11.291	8.795
20	1.199	7.999	9.839	0.585	10.481	7.361	0.334	1.824	3.721	0.536	8.056	8.336	0.272	19.988	23.607

1) Val : Validation

10. ANN 예측모델 구조 최적화 Cv(RMSE) 결과 - ② [Step 2] Hidden Layer fix & Hidden Neuron change (4)

HL 2 Neuron HL 1 Neuron	19			20		
	Train	Val ¹⁾	Test	Train	Val	Test
4	1.888	31.734	6.923	1.866	5.884	14.124
5	1.262	9.262	10.964	3.438	4.846	7.539
6	1.040	1.765	12.527	1.618	4.965	7.621
7	2.386	1.610	7.404	0.441	7.674	63.268
8	0.925	6.323	11.815	1.168	6.625	9.163
9	2.707	4.776	20.955	0.532	1.271	4.531
10	1.525	9.914	8.289	1.075	24.244	9.658
11	0.552	13.739	9.306	1.679	5.883	3.981
12	0.902	4.013	8.518	1.301	12.485	12.006
13	1.567	11.646	5.343	0.453	2.121	38.056
14	1.611	6.619	8.661	0.419	7.108	12.888
15	0.345	17.394	8.058	0.251	12.033	5.850
16	0.151	10.230	18.824	0.624	13.364	8.920
17	0.770	8.690	71.659	3.768	6.834	9.426
18	0.705	10.035	24.975	0.418	29.122	11.672
19	0.275	5.172	7.634	0.321	5.996	21.253
20	0.257	9.176	11.008	2.887	6.174	9.437

1) Val : Validation

참 고 문 헌

<국내문헌>

1. 곽영훈, 실시간 건물 에너지 시뮬레이션 프레임워크 개발을 통한 냉방 시스템 예측 제어, 서울시립대학교 대학원, 건축공학과, 박사학위논문, 2014.
2. 에너지경제연구원, 2014 에너지 총조사 보고서, 2014.
3. 조진균, 정차수, 김병선, 고밀도 내부부하 중심 건물의 에너지 절약적 공조방식에 대한 연구, 대한설비공학회, 설비공학논문집, 2018. 22(8), pp.530-537.
4. 송준화, 송명호, Korea data center market 2020-2030, (사)한국데이터센터연합회, 2020.
5. 건축법 시행령, 제3조 5, 별표 1, 용도별 건축물의 종류, 2018.
6. 이상학, 문성준, 그린데이터센터 구현기술 및 표준화 동향, 한국정보사회진흥원 국가정보사업단 녹색정보화지원부, 2010.
7. 조진균, 고밀도 데이터센터의 공조효율 및 에너지성능 개선을 위한 공조시스템 계획방법 연구, 연세대학교 대학원, 박사학위논문, 2009.
8. 한국네트워크산업협회, ICT 장비 산업 경쟁력 강화 전략 정책연구, 미래창조과학부 연구 보고서, 2013.
9. 과학기술정보통신부, 관계부처 합동, 제 1차 혁신성장전략회의, 데이터·AI경제 활성화 계획('19~'23년), 제 1차 혁신성장전략회의, 2019.
10. IBM, 그린, 그린IT 그리고 그린데이터센터, 한국경제신문, 2009.
11. 서원준, 박철수, 유진 프로그래밍과 BEMS 데이터를 이용한 실내온도 기계학습 모델, 대한건축학회 논문집, 2016, 23(6), pp.105-112.
12. 라선중, 신한솔, 서원준, 추한경, 박철수, 기존 건물 HVAC 시스템에 대한 다섯 가지 기계학습 모델 개발, 대한건축학회 논문집, 2017, 33(10), pp.69-77.
13. 박창봉, 사무소건물의 에너지절약형 냉방시스템 적용에 관한 연구,

- 박사학위논문, 중앙대학교, 2011.
14. 김석우, 에너지 시뮬레이션 기술 동향, 건축환경설비, 2015, 9(1), pp.22-30.
 15. 데이터센터의 정의 및 분류체계, 한국IT서비스산업협회, 2008.
 16. 김세훈, 원종연, 이연구, 건물의 에너지 절약을 위한 외기냉수냉방 시스템에 관한 연구, 대한건축학회, 학술발표대회논문집, 2004, 24(1), pp.746-749.
 17. 정상진, 김문구, 그린 데이터센터 표준화 및 인증제 동향, TTA 저널, 2013, 145, pp.76-82.
 18. 한국에너지공단, 데이터센터가 건물부문 에너지 원단위에 미치는 영향, 주간 에너지 이슈브리핑, 제151호, 2016.
 19. 배용진, 한국은 데이터센터 각축장, 글로벌 기업 속속 들어오는 이유, 2019.
 20. 한국건설생활환경시험연구원, PUE 1.3x급 구현을 위한 에너지 절감 통합 솔루션 및 설비 모듈 개발, 산업기술혁신사업 계획서, 2018.
 21. 연창근, 이진영, 네이버 데이터센터 ‘각’, 건축환경설비, 2019, 10(3), pp.51-57.
 22. 김지선, 이슈분석, 2025년 아태지역 IDC 2위 시장으로 부상, 2020.
 23. 박성우, 이동욱, 오상운, 김재훈, 데이터센터에서의 에너지 절약을 위한 유비쿼터스 센서 네트워크 기반의 적응적 분산 냉각 전략, 한국정보과학회 학술발표논문집, 2009, 36(18), pp.266-271.
 24. 이승연, 김민호, 이성구, 연창근, 데이터센터의 냉방에너지 절감을 위한 외기냉방 시스템 개선에 관한 연구, 대한설비공학회 학술발표대회논문집, 2017. pp.810-814.
 25. 김민휘, 박준영, 정재원, 데이터센터 냉방을 위한 제습 증발냉각시스템의 적용성 분석, 대한건축학회 학술발표대회 논문, 2013. pp.283-284.
 26. 윤정인, 손창효, 허정호, 김영민, 데이터센터의 외기냉수냉방 시스템에 대한 에너지 절감효과 분석. 한국동력기계공학회지, 2014, 18(3), pp.73-78.
 27. 김제영, 장현재, 정용호, 멀티 외기냉방을 이용한 데이터센터의

- 에너지절약 시스템 개발에 관한 연구, 대한건축학회 학술박표대회논문집, 2014, 34(2), pp.267-268.
28. 조진균, 정차수, 김병선, op. cit., pp. 209.
29. 함상우, 정재원, 컨테인먼트가 적용된 데이터센터의 CFD 모델링 기법 및 열 관리 성능 평가. 2015. 31(1), pp.159-166.
30. 최영재, 컨테인먼트형 데이터센터의 최적 열환경을 위한 적응형 제어알고리즘 개발 및 성능평가, 석사학위논문, 중앙대학교, 2020.
31. 안기연, Deep Q-learning의 강화학습 기반 건물 에너지 시스템의 model-free 최적 제어, 박사학위논문, 성균관대학교, 2018.
32. 권한솔, 인공지능망을 이용한 부하 예측 기반 대형 건물의 복합 냉동기 최적운영 방안, 박사학위논문, 서울시립대학교, 2013.
33. 문지훈, 전상훈, 박진웅, 최영환, 황인준, 인공 신경망과 지지 벡터 회귀분석을 이용한 대학 캠퍼스 건물의 전력 사용량 예측 기법, 정보처리학회 논문지, 컴퓨터 및 통신 시스템, 2016, 5(10), pp. 293-302.
34. 김영진, 박철수, 가우시안 프로세스 모델과 냉동기 실시간 최적 제어, 대한건축학회 논문집 - 계획계, 2014, 30(7), pp.221-220.
35. 최영재, 박보랑, 조지현, 문진우, 컨테인먼트형 데이터센터 최적 제어알고리즘을 위한 열환경 예측모델 개발. 한국생태환경건축학회 논문집, 2020, 20(5), 159-164.
36. 강인성, 문진우, 박진철, 최근 건축분야의 인공지능 기계학습 연구동향, 대한건축학회, 논문집, 2017, 33(4), pp.63-68.
37. 광영훈, 데이터 피드백을 통한 사무소 건물의 에너지 수요예측기법 개발, 한국건축친환경설비학회, 추계학술발표대회, 2009, pp.55-58.
38. 최상열, 김형중, 데이터마이닝을 이용한 단기부하예측, 한국조명전기설비학회, 2009, 21(10), pp.126-133.
39. 공동석, 광영훈, 이병정, 허정호, 인공신경망을 이용한 데이터베이스 기반의 광역단지 에너지 수요예측 기법 개발, 한국태양에너지학회 학술대회논문집, 2009, 29(1), pp.184-189.
40. 김영민, 김용세, 안기연, 박철수, 에너지 실시간 모델 예측 제어를 위한

- 인공신경망 변수 최적화, 한국건축친환경설비학회, 학술발표대회논문집, 2015, pp.159-160.
41. 성남철, 김지현, 최원창, 윤상천, Nabil Nassif, 인공신경망을 이용한 건물의 에너지 모델 최적화 알고리즘 개발 및 검증에 관한 연구, 한국생활환경학회 논문집, 2017, 24(1), pp.29-36.
 42. 강인성, 양영권, 이효은, 박진철, 문진우, 건물 냉방시스템의 예측제어를 위한 인공신경망 모델개발, 한국생태환경건축학회 논문집, 2017, 178(5) pp.69-76.
 43. 박현규, 김용주, 신상용, 김진환, 최지혜, 류은경, 그린, 그린IT 그리고 그린데이터센터, 한국경제신문, 2009.
 44. 강인성, 오피스건물 공조시스템의 인공신경망 기반 에너지사용량 예측모델 개발, 석사학위논문, 중앙대학교, 2017.
 45. 현석균, 건물냉난방에너지의 동적성능시뮬레이션, 석사학위논문, 경희대학교, 2003.
 46. 라선중, 신한솔, 서원준, 추한경, 박철수, 기존 건물 HVAC 시스템에 대한 다섯 가지 기계학습 모델 개발, 대한건축학회 논문집, 2017, 33(10), pp.69-77.
 47. 김석우, 에너지 시뮬레이션 기술 동향, 건축환경설비, 2015, 9(1), pp. 22-30.
 48. 윤상용, 곽하늬, 한철호, 심문보, 장병탁, 베이지만 최적화 기반 능동 학습 통한 효율적 유기 분자 탐색, 한국정보과학회 학술발표논문집, 2015, pp.772-774.
 49. 박철수, 건물에너지 성능 시뮬레이션의 불확실성과 표준적 접근, 대학교수 해외 방문연구자 결과보고서, 성균관대학교, 2010.
 50. 조진균, 홍원표, 기존 데이터센터의 구역단위 에너지효율평가 방법 및 PUE 기반 M&V 베이스라인 모델 개발, 대한설비공학회 논문집, 2020, 32(2), pp.88-99.

<국외문헌>

1. Gartner, Green Data Centers: The six Key Attributes of Data Center Energy Efficiency Metrics, 2008.
2. Simon Mingray, Green IT: The New Industry Shockwave, Gartner RAS Core Research Note G00153507, 2007.
3. Info-Tech Research Group, Top 10 Energy Saving Tip for Greener Data Center, Operate & Optimize Info-Tech Advisor Premium, 2007.
4. ASHRAE, ASHRAE TC9.9: Data center Power Equipment Thermal Guidelines and Best Practices, 2016.
5. BICSI, BICSI 002: Data Center Design and Implementation Best Practices, 2019.
6. Young-hak, Song, Yasunori Akashi, Jung-Jae Yee, Energy performance of a cooling plant system using the inverter chiller for industrial building, Energy and Buildings, 2007, 39, pp.289-297.
7. John Niemann. Hot Aisle vs. Cold Aisle Containment, White Paper #135, Schneider Electric, 2008.
8. ASHRAE TC 9.9, Thermal Guidelines for Data Center Processing Environments, 2011.
9. Neil Rasmussen, Calculating Total Cooling Requirements for Data Centers, APC White Paper #25. 2003.
10. Tony Evans, The different types for air conditioning equipment for it environments, APC white paper #59, 2004.
11. The Green Grid, Technical Committee White Paper, 2010.
12. A. S. G. Andrae, T. Edler, On Global Electricity Usage of Communication Technology: Trends to 2030, challenges, 2015, 6(1), pp.117-157.
13. Commercial Buildings Energy Consumption Survey (EIA).
14. Emerson Network Power, Energy Logic: Reducing Data Center Energy

- Consumption by Creating Savings that Cascade Across Systems, A White Paper from the Experts in Business-Critical Continuity, 2008.
15. Sami Alkharabsheh, John Fernandes, Betsegaw Gebrehiwot, Dereje Agonafer, Kanad Ghose, Alfonso Ortega, Yogendra Joshi, Bahgat Sammakia, A Brief Overview of Recent Developments in Thermal Management in Data Centers, *Journal of Electronic Packaging*, 2015, 137(4), pp.19.
 16. Weiwen Zhang, Yonggang Wen, Yew Wah Wong, Kok Chuan Toh, Chiu-Hao Chen, Towards Joint Optimization Over ICT and Cooling Systems in Data Centre.
 17. Harfiz M. Daraghmeh, Chi-Chuan Wang, A review of current status of free cooling in datacenters, *ATE*, 2017, 114(5), pp.1224-1239.
 18. Jiacheng Ni, Xuelian Bai, A review of air conditioning energy performance in data centers. *Renewable and Sustainable Energy Reviews*, 2017, 67, pp.625-640.
 19. C.B. Bash, C.D. Patel, R.K. Sharma, Dynamic thermal management of air cooled data centers, *IEEE Xplore*, 2006.
 20. Monem H. Beitelmal, Chandrakant D. Patel, Model-Based Approach for Optimizing a Data Center Centralized Cooling System, *hp invent*, 2006, 67, pp.45
 21. Yuan Chen, Daniel Gmach, Chris Hyser, Zhikui Wang, Cullen Bash, Christopher Hoover, Sharad Singhal, Integrated Management of Application Performance, Power and Cooling in Data Centers, *IEEE Xplore*, 2010.
 22. Weiwen Zhang, Yonggang Wen, Yew Wah Wong, Kok Chuan Toh, Chiu-Hao Chen, Towards Joint Optimization Over ICT and Cooling Systems in Data Center: A Survey, *IEEE Xplore*, 2016. 18(3), pp.1596-1616.
 23. Junwen DengLiu YangXinrong ChengWu Liu, Self-tuning PID-type

- Fuzzy Adaptive Control for CRAC in Datacenters, International Conference on Computer and Computing Technologies in Agriculture, 2014.
24. Jim Gao, Machine Learning Applications for Data Center Optimization, Google, 2014.
 25. 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, 2014, 134, pp.45-56.
 26. Dong WEI, Baiyu LI, Yancai SHI, Zhuangju LI, Energy-Efficient Mode Transition Strategies of Data Center Cooling Systems, 2016.
 27. Marina Zapater, Jose L. Risco-Martin, Patricia Arroba, Jose L. Ayala, Jose M. Moya, Roman Hermida, Runtime data center temperature prediction using Grammatical Evolution techniques, Applied Soft Computing, 2016, 49, pp. 94-107.
 28. Dayarathna, M., Wen, Y., Fan, R., Data center energy consumption modeling: A survey, 2016, 18(1), pp. 732-794.
 29. Alessandro Beghi, Lica Cecchinato, Giuseppe Dalla Mana, Nirco Rampazzo, Enrico Sisti, Modelling and control of a free cooling system for Data centers, Eenergy Procedia, 2017, 140, pp.447-457.
 30. Srimoyee Bhattacharjee, Sunirmal Khatua, Sarbani Roy, A review on Energy Efficient Resource Management Strategies for cloud, Advanced Computing and Systems for Security, 2017, 568, pp.3-15.
 31. Leehter YaoJin-Hao Huang, Multi-Objective Optimization of Energy Saving Control for Air Conditioning System in Data Center, Energies, 2019, 12(8), pp. 1474.
 32. Qui Fang, Qi Gong, jun Wang, Yaonan Wang, Optimization based resource and cooling management for a high performance computing data center, ISA Transactions, 2019, 90, pp.202-212.

33. McCullock, W. S., & Pitts, W. A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 1943, 5(4), pp.115–113.
34. A.Afram, F. Janabi-Sharifi, A.S. Fung, Raahemifar, Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems; Astate of the art review and case study of a residential HVAC system, Eenergy Buildings, 2017, 141, pp.96–113.
35. Rosenblatt, F, The Perceptron: A Probabilistic Model for Information Storage and Organization in thr Brain. Cornell Aeronautical Laboratory, Psychological Review. 1958, 56(6), pp.386–408.
36. Sanchit Tanwar, Introduction to machine learning and deep learning, 2019.
37. Aurellen Geron, Hands-On Machine Learning with Scikit-Learn & TensorFlow, Oreilly. 2017.
38. J.A. Suykens, J. Vandewalle, Least squares support vector machine classifiers, Neural Processing letters, 1999, 9(3), pp.293–300.
39. M. Martin, On-line support vector machine regression, In European Conference on Machine Learning, Springer, Berlin, Heidelberg, pp.282–294.
40. Radu Platon, Vahid Raissi Dehkordi and Jacques Martel, Hourly Prediction of a Building's Electricity Consumption using Case-based Reasoning, Artificial Neural Networks and Principal Component Analysis, Energy and Buildings 2015, 92.
41. Pedro A. Gonzalez and Jesus M. Zamarreno, Prediction of Hourly Energy Consumption in Buildings based on a Feedback Artificial Neural Network, Energy and Buildings, 2005, 37.
42. A. Garnier, J. Eynard, M. Caussanel, S. Grieu, Predictive control of multizone heating, ventilation and air-conditioning systems in non-residential buildings, Appl Soft Comput, 2015, 37, pp.847–862.

43. A. Kusiak, G.L. Xu, Z.J. Zhang, Minimization of energy consumption in HVAC systems with data-driven models and an interior-point method, *Energy Convers Manage*, 2014, 85, pp.146-153.
44. A. Afram, F. Janabi-Sharifi, Theory and applications of HVAC control systems – A review of model predictive control (MPC), *Build Environ*, 2014, 72, pp.343-355.
45. ASHRE, Green Tips for Data Centers, ASHRAE Datacom Series Series Book 10, 2010.
46. Yann LeCun, Leon Bottou, Genevieve B. Orr and Klaus-Robert Müller, Efficient BackProp, *Neural Networks: Tricks of the Trade*, 1998, pp. 9-50.
47. M. Buscema, Back propagation neural networks. *Substance use & misuse*, 1998, 33(2), pp. 233-270.
48. T. Y. Liu., P. Zhang., J. Wang., Y. Ling., Compressive Strength Prediction of PVA Fiber-Reinforced Cementitious Composites Containing Nano-SiO₂ Using BP Neural Network, *Materials*, 2020, 13(521), pp.1-25.
49. J. J. Moré, The Levenberg-Marquardt algorithm: implementation and theory, In *Numerical analysis*, Springer, Berlin, Heidelberg. 1978, pp. 105-116.
50. Aurelien Geron, *Hands-On Machine Learning with Scikit-Learn & Tensorflow*, OREILLY, 2017.
51. J.C. Schlimmer, R.H. Granger, JR, Incremental Learning from Noisy Data, *Machine Learning*, 1986, 1, pp.317-354.
52. ASHRAE, ASHRAE Guideline 14-2014, Measurement of Energy and Demand, and Water Savings, 2014.

<Web Site>

1. Data Center Map, <https://www.datacentermap.com>, (accessed on 5 Aug 2020)
2. MathWorks, <https://kr.mathworks.com/>(accessed on 5 Aug 2020)
3. ZD Net Korea, 세계 데이터센터 온도가 5도 올라가면?, 2011. <https://zdnet.co.kr/>, (accessed on 7 Sep 2020)
4. MathWorks, <https://www.mathworks.com/> (accessed on 7 Oct 2020)
5. MathWorks, <https://www.mathworks.com/> (accessed on 11 Oct 2020)

국 문 초 록

데이터센터의 에너지 절약을 위한 인공신경망 기반 냉수 유량 제어알고리즘 개발

박 보 량

건축학과 건축환경계획 전공

중앙대학교 대학원

IT 산업의 급속한 발달로 기업들의 사업변화로 데이터센터 수요가 급증하고 있다. 전 세계 기업의 IT 전력소비량은 한 해 1,000억 kW로 전 세계 이산화탄소 배출량의 2%를 차지하고 있다. 데이터센터 IT 서버 수는 매년 13% 증가, 전력소비량은 연 20%의 증가추세에 있다. 데이터센터는 대표적인 에너지 과소비 건축물로 보편적 에너지 소비비율은 냉방이 전체의 50%를 차지함에 따라 서버냉각 에너지를 줄이는 것이 전체 에너지 소비를 줄이는 최선의 방안이다. 따라서, 본 연구에서는 데이터센터의 최적 실내 열환경 제공 및 냉방에너지의 절약을 위하여 냉수 유량제어를 기반으로 ANN을 활용한 예측모델과 적응형 제어알고리즘을 개발하였다.

대상 데이터센터는 중앙 냉수식 시스템이 적용된 컨테이너먼트 방식이며 냉수 유량제어를 통해 실내온도 및 냉방에너지를 예측·제어한다. 에너지보존의 법칙에 근거한 수학적 모델에 의해 20,200개의 데이터를

취득하였으며 제어알고리즘의 성능평가를 위해 MATLAB을 활용하여 시뮬레이션 모델을 실제 데이터센터와 유사하게 모사하여 구축하였다. 예측모델의 입력변수는 IT 서버 발열량, CRAH 회수공기 온도, 냉수 유량이며 출력변수는 CRAH 공급공기 온도로 설정하였다. 이를 활용하여 ANN을 통한 초기 CRAH 공급공기 온도 예측모델을 개발하였다. 인공신경망 예측모델의 성능 입증을 위하여 세 가지 기계학습 RF, GPR, SVM을 개발하여 예측성능을 비교·분석하였다. ANN 예측모델은 구조 최적화, 세 가지 기계학습 예측모델은 하이퍼파라미터 최적화를 진행하였다. 그 결과 ANN 예측모델 은닉층 2개, 은닉층 뉴런수 14-14개 모델이 Cv(RMSE) 0.98%으로 네 가지 예측모델 중 가장 우수한 성능으로 최종 예측모델 구조로 채택되었다.

개발된 예측모델을 포함한 제어알고리즘은 오차에 대한 재학습 과정 포함 여부에 따라 비적응과 적응형 제어알고리즘으로 나누어 성능평가를 실시하였다. 적응형 제어알고리즘은 세 가지 재학습 알고리즘 기법을 적용하고 각각의 기법에 대해 하이퍼파라미터 최적화를 수행하여 최적 적응형 제어알고리즘을 선정하였다. 그 결과, Sliding Window 기법의 적응형 제어알고리즘의 RMSE가 0.04℃로 산출되어 가장 예측 정확도가 높았으며 또한 비적응형 제어알고리즘 대비 RMSE가 약99% 개선되었다. 따라서 가장 우수한 제어 정확도를 나타냄에 따라 최종 제어알고리즘 모델로 선정하였다.

선정된 적응형 제어알고리즘의 새로운 환경에 대한 적응성 및 확장성을 검증하기 위하여 컨테이너먼트 규모와 IT서버 발열량 및 설정온도를 변경하여 제어를 실시한다. ANN 제어기의 성능 검증을 위하여 기존에 일반적으로 사용되고 있는 ON-OFF, PID 제어기와 비교하여 예측·제어 정확성, 안정성, 에너지 절약성, 적응성을 평가하였다. 그 결과, ANN

적응형 제어알고리즘이 새로운 환경에서의 변경된 두 가지 제어 시나리오 모두에서 각각 RMSE 0.23℃, 0.24℃로 높은 정확도를 보였으며 최대 오차 온도와 냉방 에너지소비량 측면에서도 가장 낮게 나타나 안정성, 에너지 절약성에서도 가장 우수한 성능을 보였다. 즉, 새로운 환경에 대한 ANN 기반 적응형 제어알고리즘의 적응성 및 확장성이 합리적으로 검증되었다.

따라서, 본 연구에서 개발한 제어알고리즘은 다양한 데이터센터 및 냉수 유량제어 기반 냉각 시스템에 적용 가능성이 확인되었다. 또한, 개발 기술은 데이터센터의 효율적 냉각 시스템 운영을 가능하게 하여 냉방에너지 절감 및 CO₂ 배출량 감소에 도움을 주어 그린 데이터센터 구현의 핵심 기능을 제공할 수 있을 것으로 기대된다.

핵심어 : 데이터센터, 건물에너지, 인공지능망, 냉수 유량제어, 적응형 제어알고리즘

ABSTRACT

Development of an Artificial Neural Network based Chilled water flow Control Algorithm to Improve the Energy Saving of the Data centers

Park, Bo Rang

Major in Environmental Design in Architecture
Department of Architecture and Building Science
The Graduate School of Chung-Ang University

Recently, With the rapid development of the IT industry, the demand for data centers is rapidly increasing due to business changes of companies. IT power consumption of the world companies is 100 billion kW per year, accounting for 2% of world-wide carbon dioxide emissions. The number of IT servers in the data center is on the rise of 13% annually and power consumption is on the rise of 20% annually. As data centers are excessive energy consuming buildings, cooling accounts for 50% of the total energy consumption ratio of the building, the best way to reduce overall every consumption is reducing server cooling. Therefore, in this study, we developed a predictive model and an adaptive control algorithm using ANN based on chilled water mass flow control to provide the optimal indoor thermal environment of the data center and save cooling energy.

The target data center is a containment type with a central cooling

water system applied and predicts controls indoor thermal environment and cooling energy through control of chilled water mass flow. 20,200 data were acquired by a mathematical model based on the law of conservation of energy, and a simulation model was constructed similar to a real data center using MATLAB to evaluate the performance of the control algorithm. The input variables of the predictive model were IT server calorific value, CRAH recovered air temperature, and chilled water mass flow rate while the output variables were set as CRAH supply air temperature. Using this, an ANN-based initial CRAH supply air temperature prediction model was developed. To prove the performance of the artificial neural network prediction model, three machine learning RF, GPR, and SVM were developed to compare analyze the prediction performance. The ANN prediction model was structure optimized, and the three machine learning prediction models were hyperparameters optimized. As a result, the ANN prediction model was adopted as the final prediction model with 2 hidden layers and 14-14 hidden neurons with a Cv (RMSE) of 0.98%, with the best performance among the four prediction models.

The control algorithm including the developed prediction model was divided into non-adaptive and adaptive control algorithms based on the capacity of relearning process for errors in order to evaluate the performance. For the adaptive control algorithm, the optimal adaptive control algorithm was selected by applying three relearning algorithm techniques and performing hyperparameter optimization for each technique. As a result, the RMSE of the adaptive control algorithm of the Sliding Window technique was calculated as 0.04°C, and the prediction accuracy was the highest. In addition, RMSE improved

about 99% compared to non-adaptive control algorithm. Therefore, it was selected as the final control algorithm model as it showed the best control accuracy.

To verify the adaptability and scalability of the selected adaptive control algorithm to a new environment, control is performed by changing the containment size, the heating value of the IT server, and the set temperature. To verify the performance of the ANN controller, the prediction-control accuracy, stability, energy-saving, and adaptability were evaluated compared with the conventional ON-OFF and PID controllers. As a result, the ANN adaptive control algorithm showed high accuracy at RMSE 0.23°C and 0.24°C , respectively, in both the changed two control scenarios in the new environment, and it was the lowest in terms of maximum error temperature and cooling energy consumption, resulting in stability and energy savings also showed the best performance. That is, the adaptability and scalability of the ANN-based adaptive control algorithm to the new environment have been verified reasonably.

Therefore, it was confirmed that the control algorithm developed in this study can be applied to various data centers and cooling systems based on chilled water mass flow control. In addition, the developed technology is expected to provide key functions of implementing a green data center by helping to reduce cooling energy and CO_2 emissions with allowing of efficient cooling system operation to the data center.

Keyword : Data Center, Building Energy, Artificial Neural Network, Chilled Water Mass Flow Control, Adaptive Control Algorithm