

인공신경망 기반 공조시스템 운전 예측모델 개발

Development of Predictive Model for Air-conditioning System Operation Based on Artificial Neural Network

강인성(In Sung Kang), 양영권(Young Kwon Yang), 이효은(Hyo Eun Lee), 박진철(Jin Chul Park)[†]
중앙대학교

Chung-Ang University, 84 Heuksuk-ro, Dongjak-gu, Seoul, Korea

Abstract This study aimed at developing an artificial neural network model predicting the cooling energy consumption and heating energy cost for the different settings of HVAC system's control variables. Matrix laboratory (MATLAB) was used for the ANN model development and test performance. For data training and performance evaluation, real data sets organized by the hour were collected by the office building. Four steps were conducted in the development process: initial model development, input variable selection, model optimization, and performance evaluation. The optimized models were set to have NHL(=2), NHN(=15), LR(=0.3), MO(=0.3) in summer, NHL(=1), NHN(=15), LR(=0.5), MO(=0.4) in winter. The optimized model demonstrated its prediction accuracy within the recommended level showing CVRMSE value of 11.28% in summer and 4.87% in winter.

Key words Artificial Intelligence(인공지능), Artificial Neural Network(인공신경망), Air-conditioning system (공조시스템), Predictive model(예측모델)

[†] Corresponding author, E-mail: jincpark@cau.ac.kr

1. 연구배경 및 목적

전 세계적으로 ICT(Information and Communications Technologies) 산업의 발달과 더불어 인공지능(AI, Artificial Intelligence)에 대한 관심이 급격하게 증가하고 있다. “인공지능”이라는 용어는 1956년 미국의 Dartmouth 대학에서 열린 학술발표에서 John McCarthy 외 3인에 의하여 처음 제안되었으며, 컴퓨터 프로그램을 통해 인간의 지능이 구현될 수 있는 인공지능은 과학적 혹은 공학적 수단으로 적용되어 왔다.⁽¹⁾ 인공지능 이론은 대표적으로 인공신경망(artificial neural network), 딥러닝(deep learning), 퍼지 이론(fuzzy logic), 적응뉴로퍼지(adaptive neuro-fuzzy inference system), 유전자 알고리즘(genetic algorithm) 등이 있다.⁽²⁾

건축분야에서의 인공지능은 건축 디자인 과정에서 새로운 설계방법론을 제시하거나 구조물의 손상위치를 파악, 콘크리트의 강도를 추정하는 등 여러 건축 분야에서 다양한 접근과 활용이 이루어지고 있다. Kang et al.⁽³⁾은 인공지능의 적용은 환경·설비 분야에서 가장 활발하게 연구되고 있으며, 주로 건물 에너지 최적화 및 공조 시스템 제어에 활용되어 쾌적한 건물 환경 조성을 위한 기술로 사용되는 것으로 분석되었다. 이는 기존의 건물 환경제어보다 진보된 제어방법이며, 특히 건물 부하 및 온열 환경 예측을 바탕으로 공조시스템의 최적 운전하는 관점에서 매우 효과적인 방법이다.

본 연구에서는 자가학습과정(a self-tuning process)을 통한 결과물을 예측하는 인공신경망을 활용하여 건물의 공조시스템 부하 예측 모델을 개발하고, 이를 통하여 보다 에너지 효율적이고 정확한 알고리즘 개발을 위한 기초자료 제공을 목적으로 한다.

2. 연구방법

본 연구에서는 첫 번째로 오피스 건물의 냉·난방 에너지소비량을 측정하고 시간별 부하 패턴을 분석하여 인공신경망 기반 에너지수요 예측 모델을 제시하였다. 예측 모델은 수치 해석 및 프로그래밍 소프트웨어인 MATLAB(Matrix Laboratory)을 통해 개발하였으며, 대상 건물 내 건물통합관리시스템(BMS, Building Management System)를 통해 여름철(7월~9월)과 겨울철(12월~2월)의 냉·난방 에너지소비량, 기상데이터, 냉각탑 및 보일러 설정값 등을 수집하였다. 이후 출력값과의 상관관계분석을 통해 입력변수를 선정하여 학습을 실시하였으며 예측된 에너지사용량과 실제 건물의 에너지사용량을 비교하여 최적화된 모델을 개발하였다.

3. 공조시스템 운전 예측모델 개발

3.1 대상 건물의 공조시스템 데이터

인공신경망 기반 냉·난방 에너지 수요예측 모델을 개발하기 위한 기초 자료로써 대상 건물에서 2016년에 가동된 공조 시스템의 설정값, 운전조건, 외기조건 등을 측정하였다. 아래 Fig. 1과 Fig. 2는 여름철과 겨울철로 나뉜 건물관리시스템에서 수집한 공조기의 설정값 및 측정값, 기상 데이터, 에너지 사용량을 통합하여 시간별로 정리한 예시이다.

		INPUT									OUTPUT					
SET	일시	실외온도	실외습도	실내온도	냉방부하 (Kwh/h)	일사량 (W/m2)	설정값, 냉매중합온도	설정값, 급기온도	설정값, 냉각수온도	설정값, 물단차압	실외기	팬	냉각탑	펌프	TOTAL (Kwh)	
1	2016-07-16 0:00 Sat	-	-	-	-	-	5.0	18.0	30.0	1.0	42	32	18	9	101	
2	2016-07-16 1:00 Sat	25.4	87.8	23.9	398.2	0.8	5.0	18.0	30.0	1.0	11	8	0	7	26	
3	2016-07-16 2:00 Sat	24.7	88.3	26.4	87.8	0.5	5.0	18.0	30.0	1.0	10	9	5	6	30	
4	2016-07-16 3:00 Sat	23.7	87.0	27.3	189.8	1.6	5.0	18.0	30.0	1.0	9	9	7	7	32	
5	2016-07-16 4:00 Sat	22.8	91.5	27.6	208.7	1.4	5.0	18.0	30.0	1.0	11	10	0	7	28	
6	2016-07-16 5:00 Sat	22.2	94.6	27.6	127.0	1.2	5.0	18.0	30.0	1.0	76	50	17	11	154	
7	2016-07-16 6:00 Sat	21.9	96.3	23.7	619.4	1	5.0	18.0	30.0	1.0	61	46	15	10	132	
8	2016-07-16 7:00 Sat	21.6	97.9	23.1	527.0	0.4	5.0	18.0	30.0	1.0	61	47	16	9	133	
9	2016-07-16 8:00 Sat	21.6	98.6	23.0	550.7	0.3	5.0	18.0	35.0	0.8	71	47	0	7	125	
10	2016-07-16 9:00 Sat	21.7	98.8	22.9	226.5	0.2	5.0	18.0	35.0	0.8	76	47	3	6	132	
11	2016-07-16 10:00 Sat	21.8	98.7	22.9	368.5	0.6	5.0	18.0	35.0	0.8	70	49	3	6	128	
12	2016-07-16 11:00 Sat	21.8	99.4	22.9	367.5	3.9	5.0	18.0	35.0	0.8	75	46	9	6	136	
13	2016-07-16 12:00 Sat	21.9	99.8	22.8	397.8	66.4	5.0	18.0	35.0	0.8	70	51	7	6	134	
14	2016-07-16 13:00 Sat	22.2	100.0	22.8	379.4	229.4	11.0	18.0	35.0	0.8	64	46	12	6	128	
15	2016-07-16 14:00 Sat	22.5	99.7	22.8	444.0	420.6	11.0	18.0	35.0	0.8	69	45	15	6	135	
16	2016-07-16 15:00 Sat	22.9	97.6	22.8	529.8	534.1	11.0	14.0	30.0	0.8	53	45	25	5	128	
17	2016-07-16 16:00 Sat	23.2	96.5	22.8	479.2	628.7	11.0	14.0	30.0	0.8	50	51	16	6	123	
18	2016-07-16 17:00 Sat	23.2	95.9	22.9	396.4	695.1	11.0	14.0	30.0	0.8	53	48	23	6	130	
19	2016-07-16 18:00 Sat	23.2	96.1	22.8	458.1	804.6	11.0	14.0	30.0	0.8	47	43	17	6	113	
20	2016-07-16 19:00 Sat	23.3	96.7	22.8	410.9	525.1	11.0	14.0	30.0	0.8	33	33	13	5	84	
21	2016-07-16 20:00 Sat	23.3	97.2	23.1	340.1	569.2	11.0	14.0	30.0	0.8	10	9	0	5	24	
22	2016-07-16 21:00 Sat	23.3	98.0	25.6	34.6	254	11.0	14.0	30.0	0.8	12	8	0	4	24	
23	2016-07-16 22:00 Sat	23.5	97.9	26.8	14.8	295.5	11.0	14.0	30.0	0.8	10	9	0	4	23	
24	2016-07-16 23:00 Sat	23.6	96.9	27.0	16.5	226.8	11.0	14.0	30.0	0.8	8	8	0	4	20	

Fig. 1 Data sets collected by HVAC system(summer)

		INPUT											OUTPUT					
SET	일시	실외온도	실외습도	실내온도	난방부하 (kWh)	온수공급온도	급기온도	온수유량 냉매중합온도	설정값, 급기온도	설정값, 냉각수온도	설정값, 물단차압	실외기	팬	냉각탑	펌프	TOTAL (kWh)		
1	2016-12-01 0:00 Thu	-	-	-	-	-	-	-	5.0	18.0	30.0	1.0	42	32	18	9	101	
2	2016-12-01 1:00 Thu	8.6	94.8	22.7	398.2	24.1	21.2	36.6	5.0	18.0	30.0	1.0	11	8	0	7	26	
3	2016-12-01 2:00 Thu	9.0	92.2	22.1	87.8	24.1	21.2	36.8	5.0	18.0	30.0	1.0	10	9	5	6	30	
4	2016-12-01 3:00 Thu	9.3	84.7	21.6	189.8	24.6	21.7	36.4	5.0	18.0	30.0	1.0	9	9	7	7	32	
5	2016-12-01 4:00 Thu	9.3	82.6	21.2	208.7	24.3	22.0	48.1	5.0	18.0	30.0	1.0	11	10	0	7	28	
6	2016-12-01 5:00 Thu	9.3	80.5	21.2	127.0	23.9	22.1	94.3	5.0	18.0	30.0	1.0	76	50	17	11	154	
7	2016-12-01 6:00 Thu	9.5	74.6	23.0	619.4	23.2	25.1	99.2	5.0	18.0	30.0	1.0	61	46	15	10	132	
8	2016-12-01 7:00 Thu	9.6	65.3	22.8	527.0	21.3	19.9	106.1	5.0	18.0	30.0	1.0	61	47	16	9	133	
9	2016-12-01 8:00 Thu	9.0	62.6	22.9	550.7	24.7	22.5	86.9	5.0	18.0	35.0	0.8	71	47	0	7	125	
10	2016-12-01 9:00 Thu	8.3	64.9	22.9	226.5	25.5	19.9	71.7	5.0	18.0	35.0	0.8	76	47	3	6	132	
11	2016-12-01 10:00 Thu	7.6	59.1	21.0	368.5	24.4	20.4	87.7	5.0	18.0	35.0	0.8	70	49	3	6	128	
12	2016-12-01 11:00 Thu	8.5	62.6	22.9	367.5	22.4	20.4	86.7	5.0	18.0	35.0	0.8	75	46	9	6	136	
13	2016-12-01 12:00 Thu	8.1	57.6	23.0	397.8	16.5	19.4	93.7	5.0	18.0	35.0	0.8	70	51	7	6	134	
14	2016-12-01 13:00 Thu	7.9	39.7	23.0	379.4	27.4	20.7	79.9	11.0	18.0	35.0	0.8	64	46	12	6	128	
15	2016-12-01 14:00 Thu	7.8	34.7	23.0	444.0	26.0	19.4	75.9	11.0	18.0	35.0	0.8	69	45	15	6	135	
16	2016-12-01 15:00 Thu	7.6	31.9	23.0	529.8	24.2	19.9	71.1	11.0	14.0	30.0	0.8	53	45	25	5	128	
17	2016-12-01 16:00 Thu	7.5	36.0	23.1	479.2	22.1	18.9	75.5	11.0	14.0	30.0	0.8	50	51	16	6	123	
18	2016-12-01 17:00 Thu	7.8	38.7	23.2	396.4	19.5	19.2	75.1	11.0	14.0	30.0	0.8	53	48	23	6	130	
19	2016-12-01 18:00 Thu	7.9	41.3	23.2	458.1	25.9	19.7	72.0	11.0	14.0	30.0	0.8	47	43	17	6	113	
20	2016-12-01 19:00 Thu	7.2	46.7	23.0	410.9	25.6	18.9	79.7	11.0	14.0	30.0	0.8	33	33	13	5	84	
21	2016-12-01 20:00 Thu	6.3	43.7	22.9	340.1	24.3	19.3	85.3	11.0	14.0	30.0	0.8	10	9	0	5	24	
22	2016-12-01 21:00 Thu	5.2	39.4	22.9	34.6	22.5	19.7	86.3	11.0	14.0	30.0	0.8	12	8	0	4	24	
23	2016-12-01 22:00 Thu	4.1	40.6	22.9	14.8	16.8	20.2	93.1	11.0	14.0	30.0	0.8	10	9	0	4	23	
24	2016-12-01 23:00 Thu	3.5	42.1	22.8	16.5	26.8	19.2	109.1	11.0	14.0	30.0	0.8	8	8	0	4	20	

Fig. 2 Data sets collected by HVAC system(winter)

3.2 예측모델 개발

3.2.1 예측모델의 최적화

공조시스템의 운전 예측모델은 MATLAB을 통해 인공신경망 모델을 개발하였다. 대상 건물의 BMS에서 수집한 데이터의 예측 및 학습 성능을 향상시키기 위해 선처리 과정으로 데이터 필터링을 실시하였으며, 주말을 제외한 평일 중 근무 시간만 고려하여 시간별 부하 패턴을 분석하였다. 또한 입·출력 변수의 상관관계 분석을 통하여 입력 변수를 선정하였으며, 여름철의 입력 뉴런 8개, 겨울철의 입력 뉴런 10개를 적용하였다. 학습 데이터(Training data sets)와 검증 데이터(Checking data sets)는 각각 185개(여름철), 150개(겨울철)로 학습과 검증을 실시하였다.

가장 정확하게 예측하는 인공신경망 모델을 찾는 최적화(Optimization) 과정을 통해 최종 모델이 개발되었으며, 이때, 가장 적합한 NHL(Number of hidden layers), NHN(Number of hidden neurons), LR(Learning Rate), MO(Moments)를 선정하였다. 아래 Fig. 3과 Fig. 4는 각각 여름철과 겨울철의 최적화된 공조시스템 운전 예측 모델을 나타내고 있으며, 여름철에는 대상 건물의 공조시스템 전력사용량, 겨울철에는 대상 건물의 에너지 비용(전력 환산 비용+가스 환산 비용)을 예측하였다.

3.2.2 예측모델의 성능평가

최적화된 인공신경망 모델의 예측성능을 평가하기 위하여 대상 건물에서 실제 사용된 에너지소비량 및 에너지 비용과 예측된 값을 비교하였다. Fig. 5에서는 각각 여름철과 겨울철의 예측모델의 정확성을 상관관계(R2-Value)로 나타낸 결과는 0.8136, 0.8417, 예측모델의 CVRMSE 값은 각각 11.28%, 4.87%로 미국 냉동공조 학회(ASHRAE)⁽⁴⁾에서 기준으로 지정한 30%이내를 충분히 만족시킨 것으로 나타났다.

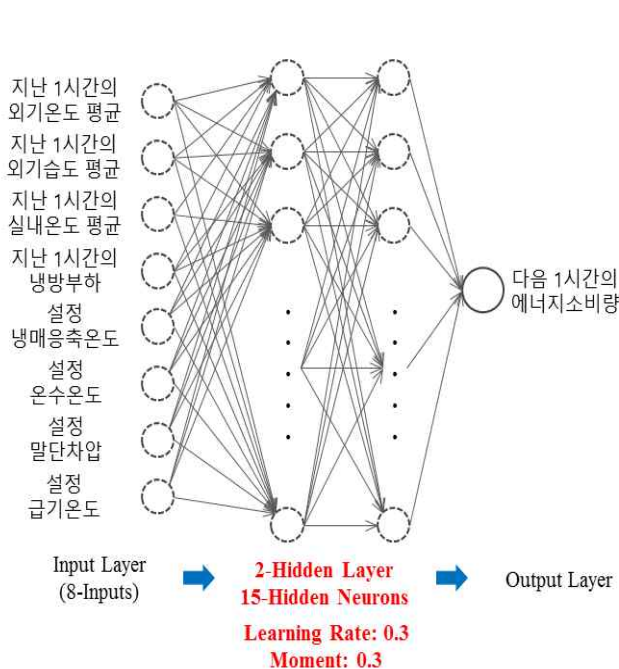


Fig. 3 ANN model for energy consumption prediction

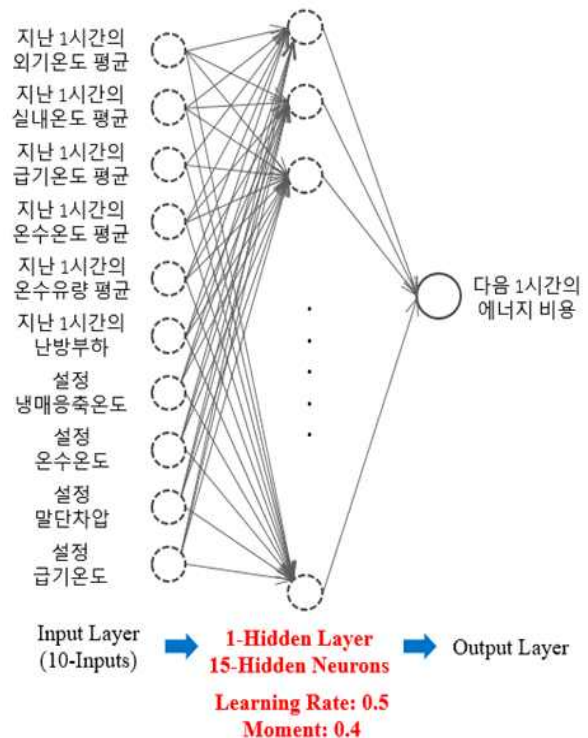


Fig. 4 ANN model for energy cost prediction

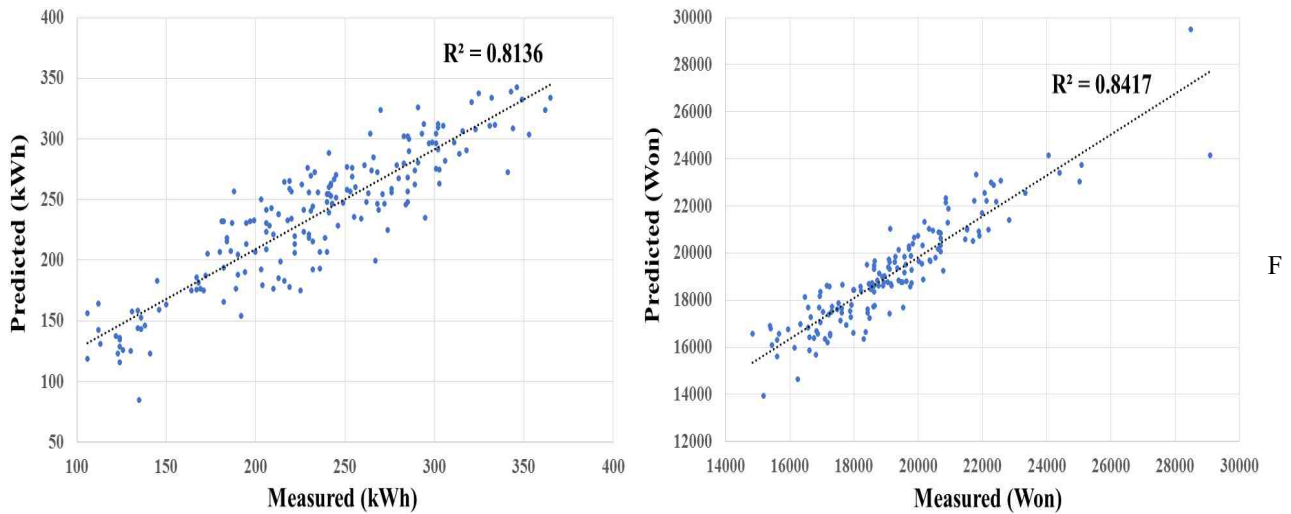


Fig. 5 Comparison of prediction and measurement(summer and winter)

4. 결 론

본 연구에서는 건물에서 사용된 2016년 실제 공조시스템 데이터를 수집하고, MATLAB에서 인공신경망을 활용하여 건물의 공조시스템 부하 예측 모델을 개발하였다. 이후, 예측값과 실측값을 비교하여 예측모델의 성능평가를 실시하였으며, 그 결과는 다음과 같다.

- (1) 대상 건물에서 사용되는 공조시스템의 에너지 예측모델은 최적화 과정을 통하여 가장 적합한 NHL, NHN, LR, MO를 도출하였으며, 여름철은 NHL(=2), NHN(=15), LR(=0.3), MO(=0.3), 겨울철은 NHL(=1), NHN(=15), LR(=0.5), MO(=0.4)로 나타났다.
- (2) 최적화된 인공신경망 모델의 예측성능을 평가하기 위하여 실제 사용된 에너지소비량 및 에너지 비용과 예측된 값을 비교한 결과, 여름철과 겨울철의 예측모델 CVRMSE 값은 각각 11.28%, 4.87%로 미국 냉동공조학회(ASHRAE)에서 기준으로 지정한 30%이내를 충분히 만족시킨 것으로 나타났다

References

1. 강인성, 문진우, 박진철, 2017, 최근 건축분야의 인공지능 기계학습 연구동향, 대한건축학회 논문집, Vol. 33, No. 4, pp. 63-68.
2. 문진우, 2015, 이중외피건물 실내 열 환경 제어를 위한 인공지능이론의 적용 비교 분석, 한국생활환경학회, 추계학술대회논문집, pp. 84-86.
3. 강인성, 정민희, 문진우, 박진철, 2016, 최근 건축물에서의 인공지능 분야 연구동향, 대한건축학회, 추계학술발표대회논문집, Vol. 36, No. 2, pp. 635-642.
4. U.S Department of Energy, 2015, M&V Guidelines: Measurement and Verification for Performance-Based Contracts Version 4.0, Energy Efficiency & Renewable Energy.