



건물 냉방시스템의 예측제어를 위한 인공신경망 모델 개발

Development of an Artificial Neural Network Model for a Predictive Control of Cooling Systems

강인성* · 양영권** · 이효은*** · 박진철**** · 문진우*****

Kang, In-Sung* · Yang, Young-Kwon** · Lee, Hyo-Eun*** · Park, Jin-Chul**** · Moon, Jin-Woo*****

* First author, School of Architectural and Building Science, Chung-Ang University, South Korea (ins kang57@gmail.com)

** Coauthor, School of Architectural and Building Science, Chung-Ang University, South Korea (dora84@naver.com)

*** Coauthor, School of Architectural and Building Science, Chung-Ang University, South Korea (bell3457@hanmail.net)

**** Coauthor, School of Architectural and Building Science, Chung-Ang University, South Korea (jincpark@cau.ac.kr)

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

ABSTRACT

Purpose: This study aimed at developing an Artificial Neural Network (ANN) model for predicting the amount of cooling energy consumption of the variable refrigerant flow (VRF) cooling system by the different set-points of the control variables, such as supply air temperature of air handling unit (AHU), condenser fluid temperature, condenser fluid pressure, and refrigerant evaporation temperature. Applying the predicted results for the different set-points, the control algorithm, which embedded the ANN model, will determine the most energy efficient control strategy. **Method:** The ANN model was developed and tested its prediction accuracy by using matrix laboratory (MATLAB) and its neural network toolbox. The field data sets were collected for the model training and performance evaluation. For completing the prediction model, three major steps were conducted - i) initial model development including input variable selection, ii) model optimization, and iii) performance evaluation. **Result:** Eight meaningful input variables were selected in the initial model development such as outdoor temperature, outdoor humidity, indoor temperature, cooling load of the previous cycle, supply air temperature of AHU, condenser fluid temperature, condenser fluid pressure, and refrigerant evaporation temperature. The initial model was optimized to have 2 hidden layers with 15 hidden neurons each, 0.3 learning rate, and 0.3 momentum. The optimized model proved its prediction accuracy with stable prediction results.

© 2017 KIEAE Journal

KEYWORD

예측제어
인공신경망
VRF 냉방시스템
최적제어변수

Predictive Control
Artificial Neural Network
VRF Cooling System
Optimal Control Variables

ACCEPTANCE INFO

Received Aug 9, 2017

Final revision received Aug 24, 2017

Accepted Aug 29, 2017

1. 서론

1.1. 연구의 배경 및 목적

2015년 파리에서 열린 COP (Conference of the Parties) 21을 통해 한국을 비롯한 세계 190여개의 국가가 신기후체제 (Paris Agreement)에 합의했다.¹⁾ 온실가스 저감을 위한 각 정부의 재정지원, 기술이전 등의 내용과 더불어 탄소 배출량 감축을 위한 건물부문 에너지소비 절감의 중요성을 강조하고 있다. 특히, 국내의 건물부문의 에너지소비량은 전체 에너지 소비량의 약 23%를 차지하며 평균 에너지소비량은 연간 약 7,829Gcal에 달한다.^{2,3)} 이 중 전력소비량이 5,082Gcal로 전체 에너지의 약 65%를 차지하고 있어 건물 내 전력소비량 절감은 신기후체제 목표달성에 있어 필수적이다.⁴⁾ 이에 산업통상 자원부는 효율적인 에너지절약 방안으로 '하절기 에너지절약 종합대책 및 에너지 기술개발 계획'을 시행하고 있으며, 국토교통부는 '제로에너지 활성화 정책' 등 냉방에너지 절감에 대한 국가적 차원의 정책 및 제도를 시행하고 있다.⁵⁾

최근 건물은 경제적 성장으로 인해 대형화·고층화 되고 있으며, 삶의 질이 향상됨에 따라 거주자의 쾌적한 온열환경에 대한 요구와 냉·난방기 사용 증대로 인하여 건물에너지 소비량은 점점 증가하는 추세이다.⁶⁾ 이에 따라 쾌적한 온열환경 조성 및 에너지절감을 위한 건물의 냉·난방시스템 운영전략으로 실별 개별제어가 가능하여 부분부하운전 효율이 우수한 VRF (Variable Refrigerant Flow) 시스템의 사용이 증가하고 있다.⁷⁾

그 중 수냉식 VRF 시스템은 실내로 연간 냉·난방 열량을 안정적으로 공급할 수 있어 중대형 건물에 적용하는데 있어 에너지절감의 관점에서 우수하다는 장점이 있다. 일반적으로 수냉식 VRF 시스템은 Fig. 1과 같이 하나의 수냉식 실외기에 다수의 실내기가 연결된 멀티히트펌프 방식으로 변화하는 외기 상태나 부하의 변동에 따라 시스템 변수인 냉매유량, 급기 설정온도, 말단차압 등 독립적인 제어나 운영이 요구되는 실에 대하여 개별적으로 제어할 수 있다.⁸⁾

하지만 현재 대부분의 건물에서 VRF 시스템을 통한 기존 제어방법은 전문가의 경험에 의한 제어변수(setpoints)로 운영된다는 한계점을 보이고 있다. 따라서 에너지를 최소한으로 사용하며 실내의 쾌적 온열환경을 만족시키는 VRF 시스템의 최적 운영방안이 필요하다.

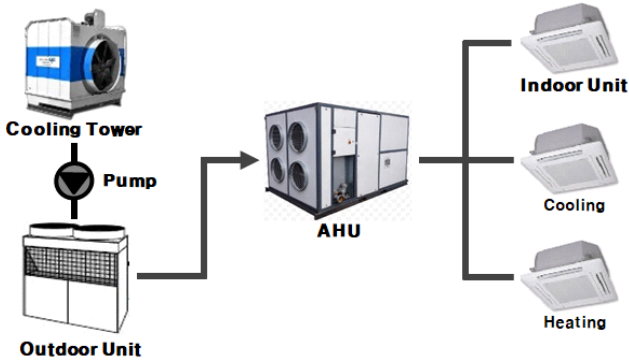


Fig. 1. Distribution diagram of VRF system

본 연구의 목표는 인공신경망(ANN, Artificial Neural Network)을 활용하여 VRF 시스템의 에너지 성능 향상을 위한 최적 제어 알고리즘 개발의 선행연구 단계로써, VRF 시스템의 냉방에너지 사용량을 예측하는 ANN 모델을 개발하는 것이다.

특히, 인공신경망은 자가학습(self-tuning process) 과정과 예측 제어로 결과 값이 도출되어, VRF 시스템의 다양한 제어변수의 조합에 따른 에너지사용량의 비교·분석이 가능하다. 또한 최종적으로 인공신경망을 활용한 VRF 시스템의 최적 제어변수 설정값 도출과 최적운전 알고리즘 개발을 통해 기존 건물제어의 문제점을 개선할 수 있다.

1.2. 연구의 방법 및 범위

연구의 전체 흐름은 아래 Fig. 2와 같다. 우선 VRF 시스템의 에너지사용량을 예측하는 초기 예측모델에 대한 최적화 과정이 실시되었으며, 예측성능 평가를 통해 최종 예측모델이 개발되었다. 이후 운전 알고리즘을 개발하여 최적의 시스템 제어변수 설정값을 도출하고, 최종적으로 시뮬레이션 및 실제 건물에 적용하여 에너지절감량이 확인되었다.

본 연구의 범위는 선행 연구로써 에너지사용량 예측모델 개발 및 예측성능 평가가 실시되었으며, 주요 과정은 크게 3가지로 i)초기모델 개발, ii)모델 최적화, iii)성능평가가 진행되었다.

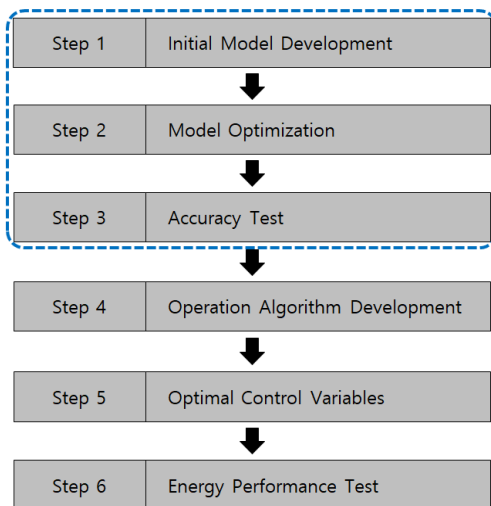


Fig. 2. Methodology and range of the study

먼저 초기모델은 MATLAB (Matrix Laboratory) 및 NN (Neural Network) toolbox를 이용하여 개발되었다. 이후 대상 건물의 VRF 시스템 관련 과거 운전 현황 및 설정값, 기상 데이터, 에너지사용량 등을 수집하여 예측모델에 적용되었다.

다음으로 예측모델의 최적화 과정에서는 ANN 모델의 가장 뛰어난 예측성능을 갖는 은닉층의 구조변수(은닉층 수, 각 은닉층의 뉴런수)와 학습변수(학습률, 모멘텀, 학습 횟수, 임계값, 목표 등)가 도출되었다.⁹⁾

마지막으로 개발된 ANN 모델의 예측성능과 신뢰성을 파악하기 위하여 ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers) Guideline14에서 제시한 실측값과 예측값의 상관관계 기준($R^2 > 0.8$)과 평균제곱근 오차의 변동계수($Cv(RMSE) < 30\%$)를 이용하여 ANN 모델의 예측정확도가 평가되었다.¹⁰⁾

2. 인공신경망의 개요 및 연구사례

2.1. 인공신경망

ANN은 1943년 Warren McCulloch와 Walter Pitts에 의해 제안되었으며, 인간의 신경체계를 모방한 알고리즘을 통해 데이터를 학습하고 미래를 예측할 수 있다는 장점이 있다.¹¹⁾ ANN의 대표적인 모델은 다층신경망(multi layer neural network)으로 아래 Fig. 3과 같이 입력층(input layer), 하나 또는 그 이상의 은닉층(hidden layer), 출력층(output layer)과 각 층에는 다수의 뉴런으로 구성된다.^{12,13)}

기본적으로 전방향(feed-forward propagation) 전파로 입력신호는 입력층, 은닉층, 출력층 순으로 전달된다. 각 층을 구성하는 뉴런들은 외부로부터 입력값을 받으면 연결강도 (weight)가 곱한 값의 합으로 계산된 이후 최종적으로 전이함수 (transfer function)에 의해 출력값이 도출된다.¹⁴⁾ 대표적인 활성화 함수는 계단함수(step function), 시그모이드 함수(sigmoid function), 선형함수(linear function)가 있으며, Fig. 4에서는 전이함수의 그래프와 수식이 나타나고 있다.

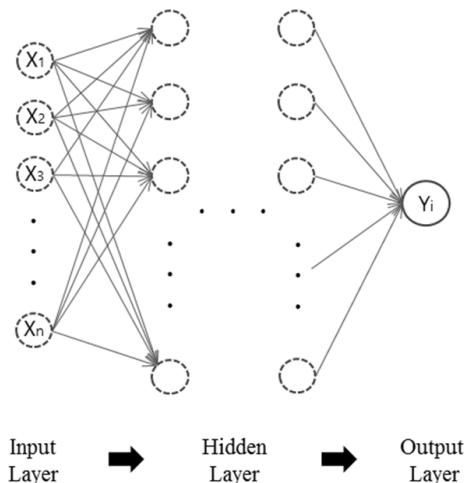


Fig. 3. Structure of multi layer neural network

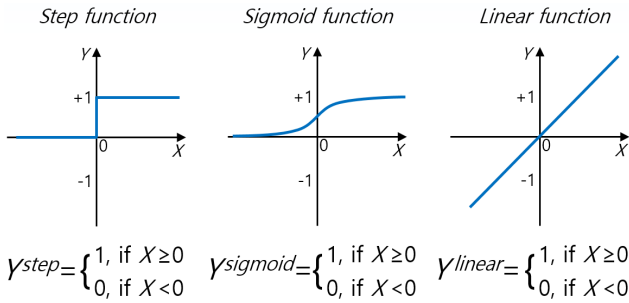


Fig. 4. Transfer functions of ANN

이후 ANN은 주어진 입력값이 원하는 출력값에 도달하기 위해 아래 Fig. 5와 같이 역전파(back-propagation) 과정을 수행한다. 출력값과 목표값의 오차에 따라 역방향으로 전파하여 각 층의 연결강도를 조정하며, 이때 연결강도에 대한 학습 규칙을 수학적으로 경사하강법(gradient descent method)을 이용하여 오차가 최소화되도록 수정한다. 이후 이와 같은 반복 과정을 통하여 허용범위 안에 목표 오차율이 들어오면 학습이 완료된다.^{15,16)}

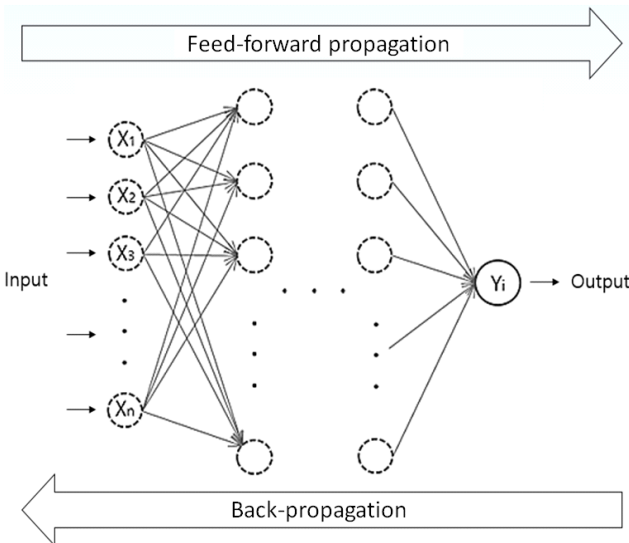


Fig. 5. Principle of back-propagation process

2.2. 선행연구 고찰

ANN을 활용하여 건물 및 시스템의 에너지사용량을 예측한 선행 연구를 분석하였으며 본 연구에 필요한 이론적 요소와 활용방안이 도출되었다.

권한솔¹⁷⁾은 대형 복합건물의 실측 데이터와 기상자료를 기반으로 냉방에너지 사용량을 분석하였고, ANN을 활용한 예측모델과 냉동기 최적 운영방안을 제시하였다. 기상데이터는 기상청에서 제공하는 데이터를 기반으로 외기온도, 상대습도, 일사량, 운량, 풍속, 강우량 등을 다양한 항목을 입력되었으며, 불쾌지수를 계산하여 기상 변수에 따른 분석이 실시되었다.

한도영¹⁸⁾은 기상정보를 통해 외기온도 분포를 예측하였고, 공조 시스템의 최적기동/정지와 예냉운전이 가능한 알고리즘이 개발되었으며 시뮬레이션을 통해 건물에너지가 예측되었다.

이재현¹⁹⁾은 수냉식 VRF 시스템의 설정값 제어 알고리즘을 개발하여 효과를 검증하였다. 이때, 사전에 실시한 칼로리미터 실험 데이터를 기반으로 시스템의 최적 설정값을 도출하였으며, 연구 결과 시스템 COP가 14.2% 향상되었고 에너지 비용이 32.6% 절감되었다.

Chirag Deb²⁰⁾은 ANN을 활용하여 3가지 건물에 대한 냉방에너지 사용량을 예측하였으며 요일별 · 단계별로 대상 건물의 에너지 사용량을 분석하여 예측성능이 가장 높은 모델 ($r^2=0.9852$)이 도출되었다.

Radu Platon²¹⁾은 ANN과 사례기반 추론방법을 활용한 기관 건물의 시간당 냉방에너지 사용량 예측모델을 개발하여, ANN과 사례기반 추론방법의 예측성능이 비교되었다. 입력변수는 외기온도, 외기습도, 보일러온수 토출온도, 온수유량, 냉동기 냉매 토출온도, 냉매유량, 급기온도, 실내온도, 공조시스템 설정값을 포함되었다.

Pedro A. Gonzalez²²⁾은 ANN을 활용하여 시간별 단기 건물에너지를 예측하는 모델이 개발되었으며, 예측성능은 실제 건물에너지와 예측값을 비교하여 평가되었다.

선행연구를 종합적으로 분석한 결과 인공지능경망을 활용하여 건물의 에너지사용량을 예측하거나 일반적인 공조시스템의 운전 알고리즘이 개발되었다. 하지만 인공지능경망을 활용한 VRF 시스템에 관한 에너지사용량 예측 및 운전 알고리즘 연구가 활발하게 진행되지 않은 것으로 나타났다. 따라서 본 연구와 같이 인공지능경망 기반 VRF 시스템의 냉방에너지 예측모델을 개발하고 예측결과를 실측 데이터와 비교하여 예측모델의 예측성능을 확인하는 연구가 필요하다고 사료된다.

3. 인공지능망 예측모델 개발

3.1. 초기모델 개발

ANN을 통한 VRF 시스템의 냉방에너지 예측모델은 수학적 해석프로그램인 MATLAB 및 NN toolbox를 통해 개발되었고, 1시간 전의 데이터와 시스템 설정값에 따른 1시간 이후의 냉방에너지를 예측하는 사이클로 계획되었다.

초기모델은 ANN 모델의 기본적인 구조(입력층, 은닉층, 출력층)의 뉴런을 선정하고, 적절한 전이함수, 학습함수, 매개변수를 선정하는 과정으로 개발되었다. ANN 모델에서 학습을 위한 데이터 세트는 200개가 사용되었으며, 새로운 데이터를 계속 업데이트하기 위해 가장 처음에 학습된 데이터 세트를 지우는 방법인 Sliding-window 방법이 사용되었다.

(1) 입력변수 선정

우선 입력층 뉴런으로 VRF 시스템의 냉방 에너지 사용량에 영향을 미치는 변수들이 선정되었고, 크게 주변 환경조건에 관련된 변수와 VRF 시스템의 제어변수 설정값으로 분류되었다.

주변 환경조건에 관련된 변수는 실외온도(TEMP_{OUT}), 실외습도(HUMID_{OUT}), 실내온도(TEMP_{IN}), 일사량(SOLAR), 냉동부하(LOAD_{COOL})로 선정되었으며, 이 항목은 시스템변수로 설정되지

Table 3. Prediction accuracy by four cases

Input variables	Case 1	Case 2	Case 3	Case 4
HUMID _{OUT}	O	X	X	O
SOLAR	O	O	X	X
TEMP _{OUT}	O	O	O	O
TEMP _{IN}	O	O	O	O
LOAD _{COOL}	O	O	O	O
TEMP _{SA}	O	O	O	O
TEMP _{COND}	O	O	O	O
PRES _{COND}	O	O	O	O
TEMP _{EVAP}	O	O	O	O
Cv(RMSE)[%]	21.35	21.84	15.93	15.49

마지막으로 최적 입력변수를 선정하기 위해 입력변수들의 조합에 따라 Cv(RMSE)값을 척도로 예측정확도가 분석되었다. Table 3과 같이 VRF 시스템 냉방에너지의 주요인자인 시스템 제어변수(급기 설정온도, 말단차압, 냉각수 설정온도, 냉매증발 설정온도)는 입력변수로 선정되었고, r²값이 가장 낮은 실외습도와 일사량을 제거 항목으로 고려한 4가지 경우를 분석하였다. 분석 결과 Cv(RMSE)가 가장 낮은 일사량을 제외한 입력변수 조합인 Case 4가 선정되었다.

(2) 초기모델 설계

최적의 입력변수가 선정된 이후 초기모델 개발을 위하여 은닉층의 구조와 적절한 전이함수, 학습함수, 매개변수가 선정되었다. ANN 모델은 가장 대표적인 전방향 오류 역전파 신경망이 사용되었다.

선행연구^{25,26)}를 바탕으로 초기모델의 은닉층 수(NHL, number of hidden layers)와 각 은닉층의 뉴런수 (NHN, number of hidden neurons)는 각각 1과 17로 설정되었다. 또한 매개변수인 초기 학습률(LR, learning rate) 및 모멘텀(MO, momentum)을 0.6과 0.2로 설정되었다.

전이함수는 시그모이드 함수로 은닉층에서 신호 처리과정에 사용되었으며, 출력층의 결과값 산출에 선형함수가 사용되었다. 또한 최적화에 따라 연결가중치 및 bias값을 업데이트하는 학습함수인 LM (Levenberg Marquardt) 알고리즘이 사용되었다.²⁷⁾ 아래 Fig. 7은 초기모델의 구조를 나타내고 있다.

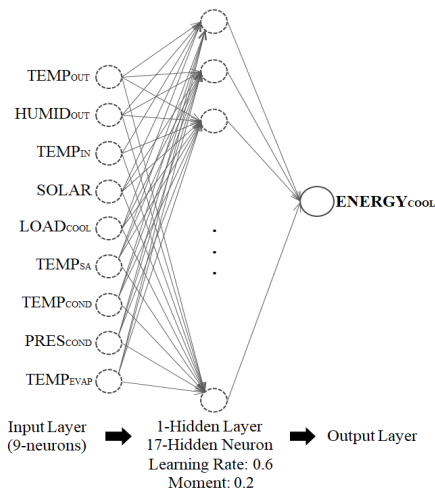


Fig. 7. Structure of initial ANN model

(3) 대상 건물 선정

예측모델을 실제 건물에 적용하기 위하여 VRF 시스템을 운영 중인 대상 건물이 고려되었다. 서울시 서초구 우면동에 위치한 R&D 센터로 연구 및 개발활동을 주 목적으로 일정한 재실패턴을 보이는 오피스건물로 선정되었다. 대상 건물은 Fig. 8과 같이 지하층, 기준층, 옥상으로 구성되어 있으며, 재실자가 주로 활동하는 기준층의 VRF 시스템에 대하여 분석되었다.

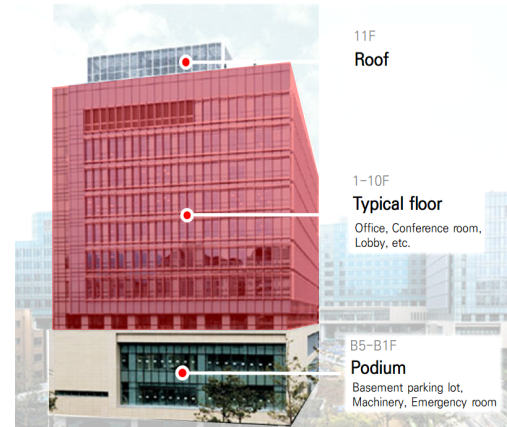


Fig. 8. Arrangement plan of R&D center

3.2. 모델 최적화

ANN 모델의 최적화란 예측성능을 최적으로 향상시키기 위해 가장 적합한 구조변수인 NHL, NHN, 매개변수인 LR, MO, epochs, goal 등을 도출하는 과정이다. 아래 Table 4에서는 ANN 모델의 구조변수와 학습변수의 일반적인 범위 및 설정값과 특징에 대하여 설명되었다.

앞서 개발한 ANN 초기모델을 기반으로 검증데이터(checking data) 185세트를 이용하여 최적화 과정이 진행되었으며, 실제 냉방에너지 사용량과 예측된 결과값의 예측정확도 분석을 통해 진행되었다. 이때, 최적의 NHL과 NHN을 도출한 이후 최적의 LR과 MO가 도출되었다. Table 5와 같이 변수 값이 순차적으로 변화되며 예측정확도가 분석되었으며, 가장 낮은 Cv(RMSE) 값을 보이는 구조변수 및 매개변수가 도출되었다.

Table 4. Parameters of ANN model

Division	Range	Contents
NHL	1~n	Accuracy performance become improved As NHL/NHN higher, but it takes longer time
NHN	1~n	Accuracy performance become improved As LR lower, but it takes longer time
LR	0.1≤n≤1.0	As MO higher, learning process faster
MO	0.1≤n≤1.0	Maximum number of learning iteration
Epochs	1000	Target accuracy of estimation
Goal	0.01	

Table 5. Values for parameters of the optimization

Division	Range
NHL	1, 2, 3, 4, 5
NHN	10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20
LR	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0
MO	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0

3.3. 예측성능 평가

ANN 모델의 예측성능 및 신뢰도를 분석하기 위하여 실제 냉방에너지 사용량과 예측된 결과값이 비교되었다. 이때, ASHRAE에서는 실측데이터와 시뮬레이션 결과값을 비교하고 평가하는 통계적 기준을 제시하고 있으며, ANN 모델의 예측성능은 r^2 값과 Cv(RMSE)로 평가되었다.

상관관계를 나타내는 r^2 는 데이터의 출력변수 변동에 대한 입력 변수들의 설명력 크기를 나타내는 척도이며, ASHRAE 기준 0.8이상일 때 상관관계가 적합하다고 판단되었다.

Cv(RMSE)는 평균제곱근 오차(RMSE, root mean square error)의 변동계수(Cv, coefficient of variation)이며, 실제값과 예측값의 차이를 파악하는 척도로 사용되었다. 일반적으로 Cv(RMSE)는 0%에 가까울수록 예측이 정확하다는 것을 의미하고 ASHRAE에서는 30%를 적정기준으로 제시하였다. 다음은 Cv(RMSE)의 계산과정이 나타나고 있다.

$$Cv(RMSE) = \frac{RMSE}{A} \times 100 \quad \text{Equation (1)}$$

$$RMSE = \sqrt{\sum \frac{(S-M)^2}{N}} \quad \text{Equation (1.1)}$$

4. 결과 분석

4.1. 최적화 결과

Table 6. Cv(RMSE) by structural parameters

NHL \ NHN	1	2	3	4	5
10	14.9	14.1	18.2	15.3	24.6
11	16.8	13.7	14.4	14.1	17.7
12	13.2	17.6	14.6	13.5	24.4
13	13.1	14.2	12.5	15.4	20.0
14	14.4	14.3	13.9	15.6	13.1
15	12.7	12.3	12.8	18.9	13.1
16	21.6	15.1	14.5	12.6	13.8
17	15.6	14.4	16.2	12.7	14.0
18	13.2	13.4	13.6	15.8	13.0
19	16.2	13.9	16.0	13.7	13.7
20	14.2	13.9	14.6	14.4	14.3

Table 7. Cv(RMSE) by learning parameters

LR \ MO	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
0.1	15.9	17.6	16.4	14.2	13.8	16.0	15.3	12.9	12.3	12.3
0.2	12.8	14.4	15.6	12.3	15.2	12.3	12.9	13.4	12.9	13.3
0.3	15.8	14.0	11.3	14.2	12.8	13.7	18.3	15.9	14.5	15.1
0.4	12.9	13.6	15.1	14.8	16.3	13.0	14.4	14.2	17.0	15.4
0.5	13.3	12.6	12.9	13.8	13.1	17.0	16.6	12.0	17.4	12.2
0.6	13.9	12.5	11.7	13.6	13.1	15.1	15.4	13.0	15.2	13.4
0.7	13.1	11.7	14.8	15.4	14.3	13.0	12.9	13.3	14.9	13.7
0.8	12.9	14.6	13.7	15.6	13.3	12.6	13.2	13.1	15.3	15.0
0.9	16.1	15.5	14.1	15.4	13.9	14.4	14.0	13.5	13.0	13.3
1.0	13.7	13.5	12.0	12.7	13.1	11.4	16.3	15.3	12.3	14.3

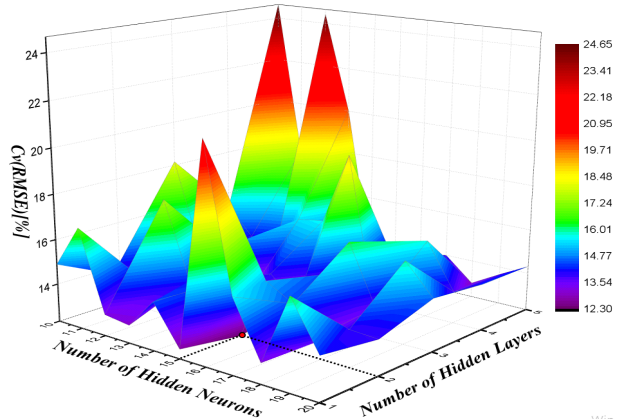


Fig. 9. Optimization diagram by structural parameters

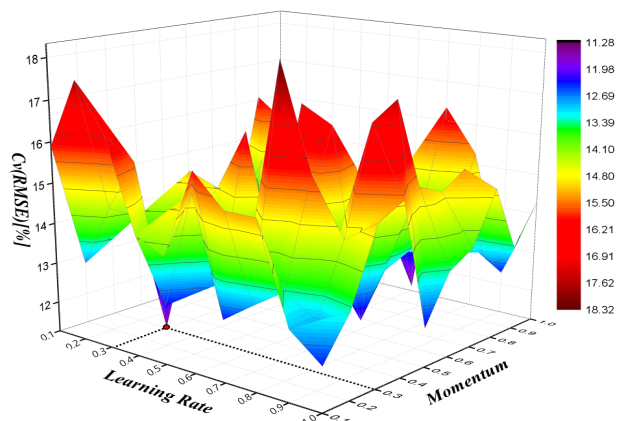


Fig. 10. Optimization diagram by learning parameters

Table 6은 최적의 은닉층 구조변수인 NHL 및 NHN에 따른 Cv(RMSE)값, Table 7은 최적의 매개변수인 LR 및 MO에 따른 Cv(RMSE)값이 나타나고 있다. 또한 Fig. 9과 Fig. 10에서는 각각의 최적 구조변수 및 매개변수가 도출되는 과정이 나타나고 있다. 따라서 최적화 과정 결과, 초기 예측모델은 Fig. 11과 같이 NHL 2개, NHN 15개, LR 0.3, MO 0.3을 갖는 구조로 개발되었다.

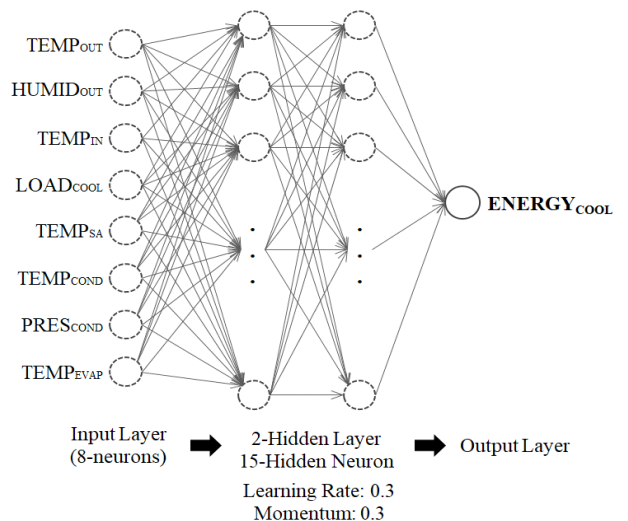


Fig. 11. Structure of optimized ANN model

4.2. 예측성능 평가결과

아래 Fig. 12에서는 최종적인 ANN 모델을 통해 예측된 VRF 시스템의 냉방에너지 사용량과 실측값이 비슷한 추이로 확인되었다. 또한 Cv(RMSE)값은 앞서 최적화 결과를 통해 11.3%로 30%보다 낮으며, R²값은 Fig. 13과 같이 0.8136으로 0.8보다 높게 나타나 ASHRAE Guideline 14의 기준을 충분히 만족하는 것으로 확인되었다.

따라서 본 연구의 결과를 바탕으로 개발된 인공지능경망 기반 예측 모델은 VRF 시스템의 운전 제어알고리즘에 적용하는데 있어 적합하다고 판단되었다. 또한 추후 동절기 및 간절기의 에너지사용량 예측모델을 개발하여 VRF 시스템의 종합적인 에너지사용량을 분석하는 연구가 필요하다.

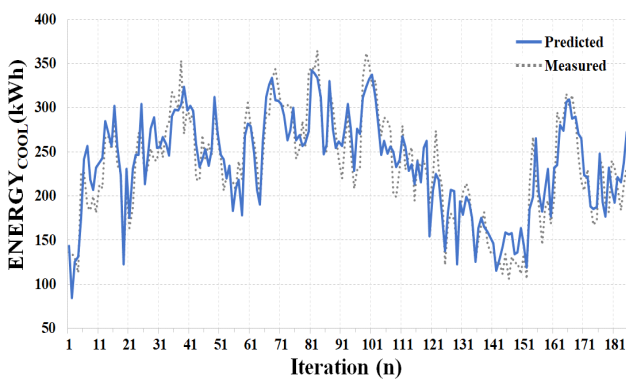


Fig. 12. Comparative analysis of cooling energy consumption

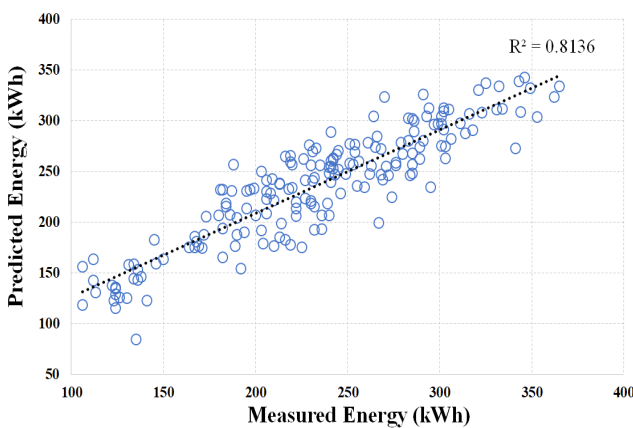


Fig. 13. Correlation between measured cooling energy and predicted cooling energy

5. 결론

본 연구는 VRF 시스템의 에너지성능 향상을 위한 최적제어 알고리즘 개발의 선행연구 단계로써, 인공지능경망을 활용하여 VRF 시스템의 냉방에너지 사용량이 예측되었으며, 결론을 요약하면 다음과 같다.

첫째, VRF 시스템의 냉방에너지 사용량을 예측하기 위한 ANN

모델의 입력변수는 시스템을 구성하는 실외기, 냉각탑, 펌프, 팬의 전력사용량에 영향을 미치는 주요 인자인 급기 설정온도, 말단차압, 냉각수 설정온도, 냉매증발 설정온도로 나타났다. 추가적으로 실외 온도, 실외습도, 실내온도, 일사량, 냉동부하는 환경변수로써, 1시간 이후의 냉방에너지 사용량을 예측하는 입력변수로 선정되었다.

둘째, 개발된 초기모델은 입력변수에 따른 예측정확도를 분석하여 일사량을 제외한 최적의 입력변수가 선정되었다. 이후 최적화 과정을 거쳐 은닉층 수 2개, 각 은닉층의 뉴런수 15개, 학습률 0.3, 모멘텀 0.3의 구조로 설계되었다.

셋째, 최종적으로 개발된 예측모델의 성능평가 결과, R²값은 0.8136, Cv(RMSE)값은 11.3%로 나타나 ASHRAE Guideline 14의 기준에 적합한 예측모델이 개발된 것으로 나타났다.

향후 본 연구 결과를 기반으로 VRF 시스템 운전 알고리즘을 개발하여 각 시스템의 설정값 및 변수들을 제어하고, 시뮬레이션 및 실제 건물에 적용하여 냉방 에너지절감량을 확인하는 연구가 필요하다고 사료된다.

Acknowledgements

본 연구는 국토교통부 국토교통기술촉진연구사업(17CTAP-C129762-01)에 의해 수행되었습니다.

This research was supported by the Basic Science Research Program through the National Research Foundation (NRF) of Korea funded by the Ministry of Science, ICT & Future Planning (grant number 2015R1A1A1A05001142).

Reference

- [1] 왕광익, 노경식, “신기후변화체제에 대비한 도시정책 방향”, 국토연구원, 국토정책 Brief 608, 2017 // (Wang, Kwang-Ik, Noh, Kyung-Sik, “Urban Policy Direction for the New Climate Change Regime”, Korea Research Institute for Human Settlements, 2017)
- [2] 장향인, 조영흠, 조재훈, “건물에 설치된 신재생에너지관리시스템의 적용 현황 및 개선 방향”, 대한건축학회논문집, 제 29권 제 2호, 2013 // (Jang, Hyang-In, Cho, Young-Hum, Jo, Jae-Hun, “Application and Improvement of the Renewable Energy Management System in Existing Buildings”, Journal of the architectural institute of Korea, Vol. 29, No. 2, 2013)
- [3] 에너지경제연구원, “2014년도 에너지총조사 보고서”, 에너지경제연구원 통계정보시스템, 2014 // (Korea Energy Economics Institute, “Energy Consumption Survey 2014”, 2014)
- [4] 에너지경제연구원, “건물에너지소비 상설표본조사 연구”, 에너지경제연구원 통계정보시스템, 2016 // (Korea Energy Economics Institute, “Building Energy Consumption Standing Sampling Survey”, 2016)
- [5] 지식경제부, “2016 에너지기술개발 실행계획”, 2015 // (Ministry of Trade Industry and Energy, “2016 Energy Technology Development Plan”, 2015)
- [6] 국토교통부, “제1차 녹색건축물 기본계획”, 2014 // (Ministry of Land, Infrastructure and Transport, “The 1st green building basic plan”, 2014)
- [7] 문현준, 김정원, “패적제어 알고리즘 기반 VRF 시스템의 냉방기 제어 특성 실험”, 한국건축환경설비학회논문집, 제 9권 제 3호, 2015 // (Moon, Hyeun-Jun, Kim, Jeong-Won, “An Experimental Study on the Performance of a VRF Air Conditioning System with a Thermal Comfort Control Algorithm”, Journal of KIAEBS Vol. 9, No. 3, 2015)
- [8] 기현승, 박준원, 강기남, 김주욱, 송두삼, “TRNSYS 시뮬레이션을 통한 VRF시스템의 구현과 타당성 검증”, 대한설비공학회 하계학술발표대회 논문집, 2011 // (Ki, Hyun-Seung, Park, Jun-Won, Kang, Ki-Nam, Kim, Joo-Wook, Song, Doo-Sam, “Development of VRF System Module and

Verification by TRNSYS Simulation”, Journal of The Society of Air-conditioning and Refrigerating Engineers of Korea, 2011)

[9] 손재호, 김청용, “교육시설의 개념단계 공사비예측을 위한 인공지능망 모델 개발에 관한 연구”, 한국건설관리학회 논문집, 제 7권 제 4호, 2006 // (Kim, Chung-Yung, Son, Jae-Ho, “A Study on the Model of Artificial Neural Network for Construction Cost Estimation of Educational Facilities at Conceptual Stage”, Korea Journal of Construction Engineering and Management, Vol. 7, No. 4, 2006)

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

[11] McCulloch and Walter Pitts, A Logical Calculus of Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, 1943

[12] Moon, Jin-Woo and Kim, Jong-Jin, Application of ANN in Residential Thermal Control, 11TH International Building Performance Simulation Association Conference, Building Simulation, 2009

[13] Moon, Jin-Woo and Kim, Jong-Jin, ANN-based Thermal Control Models for Residential Buildings, Building and Environment, 2010

[14] 이슬기, 정성관, 이우성, 박경훈, “인공지능망을 이용한 도시기온 예측 모형 구축”, 대한국토계획학회지, 제 46권 제 1호, 2011 // (Lee, Seul-Gi, Jung, Sung-Gwan, Lee, Woo-Sung, Park, Kyung-Hun, “Predictive Model for Urban Temperature Using the Artificial Neural Network”, Journal of Korea Planning Association, Vol. 46, No. 1, 2011)

[15] 이병옥, 태준성, 최재혁, “오류역전파 알고리즘을 이용한 사출성형금형 냉각회로 최적화”, 한국공작기계학회지, 제 18권 제 4호, 2009 // (Rhee, Byung-Ok, Tae, Jun-Sung, Choi, Jae-Hyuk, “Injection Mold Cooling Circuit Optimization by Back-Propagation Algorithm, Journal of the Korean Society of Machine Tool Engineers, Vol.18, No.4, 2009)

[16] Randall C. O’Reilly and Yuko Munakata, Computational Explorations in Cognitive Neuroscience, MIT Press, 2000

[17] 권한솔, “인공지능망을 이용한 부하 예측 기반 대형 건물의 복합 냉동기 최적운영 방안”, 박사학위논문 서울시립대학교, 2013 // (Kwon, Han-Sol, “Optimal Operating Strategy of a Hybrid Chiller Plant Utilizing Artificial Neural Network based Load Prediction in a Large Building Complex”, Doctor’s thesis in University of Seoul, 2013)

[18] 한도영, 윤형범, “건물부하예측을 이용한 공조기 운전제어 알고리즘에 관한 연구”, 대한설비공학회 하계학술발표대회 논문집, 2002 // (Han, Do-Young, Yoon, Hyoung-Bum, “Study on Air Handling Unit Control Algorithms by Using Building Load Prediction”, Journal of The Society of Air-conditioning and Refrigerating Engineers of Korea, 2002)

[19] 이재현, 송영학, 윤현진, 최동석, 태상진, 김익근, “수냉식 VRF 시스템 대상 설정값 제어 알고리즘 개발 및 효과 검증에 관한 연구”, 대한설비공학회 하계학술발표대회 논문집, 2016 // (Lee, Je-Hyeon, Song, Young-Hak, Yoon, Hyun-Jin, Choi, Dong-Suk, Tae, Sang-Jin, Kim, Ik-Keun, “Development of VRF System Module and Verification by TRNSYS Simulation”, Journal of The Society of Air-conditioning and Refrigerating Engineers of Korea, 2016)

[20] Chirag Deb, Lee Siew Eang, Junjing Yang and Mattheos Santamouris, Forecasting Diurnal Cooling Energy Load for Institutional Buildings using Artificial Neural Networks, Energy and Buildings 121, 2016

[21] 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

[22] Pedro A. Gonzalez and Jesus M. Zamarrero, Prediction of Hourly Energy Consumption in Buildings based on a Feedback Artificial Neural Network, Energy and Buildings 37, 2005

[23] The U.S. D.O.E., EnergyPlus Engineering Reference Ver. 8.5; The Reference to EnergyPlus Calculations, 2011

[24] Samsung Electorincs Co., DVM S Water Technical Data Book, 2015

[25] Yang, In-Ho and Kim, Kwang-Woo, Prediction of the Time of Room Air Temperature Descending for Heating Systems in Buildings, Building and Environment, 2004

[26] Moon, Jin-Woo, Kim, Kyung-Jae and Min, Hyun-Suk, ANN-Based Prediction and Optimization of Cooling System in Hotel Rooms, Energies, 2015.

[27] 매트릭스코리아, <https://kr.mathworks.com>

HUMID_{OUT}: average outdoor relative humidity[%]

TEMP_{IN}: average indoor dry-bulb temperature[° C]

SOLAR: average solar radiation[w/m²]

LOAD_{COOL}: cooling load[kWh]

TEMP_{SA}: air handling unit supply air temperature[° C]

PRES_{COND}: condenser fluid pressure[kg/cm²]

TEMP_{COND}: condenser fluid temperature[° C]

TEMP_{EVAP}: condenser fluid evaporation temperature[° C]

LOAD_{CT}: load of cooling tower[kWh]

ENERGY_{OUTUNT}: energy used by outdoor units[kWh]

FR_{CT}: condenser water volume flow rate[m³/h]

c_p: specific heat for water[kcal/kg·° C]

ρ: density of water[kg/m³]

P_{OUTUNT}: electric power of outdoor units[kW]

Q_{OUTUNT}: reference capacity of outdoor unit[kW]

COP_{REF}: reference coefficient of performance[4.787W/W]

CAPFT: cooling capacity ratio according to the entering condenser fluid and inlet wet-bulb air temperatures

EIRFT: electric power ratio according to the entering condenser fluid and inlet wet-bulb air temperatures

EIRFPLR: electric power ratio according to the part load ratio

EIRFLPM: electric power ratio according to the amount of condenser fluid

X: inlet air wet-bulb temperature entering the DX coil in the AHU[° C]

Y: condenser fluid supply temperature[° C]

PLR: part load ratio[%]

CMH: flow rate of condenser fluid[m³/h]

CTEP: electric power of fan in the cooling tower[kWh]

TTFE: electric power of constant-speed fan in the cooling tower[kW]

deltim: time step in the simulation process

compCoef: cooling tower fan power correction coefficient

FF: flow fraction

fpl: fraction of full load power

P_{CT}: electric power of pumps in cooling tower[kW]

gw_{lpm}: flow rate of condenser fluid[l/m]

FF: flow fraction

m: current air mass flow[kg/s]

m_{design}: design(maximum) airflow[kg/s]

f_{pl}: fraction of full load power

Q_{tot}: fan power[W]

ΔP: fan design pressure increase[Pa]

e_{tot}: fan total efficiency

ρ_{air}: air density at standard conditions[kg/m³]

Nomenclature

TEMP_{OUT}: average outdoor dry-bulb temperature[° C]