LHI Journal (2019) 10(3):9-16 http://dx.doi.org/10.5804/LHIJ.2019.10.3.009
http://lhi.lh.or.kr

# 인공신경망 기반 VRF 시스템 제어

# ANN-Based VRF (variable refrigerant flow) system control

문진우[1]

Jin Woo Moon

(Received September 6, 2019 / Revised September 25, 2019 / Accepted October 8, 2019)

ABSTRACT

This study aimed at developing control algorithms for operating a variable refrigerant flow (VRF) heating and cooling system with optimal system parameter set-points. Two artificial neural network (ANN) models, which were respectively designed to predict the heating energy cost and cooling energy amount for upcoming next control cycle, was developed and embedded into the control algorithms. Performance of the algorithms were tested using the computer simulation programs - EnergyPlus, BCVTB, MATLAB in an incorporative manner. The results revealed that the proposed control algorithms remarkably saved the heating energy cost by as much as 7.93% and cooling energy consumption by as much as 28.44%, compared to a conventional control strategy. These findings support that the ANN-based predictive control algorithms showed potential for cost- and energy-effectiveness of VRF heating and cooling systems.

**Key words:** VRF 냉난방시스템(VRF Heating and Cooling System), 인공신경망(Artificil Neural Network), 최적제어(Optimal Control)

## 1. 서 론

우리나라는 자원 공급의 항상성 및 안정성이 확보하고 있지 않음에도 불구하고 연간에너지소비량은 OECD (Organization for Economic Cooperation and Development) 국가 중 8번째이며, 특히 연간 에너지소비 증가율이 6.6%로써 가장 높은 수치를 보여주고 있다 (IEA, 2015; Korea Energy Agency, 2016)]. 이러한 현실을 직시한 정부 및 다양한 유관단체는 에너지소비감축을 위하여 다양한 정책 및 계획을 수립, 제안하고 있으며, 이러한 노력들 중 상당수는 국가에너지 소비량의 24%를 차지하는 건물분야에 집중되고 있다(Ahn et al., 2009; Jang and et al., 2013).

VRF (variable refrigerant flow) 시스템의 개발 및 적용은 건물 냉난방에너지 소비 감축을 위한 유용한 기술로 대두되고 있다(Lee et al., 2016; Aynur et al., 2010). VRF 시스템은 수식과 공기식으로 나눌 수 있으며, 그 중 수냉식 VRF 시스템은 연간 안정적인 냉·난방 열량을 공급할 수 있는 장점을 바탕으로 중대형 건물으로의 적용이 확대되고 있다. Fig.1 수냉식 VRF 시스템의 일반적 구성을 보여준다. 하나의 수냉식 공기조화기(air handling unit)에 다수의 실외기(outdoor units)가 연결된 멀티히트펌프 방식이며, 실외기들은 각각 냉각탑(cooling tower)과 보일러(boiler)에 연결되어 냉,난방이 가능하게 된다. 특히, 변화하는 외기 상태나 부하율의 변동에 따라 냉매유량, 냉매증발/응축온도, 급기 설정온도, 말단차압 등 시스템변수의 제어를 통하여 역동적으로 대응할 수 있는 장점이 있다. 또한, 최적의 변수제어를 통하여 건물 냉난방에너지성능을 향상시킬 수 있는 가능성을 내포하고 있다(기현승 등 2011).

하지만, 현재 적용된 VRF 시스템의 운용은 이러한 장점과 가능성을 충분히 활용하지 못하는 한계점을 가지고 있다. 일반적으로 시스템 변수의 설정값 (setpoints)은 고정된 값(values) 혹은 전문가의 경험을 바탕으로 한 임의의 값에 근간하여 결정되고 있다. 이는 앞서 언급한 역동적 시스템의 운용 및 에너지효율적 운용을 방해하는

1) 중앙대학교 건축학부 교수(주저자 : gilerbert73@cau.ac.kr)

요소이다. 따라서 에너지를 최소한으로 사용하며 실내의 쾌적 온열환경을 만족시키는 역동적인 VRF 시스템의 최적 운영방안이 필요하다.

이러한 배경을 바탕으로 본 연구에서는 VRF 냉·난방시스템의 최적제어를 위하여 변수별 최적값(setpoints)를 예측하는 인공신경망모델을 내포한 제어알고리즘을 개발하고 그 성능평가를 통하여 적용 가능성을 분석하는 것을 목적으로 하였다. 이를 위하여 알고리즘을 개발하는 과정과 성능평가의 과정이 진행되었으며, 특히 성능평가는 컴퓨터시뮬레이션 기법을 사용하였다.

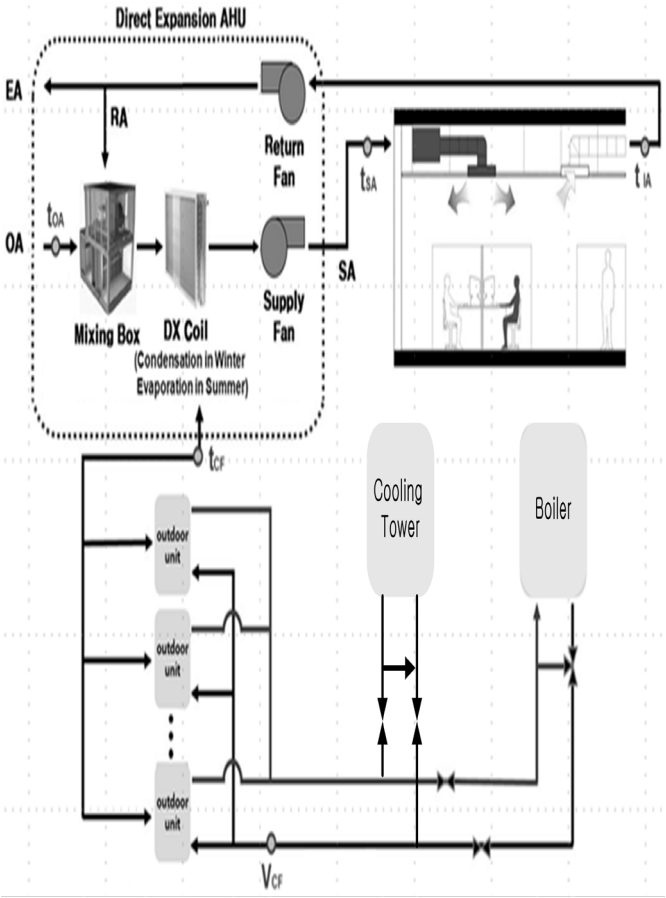



Fig. 1. Diagram of the DX AHU-water source VRF system. SA: supply air; RA: return air; EA: exhaust air; OA: outdoor air, tSA: supply air temperature, tIA: return air temperature, tOA: outdoor air temperature, tCF: condenser fluid temperature, and VCF: condensing fluid amount.

## 2. 냉난방에너지 소비량 예측 모델 및 제어알고리즘 개발

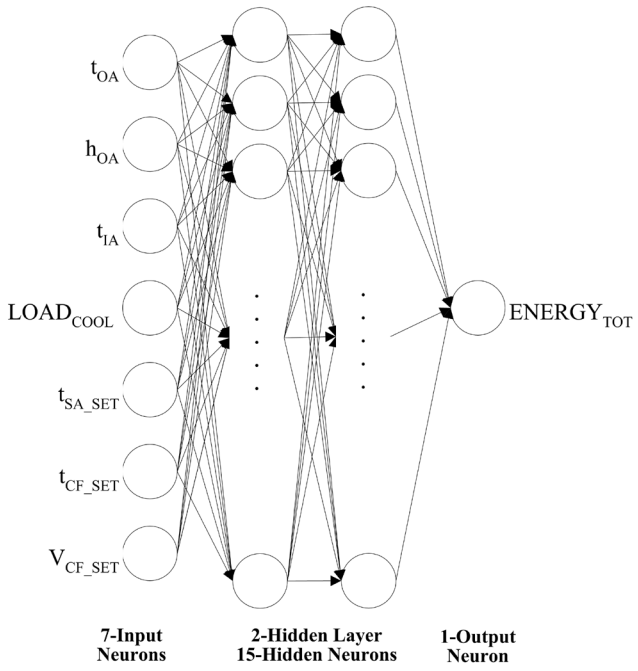
건물환경제어분야는 정보 및 컴퓨터기술의 발전과 더불어 괄목할 진척을 이루고 있다. 최근 인공지능 이론과 기술은 제어분야의 해결책으로 각광받고 있으며 적용이 확대되고 있다(Panja et al., 2018; Gupta et al., 2017) 특히, 인공신경망(ANN)에 기반한 제어법은 예측의 정확성과 유연한 적용성을 바탕으로 다양한 시스템 제어를 위하여 활용되고 있다(Ferdyn et al., 201; Yang et al, 2005). 본 연구에서는 VRF 시스템의 최적 냉·난방 운용을 위하여 선행연구에서 개발된 두 가지의 인공신경망 모델을 내포한 냉·난방 제어알고리즘을 개발하여 예측 및 적응제어가 가능하도록 계획되었다.

### 2.1. 예측모델 개발

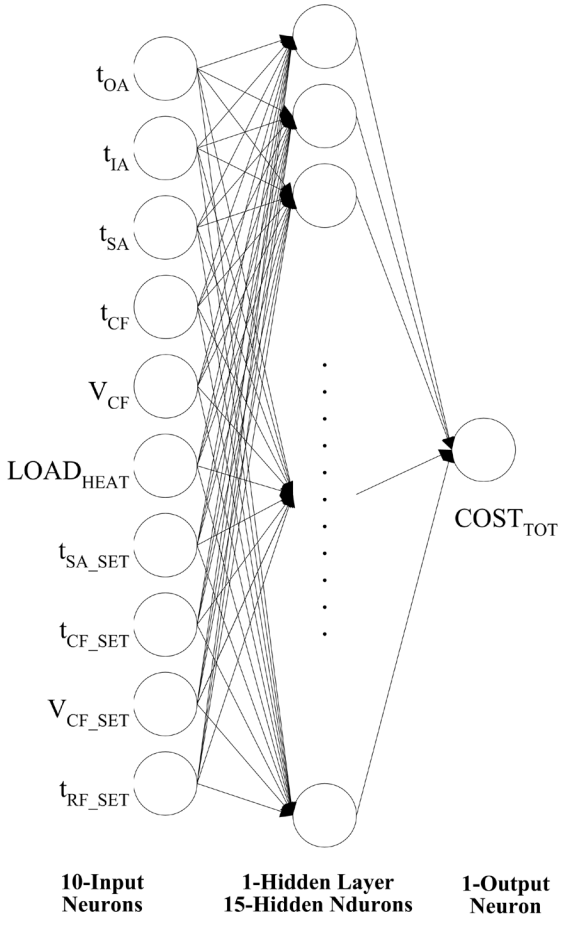
선행연구에서는 냉·난방시스템 작동상태를 예측하기 위한 두 가지의 인공신경망 모델이 개발되었다(Chung et al., 2017; Park et al., 2018). Fig. 2는 각 모델의 구조를 보여주고 있으며, Table 1에는 최적화된 모델의 상세가 정리되어 있다. 각 모델의 구조 및 학습방법은 예측성능을 최대화 할 수 있는 최적화 과정을 통하여 결정되었다.

첫 번째 ANN 모델은 현재의 실내외 열환경조건(실외온도 tOA, 실내온도 tIA, 실외습도 hOA), 냉방부하(LOADCOOL), 그리고 다음 제어주기 1시간 동안의 시스템 작동조건(설정공급공기온도 tSA_SET, 설정냉수온도 tCF_SET, 설정냉수유량 VCF_SET)을 기반으로 다음 제어주기 1시간 동안의 냉방에너지 ENERGYTOT(전기, kWh)를 예측하는 것을 목적으로 한다. 입력뉴런은 출력뉴런과의 상관관계 분석을 통하여 상관성이 높은 변수들고 결정되었다. 최적화된 숨겨진층의 구조는 두 개 층에 각각 15개의 뉴런이 배치되어 있는 것으로 결정되었으며, 학습률과 모멘트는 각각 0.3일 경우가 가장 예측률이 뛰어난 것으로 밝혀졌다(Chung et al., 2017).

두 번째 ANN 모델은 현재의 실내외 열환경조건(실외온도 tOA, 실내온도 tIA), 시스템 운용 조건 (공급공기습도 tSA, 온수온도 tCF_SET, 온수유량 VCF), 냉방부하(LOADCOOL), 그리고 다음 제어주기 1시간 동안의 시스템 작동조건(설정공급공기온도 tSA_SET, 설정온수온도 tCF_SET, 설정온수유량 VCF_SET, 냉매응축온도 tRF_SET)을 기반으로 다음 제어주기 1시간 동안의 난방비용 COSTTOT(원)를 예측하는 것을 목적으로 한다. 난방비용의 경우 전기소비와 가스소비의 총합으로 계산되었다. 각 비용은 2017년 기준 전기 689원/kWh와 가스 689원/m3이 적용되었다. 최적화된 숨겨진층의 구조는 단일층에 15개의 뉴런이 배치되어 있는 것으로 결정되었으며, 학습률과 모멘트는 각각 0.4일 경우 성능이 가장 우수한 것으로 나타났다(Park et al., 2018). 두가지 인공신경망 모델 모두 sigmoid function과 a pure linear function이 숨겨진층 뉴런과 출력층뉴런의 전이함수로 사용되었다.




(a) Cooling energy prediction model




(b) Heating cost prediction model

Fig. 2. Two ANN models for predicting energy and cost performance

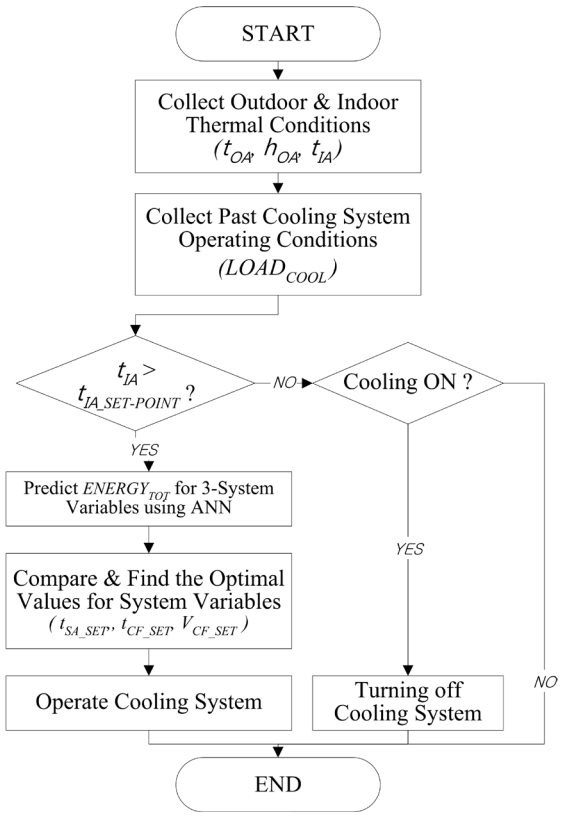
Table 1. Structure and learning methods of prediction models

| Prediction Type | Input Layer | | Hidden Layer | | Output Layer | Learning Methods |
|---|---|---|---|---|---|---|
| | Variables | Ranges | Layer | Neuron | | |
| Cooling Energy | · $t_{OA}$<br>· $h_{OA}$<br>· $t_{IA}$<br>· $LOAD_{COOL}$<br>· $t_{SA_SET}$<br>· $t_{CF_SET}$<br>· $V_{CF_SET}$ | 10 - 40 °C<br>0 - 100 %<br>15 - 30 °C<br>0 - 3000 kWh<br>8 - 20 °C<br>15 - 40 °C<br>1000 - 7000 l/min | 2 | 15 | $ENERGY_{TOT}$ | ·0.3 lr<br>·0.3 mo |
| Heating Cost | · $t_{OA}$<br>· $t_{IA}$<br>· $t_{SA}$<br>· $t_{CF}$<br>· $V_{CF}$<br>· $LOAD_{HEAT}$<br>· $t_{SA_SET}$<br>· $t_{CF_SET}$<br>· $V_{CF_SET}$<br>· $t_{RF_SET}$ | -20 - 20 °C<br>15 - 30 °C<br>34 - 40 °C<br>15 - 25 °C<br>800 - 1,800 l/min<br>0 - 300 kWh<br>34 - 40 °C<br>15 - 25 °C<br>800 - 1,800 l/min<br>37 - 46 °C | 1 | 15 | $COST_{TOT}$ | ·0.4 lr<br>·0.4 mo |

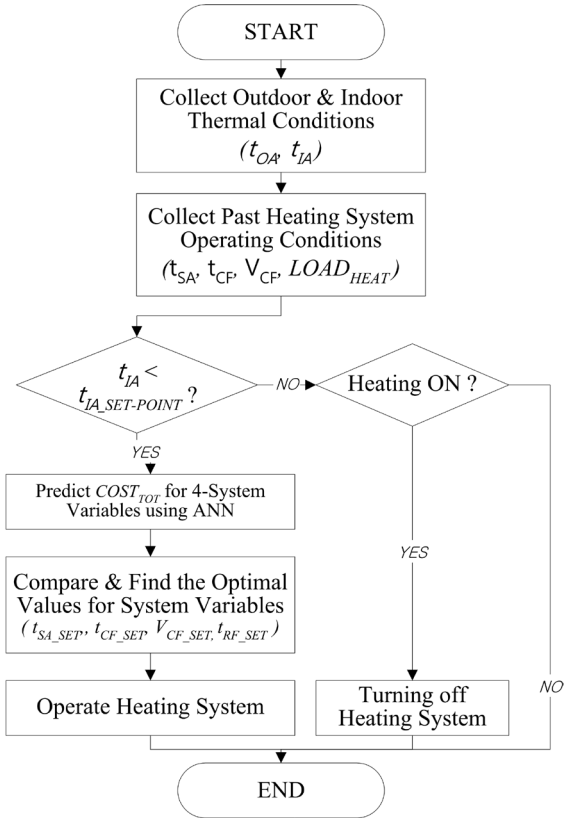
## 2.2. 제어알고리즘 개발

본 연구에서는 선행연구에서 개발된 두 가지 예측모델이 적용된 독립된 냉·난방 제어 알고리즘이 개발되었다. Fig. 3은 각 알고리즘의 흐름을 보여준다. 알고리즘은 실내·외 열환경 조건, 시스템 작동 조건에 대한 데이터를 수집하여 사용하게 된다. 특히, 각 인경신경망모델은 다음제어주기 1시간동안의 시스템 운용 설정값에 대한 소비에너지(냉방)과 비용(난방)을 각각 예측하게 된다. 알고리즘은 다양한 설정값 조합에 대한 예측값을 비교하는 과정을 통하여 최소 에너지소비 혹은 비용소비가 예상되는 설정값 조합을 도출한다. 도출된 최적의 시스템 설정값은 다음 제어주기 동안 시스템을 작동하게 된다.

최적 설정값 도출을 위한 개념적 과정이 Fig. 4에 나타나 있다. 냉방알고리즘의 경우 최적 tSA_SET, tCF_SET, VCF_SET의 조합을 찾는 과정으로 구성되어 있으며, 난방알고리즘의 경우 최적 tSA_SET, tCF_SET, VCF_SET, tRF_SET의 조합을 찾게 된다. 특히, 냉·온수 유량의 경우 500 l/min (냉수), 100 l/min (온수) 간격으로 비교를 실시하도록 계획되었다.




(a) Algorithm for cooling




(b) Algorithm for heating

Fig. 3. Flowchart of the control algorithms

```
for tSA_SET = 8:20
    for tCF_SET = 15:40
        for VCF_SET = 1000:500:7000
            Predict the ENERGYTOT from ANN model
            Compare ENERGYTOT for the different set-point combination
            Find the set-point combination of the least ENERGYTOT
        end
    end
end
```

(A) Algorithm for cooling

```
for tSA_SET = 34:40
    for tCF_SET = 15:25
        for VCF_SET = 800:100:1800
            for tRF_SET = 37:46
                Predict the COSTTOT from ANN model
                Compare COSTTOT for the different set-point combination
                Find the set-point combination of the least COSTTOT
            end
        end
    end
end
```

(b) Algorithm for cooling

Fig. 4. Conceptual code for finding optimal setpoint combination

## 3. 컴퓨터 시뮬레이션 적용 성능평가

개발된 알고리즘의 성능은 기존의 전통적인 (Conventional) 제어알고리즘과의 에너지소비량(냉방) 및 에너지소비비용(난방)의 비교를 통하여 이루어졌다. 전통적인 방법은 시스템 변수의 값이 고정되어 작동하게 되며 그 값들은 Table 2에 정리되어 있다. 반면, 본 연구에서 개발된 알고리즘은 앞선 Table 1과 Fig. 4에서 설명되었듯 일련의 범위와 간격을 가지는 값에 대하여 최적의 조합을 찾아 사용하게 된다. 따라서 최적의 조합은 4394가지(냉방), 8470가지(난방)의 조합에 대한 에너지소비량 및 에너지소비비용을 각각 비교한 결과이다.

Table 2. Set-points of the control variables in the conventional algorithm.

| Control Variables | Cooling | Heating |
|---|---|---|
| $t_{SA_SET}$ | 16°C | 38°C |
| $t_{CF_SET}$ | 32°C | 20°C |
| $V_{CF_SET}$ | 6000 l/min | 1666 l/min |
| $t_{RF_SET}$ | - | 43°C |

성능평가는 EnergyPlus, MATLAB, BCVTB (Building Controls Virtual Test Bed) 소프트웨어 프로그램을 이용하여 실시되었다. Fig. 5는 각 프로그램의 역할과 연결과정을 보여준다. 시뮬레이션은 다음의 과정을

통하여 진행된다. 우선, EnergyPlus는 VRF 시스템의 테스트건물, DX AHU, 실외기를 모델링하고 실외외기조건 반영 및 실내 열환경조건을 생성한다. 다음으로 MATLAB은 보일러, 냉각탑, 펌프 등을 모델링하며, 인공신경망모델과 알고리즘을 구성한다. 마지막으로 BCVTB는 EnergyPlus와 MATLAB간의 데이터교환을 하는 역할을 하게된다. EnergyPlus가 실내외 열환경조건에 대한 데이터를 생상하게 되면 BCVTB는 그 데이터를 MATLAB에 전달하게 되고, MATLAB은 전달된 데이터와 인공신경망모델, 제어알고리즘을 이용하여 최적의 시스템 변수값 조합을 도출하게된다. 도출된 변수값 조합은 다시 BCVTB를 통하여 EnergyPlus로 전달되어 냉난방 시스템을 작동시키고, 그 결과 새로운 실내 열환경조건이 생성되게 된다. 이러한 과정은 매 제어주기마다 반복되어 테스트기간 중의 에너지사용량 및 비용이 계산되게 된다.

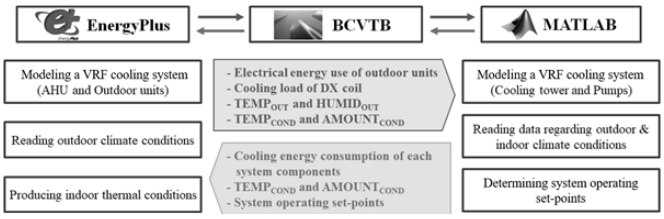



Fig. 5. Simulation process with the three software programs

성능평가를 위한 테스트건물은 서울에 위치한 S기업의 R&D 센터로 선정되었다. Fig. 6은 대상건물의 전면을 보여주고 있다. 대상건물은 11층 오피스 건물이며 podium, typical floors와 roof로 구성되어 있다 냉난방시스템은 수식 VRF시스템이며, 하나의 냉각탑, 11개의 AHU, 그리고 27개의 실외기로 구성되어 있다. 실내온도는 냉방기간의 경우 재실 시 26℃, 비재실 시 29℃, 난방기간의 경우 재실 시 21℃, 비재실 시 15℃로 고정되어 운영되고 있다.

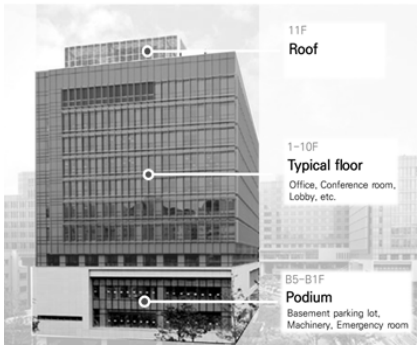



Fig. 6. Front view of the test building

실내발열부하는 Table 3, 4를 이용하여 결정되었다. Table 3은 실내발열부하의 기준치이며, Table 4는 시간대별 발생비율을 나타낸다. 기준치와 비율을 적용하여 재실기간중 변화되는 시간대별 실내부하를 계산하고, 계산된 값이 시뮬레이션에 적용되었다. 마지막으로 Table 5에는 시스템 운용과 관련된 시뮬레이션 조건이 정리되어 있다.

Table 3. Baseline of internal heat gain.

| Components | Values |
|---|---|
| Occupants | 0.078 person/m$^2$ |
| Lighting | 21.52 W/m$^2$ |
| Electric Equipment | 16.14 W/m$^2$ |

Table 4. Cooling schedules for internal heat load.

| Cooling Schedule | Ratio | | |
|---|---|---|---|
| | Occupants | Lighting | Electric quipment |
| Weekdays | 00:00 ~ 06:00 (0.000)<br>06:00 ~ 22:00 (0.500)<br>22:00 ~ 23:59 (0.025) | 00:00 ~ 23:59 (0.250) | 00:00 ~ 23:59 (1.000) |
| Saturday | 00:00 ~ 06:00 (0.000)<br>06:00 ~ 08:00 (0.500)<br>08:00 ~ 12:00 (0.150)<br>12:00 ~ 17:00 (0.050)<br>17:00 ~ 23:59 (0.000) | 00:00 ~ 06:00 (0.012)<br>06:00 ~ 08:00 (0.025)<br>08:00 ~ 12:00 (0.075)<br>12:00 ~ 17:00 (0.037)<br>17:00 ~ 23:59 (0.012) | 00:00 ~ 06:00 (0.300)<br>06:00 ~ 08:00 (0.400)<br>08:00 ~ 12:00 (0.500)<br>12:00 ~ 17:00 (0.350)<br>17:00 ~ 23:59 (0.300) |
| Sunday | 00:00 ~ 23:59 (0.000) | 00:00 ~ 23:59 (0.012) | 00:00 ~ 23:59 (0.300) |

Table 5. Simulation conditions.

| Category | Input Value |
|---|---|
| Simulation program | EnergyPlus v8.5 |
| Site/weather location | Seoul/Republic of Korea |
| Window-to-wall ratio | 40% |
| AHU/water type VRF schedule | 24 Hours |
| Cooling set-point | 26℃ |
| Cooling period | July 01-August31, 2017 |
| Heating set-point | 21℃ |
| Heating period | January 01-February 28, 2017 |
| COP | 4.787 |
| Pump motor efficiency | 90% |
| Infiltration | 0.0003167m$^3$/s-m$^2$ |

EnergyPlus와 MATLAB에서 모델링된 AHU, 실외기, 냉각탑, 보일러, 펌프 등의 적절성 확보를 위하여 대상건물에서 3개월간 측정된 운용데이터와의 비교를 바탕으로 보정과정이 진행되었다. 특히, 실외기 성능은 3가지의 성능곡선(the low temperature curve, the high temperature curve, and the boundary curve)을 이용하여 분석되었다. 보정 후 시뮬레이션에서 도출된 에너지소비량은 실제 건물에서 측정된 에너지소비량과의 비교결과 CVRMSE 15.2%로써 ASHRAE Guideline 14-Measurement of energy and demand savings (ASHRAE, 2002)에서 제시한 기준값인 30% 이하인 것으로 나타나 모델링 결과물의 신뢰도가 확보되었다.

## 4. 성능분석

본 연구에서 개발된 VRF 냉·난방시스템 제어로직 적용에 따른 시스템 제어변수의 작동결과가 Fig. 7과 8에 나타나 있다. Fig. 7은 냉방시스템의 작동결과이며, 전기에너지 사용 최소화를 위한 tSA_SET, tCF_SET, VCF_SET의 변화를 보여준다. 최적의 설정값은 각각 10-18℃, 25-35℃, 1,000-7,000 liter/minute의 범위에서 결정되었으나 대부분의 경우 12-14℃, 35℃, 3,000-5,000 l/min로 작동되었다.

난방시스템의 제어결과는 Fig. 8에 나타나 있다. 초기를 제외한 대부분의 경우 tSA_SET, tCF_SET, VCF_SET, tRF_SET은 38 ℃, 25 ℃, 1600 l / min, 40 ℃로 유지되었다. 초기의 경우 인공신경망모델이 테스트빌딩의 작동결과에 적응하는 단계이기 때문에 변화가 발생한 것으로 사료된다. tSA_SET의 경우 전통적 방법에서 고정적으로 적용된 38 ℃와 동일하게 결정되었으나 나머지 세 변수는 기존의 방법과 상이한 값으로 적용되었다(Table 2 참조). 본 건물에서는 일정기간 이후 동일한 설정값 조합으로 결정되었으나 같은 결과가 모든 건물에서 발생할 것임을 의미하지는 않는다. 건물과 시스템의 규모, 배치 등에 따라 상이한 결과가 발생할 수 있을 것으로 사료된다.

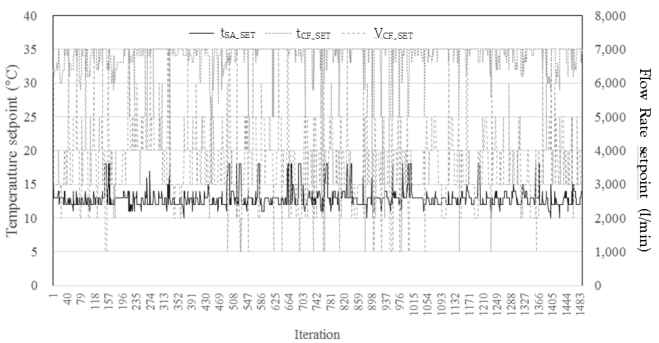



Fig. 7. Optimal set-points of the system variables

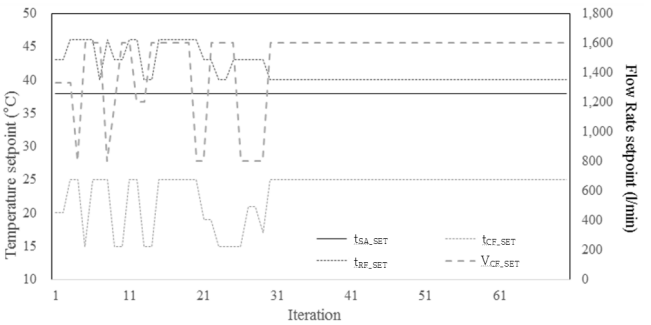



Fig. 8. Setpoints of variables determined by the predictive control algorithm

시스템 운용에 따른 냉방에너지소비량과 난방에너지소비비용이 Fig. 9과 10에 정리되어 있다. Fig. 9은 전통적방법과 본 연구에서 제안된 최적제어방법에 의한 냉방에너지소비량의 비교 결과를 나타낸다. 실외기, 팬, 펌프, 냉각탑으로 구성된 냉방시스템은 전적으로 전기에너지를 사용하고 있다. 모든 구성기기에서 최적제어방법이 전기에너지를 적게 사용하는 것으로 나타났다. 기기별 개별 감소량은 30.57%, 26.59%, 51.78%, 9.05%인 것으로 분석되었으며, 전체 감소비는 28.44%에 달하는 것으로 나타났다. 이 감소량은 95,509kWh이며 경제적으로는 2017년 기준 13,562,278원 감소로 환산할 수 있다.

Fig. 10은 난방에너지소비비용의 비교결과를 보여준다. 난방의 경우 실외기, 팬, 펌프는 전기에너지를 소비하는 반면 보일러는 가스에너지를 사용한다. 따라서, 에너지 성능 비교를 위하여 각 에너지원을 비용으로 환원하여 비교를 실시하였다. 실외기와 펌프에서 사용되는 전기에너지비용은 최적제어방법에 의하여 각각 17.54%, 3.27% 감소하였으나 보일러에서 사용되는 에너지비용은 29.95% 증가된 것으로 나타났다. 따라서, 전체 소비비용은 7.93% 감소되는 것으로 분석되었다. 이는 2017년 기준 556,940원에 해당한다.

보일러 소비되는 에너지비용의 증가는 실외기 소비에너지비용의 감소와 관련이 있다. 실외기에서 요구되는 에너지소비비용은 전통적제어법의 경우 전체 에너지비용의 73.71%를 차지하는 가장 주된 요소이다. 최적제어알고리즘은 비용의 측면에서 가장 효율적인 설정값 조합을 찾는 것을 목적으로 한다. 그 결과 설정값 조합을 결정함에 있어 소비비중이 가장 큰 실외기의 작동을 최소화하는 방향으로 제안한 것으로 판단된다. 이 경우 동일한 난방효과를 제공하기 위하여 보일러의 작동을 증가시켜 온수온도(tCF_SET,)를 높이도록 시스템을 작동하게 된다. 따라서, 보일러에서 소비되는 가스의 비용이 증가하게 된 것으로 사료된다.

Fig. 11은 난방을 위한 전기 및 가스소비량의 비교를 보여준다. 전기의 경우 전통적방법과 최적제어방법에 의하여 각각 41,120kWh와 34,819kWh로 최적제어법에 의하여 6,301 kWh 감소되었으나, 가스의 경우 1,666 m3와 2163m3로써 497m3가 증가되었다. 이러한 난방에너지 소비비용 및 전기, 가스소비량은 전기와 가스의 단위비용에 따라 그 효과가 상이해질 수 있다. 예를 들어 전기에너지료가 저렴해지고 가스료가 상승하면 보일러의 사용을 감소시키고 실외기의 사용을 증가시키는 변화된 설정값을 유도할 필요가 있다. 본 연구에서 개발된 인공신경망모델은 이러한 변화에 대한 지속적 학습을 바탕으로 에너지소비비용을 예측할 것이며 제어알고리즘은 예측된 값들의 비교를 통하여 최적의 조합을 찾게되므로, 가격의 변화에 대하여 적응이 가능할 것으로 판단된다.

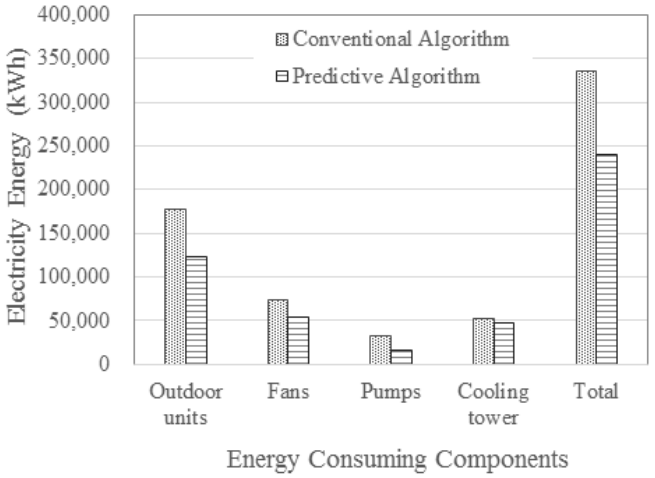



Fig. 9. Cooling energy consumption by the conventional and predictive algorithms

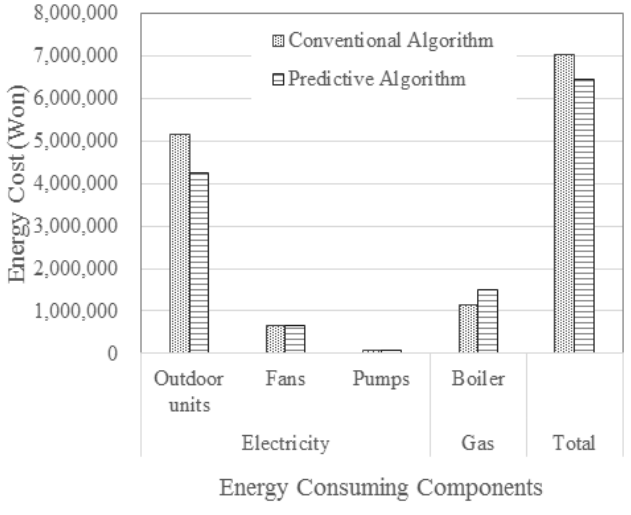



Fig. 10. Energy cost for each heating system component

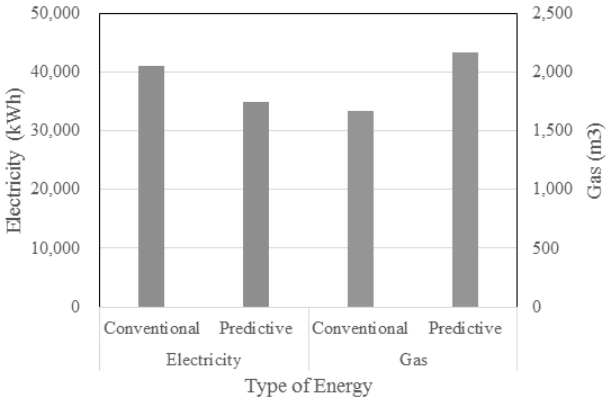



Fig. 11. Elctricity and gas consumption by the conventional and predictive algorithms

## 5. 결 론

본 연구는 VRF 냉·난방 시스템의 최적운용을 위한 최적제어알고리즘을 개발하고 성능평가를 하는 것을 목적으로 하였다. 알고리즘은 냉방에너지소비량 및 난방에너지소비비용을 예측하는 인공신경망모델을 내포하고 있으며, 다양한 시스템 작동 설정값 조합에 대한 비교를 통하여 최적의 설정값 조합을 도출할 수 있도록 계획되었다. 개발된 최적제어 알고리즘은 고정된 설정값 조합을 사용하는 전통적인 방법과의 비교성능 평가를 통하여 효율성을 확보하고자 하였다. 연구과정을 통하여 밝혀진 사실은 다음과 같다.

(1) 냉방시스템의 전기에너지 사용 최소화를 위한 tSA_SET, tCF_SET, VCF_SET의 최적 설정값은 대부분의 경우 12-14°C, 35°C, 3,000-5,000 l/min로 작동되었으며, 난방시스템의 tSA_SET, tCF_SET, VCF_SET, tRF_SET은 일정기간 이후 38 °C, 25 °C, 1600 l / min, 40 °C로 유지되었다. 이러한 변화는 기존의 고정된 설정값조합과는 상이한 결과이며, 이는 인공신경망예측모델과 최적제어알고리즘의 적용에 따른 효과로 볼 수 있다.

(2) 냉방에너지소비량의 경우 모든 구성기기에서 최적제어방법이 전기에너지를 적게 사용하는 것으로 나타났으며, 개별 감소량은 각각 30.57%, 26.59%, 51.78%, 9.05%이고 전체 감소비는 28.44%(95,509kWh, 13,562,278원)였다. 난방에너지소비비의 경우 실외기와 펌프에서 사용되는 전기에너지비용은 17.54%, 3.27% 감소하였으나 보일러에서 사용되는 에너지비용은 29.95% 증가되어 전체 소비비용은 7.93%(556,940원) 감소되었다. 이로써 본 연구에서 제안하는 최적제어알고리즘이 전체 냉·난방에너지소비량 및 소비비 감소에 효과가 있는 것으로 판단

할 수 있다.

(3) 난방의 경우 전기와 가스의 단위비용에 따라 최적의 설정값조합이 변경될 수 있을 것으로 예상된다. 가스료이 상승하고 전기료가 하강할 경우 개발된 인공신경망은 현재 기준과는 상이한 에너지소비비용을 예측할 것이고, 최적제저알고리즘은 그에 따른 새로운 조합의 최적 설정값을 도출하게 될 것이다. 이러한 과정은 변화에 대한 인공신경망모델의 지속적 학습을 통하여 가능할 것이다.바탕으로 에너지소비비용을 예측할 것이며 제어알고리즘은 예측된 값들의 비교를 통하여 최적의 조합을 찾게 되므로, 가격의 변화에 대하여 적응이 가능할 것으로 판단된다.

이러한 분석결과는 인공신경망 및 최적제어알고리즘에 기반한 VRF 냉·난방시스템 제어의 가능성을 제시한 것으로 사료된다. 본 연구를 기반으로 추후 실제 건물에 적용 후 성능분석의 과정이 뒤따를 것이며, PID 등 전통적 제어법과의 비교성능평가를 실시하여 적용성을 확보할 필요성이 있다.

## Acknowledgement

This work was supported by the Korea Institute of Energy Technology Evaluation and Planning (KETEP) and the Ministry of Trade, Industry & Energy (MOTIE) of the Republic of Korea (No. 20182010600010).

## 참고문헌

1. International Energy Agency(2015), 「Energy balances of OECD/Non-OECD countries」.
2. Korea Energy Agency(2016), 「2016 Korea energy handbook」.
3. Ahn B.L., Kim C.H., Kim J.Y., Jang C.Y.(2009), “A study on the analysis of building energy rating considering the region”, 「Journal of Korean Solar Energy Society」, 29: 53~58.
4. Jang H.I., Cho Y.H., Jo J.H.(2013), “Application and improvement of the renewable energy management system in existing buildings”, 「Journal of Architectural Institute of Korea」, 29: 227~234.
5. Lee J.H., Song Y.H., Yoon H.J., Choi D.S., Tae, S.J., Kim I.K.(2016), “A study on development and effectiveness verification of set-point control algorithm for water-cooled VRF System”, 「Journal of The Society of Air-conditioning and Refrigerating Engineers of Korea」, 28: 399~402.
6. Aynur T.N.(2010), “Variable refrigerant flow systems: a review”, 「Energy and Buildings」, 42: 1106~1112.
7. 기현승, 박준원, 강기남, 김주욱, 송두삼(2011), “TRNSYS 시뮬레이션을 통한 VRF시스템의 구현과 타당성 검증”, 「대한설비공학회 하계학술발표대회 논문집」.
8. Panja P., Velasco R., Pathak M., Deo M.(2018) “Application of artificial intelligence to forecast hydrocarbon production from shales”, Petroleum, 4: 75~89.
9. Gupta A.K., Kumar P., Sahoo R.K., Sahu A.K., Sarangi S.K.(2017), “Performance measurement of plate fin heat exchanger by exploration: ANN, ANFIS, GA, and SA”, 「Journal of Computational Design and Engineering」, 4: 60~68.
10. Ferdyn-Grygierek J., Grygierek K.(2017), “Multi-variable optimization of building thermal design using genetic algorithms”, Energies, 10: 1570.
11. Yang J., Rivard H., Zmeureanu R.(2005), “Building energy prediction with adaptive artificial neural networks”, 「9th International IBPSA Conference」, 1401~1408.
11. Chung M.H., Yang Y.K., Lee K.H., Lee J.H., Moon J.W.(2017), “Application of artificial neural networks for determining energy-efficient operating set-points of the VRF cooling system”, 「Building and Environment」, 125: 77~87.
12. Park B.R., Choi E.J., Hong J., Lee J.H., Moon J.W.(2018), “Development of an energy cost prediction model for a VRF heating system”, 「Applied Thermal Engineering」, 140: 476~486.
13. ASHRAE(2002), 「ASHRAE Guideline14-measurement of Energy and Demand Savings」.