JDCS
디지털콘텐츠학회논문지
Journal of Digital Contents Society
Vol. 19, No. 4, pp. 749-756, Apr. 2018

머신러닝 기반의 온실 제어를 위한 예측모델 개발

김 상 엽[1,3] · 박 경 섭[2] · 이상민[1] · 허 병 문[3] · 류 근 호[3*]
[1]한국기계연구원 청정연료발전연구실
[2]국립원예특작과학원 시설원예연구소
[3]충북대학교 데이터베이스/바이오인포매틱스 연구실

Development of Prediction Model for Greenhouse Control based on Machine Learning

Sang Yeob Kim[1,3] · Kyoung Sub Park[2] · Sang Min Lee[1] · Byeong Mun Heo[3] · Keun Ho Ryu[3*]
[1]Department of Clean Fuel & Power Generation, Korea Institute of Machinery & Materials, Daejeon, Korea
[2]Protected Horticulture Research Institute, National Institute of Horticultural and Herbal Science, Haman, Korea
[3]Database/Bioinformatics Lab, School of Electrical & Computer Engineering, Chungbuk National University, Cheongju, Korea

[요 약]

본 연구는 머신러닝 기법을 이용한 온실 제어를 위한 예측모델을 개발하는 것이 목적이다. 시설원예연구소의 실험온실에서 측정된 데이터(2016년)를 사용하여 예측모델을 개발하였다. 모델의 예측성능 향상과 데이터의 신뢰성 확보를 위해 상관관계분석을 통해 데이터의 축소를 수행하였다. 데이터는 계절별 특성을 고려하여 봄, 여름, 가을 및 겨울로 나누어 구축하였다. 머신러닝 기반의 예측모델로 인공신경망, 순환신경망 및 다중회귀모델을 구축하고 비교분석을 통해 타당성을 평가하였다. 분석 결과에서, Selected dataset에서는 인공신경망 모델이 Full dataset에서는 다중회귀모델이 좋은 예측성능을 보였다.

[Abstract]

In this study, we developed a prediction model for greenhouse control using machine learning technique. The prediction model was developed using measured data (2016) on greenhouse in the Protected Horticulture Research Institute. In order to improve the predictive performance of model and to ensure the reliability of data, the dimension of the data was reduced by correlation analysis. The dataset were divided into spring, summer, autumn, and winter considering the seasonal characteristics. An artificial neural network, recurrent neural network, and multiple regression model were constructed as a machine leaning based prediction model and evaluated by comparative analysis with real dataset. As a result, ANN showed good performance in selected dataset, while MRM showed good performance in full dataset.

색인어 : 온실제어, 예측모델, 기계학습, 인공신경망, 순환신경망
Key word : Greenhouse control, Prediction model, Machine learning, Artificial neural network, Recurrent neural network

http://dx.doi.org/10.9728/dcs.2018.19.4.749

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-CommercialLicense(http://creativecommons.org/licenses/by-nc/3.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 10 April 2018; **Revised** 14 April 2018
Accepted 25 April 2018

***Corresponding Author; Keun Ho Ryu**
Tel: +82-43-267-2254
E-mail: khryu@dblab.chungbuk.ac.kr

Ⅰ. 서 론

전 세계적으로 온실의 면적이 증가하고 있고, 그중 한국의 1인당 온실면적이 세계 1-2위를 차지할 정도로 우리나라에서 온실 재배가 널리 이루어지고 있다. 이중에 시설재배 면적이 나날이 증가하고 있다. 시설재배는 노지재배와 다르게 재배 환경을 조절하고 기상환경조건 등 재배환경의 분석을 통해 생산성의 증대와 품질 향상을 달성할 수 있기 때문에 시설재배 면적에서 난방이 되는 온실이 증가하고 있는 추세이다[1]. 온실에 사용되는 에너지 비용 중 대부분을 난방비가 차지하고 있으며[2, 3], 유가 상승에 따라서 비용이 증가하는 추세이다. 이는 농가의 수입과 가장 밀접한 연관이 있으며, 이를 줄이는 것이 최대의 효과를 나타낼 수 있다. 온실에 사용되는 다양한 에너지를 효율적으로 관리하기 위해 정밀한 환경제어 방법이 필요하다.

이에 따라 다양한 환경 조건에서 효과적으로 온실을 제어하고 에너지 소비를 줄이고 수익을 증대시키는 방향으로 연구가 수행되어왔다. 미기상 환경 예측모델을 제안하였고, 이 모델은 온실 환경 조절 시스템에 적용할 수 있도록 설계 되었다[4]. 인공신경망을 이용해 온실 내 습도 모델링, 난방 에너지 소비 예측 등의 예측모델을 통한 연구가 수행되어 회귀모델과의 비교를 통해 타당성을 검증하였다[5-7]. 온실 환경의 최적 제어를 위해 외부기상을 고려한 Solar greenhouse model을 개발한 연구에서는 보일러, 환기, CO_2 공급 장치, 펌프 등의 장치에 대한 온실 내 제어를 위한 각각의 모델을 제안하였다[8]

온실 환경제어를 위한 내부 온도 예측모델은 통계적 접근이나 복잡한 데이터마이닝 기법까지 여러 방법으로 구축될 수 있으나, 정확한 예측을 위해 데이터 전처리 통한 데이터의 신뢰성 확보 과정이 필요하다. 또한 실제 온실 내부의 측정 데이터와 예측치 차를 통계적인 방법으로 검증하여야 한다.

따라서 이 연구에서는 정밀한 온실 제어를 위해 머신러닝 기반의 예측모델을 개발한다. 데이터 전처리 단계에서 예측모델의 정확성을 향상시키기 위해 상관관계분석을 통해 데이터를 축소하고, 새로운 Feature를 추출하여 Training dataset 데이터에 반영하였다[9]. 예측모델의 성능 비교분석을 위해 Training dataset은 계절별로 구분되며, Selected dataset과 Full dataset으로 나누어 각각의 예측모델을 구축하고 비교하였다. Full dataset은 센서로부터 측정되는 모든 변수를 입력값으로 하는 동시에 전처리 과정에서 추출된 새로운 Feature도 포함한다. Training dataset의 확장을 통해 머신러닝 예측모델로써 다양한 구조의 ANN (artificial neural network), RNN (recurrent neural network) 및 MRM (multi regression model)을 구축하고 비교분석을 통해 예측모델의 타당성 검증하였다. 아울러 계절별 모델의 비교를 통해 가장 적합한 예측모델을 선택하여 온실 제어에 활용토록 하였다. 제안한 예측모델을 적용하여 효율적인 온실 에너지 관리를 가능케 하며, 온실에 사용되는 에너지 비용의 절감 효과를 기대할 수 있다.

Ⅱ. 재료 및 방법

본 연구에서는 함안에 위치한 시설원예연구소 내의 온실 내·외부에서 측정한 데이터를 수집 및 가공하여 실험을 수행하였다. 이를 이용하여 Training dataset을 구성하며, Full dataset과 Selected dataset으로 구분한다. 각 Training dataset을 계절별로 나누어 예측모델을 구축하는데 사용한다. 계절별로 구축된 모델을 비교분석하여 예측모델의 타당성을 검증한다.

2-1 데이터 수집

벤로형 온실(Venlo type greenhouse)에서 데이터 수집하고 실험을 진행하였다. 데이터 수집을 위해 차광 조건 하에서 온도, 습도 및 CO_2센서(소하테크, VT-250, 한국), 일사량 센서(KIPP&ZONEN, CNR4, 네덜란드), 데이터 로거(캠벨, CR1000, 미국)를 사용하였다. 수집되는 데이터는 표 1과 같으며, 총 29개의 Attribute로 구성되며, 2016년 1년 동안의 데이터를 활용하였다. 데이터의 변화가 적기 때문에 10분 평균 데이터로 구성한다.

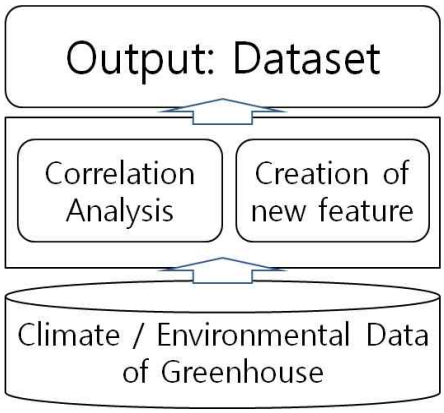

그림 1. 데이터 전처리 흐름도
Fig. 1. Framework of Data Preprocessing

2-2 데이터 전처리

예측모델의 Training dataset을 구성하기 위해 데이터의 전처리를 수행하였다. Full dataset은 수집된 모든 데이터를 이용하여 예측모델을 구축하는데 사용되고, Selected dataset은 예측 성능향상을 위해 데이터를 축소하여 구성한다. 본 연구에서는 데이터의 축소를 위해 상관관계분석을 이용한 Filter 방식을 선택하였고, 이러한 이유는 구축된 최종 모델을 실제 환경에서 사용할 경우 발생하는 다중공선성 문제를 해결하기 위해서이다[10].

표 1. 온실 내외에서 수집되는 데이터
Table 1. Collected data of internal/external greenhouse

Attribute of Data(Unit)	Contents
AirTemp (℃)	Temperature in Greenhouse
RH (%)	Relative Humidity in Greenhouse
TgtAirTemp (℃)	Target Temperature
SurfTempHigher (℃)	Temperature of Intro Heating Pipe
SurfTempLower (℃)	Temperature of Outro Heating Pipe
HeatPumpAccLength (sec)	Operating Time of Heat Pump
AirTemp_AWS (℃)	External Temperature
RH_AWS (%)	External Relative Humidity
sum_10m (min)	Radiation Value over 120W/㎡
wet_10m (min)	Condensation Value under 150Kohm
SlrW (W/㎡)	Solar Radiation
SlrW_Max (W/㎡)	Maximum Solar Radiation(AVG. 10min)
WS (m/s)	Wind Speed
WD (°)	Wind Direction
ws_gust (m/s)	Maximum Wind Speed (AVG. 10min)
wd_gust (°)	Direction of Maximum Wind Speed
PAR_Flux_Density (umol/㎡)	Intensity of Radiation
bar_pressure_kpa (kPa)	Air Pressure
Rain_mm (mm)	Rainfall
Under_10, 30, 50cm, 1, 1.5m (℃)	Subsurface Temperature - 10, 30, 50cm, 1, 1.5m
soilheat_10, 30, 50cm (W/㎡)	Subsurface Thermal Flux - 10, 30, 50cm
CO_2_AWS (ppm)	External CO_2

1) 상관관계분석을 통한 데이터 축소

온실 내 온도와 나머지 데이터의 상관관계분석을 통해 데이터의 축소를 수행하였다. Pearson correlation coefficient 방법을 사용하였으며, 측정되는 데이터 중 중복되는 값은 제외하였다. 또한 상관계수의 값을 분석하여 강한 음의 상관관계와 강한 양의 상관관계($-0.3 \leq e \leq 0.3$)에 있는 변수들을 선택하였으며, 조건을 만족하지 못하는 변수를 제외하였다. 29개의 변수 중 11개의 변수가 선택되었다.

표 2. 상관관계분석을 통한 변수 선택, 11 variables
Table 2. Selection variables by correlation analysis, 11 variables

Attribute of Data(Unit)	Contents
RH (%)	Relative Humidity in Greenhouse
SurfTempLower (℃)	Temperature of Outro Heating Pipe
AirTemp_AWS (℃)	External Temperature
RH_AWS (%)	External Relative Humidity
WS (m/s)	Wind Speed
SlrW (W/㎡)	Solar Radiation
PAR_Flux (umol/㎡)	Intensity of Radiation
sun_10m (min)	Radiation Value over 120W/㎡
wet_10m (min)	Condensation Value under 150Kohm
soilheat_10cm (W/㎡)	Subsurface Thermal Flux - 10cm
CO_2_AWS (ppm)	External CO_2

2) Feature 추출

선정한 입력변수 중 상대습도는 단위의 문제 때문에 통계적 분석이나 온실 제어에 많이 사용되지 않는다. 따라서 수증기 포차(Vapor Deficit)를 구하여 새로운 Feature로 활용하였다. 수증기 포차를 계산하는 수식은 다음과 같다[11].

$$VD = SV - AH \quad (1)$$
$$SV = 0.6219 \times SVP / (1013.25 - SVP) \times 1000 \quad (2)$$
$$AH = 0.6219 \times VP / (1013.25 - VP) \times 1000 \quad (3)$$
$$VP = SVP \times RH \quad (4)$$
$$SVP = 6.1078 \times 10^{\wedge} ((7.5 \times T)/(237.4 + T)) \quad (5)$$

여기서 VD는 Vapor Deficit를 의미하고, SV는 Saturated Vapor, AH는 Absolute Humidity, RH는 Relative Humidity, VP는 Vapor Pressure, SVP는 Saturated Vapor Pressure, T는 온실 온도를 의미한다.

3) Training Data 구성

Training dataset의 구성은 측정변수를 모두 반영한 Full dataset과 데이터 축소를 수행한 Selected dataset으로 구성(11 Variables)하였다. Full Dataset 역시 앞서 추출한 Vapor Deficit을 포함하며, 총 30 Variables로 구성하였다. 각 Dataset은 계절별로 봄(3-5월), 여름(6-8월), 가을(9-11월) 그리고 겨울(12-2월)로 나누었으며, 각각 13,249 Samples, 13,248 Samples, 13,103 Samples, 12,975 Samples로 총 52,575 Samples 이다. 표 3은 전처리를 통해 구성한 Selected data을 나타낸다.

표 3. 예측모델 구축을 위한 Selected training dataset
Table 3. Selected training dataset for prediction model

Attribute of Data(Unit)	Contents
VD (g/kg)	Vapor Deficit
SurfTempLower (℃)	Temperature of Outside Heating Pipe
AirTemp_AWS (℃)	External Temperature
VD_AWS (g/kg)	External Vapor Deficit
WS (m/s)	Wind Speed
SlrW (W/㎡)	Solar Radiation
PAR_Flux (umol/㎡)	Intensity of Radiation
sum_10m (min)	Radiation Index over 120W/㎡
wet_10m (min)	Condensation Value under 150Kohm
soilheat_10cm (W/㎡)	Subsurface Thermal Flux - 10cm
CO_2_AWS (ppm)	External CO_2

Ⅲ. 예측모델 구축

온실 환기 제어를 위해 온실 내 온도를 예측하는 예측모델을 구축하였다. 예측모델의 비교분석을 위해 ANN, RNN과 MRM을 구축하였다. Neural network 모델의 은닉층을 결정하기 위해 입력 데이터가 n개 일 때, n/2, n, 2n과 2n+1의 평균제곱근오차(RMSE: root mean square error)를 비교하여 가장 작은 값의 구조를 선택하였다[12]. 학습과 테스트를 위한 데이터의 구성은 70/30으로 하여 구축을 수행하였다. 표 4와 5는 데이터에 따른 예측모델의 각 구조를 비교한 결과이다. 비교결과로 Selected data에서는 11-23-1구조이며, Full dataset에서는 30-60-1의 구조로 모델을 구축하였다. 같은 Dataset을 기반으로 하여 MRM도 구축하였다. Target 변수는 온실 내부 온도이고 독립변수로는 나머지 변수를 적용하였다. 표7과 8은 각각 Full dataset일 경우에 ANN과 RNN의 구축 성능을 비교한 것이다. 구축된 결과를 보면, 여름의 경우 ANN의 성능이 가장 좋았으며, 가을의 경우 RNN 모델의 성능이 좋은 것으로 나타났다.

표 4. Selected dataset에 의한 모델 구조의 RMSE 비교
Table 4. Comparison of RMSE for prediction model structures by selected dataset

Season \ Structure	11 - 5 - 1	11 - 11 - 1	11 - 22 - 1	11 - 23 -1
Spring	0.842	0.747	0.676	0.662
Summer	0.345	0.292	0.276	0.267
Autumn	0.828	0.711	0.599	0.583
Winter	1.020	0.792	0.780	0.744

표 5. Full dataset에 의한 예측모델 구조의 RMSE 비교
Table 5. Comparison of RMSE for prediction model structures by full dataset

Season \ Structure	30 - 15 - 1	30 - 30 - 1	30 - 60 - 1	30 - 61 -1
Spring	0.467	0.382	0.307	0.319
Summer	0.367	0.390	0.221	0.277
Autumn	0.099	0.246	0.070	0.254
Winter	0.133	0.377	0.098	0.326

표 6. Full dataset에 의한 계절별 ANN 모델 비교
Table 6. Comparison of seasonal ANN model by full dataset

	Number of epoch	Structure of model	Performance (RMSE)
ANNF-M1	44	30-60-1 (Backpropagation)	0.277
ANNF-M2	104		0.202
ANNF-M3	30		0.281
ANNF-M4	49		0.294

M1: spring, M2: Summer, M3: Autumn, M4: Winter

표 7. Full dataset에 의한 계절별 RNN 모델 비교
Table 7. Comparison of seasonal RNN model by full dataset

	Number of epoch	Structure of model	Performance (RMSE)
RNNF-M1	19	30-60-1 (Layer Recurrent)	0.426
RNNF-M2	59		0.264
RNNF-M3	85		0.212
RNNF-M4	36		0.334

M1: spring, M2: Summer, M3: Autumn, M4: Winter

Ⅳ. 결과 및 고찰

4-1 예측모델 비교분석

예측모델의 비교분석을 위해 예측 데이터와 실측 데이터의 패턴을 분석하였다. ANN 모델에 비해 다중회귀모델은 예측값과 실측값의 패턴은 비슷하나 급격하게 변화하는 실내 온도값을 예측하기 어려우며, 정확성이 떨어지는 것을 알 수 있다. 그리고 RNN 모델은 ANN 모델과 비슷한 예측 성능을 나타내었다. RMSE를 비교하였을 때 계절별로 약간씩 차이는 있지만, 표 8을 보면 ANN 모델이 다른 예측모델 보다 작은 RMSE 값을 가지므로 전체적으로 ANN의 성능이 보다 정확하다고 판단할 수 있다.

표 8. Selected dataset에 의한 계절별 예측모델의 RMSE 비교
Table 8. Comparison of seasonal RMSE of prediction models by selected dataset

Season \ RMSE of Models	ANN	MRM	RNN
Spring	2.311	1.105	2.286
Summer	1.723	1.834	1.971
Autumn	1.590	1.594	1.859
Winter	2.154	2.627	2.041

표 9. Full dataset에 의한 계절별 예측모델의 RMSE 비교
Table 9. Comparison of seasonal RMSE of prediction models by full dataset

Season \ RMSE of Models	ANN	MRM	RNN
Spring	1.337	1.795	0.978
Summer	1.540	1.056	1.298
Autumn	1.326	2.362	1.045
Winter	6.751	1.140	3.474

봄의 경우 MRM 모델이 가장 좋은 성능을 나타냈고, 여름과 가을에는 ANN모델이 겨울에는 RNN 모델이 가장 좋은 성능을 나타냈다. 이 경우에는 ANN모델을 선택하는 것이 가장 좋은 효과를 볼 수 있을 것이다.

표 9는 Full dataset일 경우에 계절별 예측모델의 예측값과 실측값의 성능을 비교한 결과를 나타낸다. 전체적으로 MRM의 성능이 보다 정확하다고 판단된다.

4-2 고찰

기존 연구에서는 Backpropagation algorithm을 이용하여 온실 내 온도를 예측하고 이를 온실 환기에 적용하여 효율적인 온실 제어에 활용하고자 하였다. 각 예측모델의 비교 분석을 통해 ANN의 성능이 가장 뛰어나다고 판단되었다[9]. 이 연구에서는 Training dataset으로 모든 측정값 및 새로운 Feature를 입력 변수로 하는 Full dataset을 구성하여 예측 성능을 평가를 위해 기존 예측모델과 비교분석을 수행하였다. 그림 2와 3은 계절별 모델의 예측값과 실측값을 비교한 그래프이다. 계절별로 예측모델이 비슷한 패턴을 나타내는 것을 알 수 있다. 봄과 겨울에 경우에는 실측 데이터와 비슷한 경향을 나타내나 예측 성능이 떨어지는 것을 알 수 있다. 그림 4와 5는 Training dataset별로 예측모델의 구축 속도를 비교한 그래프이다. ANN 모델이 다른 예측모델보다 빠른 구축 속도를 보이고 있으며, 제안된 온실 환경 즉, 낮은 성능이 제어시스템에 따라 빠른 응답을 위해 구축 속도가 빠르고 예측 성능이 보다 좋은 모델을 선택하는 것이 옳다고 생각된다.

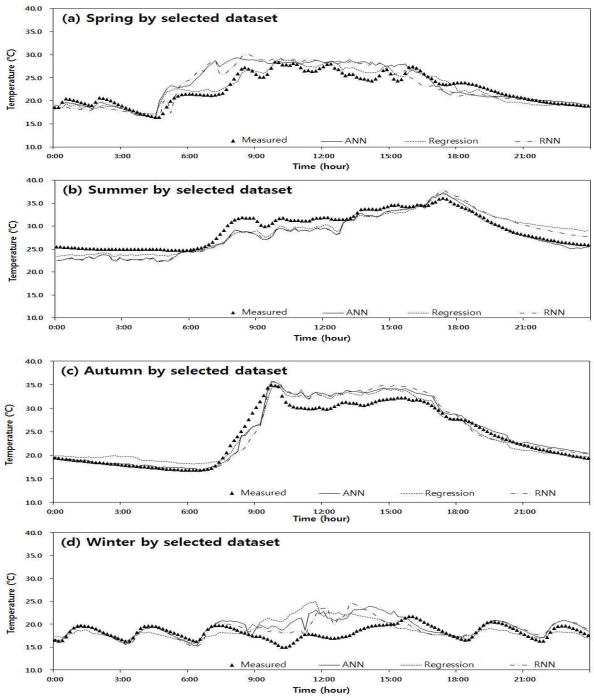

그림 2. Selected dataset의 예측모델 비교
Fig. 2. Comparison of prediction models by selected dataset

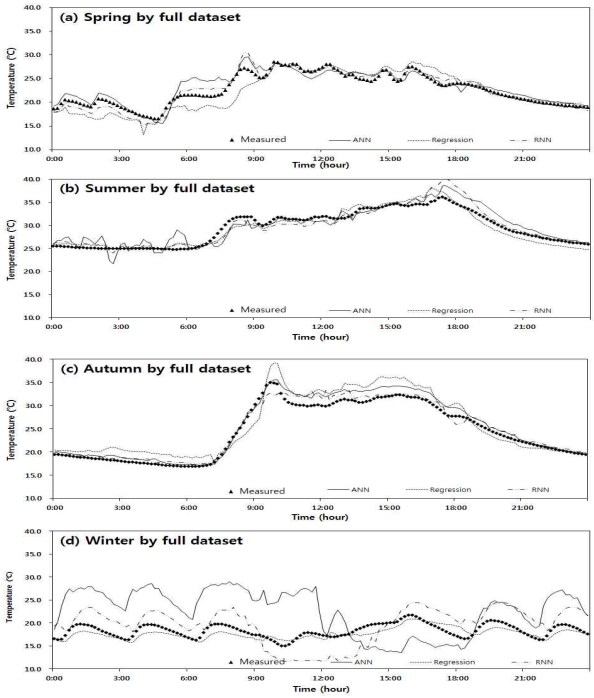

그림 3. Full dataset의 예측모델 비교
Fig. 3. Comparison of prediction models by full dataset

입력 데이터가 많은 경우에, ANN 모델은 최악의 성능을 나타냈다. RNN 모델은 봄과 가을에 가장 좋은 성능을 보였으며, MRM은 여름과 겨울에 가장 좋은 성능을 나타냈다. 이러한 경우에는 제한적인 제어 환경을 고려할 때 MRM 모델을 선택하는 것이 가장 좋은 방법이다.

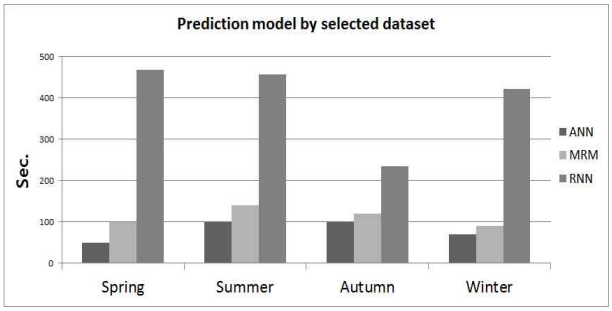

그림 4. Selected dataset의 예측모델 구축 속도 비교
Fig. 4. Comparison of prediction models's building speed by selected dataset

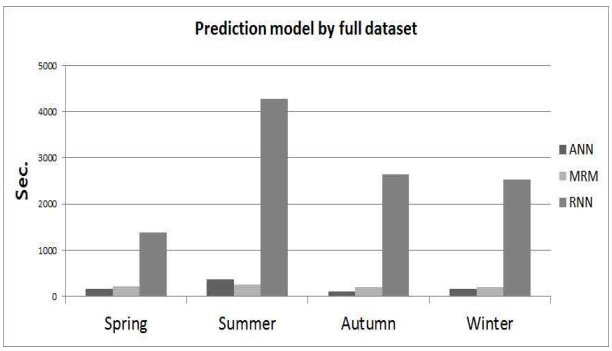

그림 5. Full dataset의 예측모델 구축 속도 비교
Fig. 5. Comparison of prediction models's building speed by full dataset

각 모델의 겨울의 예측 비교를 보면 낮 시간 동안의 온도 예측 패턴이 상이하게 나타나는 것을 볼 수 있다. 이는 겨울 데이터의 경우 온실 난방을 저녁부터 다음날 오전 9시까지 하였기 때문에 하지 않은 낮 동안에 측정된 데이터들이 온실 내 온도 예측에 영향을 미치는 것으로 판단된다. 따라서 보다 정확한 모델을 구축하기 위해 난방을 하지 않은 온실의 데이터를 확보하여 예측모델을 구축하고 실측 데이터와의 추가적인 비교분석이 필요할 것으로 보인다.

Ⅴ. 결 론

복잡한 온실 환경을 제어하기 위해 다양한 방법이 시도되고 있지만, 아직까지 온실의 기상을 정확하게 판단하고 제어하기엔 전통의 제어 방법으로는 부족한 점이 많다. 이 연구에서는 함안 시설원예연구소의 벤로형 온실에서 수집된 데이터를 기반으로 예측모델을 이용하여 온실 내부의 온도를 예측하고 예측한 결과와 ANN, RNN 모델과 MRM과의 비교분석하여 모델의 타당성을 검증하였다. 또한 예측된 온실 내 온도 데이터를 온실 환기 제어에 활용함으로써 보다 효율적인 온실 제어를 가능케 하였다. 예측 성능의 향상을 위해 상관관계 분석을 통해 데이터 축소를 수행하였으며, 새로운 Feature의 추출을 통해 데이터의 신뢰성 및 제어 성능 향상에 기여하였다. ANN, RNN 및 MRM을 비교한 결과 입력 데이터의 개수에 따라 다른 성능을 나타내었다. Selected dataset의 경우 ANN이 대체적으로 좋은 성능을 보였으며, Full dataset의 경우 MRM이 좋은 성능을 보였다. 하지만, Full dataset의 경우 겨울의 예측성능이 현저히 떨어지는 것을 알 수 있었으며, 입력 데이터가 많다고 좋은 예측 성능을 보이는 것은 아니라는 결론을 얻을 수 있었다. 또한 온실 환경같이 제안된 조건하에서는 예측 성능의 향상 및 데이터의 신뢰성 확보를 위해 데이터의 축소가 필요하고, 모델의 구축 속도나 처리 속도가 빠른 보다 가벼운 예측모델을 선택하여 제어에 활용하는 것이 옳다고 판단된다.

향후 연구로 퍼지 이론을 온실 제어에 접목하여 온실을 운영하는 사람의 판단에 도움을 주고, 자동으로 정밀한 온실 제어를 함으로써 온실에 사용되는 에너지의 효율적인 관리가 가능할 것으로 판단된다. 이를 활용하여 에너지 절약 및 수확물 증가로 인한 농가의 수입 증대가 예상된다.

감사의 글

본 성과물은 농촌진흥청 연구사업(세부과제번호: PJ0120692018)의 지원에 의해서 이루어진 것임

참고문헌

[1] H. Benli, "Performance prediction between horizontal and vertical source heat pump systems for greenhouse heating with the use of artificial neural networks," Heat and Mass Transfer, vol. 52, no. 8, pp. 1707-1724, 2016.

[2] Rural Development Administration (RDA) (2015) Agriculture and livestock income database for improving agricultural management, 2015.

[3] S. M. Lee, Y. D. Lee, S. Y. Kim, C. U. Kim, K. S. Park, "Development of Energy Efficient Horticultural System

based on Gas Engine Driven Heat Pumps", Greensys 2017, pp.120, 2017.

[4] S. W. Hong, I. B. Lee, "Predictive Model of Micro Environment in a Naturally Ventilated Greenhouse for a Model Based Control Approach," Protected Horticulture and Plant Factory, vol. 23, no. 3, pp. 181-191, 2014.

[5] F. He, C. Ma, "Modeling greenhouse air humidity by means of artificial neural network and principal component analysis," Computers and Electronics in Agriculture, vol. 71, no. 1, pp. S19-S23, 2010.

[6] S. L. Patil, H. J. Tantau, V. M. Salokhe, "Modelling of tropical greenhouse temperature by auto regressive and neural network models," Bio systems Engineering, vol. 99, no. 3, pp. 423-431, 2008.

[7] A. Famili, W. M. Shen, R. Weber, "Data preprocessing and intelligent data analysis," Intelligent Data Analysis, vol. 1, no. 1, pp. 3-23, 1997.

[8] R. J. C. van Ooteghem, "Optimal Control Design for a Solar Greenhouse," IFAC Proceedings Volumes, vol. 43, no. 26, pp. 304-309, 2010.

[9] S. Y. Kim, S. M. Lee, K. S. Park, K. H. Ryu, "Prediction Model of Internal Temperature using Backpropagation Algorithm for Climate Control in Greenhouse," Horticultural Science and Technology, to be submitted, 2018.

[10] I. Guyon, A. Elisseeff, "An Introduction to Variable and Feature Selection," Journal of Machine Learning Research, pp. 1157-1182, 2003.

[11] D. B. Anderson, "Relative Humidity or Vapor Pressure Deficit," Ecology, no. 17, pp. 277-282, 1936

[12] G. Zhang, B. E. Patuwo, and M. Y. Hu, "Forecasting with artificial neural networks: The state of the art," International Journal of Forecasting, 1998.

김상엽(Sang Yeob Kim)

2010년 : 충북대학교 대학원 전자계산학과 (공학석사)
2014년 : 충북대학교 대학원 컴퓨터과학과(공학박사 수료)
2010년～2013년: 한국에너지기술연구원
신재생에너지자원센터 (연구원)
2014년～현 재 한국기계연구원 청정연료발전연구실(선임연구원)
※관심분야 : 데이터마이닝, 데이터베이스, 신재생에너지, 시설원예

박경섭(Byeong Mun Heo)

2001년 : 서울대학교 대학원 식물생산과학부 (농학석사)
2016년 : 서울대학교 대학원 식물생산과학부 (농학박사)

2002년～현 재: 국립원예특작과학원 (농업연구관)
※관심분야 : 시설원예학

이상민(Byeong Mun Heo)

1999년 : 서울대학교 대학원 기계공학과 (공학석사)
2003년 : 서울대학교 대학원 기계공학과 (공학박사)

2003년～현 재 한국기계연구원 청정연료발전연구실(책임연구원)
※관심분야 : 시설원예, 스마트 에너지 제어

허병문(Byeong Mun Heo)

2008년 : 충북대학교 대학원 전자계산학과 (공학석사)
2011년 : 충북대학교 대학원 컴퓨터과학과 (공학박사수료)

2008년～2010년: 한국전력공사 전력연구원
2010년～현 재: 질병관리본부 국립보건연구원 근무 중
※관심분야 : 데이터마이닝, 데이터베이스, 바이오인포매틱스

류근호(Keun Ho Ryu)

1976년 : 숭실대학교 전산과 (공학사)
1980년 : 연세대학교 공학대학원 전산전공 (공학석사)
1988년 : 연세대학교 대학원 전산전공 (공학박사)

1976년～1986년: 육군군수 지원사 전산실(ROTC 장교),
한국전자통신연구원 (연구원),
한국방송통신대학교 전산학과 (조교수)
1989년～1991년: Univ. of Arizona Research Staff
1986년～현 재: 충북대학교 소프트웨어학과 교수
※관심분야 : 시간 데이터베이스, 시공간 데이터베이스, Temporal GIS, 지식기반 정보검색 시스템, 유비쿼터스 컴퓨팅 및 스트림 데이터 처리, 데이터 마이닝, 데이터베이스 보안, 바이오 인포메틱스 및 바이오 메디칼