

전력 소모 절감을 위한 딥 러닝기반의 지능형 그린 하우스 제어 시스템

Intelligent Green House Control System based on Deep Learning for Saving Electric Power Consumption

신 현 엽*, 임 효 균**, 김 원 태*★

Hyeonyeop Shin*, Hyokyun Yim**, Won-Tae Kim*★

Abstract

Smart farm dissemination by continuously developing IoT is one of the best solution for decreasing labor in Korea farming area because of ageing. For this reason, the number of Smart farm in Korea is being increased. The Smart farm can control farming environment such as temperature for human. Specially, The important thing is controlling proper temperature for farming. In order to control the temperature, legacy smart farms are usually using pans or air conditioners which can control the temperature. However, those devices result in increasing production cost because the electric power consumption is high. For this reason, we propose a smart farm which can predict the proper temperature after an hour by using Deep learning to minimize the electric power consumption by controlling window instead of pans or air conditioners. We can see the 83% of electric power saving by means of the proposed smart farm.

요 약

지속적인 IoT의 발전으로 인한 스마트팜 보급은 고령화와 일손부족 현상이 지속되고 있는 우리나라 농촌의 해결책으로 부각되고 있다. 이에 현재 스마트팜의 보급은 지속적으로 증가하고 있다. 스마트팜은 사람을 대신하여 온도, 습도, 이산화탄소, 그리고 날씨와 같이 작물 재배를 위한 환경을 모니터링하고 제어한다. 특히 작물을 재배함에 있어서 온도를 제어하는 것은 매우 중요하다. 온도를 제어하기 위해 스마트팜 내에서는 에어컨, 팬과 같이 온도를 제어할 수 있는 기기가 널리 사용되고 있다. 하지만 이러한 기기들은 전력소모가 심해 생산비의 증가를 초래한다. 본 논문은 인공지능을 이용하여 스마트팜 빅데이터를 학습하고 1시간후의 비닐하우스 최적온도를 예측하고 창문을 이용해 온도를 제어함으로써 다른 온도제어기기들보다 전력을 절약할 수 있는 전력절약형 스마트팜 시스템을 제시한다. 본 논문에서 연구한 방법을 이용한 시뮬레이션을 통해 기존에 사용하는 팬보다 특정 조건 하에서 83%전력소모가 절약될 수 있다는 것을 확인하였다.

Key words : deep learning, smart farm, smart system, Internet of Things, electric power saving

* Dept. of Computer Science and Engineering, Koreatech University

** Dept. of TI Platform, Hansol Secure

★ Corresponding author

E-mail: wtkim@koreatech.ac.kr, Tel:+82-41-560-1485

※ Acknowledgment

This paper was supported by the National Research Foundation of Korea(No. 2017R1A2B4010875).

Manuscript received Mar. 10, 2018; revised Mar. 24, 2018 ; accepted Mar. 27, 2018

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<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.

I. 서론

도시지역은 도시화로 인해 인구집중, 교통체중, 환경파괴, 자연공간 부족과 같은 도시문제가 나타나고 있는 반면, 농촌지역은 지속적인 인구감소와 더불어 고령화가 급속하게 진행되고 있기 때문에 사회적 큰 문제로 제기되고 있다 [1]. 특히 대한민국은 고령화사회로 진입하고 있는데 2017년 국내의 65세 이상 고령인구의 비중이 전체 인구의 13.8%인데 반해 2060년에는 41%로 증가할 것이라 예측한다 [2]. 이에 따라 농촌의 고령화도 지속적으로 진행되고 있는데 2007년 농업종사 인구 중 65이상 고령인구의 비중은 32.1%였고 꾸준한 고령화현상으로 인해 2015년에는 38.4%에 달하였다 [3]. 농촌의 꾸준한 고령화와 함께 농촌인구의 감소 또한 지속적으로 진행되고 있다. 2007년 327만4천명이었던 농가인구는 2016년 106만8천명으로 10년 동안 200만명 이상 감소하였다 [4]. 그 결과 농촌에서 일을 할 수 있는 인구 또한 점점 감소하고 있는 상태이다.

농업인구의 급속한 감소 문제의 해결책으로 스마트팜이 제시되고 있다. 스마트팜이란 그린 하우스나 축사에 ICT를 접목하여 원격·자동으로 작물과 가축의 생육환경을 적정하게 유지·관리할 수 있는 농장을 의미한다. 이를 활용하여 작물의 최적 생육환경을 조성하고 노동력·에너지·양분 등을 이전보다 덜 투입하고도 농산물의 생산성과 품질 제고가 가능해졌다 [5]. 농림축산식품부의 '2016년 스마트 팜 도입농가 성과분석'자료에 따르면 스마트팜 도입으로 단위면적당 생산량이 27.9%가 향상되었으며, 고용 노동비는 15.9%가 절감되었다. 이런 효과 때문에 스마트팜의 보급률은 2014년 405ha에서 2016년 1369ha로 가파르게 증가하고 있다 [6].

스마트팜이 최대의 재배량을 얻기 위해서는 여러 가지 환경요인들을 고려해야한다 [7]. 다양한 환경 요인들은 독립적인 것이 아니라 서로 밀접한 관계를 가지고 있기 때문에 환경 요인들 간의 상관관계를 이해하기 힘들다. 특히, 원예농업의 경우 실시간으로 변하는 기상환경에 따라 유지해야하는 실내 환경이 다르다 [8]. 따라서, 상황에 맞춰 온도를 유지하기 위해서는 팬이나 에어컨과 같이 빠른 시간에 온도를 제어할 수 있는 기기가 널리 사용 중이다.

그러나, 팬이나 에어컨을 사용하면 전력 소모가 크기 때문에 생산비의 증가를 초래한다. 생산비 증가의 문제를 해결하기 위해 본 논문에서는 창문을 자동으로 개폐함으로써 실내온도를 제어하고, 작물의 적절한 온도를 유지하여 재배환경을 최적으로 관리할 수 있는 전력절약형 스마트팜 시스템을 제시한다. 더불어, 창문을 통해 온도를 제어하는 방법의 단점은 온도의 변화가 느려서 이상상황에 대해 빠르게 대처하지 못하는 것이다. 기존의 창문을 이용하는 방법의 단점을 해결하기 위해 본 논문에서는 재배환경을 위한 최적의 온도를 1시간 전에 예측하여 실내 온도를 제어하는 해결법을 제시하였다.

본 논문은 2장에서 기존 스마트팜 시스템에 대한 분석을 제시하고, 3장에서는 스마트팜 전력절약 시스템의 전체 구성도와 각 구성 요소에 대한 상세기술을 설명한다. 4장에서는 스마트팜 데이터를 학습하고 최적 온도를 예측하는 과정과 온도를 제어하는 기기별로 전력소모량을 비교한 다음 본 논문의 결론을 맺음으로 구성한다.

II. 관련 논문

기존에 연구된 스마트팜 시스템은 재배환경을 모니터링하고 제어하는 방향으로 활발하게 진행되고 있다. *Chieochan*은 버섯 스마트팜 시스템을 연구하여 시스템이 스스로 재배공간의 습도를 제어하는 것을 제안하였다 [9]. 재배공간의 습도를 적은 오차율로 모니터링하고 자동 제어가 가능함을 보여주었다.

*Lee*는 그린 하우스 측면의 창문을 이용하여 그린 하우스의 실내온도를 설정온도로 유지하는 연구를 진행하였다. 본 연구와 동일한 방법을 사용하여 전력소모를 줄였다는 측면에서는 장점을 가지지만, 다양한 날씨변화에 설정온도가 변하지 않기 때문에 환경 변화에 대한 적응력이 좋지 않다. 환경변화에 대한 낮은 적응력을 해결하기 위해 딥러닝 알고리즘을 활용하는 방법이 연구중이다.

*Kia*은 퍼지 알고리즘을 지능적으로 온실 관계 시스템을 운영하는 방법에 대해 연구하였다. 온실의 환경특성, 토양의 특성 등을 이용하여 작물의 수분 흡수량을 예측하여 지능적으로 예측하였다 [10]. *El-Bendary*는 머신러닝을 이용해 토마토의

재배기를 예측하고 토마토 색깔과 주변 환경을 학습하여 최적의 재배시간을 알려준다 [11].

앞서 관련 논문들을 참고하면 다양한 조건을 고려할수록 스마트팜을 더 정밀하게 예측하기 위한 다양한 변수를 고려해야 한다. 또한, 농가의 생산성을 높이기 위해서는 생산비를 줄이는 것이 중요하다. 따라서, 본 연구에서 다양한 환경변화에 대처하여 실내 최적 온도를 예측하고 제어하는 방법을 연구한다.

III 본론

1. 전체 아키텍처

그림 1은 본 연구에서 제안하는 전체적인 시스템 구성도이다. 하우스 관리부(House Management Part)는 센서부(Sensor)와 제어(Control)부로 이루어져있다. 센서부는 온도센서와 습도센서를 이용하여 그린 하우스(Green house)의 현재 상태를 측정하고 LoRa통신을 통해 게이트웨이(oneM2M Gateway)로 보낸다. 또한 제어부는 게이트웨이로부터 RoLa통신을 통해 제어 메시지를 수신하고 창문 모터를 제어한다. 창문이 개폐하는 동작을 수행함으로써 하우스의 실내온도가 예측한 온도로 도달하는 하우스 최적화가 실행된다.

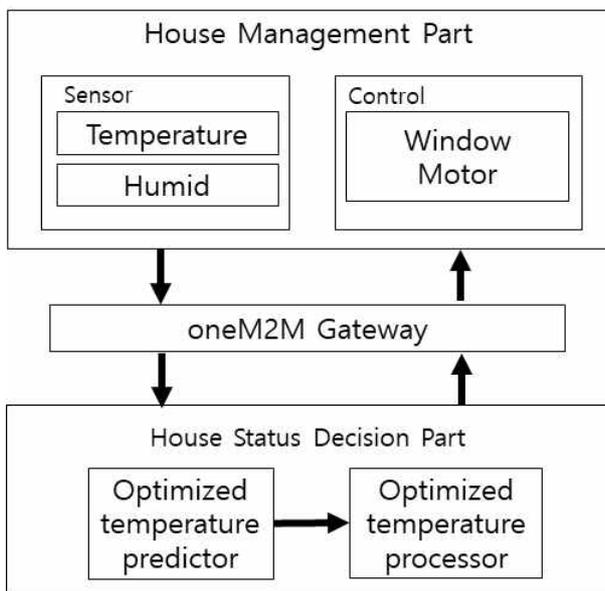


Fig 1. The proposed green house control system structure
그림 1. 제안하는 그린 하우스 제어시스템 구성도

하우스 상태 결정부(House Status Decision Part)는 기대 최적 온도 예측기(Optimized Temperature Predictor)와 기대 최적 온도 제어기(Optimized Temperature Processor)로 구성되어 있다. 하우스 상태 결정부는 oneM2M Gateway를 통해 그린 하우스 실내의 온도와 습도를 수신한다. 수신한 실내의 온도와 습도는 기대 최적 온도 예측기에서 기대 최적 온도를 예측하는데 사용된다. 기대 최적 온도는 1시간 후에 그린 하우스가 도달해야 하는 최적온도이다. 예측된 기대 최적 온도는 하우스 상태 결정부에서 그린 하우스의 상태를 결정하는데 기준으로 사용된다. 만약, 그린 하우스의 상태가 기대 최적 온도를 기준으로 최적일 수 없다고 판단될 때, 기대 최적 온도 제어기를 통해 하우스 최적화 시간을 계산한다. 최적 온도 제어기는 계산된 시간 직후에 제어 메시지를 하우스 관리부로 보내서 하우스 관리부가 하우스 최적화를 시작하도록 한다.

1.1. 하우스 상태 결정부

하우스 상태 결정부는 그림 2와 같이 기대 최적 온도 예측기(Optimized temperature predictor)와 기대 최적 온도 제어기(Optimized temperature processor)로 구성되어 있다. 기대 최적 온도 예측기를 통해 기대 최적 온도를 예측하고 기대 최적 온도 제어기를 통해 그린 하우스가 기대 최적 온도로 도달할 수 있도록 최적화한다.

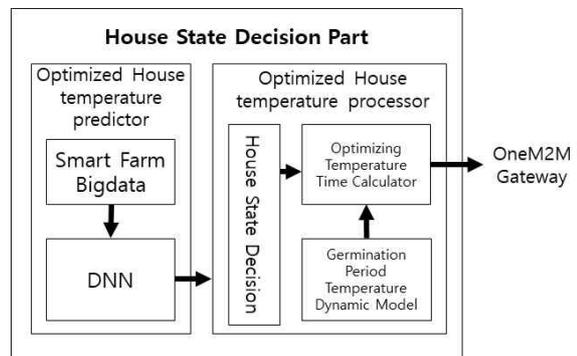


Fig 2. The structure of the green house state decision part
그림 2. 그린하우스 상태 결정부 구성도

1.1.1 기대 최적 온도 예측기

기대 최적 온도 예측기는 *Multilayer Perceptron* 알고리즘으로 스마트팜 데이터셋을

학습하고 그 결과를 이용하여 새로운 실외 온도와 실외 습도 데이터가 입력되면 기대 최적 온도를 예측하는 과정이다.

```

Algorithm 1. Optimized House Temperature Predictor


---


Input :
    Train_data : Smart Farm Dataset Array
    Test_data : Test_data Array
Output :
    Data_prediction : Predicted Optimizing Temperature
Algorithm :
    POT_prediction(Train_data, Test_data)
    {
        POT_predictor = multilayerPerceptron();
        POT_predictor.setLearningRate(0.1);
        POT_predictor.setTrainingTime(10000);
        POT_predictor.setHiddenLayers("3");
        POT_predictor.buildClassifier(Train_data);
        data_prediction =
            POT_predictor.classifyInstance(Test_data);
        return(Data_prediction);
    }
    
```

Fig 3. The algorithm of the optimized temperature predictor
 그림 3. 기대 최적 온도 예측기 알고리즘

그림 3은 *Multilayer Perceptron*으로 데이터셋을 학습하고 기대 최적 온도를 예측하는 알고리즘이다. 31070개의 데이터를 10000번 학습하였고 Learning Rate는 0.1, Hidden Layer는 3개로 DNN을 구성하여 기대 최적 온도 예측 모델을 만들었다. 실제 실외 환경 및 시간을 기대 최적 온도 예측 모델에 입력하여 기대 최적 온도를 예측하고 예측된 값을 기대 최적 온도 제어기로 전송한다.

1.1.2. 기대 최적 온도 제어기

기대 최적 온도 제어기는 기대 최적 온도 예측기가 전송한 기대 최적 온도와 실제 그린 하우스의 실내온도를 비교하여 그린 하우스의 상태를 판단하고 하우스 최적화가 시작해야하는 시간을 계산하여 그 시간에 제어 메시지를 oneM2M Gateway로 전송한다. 이런 과정을 위해 기대 최적 온도 제어기는 상태결정부(State Decision), 하우스 온도 변화 물리 모델(Germination Period Temperature Dynamic Model) 그리고 하우스 최적화 시간 계산부(Optimizing Temperature Time Calculator)로 이루어져 있다.

Algorithm 2. Optimized Temperature Processor

```

Input :
    Predicted_data : Predicted Optimizing House Temperature
    Real_data : Real House Temperature Data
    Outside_data : Outside Temperature and Humidity Data
Output :
    Control_state : control message data
Algorithm :
    POT_Processor(Predicted_data, Real_data, Outside_data)
    {
        state = House_State_Decision(POT, Real_data);
        if state == 1 then
        {
            house_dynamic_data =
                GPTDM(Outside_data, Real_data);
            optimizing_duration =
                OTP(house_dynamic_data, difference_temp);
            send_control(optimizing_duration, state);
        }
        endif
    }
    
```

Fig 4. The algorithm of the optimized temperature processor

그림 4. 기대 최적 온도 제어기 알고리즘

그림 4는 기대 최적 온도 제어기의 알고리즘을 보여준다. 입력값으로 기대 최적 온도(Predicted_data), 실제 그린 하우스 내부 온도(Real_data), 실외 환경 데이터(Outside_data)를 받는다. 상태결정부를 통해 하우스 최적화가 필요하다고 판단되면 하우스 온도 변화 물리 모델을 이용하여 그린 하우스 실내의 온도가 1시간 뒤에 기대 최적 온도로 도달하기 위해 필요한 하우스 최적화 시간을 계산한다. 그 결과 계산된 시간 이후에 최적 온도 제어기는 oneM2M Gateway로 제어 메시지를 보내 하우스 관리부가 그린 하우스의 창문을 제어하게 한다.

가. 하우스 상태결정부

상태결정부는 기대 최적 온도 예측기로부터 받은 기대 최적 온도를 실제 그린 하우스 실내 온도와 비교하여 하우스 최적화의 실행 유무를 판단한다. 그림 5는 하우스 상태 결정부의 알고리즘이다. 실제 그린 하우스 내부 온도와 기대 최적 온도의 차이값을 계산하여 기대 최적 온도까지 떨어져야하는 ‘실내 그린 하우스 온도차(difference_temp)’를 계산한다. 실내 그린 하우스 온도차가 0.5보다 작거나 -0.5보다 크면 1시간 뒤 예상되는 그린 하우스의 실내온도는 최적의 상태라고 판단하여 변화를 주지 않는다. 하지만 실내 그린 하우스 온도차가 0.5 크거나 -0.5보다 작으면 1시간 뒤 예상되는 그린 하우스의 실내 온도는 최적의 상태가 되기 어렵다고 판단한다.

따라서, 하우스 최적화가 필요하기 때문에 하우스 최적화를 동작시킬 수 있도록 변수(*Control_state*)를 1로 초기화 시킨다.

```

Algorithm 3. House State Decision


---


Input :
    Predicted_data : Predicted Optimizing House Temperature
    Real_data : Real House Temperature Data
Output :
    Control_state : control message data


---


Algorithm :
state_decision(Train_data, Test_data)
{
    difference_temp = real_data - Predicted_data;
    if difference_temp < 0.5 || difference_temp > -0.5 then
        Control_state = 0;
    else
        Control_state = 1;
    endif
    Return(control_state);
}
    
```

Fig 5. The algorithm of house state decision
그림 5. 하우스 상태결정부 알고리즘

나. 하우스 온도 변화 물리 모델

하우스 온도 변화 물리 모델은 밀폐되어 있는 그린 하우스에서 창문을 이용하여 외부 공기가 내부로 유입됐을 때 일어나는 그린 하우스의 실내 온도 변화량을 계산할 때 사용한다. 모델에 사용되는 변수들은 표 1과 같다. 계산한 변화량은 그린 하우스에서 하우스 최적화가 진행될 때, 진행되어야 하는 시간을 계산할 때 사용된다. 모델에서 사용하는 식은 식 1과 같다 [12].

$$\frac{dT_i}{dt} = \frac{1}{C_g} (\delta G + K_h (T_p - T_i) + K_s (T_s - T_i) + K_v (T_0 - T_i) + K_r (T_0 - T_f)) \quad (1)$$

하우스 온도 변화 물리 모델을 이용하여 해가 있는 날과 없는 날의 실제 온도와 모델을 통해 예측된 온도를 [12]에서 비교하였다. 그 결과 예측된 값이 실제 온도를 잘 따라가고 있어 신뢰할만하다고 할 수 있다 [12].

Table 1. The germination period temperature dynamic model parameters

표 1. 하우스 온도 변화 물리 모델 변수

symbol	symbol significance	Parameter value	unit
--------	---------------------	-----------------	------

ρ_g	air density	1.29	$\text{kg}\cdot\text{m}^{-3}$
V_g	greenhouse capacity	1036.8	m^3
C_g	air specific heat at constant pressure	1.01	$\frac{\text{J}\cdot\text{Kg}^{-1}}{\text{K}^{-1}}$
δ	radiation conversion factor	0.7	
G	average energy of solar radiation at time t	-	$\text{W}\cdot\text{m}^{-2}$
K_h	heating pipe coefficient	2.1	$\frac{\text{W}\cdot\text{m}^{-2}}{\text{C}^{-1}}$
K_s	oil heat transfer coefficient	5.7	$\frac{\text{W}\cdot\text{m}^{-2}}{\text{C}^{-1}}$
K_v	roof and cover material coefficient of heat transfer	7.9	$\frac{\text{W}\cdot\text{m}^{-2}}{\text{C}^{-1}}$
T_p	heating pipe temperature	-	C
T_s	soil temperature	-	C
T_o	outdoor temperature	-	C
Φ_b	hot-pressing ventilation	-	$\frac{\text{W}\cdot\text{m}^{-2}}{\text{C}^{-1}}$
Φ_v	wind pressure ventilation	-	$\frac{\text{W}\cdot\text{m}^{-2}}{\text{C}^{-1}}$
C_f	flow coefficient	0.6	K^{-1}
β	air coefficient of expansion	-	m
L_o	skylight length	10	m
V_w	Wind speed	-	m/s

다. 하우스 최적화 시간 계산부

하우스 상태결정부로부터 하우스의 실내온도를 내려야 한다고 판단된 후 하우스 최적화 시간 계산부는 기대 최적 온도까지 하우스 최적화를 했을 때 걸리는 시간을 계산한다. 그림 6은 하우스 최적화 시간 계산부의 알고리즘이다.

```

Algorithm 3. Optimizing Time Calculator


---


Input :
    house_dynamic_data : temperature change per second
    difference_temp : difference between predicted and real temperature
Output :
    optimizing_duration : control message data


---


Algorithm :
OT_Calculator(Train_data, Test_data)
{
    optimizing_duration = difference_temp / house_dynamic_data;
    Return(optimizing_duration);
}
    
```

Fig 6. The algorithm of the optimizing time calculator
그림 6. 하우스 최적화 시간 계산부 알고리즘

하우스 상태 결정부에서 계산한 ‘실내 그린 하우스 온도차 (*difference_temp*)’와 하우스 온도 변화 물리 모델을 이용해서 계산한 ‘온도변화율

(*house_dynamic_data*)'을 이용하여 '최적화 수행 시간(*optimizing_duration*)'을 도출한다. 그 후, *difference_temp*를 *house_dynamic_data*로 나눔으로써 기대 최적 온도까지 실제 그린 하우스 온도가 도달하기 위한 '최적화 수행 시간(*optimizing_duration*)'을 계산한다. 그 다음, 계산된 *optimizing_duration*만큼 시간이 흐르고 제어 메시지를 oneM2M Gateway로 보낸다.

IV 실험 및 분석

1. 실험의 전제조건 및 가정

효과적인 시뮬레이션을 위해서 본 연구의 실험에서는 몇가지 전제조건을 가정한다. 첫째, 학습한 데이터는 현재 스마트팜을 운영하고 있는 곳에서 측정된 데이터이다. 따라서, 스마트팜 데이터셋을 충분히 신뢰할만하다고 판단할 수 있다. 둘째, 본 연구의 시뮬레이션에서 밀폐된 공간에서의 실내온도는 변하지 않는다고 가정한다. 또한 실외의 공기를 이용하여 실내의 온도를 제어하기 때문에 실외 온도가 실내온도 보다 낮은 상황에서만 실험을 한다. 셋째, 본 연구의 실내 온도 변화량을 측정할 때는 [12]에서 가정한 주변 환경을 이용하여 실험하였다. 넷째, 창을 개폐하는데 사용한 모터의 소비전력은 20W, 팬은 320W 그리고 에어컨은 6kW로 가정한다. 다섯째, 사용한 데이터는 4월의 데이터이기 때문에 시뮬레이션 또한 4월이라는 가정에서 실행한다. 마지막으로, 본 연구는 효율적으로 스마트팜 실내의 온도를 낮추는 방법에 대해 연구했기 때문에 실내 온도를 올려야 하는 경우에 대해서는 고려하지 않았다.

2. 모델의 정확도

본 논문에서는 스마트팜코리아에서 제공하는 농가 데이터셋을 이용하여 학습한 모델이 1시간 후의 적절한 온도를 도출해낼 수 있는지 두 번의 실험을 통해 확인하였다. 모델의 정확도를 확인하기 위해 사용된 테스트 자료는 스마트팜코리아의 데이터 중에서 학습하지 않은 데이터를 이용하였다. 먼저 같은 시간의 실외 온도, 실외 습도 그리고 실내 온도를 학습한 모델을 이용하여 실제 실내 온도와 예측한 실내 온도의 정확도를 확인했다. 그 결과 그림 7과 같은 그래프를 확인할 수

있었다. 실제 온도와 예측된 온도의 오차율이 3~7%이다. 따라서 설계한 DNN모델은 실내온도를 신뢰할 수 있게 예측한다는 것을 확인했다.

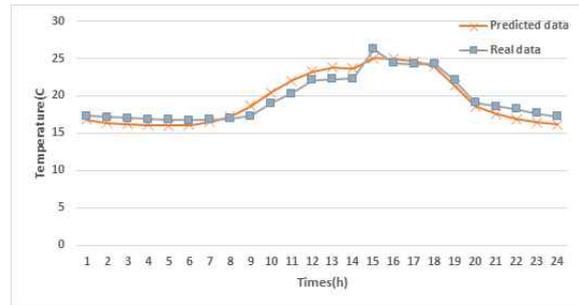


Fig 7. The optimizing temperature predictor accuracy at the same time

그림 7. 동일시간 최적 온도 예측 모델 정확도

다음으로 앞서 사용한 데이터 중 실내 온도를 다른 데이터보다 1시간 늦게 입력하여 데이터셋을 다시 만들었다. 이 데이터 셋을 이용하여 설계한 DNN모델을 학습시켰다. 설계한 DNN모델을 이용하여 1시간 후의 적절한 실내온도를 예측해 보았다. 그림 8의 그래프는 실제 실내 온도와 예측된 1시간 후의 실내온도를 비교하고 있다. 그 결과 DNN모델을 이용하면 1시간 후의 온도를 최대 7%의 오차율로 예측하는 것을 알 수 있다. 그 그래프에서도 알 수 있듯이 Predicted data 그래프가 Real data 그래프의 양상을 유사하게 따라 가는 것을 확인할 수 있었다.

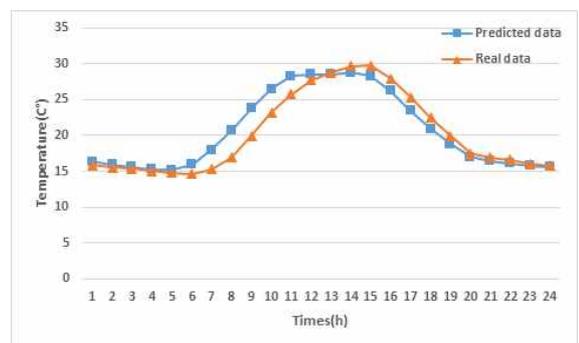


Fig 8. The optimizing house model accuracy

그림 8. 하우스 최적화 모델 정확도

3. 시뮬레이션 결과

같은 테스트 데이터와 알고리즘을 이용하여 비교한 창과 에어컨의 전력소비는 그림 9와 같은 차이를 보였다. 시뮬레이션 중 창문을 열고 닫는데 총 302번 동작했다. 한번 동작하는데 0.167W가

소비되므로 총 소비 전력은 50.4W이다. 반면 팬의 경우 150번에 걸쳐 55분 동안 동작하여서 295.2W의 전력이 소모되었고, 에어컨의 경우 183분 동안 동작하여 11,020W가 소모되었다. 그 결과 팬을 사용했을 때 전력소모의 83%의 전력소모 절약을 할 수 있다는 것을 확인했다. 계절의 특성상 실외 온도가 에어컨 설정온도보다 낮을 때 팬의 효율성이 에어컨의 효율성보다 우수함을 확인할 수 있다.

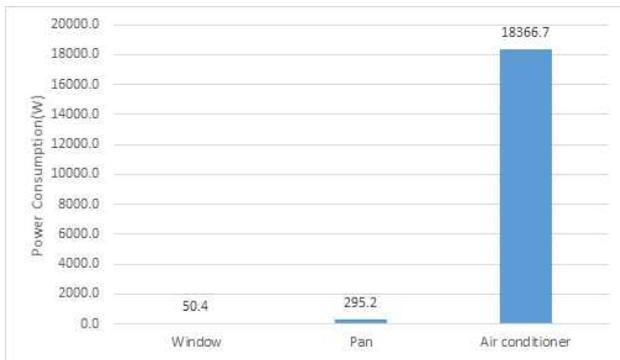


Fig 9. The comparison of power consumption of the temperature control devices

그림 9. 온도 제어기기들의 에너지 소모량 비교

IV 결론

본 연구에서는 스마트팜의 빅데이터를 이용하여 딥 러닝 모델을 학습시키고 실시간으로 날씨 정보를 기상청에서 받아와서 1시간 후의 실내 온도를 예측하여 자동으로 창문을 개폐함으로써 에어컨이나 팬을 이용한 방법보다 전력소모가 적은 지능형 그린하우스 제어 시스템을 제시하였다. 실내온도를 예측하기 위해 DNN을 이용하여 학습모델을 만들었고 실제 스마트팜 데이터를 이용하여 모델의 정확도를 테스트하여 3~8%의 오차율을 얻었다.

본 연구에서 제시한 시스템의 성능을 검증하기 위해 팬, 에어컨 그리고 창문을 이용하는 스마트팜 시스템의 전력소모량을 비교하였다. 팬과 에어컨을 이용하여 실내온도를 제어하는 방법은 기존의 스마트팜 시스템의 기능을 참고하여 같은 시간의 최적온도를 예측하여 실내온도를 제어하는 방법을 사용하였다.

본 연구에서 제시한 방법은 기존의 시스템보다 전력소모측면에서 83%의 전력 감소 성능을 보여

효율성이 높다는 것을 검증하였다. 비록 여름이나 겨울같이 온도가 극단적으로 높거나 낮은 상황에서는 창문을 제어하는 것이 불필요하지만, 그 외의 상황에서는 충분히 높은 효율성을 보일 것으로 판단된다. 따라서, 생산비 절감으로 인한 농가의 소득증가에 도움이 될 것으로 예상된다.

References

[1] C. O. Um, K. U. Roh and S. W. Park, "A study on the mitigation of rural areas manpower shortage through the city-rural circulation model - based on the case of Kimcheon-", *Journal of Regional studies*, vol.21, no.3, pp. 149-166, 2013.

[2] Statistics Korea, 2017 Elderly person statistics

[3] Statistics Korea, 2015 Agricultural Census

[4] Ministry of Agriculture, Food and Rural Affairs, "e-index of korea," http://www.index.go.kr/potal/main/EachDtlPageDetail.do?idx_cd=2745

[5] Korea Agency of Education, Promotion and Information Service in Food, Agriculture, Forestry and Fisheries, "Smart Farm," <http://www.smartfarmkorea.net/contents/view.do?menuId=M01010102>

[6] S. Tenzin, S. Pobkrut, T. Pobkrut and T. Kerdcharoen, "Low cost weather station for climate-smart agriculture," *2017 9th International Conference*, 2017, pp. 172-177.DOI: 10.1109/KST.2017.7886085

[7] H. K. Kim, J. G. Jeon, L. Baek, H. Y. Pyo, J. Y. Jeong, Y. C. Kim, "Analysis of Temperature Changes in greenhouses with Recirculated Water Curtain System," *Protected Horticulture and Plant Factory*, vol.24, no.2, pp.93-99, 2015.DOI: 10.12791/KSBEC.2015.24.2.093

[8] NARETREND, "Nare," <http://www.xspark.co.kr/eng/system/smartfarm.php>

[9] O. Chiochan, A. Saokaew, and E. Boonchieng, "IoT for smart farm: A case study of the Lingzhi mushroom farm at Maejo University." *2017 14th International Joint Conference*, pp 1-6, 2017.DOI: 10.1109/JCSSE.2017.8025904

- [10] P. J. Kia, T. Far, M. Omid, R. Alimardani, and L. Naderloo, "Intelligent control based fuzzy logic for automation of greenhouse irrigation system and evaluation in relation to conventional systems," *World applied science journal*, vol.6, no.1, pp. 16-23, 2009
- [11] J. R. dela Cruz, R. G. Baldovino, A. A. Bandala and E. P. Dadios, "Water usage optimization of Smart Farm Automated Irrigation System using artificial neural network.," *2017 5th International Conference*, pp 1-5, 2017.DOI: 10.1109/ICoICT.2017.8074668
- [12] Z. Yao, Z. Xu, S. Du, "Optimal control based on temperature dynamic model of greenhouse crop germination period.," *2013 Fourth International Conference*, pp.267-270, 2013.DOI: 10.1109/ICICIP.2013.6568080

BIOGRAPHY

Hyeonyeop Kim (Member)

2018 : BS degree in
Computer Engineering,
Koreatech University
2018~ : Course of MS degree
in Computer Engineering,
Koreatech University

Hyokyun Yim (Member)

2018 : BS degree in
Computer Engineering,
Koreatech University
2018~ : TI Platform
Researcher, Hansol Secure

Won-Tae Kim (Member)

1994 : BS degree in
Electronics Engineering,
Hanyang University
1996 : MS degree in
Electronics Engineering,
Hanyang University
2008 : PhD degree in
Electronics Engineering, Hanyang University
2001~2005 : CTO, Rostic Technologies Inc.
2005~2015 : CPS Team Manager, ETRI
2015~ : Assistant professor, Koreatech
University