creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학석사 학위논문

CNN 온도 예측 모델 기반의 단동 온실 온도 제어기술 개발

Development of Single-span Greenhouse Temperature Control Technology Based on CNN Temperature Prediction Model

2022 년 8 월

서울대학교 대학원

바이오시스템공학과

이 윤 홍

CNN 온도 예측 모델 기반의 단동 온실 온도 제어기술 개발

지도 교수 김 학 진

이 논문을 공학석사 학위논문으로 제출함
2022년 6월

서울대학교 대학원
바이오시스템공학과
이 윤 홍

이윤홍의 공학석사 학위논문을 인준함
2022년 8월

위 원 장 _____ 이 중 용 _____ (인)

부위원장 _____ 김 학 진 _____ (인)

위 원 _____ 정 대 현 _____ (인)

초 록

온실은 작물 재배를 위한 최적의 환경을 조성해 줄 수 있다는 장점이 있지만 이상적인 재배환경을 만들기 위해서는 세심한 관리가 필요하다. 작물들이 생육 적온을 벗어난 고온 또는 저온의 환경에 장시간 노출되면 스트레스를 받거나 질병에 걸리게 되고 이는 최종적으로 생산성 저하로 이어지게 된다. 특히 지구 온난화로 인해 폭염이나 폭설 같은 기상이변이 자주 발생하면서 급격하게 변화하는 외부기상에 대응할 수 있는 온실 제어 기술 개발의 필요성이 증가하고 있다.

본 연구에서는 온실 내외부 기상 데이터를 기반으로 온실 내부 온도 변화를 예측하고 이를 온실 제어에 활용함으로써 외부 기상의 변화에 대응하여 생육 적온을 유지하는 온실 제어 기술을 개발하였다. 인공 신경망 기법 중 하나인 convolutional neural network (CNN)을 이용하였으며 내부온도, 내부습도, 내부 CO_2 농도, 외부온도, 외부습도, 일사량, 풍속, 풍향, 시간 총 9가지 요인들을 입력으로 하여 30분뒤 온실 내부온도 변화를 예측하는 모델을 개발하였다. 예측 모델은 수원에 위치한 서울대학교 부속 농장의 단동형 비닐온실에서 관측된 4월, 11월, 1월의 계절별 데이터를 사용하여 개발하였다.

예측 모델을 통해 출력되는 예측 온도를 제어에 활용하기 위해 Message Queueing Telemetry Transport (MQTT) 통신을 활용하여 실시간 온도 변화 예측 시스템을 구성하였다. 실시간으로 예측되는 30분뒤 온도를 제어에 적용하기 위해 국내 단동형 온실에서 쓰이는 proportional band(P-band) 제어식에 예측온도와 목표온도의 차이를 고려하는 예측 제어 계수 K_p를 더하여 예측 제어식을 개발하였다. 제어 대상으로는 환기 팬, 천창, 측창, 온풍기, 다겹 보온 커튼이 있으며 환풍기와 온풍기는 작동시간을 천창, 측창, 다겹 보온 커튼은 열림 정도를 비례적으로 제어하였다. 목표온도는 온실 재배 작물 중 하나인 방울 토마토의 생육 적온인 17-27 ℃로 설정하였다.

개발된 제어식의 예측 제어 계수 K_p값의 정도에 따라 예측 온도의 영향을 실험하고자 Kp값을 0.1, 0.2, 0.3으로 늘려가며 각각 이틀씩 제어하였고 예측 제어의 성능을 비교하고자 하였다. 실험 결과, 각각의 예측 제어 계수 0.1, 0.2, 0.3은 목표온도를 기준으로 각각 평균제곱근오차(RMSE) 3.2℃, 2.7℃, 2.0℃를 보였고 예측 제어 계수가

증가함에 따라 평균제곱근오차가 줄어들었다. 본 연구에서 개발된 예측 모델을 적용한 예측 기반 제어 실험 결과, 실시간으로 온도 변화 예측이 가능함을 보였고 온실 제어 또한 내부 온도 변화를 미리 알고 대응하여 제어함으로써 목표온도를 추종할 수 있음을 보였다.

주요어 : 단동형 온실, 온실 온도 제어, 온도 예측, CNN, 예측 기반 제어
학 번 : 2020-24303

목 차

1. 서 론 1
1.1. 연구 배경 1
1.2. 연구 목적 3
1.3. 문헌 조사 4
1.3.1 온실 대기환경 관련 연구 4
1.3.2 인공지능 기반의 온실 연구 6

2. 재료 및 방법 8
2.1. 실험 온실 시스템 구성 8
2.1.1. 요인 실험 온실 8
2.1.2. 냉난방기 구성 11
2.1.3. 센서 및 데이터 취득 구성 14
2.1.4. IoT 원격 통신 구성 16
2.2. 예측기반 온도 제어 17
2.2.1. CNN 예측 모델 17
2.2.2. 학습데이터별 예측 모델 개발 18
2.2.3. P-band 제어 19
2.2.4. 예측 기반 제어 알고리즘 19
2.2.5. 실시간 제어 구성 20
2.3. 실험 및 평가 21
2.3.1 실시간 예측 성능 평가 21
2.3.2 예측기반 실시간 제어 성능 평가 22

3. 결과 및 고찰 23
3.1. 학습 데이터별 온도 예측 모델 성능 23
3.2. 실시간 온도 예측 성능 24
3.3. 상용제어와 예측제어 성능 비교 분석 25
3.4. 실험 온실에서의 예측 제어 기술 검증 및 성능 평가 29
3.4.1. 예측제어 계수에 따른 온도 제어 성능 평가 29

4. 결 론 33

참고문헌 34

Abstract 38

표 목차

Table 1. The specification of Raspberry Pi 3.0 model B+ .. 9
Table 2. Time slots for the greenhouse climate control operation and the target temperature for each time slot 11
Table 3. The specification of ventilation motor and fan 13
Table 4. The specification for heater and heating curtain motor 14
Table 5. The specification of the Vantage Pro 2 weather station 15
Table 6. The specification of the SH-VT260 sensor detecting temperature and humidity and CO_2 16
Table 7. Greenhouse actuators and maximum operating time 21
Table 8. CNN based temperature prediction model performance according to different data set 23
Table 9. RMSE and overshoot and undershoot of prediction-based control according to prediction coefficient K_p2... 31

그림 목차

Figure 1. Monitoring sensors and environmental control actuators included in the greenhouse 8
Figure 2. Features of the Raspberry Pi 3.0 model B+ 9
Figure 3. A design drawing of growing bed. 10
Figure 4. Inside of the single-span greenhouse. (a) Control space, (b) experimental space 10
Figure 5. Greenhouse temperature control profile for each time slots 11
Figure 6. Greenhouse heating and cooling system 12
Figure 7. Overview diagram of the IoT based control system 15
Figure 8. Vantage Pro 2 (Davis Instruments, USA) 15
Figure 9. SH-VT260 (Soha-tech, KR) 16
Figure 10. Node-RED control interface 17
Figure 11. Node-RED dashboard 17
Figure 12. An overview of a convolutional neural network (CNN) architecture 18
Figure 13. Overview of the real-time prediction system ... 21
Figure 14. Real-time prediction performance results (2/16 to 2/20) 24
Figure 15. Real-time prediction performance results (4/9 to 4/14) 24
Figure 16. Outside temperature from 4/9 to 4/14 25
Figure 17. Radiation from 4/9 to 4/14 25
Figure 18. Conventional P-band control in 4/9 26
Figure 19. Prediction based control in 4/19 (Kp=0.1) 26
Figure 20. Outside temperature condition in the experiment (4/9 and 4/19) 27
Figure 21. Roof ventilation window control history (4/9, 4/19) 28
Figure 22. Side curtain control history (4/9, 4/19) 28
Figure 23. Prediction based control (Kp=0.1, 4/27 to 4/28) 30
Figure 24. Prediction based control (Kp=0.2, 4/29 to 4/30) 30
Figure 25. Prediction based control (Kp=0.3, 5/1 to 5/2) .. 30
Figure 26. Changes in outside environmental conditions in the experiment 32

1. 서 론

1.1. 연구 배경

세계적으로 극심한 기상이변, 자연재해 그리고 물 부족과 같은 문제가 나타나고 있고, 이는 농업사회에 큰 문제로 다가오고 있다. 특히, 앞서 언급한 환경 문제들을 직접적인 영향을 받는 노지 농업의 경우 점점 작물 생산에 있어서 안정성을 잃어가고 이는 전 국가적인 식량안보에 큰 위협이 될 수 있다. 이러한 기후변화에 대응하여 안정적인 농업 생산량 유지 및 식량안보의 대책으로 스마트 팜 시설 농업에 대한 관심이 증가하고 있다.

스마트 온실은 노지 재배와는 다르게 작물의 생육 및 생리에 필요한 환경들을 임의로 조성해 줄 수 있다는 특성을 이용하여 기후 변화에 취약한 노지재배 대비 연중 안정적인 생산을 가능하게 한다. 또한, 설치된 센서와 외부기상대로부터 온도, 습도, 일사량, CO_2 등 각종 요인들의 측정을 통해 제어를 자동으로 수행하기 때문에 노동력 또한 절감할 수 있다. 스마트 온실에는 다양한 기술들이 종합적으로 접목되어 있는데, 그 중에서도 환경 제어 기술은 매우 중요하다. 온실 내부의 경우 온도, 습도, 일사량, CO_2 와 같이 작물의 생장에 영향을 미치는 요인들이 복합적으로 작용하고 있고 각 요인들은 서로에게 영향을 미치기에 이러한 환경을 잘 조절해주는 것이 스마트 온실에 있어서 핵심 기술로 여겨진다.

원예기술 및 온실 관리 기술에 있어 세계적으로 유명한 회사 중 하나인 네덜란드의 Priva는 지난 수 십년간 취득한 자국의 여러 농가 데이터를 이용한 환경 제어 알고리즘을 운용한다. 하지만 이러한 경험식 기반의 제어는 국내의 경우 축적된 데이터가 없기에 실정에 맞지 않다. 국내의 온실 환경 제어는 농촌진흥청의 계획하에 보급되고 있는 국내 비닐하우스 여건과 농가 규모에 적합한 정보통신기술을 적용하여 편의성 향상 중심의 온실 환경제어 기술이다.

기존에 온실의 거동을 이해하기 위해 수행된 국내외 연구들은 주로 에너지균형식 또는 질량균형식 기반의 동적 모델을 이용하여 온실 전체에서 일어나는 열적 거동의 평형을 유지하는 방향으로 연구가 이루어져왔다. 물리학적 평형을 맞추는 식의 연구는 가시적으로 이해하기 쉽고 전체적인 온실 내 요인들의 거동을 알 수 있다는 이유에서 활발히 연구가 진행되었지만 그 소득은 미비했다. 그

이유인즉슨, 온실 내에는 현재의 기술로는 측정이 불가하여 그 정확한 값을 알 수 없는 토양 복사열 또는 온실 필름의 광 투과율과 같은 요인들 존재하기 때문에 해당 요인들은 대략적으로 값을 추정하여 모델식에 적용할 수밖에 없고 이로 인해 모델의 정확도가 떨어진다. 이와 같은 이유로 열 평형 기반의 모델식은 실제 온실에 적용하기가 쉽지 않다.

최근에 컴퓨터기술의 발전에 힘입어 활발히 연구되는 온실 제어 방법 중 하나는 인공지능을 이용한 예측 제어이다. 실제 온실에 적용되기 힘들었던 열 평형식 기반의 모델링이 가진 한계를 해결할 수 있으며 빅 데이터를 이용하여 그 정확도를 높일 수 있어 최근 많은 연구들이 진행되고 있다. 또한 종래의 복합 환경제어기의 문제점으로 지적되던 과도응답상태, 즉 센서에 의해 작물의 생육환경을 벗어났다고 판단하고 제어하는 시점에는 이미 작물이 적절치 못한 환경에 노출되고 있는 현상에 대해서도 인공지능 기반의 예측제어가 해결책이 될 수 있다.

농촌진흥청 스마트 온실환경관리 가이드라인(2018)의 정보에 따르면 작물의 생리 반응은 복잡한 물리화학적 반응이며 온도의 영향을 가장 많이 받는다고 한다. 작물의 생육이 가장 왕성한 온도를 생육 적온이라 하는데 적온을 벗어날 경우 고온 또는 저온의 장해를 입는다.

토마토의 경우 생육적온이 27 ℃로 권장되는데 30 ℃이상의 고온에 노출되면 호흡에 의한 양분 소비가 많게 되어 생육이 나빠지고, 35 ℃가 넘어가게 되면 꽃에 장해가 발생하여 기형과의 원인이 된다. 이렇듯 작물의 최적 생육 온도를 벗어나게 되면 생육 및 생식에 문제가 발생하게 되고 최종적으로 생산성 하락으로 이어진다. 따라서 기존의 센서 정보에 의해서 피드백 제어를 하던 상용제어는 작물에게 고온의 환경에 노출될 위험이 존재하므로 인공신경망을 통해 온도 변화를 미리 감지하고 변화에 대응하여 제어를 해야 한다.

1.2. 연구 목적

본 연구의 목적은 급격하게 변화하는 외부기상에 대응하여 온실 내부 온도 변화를 미리 예측하고 온실 내 최적의 작물 생육 환경을 조성할 수 있는 온실 제어 기술을 개발하는 것이다. 구체적인 목적은 다음과 같다.

1) CNN 기반의 온실 내부 온도 변화 예측 모델 개발

2) 온도 예측 기반의 예측 제어 알고리즘 개발

3) 온실 내 실시간 제어 성능 평가

본 연구에서는 internet of things(IoT) 기반의 원격통신이 가능한 실험 온실이 설계되었고 온실 내부 온도 변화를 예측하기 위해 인공신경망 기법 중 하나인 convolutional neural network (CNN)을 활용하였다. 모델 학습에 쓰이는 입력 데이터로는 시간, 내부온도, 내부습도, 내부 CO_2, 외부온도, 외부습도, 일사량, 풍속, 풍향의 9가지 요인들이 사용되었고 작동기의 동작 시간과 그에 대한 영향이 나타나기까지의 시간을 고려하여 30분 뒤의 온실 내부 온도를 예측하게 된다. 본 연구에서 개발된 예측 모델을 통해 얻어지는 30분 뒤 온도를 상용 proportional band (P-band) 제어에 반영함으로써 온실 내부 온도 변화를 미리 알고 각 작동기들의 동작 시간을 결정하였다. 이를 통해 급격하게 변화하는 외부 기상에 대응하여 제어가 가능함을 밝히고, 작물이 필요로 하는 목표 온도 값을 잘 추종하였는지 검증하였다. 최종적으로는 작물에게 가해지는 고온, 저온 스트레스를 줄이고자 하였다.

1.3. 문헌 조사

1.3.1. 온실 대기환경 관련 연구

Körner 등(2008)은 에너지 절감과 작물의 성장 두 가지 요소를 고려하여 온실 내 작동기 제어 전략을 일주일 단위로 최적화하였다. 사용자로 하여금 에너지 소비에 중점을 둘 것인지 작물의 성장에 초점을 둘 것인지 결정할 수 있는 테이블을 제시하였다. 고정된 온습도 설정값으로 제어를 하는 blue print (BP), temperature integration Nested 24 hours (TI_{24}) and 6 days (TI_n) 그리고 DIF (=difference between average day and average night temperature)의 조합을 통해 온실을 운영하는 이로 하여금 1년, 48주 동안의 제어 방향성을 제시하고 있다.

Gruber 등(2011)은 자연환기를 이용한 비선형 MPC 기반의 온실 온도 제어 모델을 개발하였다. 해당 실험을 통해 온실 내부 온도와 환기 비율의 상관관계가 이중선형적인 관계이고 온도와 제어 신호에 있어서는 높은 비선형성을 띄는 것을 확인했다. second-order volterra series 모델에 측창과 천창의 작동, 그리고 외부기온, 풍속, 지표면 온도, 일사량을 고려하여 실험을 진행했고, 실험을 통해 제시된 제어 전략을 실제 온실에 적용해본 결과 원하는 기준 값에 도달하는 모습을 보였다.

Chen 등(2018)은 건물 내에서 heating, ventilation and air cooling (HVAC) 시스템과 같이 쓰이는 자연환기의 작동 조건이 명확하지 않음을 명시하고 최적의 제어 전략을 산출하는 model-free Q-learning을 통해 건물 내 최적의 온습도 및 에너지 소모도를 최소화하는 창 개폐 시스템을 개발하였다. 최적화되지 않은 작동기 조건으로 인해 경험기반의 제어는 불필요한 작동기들의 작동을 일으켰고 이는 곧 에너지 소모를 유발했다. 자연환기와 공조시스템의 냉방방식 두 가지를 결합하여 나오는 작동기의 조건을 각각 Miami와 Los Angeles의 다른 환경에서 시뮬레이션을 수행하였다. 시뮬레이션의 세부사항으로 목표온도는 24.5 ℃, 내부습도 70 % 이하(1년간 낮, 밤 모두)였으며 한 시간 단위의 일 년간 기상데이터를 사용했고 제어는 20분 간격으로 수행되었다. 경험 기반의 heuristic control과 학습 기반의 강화학습을 비교하였고 그 결과 강화학습이 온도 유지 측면에서 변동의 폭이 적어 안정성이 더 높았으며, Miami는 약 19 %, Los Angeles는 23 %의 에너지 절감률을 보였다. 건물 내에서의 자연환기를 이용한 냉방제어 작동기 조건을 최적화한 연구 사례를 보아 온실에서의 천창, 측창 작동의 조합에서도 강화학습을 통해 최적의 제어 전략을 산출할

가능성을 보였다.

Tchamitchian 등(2005)은 일반 온실 대기 환경 최적화 문제에 있어 강화학습이 적용될 수 있는가를 밝히고자 했다. 실험 대상으로는 장미를 선정하여 생물학적으로 다르게 취급을 해야 하는 장미의 성장과 꽃의 발달 2가지 측면 모두 만족시키는 동시에 일중 난방비용을 줄이는 방향으로 실험을 진행했다. 강화학습은 주어진 상황에서 주변의 환경과 상호작용하면서 시행착오를 거쳐 보상을 최대화하는 방향으로 구조가 짜이게 된다. 실험 결과 강화학습은 불확실한 외부 환경에 대해서 최적의 정책을 찾게 설계가 되었고 이러한 구조는 미래로 예상되는 환경이 아닌 주어진 환경에서 최적의 해를 찾던 기존의 최적화 기법보다 더 장점이 있을 것으로 결론지었다.

Wang 등(2020)은 온실 산업이 직면한 자동 제어 문제를 강화학습을 통해 해결하고자 했다. 강화학습은 이러한 의사결정 자동화 문제에 있어서 강력한 해결책으로 사용된다. 본 연구에서는 오이 농장의 대기 환경 조성에 있어서 강화학습을 통해 자동 제어를 수행하고자 한다. 기존의 머신러닝 기법에서는 2가지 문제점이 드러나는데 첫 번째는 기존 머신러닝은 현재의 보상만을 고려한다는 점, 두 번째는 하나의 제어 변수만을 고려한다는 점이다. 하지만 작물의 성장은 하나의 요인이 아니라 여러 가지 요인들이 복합적으로 얽혀 있다. 위의 머신러닝 기법의 문제점을 해결하기 위해 강화학습의 일종은 deep reinforcement learning 기반의 제어 방법을 제시한다. 오이 시뮬레이션 환경의 정책을 DDPG 방법을 통해 학습하였고 기존의 강화학습보다 학습을 잘 수행한다는 것을 밝혔다. 강화학습을 통해 경험 없이도 사람이 수행하는 제어의 행동을 학습함을 확인하였고, 머신러닝 기법을 통해 전문가 수준의 제어가 가능함을 확인하였다.

Jung 등(2020)은 자연환기를 통한 온실 내 온도 제어를 위해 proportional derivative band (PD-band)제어 전략을 사용하였다. 해당 연구에서는 일중 온실 내부 온도 변화에는 일정한 패턴이 있음을 명시하고 그 기준을 일출, 일몰, 정오, 자정을 기준으로 하루 24시간을 6개의 시간대역으로 구분하고 각 time slot별 최적의 PD 계수를 찾고자 하였다. PD-band 계수 최적화 방법으로는 표면반응분석법을 이용하여 각 6개 시간대역별 최적의 계수를 제시하였다. 최적화를 위해 총 32개의 실험조건이 모델에 적용되었다. 본 연구를 통해 기존의 사용자의 경험에 의존해 최적화된 계수를 결정하던 방식에서 수학적 모델링과 통계적 접근방법으로도 최적화 계수 결정의 가능성을 보였다.

그러나 실험이 장기간에 걸쳐 수행되었음으로 실험을 통해 얻어진 최적화 계수들이 특정 지역의 특정 온실에서만 적용이 될 우려가 있고 급변하는 외부기상에 대응하여 최적화 계수를 결정하는 점에 있어 한계를 보였다.

1.3.2. 인공지능 기반의 온실 연구

Dariouchy, A. 등(2009)은 외부온도, 외부습도, 일사량, 풍속, 풍향과 같은 외부 인자들을 artificial neural network (ANN)모델에 입력하여 온실 내부의 온도, 습도 인자를 예측하고자 하였다. ANN 모델은 온실 내부와 외부의 기상 요인들의 복잡한 관계를 예측하는데 강인함을 보이는 모델이다. 실험 결과로 온도와 습도 예측성능의 mean relative error (MRE)가 각각 4.23%, 3.85%로 나왔다. 기존의 회귀 모델에 비해 ANN의 예측 성능이 더 개선되었음을 보였으며 인공 신경망을 기반으로 한 예측 모델의 가능성을 보였다.

Moon 등(2018)은 ANN을 이용하여 작물의 광합성 효율 증대를 위한 요소 중 하나인 CO_2 농도를 예측하는 모델을 개발하였다. 예측 모델의 개발에 사용된 데이터는 보령의 망고 농장에서 10분마다 취득된 6개월간의 내부온도, 내부습도, 내부기압, 내부 광합성 광량 자속 밀도(PPFD), 외부온도, 외부습도, 외부기압, 풍향, 풍속, 내부 CO_2 농도 데이터 14,866개를 사용하였다. 그중 10,000개는 학습에 4866개는 테스트에 사용되었다. ANN의 예측 결과 결정계수 0.97의 정확도를 보였고 비교군으로 실험한 다중 선형회귀 모델의 경우 결정계수 0.78의 정확도를 보였다. 본 실험을 통해 환기창의 제어이력을 제외한 온실 내외부의 기상데이터 만으로도 CO_2 농도의 변화를 예측할 수 있었다.

Jung 등(2020)은 온실 내부 온도의 거동의 해석을 위한 물리학적 모델 기반의 많은 연구들이 수행되어왔지만 실제 온실 내부의 복합적인 요인들 간의 관계 그리고 비선형성에 의해 적용이 어려운 점을 밝혔고 이를 해결하기 위해 데이터 기반의 인공지능 예측 모델을 제시하였다. 실험에는 딥러닝 기법들인 ANN, nonlinear autoregressive exogenous model (NARX), recurrent neural networks - long short term memory (RNN-LSTM)을 기반으로 예측 모델을 만들고 그 성능을 비교하였다. 각 예측 모델은 온실 주변의 기상 데이터와 작동기들의 제어이력을 입력으로 하여 5분에서 30분 뒤의 온도, 습도, CO_2를 5분 단위로 예측하였다. 실험 결과 RNN-LSTM이 가장 높은 성능을 보였다. 하지만 3가지 모델 모두 습도의 예측에 있어서는 결정계수 R^2 0.8

이하의 정확도를 보였는데 추후 연구에서 강수량 데이터를 추가한다면 습도의 예측력을 높일 수 있을 것이라고 제시하였다.

2. 재료 및 방법

2.1. 실험 온실 시스템 구성

2.1.1. 요인 실험 온실

본 연구에서 실험을 진행하기 위해 경기도 수원시에 위치한 서울대학교의 부속농장(경기 수원시 권선구 서호동로 13 서울대학교 농장)에 단동형 비닐온실을 Figure 1과 같이 설계 및 구축하였다.

실험 온실의 규모는 70 m^2 (5 W × 14 L, m)이며 온실내 작동기들을 제어하는 환경제어기 및 PC가 설치 되어있는 제어부와 실제 작물이 길러지는 재배부로 나뉘어져 있다.

제어부에는 온실 내 설치된 각종 작동기들을 제어하는 환경제어기가 설치되어 있고 외부기상대 및 내부 센서를 통해 얻어지는 온실 내외부 데이터를 취득하는 센서 노드가 설치되어 있다.

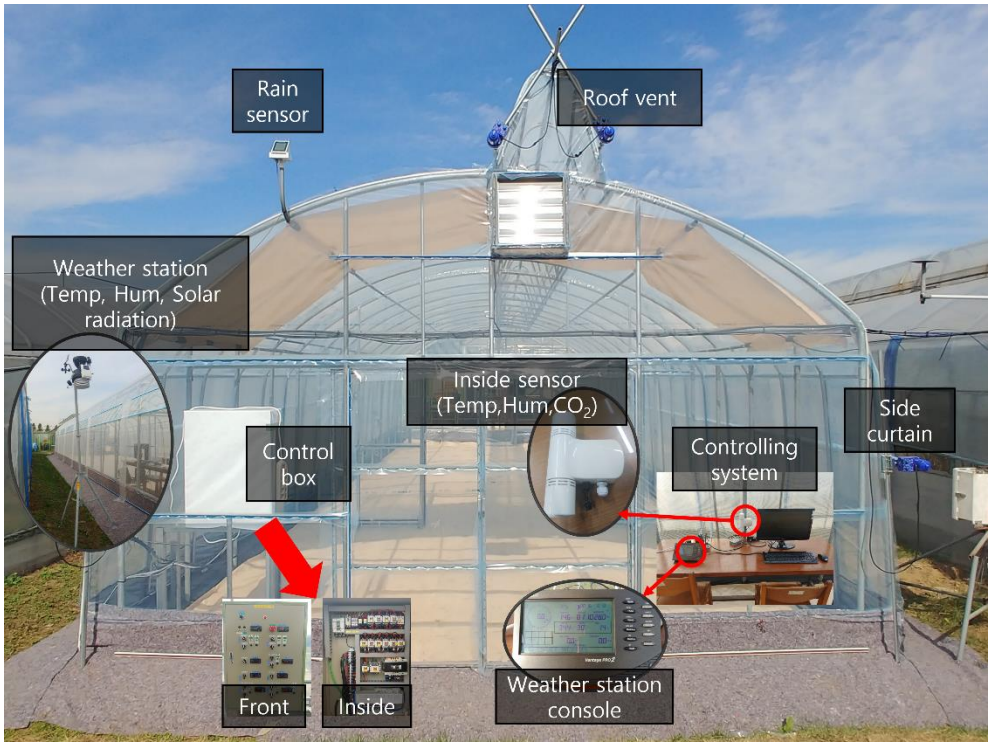

Figure 1. Monitoring sensors and environmental control actuators included in the greenhouse.

데이터를 취득하는 센서 노드로는 Raspberry Pi (Model B+, Raspberry Pi Foundation, United Kingdom)라는 Micro PC를 이용하였다(Figure 2). 저렴하게 구입할 수 있는 Micro PC이며 자세한 제원 사항은 Table 1에 정리하였다. 센서 노드인 Raspberry Pi를 통해 내부센서와 외부기상대의 데이터를 저장하여 예측 모델이 탑재된 PC로 송신하기 전에 저장하는 역할을 한다.

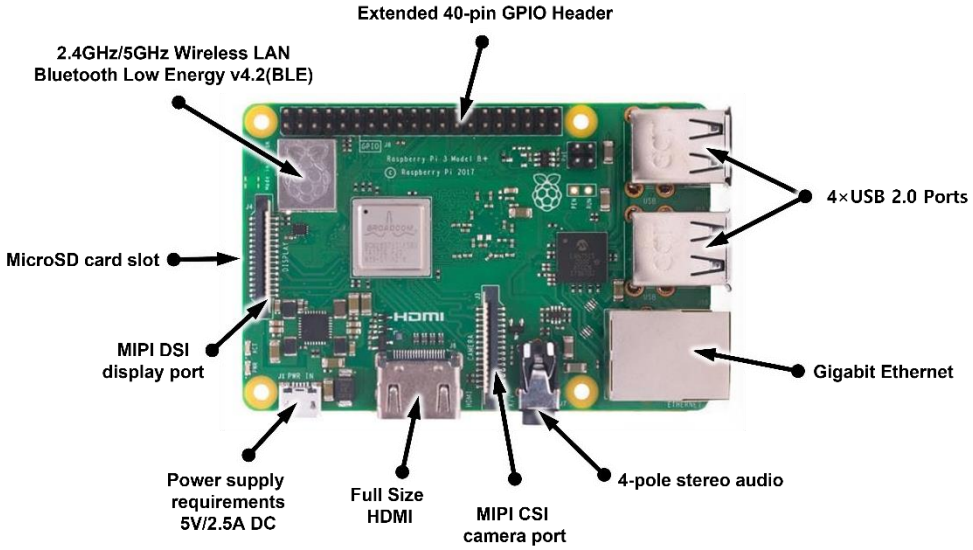

Figure 2. Features of the Raspberry Pi 3.0 model B+.

Table 1. The specification of Raspberry Pi 3.0 model B+

	Raspberry Pi (Model B+)
CPU	Quad-core ARM A53 @1.4GHz
Memory	1GB 64-bit
Power	5V 3A
Networking	Gigabit Ethernet, Wifi
GPIO	40-pin GPIO header

재배부에는 2줄의 행잉타입 재배베드를 가로×세로×높이 = 30×500×50 cm^3으로 설계하였다(Figure 3). 재배에 사용된 배지는 네덜란드 암면배지 제품인 Grodan 배지를 사용하였다. 함수율 제어 범위는 45 - 85 % 범위이며 정식 가능한 구멍은 4구이다. 개당 가로×세로×높이 = 20×120×7 cm^3의 크기로 베드 한 줄 당 4개의

배지가 들어가게 된다. 복합환경 제어기가 있는 재배부와 본 실험에서 설계한 행잉베드가 있는 재배부는 Figure 4에 나타나 있다.

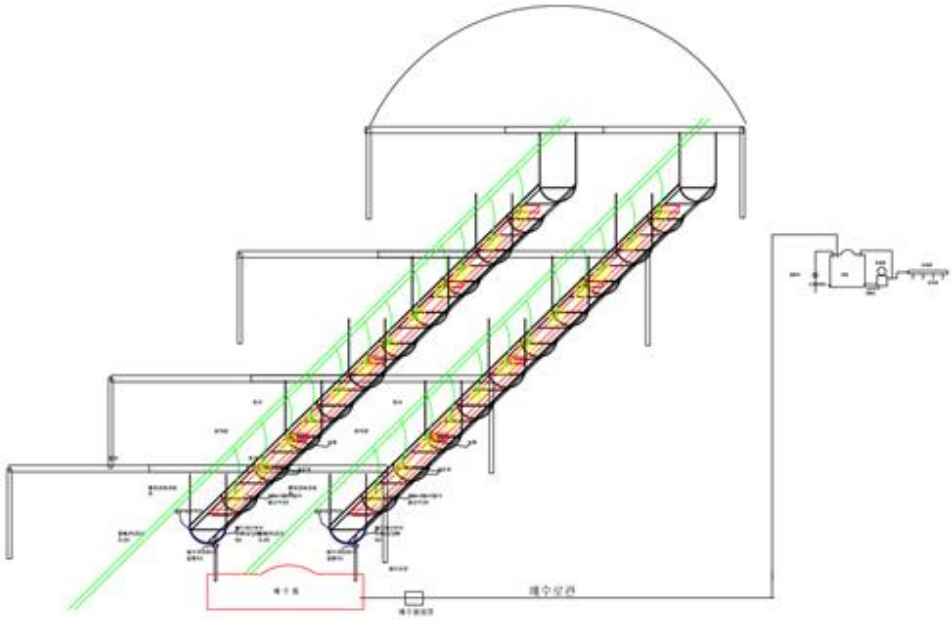

Figure 3. A design drawing of growing bed.

(A) (B)

Figure 4. Inside of the single-span greenhouse. (a)Control space, (b) experimental space

본 실험에서 사용된 작물로는 방울토마토(학명: Solanum lycopersicum var. cerasiforme)를 선정하였다.

온도 프로파일의 경우 Jung et al., (2020)의 선행 연구를 기반으로 일중 시간대를 일출, 일몰, 정오 그리고 자정을 기준으로 6개의 시간대로 구별하여 각 시간대에 맞는 목표 온도 값을 설정하였다(Table

2). 최저온도는 17℃, 최고 29℃로 설정하였고 목표 온도 값에 맞게 하루 중 온도 프로파일을 Figure 5와 같이 구성하였다.

Table 2. Time slots for the greenhouse climate control operation and the target temperature for each time slot

	Time slot	Target temperature(℃)
P1	-1 hour before sunrise	17
P2	1 hour before sunrise – 2 hours after sunrise	17 – 24
P3	2 hours after sunrise – 4 hours after sunrise	24 – 27
P4	4 hours after sunrise – 4hours before sunset	27 – 29
P5	4hours before sunset – sunset	29 – 24
P6	Sunset – 00:00	20 – 17

***sunrise: 07:00, sunset: 19:00**

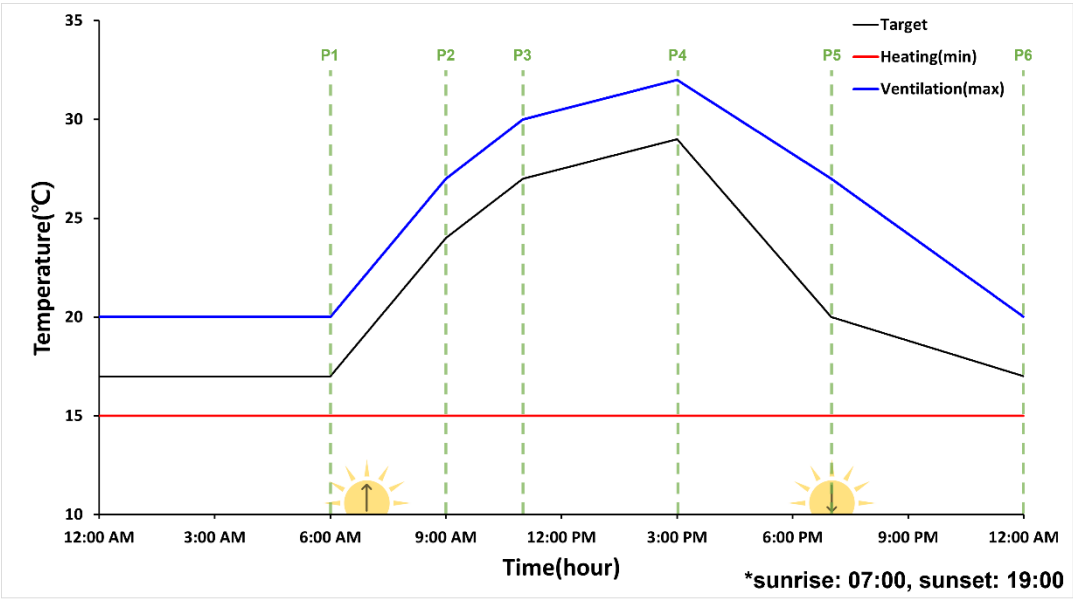

Figure 5. Greenhouse temperature control profile for each time slots

2.1.2. 냉난방기 구성

온실 내부 대기 환경을 제어하는 측면은 크게 냉방과 난방 2가지로 나뉘어진다. 본 연구에서 설계한 온실의 냉난방 시스템의 개략도는 Figure 6와 같다.

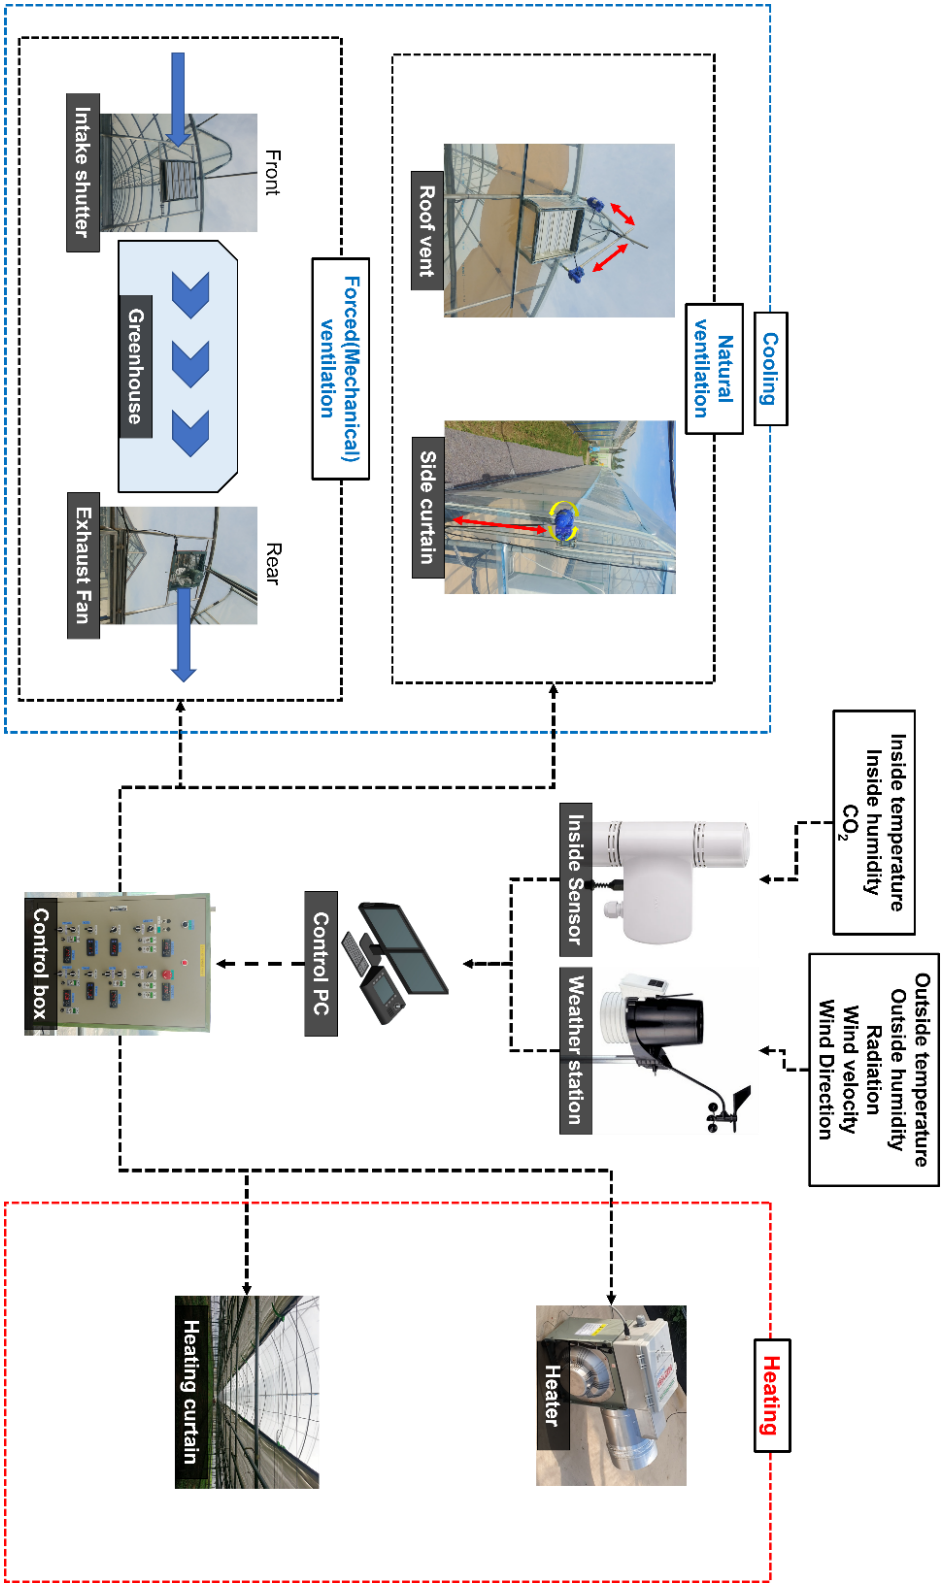

Figure 6. Greenhouse heating and cooling system.

냉방은 국내 단동형 온실에서 일반적으로 사용되는 천창과 측창에 모터를 설치하여 플라스틱 피복을 말아 올리는 권취식 환기방식을 선택했으며, 일사량이 강한 주간의 냉방을 위해 추가적으로 환기팬을 설치하여 강제환기를 진행했다. 권취식 모터와 환기팬의 자세한 제원은 Table 3와 같다.

Table 3. The specification of ventilation motor and fan.

	Roof, side curtain motor Keeper KOS4060 – Voltage: DC24V – Power consumption: 48W – Allowable current ampacity: 2.5A – Rpm: 4rpm
	Fan – Voltage: AC 220V – Power consumption : 200W – Air volume: 4080 m^3/h

난방에 있어서 가장 중요한 부분은 난방기 설정 이전에 온실의 보온력을 확보하는 것이다. 보온이 확보되지 않은 온실에서 아무리 난방기를 작동시켜도 빠져나가는 열량을 잡아 두지 못한다면 밤시간대의 작물 최저 한계온도를 유지하지 못하고 작물에게 악영향을 끼치게 된다. 설계된 실험 온실에서의 보온은 다겹보온 커튼을 수직 방향과 수평방향으로 설치를 하였다. 측창의 안쪽에 수직 다겹보온 커튼을 설치하여 새벽 시간대에 측창의 개폐를 통해 온실 내부 온도의 급격한 하락을 방지하였고, 온실의 중앙에 중방대를 설치하여 수평방향의 다겹보온 커튼을 설치하였다. 난방기로는 전기 온풍기를 설치하였고

자세한 제원은 Table 4와 같다.

Table 4. The specification for heater and heating curtain motor.

	Electric heater GNHP-0910 - Standards: 380V three-phase four-wire system - Power consumption: 10kW
	Heating curtain motor ZOS5150 - Voltage: DC24V - Power consumption: 48W - Allowable current ampacity: 6A - Rpm: 2.5rpm

2.1.3. 센서 및 데이터 취득 구성

환기 제어를 위한 온실 내외부의 환경 데이터들을 취득하는 IoT 시스템의 개략도가 아래와 같이 구성하였다. 외부기상대(Figure 8, Table 5)로부터 외부 온도, 외부 습도, 일사량, 풍속의 데이터가, 내부 센서(Figure 9, Table 6)로부터 내부 온도, 내부 습도, CO_2 값이 RS485 및 UART통신을 통해 센서 노드인 라즈베리 파이로 취득된다. 외부기상대의 경우 실제 환기에 영향을 미치는 풍속과 풍향을 취득하기 위해 측창이 개폐되는 온실의 옆에 설치하였다. 내부센서는 작물의 중심부 온도를 대표하는 값을 취득하기위해 작물의 중간 높이인 지상에서 약 1m 20cm의 높이에 설치하였다. 취득된 온실 내외부 데이터는 MQTT 통신을 통해 인터넷상의 클라우드 서버에 업로드가 되고 제어 알고리즘이 탑재된 컴퓨터에서는 클라우드 서버에 업로드 된 환경 데이터를 수신 받아 최종적으로 온실 제어를 수행하게 된다(Figure 7).

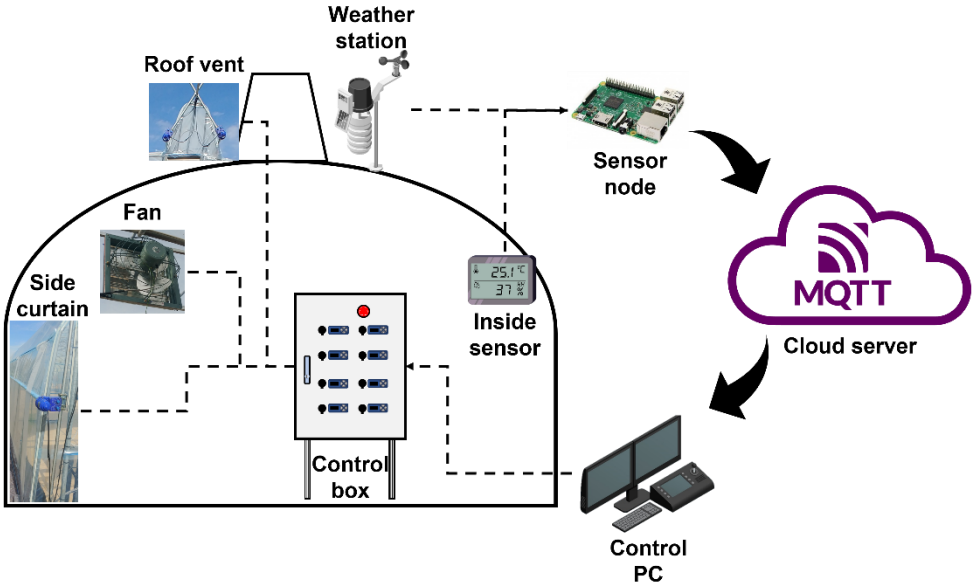

Figure 7. Overview diagram of the IoT based control system.

Figure 8. Vantage Pro 2 (Davis Instruments, USA)

Table 5. The specification of the Vantage Pro 2 weather station.

	Measurement range	Resolution	Accuracy
Temperature	−40~65℃	0.1℃	0.5℃
Humidity	0~100%	1%	3%RH
Radiation	0~1800W/m^2	1W/m^2	5%

Figure 9. SH-VT260 (Soha-tech, KR)

Table 6. The specification of the SH-VT260 sensor detecting temperature and humidity and CO_2.

	Measurement range	Accuracy	Response time
Temperature	-25~85℃	±0.3%	5~30sec
Humidity	0~99%	±2%RH	8sec
CO_2	0~3000ppm	±3% (Proportional to measurement range)	

2.1.4. IoT 원격 통신 구성

Node-RED는 하드웨어 장치들, application programming interface (API), 온라인 서비스를 사물인터넷의 일부로 와이어링(배선화)시키기 위해 본래 IBM이 개발한 시각 프로그래밍을 이용한 개발도구이다. Node-RED는 인터넷을 통해 쉽게 접근 가능하고, 다양한 장치들의 연동이 가능하여 농가 적용에도 용이하다. 이러한 장점들을 바탕으로 본 연구에서는 원격 제어를 위한 IoT 기반 온실을 설계하는데 있어 Node-RED를 사물인터넷의 운영체제로 선정하였다.

온실 내 천창, 측창, 환풍기, 온풍기, 다겹 보온 커튼의 사용자 인터페이스를 Figure 10과 같이 구성하였고 센서를 통해 취득되는

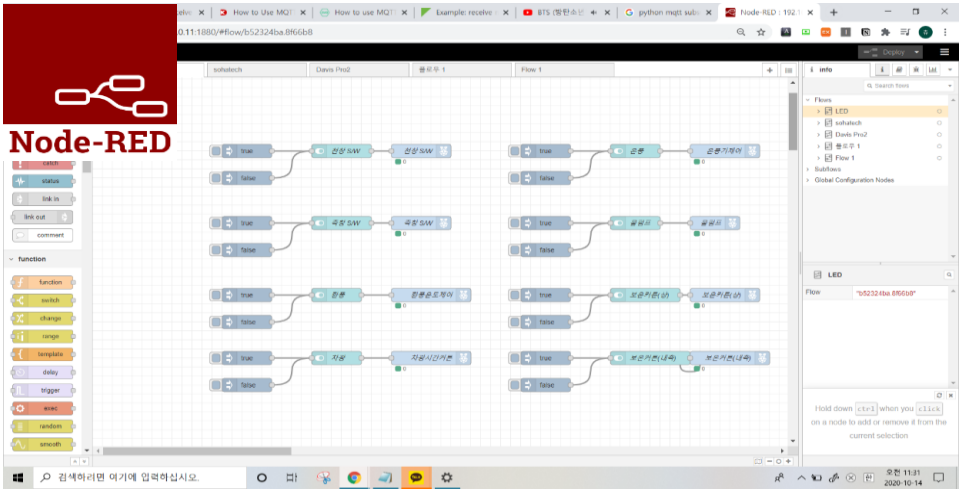

Figure 10. Node-RED control interface.

Figure 11. Node-RED dashboard.

내부온도, 내부습도, CO_2, 외부온도, 외부습도, 일사량, 풍속, 풍향의 데이터들을 Figure 11과 같이 표시하였다.

2.2. 예측 기반 온도 제어

2.2.1. CNN 예측 모델

본 연구에서 온도를 예측하는 모델로 CNN을 선정하였다. 일반적으로 순차적인 시계열 데이터를 다룰 때에는 내부구조적으로 과거의 학습을 현재 학습에 연결시키는 순환구조를 가진 recurrent

neural network (RNN)를 많이 사용한다. 하지만 90분간의 시간, 내부온도, 내부습도, 내부 CO_2 농도, 외부온도, 외부습도, 일사량, 풍속, 풍향의 9가지 데이터를 90×9의 구조로 2D 이미지화 시킨다면 CNN으로도 시계열 데이터를 처리함과 동시에 온도 변화 패턴을 분석할 수 있다. CNN은 입력 데이터의 특징을 추출하는 부분과 클래스를 분류하는 부분으로 나뉜다. 특징을 추출하는 영역은 convolutional layer와 pooling layer를 여러 겹 쌓는 형태로 구성된다. convolution layer에서 반영한 활성화 함수로는 Rectified Linear Unit (ReLU)를 사용하였다. Pooling layer는 average pooling을 사용하였다. 본 연구에서는 특징 추출과정에서 오버 피팅을 줄이기 위해 신경망 층의 일정 노드를 확률적으로 제외시키는 dropout을 포함시켰다.

CNN의 마지막 부분에는 분류를 위한 fully connected layer는 flatten layer와 dense layer로 구성된다. Flatten layer는 CNN의 데이터 타입을 fully connected neural network의 형태로 변경하는 레이어이다. 본 연구에서는 2개의 dense layer를 구성하였는데 첫번째 dense layer의 활성함수로는 ReLU를 사용하였고, 두번째 dense layer는 linear 활성 함수를 사용하여 최종적으로 온도 데이터 한가지를 출력 값을 내도록 하였다(Figure 12).

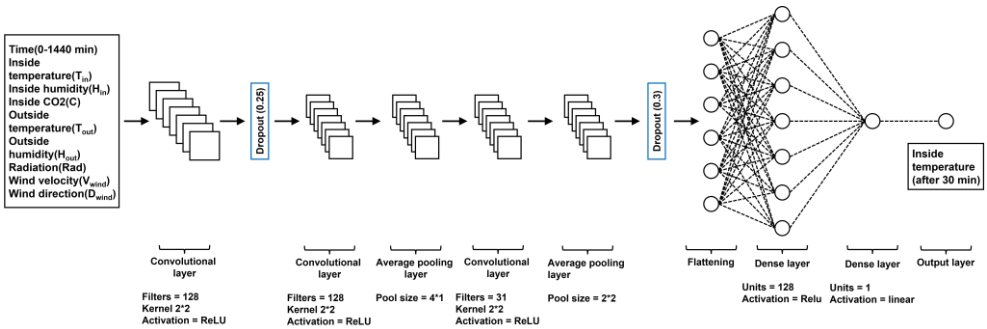

Figure 12. An overview of a convolutional neural network (CNN) architecture.

2.2.2. 학습데이터별 예측 모델 개발

학습 데이터에 따라 예측모델의 성능이 달라지므로 각 계절의 데이터를 포함시켜 다른 학습 데이터 셋을 달리하여 모델을 개발하였다. 1번 모델(4월 데이터), 2번 모델(4월,11월 데이터), 3번 모델(4월, 11월 1월 데이터)의 각각 다른 데이터 셋을 이용하여 모델을 개발하였다. 4월은 봄, 11월은 가을, 1월은 겨울의 데이터 셋이며, 여름의 경우

휴작기에 해당하므로 학습 데이터 셋에서 제외시켰다.

2.2.3. P-band 제어

온실에서의 환경관리란 작물에게 필요한 광, 온도, 습도 등을 이해하고 작물이 광합성을 하기위한 최적의 환경을 조성할 수 있도록 구동기를 제어하는 것이다(농촌진흥청, 스마트 온실환경관리 가이드라인 2018).

P-band 제어는 On/Off 제어와 함께 국내 온실 제어에서 가장 널리 사용되는 제어의 개념이다. On/Off 제어는 단순히 설정 값보다 낮으면 작동하고 높으면 작동을 멈추는 개념이다. 단순한 만큼 사용자들이 온실에 적용하기 쉽지만 온도가 설정 값에 도달했을 경우 반복적으로 작동을 하기 때문에 기계적으로 무리를 요할 수 있다. P-band 제어의 경우 설정 값과의 온도 차이에 비례하여 제어를 수행하기 때문에 On/Off 제어보다 설정 값에 수렴할 수 있다는 장점이 있다.

2.2.4. 예측 기반 제어 알고리즘

본 연구에서 개발한 예측 제어 알고리즘 Equation 1은 농촌진흥청 국립원예특작과학원에서 발표한 2019 시설원예 스마트팜 현장적용기술에서 제시된 P-band 제어를 기반으로 예측 온도에 대한 항을 추가하여 개발되었다. P-band 제어식은 천창과 측창, 그리고 다겹 보온 커튼과 같이 열림의 정도를 정할 수 있는 작동기들의 제어를 위해 제시되었고, 온풍기와 환풍기의 경우에는 On/Off 제어를 수행하였다.

기존의 센서 신호를 통해 측정되는 현재 내부 온도 값 만을 고려한 P-band제어는 측정을 하고 제어 동작에 들어가기까지 시간이 소요되어 급격하게 온도가 상승하는 주간에는 동작이 일어나는 중에도 온도가 올라가 목표 온도를 넘어가는 과도응답 상태가 발생하였다. 본 연구에서 개발된 예측 제어식은 예측온도에 대한 가중치를 고려하기 때문에 급격한 온도 변화를 예측하고 이를 제어에 반영함으로써 온도가 급상승하는 주간에 작동기를 미리 작동하거나 기존보다 더 많이 작동시켜 상용제어에서 나타나던 문제점을 보완할 수 있을 것으로 보인다.

제시된 예측 제어식에서 상용제어 계수인 K_p1은 상수 값 1로 고정되었고 예측제어 계수인 K_p2는 0.1, 0.2, 0.3으로 증가시켜가며 적합한 계수를 선발하고자 하였다.

상용제어에서는 외부온도, 일사량, 풍속 값에 대한 영향값을 P-

band에 반영하였지만, 본 연구에서는 이러한 외부 인자들이 예측 모델에 활용되었고 해당 예측 온도를 반영하여 제어식을 개발하였기 때문에 P-band 값을 3℃로 고정하였다.

$$[\{K_p1(T_{in} - T_{target}) + K_p2(T_{pred} - T_{target})\}/Pband] \times Operating\ time \quad (1)$$

$where,$

$T_{in} = inside\ temperature$

$T_{target} = target\ temperature$

$T_{pred} = predicted\ temperature$

$K_p1 = the\ proportional\ gain$

$K_p2 = the\ prediction\ gain$

$Pband = band\ with\ index$

2.2.5. 실시간 제어 구성

앞서 개발된 예측 모델을 통해 출력되는 예측 온도를 예측온도 기반의 P-band 제어식에 실시간으로 적용하기 위한 모식도를 Figure 13과 같이 나타냈다. 내부센서와 외부기상대를 통해 90분간 취득된 8가지 인자(내부온도, 내부습도, CO2, 외부온도, 외부습도, 일사량, 풍속, 풍향)와 시간인자까지 총 9가지 인자가 예측모델에 입력이 된다. 시간인자의 경우 하루치의 온도 변화를 분 단위로 입력하기 위해 0~1439의 1440개 데이터 형식으로 입력한다. 실시간 예측 모델을 최근 90분간의 입력 데이터를 기반으로 예측 모델이 동작 하여 30분 뒤의 온실 내부 온도 값을 출력을 하게 되고, 해당 예측 값을 온실을 제어하는 PC에 송신하게 된다. 예측 온도 값을 받은 제어 PC에서는 본 연구에서 제안한 예측 기반의 P-band 계산식에 예측 온도를 입력하게 되고 최종적으로 작동기의 동작 시간이 결정된다. 따라서 작동기들은 예측 온도의 영향성을 고려하여 다음 동작의 시간을 결정하게 된다. 각 작동기들의 최대 동작시간은 Table 7에 표시하였다.

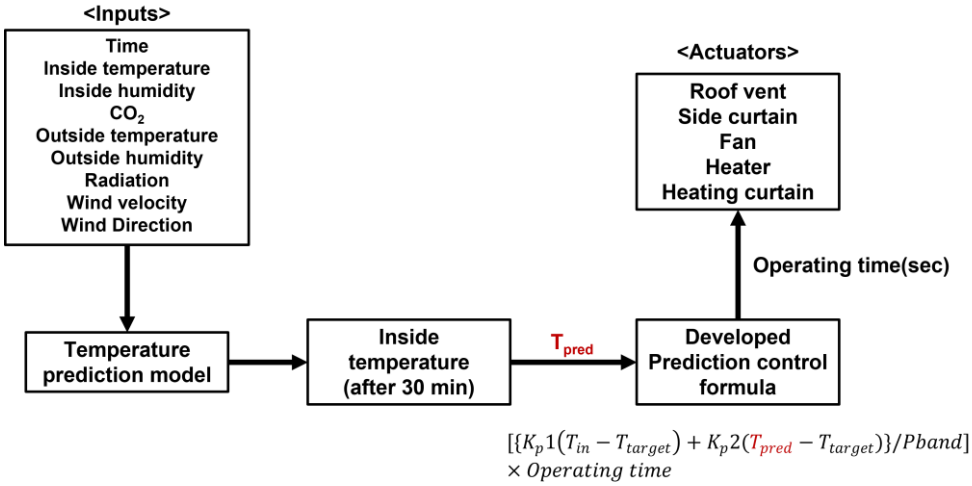

Figure 13. Overview of the real-time prediction system.

Table 7. Greenhouse actuators and maximum operating time.

Actuators	Maximum operating time (sec)
Roof vent	60
Side curtain	170
Heating curtain (vertical)	200
Heating curtain (horizontal)	210

2.3. 실험 및 평가

2.3.1. 실시간 예측 성능 평가

개발된 CNN 기반의 온도 예측 모델의 실시간 예측 성능을 평가하기 위해 본 연구에서 설계한 단동형 비닐 온실에서 성능평가를 진행하였다.

실험은 2월 16일에서 2월 21일, 그리고 4월 9일에서 4월 14일까지 총 2번에 걸쳐 실험을 진행하였다. 모델의 실시간 예측 성능 비교는 내부 온도 센서를 통해 취득되는 실제 온도 데이터와 예측을 통해 출력되는 예측 온도와의 RMSE (Equation 2)를 비교하였다.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(T_{in} - T_{pred})^2} \quad (2)$$

$where,$

$T_{in} = Inside\ temperature$

$T_{pred} = Predicted\ Temperature\ after\ 30\ minute$

이후 상용제어와 예측 제어의 성능 비교를 위해 상용제어를 6일간(4/9~4/14) 진행하였고 이후 예측 제어의 계수를 0.1에서 0.4까지 변화를 주며 4일간(4/19~4/22) 실험을 진행하였다. 그 중 외부기상 조건이 가장 유사한 날인 4월 9일과 4월 19일을 선정하여 그 성능을 비교하였다. 예측 모델에 사용된 데이터는 실험 온실에서 1분 간격으로 취득된 4월, 11월, 1월의 데이터 약 56,000개가 사용되었고 학습 70 %, 검증 30 %의 비율로 모델이 개발되었다.

2.3.2. 예측 기반 실시간 제어 성능 평가

실시간 제어 성능 평가를 위해 본 연구에서 설계한 단동형 비닐온실에서 4월 27일부터 5월2일까지 총 6일간 실험을 진행하였다.

실험은 본 연구에서 제시한 예측 기반 P-band 제어의 예측 제어 계수 K_p2를 0.1, 0.2, 0.3으로 늘려가며 각각 이틀씩 순차적으로 진행하였다.

제어 성능 평가로는 총 2가지 측면에서 그 성능을 비교하고자 하였다. 첫번째로 앞서 제시된 방울 토마토의 온도 프로파일(Table 2)을 기준으로 예측 제어를 수행한 결과인 내부 온도와 목표온도의 RMSE를 구하여 제어 성능을 평가하였다. 두번째는 목표온도를 초과하거나 도달하지 못하는 잔여 오류를 시간당 y축값을 누적 합산하는 방법(Equation 3)으로 평가하였다.

$$error = \begin{cases} overshoot = \sum_{i=1}^{n}(T_{target} - T_{in}) \\ undershoot = \sum_{i=1}^{m}(T_{target} - T_{in}) \end{cases} \quad (3)$$

$where,$

$n = Minute, \quad if\ (T_{target} - T_{in}) > 0$

$m = Minute, \quad if\ (T_{target} - T_{in}) < 0$

$T_{target} = Target\ temperature$

$T_{in} = Inside\ temperature$

3. 결과 및 고찰

3.1. 학습 데이터별 온도 예측 모델 성능

학습데이터 셋 별로 각기 다른 3가지 온도 예측 모델을 개발하였다.

4월 데이터 셋의 1번모델, 4월, 11월 데이터 셋의 2번 모델, 4월, 11월, 1월 데이터 셋의 3번 모델을 개발하였고 각 예측 모델의 예측 성능을 RMSE로 비교하였고, 각 모델을 1월 22일부터 1월 26일의 5일간의 데이터로 검증을 진행하였다.

1번 모델의 결정계수 R^2는 0.92, 2번 모델의 결정계수 R^2는 0.9, 3번 모델의 결정계수 R^2는 0.91로 각 모델 별 검증 성능에서는 큰 차이가 없었다. 각 모델의 예측 성능을 검증하기 위해 학습에 사용되지 않은 2022년 1월 22일부터 1월 26일까지의 데이터를 사용하여 개발된 3개의 예측 모델 성능을 비교하고자 하였다(Table 8). 1번 모델과 2번 모델의 RMSE는 각각 10.49℃, 9.57℃로 높게 나타난 반면 3번 모델은 RMSE가 4.7℃였다. 1월 데이터 셋으로 검증을 하였기 때문에 비교적으로 1월의 추운 날씨에 대한 데이터 셋이 부족했던 1번과 2번 모델의 경우 검증에 있어서 온도 예측 성능이 3번 모델에 비해 떨어지는 양상을 보였다. 반면 4월, 11월, 1월의 모든 계절의 데이터 셋으로 학습한 3번 모델의 경우 1월 검증 데이터 셋에 대해 RMSE 4.7℃으로 앞의 1번, 2번 모델에 비해 높은 성능을 확보하였다.

이를 통해 학습 데이터 셋에 있어 가능한 계절별의 데이터 셋을 포함하여 학습을 진행해야 실제 적용에 있어서 유리함을 확인할 수 있었다. 이후 실제 농가에 예측 모델을 적용시킨다면 적용하고자 하는 온실의 계절별 데이터가 확보되어야 빠른 적용이 가능하고 만약 계절 별 데이터가 확보되지 않았다면 상용제어로 온실을 구동하여 1년간의 데이터 확보가 필요함을 알 수 있다.

Table 8. CNN based temperature prediction model performance according to different data set.

	모델 성능 R^2	1월 테스트 데이터 RMSE(℃)
1번 모델	0.92	10.49
2번 모델	0.9	9.57
3번 모델	0.91	4.7

3.2. 실시간 온도 예측 성능

상용 P-band제어를 수행하는 동안 본 연구에서 개발한 온도 예측 모델을 통해 실시간 온도 예측 실험을 수행한 결과 Figure 14과 Figure 15와 같은 결과가 나왔다. 2월과 4월 두 번의 실험은 각각 RMSE 2.2 ℃, 2.9 ℃의 성능을 보였다.

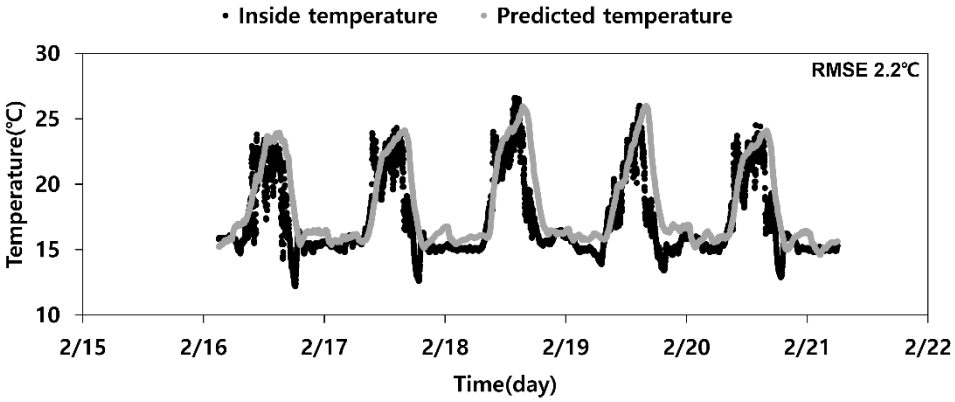

Figure 14. Real-time prediction performance results (2/16 to 2/20).

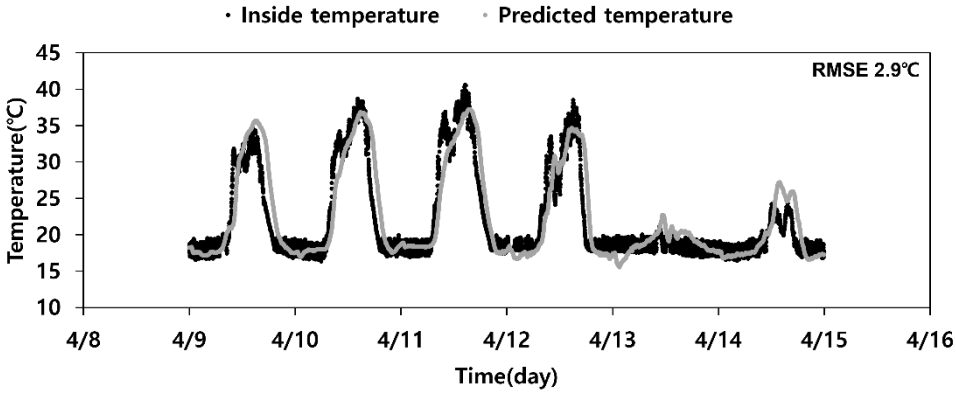

Figure 15. Real-time prediction performance results (4/9 to 4/14).

2월의 성능에 비해 4월의 RMSE가 더 크게 나온 이유를 분석한 결과 4월 13일에서 4월 14일까지 흐린 날씨가 지속되어 일사량과 외부온도가 비교적 낮게 관측되어 내부온도 또한 낮게 나타났다(Figure 16, Figure 17). 이를 통해 예측 모델을 개발함에 있어 학습데이터 셋의 중요함을 알 수 있다. 학습 데이터 내에 넓은 범위의 온도 데이터가 다양하게 포함이 되어있었다면 4월달의 실험처럼 외부 기온이 낮은 날씨에서도 예측성능이 증가했을 것으로 판단된다.

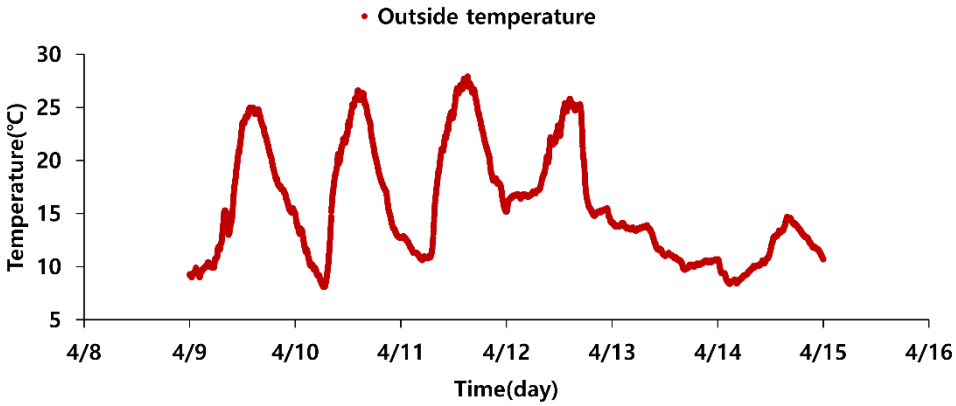

Figure 16. Outside temperature from 4/9 to 4/14.

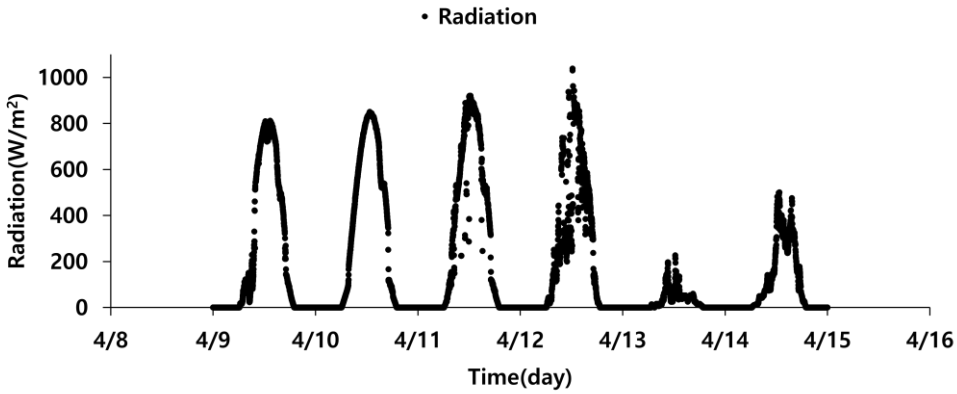

Figure 17. Radiation from 4/9 to 4/14.

3.3. 상용제어와 예측제어 성능 비교 분석

Figure 20의 외부기상그림과 같이 실험이 진행된 두 날짜는 08:00 AM 부터 12:00 PM 까지 매우 동일한 기후를 보여준다. 이 때 상용제어와 예측제어를 비교해보면 상용제어는 온도 프로파일 상단을 벗어나는 overshoot 현상을 보였다(Figure 18). 이러한 현상은 일반적인 상용제어에서 자주 발생한다. 그 원인은 센서를 통해 들어오는 현재 온도 값을 보고 제어를 하게 되고 목표 온도 값과의 차이만큼 작동기를 동작하는데 시간이 소요된다. 이때 동작을 하는 순간에도 외부 기상은 상승하는 중이기 때문에 작동기의 동작이 완료되었음에도 불구하고 내부 온도는 여전히 높은 온도를 유지했다.

예측 제어의 경우 같은 시간대역에서 내부 온도가 온도 프로파일을 벗어나지 않고 프로파일 안쪽으로 제어가 된 것을 확인하였다(Figure

19). 천창과 측창의 작동기 제어 이력을 분석한 결과 예측 제어에서 천창과 측창을 여는 시점이 상용제어 보다 더 일찍 작동한 사실을 확인하였다.

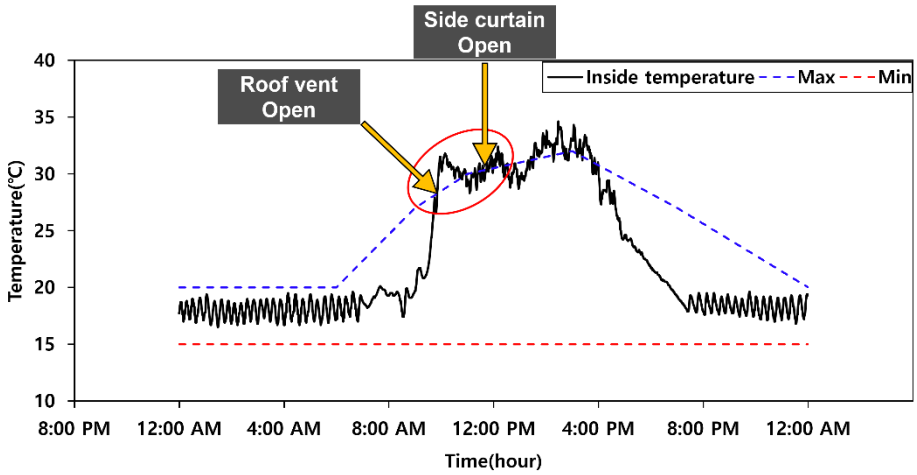

Figure 18. Conventional P-band control in 4/9.

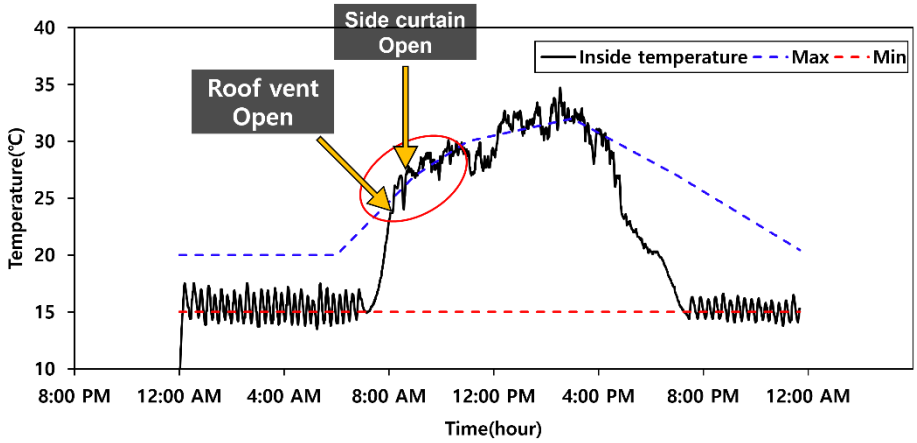

Figure 19. Prediction based control in 4/19 (K_p=0.1).

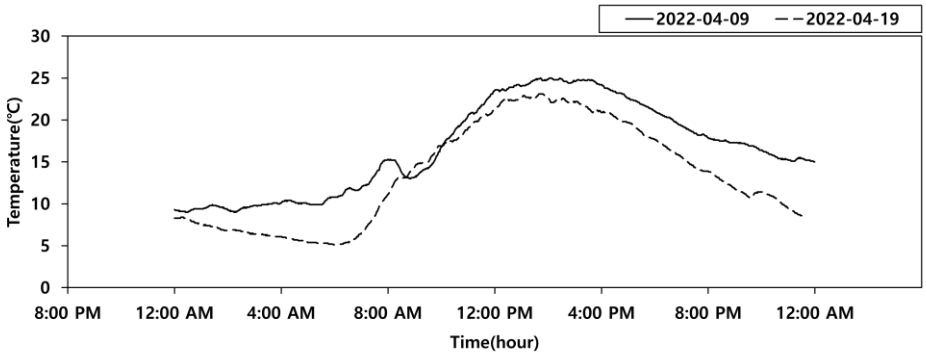

Figure 20. Outside temperature condition in the experiment (4/9 and 4/19).

제어 이력 분석을 한 결과 Figure 21과 Figure 22에서 보이듯이 상용제어를 한 4월 9일에 비해 예측 제어를 수행한 4월 19일의 천창과 측창의 작동 시점이 약 한 시간 정도 빠른 것을 확인할 수 있었다. 외부 기상의 조건이 비슷한 두 날짜의 결과로 보아 예측 제어를 통해 온도 상승을 미리 알고 작동기의 동작 시점을 앞당겨 제어를 수행했기 때문에 Figure 19에서 볼 수 있듯이 온도 프로파일의 max 지점을 넘기지 않았던 것으로 보인다.

밤 시간대의 천창과 측창의 작동 시점을 살펴보면 예측 제어를 수행한 4월 19일이 4월 9일 보다 더 일찍 폐쇄하는 것을 확인할 수 있다. 밤 시간대의 온도 하강을 예측하고 미리 측창과 천창을 닫음으로써 온도 하강을 방지한 모습을 볼 수 있다.

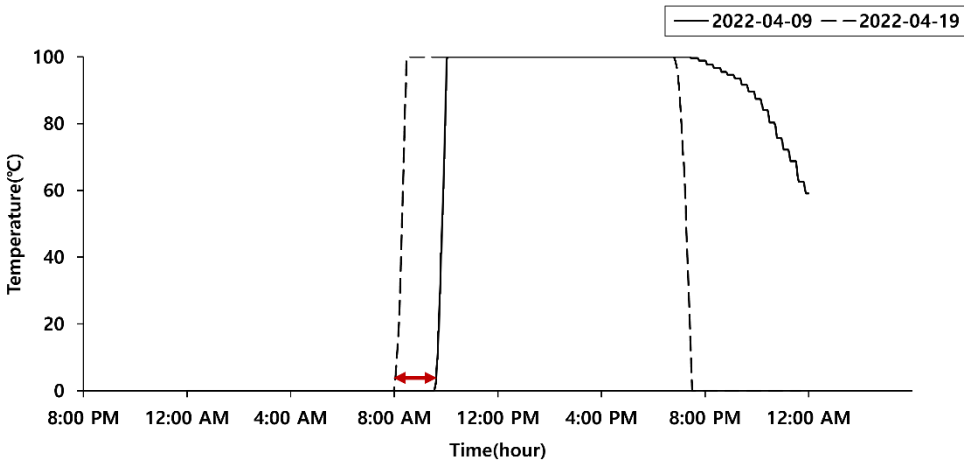

Figure 21. Roof ventilation window control history(4/9, 4/19).

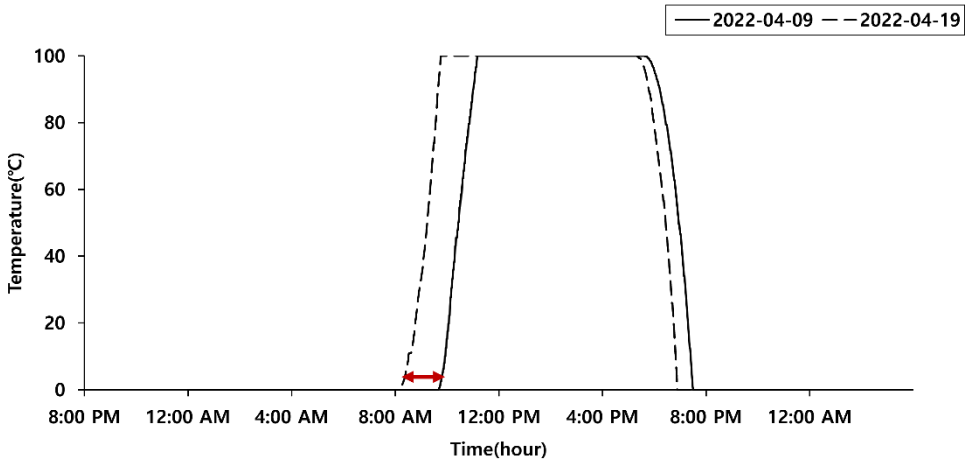

Figure 22. Side curtain control history(4/9, 4/19).

3.4. 실험 온실에서의 예측 제어기술 검증 및 성능 평가

3.2.1. 예측제어 계수에 따른 온도 제어 성능 평가

본 연구에서 개발 및 제시한 예측 제어식의 가중치 K_p2의 값을 0.1부터 0.3까지 증가시키면서 예측 제어를 수행한 결과, 예측 제어 계수 K_p2=0.1의 정확도는 RMSE=3.2 ℃(Figure 23), K_p2=0.2는 RMSE=2.7 ℃(Figure 24) 그리고 K_p2=0.3은 RMSE=2.0 ℃(Figure 25)의 결과를 보였다. 예측 제어 계수 K_p2의 값이 증가함에 따라 RMSE가 낮아지는 경향을 보였다. 이를 바탕으로 제어를 할 때 예측 제어 계수에 가중치를 높임으로써 현재의 온도를 보고 제어를 하는 것이 아닌 예측 온도에 대한 영향력을 높여 30분뒤 변화할 온도에 대응하여 제어를 수행하였다.

목표 온도 프로파일을 기준으로 목표 값을 상회하는 구간(Overshoot)의 면적을 계산 한 결과 K_p2=0.1는 5322 ℃, K_p2=0.2는 741 ℃, K_p2=0.3은 1785 ℃로 예측 제어 계수의 가중치가 증가함에 따라 12:00 PM부터 15:00 PM의 주간 시간대의 과도응답 상태가 현저히 줄어드는 것을 확인할 수 있었다.

Table 9에서 볼 수 있듯이 예측 제어 계수 K_p2를 0.1, 0.2, 0.3로 증가시키면서 실험하였을 때 제어의 성능이 목표 값을 상회하는 구간(overshoot)은 줄어들고 반대로 목표 값보다 떨어지는 구간(undershoot)은 증가하는 모습을 보였다. 이를 통해 온도가 급격하게 상승하는 주간에는 예측제어가 미리 창의 개폐를 동작시킴으로써 효과를 보았다고 할 수 있지만 온도변화를 보고 미리 작동기를 기존 온도 차보다 더 많이 개방을 함으로써 전체적인 제어 온도 프로파일이 낮아지는 현상이 발생하였다. 하지만 최저 생육 온도인 15℃보다 떨어지지 않았기 때문에 본 연구에서 개발한 예측 기반의 온도제어 알고리즘이 효용성이 있음을 보였다.

비록 최저 생육온도 범위 내로 제어가 수행되었다고는 하지만 제어 계수에 따라 온도 제어 성능에 영향을 미치는 것을 확인하였음으로 후속 연구에서는 최적의 예측계수를 결정할 수 있는 방안에 대해서 고민할 필요가 있다. 또 다른 방안으로는 시간대 별로 예측 제어 계수를 달리하는 적응형 예측 제어 방식을 사용하여 목표 값을 상회하는 구간(overshoot)은 줄이면서 목표 값보다 떨어지는 구간(undershoot)이 발생하지 않도록 하는 방안도 고려할 필요가 있다.

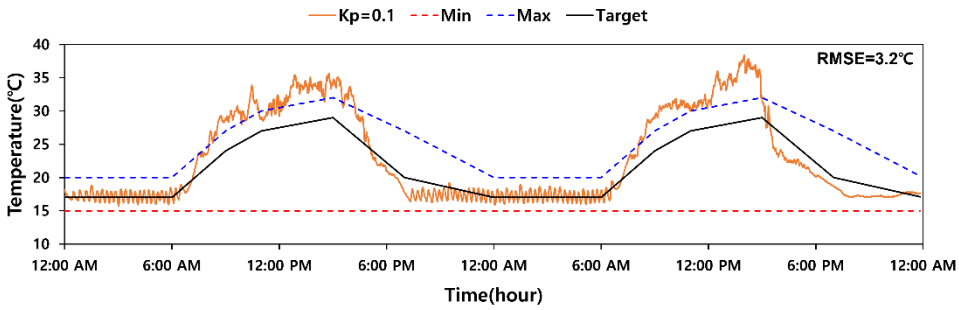

Figure 23. Prediction based control (K_p=0.1, 4/27 to 4/28).

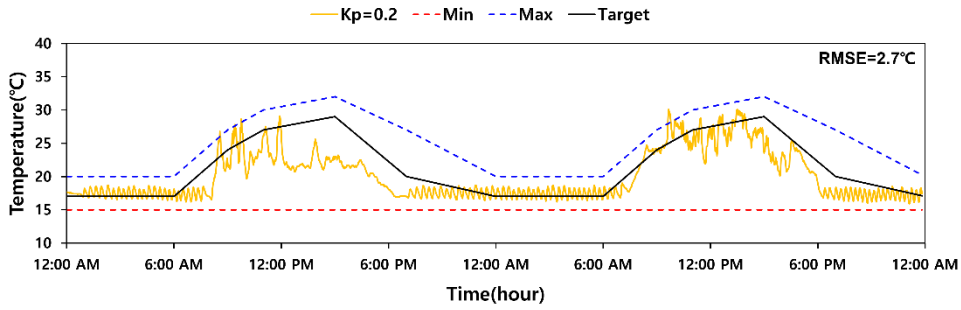

Figure 24. Prediction based control (K_p=0.2, 4/29 to 4/30).

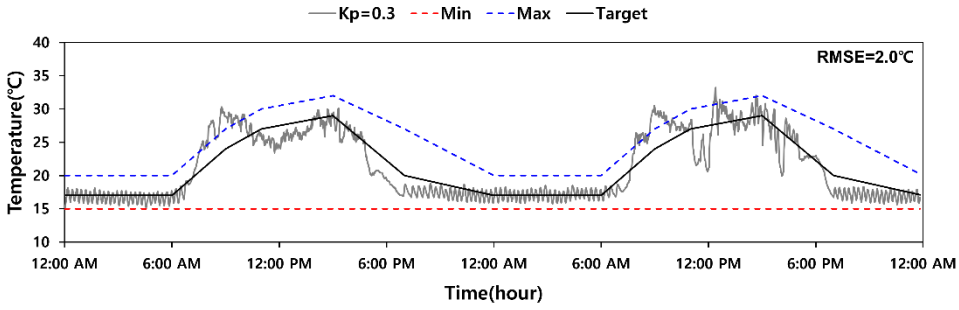

Figure 25. Prediction based control (K_p=0.3, 5/1 to 5/2).

Table 9. RMSE and overshoot and undershoot of prediction-based control according to prediction coefficient K_p2.

	RMSE(℃)	Overshoot(℃)	Undershoot(℃)
Kp=0.1	3.2	5322	-1553
Kp=0.2	2.7	741	-5101
Kp=0.3	2.0	1785	-2706

각 실험이 진행된 날짜의 외부기상 데이터(온도, 습도, 일사량, 풍속)는 Figure 26과 같이 나타났다. 전체 기간 중 앞쪽에서 수행된 K_p2=0.1 실험에서는 비교적 외부 기온이 높았고 후반부에 진행된 K_p2=0.2, K_p2=0.3는 외부 기상조건이 비슷하게 형성이 되었다. 이를 통해 K_p2=0.1 실험이 수행된 날의 기온이 상대적으로 높아 제어 온도 프로파일이 높게 형성이 되었을 것이라고 판단이 되지만 나머지 실험을 수행한 날의 외부 기상이 비슷한 조건으로 형성이 되어 예측 계수 간의 성능을 비교할 수 있었다. 추후 실험에서는 동일한 조건의 온실을 구축하여 비교군으로 설정한다면 동일한 기상 조건하에 실험을 진행할 수 있을 것으로 생각된다. 선행연구인 Jung(2020)은 PD-band 함수에 외부 환경 인자들에 대한 변수와 그 계수를 표면반응 분석으로 최적화하는 방법을 제안하였는데, 본 연구에서는 이 영향 인자를 딥러닝 학습으로 대체하여 온도 변화를 예측하였고, 이 학습된 모델에 외부 환경 인자들의 영향 값이 반영되었다고 볼 수 있다.

후속 연구로 예측 모델을 학습시킬 때 입력하는 인자로 운량 데이터를 고려해볼 필요가 있다. 농업적 측면에서 밤 사이에 구름이 많이 형성되어 있으면 복사 에너지가 누적되어 다음날 아침 온도가 따뜻하게 유지되고 밤 사이에 구름이 적을 경우 복사 에너지가 대기중으로 방출되어 다음날 아침 온도가 떨어지는 양상을 보인다. 따라서 다음날 온실 내부 온도를 제어함에 있어서 운량 데이터가 중요한 인자로 작용할 수 있기 때문에 이를 고려한 예측 모델을 개발한다면 보다 정확한 온도 예측이 가능할 것이고 이를 통해 정밀한 온실 내부 온도 제어가 가능할 것이다.

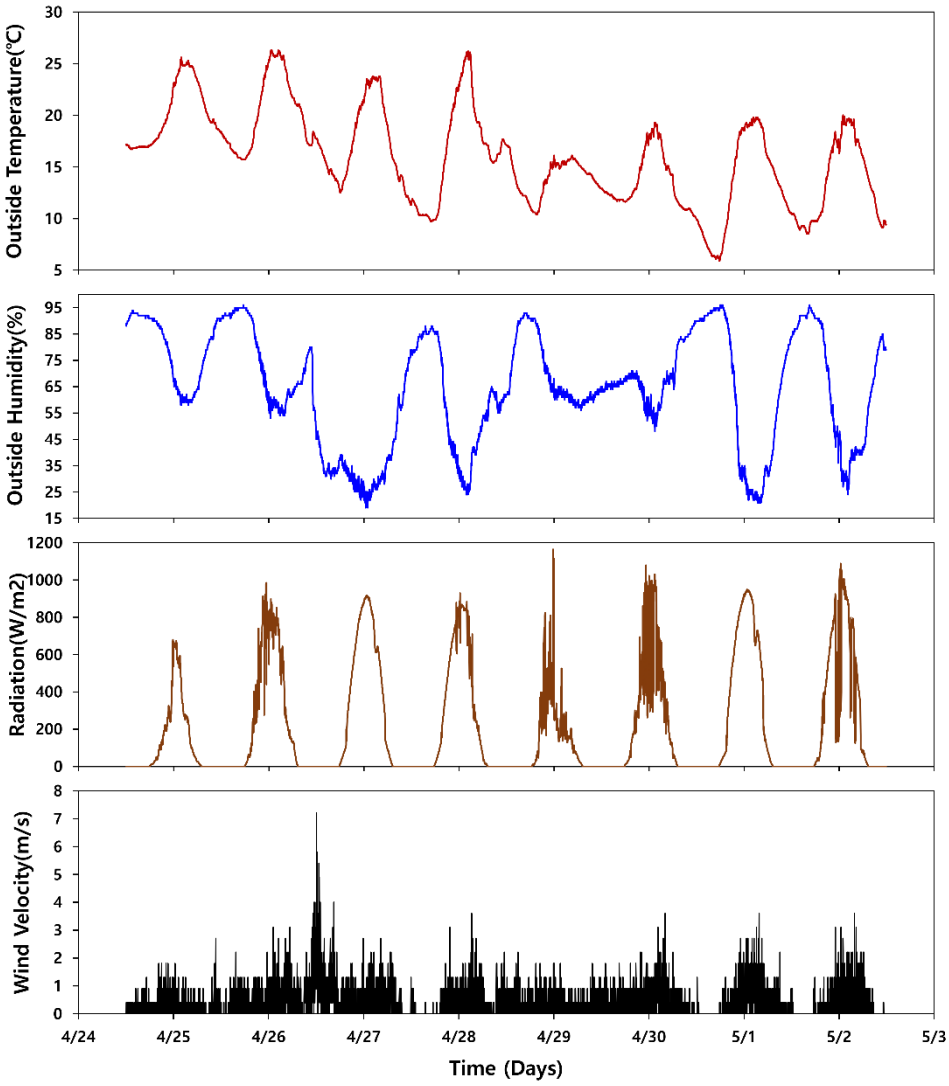

Figure 26. Changes in outside environmental conditions in the experiment

4. 결론

본 연구에서는 급격하게 변화하는 외부기상에 대응하여 온도 변화를 미리 예측하고 제어에 적용하기 위해 CNN 모델을 이용하여 온실 내부 온도 변화를 예측하는 모델을 개발하고 검증하였다. 학습 데이터 셋의 차이에 의한 모델의 성능 평가를 하였고 데이터 셋 내의 온도 변화 범위가 가장 다양하고 데이터의 양이 많았던 4월, 11월 1월 데이터 셋을 사용한 모델이 결정계수 R^2 0.91로 성능이 가장 우수하여 해당 모델을 최종 선발하였다.

또한 예측모델을 실제 제어에 활용하기 위해서는 실시간 온도 예측이 가능함을 보여야 했으며 온실에 설치한 내부센서, 외부 기상대를 통해 실시간으로 취득되는 데이터를 IoT 원격 통신을 활용하여 예측 모델이 탑재된 온실 제어용 PC로 데이터를 송신하였고 이를 실시간으로 모델에 적용하였다. 예측 시점은 온실 내 작동기들의 동작 시간과 동작으로 인해 온실 내부 온도가 변화하는 시간을 고려하여 30분 뒤의 온도를 예측하였다.

오프라인으로 검증한 온도 예측모델의 성능에 비해 낮은 정확도를 보였지만 실시간 온도 예측 또한 제어 온도 편차인 ±3℃ 안의 정확도를 확보하였기에 실시간으로 온도 예측이 가능함을 보였다.

최종적으로 실시간 온도 예측을 활용하여 본 연구에서 제시한 예측 제어식을 기반으로 예측 기반 제어를 수행한 결과 예측 온도에 대한 가중치를 높일수록 목표 온도와의 RMSE가 낮아져 정확도가 올라가는 것을 확인하였다.

본 연구를 통해 국내 단동형 온실의 시스템에 맞는 단순한 예측 제어식을 개발하여 제시하였으며 그 성능을 확인하였다. 향후 수많은 온도 예측 연구를 통해 출력되는 예측 온도를 본 연구에서 제시된 예측 제어식에 활용한다면 온도 예측 모델의 제어 성능을 쉽게 확인할 수 있으며, 개발된 예측 제어 기술을 통해 작물의 최적 생육 환경을 조성하여 작물의 생산성 증가에 기여할 수 있을 것으로 판단된다.

후속 연구로 예측 모델의 성능을 향상시키기 위해, 운량에 대한 고려, 계절에 대한 고려를 하여 예측 모델 학습을 수행할 필요가 있으며, 제어 성능을 향상시키기 위해서 예측 제어 계수 최적화에 대한 고도화가 필요해 보인다.

참고 문헌

1. Aytenfsu, S. A., Beyene, A. M., & Getaneh, T. H. (2020, July). Controlling the Interior of Greenhouses using Elman Recurrent Neural Network. In 2020 Fourth World Conference on Smart Trends in Systems, Security and Sustainability (WorldS4) (pp. 32-39). IEEE.
2. Chen, Y., Norford, L. K., Samuelson, H. W., & Malkawi, A. (2018). Optimal control of HVAC and window systems for natural ventilation through reinforcement learning. Energy and Buildings, 169, 195-205.
3. Dariouchy, A., Aassif, E., Lekouch, K., Bouirden, L., & Maze, G. (2009). Prediction of the intern parameters tomato greenhouse in a semi-arid area using a time-series model of artificial neural networks. Measurement, 42(3), 456-463.
4. Escamilla-García, A., Soto-Zarazúa, G. M., Toledano-Ayala, M., Rivas-Araiza, E., & Gastélum-Barrios, A. (2020). Applications of artificial neural networks in greenhouse technology and overview for smart agriculture development. Applied Sciences, 10(11), 3835.
5. Gharghory, S. M. (2020). Deep network based on long short-term memory for time series prediction of microclimate data inside the greenhouse. International Journal of Computational

Intelligence and Applications, 19(02), 2050013.

6. Jung, D. H., Kim, H. S., Jhin, C., Kim, H. J., & Park, S. H. (2020). Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. Computers and Electronics in Agriculture, 173, 105402.
7. Jung, D. H., Kim, H. J., Kim, J. Y., Lee, T. S., & Park, S. H. (2020). Model predictive control via output feedback neural network for improved multi-window greenhouse ventilation control. Sensors, 20(6), 1756.
8. Jeong, S., Park, I., Kim, H. S., Song, C. H., & Kim, H. K. (2021). Temperature prediction based on bidirectional long short-term memory and convolutional neural network combining observed and numerical forecast data. Sensors, 21(3), 941.
9. Lee, J., Oh, J., Cho, Y., & Lee, D. (2020). A Research about Time Domain Estimation Method for Greenhouse Environmental Factors based on Artificial Intelligence. Journal of Bio-Environment Control, 29(3), 277-284.
10. Liu, Y., Li, D., Wan, S., Wang, F., Dou, W., Xu, X., ... & Qi, L. (2022). A long short-term memory-based model for greenhouse climate prediction. International Journal of

Intelligent Systems, 37(1), 135-151.

11. Moon, T. W., Jung, D. H., Chang, S. H., & Son, J. E. (2018). Estimation of greenhouse CO2 concentration via an artificial neural network that uses environmental factors. Horticulture, Environment, and Biotechnology, 59(1), 45-50.

12. Su, Y., Yu, Q., & Zeng, L. (2020). Parameter self-tuning pid control for greenhouse climate control problem. IEEE Access, 8, 186157-186171.

13. Wang, Y., Velswamy, K., & Huang, B. (2017). A long-short term memory recurrent neural network based reinforcement learning controller for office heating ventilation and air conditioning systems. Processes, 5(3), 46.

14. Yu, H., Chen, Y., Hassan, S. G., & Li, D. (2016). Prediction of the temperature in a Chinese solar greenhouse based on LSSVM optimized by improved PSO. Computers and Electronics in Agriculture, 122, 94-102.

15. Yue, Y., Quan, J., Zhao, H., & Wang, H. (2018, August). The prediction of greenhouse temperature and humidity based on LM-RBF network. In 2018 IEEE International Conference on Mechatronics and Automation (ICMA) (pp. 1537-1541). IEEE.

16. Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018).

Convolutional neural networks: an overview and application in radiology. Insights into imaging, 9(4), 611–629.

17. Zou, W., Yao, F., Zhang, B., He, C., & Guan, Z. (2017). Verification and predicting temperature and humidity in a solar greenhouse based on convex bidirectional extreme learning machine algorithm. Neurocomputing, 249, 72–85.

Abstract

Development of Single-span Greenhouse Temperature Control Technology Based on CNN Temperature Prediction Model

Yoon Hong Yi
Department of Biosystems Engineering
The Graduate School
Seoul National University

Greenhouses have the advantage of creating an optimal environment for crop cultivation, but careful management is required to create an ideal cultivation environment. Plants exposed to high or low temperatures become stressed or sick, eventually decreasing productivity. In particular, as weather changes such as heat waves and heavy snow frequently occur due to global warming, there is an increasing need to develop greenhouse control technologies that can cope with rapidly changing external weather. This study developed a greenhouse control technology that predicts the temperature change inside the greenhouse based on the weather data inside and outside the greenhouse and uses it for greenhouse control to maintain the growth temperature in response to changes in the external weather. Convolutional neural network (CNN), one of the artificial neural network techniques, was used to predict changes in the internal temperature of the greenhouse after 30 minutes by inputting nine factors: internal temperature, internal humidity, external temperature,

external humidity, solar radiation, wind speed, and time. The prediction model was developed using seasonal data from April, November, and January observed in a single-type vinyl greenhouse at a farm affiliated with Seoul National University in Suwon. A real-time temperature change prediction system was constructed using Message Queuing Telemetry Transport (MQTT) communication to utilize the predicted temperature output through the prediction model for control. In this study, the prediction-based control equation was developed by adding the prediction control coefficient Kp, which considers the difference between the prediction temperature and the target temperature in conventional proportional control. The control targets are ventilation fans, skylights, side windows, hot fans, and multi-layered insulation curtains, and ventilation fans and hot fans control the operating time of skylights, side windows, and multi-layered insulation curtains proportionally. The target temperature setpoint was at 17-27°C, the growth temperature of cherry tomatoes, one of the greenhouses cultivated crops. To test the effect of the prediction-based control, the prediction control coefficient Kp value was increased to 0.1, 0.2, and 0.3 for two days each and compared each prediction-based control performance. As a result of the experiment, each of the prediction control coefficients, 0.1, 0.2, and 0.3, showed an average square root error (RMSE) of 3.2℃, 2.7℃, and 2.0℃ based on the target temperature. As the prediction control coefficient increased, the average square root error decreased. As a result of the prediction-based control experiment applied with the prediction model developed in this research, it was possible to predict the temperature change in real-time, and it was also possible to follow the target temperature by knowing and responding to the internal temperature change in advance.

Keywords : Single-span greenhouse, Greenhouse temperature control, Temperature prediction, Convolutional neural network, Prediction-based control
Student Number : 2020-24303

감사의 말

지난 석사 학위 과정 동안 정말 좋은 사람들을 만났고 많은 도움을 받았습니다. 학위를 마무리하며 감사의 인사를 드리고자 합니다.

먼저, 졸업에 이르기까지 저의 앞에서 이끌어 주신 김학진 교수님께 감사를 드립니다. 부산에서 올라온 저에게 기회를 주시고 저의 연구자적 시야를 넓혀 주셔서 감사합니다. 교수님께서는 연구를 진행함에 있어 가져야하는 자세와 나아가야할 방향성을 제시해 주셨습니다. 무언가 어려움에 부딪혔을 때 돌아가는 것이 아닌 큰 벽을 넘어야 성장할 수 있다는 교수님의 말씀이 가장 가슴에 와 닿았습니다. 박사과정을 미국으로 갈 수 있었던 것도 교수님의 덕이 크고 타국에서도 교수님의 가르침을 잊지 않도록 하겠습니다.

논문 심사위원으로 지도해주신 이중용 교수님께 감사드립니다. 중간 계획 발표부터 저의 졸업 발표까지 참여해주시면서 해 주신 세세한 피드백 덕분에 저의 학위논문이 완성도를 갖추었고 무사히 졸업을 할 수 있었습니다. 교수님의 피드백을 볼 때면 학생에 대한 무한한 관심과 연구에 대한 열정을 느낄 수 있었습니다. 다시 한번 감사드립니다.

저의 연구의 바탕이자 연구적으로 저를 옆에서 끝까지 이끌어 주셨던 정대현 교수님께 깊은 감사의 인사를 드립니다. 정대현 교수님의 온실 연구 주제를 이어받아 연구를 할 수 있어서 영광이었고 이 연구 주제를 맡을 수 있어서 정말 다행이라고 생각합니다. 제가 많이 부족하고 서툴어서 따라가기 벅찬 순간도 있었지만 그 때 마다 다그쳐가면서도 친절하게 하나하나 가르쳐 주셔서 제가 무사히 졸업을 할 수 있게 된 것 같습니다. 같이 재밌게 탁구를 칠 때는 연구실 큰형 같기도 하지만 연구적으로 지도를 해 주실 때는 정말 넘볼 수 없는 연구자의 모습을 본 것 같습니다.

부산대학교 때부터 저에게 많은 도움을 주신 김종순 교수님께 감사드리고 싶습니다. 대학원 진학을 희망하는 저에게 방향성을 제시해주시고 대학원에 진학한 선배분들에게도 연락을 하셔서 저에게 많은 조언과 도움을 주셨습니다. 교수님 덕분에 무사히 서울대학교에서 졸업을 마칠 수 있었습니다 감사합니다.

저의 영원한 사수인 조우재 교수님께 감사의 말 전합니다. 처음 연구실 들어와서 아무것도 모르는 저에게 많은 것을 가르쳐 주었고 연구실 생활하는데 정말 큰 버팀목이 되었습니다. 우재형이 졸업을 하고 가실 때는 정말 하늘이 무너지는 듯한 느낌이 들 정도로 저에게는

의지가 되었던 분입니다. 경상대의 교수가 된 이후에도 종종 연구실에 들러서 얼굴을 비추는 형이 얼마나 반가웠는지 모릅니다. 이른 나이에 교수가 되신 형을 롤 모델로 삼아서 앞으로 성실한 연구자가 되도록 하겠습니다.

우리 연구실의 큰형 창호형! 정말 제가 본 사람 중에 가장 농업에 대한 애정이 크고 연구에 대한 열정이 가득한 사람입니다. 형의 그런 열정을 보면서 형은 농업이 아니라 어떤 일을 하더라도 무언가 해낼 사람이라고 생각했습니다. 연구실의 큰형이지만 늘 실원들과 거리감 없이 장난도 치고 받아주는 형 덕분에 연구실의 분위기가 즐거웠던 것 같습니다. 농구는 저보다 살짝 못하시지만 열심히 하신다면 금방 저를 뛰어 넘을 수 있을 거라고 믿습니다. 창호형 파이팅!

온실 팀의 든든한 기둥인 민석이형. 저의 연구에도 정말 많은 도움을 주시고 연구적으로 질문이 있을 때면 언제든 편안하게 물어볼 수 있을 정도로 의지가 되었습니다. 양액 시스템을 혈혈단신으로 밤을 새워가며 만들어내는 형의 모습을 보고 정말 감탄을 금치 못했습니다. 형의 열정이라면 박사과정도 잘 해내리라 믿어 의심치 않습니다. 한이도 항상 건강하길 바라고 형도 늘 건강 잘 챙기시기를 바랍니다.

이제는 한 회사의 대표가 되어버린 찬우형. 나만의 작은 찬우형으로 남기를 바랐는데 형이 가진 재능이 너무나도 크네요. 처음 연구실에 지원을 할 때부터 친절하게 소개를 해 주시던 형의 모습이 아직도 새록새록한데 어느새 저도 졸업을 하게 되었네요. 앞으로도 AgMo의 미래가 창창하기를 바라며 제가 한국에 돌아왔을 때는 한국을 대표하는 농기계 회사가 되어 있을 것을 의심치 않습니다.

우리 연구실의 엄마 같은 존재 동욱이형. 형과는 연구실을 깨끗하게 유지하거나 물건을 정리하는 부분에 있어서 비슷한 점이 많아 정말 좋았습니다. 노력에도 불구하고 금방 어질러졌지만 형의 노력덕에 연구실이 쾌적하게 유지됐던 것 같습니다. 늘 남들보다 앞에 나서서 솔선수범을 보였던 형 덕분에 실원들도 믿고 따르면서 연구실 생활을 할 수 있었던 것 같습니다. 앞으로 남은 박사과정 잘 마무리하시고 건강하시길 바랍니다.

우리 연구실의 만능 엔터테이너 예빈이형. 연구적으로도 뛰어나지만 정말 할 줄 아는 것도 많고 지식도 많은 다재 다능한 형이라고 느꼈습니다. 인생을 진정으로 즐길 줄 아는 형이 챔피언입니다. 늘 연구실에 웃음을 가져다줘서 즐거운 연구실 생활할 수 있었습니다. 감사합니다.

인턴때의 질긴 인연이 벌써 3년차가 되어가는 승진이. 처음 연구실 들어왔을 때부터 동갑내기 친구로 의지가 많이 되었고 다음해에 연구실에 들어왔을 때 정말 반가웠어. 조용한 것 같으면서도 할말은 다하는 소신 있는 너의 모습이 정말 좋았어. 남은 졸업 마무리 잘하고 졸업 이후에도 늘 너의 앞길에 성공이 있길 바랄게.

늘 쾌활한 주신이. 너의 긍정적인 바이브는 늘 주변사람들로 하여금 힘이 나게 하는 것 같아. 나한테는 연구적으로 가장 도움을 많이 준 정말 없어서는 안 될 존재였어. 같이 2년 가까이 연구하면서 많은 사건 사고가 있었지만 정말 재밌었어. 너가 가진 능력이라면 원하는 국제기구 취업도 무리 없을 거라고 생각해. 늘 응원하고 다시 한번 감사의 말을 전할게.

언제나 든든하게 형들의 뒤를 봐주는 경민이. 첫인상과 다르게 순수한 내면을 가진 경민이. 너의 연애 사업에 도움이 되지 못해 정말 미안하다. 앞으로는 연구길만 걷자.. 성실히 연구하다 보면 좋은 인연이 나타날 것이라고 생각한다. 앞으로 연구와 연애 두 마리 토끼를 잡기를 바랄게.

항상 열정으로 가득 찬 규진이. 동생이지만 연구적으로는 늘 선배 같고 형 같았고 너의 연구에 대한 열정은 본 받을 필요가 있다고 생각했어. 지금 하는 대로만 하면 정말 좋은 연구자가 될 것이라고 장담해. 자신이 하는 일에 의심을 갖지 말고 자신 있게 하면 좋은 결과가 있을 거야. 형들이 많이 놀리는데도 늘 잘 받아주고 웃어넘겨줘서 고맙고 항상 건강하기를 바랄게.

연구실 막내 용현이. 형들이랑 있는데도 기죽지 않고 오히려 형들을 놀리는 너의 모습 존경한다. 온실 팀, 트랙터팀 가리지 않고 좋은 연구 역량을 보여준 너라면 어떤 연구를 하든 좋은 연구자가 될 것이라고 생각한다. 앞으로 형들이 졸업하면 연구실을 이끌어갈 기둥이 될 인재라고 생각하고 앞으로도 웃음 잃지 않고 즐거운 연구실 생활했으면 좋겠어.

니샤디에게. 먼 스리랑카에서 한국까지 연구를 하러 온 것에 대해 정말 대단하다고 생각하고 이제는 연구실원들과도 친하게 지내는 모습을 보면 진정한 연구실원이 된 것 같아. 한국말도 열심히 공부하고 연구 또한 성실히 하는 모습을 옆에서 지켜보면 앞으로 남은 연구 생활도 잘 할 수 있을 것이라고 생각해. 한국에서 성공적인 연구자가 되길 바랄게.

그리고 서울에 홀로 아들을 보내서 늘 걱정이 많으셨던 부모님에게 졸업의 영광을 돌립니다. 대학원에 오게 된 이유이자 저의 롤 모델이신

아버지에게 먼저 감사의 말을 전하고 싶습니다. 항상 여유가 많은 저를 걱정하셨던 아버지였지만 한 편으로는 저를 가장 믿어 주신 분이십니다. 그리고 둘째아들 걱정 많이 하신 어머니에게도 늘 걱정해주시고 저를 위해서 기도해 주셔서 감사합니다. 덕분에 무사히 졸업을 할 수 있었습니다. 그리고 우리 집의 큰 기둥인 형에게도 늘 건강한 모습으로 있어줘서 고맙고 저의 분신인 쌍둥이 혁이에게도 감사의 말 전하고 싶습니다.

고향을 떠나 먼 서울에서 혼자 있는 저를 늘 아들처럼 챙겨 주시고 아껴 주신 도이네 아버지와 어머니 그리고 할머니에게도 감사드립니다. 이제는 정말 한 가족이 되어서 기쁜 마음이 정말 크고 앞으로도 아들 같은 역할 잘 할 테니 지켜봐 주세요.

마지막으로 나의 사랑 도이에게 이 영광을 돌립니다. 서울에 와서 석사학위를 무사히 마친 것도 정말 감사한 일인데 일평생의 짝을 만나게 되다니 전생에 나라를 구했나 봅니다. 같이 미국으로 박사과정을 가게 되었는데 지금처럼 서로에게 힘이 되어준다면 어떤 일이든 잘 헤쳐 나갈 수 있을 거라고 믿습니다. 항상 제 곁에 있어줘서 고맙고 사랑합니다.

2022년 8월 8일

이윤홍 올림