JDCS
디지털콘텐츠학회논문지
Journal of Digital Contents Society
Vol. 25, No. 2, pp. 557-565, Feb. 2024

4계절 딸기 생육을 위한 스마트팜 센서 데이터 및 딥러닝 예측 모델

박 철 홍[1‡] · 이 수 창[1‡] · 이 미 정[2] · 김 진 영[3] · 유 광 현[4*]
[1‡] 전남대학교 전자컴퓨터공학과 연구원 [2]담양군농업기술센터 농업연구사
[3]전남대학교 ICT융합시스템공학과 교수 [4*]전남대학교산학협력단 박사후연구원

Smart Farm Sensor Data and Deep Learning Prediction Models for Strawberry Growth in All Seasons

Chul-Hong Park[1‡] · Soo-Chang Lee[1‡] · Mi-Jeong Lee[2] · Jin-Young Kim[3] · Gwang-Hyun Yu[4*]

[1‡] Researcher, Department of Electronic and Computer Engineering, Chonnam National University, Gwangju 61186, Korea
[2]Agricultural Researcher, Agricultural Technology Center, Damyang 57365, Korea
[3]Professor, Department of ICT Convergence System, Chonnam National University, Gwangju 61186, Korea
[4*]Postdoctoral Researcher, Department of ICT Convergence System, Chonnam National University, Gwangju 61186, Korea

[요 약]

스마트팜은 연중무휴로 작물을 재배할 수 있으며, 생육환경을 센싱하고 제어함으로써 농가의 생산량을 향상시킬 수 있다. 본 논문은 농가에서 가장 높은 소득원인 딸기를 4계절 재배할 수 있는 스마트팜과 스마트팜 생육환경 센서 데이터를 예측하는 딥러닝 모델을 소개한다. 제안하는 스마트팜은 생육환경 원격 제어 및 데이터를 수집하고 이를 기반으로 인공신경망, 순환신경망, 합성곱신경망의 대표적인 딥러닝 모델들을 비교 실험하여 시기별 생육환경을 예측한다. 실험 결과, 온도와 습도 센서는 LSTM 모델이, 이산화탄소 센서는 TCN 모델이 최적의 성능을 보여주었다. 따라서 딥러닝 모델을 통해 이상적인 딸기 생육환경을 조성할 수 있도록 기대된다.

[Abstract]

Smart farming, through sensing and controlling the growth environment, enables year-round crop cultivation, enhancing agricultural productivity. This paper introduces a smart farm specializing in year-round cultivation of strawberries, a highly profitable crop for farmers. It incorporates a deep learning model predicting sensor data for the smart farm's growth environment. The proposed smart farm facilitates remote environmental control and data collection. Representative deep learning models such as artificial neural networks, recurrent neural networks, and convolutional neural networks are experimentally compared in terms of their prediction performance for seasonal growth environments. Results indicate that the LSTM model excels with temperature and humidity sensors, whereas the TCN model performs best with carbon dioxide sensors. This suggests potential for creating an ideal strawberry growth environment through the application of deep learning models.

색인어 : 스마트팜, 딸기, 생육환경, 예측 모델, 딥러닝
Keyword : Smart Farm, Strawberry, Growth Environment, Prediction Model, Deep Learning

http://dx.doi.org/10.9728/dcs.2024.25.2.557

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 26 December 2023; **Revised** 24 January 2024
Accepted 29 January 2024

‡ These authors contributed equally to this work
***Corresponding Author; Gwang-Hyun Yu**
Tel: +82-62-530-0380
E-mail: sayney1004@gmail.com

Ⅰ. 서 론

스마트팜이란 비닐하우스, 축사, 돈사, 과수원 등 운영에 정보기술을 접목하여 작물과 가축의 생육환경을 적정하게 유지·관리할 수 있는 농장을 의미한다[1]. 스마트팜을 농업 현장에 도입함으로써 작물 생육정보와 환경정보에 대한 데이터를 기반으로 최적 생육환경을 조성할 수 있고, 노동력·에너지 등을 종전보다 덜 투입하고도 농산물의 생산성 향상과 품질 제고를 실현할 수 있다[2].

농촌진흥청에서는 스마트팜을 수준별로 모델화하여 기술의 단계적 개발과 실용화를 추진해가고 있다. 한국형 스마트팜 1세대 모델에서는 온실 내부에 각종 환경 센서 및 폐쇄 회로 텔레비전 등을 설치하여 온실 환경을 관찰하고, 설정된 환경을 원격으로 제어하여 농업작업의 편리성 향상을 목표로 한다. 한국형 스마트팜 2세대 모델에서는 온실 내부의 대기·토양 환경과 작물 스트레스를 실시간으로 관측하여 지능형 환경제어 알고리즘을 적용하여 환경을 제어하고, 빅데이터 분석을 통한 영농의 의사결정을 지원하는 서비스를 제공하여 최적 생육환경 제어를 통한 생산성과 품질 향상을 목표로 한다. 한국형 스마트팜 3세대 모델에서는 복합에너지 최적 제어 기술을 적용하여 에너지 소비량을 줄이고, 로봇 및 지능형 농기계를 이용하여 농업작업을 자동화하고, 작물의 영양과 질병 감염 상태를 조기에 진단하고 처방하는 기술개발을 그 목표로 한다[3]. 또한 농산물 소득 조사 결과 생산된 50개 농산물의 소득 중 소득이 높은 작목은 촉성오이, 시설가지, 시설딸기 등 시설작목이었다[4].

이러한 점에 착안하여 본 논문에서는 농가에서 가장 높은 소득이 보장되는 딸기를 1년 내내 최적 생육 환경 제어를 통한 생산성과 품질을 향상시킬 수 있는 스마트팜을 제안한다. 제안하는 스마트팜은 내부에 각종 환경 센서와 정보기술이 접목된 제어기가 설치되어 원격으로 딸기 생산이 극대화되는 조건으로 온도, 습도, 이산화탄소 등의 환경 조건이 제어되고, 실시간으로 생육환경 데이터가 수집된다. 수집된 생육환경 데이터를 기반으로 기계학습 및 딥러닝 예측 모델을 제안하고, 이를 통해 최적의 스마트팜 생육환경 제어를 위해 사용한다.

본 논문의 구성은 다음과 같다. 2장에서는 스마트팜과 스마트팜 데이터를 활용한 다양한 연구를 살펴보고, 3장에서는 스마트팜과 환경 센서 데이터 및 제어 기술을 설명한다. 4장에서는 시기별 생육환경 값 예측 모델의 실험 결과 및 분석에 관하여 기술하고, 5장에서는 결론을 기술한다.

Ⅱ. 관련 연구

2-1 스마트팜 모델 제시 연구

스마트팜 구성을 위한 연구로는 스마트팜 운영에 필요한 각종 기기를 클라우드 상에서 운영하는 클라우드 기반 스마트팜 기술과 ICT 기술과 빅데이터를 활용한 스마트팜 모델 연구[5]와 4차 산업의 기반 기술인 빅데이터, 인공지능, 클라우드 기술을 적용한 스마트팜 통합 플랫폼[6] 연구가 있다. 위와 같은 연구들은 신기술 기반의 스마트팜 모델을 제시하지만 실제 운영되는 스마트팜은 없다.

2-2 스마트팜 운영 연구

실제 스마트팜을 운영하면서 수행하는 연구로는 스마트팜 환경모니터링 및 원격제어[7]와 다중 센서를 이용한 스마트팜 특성 연구[8]가 있다. 두 연구 모두 스마트폰을 통해 환경정보를 모니터링하고 정해진 최적 생육 환경으로 제어가 가능하였지만, 데이터를 분석하고 예측 모델을 통해 최적의 생육환경 제어값을 도출하지는 않았다.

2-3 예측 모델을 활용한 스마트팜 연구

예측 모델을 활용한 스마트팜 연구로는 스마트 축사에서 축사의 환경데이터를 기반으로 학습된 딥러닝 예측 모델로 사료를 적정하게 공급할 수 있는 연구[9]와 스마트팜 토마토 환경 데이터를 기반으로 토마토 수확시간을 예측하는 딥러닝 모델 연구[10], 스마트팜 환경데이터 기반 파프리카 엽장과 엽폭을 예측하는 다중선형회귀 모델을 제시한 연구[11] 등이 있다.

2-4 딸기 스마트팜 연구

딸기와 관련된 스마트팜 연구로는 딸기의 수확 시기를 예측할 수 있도록 딸기 이미지를 기반으로 학습한 딥러닝 분류 모델 연구[12]와 딸기의 잎과 꽃 과실 이미지를 6단계의 생육 단계로 분류하고 이를 ResNet50 모델 기반으로 학습한 연구[13]가 있다.

스마트팜 센서 및 생육환경 데이터를 기반으로 예측 모델을 활용한 연구는 다양한 작물에 적용되고 있지만 아직 딸기 작물에서는 연구가 부족하다. 특히 딸기 스마트팜과 관련해서는 딸기 작물 이미지를 중점으로 연구되고 있다.

따라서, 본 논문에서는 4계절 딸기를 생육할 수 있는 스마트팜을 제안하고, 수집되는 생육환경 데이터를 기반으로 예측 모델을 연구하여, 시기별 최적의 딸기 생육환경을 제어할 수 있는 값을 도출하고자 한다.

Ⅲ. 스마트팜

3-1 스마트팜 구성

본 논문에서 제시하는 4계절 딸기를 생육할 수 있는 스마트팜은 길이 11,554mm, 폭 2,286mm, 높이 2,216mm의 40

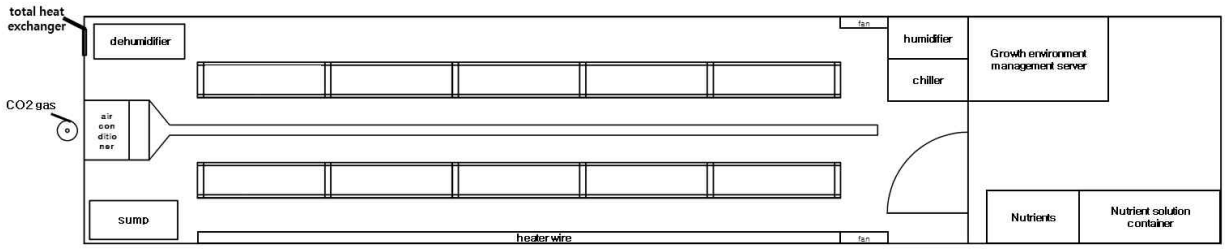

그림 1. 스마트팜 내부 구성도
Fig. 1. Smartfarm internal configuration diagram

그림 2. 스마트팜 단열 작업
Fig. 2. Smartfarm insulation work

그림 3. 생육실 전경
Fig. 3. View of the growth room

피트 컨테이너를 토대로 구성된다. 스마트팜 내부는 그림 1과 같이 딸기를 키우는 생육실과 생육실에 설치된 생육환경 데이터를 수집하고 생육환경을 제어하고, 양액을 관리하는 제어실로 구성된다.

4계절 딸기 생육을 위한 스마트팜은 그림 2와 같이 40피트 컨테이너 외부에 단열재와 홑강판을 설치하고, 바닥에는 단열재와 타일을 시공하여 여름철과 겨울철을 위한 단열을 보강한다.

생육실에는 냉난방기, 칠러, 열선, 가습기, 제습기, 팬, 전열교환기, 이산환탄소 가스가 설치된다. 특히 냉난방기는 덕트를 통해서 생육실 전체로 골고루 냉난방이 전달된다.

생육실 중앙에는 딸기를 생육할 수 있는 3층으로 구성된 5칸짜리 배지 프레임이 2줄로 설치되고, 1칸의 배지 프레임에는 토경 화분이 2개 설치된다. 배지 프레임에는 제어실의 양액기 파이프가 연결되고 각 칸마다 식물성장용 LED(Light Emitting Diode)가 설치된다. 배지 프레임 각 층에는 딸기 생육환경 데이터를 수집할 수 있는 센서가 설치된다. 그림 3은 생육실 구성을 보여준다.

제어실에는 양액통과 양액기가 설치되어 생육실의 배지 프레임으로 연결된 파이프를 통해 양액이 관수된다. 또한 생육실에 설치된 센서 데이터를 수집하고 스마트팜 생육환경을 제어할 수 있는 서버가 설치된다.

3-2 생육환경 제어

생육실에 설치된 냉난방기, 칠러, 열선, 가습기, 제습기, 팬, 전열교환기, 이산환탄소 가스는 IoT(Internet of Things)기술이 접목된 제품을 사용하여 스마트폰 어플리케이션을 통해 스마트팜 생육환경 제어가 가능하다.

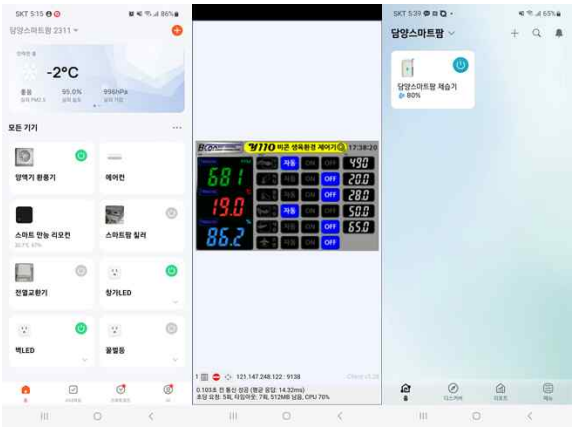

*Smartphone application content is only displayed in Korean.

그림 4. 스마트팜 생육환경 제어를 위한 스마트폰 어플리케이션
Fig. 4. Smartphone application for controlling smart farm growth environment

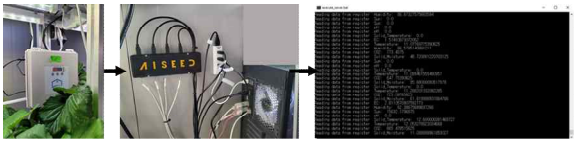

그림 5. 스마트팜 생육환경 데이터 수집
Fig. 5. Smart farm growth environment data collection

그림 4와 같이 스마트폰 어플리케이션을 통해 스마트팜의 시간별, GPS(Global Positioning System)별, 생육환경 조건별 온도, 습도, 이산화탄소 농도, 식물성장용 LED 및 공기순환을 제어할 수 있다.

4계절 딸기 생육을 위한 스마트팜 생육환경 제어는 딸기 재배를 전문적으로 하는 담양농업기술센터 연구사님의 노하우를 기반으로 시기별, 시간별, 일출, 일몰 조건에 따라 제어값을 제어한다.

3-3 생육환경 데이터 수집

제어실의 생육환경 관리 서버는 생육환경 데이터를 수집할 수 있는 센서 정보를 실시간으로 수집할 수 있다. 생육환경 관리 서버와 센서는 RS485 유선통신 프로토콜을 통해 분단위로 데이터를 전송받는다.

그림 5와 같이 생육환경 센서 데이터는 일시, 온도, 습도, 이산화탄소 농도, 광량, EC농도, pH농도가 수집되고, 센서 상태 모니터링을 위해 온도, 습도, 이산환탄소 농도, 조도, EC, pH 센서 상태가 전송된다.

Ⅳ. 시기별 생육환경 값 예측 모델

4계절 딸기 생육을 위한 스마트팜 생육환경 제어를 위해서 시기별 최적의 온도, 습도, 이산화탄소 농도 및 광량 조건으로 생육실을 제어하는 것이 중요하다. 이를 위해 본 장에서는 센서에서 수집되는 생육환경 데이터를 기반으로 시기별 생육환경 값을 정확히 예측하는 모델을 연구한다.

4-1 생육환경 데이터셋

4계절 딸기 스마트팜의 시기별 생육환경 데이터는 분단위로 일시, 온도, 습도, 이산화탄소 농도, 광량, 양액 EC 및 pH 농도가 수집된다. 본 연구에서는 6월 20일 0시부터 11월 15일 23시 59분까지 207,360개의 6개 센싱 데이터를 수집하였다. 딸기 생육환경 관리를 하시는 담양농업기술센터 연구사님의 노하우를 반영하여 1분 단위 데이터에서 1시간 단위 데이터로 변경하고, 온도, 습도, 이산화탄소 농도 센서 데이터만을 사용하는 것으로 데이터 범위를 결정하였다. 최종적으로 전체 원본 데이터로부터 6월 20일 0시부터 11월 15일 23시까지 1시간 간격의 3,456개의 3개 센싱 데이터를 최종적으로 사용한다. 총 3,456개의 3개 센싱 데이터 중 일부는 센서 상태값에 따라 NaN(Not a Number)값이 포함되어 있어, 전처리를 위해 NaN값이 존재하는 데이터는 날짜를 확인하여 NaN값 이전 시간들의 센서 값의 평균값으로 대체하였다. 생육환경 데이터셋 통계는 표1과 같다. 시기별 생육환경 값 예측 모델 데이터셋으로 사용하기 위해 온도, 습도, 이산화탄소 농도를 0과 1사이로 정규화하여 사용한다.

표 1. 데이터셋 통계
Table 1. Dataset statistics

	Temperature	Humidity	CO2
Min	9.18	45.18	393.16
Max	33.91	93.40	2429.88
Average	21.58	75.13	698.13

4-2 시기별 생육환경 값 예측 모델

센서에서 수집되는 생육환경 데이터를 기반으로 시기별 생육환경 값을 정확히 예측하는 모델 연구는 시계열 데이터 예측(Time Series Forecasting) 문제와 유사하다. 이 중 온도, 습도, 이산화탄소 농도의 시기별 값을 예측하는 문제는 단변량 시계열 예측 문제[14]와 동일하다.

$$\hat{y}_{i,t+1} = f(y_{i,t-k:t}, x_{i,t-k:t}, s_j) \tag{1}$$

식 (1)은 시계열 예측 문제를 일반적으로 정의하는 수식으로 여기서, $\hat{y}$는 예측하는 값이고, x와 y는 입력값, t는 시간, k는 윈도우 크기(window size)이고, s_i는 시간이 변해도 바뀌지 않는 값을 의미한다. 따라서 단변량 시계열 예측 문제는 $t-k$번째부터 t까지의 입력 값과 시간이 변해도 바뀌지 않는 값을 f라는 함수에 넣어서 얻어진 예측값이라고 정의할 수 있다. 시계열 데이터를 이용하여 단변량 시계열 예측 기초 모델을 구성할 수 있으며 식 (2)와 (3)과 같다.

$$z_t = g_{encoder}(y_{t-k:t}, x_{t-k:t}, s) \tag{2}$$

$$f(y_{t-k:t}, x_{t-k:t}, s) = g_{decoder}(z_t) \tag{3}$$

여기서, z_t는 잠재 벡터(latent vector)이다. 입력값을 인코더(encoder)를 통해서 잠재 벡터를 도출하고, 도출된 잠재 벡터를 디코더(decoder)를 통해 최종적인 예측을 한다. 이때 $g_{encoder}$에 들어갈 수 있는 다양한 딥러닝 모델들이 존재하고, $g_{decoder}$는 단순한 선형 함수부터 시퀀스 투 시퀀스(sequence to sequence)와 같은 딥러닝 모델 구조를 포함할 수 있다. 일반적으로 단변량 시계열 예측을 위한 딥러닝 모델은 시퀀스 투 시퀀스 구조가 아닐 경우 $g_{encoder}$만 사용하게 된다. 그림 6은 단변량 시계열 예측을 위한 대표적인 딥러

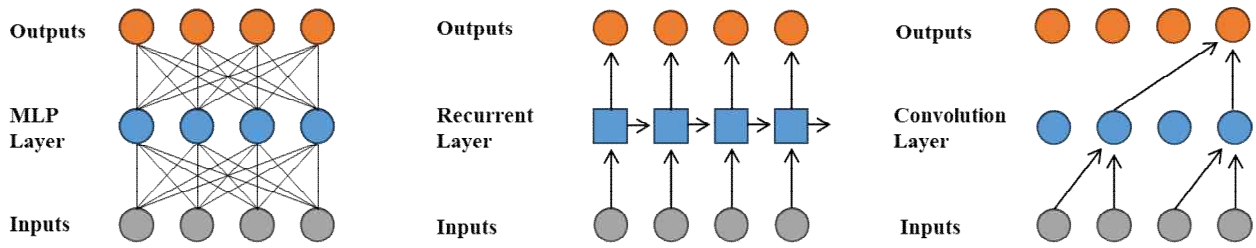

(a) (b) (c)

그림 6. 단변량 시계열 예측을 위한 대표적인 딥러닝 모델
Fig. 6. Representative deep learning model for univariate time series prediction

닝 모델을 3가지 타입으로 구분한 것이다. (a)는 인공 신경망(ANN: Artificial Neural Network), (b)는 순환 신경망(RNN: Recurrent Neural Network), (c)는 합성곱 신경망(Convolutional Neural Network)이다.

1) 인공 신경망 기반 단변량 시계열 예측

인공 신경망[15] 기반의 단변량 시계열 예측 방법론은 그림 7의 (a)와 같이 단순화시킬 수 있다. 뉴런(neuron)이란 딥러닝 모델을 이루는 노드(node)로 입력을 받아 가중치(weight)와 곱해지고, 편향(bias)을 더해주고 활성 함수(activation function)에 따라 연산된 값을 출력하는 구조이다.

$$y = f(W_k x_k + b_k) \tag{4}$$

식 (4)는 일반적인 인공 신경망 모델을 수식으로 표현한 것으로 y는 예측 값, W_k는 가중치, x_k는 입력, b_k는 편향, f는 활성 함수를 의미한다. 이것을 계속 쌓으면 다층 인공 신경망이 된다. 시계열 예측에서는 과거의 정보를 입력으로 가중치와 편향을 활성함수를 통한 연산된 값으로 예측값 y로 얻는다. 단순하고 짧은 기간의 데이터에서는 좋은 성능을 보이지만, 빅데이터에서는 좋은 성능을 보이지 않으며 완전 연결층(fully connected layer)를 사용하므로 파라미터수가 많은 단점을 가진다.

2) 순환 신경망 기반 단변량 시계열 예측

순환 신경망[16] 기반의 단변량 시계열 예측 방법론은 그림7의 (b)와 같이 단순화하여 표현될 수 있다. 순환 신경망이란 은닉층(hidden layer)을 순환(recurrent)하여 이전 상태의 은닉층의 출력값이 현재 상태의 은닉층의 입력으로 들어가 연산에 포함되는 구조를 의미한다. 순환 신경망의 출력을 수식으로 표현하면 다음과 같다.

$$y_t = f([Ux_t, vh_{t-1}] + b_k) \tag{5}$$

여기서 y_t는 현재 입력에 대한 출력을 나타내고, f는 활성함수, U는 입력에 대한 연결계수, x_t는 현재 입력, v는 이전 은닉층에 대한 연결계수, h_{t-1}은 이전 은닉층의 출력, b_k는 편향을 의미한다. 시계열 예측 문제에서는 과거의 정보를 입력으로 메모리 상태(memory state)를 통해 과거의 정보를 기억할 수 있는 구조로 시계열 데이터에 가장 적합한 구조이다. 일반적인 순환 신경망 구조를 보완한 LSTM(Long Short-Term Memory)[17], GRU(Gated Recurrent Neural Networks)[18]와 같이 변형된 순환 신경망도 시계열 예측 연구에 사용된다. 하지만 윈도우 크기가 고정되어 있기 때문에 예측하는 지점에서 멀리 떨어진 시계열 값들에 대한 관계성이 잘 학습되지 않은 문제와 구조상 데이터를 순차적으로 처리해야 하므로 병렬화가 불가능하다는 약점을 가진다.

3) 합성곱 신경망 기반 단변량 시계열 예측

합성곱 신경망[19]은 이미지 분류(classification)에서 많이 사용되는 딥러닝 모델로, 컨벌루션 필터(convolution filter)와 풀링 필터(pooling filter)를 반복적으로 수행하면서 입력 이미지의 특징을 추출하는 구조이다. 시계열 데이터를 합성곱 신경망에 적용하기 위해서는 컨벌루션 필터를 과거의 데이터만 볼 수 있도록 인과적 컨벌루션(causal convolution) 설계가 필요하다.

$$h_t^{l+1} = A((W*h)(l,t)) = \sum_{\tau=0}^{k} W(l,\tau) h_{t-\tau}^{l} \tag{6}$$

여기서, h_t^l은 입력에 대한 컨벌루션 출력값, 필터 가중치 $W(l,\tau)$는 필터 가중치, A는 활성함수이다. 따라서 각 레이어를 지난 압축 정보는 잠재값 z_t가 된다. 또한 더 큰 수용 필드(Receptive filed)를 가지면서도 계산량을 감소시키기 위해 확장 컨벌루션(Dilated convolution)을 사용한다. 일반적인 인과적 컨벌루션에서는 레이어를 깊게 쌓아도 큰 수용 필드를 만드는 것에 한계가 있다. 이는 먼 과거에 영향을 받는 시계열 데이터 특징을 얻는 것을 어렵게 만든다. 하지만 확장 컨벌루션을 사용하게되면 레이어가 깊어짐에 따라 수용 필드가 지수적으로 증가하여 먼 거리의 시계열 데이터 특징을 얻을 수 있다. 이와 같이 합성곱 신경망을 시계열 예측 문제 해결에 중점을 둔 모델을 시간적 합성곱 신경망(Temporal Convolution Neural Network)[20]이라고 한다.

4-3 실험 및 결과 분석

1) 실험

센서에서 수집되는 생육환경 데이터를 기반으로 시기별 생육환경 값을 정확히 예측하는 모델을 연구하는 실험은 챕터 4-1의 생육환경 데이터셋에서 구축된 1시간 간격의 3,456개의 온도, 습도, 이산화탄소 농도 데이터셋을 사용한다. 기간은 2023년 6월 20일 0시부터 2023년 11월 15일 23시까지 총 148일간이다. 전체 데이터 3,456개 중 90%는 학습용 10%는 테스트용으로 사용하였다.

시기별 생육환경 값 예측 모델을 위해서 단변량 시계열 예측에서 많이 활용되는 ANN, LSTM, GRU, TCN을 실험한다. 시기별 생육환경 값 예측을 위한 딥러닝 예측 모델들에 대한 입력값은 168시간으로 일주일에 해당되는 시간이고, 예측값은 6시간, 12시간, 24시간을 기준으로 비교 실험한다.

표 2는 시기별 생육환경 값 예측을 위한 딥러닝 예측 모델별 하이퍼 파라미터를 정리한 내용이다. 인공 신경망은 3개의 은닉층을 각각 512, 128, 64개의 노드로 구성하였고, 순환 신경망인 LSTM과 GRU는 3개의 은닉층을 각각 64, 120, 100개의 노드로 구성하였다. 시간적 합성곱 신경망은 2^n을 기준으로 1, 2, 4, 8의 확장 컨벌루션층을 쌓고, 컨벌루션 필터 크기는 3이다. 모든 딥러닝 예측 모델들의 배치 크기는 512이고 에폭은 10으로 학습하였고, 옵티마이저는 아담 옵티마이저를 사용하였다. 평가지표로는 평균 제곱 오차(MSE: Mean Squared Error)와 평균 절대 오차(MAE: Mean Absolute Error)를 사용하였다. 평균 제곱 오차는 식 (7)과 같이 실제 정답 값과 예측 값의 차이를 제곱한 뒤 평균을 구하는 것으로 값이 낮을수록 좋다. 평균 절대 오차는 식 (8)과 같이 실제 정답 값과 예측 값의 차이를 절댓값으로 변환한 뒤 합산하여 평균을 구한 것으로 값이 낮을수록 좋다.

표 2. 딥러닝 예측 모델별 하이퍼 파라미터
Table 2. Hyperparameters for each deep learning prediction model

	ANN	LSTM	GRU	TCN
num_hidden_layer	[512, 128, 64]	[64, 120, 100]	[64, 120, 100]	[1, 2, 4, 8]
input	168			
output	[6, 12, 24]			
epoch	10			
batch_size	512			
optimizer	adam			

$$MSE = \frac{\sum_{i=1}^{n}(y-\hat{y})^2}{n} \tag{7}$$

$$MAE = \frac{\sum_{i=1}^{n}|y-\hat{y}|}{n} \tag{8}$$

두 평가지표 모두 직관적이고 시계열 예측 및 회귀 모델(regression model)을 평가할 때 주로 사용하는 평가지표이다.

2) 실험 결과 분석

표 3부터 표 5는 시기별 생육환경 값 예측을 위한 딥러닝 예측 모델별 실험 결과이다. 4계절 딸기 생육을 위한 스마트팜의 시기별 온도와 습도 값 예측은 LSTM 모델이 다른 딥러닝 예측 모델들보다 좋은 성능을 보였다. 시기별 이산화탄소 값 예측은 시간적 합성곱 신경망 모델이 다른 딥러닝 예측 모델들보다 우수한 성능을 보였다. 모든 결과는 6시간 예측 모델, 12시간 예측 모델, 24시간 예측 모델에서 동등한 결과를 보였다.

시기별 생육환경 값 예측을 위한 딥러닝 예측 모델별 실험 결과를 분석하면 표 1과 같이 온도 데이터는 9~33도의 범위 분포를 가지고, 습도 데이터는 0~100%의 범위 분포를 가진 반면 이산화탄소는 393~2429 농도 범위 분포를 가진다. 따라서 딥러닝 예측 모델에 데이터셋을 정규화하여 학습한다고 하여도 데이터 수 대비 데이터 분포 범위가 온도와 습도보다 상대적으로 큰 이산화탄소 농도 데이터의 경우 더 안좋은 데이터라고 할 수 있다. 온도와 습도 데이터는 상대적으로 좋은 데이터라고 보이기 때문에 전통적으로 시계열 데이터 예측에서 좋은 성능을 보이는 LSTM이 우세한 성능을 보였고, 이산화탄소 농도 데이터는 덜 좋은 데이터이기 때문에 시간적 합성곱 신경망 모델이 좋은 성능을 보인 것으로 분석할 수 있다.

표 3. 딥러닝 예측 모델별 실험 결과(온도)
Table 3. Experiment results for each deep learning prediction model (temperature)

Time	ANN		LSTM		GRU		TCN	
	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
6	0.0191	0.1114	**0.0153**	**0.0917**	0.0457	0.1777	0.0366	0.1577
12	0.0612	0.2072	**0.0184**	**0.1025**	0.0273	0.1326	0.0331	0.1436
24	0.0416	0.1725	**0.0192**	**0.1045**	0.0238	0.1212	0.0386	0.1578

표 4. 딥러닝 예측 모델별 실험 결과(습도)
Table 4. Experiment results for each deep learning prediction model (humidity)

Time	ANN		LSTM		GRU		TCN	
	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
6	0.0152	0.0993	**0.0151**	**0.0991**	0.0191	0.1107	0.0173	0.1046
12	0.0201	0.1154	**0.0146**	**0.0971**	0.0162	0.1024	0.0180	0.1061
24	0.0148	0.0977	**0.0145**	**0.0967**	0.0148	0.0980	0.0190	0.1101

표 5. 딥러닝 예측 모델별 실험 결과(이산화탄소)
Table 5. Experiment results for each deep learning prediction model (CO2)

Time	ANN		LSTM		GRU		TCN	
	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
6	0.0018	0.0345	0.0019	0.0349	0.0018	0.0330	**0.0014**	**0.0307**
12	0.0021	0.0366	0.0020	0.0353	0.0024	0.0378	**0.0020**	**0.0363**
24	0.0030	0.0430	0.0019	0.0353	0.0026	0.0394	**0.0019**	**0.0350**

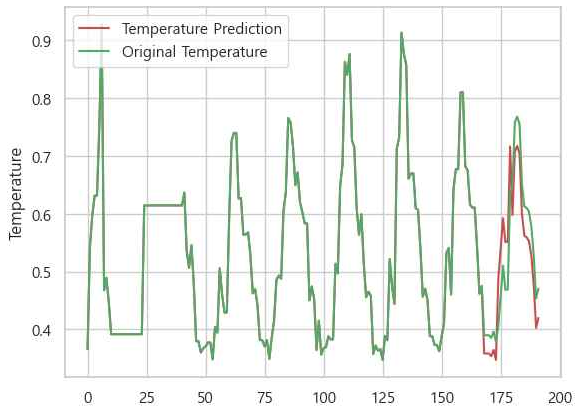

그림 7. 스마트팜 온도 예측 LSTM 모델 테스트
Fig. 7. Smart farm temperature prediction LSTM model test

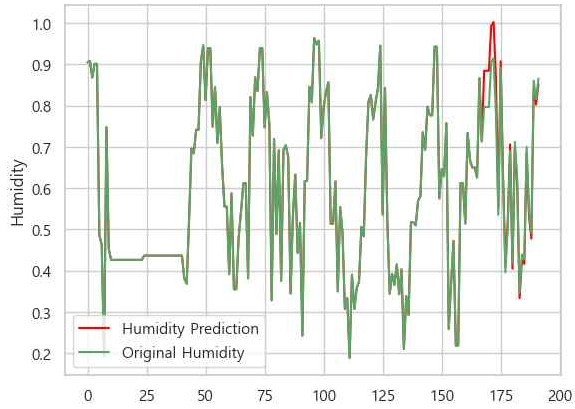

그림 8. 스마트팜 습도 예측 LSTM 모델 테스트
Fig. 8. Smart farm humidity prediction LSTM model test

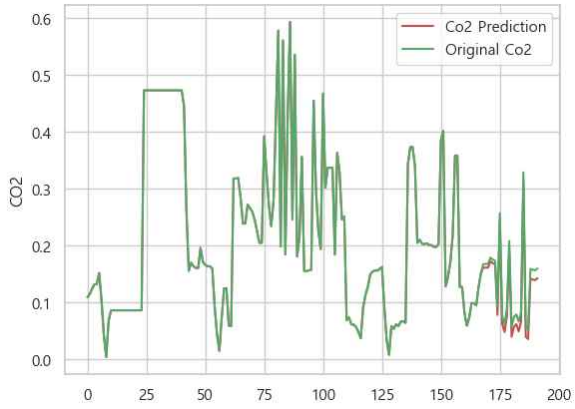

그림 9. 스마트팜 이산화탄소 예측 시간적 합성곱 신경망 모델 테스트
Fig. 9. Smart farm CO2 prediction TCN model test

그림 7부터 그림 9까지는 4계절 딸기 생육을 위한 스마트팜 생육환경 데이터 중 테스트 데이터를 표 3부터 표 5에서 각각 온도, 습도, 이산화탄소 농도에서 우수한 성능을 보인 LSTM 모델과 시간적 합성곱 신경망 모델의 실제 테스트 결과를 보여준다. 좋은 시계열 예측 모델의 예측 결과처럼 온도와 습도 값에서 LSTM과 이산화탄소 농도 값에서 시간적 합성곱 신경망이 시기별 생육환경 값의 패턴 및 추세를 정확히 예측하는 것을 확인할 수 있다.

V. 결 론

최근 우리나라 농촌은 이상기후현상, 고령화, 출산률, 식량자급률 개선 등의 문제로 스마트팜이 주목받고 있다. 스마트팜은 작물을 1년 365일 키울 수 있기 때문에, 생육환경 센싱 및 제어를 완벽히 관리할 수 있다면 농가의 생산량 및 소득 증대로 이어질 수 있다. 본 논문에서는 농가에서 가장 선호하고 높은 소득을 주는 딸기를 4계절 생육할 수 있는 스마트팜을 고안하고, 스마트팜에서 딸기를 생육하면서 얻은 생육환경 데이터셋을 기반으로 딥러닝 기반 예측 모델을 통해 각각의 생육환경 지표를 정확히 예측할 수 있는 딥러닝 예측 모델을 제안한다.

4계절 딸기 생육을 위한 스마트팜에서 온도와 습도 값을 6시간, 12시간, 24시간 예측에서 LSTM 모델이 가장 성능이 좋았으며, 이산화탄소 값에서는 6시간, 12시간, 24시간 예측에서 시간적 합성곱 신경망 모델이 가장 우수하였다. 이를 토대로 시계열 특성이 잘 반영되는 데이터에는 LSTM 모델이, 시계열 특성이 덜 좋은 데이터에서는 시간적 합성곱 신경망 모델이 좋은 성능을 보인다는 것을 확인할 수 있었다.

제안하는 4계절 딸기 생육을 위한 스마트팜에서 딸기 생육을 위한 온도, 습도, 이산화탄소 값을 시기별, 시간별 정확히 예측할 수 있는 LSTM 모델과 시간적 합성곱 신경망 모델을 통해 자동으로 제어할 수 있는 시스템을 구축할 것으로 기대된다. 또한 생육환경 데이터 외에 딸기 생육 데이터를 딸기 이미지 데이터를 추가로 확보하여 더 진보된 4계절 딸기 생육을 위한 스마트팜 연구가 필요할 것으로 보인다.

감사의 글

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. RS-2023-00274651).

참고문헌

[1] S. Y. Lee, “Cloud-Based Smartfarm Technology,” *Information and Communications Magazine*, Vol. 34, No. 1, pp. 51-57, December 2016.

[2] Telecommunications Technology Association. Cloud-Based Smart Farm Service Requirements [Internet]. Available: https://www.tta.or.kr/data/standard_2018/2018_guide_article_c1.html.

[3] S. Yoon, M.-H. Choi, and J. Park, "Data-Driven Smart Farm Prospect," in *Proceedings of KICS Winter Conference 2022*, Pyeongchang, pp. 930-931, February 2022.

[4] Rural Development Administration. 2022 Agricultural Income Data Collection [Internet]. Available: https://amis.rda.go.kr/portal/ms/manage/dtl?bbsId=15&nttSn=819.

[5] T. S. Kim, D. S. Park, and H. J. Kim, "Study of Smart Farm Model Using Big Data," in *Proceedings of KICS Winter Conference 2018*, Jeongseon, pp. 1408-1409, January 2018.

[6] S. W. Kim, "Design and Implementation of Smartfarm Integrated Platform," *The Journal of Korean Institute of Communications and Information Sciences,* Vol. 46, No. 12, pp. 2403-2410, December 2021. https://doi.org/10.7840/kics.2021.46.12.2403

[7] J. S. Bae and J. S. Jung, "A Remote Management System for Monitoring and Controlling of a Smart-Farm," in *Proceedings of KICS Summer Conference 2019*, Jeju, pp. 814-815, June 2019.

[8] O.-H. Kwon, I. Kang, D.-S. Min, H.-B. Im, and Y.-W. Park, "A Study on the Smart Farm Characteristics Using Multiple Sensors," *Journal of the KIECS*, Vol. 16, No. 4, pp. 719-724, August 2021.

[9] S. W. Lee, S. H. Choi, and Y. Shin, "A Smart Farm Real-Time Control Platform Using Deep Learning Prediction Algorithm," in *Proceedings of KICS Summer Conference 2020*, Pyeongchang, pp.789-790, August 2020.

[10] J. Kim, S. Kwon, I. D. Ha, and M. H. Na, "Prediction of Smart Farm Tomato Harvest Time: Comparison of Machine Learning and Deep Learning Approaches," *Journal of the Korean Data & Information Science Society*, Vol. 33, No. 2, pp. 283-298, March 2022. https://doi.org/10.7465/jkdi.2022.33.2.283

[11] H. B. Oh, K. M. Jang, J. Lim, M. B. Lee, and C. S. Shin, "A Study on Paprika Growth Prediction Model Based on Smartfarm Environment Data," in *Proceedings of KICS Winter Conference 2022*, Pyeongchang, pp. 1614-1615, February 2022.

[12] J. I. Yum, K. H. Lee, Y. H. Kim, and S. Park, "A Study on the Classification of Strawberry Images Based on Deep Learning for the Evaluation of Strawberry Maturity," in *Proceedings of KICS Winter Conference 2022*, Pyeongchang, pp. 1104-1105, February 2020.

[13] E. Kim, J. Choi, B. Kim, and D. Suh, "A Study on the Development of Strawberry Growth Stage Classification Model," in *Proceedings of KICS Winter Conference 2022*, Pyeongchang, pp. 1002-1003, February 2022.

[14] B. Lim and S. Zohren, "Time-Series Forecasting with Deep Learning: A Survey," *Philosophical Transactions of the Royal Society A*, Vol. 379, 20200209, February 2021. https://doi.org/10.1098/rsta.2020.0209

[15] M.-C. Popescu, V. E. Balas, L. Perescu-Popescu, and N. Mastorakis, "Multilayer Perceptron and Neural Networks," *WSEAS Transactions on Circuits and Systems*, Vol. 8. No. 7, pp. 579-588, July 2009.

[16] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network," *Physica D: Nonlinear Phenomena*, Vol. 404, 132306, March 2020. https://doi.org/10.1016/j.physd.2019.132306

[17] R. C. Staudemeyer and E. R. Morris, "-Understanding LSTM- A Tutorial into Long Short-Term Memory Recurrent Neural Networks," arXiv:1909.09586v1, September 2019. https://doi.org/10.48550/arXiv.1909.09586

[18] J. Chung, C. Gulcehre, K. H. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," arXiv:1412.3555v1, December 2014. https://doi.org/10.48550/arXiv.1412.3555

[19] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet Classification with Deep Convolutional Neural Networks," in *Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS '12)*, Lake Tahoe: NV, pp. 1097-1105, December 2012.

[20] Y. Chen, Y. Kang, Y. Chen, and Z. Wang, "Probabilistic Forecasting with Temporal Convolutional Neural Network," *Neurocomputing*, Vol. 399, pp. 491-501, July 2020. https://doi.org/10.1016/j.neucom.2020.03.011

박철홍(Chul-Hong Park)

2015년 : 조선대학교 생물학과(학사)

2016년~2017년: 넥스젠어쏘시에이트(주) 개발본부 사원
2018년~2019년: 넥스젠어쏘시에이트(주) 개발본부 대리
2020년~2022년: 넥스젠어쏘시에이트(주) 정보기술본부 과장
2017년~현 재: 전남대학교 전자컴퓨터공학과 석사과정
2023년~현 재: 넥스젠어쏘시에이트(주) 정보기술본부 차장
※관심분야 : 디지털 신호처리, 영상 처리, 머신러닝, 딥러닝

이수창(Soo-Chang Lee)

2016년 : 경북대학교 전자공학부
(공학학사)

2017년~현 재: 한전KDN 전력ICT기술원 선임연구원
2019년~현 재: 전남대학교 전자컴퓨터공학과 석·박과정
※관심분야 : 디지털 신호처리, 영상 처리, 머신러닝, 딥러닝

이미정(Mi-Jeong Lee)

1994년 : 전남대학교 유전공학과
(농학학사)
1998년 : 전남대학교 낙농학과
(농학석사)
2010년 : 전남대학교 생명공학과
(박사수료)

2006년~현 재: 담양군농업기술센터 농업연구사
※관심분야 : 유전공학, 딸기, 생육, 스마트팜, 인공지능

김진영(Jin-Young Kim)

1986년 : 서울대학교 전자공학과
(공학학사)
1988년 : 서울대학교 전자공학과
대학원 (공학석사)
1994년 : 서울대학교 전자공학과
대학원 (공학박사-전자공학)

1995년~현 재: 전남대학교 ICT융합시스템공학과 교수
※관심분야 : 디지털 신호처리, 영상 처리, 음성 신호처리, 머신러닝, 딥러닝

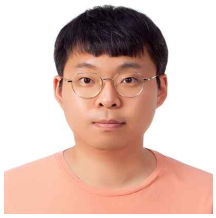

유광현(Gwang-Hyun Yu)

2018년 : 전남대학교 전자공학과
대학원 (공학석사)
2023년 : 전남대학교 전자공학과
대학원 (공학박사-전자공학)

2023년~현 재: 전남대학교산학협력단 박사후연구원
※관심분야 : 디지털 신호처리, 영상 처리, 머신러닝, 딥러닝