

컨테이너형 스마트팜 생육량 예측 시스템 설계에 관한 연구

임상민, 여 현*

*순천대학교

sangmin9642@gmail.com, *yhyun@scnu.ac.kr

A Study on the design of a growth prediction system in container-type smart farm

Lim Sang Min, Yoe Hyun*

*Suncheon National Univ.

요약

식물공장은 최초로 1950년대 유럽에서 시작되었으며, 최초의 식물공장은 1957년 덴마크의 크리스텐센(Christensen) 농장에서 새싹채소의 일종인 크레스를 컨베이어 시스템으로 재배한 것으로 알려져 있다. 국외에서의 식물공장의 발전은 1950년대부터 시작하였지만, 한국은 그에 비해 미비한 실정이다. 또한, 스마트 온실과 노지에 관한 연구는 활발히 진행되고 있지만, 식물공장에 관한 연구는 그에 비해 미비한 편이다. 본 논문은 한국에서 활용 가능한 컨테이너형 스마트팜 내부에서 생성된 환경정보를 바탕으로 작물의 생육량을 예측하고 그 결과를 영농인에게 제공함으로써 컨테이너형 스마트팜 생육량 예측 시스템은 기존에 적용하기 어려웠던 컨테이너형 스마트팜의 한계를 극복하고 더욱 정확한 수확 시기와 수확량을 조기에 결정하여 손실을 최소화할 수 있다. 또한, 이 시스템은 한국의 스마트농업의 발전과 영농인들의 의사결정에 큰 도움이 될 수 있다. 본 논문의 결과를 통해 인공지능형 컨테이너 스마트팜의 발전에 이바지할 것이라 기대된다.

I. 서론

식물공장은 최초로 1950년대 유럽에서 시작되었으며, 최초의 식물공장은 1957년 덴마크의 크리스텐센(Christensen) 농장에서 새싹채소의 일종인 크레스를 컨베이어 시스템으로 재배한 것으로 알려져 있다. 그 이후 해외에서는 꾸준히 발전하여 최근에는 재배 배드 자동이송시스템을 도입하여 완전히 자동화된 채소류 식물공장 시스템을 저가로 설치하여 운영하는 회사도 증가하고 있는 추세이다[1]. 국내에서도 IoT융합을 통한 식물공장에 관한 연구가 진행되고 있지만, 국외 선진 사례에 비해서 미비한 것이 사실이다.

또한 스마트팜 관련 연구는 AI기반의 스마트 온실 최적 생육환경을 위한 재배환경제어에 관한 연구와 병해충 탐지 및 예방, 생육량 예측 및 생산량 예측 등 인공지능기반으로의 도약을 위한 연구가 활발히 진행되고 있다[2]. 그에 비해 컨테이너형 스마트팜에 대해서는 스마트 온실에 비해 그다지 활발하게 진행되고 있지 않다. 또한, 기존의 스마트팜에서 사용중인 시스템을 컨테이너형 스마트팜에 사용하기에는 크기 및 사용 용량 등 한계가 존재한다.

본 논문에서는 인공지능기반의 컨테이너 스마트팜으로의 전환을 위해 컨테이너형 스마트팜을 도입한 농가에서 IoT센서로 수집되고 있는 생육 환경 데이터와 생육측정 데이터를 사용하여 컨테이너 스마트팜에 적용할 수 있는 머신러닝 기반의 생육량 예측 시스템을 설계하고자 한다. 또한, 컨테이너형 스마트팜에 도입이 가능할 수 있도록 모듈형으로 프로그램을 개발하여 이기종간에서도 사용이 가능하도록 설계하고자 한다.

이 연구의 결과인 생육량 예측 시스템의 생육량 예측 결과를 통해 영농인들은 수확시기와 수확량을 조기에 결정할 수 있고 생육환경 제어 의사결정에 도움이 될 것이고, 이 시스템을 통해 앞으로 우리나라의 스마트농업 발전과 영농인들의 빠른 의사결정에 도움이 될 거라 기대된다.

II. 관련 연구

본 논문에서는 컨테이너형 스마트팜에서 IoT센서로 수집한 환경데이터를 바탕으로 생육량을 예측하고자 한다. 여러 가지 머신러닝 예측기법을 비교해보고 그 중 예측 성능이 가장 좋은 모델을 선택하여 사용하고자 하였다. 본 연구에서 비교한 모델은 LSTM, GRU 모델로 두 모델 모두 시계열 데이터 기반의 예측모델이다.

LSTM은 RNN이 출력값과 멀리 떨어져 있는 데이터를 기억하지 못한다는 단점을 보완하기 위해 장기 기억과 단기 기억 모두를 가능하게 설계한 신경망의 구조이다[3]. 그림 1은 LSTM의 기본 구조를 나타내며 LSTM은 시간적 의존성을 고려하며, 기간이 긴 시퀀스 데이터를 처리할 때 다른 모델 보다 우수한 성능을 가진다. 하지만, 장기적인 의존 관계가 필요없는 경우에는 다른 모델들보다 비효율적일 수 있다.




그림 1. LSTM 모델의 기본 구조

Fig 1. Basic structure of LSTM model

GRU는 LSTM에서 파생되었으며 LSTM보다 간단한 구조로 구성되어 있으며, LSTM이 입력, 삭제, 출력 게이트로 구성된 것과 다르게 GRU는 업데이트, 리셋 게이트를 가지고 있기 때문에 이전의 상태를 얼마나 유지할지 말지 결정한다. 그림 2는 GRU의 기본 구조를 나타낸다[4]. LSTM모델보다 GRU모델이 대체로 정확도가 높으나 학습시간이 더 오래걸린다는 단점과 LSTM보다 복잡한 시퀀스 데이터를 처리하는 데에는 제한적일 수 있다[5].

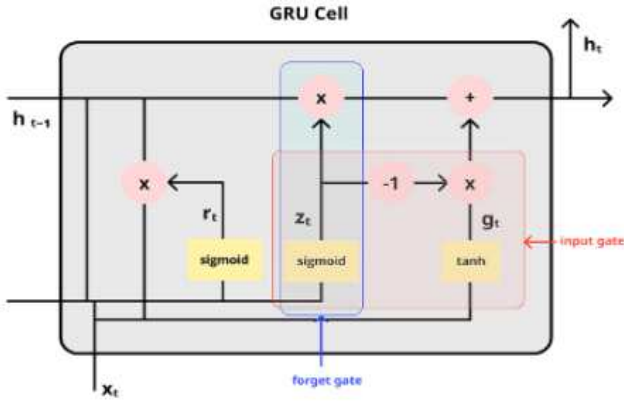


그림 2. GRU 셀 기본구조
Fig 2. GRU Cell Basic Structure

III. 본 론

컨테이너형 스마트팜 생육량 예측 시스템 구성도는 간단하게 그림 3과 같이 나타내었다. CO2, 온도, 습도 센서로부터 측정된 센서데이터를 데이터 송수신기가 수신하여 데이터베이스로 전송한다. 데이터베이스는 컨테이너별 ID와 재배 작물/품종 등 컨테이너별 정보에 따라 센서값을 구분하여 저장하고, 양액 관리 데이터, 온도, 습도, 광량 등 생육에 필요한 환경정보를 시계열 순으로 저장한다.

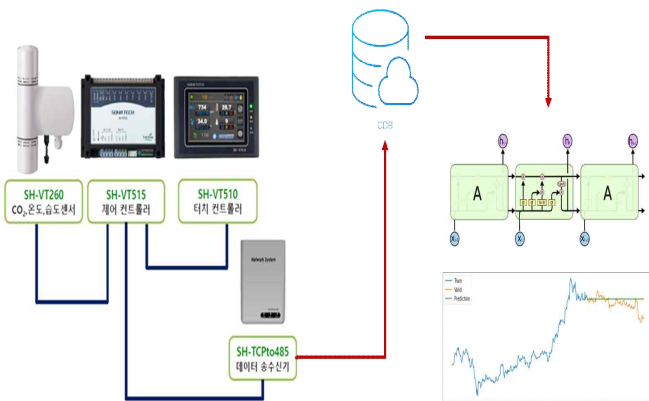


그림 3. 생육량 예측 시스템 구성도
Fig 3. Growth prediction system configuration diagram

생육량 데이터는 실측을 통해 과장의 길이를 저장한다. 데이터 실측은 공휴일을 제외한 일주일에 한 번씩 진행하였고, 과실 10개에 대한 과장의 길이를 실측하여 저장하였다. 이렇게 데이터 베이스를 구축한 후 적재된 원시데이터의 유효성 검증을 위해 데이터를 가공하였다. 데이터 가공과정에서는 결측된 데이터는 Null 값으로 대체하여 저장하였고, 학습에 진행하기에 앞서 Null 값인 데이터는 이전 주 같은 시간대(전후 30분)의 평균 값으로 대체하여 데이터셋을 구성하였다.

또한, 분 단위로 저장된 환경데이터를 온도와 습도, CO2는 일평균값을 사용하였고 광량은 일 누적값을 사용하였다. 생육량은 일주일에 한 번 측정하였기 때문에 결측된 데이터는 선형보간법을 통해 보간하였다. 학습에 사용된 특성은 표 1과 같이 내부온도, 내부절대습도, 광량, CO2를 사용하였다.

표 1. 학습에 사용된 특성

Table 1. Features used for training

Features	Data	Unit
in_temp1	내부 온도	°C
in_temp2	내부 온도	°C
abs_humi	절대 습도	%
light	광량	lx
co2	이산화탄소	ppm

학습은 테스트데이터와 학습데이터를 2:8로 나누어 진행하였으며 예포크는 LSTM모델과 GRU모델 각 100개의 예포크를 학습하였다. 활성화 함수로는 sigmoid 함수를 사용하였으며 옵티마이저로는 Adam을 사용하였다. 또한, 예측성능을 비교하기 위해 RMSE성능 지표를 사용하였으며 RMSE는 값이 낮을수록 모델의 예측이 실제값에 가깝고, RMSE는 모델이 예측한 값과 실제 값의 평균적인 거리를 나타낸다. RMSE의 식은 식 1과 같다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (1)$$

성능지표는 10개의 과실에 대한 RMSE값의 평균으로 나타내었다. 학습 결과, 그림 4와 같이 LSTM모델은 RMSE가 0.96, GRU모델은 RMSE가 0.44로 GRU모델을 사용했을 때의 예측정확도가 더 높았다.

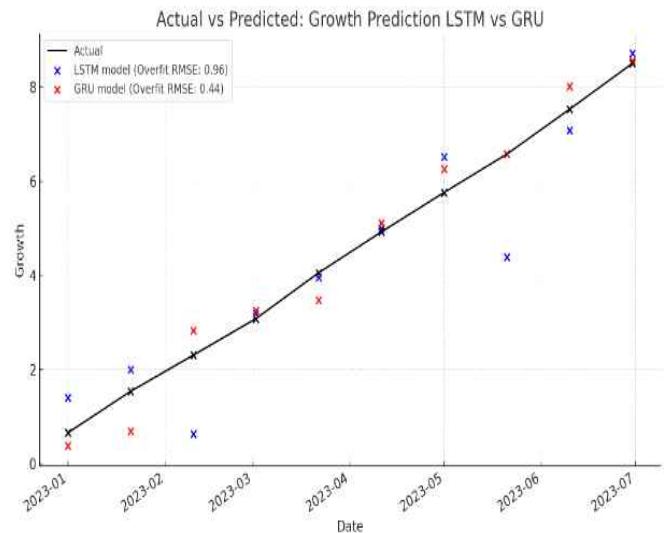


그림 4. LSTM과 GRU의 예측성능비교(RMSE)
Fig 4. Comparison of prediction performance (RMSE) between LSTM and GRU

따라서 GRU를 학습모델로 선정하였고, GRU모델의 하이퍼 파라미터 튜닝을 표 2와 같이 진행하였다.

표 2. GRU 모델에 사용된 하이퍼파라미터
Table 1. Features used for training

Parameter	Value
Learning Rate	0.01
Batch Size	32
Epochs	150
Dropout	0.2

하이퍼 파라미터를 튜닝하고 재학습한 결과 그림 5와 같이 RMSE가 0.28로 더 낮아졌다. 또한, 예측 결과와 그때의 환경정보를 사용자에게 제공하기 위한 데이터베이스를 구축하였고, 해당 데이터베이스는 웹페이지를 통해 사용자에게 제공하여 영농인들이 수확시기 결정 및 생육량에 대한 정보를 바탕으로 의사결정을 하는 데에 도움을 줄 수 있다.

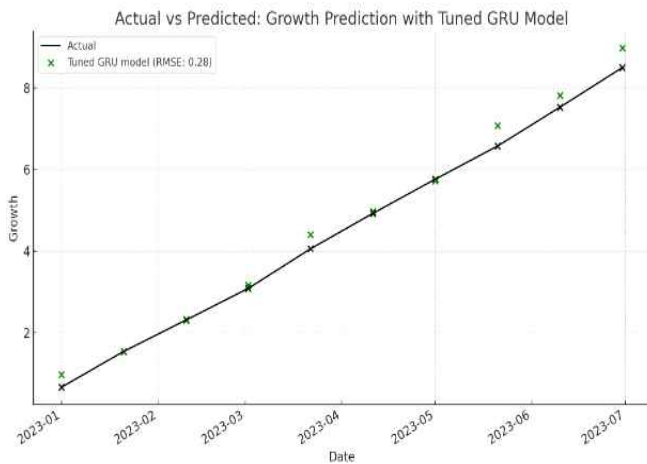


그림 5. 하이퍼 파라미터 튜닝후 GRU 학습 결과
Fig 5. GRU learning results after hyperparameter tuning

IV. 결론

본 논문에서는 컨테이너형 스마트팜에 적용 가능한 머신러닝 기반의 생육량 예측 시스템을 설계하고, 컨테이너형 스마트팜에서 수집된 IoT센서 데이터와 생육측정 데이터를 활용하여 모델을 학습하였다. 학습에 사용된 모델은 LSTM모델과 GRU모델을 비교하여 성능이 좋은 GRU모델을 사용하였고 최종적으로 예측성능지표인 RMSE 값을 0.28로 도출하였다.

해당 모델을 통해 나온 예측결과와 그에 따른 환경정보를 영농인들에게 제공함으로써 컨테이너형 스마트팜 생육량 예측 시스템은 기존에 적용하기 어려웠던 컨테이너형 스마트팜의 한계를 극복하고 보다 정확한 수확시기와 수확량을 조기에 결정하여 손실을 최소화할 수 있다. 또한, 이 시스템은 한국의 스마트농업의 발전과 영농인들의 의사결정에 큰 도움이 될 수 있다. 본 논문의 결과를 통해 인공지능형 컨테이너 스마트팜의 발전에 이바지할 것이라 기대된다.

ACKNOWLEDGMENT

“본 연구는 2023년도 전라남도 재원으로 전남인재평생교육진흥원 지원을 받아 수행됨.”

참고 문헌

- [1] 황해성, 이성호, 한승호. (2020). 컨테이너형 스마트 팜의 재배 환경 개선을 위한 환기 효율 평가. 대한기계학회 논문집 A권, 44(11), 873-879, 10.3795/KSME-A.2020.44.11.873
- [2] 고은별, 정일웅, 이철희. (2023). IoT 기술을 활용한 소형 스마트팜 플랫폼 설계 및 구현. 한국기계가공학회지, 22(11), 59-67.
- [3] Wikidocs LSTM <https://wikidocs.net/22888>
- [4] J.H. Seo, and H.S. Yong, Performance Evaluation of Recurrent Neural Network Algorithms for Recommendation System in E-commerce. KIISE Transactions on Computing Practices, 23(7), 440-445, 10.5626/KTCP.2017.23.7.440, 2017
- [5] 이가현, 김도훈. (2023). LSTM (Long-short Term Memory)과 GRU (Gated Recurrent Units) 모델을 활용한 양식산 넙치 도매가격 예측 연구. 한국수산과학회지, 56(2), 243-252.