

RESEARCH ARTICLE

객체 세분화 및 시계열 데이터를 활용한 아이스플랜트 생육 추정

김어진¹, 조수현¹, 이대현^{1*}, 변성욱^{2*}

¹충남대학교 농업기계공학과

²에이에스이(주)

Ice plant growth estimation using object segmentation and time-series data

Eo-Jin Kim¹, Soo-Hyun Cho¹, Dae-Hyun Lee^{1*}, Seong-Wook Byun^{2*}

¹Department of Agricultural Machinery Engineering, Chungnam National University, Daejeon 34134, Republic of Korea

²ASE Co. Ltd., Daegu 42921, Republic of Korea

*Corresponding author: leedh7@cnu.co.kr, swbyun@aseict.com

Abstract

Succulent plants survive in arid environments by storing water and nutrients in their leaves, stems, and roots, forming thick tissues. ice plants, a type of succulent, are well known for their benefits such as blood sugar regulation and antioxidant properties. however, they exhibit low germination rates and non-uniform growth, leading to high management costs during cultivation. to address this issue, early identification of plants with potential non-uniform growth in the initial sowing stage is crucial to improving cultivation efficiency. this study proposes a deep learning-based approach utilizing object segmentation and time-series prediction models to estimate the growth of ice plants quantitatively. we collected videos over 17 days in a sealed thin-film hydroponic system and extracted crop images at different growth stages. The YOLOv8n-seg model was applied to segment individual crops at the pixel level, allowing the calculation of area-based growth information. Additionally, a Long Short-Term Memory (LSTM) model was used to analyze time-sequenced area data, predicting the growth trends of 54 individual ice plants, and the results were aggregated for further analysis. this study serves as a fundamental analysis of ice plant growth patterns using time-series-based area data, providing essential insights for developing an automated crop growth monitoring system in smart farming environments. furthermore, the proposed method can be extended to other crops with similar growth characteristics, contributing to advancements in precision agriculture and smart farming technologies.

Keywords: machine learning, object segmentation, deep learning, time series data, ice plant



OPEN ACCESS

Journal of Agricultural Machinery Engineering
5(1):25-36

DOI: <https://doi.org/10.12972/jame.2025.5.1.3>

Received: February 27, 2025

Revised: March 31, 2025

Accepted: March 31, 2025

Copyright: © 2025 Korean Society for Agricultural Machinery



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Introduction

다육식물은 건조한 기후에 적응하여 잎, 줄기, 뿌리 등에 수분과 영양분을 저장하는 특성을 지닌 식물로, 그중 아이스플랜트(*Mesembryanthemum crystallinum*)는 표면에 투명한 결정체(bladder cells)가 있는 독특한 외관을 가지며 혈당 조절 및 항산화 효과 등의 장점이 있다(Ibtissem et al., 2012). 일반적으로 작물은 생육 과정에서 다양한 요인에 따라 개체별 성장 속도에 차이가 발생되는데(Perronne et al., 2020), 아이스플랜트의 경우 개체 간 발아율의 차이가 다른 엽채류에 비해 높게 나타나며 이로 인한 불균일 성장 및 수확 시기 불일치의 문제가 많이 발생된다(Bohnert et al., 2000). 생장 불균형을 실시간 모니터링을 통해 조기에 식별하는 것은 작물 생산량 증진에 기여할 수 있으므로, 초기 개체 상태를 지속적으로 관찰하고 관리하는 것이 중요하다(Narvekar et al., 2014). 재배 과정 중 지속적인 관찰을 통해 발아가 저조한 개체들을 재파종하는 등 관리가 필요하지만 대부분 인력에 의존되어 많은 시간과 높은 노동력이 요구된다. 특히, 대규모 재배의 경우 인력 감시의 효율이 매우 낮아 이로 인한 식물 성장률의 저하는 높은 비용 손실로 이어지게 된다(Soheli et al., 2022).

최근 합성곱신경망(convolutional neural network, CNN) 등 딥러닝 기반 객체 탐지 기법의 성능은 비약적으로 발전하여 영상 내 작물 개체들을 실시간 검출할 뿐만 아니라 그 영역을 분할(instance segmentation)하고 객체의 상태 등 더 깊은 정보를 분류할 수 있는 수준에 이르렀다(Fuentes et al., 2017). 특히, YOLO (you only look once) 계열 모델은 실시간 처리와 정확도를 동시에 달성할 수 있는 구조로 많은 연구에서 활발히 사용되고 있으며, 최근 YOLOv5를 활용한 과일 세분화(Lawal, 2023) 등 다양한 버전들이 많은 연구에 활용 및 높은 성과들이 보고되고 있다. 그러나 기존 모델은 앵커(anchor) 기반 탐지 헤드를 사용함에 따라 하이퍼 파라미터 수가 많고 환경 변화에 대한 유연성이 낮다는 단점이 지적된다(Zhang et al., 2022). 이를 개선하기 위해 앵커 없는(anchor-free) 구조를 도입하여 하이퍼 파라미터 수를 줄이고, 다양한 객체에 대한 호환성을 높인 YOLOv8 모델을 사용하였다(Yue et al., 2023).

작물의 생장은 주로 크기로 평가되며, 단순히 작물을 검출하는 것만으로는 개체별 장기 생장 경향을 파악하기 어려워 시계열 분석을 통한 생장 변화 예측 연구가 필요하다(Kamilaris et al., 2018). 특히 아이스플랜트의 경우 초기 생육 단계에서는 느리게 성장하고 중기에서 급속한 성장을 보이는 전형적인 비선형 성장 패턴을 따른다고 알려져 있어(Cha et al., 2014), 전통적 모델인 ARIMA나 VAR 등은 선형성 가정을 전제로 하여 복잡한 비선형 패턴이나 장기 의존성을 학습하는 데 어려움이 있었다(Zhang, 2003). 이에 반해 LSTM(long short-term memory)은 게이트 메커니즘을 통해 아이스플랜트와 같은 비선형 생육 패턴과 장기 의존성을 효율적으로 학습할 수 있는 딥러닝 기반 시계열 예측 모델로 주목받고 있다(Hochreiter et al., 1997). 그러나 기존 연구들은 주로 수확량 예측에 집중되어 있어(Khaki et al., 2019; Kiran et al., 2023), 실시간 환경에서 개별 작물의 불균형 생육을 조기에 식별하는 연구는 아직 충분히 이루어지지 않은 실정이다.

따라서, 본 연구는 아이스플랜트 생육의 실시간 감시 시스템 개발을 위해 진행되었으며, 딥러닝 모델을 이용하여 작물 개체별 세분화 후 면적 기반 생장 데이터를 생성하여 개체별 생장 곡선을 분석하고 생장을 예측하였다. 수경재배 환경 대상의 실시간 영상 수집 시스템을 개발하여 학습 데이터를 확보하였고, 개체별 세분화는 YOLOv8n-seg 모델로 수행하였으며, 시계열 예측은 LSTM 모델을 활용하였다. 예측 결과의 정확도는 MAE, MAPE, RMSE를 사용하여 평가하였다.

Materials and Methods

생장 예측 개요

전체적인 생장 예측 프로세스는 Fig. 1과 같다. 밀폐형 식물공장 환경에서 수행되었으며, 재배 환경 조건은 온도 18~20℃, 상대습도 60~100%, 광원은 백색 LED로 설정하였다. 아이스플랜트는 총 54개의 개체가 파종 트레이에 심어졌으며, 개체

간격은 가로, 세로 각각 5cm로 일정하게 파종되었다. 파종 시에는 동일한 조건에서 시작하였으나, 자연적인 발아 시점의 편차와 개체 간 성장 속도의 차이로 인해 실험 초반부터 개체별 생육 수준에 차이가 발생하였으며, 이를 통해 불균형 생육 조건이 자연스럽게 형성되었다. 이후 수집된 트레이 영상을 기반으로 개별 아이스플랜트의 영역을 정밀하게 구분하기 위해 객체 세분화 모델인 YOLOv8n-seg를 활용하였으며, 해당 모델은 식물의 경계를 픽셀 단위로 분리하여 각 개체를 배경과 독립적으로 구분한다. 세분화된 각 식물 영역으로부터 픽셀 면적 값을 추출하고, 이를 시간 순으로 정렬하여 개체별 시계열 데이터를 구성하였다. 최종적으로 LSTM(Long Short-Term Memory) 모델을 사용하여 과거 성장 데이터를 기반으로 미래 성장 값을 예측하였다.




Fig. 1. Prediction of ice plant growth using deep learning model

실시간 작물 영상 수집

본 연구에서는 Fig. 3과 같이 자체 제작된 데이터 수집 시스템을 사용하여 파종 트레이를 실시간으로 촬영하고 영상 데이터를 수집하였다. 데이터 수집 시스템은 카메라(Galaxy S10+, Samsung, Republic of Korea)와 파종 트레이가 평행하게 유지 되도록 구성되었으며, 카메라는 트레이 중심으로부터 80cm 위의 수직 위치에 설치하였다. 사용된 카메라는 후면에 부착된 1200만 화소의 광각 카메라로, 배울 없이 촬영을 진행하였고, 파종 트레이는 가로 16칸, 세로 7칸의 그리드로 구성되었다. 촬영은 박막식 수경재배 환경의 밀폐형 식물공장에서 진행되었으며, 측정 환경 및 촬영 조건은 Table 1에 기술되어 있다. 영상은 성장 초기에 느린 작물의 성장 속도를 고려하여 미세한 변화를 충분히 포착하기 위해 오전 9시부터 15분 간격으로 1장씩 저장하여 하루에 총 50장의 이미지를 수집하였다. 총 17일 동안 촬영을 진행하여 이미지 850장을 확보하였다. 수집된 850장의 이미지에 대해 객체 세분화를 위한 주석(annotation) 작업을 진행하였다. 주석 작업은 오픈소스 소프트웨어인 'Anylabeling'을 사용하여 폴리곤 형식으로 진행하였다. 주석된 데이터는 학습용, 검증용, 평가용으로 사용하기 위해 7:2:1의 비율로 나누어 구성하였다.

촬영 과정에서 Fig. 2와 같이 영상 가장자리 부분의 트레이 외부 영역은 불필요한 부분으로 판단하였다. 이를 제거하고 트레이 내부의 관심영역(region of interest, ROI)을 일정한 규격으로 통일하기 위해 image warping 기법을 적용하여, 1340×720 픽셀 크기로 이미지를 정규화하였다. 객체 세분화를 통해 추출된 식물의 면적 데이터는 Table 2에 나타난 바와 같이, 시계열 데이터 세트를 구축하였으며, 훈련 데이터, 검증 데이터, 테스트 데이터는 7:2:1 비율로 나누었다.



Fig. 2. Spatial distribution map of individual ice plants within the region of interest




Fig. 3. Custom-built data collection system

Table 1. Experimental conditions for image collection

Items	Specification
Light source	White LED
Temperature (°C)	18 ~ 20
Humidity (%)	60 ~ 100
Camera	12 megapixels
Distance (cm)	80

Table 2. Time-series data of ice plant growth measured as pixel area for each individual plant

Date & Time	Plant 1	Plant 2	Plant 3	...	Plant 54
2024-01-15 09:00	96	143	72	...	157
2024-01-15 09:15	96	163	174	...	167
...	...	...	...	...	...
2024-01-31 20:15	518	1211	1284	...	2743
2024-01-31 21:00	530	1229	1304	...	2770

작물 영역 검출 모델

작물 영역 검출은 객체 세분화 모델인 YOLOv8n-seg 모델을 사용하였으며(Yue et al., 2023), 트레이 내 각 작물의 영역을 픽셀 단위로 분류하여 작물을 배경과 구분한다. YOLOv8n-seg 모델은 Fig. 4와 같은 구조를 가지며 크게 Backbone, Neck, Head의 세 가지 구성 요소로 이루어진다. 먼저, 입력 이미지는 Backbone의 CNN 계층을 통해 다양한 크기와 깊이의 특징맵(feature map)을 추출한다. 이후 Neck에서는 Backbone에서 추출한 다중 스케일의 특징맵을 결합하고 정제하여 서로 다른 크기의 객체를 효과적으로 인식할 수 있도록 한다. 이 과정에서 Neck에 사용된 C2f 모듈은 기존 YOLO 모델의 C3 모듈을 개선한 것으로, 특징 정보의 효율적인 결합과 기울기 흐름 개선을 통해 학습 성능과 추론 속도를 향상시킨다. 마지막으로 Head 부분은 위치(localization), 클래스(classification), 세그멘테이션 마스크(mask) 예측이 각각 독립적으로 이루어지는 Decoupled Head 구조를 가지며, 이를 통해 객체의 정확한 경계를 픽셀 단위로 정밀하게 분류할 수 있다. 특히 마스크 예측 계층(ProtoNet)을 통해 세그멘테이션 마스크를 생성하며, 후처리 과정에서 비최대 억제(NMS)를 수행하여 중복된 객체 예측을 제거한다(Fan et al., 2024). 이렇게 생성된 픽셀 단위의 객체 마스크를 기반으로 Fig. 5와 같이 영상에 격자를 생성하여 좌측 상단부터 우측 하단까지 각 객체의 식별을 위한 순차적인 ID를 부여해 각 작물의 면적에 해당하는 픽셀 값을 추출하고 시간에 따른 면적 변화를 추적하였다. 모델 학습 과정은 총 200회(epoch) 반복 수행하였으며, 배치 사이즈(batch size)는 8, 학습율(learning rate)은 0.002로 설정하였다.




Fig. 4. Architecture of the YOLOv8n-seg model: “C” is the “Concat” operation, “U” is the “Upsample” operation, and “C2f” is the C2f module in YOLOv8n-seg




Fig. 5. Extracting pixel values for each individual object

생장 데이터 예측 모델

생장 예측 모델로는 시계열 데이터의 장기 의존성을 효과적으로 학습할 수 있는 순환 신경망(RNN) 아키텍처의 일종으로, 시간에 따른 데이터의 패턴을 학습하는 LSTM이 사용되었다(Yu et al., 2019). 작물의 생장 예측은 모델 구조는 Fig. 6과 같이 망각 게이트(forget gate), 입력 게이트(input gate), 셀 상태 업데이트(cell state update), 출력 게이트(output gate)로 이루어져 있다. 망각 게이트는 아이스플랜트의 과거 면적 데이터 중 불필요하거나 노이즈가 많은 정보를 필터링하는 데 사용되며, 입력 게이트는 입력 시점의 면적 데이터가 셀 상태에 얼마나 반영될지를 결정한다. 셀 상태 업데이트는 망각 게이트와 입력 게이트의 출력을 기반으로 이전 셀 상태를 새로운 셀 상태로 갱신하여 작물의 면적 데이터의 연속성을 유지하는 데 사용된다. 마지막으로 출력 게이트에서는 예측 결과로 반환할 면적 값을 생성한다.




Fig. 6. LSTM architecture

입력 데이터는 개체별 면적 값만을 사용하므로, LSTM의 입력 차원을 1로 설정하였다. input size는 모델이 한 번에 처리하는 입력 데이터의 차원을 의미하며, 본 연구에서는 면적 값 하나만을 사용하므로 1로 설정하였다. 또한, LSTM의 은닉 상태 크기를 의미하는 hidden size를 16으로 설정하였는데, 이는 모델이 입력 데이터에서 학습할 수 있는 패턴의 복잡성을 결정하는 요소이다. 모델의 재귀 층(recurrent layer) 개수를 나타내는 num layers는 2로 설정하여, 2개의 LSTM 층을 쌓아 보다 깊은 시계열 패턴을 학습할 수 있도록 하였다. num layers는 모델의 깊이를 조절하는 하이퍼 파라미터로, 층이 많아질수록 복잡한 시계열 패턴을 학습할 수 있다. 예측에 사용되는 과거 데이터의 시간 단계 수인 sequence length는 20으로 설정하였다. 각 예측은 직전 20개의 시간 순 면적 값을 기반으로 향후 생장 값을 출력하도록 하였으며, 출력 데이터는 각 작물의 단일 면적 값을 예측하는 형태이므로 output size는 1로 설정하여 각 시점의 면적 값을 개별적으로 예측하였다. batch size는 16, learning rate는 0.001로 설정하였으며, epoch은 130으로 설정 후 early stopping 방법을 이용하여 최적의 손실 값에서 학습을 중지하도록 하였다.

객체 세분화 및 생장 예측 성능평가 방법

성능평가는 작물 영역 세분화 및 생장 예측 2가지에 대해 수행하였다. 객체 세분화 모델의 성능 평가는 혼동 행렬을 기반

으로 한 정밀도(precision), 재현율(recall), mAP (mean average precision)지표를 사용하여 수행되었다. 정밀도는 모델이 예측한 픽셀 중 실제로 정확하게 분류된 픽셀의 비율을 나타내며, 재현율은 실제 픽셀 중 모델이 정확하게 예측한 픽셀의 비율을 의미한다. mAP@50은 교차 영역 비율인 IoU (intersection over union)값이 50%를 넘는 객체의 비율을 계산하여, 모델의 전반적인 검출 성능을 종합적으로 평가하는 지표로 사용되었다.

$$mAP = \frac{1}{N} \sum_{i=1}^{i=n} AP_i \quad (1)$$

Where,

N is the total number of classes, AP_i represents the average precision for the i -th class.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Where,

TP is the number of classes predicted plant pixels, FP is the number of pixels incorrectly predicted as plants, and FN is the number of plant pixels incorrectly predicted as non-plant.

모델의 생장 예측 성능을 평가하기 위해, 먼저 학습 데이터에서 테스트 세트를 분리하여 개체별 예측 결과를 분석하였다. 모델은 2024-01-15 9:00부터 2024-01-27 12:30까지 데이터를 학습한 후, 2024-01-27 12:45:00부터 2024-01-31 21:15:00까지의 데이터를 테스트 세트로 사용하여 예측 성능을 검증하였다. 생장 예측 모델의 성능 평가는 MAE (mean absolute error), MAPE (mean absolute percentage error), RMSE(root mean squared error)를 사용하여 평가된다. MAE는 모델의 예측 값과 실제 값의 차이를 절대값으로 변환한 뒤 합산하여 평균을 내는 개념으로, 작물 면적의 예측 값과 실제 값 간의 절대적인 차이의 평균을 나타내며, MAPE는 예측 오차를 실제 값에 대한 백분율로 표현한다. RMSE는 실제 단위와 동일한 단위로 오차 크기를 나타내는 지표로, 작물 면적의 예측 값과 실제 값 사이의 평균적인 차이를 나타낸다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

Where,

n is the total number of data samples, y_i is the actual crop area value, and $\hat{y}_i$ is the predicted crop area value.

Results and Discussion

학습

객체 검출 모델과 생장 예측 모델은 Fig.7 (a), (b)와 같이 관찰되었다. 총 200번의 학습을 하는 동안 학습 손실(train loss)은 1.90에서 0.69로 63.7%, 0.206에서 0.0012로 99.4%, 검증 손실(validation loss)은 1.92에서 0.74로 61.5%, 0.226에서 0.002로 99.1%감소하는 경향을 보였다. 객체 검출 모델은 학습 및 검증 손실이 안정적으로 감소하여 아이스플랜트 개체들을 신뢰성 있게 구별하였음을 알 수 있다. 생장 예측 모델은 비교적 단순한 면적 데이터를 사용한 것에 비해 복잡한 모델을 사용하여 두 손실이 빠르게 0에 수렴하는 모습을 보였으며, 두 모델 모두 훈련 손실과 검증 손실이 감소되어 과적합(overfitting) 없이 데이터를 학습하였다고 판단된다.




Fig. 7. Training loss and validation loss graphs for the object detection model and growth prediction model: (a) segmentation, (b) growth prediction

작물영역 세분화

Fig. 8의 (a) P-R curve는 정밀도와 재현율의 상호 관계를 시각적으로 보여주며, 학습 과정 전반에 걸쳐 두 지표가 안정적인 수준으로 수렴하는 경향을 확인할 수 있다. 초기 학습 단계에서 정밀도는 0.90, 재현율은 0.82로 나타났으나, 최종적으로 정밀도는 0.94, 재현율은 0.92로 개선되었다. (b) mAP@50 그래프는 모델의 전반적인 객체 검출 성능이 점진적으로 향상되었음을 보여주며, 학습 초기 0.82에서 0.96으로 증가하였다. 이는 모델이 다양한 크기와 형태의 아이스플랜트 개체를 정확하게 검출할 수 있도록 최적화되었음을 알 수 있다.

Table 3에 표시된 바와 같이, 객체 검출 모델의 성능을 평가하는 또 다른 지표인 Intersection over Union (IoU)은 0.79에서 0.87로 증가하였다. 이러한 IoU의 증가는 모델이 예측한 영역과 실제 객체 영역 간의 중첩 정도가 개선되었음을 보여준다. 정밀도와 재현율의 조화 척도인 F1-score는 0.93로 관측되었으며, 이는 모델이 FP(false positive)와 FN(false negative)을 줄여 검출 성능을 개선하였음을 나타낸다.

Table 3. Final performance evaluation metric values for object segmentation

Class	Precision	Recall	F1-score	IoU
Ice plant	0.94	0.92	0.93	0.87




Fig. 8. Statistical analysis of detection performance (a) PR-curve (b) mAP@50

생장 예측

본 연구에서는 생장 면적의 단위를 실제 제곱센티미터(cm^2)가 아닌 픽셀 수로 사용하였다. 이는 촬영 거리와 각도가 고정되고 영상 해상도가 일정하게 유지되는 조건에서는, 픽셀 기반 면적 변화만으로도 개체의 생장 추세를 정량적으로 반영할 수 있기 때문이다(Tong et al., 2022). Fig. 9는 테스트 데이터에서 LSTM 모델이 예측한 생장 면적과 실제 측정 면적을 시계열로 비교한 그래프이며, 두 곡선은 전반적으로 유사한 패턴을 유지하였다. 특히 특정 시점에서 급격한 생장 변화가 발생하는 구간에서도 모델이 그 추세를 잘 따라가는 경향이 확인되었다. 다만, 일부 구간에서는 예측 값이 실제보다 다소 지연되거나 과대·과소 추정되는 양상이 나타났는데, 이는 촬영 장비가 고정된 상태였음에도 불구하고 생장 과정에서 잎의 기울기나 방향 변화로 인해 투영된 면적이 실제보다 크게 또는 작게 측정되었을 가능성에 기인한 것으로 판단된다.




Fig. 9. Comparison graph of actual and predicted area values of ice plant

Table 4. Performance metrics for ice plant growth prediction model

	MAE	MAPE (%)	RMSE
Avg	55.43	5.50	77.97
Max	252.28	18.70	299.66
Min	6.45	1.05	9.98
Std	53.45	4.66	78.39

Table 4의 평가 지표에 따르면, 평균 MAE는 55.43 픽셀, 평균 MAPE는 5.50%, 평균 RMSE는 77.97 픽셀로 나타났다. 이는 모델이 실제 생장 면적과 비교하여 평균적으로 55.43 픽셀의 절대 오차, 5.50%의 상대 오차, 77.97 픽셀의 차이를 보였음을 의미한다. 최대 MAE는 252.28 픽셀, 최대 MAPE는 18.70%, 최대 RMSE는 299.66 픽셀로 나타났으며, 최소 MAE는 6.45 픽셀, 최소 MAPE는 1.05%, 최소 RMSE는 9.98 픽셀로 나타나, 특정 개체에서는 매우 낮은 오차 범위 내에서 높은 예측 정확도를 보이는 것을 확인할 수 있었다. 특히, 표준편차가 MAE 53.45 픽셀, MAPE 4.66%, RMSE 78.39 픽셀로 나타나, 평균값과 유사한 수준이다. 이는 기존 연구들과 비교하여 보았을 때, 모델이 비교적 일관된 정확도를 유지하고 있음을 알 수 있다 (Xu et al., 2023).

Conclusion

본 연구에서는 딥러닝을 활용하여 아이스플랜트의 생육을 정량적으로 추정하고자 하였다. 이를 위해 밀폐형 박막식 수경재배 환경에서 17일 동안 영상을 수집하고, YOLOv8n-seg 모델을 이용하여 개별 개체를 픽셀 단위로 분할함으로써 작물의 면적 정보를 추출하였다. 실험 결과, 객체 세분화 모델의 성능을 평가한 mAP@50은 학습 초기 대비 17.1% 향상되었으며, PR-curve 분석을 통해 모델이 높은 객체 검출 성능을 유지하면서도 균형적인 성능을 보였음을 확인하였다. IoU는 0.87, F1-score는 0.93으로 측정되어 아이스플랜트 개체를 검출하고 경계를 효과적으로 분할할 수 있음을 확인하였다. 생장 예측 모델은 추출된 면적 정보를 바탕으로 LSTM 모델을 활용하여 시간에 따른 아이스플랜트의 생장 변화를 예측하였으며, 총 54개 개체에 대한 성능을 분석한 결과, 평균 MAE는 55.43픽셀, MAPE는 5.50%, RMSE는 77.97픽셀로 나타나 모델이 비교적 안정적인 예측 성능을 보였으며, 일부 개체에서는 낮은 오차 범위 내에서 높은 예측 정확도를 확인할 수 있었다. 또한, MAE, MAPE, RMSE의 표준편차가 평균값과 유사한 수준으로 나타나 모델의 예측 값이 전반적으로 일관성을 유지함을 확인할 수 있었다.

본 연구는 아이스플랜트의 생장 예측 모니터링을 위한 기초 연구로서, 스마트팜 환경에서의 작물 생장 모니터링 시스템 개발에 기여할 수 있을 것으로 기대된다. 또한, 본 연구에서 제안한 방법은 아이스플랜트뿐만 아니라 유사한 생육 특성을 지닌 다육식물 및 기타 작물의 생장 예측에도 적용 가능성이 높으며, 정밀 농업 및 스마트팜 기술의 발전에 기여할 것으로 예상된다. 향후 연구에서는 다양한 환경적 요인을 고려한 데이터 확장 및 다중 시점 기반의 영상 분석 기법을 도입을 통해 생장 예측의 정밀도를 더욱 향상시킬 수 있을 것으로 기대된다.

Acknowledgements

본 결과물은 농림축산식품부의 재원으로 농림식품기술 기획평가원의 농식품 과학기술 융합형 연구인력양성사업의 지원을 받아 연구되었음(RS-2024-00397026)

References

- Bouftira, Ibtissem, Chedly Abdelly, Souad Sfar. 2012. Antioxidant and antibacterial properties of *Mesembryanthemum crystallinum* and *Carpobrotus edulis* extracts. *Advances in Chemical Engineering and Science*, 2(3), 359-365.
- Bohnert, Hans J., Cushman, J. C. 2000. The Ice Plant Cometh: Lessons in Abiotic StressTolerance. *Journal of Plant Growth Regulation*, 19(3), 334-346.
- Soheli, S. J., Jahan, N., Hossain, M. B., Adhikary, A., Khan, A. R., Wahiduzzaman, M. 2022. Smart greenhouse monitoring system using internet of things and artificial intelligence. *Wireless Personal Communications*, 124(4), 3603-3634.
- Perronne, R., Jabot, F., Pottier, J. 2020. Inter-and intraspecific variability of plant individual growth and its role on species ranking in grasslands. *Journal of Plant Ecology*, 13(3), 378-386.
- Narvekar, P. R., Kumbhar, M. M., Patil, S. N. 2014. Grape leaf diseases detection & analysis using SGDM matrix method. *International Journal of Innovative Research in Computer and Communication Engineering*, 2(3), 3365-3372.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., McCool, C. 2016. Deepfruits: A fruit detection system using deep neural networks. *Sensors*, 16(8), 1222.
- Fuentes, A., Yoon, S., Kim, S. C., Park, D. S. 2017. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, 17(9), 2022.
- Kamilaris, A., Prenafeta-Boldu, F. X. 2018. Deep learning in agri-culture: a survey. *Computers and Electronics in Agriculture*, 147, 70-90.
- Lawal, O. M. 2023. YOLOv5-LiNet: A lightweight network for fruits instance segmentation. *Plos one*, 18(3), e0282297.
- Zhang, Y., Guo, Z., Wu, J., Tian, Y., Tang, H., Guo, X. 2022. Real-time vehicle detection based on improved yolo v5. *Sustainability*, 14(19), 12274.
- Yue, X., Qi, K., Na, X., Zhang, Y., Liu, Y., Liu, C. 2023. Improved YOLOv8-Seg network for instance segmentation of healthy and diseased tomato plants in the growth stage. *Agriculture*, 13(8), 1643.
- Fan, Yuhe, et al. 2024. "Instance segmentation of faces and mouth-opening degrees based on improved YOLOv8 method." *Multimedia Systems* 30.5, 269.
- Verma, H., Kumar, S. 2019. An accurate missing data prediction method using LSTM based deep learning for health care. *Proceedings of the 20th International Conference on Distributed Computing and Networking*. 371-376.
- Yasrab, R., Zhang, J., Smyth, P., Pound, M. P. 2021. Predicting plant growth from time-series data using deep learning. *Remote Sensing*, 13(3), 331.
- Cha, Mi-Kyung, Ju-Sung Kim, and Young-Yeol Cho. 2014. "Growth model of common ice plant (*Mesembryanthemum crystallinum* L.) using expolinear functions in a closed-type plant production system." *Horticultural Science & Technology* 32.4, 493-498. [in Korean]
- Zhang, G. P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Hochreiter, S., Schmidhuber, J. 1997. Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Chen, Y., Wang, J., Huang, M., Yu, H. 2019. Cross-position activity recognition with stratified transfer learning. *Pervasive and Mobile Computing*, 57, 1-13.

- Khaki, S., Wang, L. 2019. Crop yield prediction using deep neural networks. *Frontiers in Plant Science*, 10, 621.
- Kiran Kumar, V., Ramesh, K. V., Rakesh, V. 2023. Optimizing LSTM and Bi-LSTM models for crop yield prediction and comparison of their performance with traditional machine learning techniques. *Applied Intelligence*, 53(23), 28291-28309.
- Yu, Y., Si, X., Hu, C., Zhang, J. 2019. A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.
- Tong, Yin-Syuen, Tou-Hong Lee, and Kin-Sam Yen. 2022. "Deep Learning for Image-Based Plant Growth Monitoring: A Review." *International Journal of Engineering & Technology Innovation* 12.3.
- Xu, Dan, et al. 2023. "Improving lettuce fresh weight estimation accuracy through RGB-D fusion." *Agronomy* 13.10: 2617.