

딥러닝을 활용한 딸기 생육지표 인식

최우주, 권경도*, 김경철, 김국환, 양창주, 이기범, 홍영기
국립농업과학원 농업공학부

Strawberry Growth Index Detection using Deep Learning

Woo-Joo Choi, Kyung-Do Kwon*, Kyoung-Chul Kim, Gookhwan Kim,
Changju Yang, Ki-Beom Lee, Young-Ki Hong
Department of Agricultural Engineering, National Institute of Agricultural Sciences

요약 기후변화, 농업 종사 인구 감소로 안정적 식량 자원 확보의 위험성이 증가함에 따라 이를 해결하기 위해 첨단 농업기술이 연구되고 있다. 특히 국내에서 많이 재배되는 딸기의 경우 재배 시기에 따라 요구되는 농작업이 다양하고 많기 때문에 안정적 수익을 위해 정확하고 빠른 모니터링 기술 기반 첨단 농업기술의 적용이 필요하다. 본 연구에서는 RGB 영상과 Deep learning을 이용해 생식생장 시기의 딸기 생육지표를 인식할 수 있는 적합한 모델을 찾고자 하였다. 학습에 사용된 알고리즘 중 YOLO v5-Large 알고리즘은 총 6개(꽃, 과실 등) Class 인식결과에서 mAP50 0.66 및 FPS 89.29의 성능을 보였다. 또한, Mask R-CNN 알고리즘 인식 결과 mAP50 0.59로 Object detection과 비슷한 수준의 성능을 보였지만, FPS가 26.04로 감소하였다. 본 연구에서 높은 성능을 보인 모델은 생식생장 시기에 적절한 자원과 인력 투입의 의사결정을 지원하는 모니터링 기술에 활용 가능하다. 추후 연구에서 인식 성능을 높이는 기술을 다룰 예정이다.

Abstract As the risks of securing stable food resources increase due to climate change and a decrease in the agricultural workforce, agricultural technologies are being developed to address this issue. In particular, many strawberries are grown in South Korea and require accurate and fast monitoring technology for stable profits. The reason is that many agricultural tasks are required depending on the cultivation period. This study attempted to find a suitable model for detecting the strawberry growth index during the reproductive growth period using an RGB image and deep learning. Among algorithms used for training, the YOLO v5-Large algorithm showed an mAP50 of 0.66 and FPS of 89.29 in the object detection results for a total of six classes (flowers, fruits, etc.). In addition, the Mask R-CNN algorithm's performance was similar with an mAP50 of 0.59, but the FPS was decreased to 26.04. The model that showed high performance to detect the growth index can be used in monitoring technology that supports decision making for appropriate resources and manpower input during growth. Future studies will improve the performance of detection.

Keywords : Deep Learning, Monitoring System, Object Detection, Strawberry Detection

본 논문은 농촌진흥청 연구사업(과제번호: PJ01676901)으로 수행되었음.

*Corresponding Author : Kyung-Do Kwon(National Institute of Agricultural Sciences)

email: Kwond89@korea.kr

Received September 27, 2023

Revised October 25, 2023

Accepted November 3, 2023

Published November 30, 2023

1. 서론

기상 악화, 농업 인구 감소 및 노동력 부족 등 안정적인 농작물 생산이 어려운 환경이 지속되고 있다. 스마트 팜은 농작업의 자동화, 기계화 등의 첨단농업 기술을 포함하여 이러한 문제를 해결할 수 있고, 과채류 수확 자동화, 병해충 인식을 통한 방제 자동화, 일사량 기반의 관수제어 등의 연구가 진행되고 있다.

과채류 중 딸기는 한국에서 많이 재배되는 과실 중 하나로 재배 중 육묘, 정식, 적엽, 적화, 수확, 환경제어 등의 작업을 시행하기 위해 많은 노동력과 전문지식이 요구된다. 작업 수행 의사는 작형, 품종, 생육 시기 및 발달 정도 등 다양한 요인에 기반해 결정되어야 하고[1,2], 스마트 농업 기술 실현을 위해 연속적이고 정확한 작물 생육 모니터링 기술의 고도화가 요구된다[3].

작물 모니터링에 필요한 영상처리기술의 발전은 농업 분야뿐만 아니라 타 산업 분야에서도 작업 자동화 및 지능화에 기여했다. RGB, 초분광, 열화상 등 영상 센서는 모양, 색상, 질감 등 관측 대상의 특징을 영상 데이터로 저장할 수 있으며[4], 영상 내 특징 추출과 학습을 하나의 Process로 통합하는 Deep learning의 적용은 실시간으로 우수한 분석 결과를 출력할 수 있어 농작업 자동화 연구에 적용된 바 있다. YOLO 알고리즘을 기반으로 다양한 Backbone을 조합하여 딸기[5,6]와 토마토[7] 같은 수확대상인 과실을 자동으로 수확할 수 있는 로봇 개발 연구가 다수 진행되었다. 하지만 대부분의 연구는 수확로봇 개발을 위한 성숙된 과실을 인식하는데 국한되었다. 꽃부터 성숙한 과실에 이르는 전주기 모니터링은 과채류 재배 시 수확 작업을 포함한 환경제어, 적화 등의 농작업의 자동화에 이용될 수 있다.

따라서 본 연구에서는 딸기 재배 중 필요한 농작업의 사결정에 활용될 Deep learning 기반 생육지표 인식 모델을 제시하고자 했다. 다양한 생육지표 인식은 수확로봇 뿐만 아니라 모니터링에 기반한 농작업 의사결정에 기여할 수 있다. 또한, RGB 영상 데이터 내 생육지표에 대한 Localization 및 Classification 정확도를 인식 모델별로 비교해 최적 모델 제시를 통해 추후 딸기 농작업 자동화 연구에 활용이 되고자 하였다.

2. 본론

2.1 재료 및 방법

2.1.1 데이터 취득

딸기 생육지표 인식 모델 학습을 위한 RGB 영상 데이터 구축을 위해 2022년 7월부터 2023년 4월까지 '설향' 품종이 연동유리온실에서 고설 방식으로 재배되었고, 영상은 총 14회 취득되었다(Fig. 1). 영상 데이터 취득 시 데이터 다양성을 고려해 취득 시간은 9~18시 사이, 촬영 각도와 대상과의 거리는 각각, 범주에서 객체의 정보가 충분히 포함될 수 있는 위치 조건을 설정했다. 영상 취득 장치는 GoPro10(GoPro, San Mateo, CA, U.S.)이 사용되었고, FPS(Frame per second) 60, Linear 화각의 촬영 조건에서 동영상상을 취득하고, 객체의 정보가 1개 이상 표현된 영상을 무작위하게 추출해 총 767장을 학습 데이터로 사용하였다.



Fig. 1. A venlo-type greenhouse where 'Seolhyang' strawberry cultivated with elevated-bed

2.1.2 데이터 전처리

딥러닝 알고리즘이 영상에서 객체 인식을 하기 위해서 객체의 Class와 위치가 우선으로 결정돼야 한다. 따라서 Labelme 소프트웨어를 이용해서 Polygon style로 Annotation을 실시하였고, 영상 내 재배 베드가 2개 이상이 포함된 경우, 가장 가까운 베드에 대해서만 Annotation을 실시하였다.

본 연구에서는 추후 농작업 자동화 기술 연구에 활용 가능하다고 판단되는 생육지표인 꽃, 과실(성숙 전), 과실(성숙), 수확지점, Color checker, 식별 불가 Class를 인식 대상으로 선정하였고, 각각 Flower, Fruit_unripen, Fruit_ripen, Picking_point, Color_checker, Unidentified로 Class를 명명하였다(Fig. 2). 꽃 Class는 화아분화 후 꽃잎의 전개가 시작되기 직전부터 완전히 전개되어 꽃잎이 4개 이상 확인되는 객체를 포함하였다. 과실(성숙 전) Class는 꽃이 수정된 후 꽃잎이 떨어지기 시작하여 3개 이하가 된 이후부터 과실의 비대 전 과정과 완전 성숙 전까지의 착색을 보이는 과실을 포함한다. 과실(성숙) Class는 착색이 완료되어 완전 성숙된 수확 대상의 과실을 포함한다. 수확지점 Class는 과실(성

속) 객체를 대상으로 식별 가능한 꽃자루를 포함한다. Color checker class는 영상 내 작물과 같이 촬영된 24개의 기준 색상을 포함한 Color checker를 포함한다. 식별 불가 Class는 영상 내에서 생육지표가 맞으나 앞선 Class로 분류할 수 없는 객체로 이 Class는 대부분 90°에 가까운 각도로 촬영된 영상에서 분류가 어려운 객체들로 구성됐다.

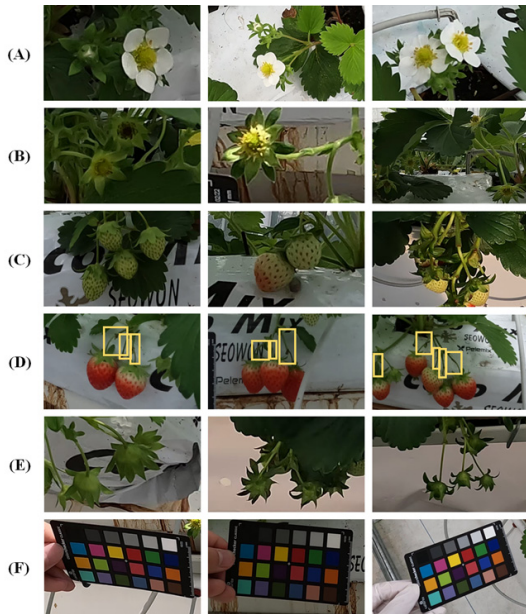


Fig. 2. The object examples that defined Flower(A), Fruit_unripen(B, C), Fruit_ripen(D), Picking_point(Yellow boxes in D), Unidentified(E) and Color_checker(F).

Table 1. The number of objects for each classes in train, validation, test dataset.

	Train	Validation	Test	Total
Flower	1,162	421	157	1,740
Fruit_unripen	3,283	805	390	4,478
Fruit_ripen	639	158	98	895
Picking point	472	110	70	652
Color checker	269	67	39	375
Unidentified	827	208	108	1,143
total	6,652	1,769	862	9,283

학습 데이터로 사용된 총 767장의 영상에서 각 Class 별로 1,740, 4,478, 895, 652, 375, 1,143개의 객체가 Annotation 되었다. 영상-annotation dataset는 학

습, 검증, 모델 성능 평가를 위한 데이터로 각각 552, 138, 77장으로 나뉘었고, 이때 나뉜 Class별 객체 수는 Table 1과 같다. 각각의 라벨 데이터는 MS COCO dataset 형식과 YOLO dataset 형식으로 변환되었다.

2.1.3 Deep learning networks

영상 내 생육지표 인식을 하기 위해 2가지(Object detection, Instance segmentation) 범주의 알고리즘을 활용하였다. Object detection은 객체의 위치정보가 포함된 Bounding box의 회귀 및 그 안의 객체 Class를 분류하는 Faster R-CNN(Faster Regions with Convolutional Neural Networks), RetinaNet, YOLO (You Only Look Once) v3, 4, 5 알고리즘을 활용하였고, Instance segmentation은 픽셀단위로 객체 Class를 분류하는 Mask R-CNN, YOLACT(You Only Look At CoefficientTs) 알고리즘을 활용하였다.

각 알고리즘은 10,000 epoch 학습 후 mAP₅₀ 지표를 이용하여 성능비교 되었다. mAP₅₀ 지표는 IoU(Intersection of union)가 0.5 이상 결과값에 대하여 Precision-Recall curve를 통해 알고리즘의 성능을 정량적으로 나타낼 수 있어 2가지 범주의 학습에 대하여 보편적으로 사용된다. 학습을 위해 설계된 각 알고리즘에 대한 전반적인 설명은 다음에 서술하였다.

2.1.3.1 Faster R-CNN

Two stage detector인 Faster R-CNN은 RPN(Region proposal network)를 포함하기 때문에 추론 속도는 느리지만 정확도가 높다[8]. 본 연구에서는 ResNet-50과 FPN(Feature pyramid network)이 결합된 Backbone을 사용하였다. 영상은 Backbone을 거쳐 추천영역을 출력하고, 이를 기반으로 RoI(Region of interest) pooling과 FC(Fully connected) layer를 통해 Bounding box regression과 Classification을 수행하였다.

2.1.3.2 RetinaNet

One stage detector인 RetinaNet은 전체 영상을 Dense sampling함으로써 생기는 Class imbalance 문제를 Focal loss를 통해 해결한다. Focal loss는 Cross entropy loss에 Class에 따라 변하는 동적 Scaling factor를 추가하여 각 샘플의 기여도를 조절해 배경에 대한 가중치를 줄여준다[9]. 본 연구에서는 ResNet-50 기반의 FPN을 Backbone으로 얻어진 Feature pyramid는 2개의 Sub-network를 통해 Bounding box regression과

Classification을 수행하였다.

2.1.3.3 YOLO

YOLO 알고리즘은 One stage detector로 매우 빠른 속도와 정확도를 보여 다양한 분야에서 적용되고 있다. YOLO v3는 ResNet-101 대비 약 1.5배 빠르고, ResNet-152 대비 2배 이상 빠르지만, 비슷한 인식 성능을 보이는 것으로 알려진 Darknet-53을 Backbone으로 사용하였다[10]. YOLO v4와 YOLO v5에서는 정확도를 유지하면서 연산량을 줄여줄 수 있는 CSP(Cross stage partial connections) 기법이 적용된 CSP-Darknet 구조를 Backbone으로 사용하였다[11]. YOLO v5는 각 계층의 연산량을 균등하게 배분하여 연산 Bottleneck을 없애고, Depth multiple과 Width multiple을 기준으로 4가지 구조로 나누었으며, 본 연구에서도 4가지 구조 모두 사용해 성능을 비교하여 적합한 알고리즘 구조를 찾고자 하였다.

2.1.3.4 Mask R-CNN

Mask R-CNN 알고리즘은 Two stage detector로, Faster R-CNN 구조를 기반으로 RoI align을 사용하며, 출력층에 Mask branch를 추가함으로써 Localization을 통해 RoI를 찾고, 그 안에서 Segmentation을 수행한다[12]. 본 연구에서는 ResNeXt-101과 FPN이 결합된 Backbone을 사용하여 Bounding box regression, Classification, Segmentation을 출력하였다.

2.1.3.5 YOLACT ++

One stage detector는 이미지 전체에서 Segmentation을 수행하기 때문에 좋은 성능을 보이기 어렵지만 YOLACT는 2가지 병렬 Sub-task를 구성하여 이미지 전체에서 Segmentation을 수행함으로써(Prototype mask를 생성하여 Convnet에서 Localization을 수행해 채널의 특정 지역만 활성화하는 마스크를 추출함) 이를 개선하였다. 또한, Instance별 Mask coefficient를 생성하여 Mask 내에서 특정 Object만 Activate하는 연산을 수행한다[13].

본 연구에서 사용한 YOLACT ++는 DCN v2에 기반하여 ResNet-50의 Deformable convolution layer를 대체한 구조를 사용하여 Bounding box regression, Classification, Segmentation을 출력도록 설정하였다.

2.1.4 학습 환경

Data preprocessing과 Neural network 학습은 i9-12900k(Intel, Santa Clara, CA, USA), RTX A6000 D6 48GB(NVIDIA, Sana Clara, CA, USA)로 구성된 컴퓨터에서 수행됐으며, Ubuntu 20.04. OS에서 Pytorch(python 3.8)가 사용되었다.

2.2 결과 및 고찰

2.2.1 Object Detection

구현된 인식 모델 중 YOLO v5 알고리즘은 영상으로부터 6가지 Class를 인식하는데 가장 높은 mAP₅₀을 보여주었다(Table 2). 이때 FPS는 YOLO v5-large 알고리즘에서 89.29로, 이는 영상 획득 시 사용된 조건인 FPS 60보다 높다. 따라서, YOLO v5 알고리즘은 재배 현장에서 실시간 인식에 활용 가능성을 시사한다. YOLO v5의 5가지 구조에 따라 큰 성능 차이를 보이지 않으므로 영상 크기, 하드웨어의 성능과 같은 촬영 및 환경에 따라 성능과 FPS를 절충하여 사용할 수 있다 (Table 3).

Table 2. The comparison result of the object detection performance of 5 DNN algorithms.

	YOLO v5	Faster R-CNN	YOLO v3	YOLO v4	RetinaNet
Flower	0.74	0.65	0.61	0.64	0.63
Fruit_unripen	0.80	0.71	0.70	0.77	0.69
Fruit_ripen	0.92	0.85	0.76	0.81	0.87
Picking poing	0.15	0.09	0.09	0.11	0.20
Color checker	0.98	0.96	0.97	0.99	0.94
Unidentified	0.38	0.31	0.21	0.35	0.27
mAP ₅₀	0.66	0.60	0.56	0.61	0.60

Test dataset의 이미지를 이용한 인식 결과 중 일부를 Fig. 3에 나타내었다. Input 영상은 다양한 밝기와 각도를 포함하고, 인식 대상인 6가지 종류의 객체는 겹침, 폐색 등 비구조적으로 표현되었다. 하지만 본 논문에서 학습 및 결과 비교된 모든 알고리즘은 영상 내에서 객체를 높은 정확도로 인식되는 것을 확인하였다. 일부 영상에 대해서는 낮은 인식 성능을 보였는데, 이는 학습에 사용된 대부분의 영상은 흰색 비닐로 쌓인 코코피트 배지 위에 정식된 딸기로, 667장 이었다. 뿐만 아니라 초록색

멸칭 위에 정식된 딸기를 포함한 100장의 영상 데이터가 포함되었는데, 초록색의 멸칭은 인식하고자 하는 객체 중 특히 과실(성숙 전)과 수확지점 객체의 영상 내 색과 질감에 있어 혼동을 야기할 수 있음을 볼 수 있다(Fig. 3). 따라서 영상 데이터의 추가 확보 및 알고리즘 최적화 과정이 추가로 필요하다[14].

Table 3. The comparison result of the object detection performance and inference speed for 4 types of YOLO v5 algorithms.

	Small	Medium	Large	Extra-large
Flower	0.72	0.74	0.74	0.74
Fruit_unripen	0.77	0.76	0.79	0.80
Fruit_ripen	0.87	0.88	0.90	0.92
Picking point	0.12	0.13	0.15	0.15
Color checker	0.97	0.98	0.98	0.98
Unidentified	0.35	0.37	0.40	0.38
mAP ₅₀	0.63	0.64	0.66	0.66
FPS	238.09	133.33	89.29	50.76

성능이 가장 우수한 YOLO v5-large 알고리즘의 Confusion matrix를 통해 각 Class 간 학습 결과를 정량적으로 확인하고자 하였다(Fig. 4).

배경을 객체로 오분류한 비율은 과실(성숙 전) 0.38, 수확지점 0.22, 식별 불가 0.17, 과실(성숙) 0.14, Color checker 0.09로 나타났다. 본 연구에서 이용한 영상은 대부분 2개 이상의 베드를 포함하였지만, 가장 가까운 베드에 대해서만 Annotation을 실시하여 학습에 사용하였기 때문에 배경을 객체로 과분류 한 것으로 판단된다. 또한 수확지점 객체의 형태, 색깔의 특징은 엽병과 유사하게 표현될 수 있기 때문에 오분류 될 수 있다(Fig. 2, 3).

각 Class가 배경으로 오분류는 결과는 영상 내에서 객체를 찾지 못했음을 의미하고 오분류된 비율은 수확지점 0.72, 식별 불가 0.36, 꽃 0.34, 과실(성숙 전) 0.19, 과실(성숙) 0.12, Color checker 0.03로 나타났다. 수확지점을 배경으로 오분류한 비율은 가장 높았고, 따라서 수확지점 Class를 정확하게 학습하지 못한 것으로 판단된다. 선행 연구들은 수확로봇 개발을 위해 대부분 인식된 딸기를 기반으로 별도의 네트워크를 구성하여 수확지점의 위치를 유추하여 비교적 높은 성능을 보였다.

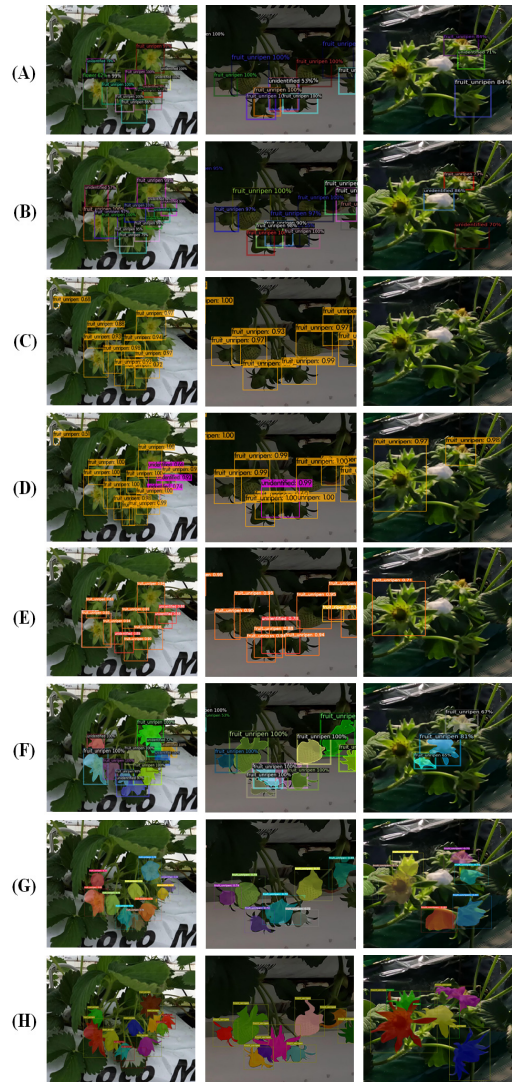


Fig. 3. Detection results of Faster R-CNN(A), RetinaNet(B), YOLO v3(C), YOLO v4(D), YOLO v5(E), Mask R-CNN(F), YOLACT ++(G) and ground truth images(H).

반면, 본 연구에서 제시한 수확지점 인식 모델은 상대적으로 인식 정확도가 낮으나 모니터링과 수확작업에 범용 가능한 통합된 알고리즘 개발이 가능함을 시사한다. 그 외의 객체에 대한 오분류는 폐색으로 인해 야기되었다고 판단된다. 온실 내 정형화되지 않은 환경과 복잡한 작물의 구조로 인한 중첩 및 폐색은 영상 내에 표현되는 객체의 특성을 변화시킬 수 있다. 선행 연구에서는 폐색을 일으키는 구조를 영상에서 제외시키는 알고리즘을 통해 정확한 포도 수확량을 예측하는 연구

가 진행되었다[15]. 이러한 알고리즘의 적용은 이 영상 내 객체를 보다 정확하게 탐지할 수 있는 하나의 방안이 될 수 있다.

각 Class의 오분류는 과실(성숙 전)과 식별 불가를 제외하고는 거의 나타나지 않았다. 인식된 객체의 분류 작업이 잘 이루어졌음을 의미한다. 식별 불가 Class는 육안으로도 명확하게 분류가 어렵지만, 생육 단계와 형태적인 특성을 고려했을 때 간접적으로 과실(성숙 전) Class로 판단할 수 있다.

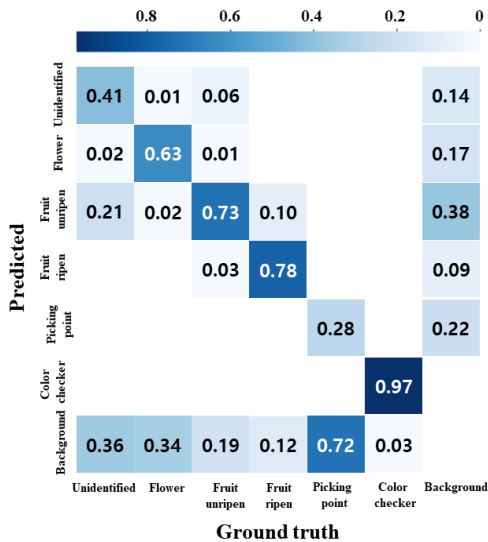


Fig. 4. The confusion matrix of 6 classes and background inferred from test images inferred with YOLO v5-Large algorithm.

2.2.2 Instance Segmentation

Mask R-CNN 알고리즘이 영상으로부터 6가지 Class에 대한 Segmentation 및 Bounding box regression에서 가장 높은 mAP₅₀을 보여주었다(Table 4). Object detection task는 영상 내 객체의 Localization만을 수행하는데 반해 Segmentation task는 픽셀 단위의 Classification으로 객체의 윤곽선 및 모양 정보를 추출할 수 있어 정교한 작업에 유리하다. 앞서 높은 성능을 보인 YOLO v5-Large 알고리즘 대비 상대적으로 낮은 mAP₅₀을 보였으며, 인식 속도(FPS 26.04)도 감소하여 실시간 모니터링 시스템의 하드웨어 성능 및 활용 목적에 따라 활용 여부를 결정해야 한다.

Table 4. The comparison result of the instance segmentation performance of 2 DNN algorithms.

	Mask R-CNN		YOLOACT ++	
	Bounding box	Segmentation	Bounding box	Segmentation
Flower	0.64	0.61	0.59	0.50
Fruit_unripen	0.72	0.71	0.66	0.62
Fruit_ripen	0.85	0.84	0.78	0.74
Picking point	0.10	0.05	0.02	0
Color checker	0.95	0.95	0.99	0.99
Unidentified	0.28	0.29	0.26	0.21

3. 결론

본 연구에서는 다양한 생육 단계의 딸기 RGB 영상 및 딥러닝 기반 생육지표의 인식 성능을 평가했다. Localization과 Classification을 수행하는 Object detection task에서는 YOLO v5-Large 모델이 0.66(mAP₅₀)으로 여러 알고리즘 중 가장 좋은 인식 결과를 보였다. 픽셀 단위의 Classification을 수행하는 Segmentation task에서는 Mask R-CNN 알고리즘이 Bounding box와 Segmentation에서 각각 mAP₅₀ 지표 0.59, 0.58로 앞선 YOLO v5-Large 모델과 비슷한 성능을 보였으나 낮은 FPS 때문에 추후 실시간 모니터링 시스템으로 확장은 적합하지 않을 것으로 판단된다. 수확지점 Class 인식 결과에서 확인된 낮은 인식률은 별도의 알고리즘 구성이 필요할 것으로 판단된다.

개발된 딸기 생육지표 인식 알고리즘을 통해 재배 중 필요한 작업 의사결정을 지원할 수 있으며, 6가지 생육 지표 외 노엽, 런너, 적화 대상의 꽃 등이 인식 대상으로 확대 가능하다고 판단된다. 추후 연구에서는 고품질 학습 데이터 추가 구축 및 인식 모델 최적화를 통해 인식 성능을 높여 딸기 재배 농작업의 자동화에 기여하고자 한다.

References

[1] G. Savini, D. Neri, F. Zucconi, and N. Sugiyama, "Strawberry growth and flowering: an architectural model", International journal of fruit science, Vol.5, No. 1, pp. 29~50, 2005.
DOI: https://doi.org/10.1300/J492v05n01_04

- [2] S. Lee, H. Kim, M. Kang, J. Ha, H. J. Song, H. J. Kang, Y. Chae, J. Hong, "Changes of Fruit Weight and Soluble Solids Content for Flower Cluster in Strawberry", Horticultural Science and Technology, Vol. 27, No. 1, pp. 180-180, 2009.
- [3] J. N. Kerfs, Z. Eagan and B. Liu, "Machine vision for strawberry detection", 2017 ASABE Annual International Meeting, American Society of Agricultural and Biological Engineers, 2017, pp. 1
DOI: <https://doi.org/10.13031/aim.201700925>
- [4] H. Kebapci, B. Yanikoglu, and G. Unal, "Plant image retrieval using color, shape and texture features", The Computer Journal, Vol. 54, No. 9, pp. 1475-1490. 2011.
DOI: <https://doi.org/10.1093/comjnl/bxq037>
- [5] Y. Yu, K. Zhang, H. Liu, L. Yang, D. Zhang, "Real-time visual localization of the picking points for a ridge-planting strawberry harvesting robot", IEEE Access, Vol. 8, pp. 116556-116568, 2020.
DOI: <https://doi.org/10.1109/ACCESS.2020.3003034>
- [6] M. Cui, Q. Jiang, N. Li and X. Xue, "Research on Strawberry Maturity Detection Technology Based on Improved YOLOv4", Journal of Physics: Conference Series, IOP Publishing, 2021, pp. 012012
DOI: <https://doi.org/10.1088/1742-6596/2138/1/012012>
- [7] O. M. Lawal, "Development of tomato detection model for robotic platform using deep learning", Multimedia Tools and Applications, Vol. 80, No. 17, pp. 26751-26772, 2021.
DOI: <https://doi.org/10.1007/s11042-021-10933-w>
- [8] S. Ren, K. He, R. Girshick and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks", Advances in neural information processing systems, Vol. 28, 2015.
DOI: <https://doi.org/10.48550/arXiv.1506.01497>
- [9] T.-Y. Lin, P. Goyal, R. Girshick, K. He and P. Dollár, "Focal loss for dense object detection", Proceedings of the IEEE international conference on computer vision, pp. 2980~2988, 2017.
DOI: <https://doi.org/10.48550/arXiv.1708.02002>
- [10] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement", arXiv preprint arXiv:1804.02767, 2018.
DOI: <https://doi.org/10.48550/arXiv.1804.02767>
- [11] A. Bochkovskiy, C.-Y. Wang and H.-Y. M. Liao, "Yolov4: Optimal speed and accuracy of object detection", arXiv preprint arXiv:2004.10934, 2020.
DOI: <https://doi.org/10.48550/arXiv.2004.10934>
- [12] K. He, G. Gkioxari, P. Dollár and R. Girshick, "Mask r-cnn", Proceedings of the IEEE international conference on computer vision, pp. 2961~2969, 2017.
DOI: <https://doi.org/10.48550/arXiv.1703.06870>
- [13] D. Bolya, C. Zhou, F. Xiao and Y. J. Lee, "Yolact: Real-time instance segmentation", Proceedings of the IEEE/CVF international conference on computer vision, pp. 9157~9166, 2019.
DOI: <https://doi.org/10.48550/arXiv.1904.02689>
- [14] K. Weiss, T. M. Khoshgoftaar and D. Wang, "A survey of transfer learning", Journal of Big data, Vol. 3, No. 1, pp. 1-40, 2016.
DOI: <https://doi.org/10.1186/s40537-016-0043-6>
- [15] J. Kierdorf, I. Weber, A. Kicherer, L. Zabawa, L. Drees and R. Roscher, "Behind the leaves: Estimation of occluded grapevine berries with conditional generative adversarial networks", Frontiers in Artificial Intelligence, Vol. 5, 2022.
DOI: <https://doi.org/10.3389/frai.2022.830026>

최 우 주(Woo-Joo Choi)

[정회원]



- 2015년 3월 ~ 2022년 8월 : 충북대학교 원예과학과 (농학 학·석사)
- 2022년 6월 ~ 현재 : 국립농업과학원 농업공학부 스마트팜개발과 전문연구원

<관심분야>

원예, 머신러닝

권 경 도(Kyung-Do Kwon)

[정회원]



- 2017년 2월 : 충남대학교 일반대학원 농업기계공학과 (공학석사)
- 2020년 9월 ~ 현재 : 농촌진흥청 국립농업과학원 농업연구사

<관심분야>

영상처리, 인공지능, 농업로봇

김 경 철(Kyoung-Chul Kim)

[정회원]



- 2009년 2월 : 전북대학교 정밀기계공학과 (공학석사)
- 2015년 8월 : 전북대학교 정밀기계공학과 (공학박사)
- 2016년 7월 ~ 2019년 1월 : 농업기술실용화재단 연구원
- 2019년 2월 ~ 현재 : 국립농업과학원 스마트팜개발과 연구사

<관심분야>

농업로봇, 인공지능, 농업드론

이 기 범(Ki-Beom Lee)

[정회원]



- 2012년 8월 : 전북대학교 컴퓨터공학과 (공학석사)
- 2021년 2월 : 전북대학교 컴퓨터공학과 (공학박사)
- 2022년 1월 ~ 2023년 1월 : 농촌진흥청 국립농업과학원 PostDoc.
- 2023년 2월 ~ 현재 : 농촌진흥청 국립농업과학원 농업연구사

<관심분야>

농업로봇, 강화학습, 영상처리

김 국 환(Gookhwan Kim)

[정회원]



- 2003년 2월 : 경희대학교 일반대학원 기계공학과 (공학석사)
- 2010년 2월 : 경희대학교 일반대학원 기계공학과 (공학박사)
- 2010년 3월 ~ 2014년 12월 : 농촌진흥청 국립농업과학원 PostDoc.
- 2015년 1월 ~ 현재 : 농촌진흥청 국립농업과학원 농업연구사

<관심분야>

농업로봇, 자율항법기술

홍 영 기(Young-Ki Hong)

[정회원]



- 2001년 3월 : 일본 동경농업대학교 농업공학전공 (공학석사)
- 2004년 3월 : 일본 동경농업대학교 생물환경조절학전공 (공학박사)
- 2004년 4월 ~ 2006년 3월 : 일본 동경농업대학교 종합연구소 박사후연구원
- 2007년 12월 ~ 현재 : 농촌진흥청 국립농업과학원 농업연구관

<관심분야>

영상처리, 패턴인식, 기계학습, 인공지능, 정보통신

양 창 주(Changju Yang)

[정회원]



- 2010년 2월 : 전북대학교 전자공학부 (전자공학석사)
- 2014년 8월 : 전북대학교 전자공학부 (전자공학박사)
- 2016년 11월 ~ 2018년 6월 : 전북대학교 산학협력단 계약교수

- 2020년 3월 ~ 2022년 1월 : 농촌진흥청 국립농업과학원 박사후연구원
- 2022년 1월 ~ 현재 : 농촌진흥청 국립농업과학원 농업연구사

<관심분야>

농업로봇, 인공지능, 센서기반제어, 영상처리, 정보통신