

수경재배 온실 모니터링 로봇을 위한 작물 인식 시스템 연구

김용현¹, 조병효¹, 서다솜², 송혜영¹, 김경철^{1*}
¹국립농업과학원 농업공학부, ²전북대학교 컴퓨터공학부

The study on crop detection robot system for hydroponic green house

Yong-Hyun Kim¹, Byeong-Hyo Cho¹, Dasom Seo²,
Hye-Young Song¹, Kyoung-Chul Kim^{1*}

¹Department of Agricultural Engineering, National Institute of Agricultural Sciences
²Division of Computer Science and Engineering, Jeonbuk National University

요약 농업에서 작물 모니터링은 방제, 수확 등과 같은 작업을 효율적이고 안정적으로 수행하기 위한 가장 중요한 기술 중 한 가지이며, 이러한 이유로 작물 모니터링 시스템을 개발하기 위한 연구가 활발히 수행되고 있다. 최근에는 CNN (Convolutional Neural Networks) 기반의 딥러닝(Dep learning) 기술이 객체 인식 분야에서 뛰어난 성능을 나타내어, 농업분야에서도 작물 모니터링 시스템 개발에 이를 적용하기 위한 연구가 증가하고 있다. 그러나 작물 인식 기술 개발을 위해 CNN 기반의 인식모델을 비교 및 평가한 연구는 부족한 실정이다. 따라서 본 연구에서는 수확 로봇에 적용하기 위한 작물 인식 알고리즘의 인식 성능을 비교하고, 경제성 확보를 위해 GPU의 대체 가능성을 검토하고자 하였다. 스마트 온실에서 재배되는 토마토 인식을 위해 Faster R-CNN, SSD, YOLOv3 및 YOLOv4의 네 가지 모델을 활용하였으며, 학습된 토마토 인식모델의 성능을 비교 및 평가하였다. 또한, 경제성 확보를 위해 GPU를 대체하여 CPU의 적용 가능성을 검토하였다. 각 인식모델의 학습 및 검증에 4,930개의 Labeling이 있는 토마토 데이터셋이 이용되었다. 그 결과, YOLOv4 모델을 사용할 경우 92.09%의 최고 mAP (mean Average Precision)를 달성하였으며, CPU에서 fps (Frame per second)는 YOLOv3 모델이 5.39로 가장 높은 것으로 나타났다. 따라서 스마트 온실에서 토마토 인식을 위해서는 YOLO 기반의 알고리즘이 적합한 것으로 판단되며, 실시간 객체 감지를 위해 CPU의 적용 가능성을 확인하였다.

Abstract Crop monitoring is the most important in terms of efficient and stable performance of tasks such as spraying, harvesting, and so on. Thus, several studies are being conducted to develop and improve a crop-monitoring system. In addition, the applications of deep learning are increasing in the development of a crop-monitoring system since deep learning that uses a CNN has been proven to show outstanding performance in object detection. However, there are only a few studies that evaluate and compare a crop-detection model with several deep learning algorithms. Thus, the purpose of this study is to compare the detection performance and analyze the economic feasibility of object detection algorithms for applying them to a harvest monitoring robot. Therefore, we used four detection models, Faster R-CNN, SSD, YOLOv3, and YOLOv4, to detect tomato fruits and compared their performance in a hydroponic greenhouse. In addition, we wanted to confirm the applicability of a CPU by replacing the GPU. For developing a detection model, a tomato dataset with 4,930 labels was used for training and testing in this study. As a result, the YOLOv4 model achieved the best mean average precision (mAP) of 92.09%. When YOLOv3 was used with a CPU, the number of frames per second (fps) was 5.39. Therefore, the YOLO-based algorithm is suitable for tomato detection in a smart greenhouse, and a CPU can be used for real-time object detection instead of a GPU.

Keywords : Monitoring Robot, Hydroponic Greenhouse, Object Detection, Deep Learning, YOLO, Faster R-CNN

본 연구는 농림축산식품부의 및 과학기술정보통신부, 농촌진흥청의 재원으로 농림식품기술기획평가원과 재단법인 스마트팜 연구개발사업단의 스마트팜 다부처패키지 혁신기술개발사업(421031-04)의 지원을 받아 연구되었음.

*Corresponding Author : Kyoung-Chul Kim(National Institute of Agricultural Sciences)

email: kkcsmole@korea.kr

Received March 11, 2022

Revised April 6, 2022

Accepted June 3, 2022

Published June 30, 2022

1. 서론

스마트 온실이란 ICT (Information and Communications Technology)를 적용하여 원격 또는 자동으로 작물의 생육환경을 적정하게 유지 및 관리할 수 있는 시설을 의미한다[1]. 스마트 온실은 자동 환경 제어 및 환경 최적화 등을 바탕으로 기후변화, 농경지 감소 및 노동력 고령화 등에 따른 농산물 생산 불안정 문제를 해결할 수 있는 대안으로 떠오르고 있으며, 2019년 기준 국내에 보급된 스마트 온실의 면적은 5,017 ha로 보급률 또한 매년 증가하고 있다[2].

현재, 국내 토마토 생산은 2010년부터 대부분 시설재배로 이루어지고 있으며, 토마토 재배면적은 6,010 ha로 전체 시설작물 재배면적의 약 7.26%를 차지한다. 또한, 2020년 기준 토마토 생산량은 약 34.4만 톤으로, 전체 과채류 생산량의 약 19%를 차지하는 경제적으로 중요한 작물 중 한 가지이다[3]. 최근에는 일반 시설재배에서 스마트 온실로 전환할 경우 생산량 증가, 생산비 감소 및 상품화율 증가 등의 장점으로 인하여 스마트 온실로 전환하는 토마토 농가가 증가하고 있다[4].

토마토(*Solanum lycopersicum*)는 일반적으로 상향 유인 방식으로 재배되고, 최대 약 8 m 높이까지 자라기 때문에 작물을 관리하고 수확하기 위해서는 리프트가 필요하며, 이는 작업효율, 안전성 등의 문제와 관련될 수 있다. 또한, 수경재배는 유기질 및 무기질의 인공 배지를 사용하는 양액재배 시스템으로, 토양전염병의 피해를 감소시킬 수 있으며, 노지재배와 비교하여 생육에 적합한 환경조절이 가능하기 때문에 토마토 재배에 주로 이용된다[5]. 이러한 이유로 스마트 온실에서 수경재배 방식으로 재배되는 토마토의 적과, 방제, 수확까지 대부분의 작업을 자동화 및 로봇화 하기 위한 연구가 활발히 수행되고 있다[6,7].

모니터링 및 수확용 로봇을 개발하기 위해서는 작물 인식 기술은 필수적이며, 이를 위해 많은 연구들이 수행되고 있다. 특히, 작물 인식을 위해 Faster R-CNN (Faster Region-based Convolutional Neural Network)[8], SSD (Single Shot Detector)[9], YOLOv3 (You Only Look Once version 3)[10] 및 YOLOv4 (You Only Look Once version 4)[11] 등 CNN 기반의 딥러닝 기술이 주로 이용되고 있다. 한편, CNN 기반의 인식 알고리즘의 경우 크게 One-stage와 Two-stage 방식으로 분류된다. One-stage 방식의 경우 객체 분류와 인식을

동시에 수행하며, 인식 속도가 빠르다는 장점이 있고, 대표적으로 SSD 및 YOLO 알고리즘이 있다. Two-stage 방식은 객체 분류와 인식을 각각 수행하며, 먼저 영상으로부터 다양한 특징을 추출한 후에 인식을 수행하기 때문에 처리속도는 느리지만 정확도가 높다는 장점이 있다. Two-stage 기반에는 Faster R-CNN, Mask R-CNN 등의 R-CNN기반 알고리즘이 있다.

한편, 딥러닝 기술 기반의 작물 인식 알고리즘을 이용하여 실시간으로 작물을 인식할 때 일반적으로 고가의 GPU가 사용된다. 그러나, 이러한 GPU 사용은 모니터링 및 수확용 로봇 보급을 위해 농가에 경제적인 부담이 발생할 수 있으며, 이는 보급률 저하와 같은 문제로 확산될 수 있다. 이러한 이유로, 최근에는 고가의 GPU를 대체하여 인식 시스템의 경제성을 확보하기 위한 연구가 수행되고 있다[12].

따라서 본 연구에서는 스마트 온실에서 수경재배 방식으로 재배되는 토마토 과실을 인식하기 위해 CNN 기반의 Faster R-CNN, SSD, YOLOv3 및 YOLOv4의 네 가지 모델을 적용하였으며, 각 인식 알고리즘의 인식 정확도를 비교하였다. 또한, 실시간 인식 시스템의 경제성 확보를 위한 방안을 검토하고자 하였다.

2. 재료 및 방법

2.1 토마토 데이터셋

본 연구에서는 토마토 인식 모델의 학습 및 검증을 위해 Kaggle에서 제공하는 오픈 데이터셋을 사용하였으며 [13], Fig. 1은 데이터셋에 포함된 샘플 이미지를 나타낸 것이다. Fig. 1에서 보는 바와 같이 Kaggle 데이터셋에는 과실의 성숙도, 다른 과실 및 줄기 등에 의한 가림 등을 고려한 총 895장의 이미지와 Ground Truth 값인 Annotation 파일이 포함되며, 총 4,930개의 토마토 좌표정보가 포함되어 있다. 한편, 학습된 알고리즘의 처리 속도 검증은 국립농업과학원(전라북도 완주군)의 스마트 온실에서 촬영한 토마토 영상을 이용하였으며, Fig. 2는 영상을 취득한 스마트 온실이다. 토마토 영상은 RGB-D 카메라(D435, Intel, CA, USA)로 촬영하였다.



Fig. 1. Sample of tomato images for training and testing



Fig. 2. Hydroponic greenhouse for tomato

2.2 학습 알고리즘

본 연구에서는 수경재배 온실의 토마토 과실 인식 시스템 구축을 위해 Faster R-CNN, SSD, YOLOv3 및 YOLOv4의 총 네 가지 모델을 비교 및 평가하였다. 각 인식 모델은 Python(Ver. 3.7, Python software foundation, Wilmington, USA)에서 Pytorch 딥러닝 프레임워크를 이용하여 구축하였다.

Faster R-CNN은 Two-stage 구조를 갖는 객체 인식 알고리즘이다[14]. Two-stage 구조는 이미지 전체로부터 특징을 추출하지 않고 Fig. 3과 같이 객체 분류단계를 거쳐 이미지의 특징을 추출한 후, 추출된 특징을 통해 객체 인식이 이루어진다. 분류단계에서는 많은 연산처리가 이루어져 인식 시간이 오래 걸린다는 단점이 있지만, 작은 객체의 경우 인식 정확도가 높다는 장점이 있다. 따라서 본 연구에서는 layer 수가 비교적 적은 ResNet-50을 Faster R-CNN 알고리즘의 backbone으로 활용하여 스마트 온실에서 토마토 과실의 인식을 위한 알고리즘으로 사용하였다.




Fig. 3. The architecture of Faster R-CNN [14]

SSD는 One-stage 구조를 사용하는 알고리즘으로 실시간 인식에 적합하다고 알려져 있다[15]. SSD Mobile-Net과 같은 경량화 모델은 저사양 컴퓨터에서도 구현할 수 있다는 장점이 있으며, Fig. 4와 같이 이미지 안에 있는 객체를 분류단계 없이 특징을 추출 후 인식하기 때문에 빠른 장점이 있으며, 최종 분류 정보가 여러 layer에 분산 되어있는 것이 YOLO와의 차이점이다. 본 연구에서는 SSD의 backbone으로 VGG-16을 사용하였다.




Fig. 4. The architecture of SSD [15]

YOLO는 SSD와 같은 One-stage 구조이기 때문에 R-CNN 계열 등의 다른 인식 모델들과 비교하여 처리속도가 빠르며, 이로 인하여 실시간 객체 인식에 적합하다고 알려져 있다[16]. Fig. 5와 같이 YOLO는 대상물 이외의 주변 정보까지 학습하며 이미지 전체를 처리하기 때문에 background error가 적으며, 새로운 이미지에 대해서도 인식 정확도가 높다는 장점이 있다. 이러한 이유로, 농업에서도 실시간 작물 인식을 위해 YOLO를 적용하려는 연구가 증가하고 있으며, 특히, YOLOv3 [17]와 YOLOv4 [18]를 활용하는 연구들이 많이 수행되었다 [19]. YOLOv3와 YOLOv4의 네트워크는 유사하지만, 데이터 증강이나, 최적화함수 및 파라미터들을 수정하면서 연산량을 줄인 알고리즘이 YOLOv4이다. 본 연구에서는 수경재배 방식의 온실에서 재배되는 토마토의 인식

에 적합한 알고리즘을 선정하기 위해 YOLOv3 및 YOLOv4 두 가지 알고리즘을 비교하였다.

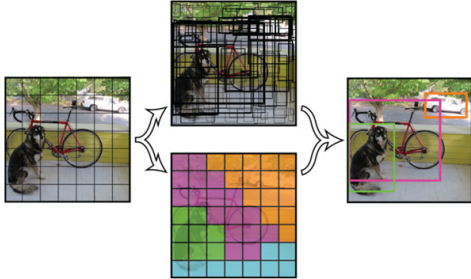


Fig. 5. The architecture of YOLO [16]

2.3 분석방법

데이터 분석방법은 위에서 언급한 네 가지 알고리즘으로 토마토 데이터를 학습시키고, 각 모델들을 검증하였다. 본 연구에서는 mAP (mean Average Precision)를 이용하여 각 인식 모델의 성능을 평가 및 비교하였다. mAP는 객체 인식 모델의 정확도를 나타내기 위한 평가 지표이다. mAP는 모델의 정확도와 정밀도 값을 이용하여 구할 수 있으며, 정확도 및 정밀도는 Eq. (1)과 Eq. (2)로 계산된다[20].

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (1)$$

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

여기서 TP (True Positive)는 맞게 검출된 객체, FP (False Positive)는 잘못 검출된 객체, FN (False Negative)의 경우에는 검출되어야 할 객체가 검출되지 않은 오류, TN (True Negative)은 검출되지 말아야 하는 객체가 검출되지 않음 의미한다. 한편, 본 연구에서는 토마토의 실시간 인식을 위해 각 모델들의 성능을 fps (Frame per Second)로 비교하였으며, GPU 및 CPU 환경에서 각 모델에 대한 fps를 측정하였다. 본 실험에서는 Intel Core i9-7920X CPU와, NVIDIA Geforce RTX 2080Ti GPU를 사용하였다.

3. 결과 및 고찰

Table 1은 각 모델에 대한 최적의 파라미터와 mAP를 나타낸 것이며, 각 모델의 파라미터는 기초실험을 통해 선정되었다. 각 모델에 대한 이미지의 사이즈는 GPU

의 메모리를 고려하여 결정되었으며, Batch size는 모든 모델에서 동일하다. 학습 수렴속도에 영향을 미치는 learning rate는 local minimum 문제와 수렴 값을 고려해 모델 선택 실험을 진행한 후, 각 알고리즘에 최적화된 수치값인 0.001과 0.0025로 진행하였다. 그 결과, IoU50 (Intersection over Union)에서 최고 mAP는 YOLOv3 및 YOLOv4 모델이 각각 91.96%, 92.09%로 비교적 높은 성능을 나타냈으며, SSD와 Faster R-CNN의 경우에는 90% 이하로 나타났다. 한편, Fig. 6은 Faster R-CNN의 mAP와 loss를 보여준다. 10,000 epoch 근처에서 수렴한 것을 확인할 수 있었으며, Faster R-CNN은 learning rate가 0.0025이기 때문에 비교적 빠르게 수렴한 것을 확인할 수 있다.

Table 1. The parameter and mAP for the each model

Model	Image Size	Batch size	Learning rate	Best mAP (IoU.5)
YOLOv3	416×416	8	0.001	91.96
YOLOv4	416×416	8	0.001	92.09
SSD	512×512	8	0.001	87.04
Faster R-CNN	256×256	8	0.0025	89.03

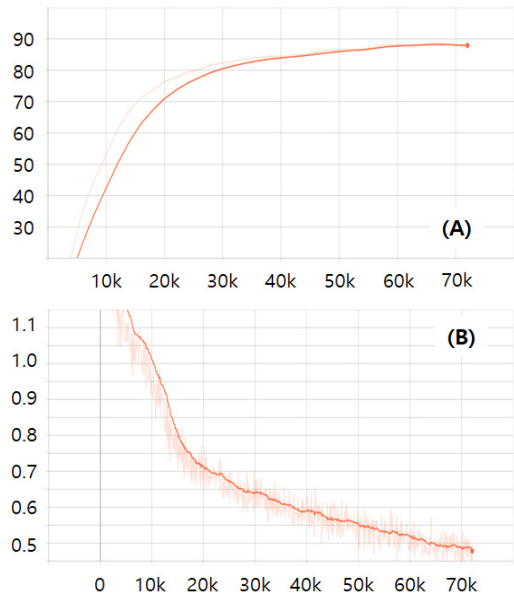


Fig. 6. Faster R-CNN graph : (A) mAP (B) loss

Fig. 7은 SSD의 mAP와 loss를 나타낸 그래프이다. 10,000 epoch까지 학습하면서 수렴하였으며, loss 값의 변동이 큰 이유는 최적화 함수로 SGD (Stochastic

Gradient Descent)를 사용했기 때문에 수렴과정에서 변동이 있었기 때문으로 판단된다.

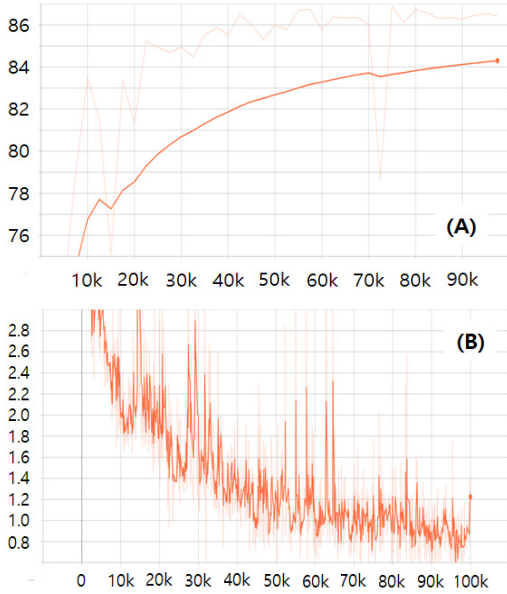


Fig. 7. SSD graph : (A) mAP (B) loss

Fig. 8은 YOLOv3 및 YOLOv4 모델의 mAP와 loss를 나타냈다. 10,000 epoch의 학습을 통해 수렴한 loss 값을 확인할 수 있었다.

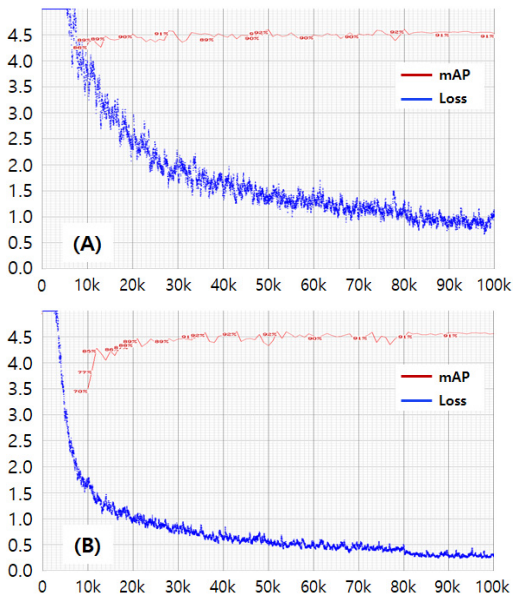


Fig. 8. mAP & loss graph : (A) YOLOv3 (B) YOLOv4

한편, GPU를 이용하여 Faster R-CNN, SSD, YOLOv3 및 YOLOv4의 네 가지 모델을 학습한 결과, 동일한 batch size에서 SSD 모델이 이미지의 사이즈를 가장 크게 조절할 수 있었으나, 인식 정확도의 경우에는 YOLOv3 및 YOLOv4 모델이 더 높은 것으로 나타났다. 한편, 전술한 바와 같이 SSD, YOLO와 같은 One-stage 알고리즘의 경우에는 작은 객체(32×32 pixel size)의 인식을 위한 정확도가 비교적 낮다는 문제점이 있다. 그러나, 본 연구에서 사용한 토마토 과실의 이미지는 32×32 pixel 보다 크기 때문에 Faster R-CNN 모델보다 YOLO 기반 모델들의 정확도가 높은 것으로 판단된다. 또한, YOLO 기반의 알고리즘이 SSD 알고리즘과 비교하여 정확도가 더 높은 이유는 YOLO의 경우 데이터 학습 시, 이미지 전체를 처리하여 background error가 적기 때문으로 판단된다.

한편, 본 연구에서는 고가의 GPU를 대체하여 인식 시스템의 경제성을 확보하기 위해 CPU의 적용 가능성을 검토하고자 하였으며, 테스트 이미지는 Fig. 9에 나타내었고, 이를 위한 결과는 Table 2에 나타냈다. 먼저, Weight file의 크기는 YOLOv4가 가장 크고, Faster R-CNN이 가장 작은 것으로 나타났으나, 이는 각 인식 모델의 학습을 위해 적용된 backbone 네트워크와 파라미터가 상이하였기 때문에 fps 평가 및 비교를 위해 상관관계가 없는 것으로 판단된다.

Table 2. Comparisons of resource with fps

Model	Weight file size	GPU inference frame rate	CPU inference frame rate
YOLOv3	246.3 MB	56.95 fps (17.56ms)	5.39 fps
YOLOv4	256.0 MB	47.8 fps (20.9ms)	4.56 fps
SSD	195.1 MB	52.63 fps (19ms)	2.55 fps
Faster R-CNN	158.0 MB	11.11 fps (90ms)	



Fig. 9. Example of the output images

GPU를 사용하여 각 인식 모델의 fps를 비교한 결과, Table 2와 같이 YOLOv3, YOLOv4 및 SSD는 각각 56.95 fps, 47.80 fps, 52.63 fps로 나타났으며, Faster R-CNN의 경우에는 11.11 fps로 나타났다. 이처럼 YOLO 기반 및 SSD 모델들의 처리속도가 빠른 이유는 전술한 바와 같이 One-stage 방식의 모델이 Two-stage 방식과 비교하여 객체 인식을 위한 연산이 적기 때문으로 판단된다.

CPU 환경에서의 각 인식 모델 별 fps도 비교하였으며, YOLOv3는 5.39 fps, YOLOv4는 4.56 fps, SSD는 2.55 fps의 성능이 도출되었다. 이처럼 CPU 환경에서 인식 모델의 frame 저하율은 YOLO 기반의 모델이 가장 적은 것으로 나타났으며, 특히, YOLOv3에서 fps는 5.0 이상으로 나타났다. 한편, 인식영역의 해상도, 온실 내부 온도 및 장시간 작동시 발생하는 장비 자체 열에 의한 성능저하 및 프레임 드랍 등의 문제가 발생할 수 있다. 이러한 문제를 방지하고 모바일 로봇의 이동 속도를 고려할 경우 YOLO 모델이 CPU 환경에서 실시간 객체 인식을 위해 적합하다고 판단된다. 또한 본 연구에서는 Intel Core i9-7920X의 고사양 CPU를 사용했기 때문에, 저사양 CPU를 사용할 경우 각 인식 모델의 fps는 감소할 가능성이 있다. 따라서 5.39 fps의 YOLOv3기반 모델이 CPU에서 가장 적합한 모델이라고 판단되며, 다양한 모델을 적용하기 위해서는 추후에 인식 모델을 보다 경량화하기 위한 추가적인 연구가 필요하다고 판단된다.

4. 결론

본 논문에서는 수경방식으로 재배되는 토마토의 인식 모델을 개발을 위해 딥러닝 기술을 적용하였으며, 이를 위해 Faster R-CNN, SSD, YOLOv3 및 YOLOv4 네 가지 알고리즘이 이용되었다. 또한, 각 알고리즘의 성능 평가 및 비교를 위해 mAP를 이용하였으며, 그 결과, YOLO 기반의 알고리즘에서 정확도가 가장 높은 것으로 나타났다. 한편, 고사양 GPU를 대체하고 객체 인식 시스템의 경제성을 확보하기 위해 CPU의 적용 가능성을 검토하기 위한 기초실험을 수행하였으며, 그 결과 YOLO 기반의 알고리즘을 이용할 경우, CPU 환경에서도 실시간 객체 인식이 가능할 것으로 판단된다. 추후에는 YOLOv5 small, SSD Mobile-Net 및 TF Light 등의 경량화 모델들을 이용하여 각 모델의 fps를 개선하기 위한 추가적인 연구를 진행할 예정이며, 또한 토마토 이

외의 수경재배 작물에도 적용하기 위한 연구를 수행할 예정이다.

References

- [1] Y.G. Park, S. Baek, J.S. Im, M.J. Kim, J.H. Kim. "Present status of smart greenhouses growing fruit vegetables in Korea: focusing management of environmental conditions and pests in greenhouses", *Korean Journal of Applied Entomology*, Vol.59, No.1 pp.55-64, Feb 2020. DOI: <https://doi.org/10.5656/KSAE.2020.02.1.061>
- [2] SmartFarm. 2021. Distribution status of smart farm. Available From: <https://www.smartfarmkorea.net/main.do> (accessed Nov. 20, 2021)
- [3] Korean Statistical Information Service (KOSIS). 2021. Crop production survey. Available From: https://kosis.kr/statHtml/statHtml.do?orgId=101&tblId=DT_1ET0027&conn_path=I2 (accessed Sep. 18, 2021)
- [4] Y.J. Kim, J.Y. Park, Y.G. Park, "An Analysis of the Current Status and Success Factors of Smart Farms", Research Report, Korea Rural Economic Institute(KREI), Korea, pp.51.
- [5] C.B. An, J.H. Shin, "Comparison of rockwool, reused rockwool and coir medium on tomato (*Solanum lycopersicum*) growth, fruit quality and productivity in greenhouse soilless culture", *Journal of Bio-Environment Control*, Vol.30, No.3, pp.175-182, May, 2021. DOI: <https://doi.org/10.12791/KSBEC.2021.30.3.175>
- [6] L. Zhang, J. Jia, G. Gui, X. Hao, W. Gao, M. Wang, "Deep learning based improved classification system for designing tomato harvesting robot", *IEEE Access*, Vol.6, pp.67940-67950, Nov. 2018. DOI: <https://doi.org/10.1109/ACCESS.2018.2879324>
- [7] P. Majumdar, S. Mitra, D. Bhattachaya, *Journal of Biosystems Engineering*, "IoT for promoting agriculture 4.0: a review from the perspective of weather monitoring, yield prediction, security of WSN protocols, and hardware cost analysis", Vol.46, pp.440-461, Nov. 2021. DOI: <https://doi.org/10.1007/s42853-021-00118-6>
- [8] D.S. Seo, B.H. Cho, K.C. Kim, "Development of monitoring robot system for tomato fruits in hydroponic greenhouses", *Agronomy*, Vol.11, No.11, pp:2211, Oct. 2021. DOI: <https://doi.org/10.3390/agronomy11112211>
- [9] J.P. Vasconeza, J. Delpianob, S. Vougioukasc, C.F. Auat, "Comparison of convolutional neural networks in fruit detection and counting: a comprehensive evaluation", *Computers and Electronics in Agriculture*, Vol.173, 105348, Mar. 2020.

DOI: <https://doi.org/10.1016/i.compag.2020.105348>

- [10] G. Liu, J.C. Nouaze, P.L.T. Mbouembe, J.H. Kim, "YOLO-Tomato: a robust algorithm for tomato detection based on YOLOv3", *sensors*, Vol.20, No.7 pp.2145, Apr. 2020.
DOI: <https://doi.org/10.3390/s20072145>
- [11] R. Gai, N. Chen, H. Yuan, "A detection algorithm for cherry fruits based on the improved YOLO-v4 model", *Neural Computing and Applications*, May. 2021.
DOI: <https://doi.org/10.1007/s00521-021-06029-z>
- [12] M.B. Ullah, "CPU Based YOLO: a real time object detection algorithm", *IEEE Region 10 Symposium (TENSymp)*, pp.552-555, Nov. 2020.
DOI: <https://doi.org/10.1109/TENSymp50017.2020.9230778>
- [13] Larxel, Tomato Detection, Kaggle, 2020, Available from: <https://www.kaggle.com/andrewmvd/tomato-detection> (accessed Aug. 23, 2021)
- [14] S. Ren, K. He, R. Girshik, J. Sun, "Faster R-CNN: towards real-time object detection with region proposal networks", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.39, No.6, pp. 1137-1149, Jun. 2017.
DOI: <https://doi.org/10.1109/TPAMI.2016.2577031>
- [15] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu, C.B. Alexander, "SSD: single shot multibox detector", *Computer Vision - ECCV 2016*, Vol.9905, pp 21-37, Sep. 2016.
DOI: https://doi.org/10.1007/978-3-319-46448-0_2
- [16] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You only look once: unified, real-time object detection", *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.779-788, Dec. 2016.
DOI: <https://doi.org/10.1109/CVPR.2016.91>
- [17] J. Redmon, A. Farhadi, "YOLOv3: An Incremental Improvement", *arXiv preprint arXiv:1804.02767*, Apr. 2018.
<https://arxiv.org/abs/1804.02767>
- [18] A. Bochkovskiy, C.Y. Wang, H.Y. Liao, "YOLOv4: optimal speed and accuracy of object detection", *arXiv preprint arXiv:2004.10934*, Apr. 2020.
<https://arxiv.org/abs/2004.10934>
- [19] A.I.B. Parico, T. Ahamed, "Real time pear fruit detection and counting using YOLOv4 models and deep SORT", *Sensors*, Vol.21, No.14, pp.4803, Jul. 2021.
DOI: <https://doi.org/10.3390/s21144803>
- [20] D. Chicco, G. Jurman, "The advantages of the matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation", *BMC Genomics*, Vol.21, No.6, Jan. 2020.
DOI: <https://doi.org/10.1186/s12864-019-6413-7>

김 용 현(Yong-Hyun Kim)

[정회원]



- 2021년 2월 : 성균관대학교 바이오메카트로닉스학과 (공학석사)
- 2021년 7월 ~ 현재 : 국립농업과학원 스마트팜개발과 전문연구원
- 2022년 3월 ~ 현재 : 충남대학교 바이오시스템기계공학과 박사과정

〈관심분야〉

인공지능, 컴퓨터비전

조 병 호(Byeong-Hyo Cho)

[정회원]



- 2017년 8월 : 충북대학교 대학원 바이오시스템공학과 (공학석사)
- 2021년 3월 : 홋카이도대학 농학원 공생기반학전공 (농학박사)
- 2021년 7월 ~ 현재 : 국립농업과학원 스마트팜개발과 박사후연구원

〈관심분야〉

영상처리, 농업 인공지능, 비파괴 분석

서 다 슴(Dasom Seo)

[정회원]



- 2019년 2월 : 전북대학교 전북대학원 컴퓨터공학 (공학석사)
- 2019년 6월 ~ 2021년 12월 : 국립농업과학원 스마트팜개발과 전문연구원
- 2020년 9월 ~ 현재 : 전북대학교 컴퓨터공학 박사과정

〈관심분야〉

인공지능, 컴퓨터비전

송 혜 영(Hye-Young Song)

[정회원]



- 2020년 2월 : 경상국립대학교
바이오시스템공학과 (공학석사)
- 2021년 7월 ~ 현재 : 국립농업과
학원 스마트팜개발과 전문연구원

<관심분야>

정보경영, 정보통신

김 경 철(Kyoung-Chul Kim)

[정회원]



- 2009년 2월 : 전북대학교 정밀기
계공학과 (공학석사)
- 2015년 8월 : 전북대학교 정밀기
계공학과 (공학박사)
- 2016년 7월 ~ 2019년 1월 : 농업
기술실용화재단 연구원
- 2019년 2월 ~ 현재 : 국립농업과
학원 스마트팜개발과 연구사

<관심분야>

농업로봇, 농업드론, 스마트 팜