

위성이미지 기반 시설하우스 판별 Mask-RCNN 모델 개발

김윤석^{1†}, 허 성^{2†}, 윤성욱¹, 안진현³, 최인찬⁴, 장성울⁵, 이승재⁶, 정용석^{*}
¹제주대학교 식물자원환경전공, ²공주대학교 원예학과, ³제주대학교 경영정보학과,
⁴국립농업과학원 농업공학부, ⁵첨단방사선연구소 방사선육종센터, ⁶국가농림기상센터
(2021년 6월 10일 접수; 2021년 8월 24일 수정; 2021년 9월 8일 수락)

Development of Mask-RCNN Model for Detecting Greenhouses Based on Satellite Image

Yun Seok Kim^{1†}, Seong Heo^{2†}, Seong Uk Yoon³, Jinhyun Ahn¹, Inchan Choi⁴,
Sungyuul Chang⁵, Seung-Jae Lee⁶, Yong Suk Chung^{1*}

¹Department of Plant Resources and Environment, Jeju National University

²Department of Horticulture, Kongju National University

³Department of Management Information Systems, Jeju National University

⁴National Agrobiodiversity Center, National Institute of Agricultural Sciences (NAS), RDA

⁵Department of Agricultural Engineering, National Institute of Agricultural Sciences

⁶National Center for AgroMeteorology

(Received June 10, 2021; Revised August 24, 2021; Accepted September 8, 2021)

ABSTRACT

The number of smart farms has increased to save labor in agricultural production as the subsidy become available from central and local governments. The number of illegal greenhouses has also increased, which causes serious issues for the local governments. In the present study, we developed Mask-RCNN model to detect greenhouses based on satellite images. Greenhouses in the satellite images were labeled for training and validation of the model. The Mask-RCNN model had the average precision (AP) of 75.6%. The average precision values for 50% and 75% of overlapping area were 91.1% and 81.8%, respectively. This results indicated that the Mask-RCNN model would be useful to detect the greenhouses recently built without proper permission using a periodical screening procedure based on satellite images. Furthermore, the model can be connected with GIS to establish unified management system for greenhouses. It can also be applied to the statistical analysis of the number and total area of greenhouses.

Key words: Deep learning, Mask-RCNN, Detectron2, Satellite image, Average precision

[†] These authors equally contributed.

^{*} Corresponding Author : Yong Suk Chung
(yschung@jejunu.ac.kr)



I. 서 론

국내 시설하우스 재배면적은 2015년 66,919 ha에서 2020년 69,972 ha로 계속 증가하고 있다. 특히, 시설하우스에서 재배되는 채소류의 생산량도 2018년 2,381,198 ton에서 2019년 2,441,287 ton으로 역시 증가 추세에 있다(KOSIS, 2021). 시설하우스가 농업의 4차 산업혁명을 이끌 수 있는 스마트팜으로 개념이 확장됨에 따라 정부의 지속적인 지원과 민간의 투자가 급속도로 이루어지고 있다. 특히, 사물인터넷(Internet of Things, IoT)을 기반으로 ICT (Information and Communication Technology)가 융합된 스마트팜이 생산성 뿐만 아니라 품질 또한 향상되고, 노동력이 절감되어 생력 재배가 가능한 장점으로 인해 선도농가 중심으로 널리 확산되고 있다(Kim and Lee, 2019). 스마트팜은 작물의 생육정보와 환경정보에 대한 대량의 데이터를 대상으로 이를 분석해 작물이 필요한 비료 및 노동력을 적시에 투입하여 기존 농업보다 노동시간, 투입비용을 낮추면서도 생산성과 품질을 제고하는 장점을 가지고 있다(Kim and Lee, 2019).

우리나라에서는 기존 시설하우스(유리온실 및 비닐하우스)를 대상으로 IoT에 기반한 자동화시스템이 우선적으로 도입되어 농장의 디지털화를 통해 원격으로 모니터링하면서 제어가 가능해 농가의 편의성을 크게 향상시키고 있다. 우리나라의 농업은 타 산업에 비해 청년층의 유입이 적어 농업인구가 노년층에 치우쳐 있고, 게다가 그 농업인구마저 고령화로 인해 노동투입 가능시간이 계속 줄고 있어 스마트팜의 도입이 절실한 상황이다. 이러한 이유로 인해 정부의 스마트팜 도입에 막대한 예산이 투입되고 있는 실정이다.

유리온실을 비롯한 비닐하우스가 전국에 계속 늘어나고 있는데 반해, 이에 대한 정부 또는 지자체의 체계적인 관리는 제대로 이루어지지 않고 있다. 초기 투자비용이 많이 요구되는 유리온실과 달리 비닐하우스는 초기 설치비용이 그다지 높지 않아 무분별하게 증가하고 있으며, 최근 베이비 붐 세대의 퇴직에 따른 귀농인구가 급속히 증가함에 따라 불법 가설된 비닐하우스가 증가하는 또 다른 이유가 되고 있다. 특히 배경지식이 전혀 없는 귀농 가구의 경우 비닐하우스 설치가 일정면적(100 m²)를 상회할 경우, 지자체에 신고 및 허가를 받아야 하는 것을 몰라 이를 단속하기 위해 지자체 공무원이 투입되고 있는 실정이다. 이러한 상황이 서울시 내 개발제한구역에 비롯하여 전국에서 이루어지

고 있어 이에 따른 행정력의 낭비가 심각하다. 더구나, 농업기술원에서 빗물, 용출수, 염지하수, 태양열 등의 자연에너지를 보급하며 국가 온실가스 감축사업에 적용 가능한 기술에 관심을 가지는 현 상황에서 무분별하게 증가하고 있는 가설 시설하우스를 관리하는 시스템을 확립하여 효율적인 정책이 진행되도록 지원하는 것이 필요하다. 특히, 이러한 시스템은 국가 또는 지방 정부 차원에서 도입하여 유지될 필요가 있다.

본 연구에서는 위성 촬영 이미지를 분석하여 무허가 시설하우스를 자동으로 찾는 인공지능 기반 기술을 제안한다.

II. Mask-RCNN (Detectron2) 모델 적용

본 연구에서는 카카오맵 OPEN API를 활용하여 위성 촬영 이미지 데이터셋을 확보하였다. 일반적인 위성 촬영 이미지는 대기 환경에 따라 또는 미세먼지 등의 영향으로 고해상도의 지표 이미지를 획득하기 어려우나 카카오맵의 경우 정제된 지표 이미지를 제공한다. 지표 이미지에서 무허가 시설하우스를 자동으로 검출하는 기술을 개발하기 위해서는 대량의 훈련 데이터가 필요하다. 하지만, 현실적으로 무허가 시설하우스와 관련된 훈련 데이터를 확보하는 것이 어렵기 때문에 카카오맵 OPEN API를 활용해 확보된 소량의 훈련 데이터에 최신의 물체 검출 모델인 Mask-RCNN을 적용한 전이학습을 수행했다(Fig. 1).




Fig. 1. Methodological Flowchart of Satellite Image Analysis.

2.1. 데이터 전처리

카카오맵 OPEN API를 활용하여 추출한 제주도 서귀포시 대정읍 지역의 중심좌표 기준(위도 33.2553, 경도 126.2732 반경 2.5km × 2.5km), 제주도 제주시 한경면 지역의 중심좌표 기준(위도 33.2998, 경도 126.2188 반경 2.5km × 2.5km), 제주도 서귀포시 성산읍 지역의 중심좌표 기준(위도 33.3644, 경도 126.8521) 위성영상 3장을, 기존 10000px × 10000px 에서 1000px × 1000px로 각각 100장씩 잘라 새로운 데이터셋을 구성한다. 그 중, 온실 객체가 존재하지 않는 데이터를 제외하여 177개의 데이터를 확보하였고, 이중 127개를 학습(Training) 데이터, 30개를 검증(Validation) 데이터, 20개를 테스트(Test) 데이터로, 무작위로 나누어 구성하였다(Fig. 2).

또한, 본 데이터는 카카오의 지도 서비스에서 보정 후 제공하는 위성 영상 데이터로, Sentinel, MODIS 와 같은 공개용 위성 영상 데이터처럼 사용자가 직접 보정하여 사용할 필요성이 없으며, 객체 인식 및 검출이라는 목적에 한하여 연구를 진행하였기 때문에, 별도의 보정을 수행하지 않았다.




Fig. 2. Pre-Processing of Satellite Images.

2.2. 이미지 라벨링

구성한 데이터셋을 오픈소스 라벨링 프로그램인 “Labelme”를 사용하여 라벨링 과정을 거친다. “Labelme” 프로그램은, 폴리곤(Polygon), 경계 상자(BBox) 등 여러 툴을 활용하여 라벨링 작업을 수행할 수 있다(Fig. 3). 이 과정을 수행한 각 영상 데이터마다 Json 파일이 생성되며 모델 학습 시 입력으로 샘플 영상과 함께 활용된다. 본 논문에서는 폴리곤(Polygon) 툴을 활용하여 영상 내 온실을 라벨링하였으며, 클래스(Class)명은 “House”로 지정하여 수행하였다.

2.3. 모델학습 및 추론

시설하우스 분류 모델 생성에는 Mask-RCNN 기반의 프레임워크인 “Detectron2”를 사용한다. 이를 이용한 신경망 학습에는 수많은 연산이 필요하기 때문에 우수한 연산 성능을 가진 시스템이 필요하며 이에 따라 속도의 차이가 존재한다. 본 연구의 학습에는, Google사의 Colaboratory Pro 서비스를 이용하였으며 주요 시스템 사양으로는, Ubuntu 18.04.5 LTS 운영체제, Intel(R) Xeon(R) CPU @ 2.00GHz, 24GB RAM, Nvidia Tesla V100 SXM2 16Gb GPU 와 같다. 학습에는 전처리를 수행한 127개의 학습 데이터와, 30개의 검증 데이터가 이용되었다(Fig. 4).

본 모델을 학습시키는 알고리즘인 Mask-RCNN은 기존의 Faster-RCNN을 사용하여 객체의 경계선을 찾는 과정과 더하여 객체의 마스크를 예측하는 과정을 별도로 추가하여 성능을 높였다(He et al., 2017). 이미지가 주어졌을 때 객체를 찾아내기 위해 “Region”이라 불리는 영역을 예측하고 동시에 양질의 마스크를 효과적으로 찾아내게 된다. 본 논문에서는 Detectron2 프레임워크 내에서 제공하는 model_final_f10217.pkl 모델을 전이학습에 이용한다. 학습에는 Table 1과 같이 하이퍼 파라미터(Hyper-parameter)를 설정하여 진행하였다.

Table 1. Hyperparameters for Training

Setting	Value
SOLVER.IMS_PER_BATCH	2
SOLVER.BASE_LR	0.00025
SOLVER.MAX_ITER	1000



Fig. 3. Data Labeling.




Fig. 4. Example of Training Samples.


반복 횟수(Iteration)에 따른 학습 과정의 손실(Total Loss), 정확도(Accuracy) 그래프는 텐서보드를 이용하여 나타내었다(Fig. 5). 손실은 모든 샘플에 대해 예측과 실재가 얼마나 다른지에 대한 측정치로 절대적인 수치는 의미가 없고 상대적인 수치로 판단한다. 정확도는 전체 샘플 개수들 중 올바르게 예측한 샘플의 개수에 대한 비율이다. 손실값이 최소로, 정확도값이

최대로 향하는 것이 본 학습의 목적이다.

그래프에서 보여지는 것과 같이, 손실과 정확도 곡선은 반복 횟수의 증가에 따라 상승곡선을 그리며, 손실은 0, 정확도는 1에 수렴하는 경향을 보여준다. 이를 세분화하여 수치화한 결과, 분류(Classification)와 마스크(Mask)의 최고 정확도는 각각, 98%, 97%이며, 최저 손실은 각각 5%, 7%로 측정되었다(Table 2).



(a) Accuracy Graph



(b) Total Loss Graph

Fig. 5. Training Accuracy (a) & Total Loss (b) Graph.

Table 2. Class, Mask Best Accuracy & Total Loss

	AP	AP ₅₀	AP ₇₅	APL
bbox	74.396	89.876	79.827	74.994
segm	75.578	91.106	81.839	76.874

학습 과정에서, 검증 데이터를 이용한 평가는 후술 할 Average Precision (AP)로 진행되었다. 학습 중 100 반복 횟수 마다 검증 데이터의 평가가 이루어졌으며, 이중 모델이 제시한 영역인 분할(Segmentation)과 실제 정답이 50%이상 겹치는 경우의 정확도 평균인 AP₅₀ 최댓값은 92.47%로 측정되었다(Fig. 6).

학습을 통해 얻은 가중치 모델을 이용하여 테스트 영상에 적용하여 추론을 수행한 결과 Fig. 6과 같은 결과가 나왔다. 추론에 사용한 영상은 학습 데이터와 마찬가지로 동일한 방법으로 분할된(1000 × 1000 크기) 영상을 사용했으며 추론시간은 약 20초가 소요되었다. 추론된 영상은 경계 상자와 클래스명, 그리고 온실 영역을 채우는 마스크가 생성되었다. 그리고 각

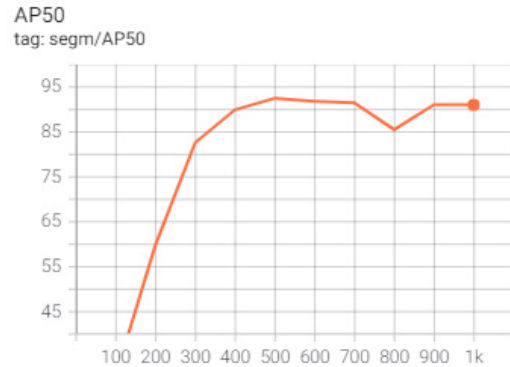

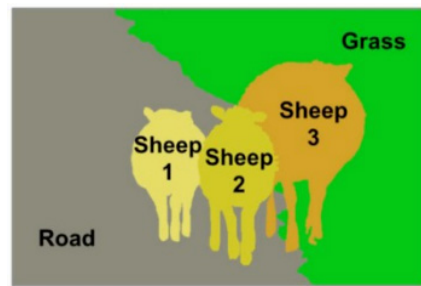


Fig. 6. Validation AP₅₀ Graph.



(a) Semantic Segmentation



(b) Instance Segmentation

Fig. 7. Difference between Semantic Segmentation and Instance Segmentation (Géron, 2018).

각의 객체가 따로 분리되어 추론되는 인스턴스 분할(Instance Segmentation)이 수행되었고 이는 영상에서 각기 다른 색으로 마스크되어 나타내어졌다. 기존에 널리 쓰이던 분할 방법 중, 시멘틱 분할(Semantic Segmentation)은, 같은 클래스의 인스턴스(Instance)를 구별하지 않는 반면에, 본 실험에서 사용된 인스턴스 분할은 인스턴스를 구별(Fig. 7)하여 수행되기 때문에, Fig. 8의 추론 이미지와 같이, 붙어있는 시설하우스라도 각각의 객체로 분할되었다.

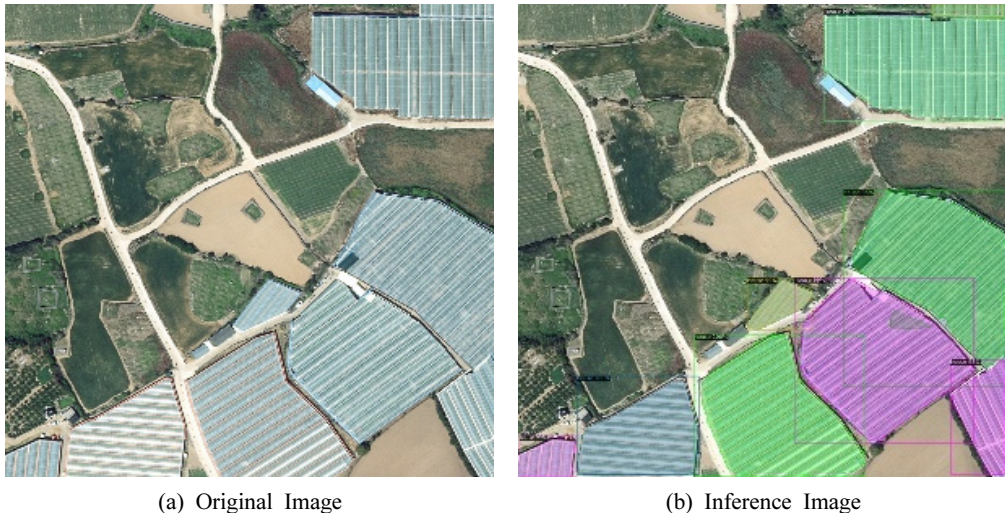


Fig. 8. Result of Inference.

2.4. 성능 평가

학습된 모델에 대한 평가는 테스트 데이터셋을 이용하였다. 물체 검출 모델의 성능 평가 기준은 모든 검출 결과 중 옳게 검출한 비율인 정밀도(Precision)와 검출해내야 하는 물체들 중 제대로 검출된 것의 비율인 재현율(Recall)이 있다. 모델의 하이퍼 파라미터값 조정에 따라 성능이 달라지기 때문에 여러 개의 하이퍼 파라미터 값에 대해 실험을 한다. 각 실험에 대한 정밀도와 재현율을 계산하고 2차원 그래프에 그린 후 곡선의 아래쪽의 면적(Area Under the Curve)인 Average Precision (AP)으로 학습된 모델의 성능을 평가한다. 정밀도와 재현율의 범위는 0.0부터 1.0까지이고 각각을 X축과 Y축에 배치했을 때 1사분면 전체 면적은 1.0이 된다. AP는 정밀도-재현율 그래프를 그렸을 때 전체 면적(1.0) 대비 그래프 아래쪽 면적의 비율(%)이다. 일반적으로 정밀도가 좋아지면 재현율이 나빠지고 재현율이 좋아지면 정밀도가 나빠진다(He et al., 2017). AP는 정밀도와 재현율을 모두 고려하는 평가 기준이다.

Table 3은 테스트 데이터를 활용하여 산출된 AP값이다. 모델이 예측한 결과와 Ground Truth가 얼마나 정확하게 겹치는가를 나타내는 지표인 IoU (Intersection over Union)과 연계하여 IoU가 50~95%인 경우의 평균은 AP, IoU가 50% 이상일 때는 AP_{50} , IoU가 75% 이상일 때는 AP_{75} 로 정의한다. APL은 큰 크기의 물체에 대한 AP이다. 분할(Segmentation) AP가 91.106%으로 가장 높게 평가되었으며, 학습 시 검증에 대한 평가와 유사

하게 나왔다. 이는, 모델이 학습 데이터에 너무 잘 맞지만 일반성이 떨어지는 과대적합(Overfitting)이 발생하지 않았으며, 새로운 데이터에 대한 예측이 잘 될 수 있다는 의미를 가진다.

Table 3. Average Precision(AP)

	AP	AP_{50}	AP_{75}	APL
segm	75.578	91.106	81.839	76.874

III. 결 론

본 연구에서는 신축된 가설 시설하우스를 기존 시설하우스와 구분하기 위해 Mask-RCNN 기반의 Detectron2를 활용하여 하우스 객체를 인식하고 검출하는 모델을 개발하였다. Detectron2는 FAIR (Facebook Artificial Intelligence Research)에서 개발한 객체 탐지 및 인스턴스 분할이 가능한 프레임워크로 R-CNN 기반의 타 모델에 비하여 뛰어난 성능을 가지고 있는 것으로 평가받고 있다(Carvalho et al., 2020). 위성 이미지를 가공하여 대량의 분석 데이터를 확보하고, 하우스 객체를 라벨링하여 모델 학습에 활용하였다. 테스트 이미지를 대상으로 추론한 결과 인스턴스 분할 모델 평가에 많이 활용되는 AP 보편 75.6% (AP), 91.1% (AP_{50}), 81.8% (AP_{75})로 비교적 적은 데이터로도 우수한 객체 탐지 성능을 보여주었다.

적 요

본 인스턴스 분할 모델은 위성을 이용해 촬영된 원격탐지 영상 내의 객체 탐지에 높은 정확도를 갖는다는 것을 입증하였으며, 불법으로 가설된 시설 하우스를 발견하는데 활용될 수 있다. 즉, 특정 지역 및 일정 시기를 기준으로 시설하우스를 인식시키고 그 이후에 신축된 하우스를 분별하는데 사용할 수 있을 것이다. 또한 본 기술을 응용하여, 토지피복도 조사와 같은 인력중심의 작업을 빠르게 해결할 수 있다. 앞으로 이 모델은 지리정보시스템(Geographic Information System)과 연계하여 중앙정부 차원의 단일화된 관리체계를 수립할 수 있을 것이며 또한 시설하우스 면적 통계 수치 계산에도 쉽게 응용될 수 있을 것으로 판단된다.

감사의 글

본 연구는 농촌진흥청 국가생명연구자원선진화 사업 농업과학기술연구 개발사업(중자클러스터 중앙·거점 소재은행 자원정보 표준화 및 연계통합, 과제번호: PJ015870)의 지원에 의해 이루어졌습니다. 또한 본 연구는 제주대학교 친환경농업연구소의 연구소 지원을 받았습니다.

REFERENCES

- Carvalho, O. L. F. d., O. A. de Carvalho Júnior, A. O. d. Albuquerque, P. P. d. Bem, C. R. Silva, P. H. G. Ferreira, R. d. S. d. Moura, R. A. T. Gomes, R. F. Guimarães, D. L. Borges, 2020: Instance Segmentation for Large, Multi-Channel Remote Sensing Imagery Using Mask-RCNN and a Mosaicking Approach. *Remote Sensing* **13**(1), 39.
- He, K., G. Gkioxari, P. Dollár, and R. Girshick, 2017: Mask R-CNN. *2017 IEEE International Conference on Computer Vision*, Venice, Italy, 2961-2969.
- Kim, J. E., and J. W. Lee, 2019: Smartfarm technology and market report. Commercializations Promotion Agency for R&D Outcomes, 1-16pp.
- KOSIS (Korean Statistical Information Service), 2021: Agricultural area and crop production survey. <http://kosis.kr/index/index.do> (Accessed on Feb. 24th, 2021)
- Géron, Aurélien, 2018: Introducing Capsule Networks, <https://www.oreilly.com/content/introducing-capsule-networks> (Accessed on Sep. 6th, 2021)