

# YOLO v2를 이용한 고해상도 항공영상에서의 태양광발전소 탐지 방법 연구

김하영 · 나라\* · 주동혁\* · 최규훈\*\* · 오윤경\*\*\*

전남대학교 농업생명과학대학 지역·바이오시스템공학과 BK21 석사과정

\*전남대학교 농업생명과학대학 지역·바이오시스템공학과 BK21 박사과정

\*\*위디비 주식회사 대표

\*\*\*전남대학교 농업생명과학대학 농업과학기술연구소 학술연구교수

## A Study on the Detection of Solar Power Plant for High-Resolution Aerial Imagery Using YOLO v2

Kim, Hayoung · Na, Ra\* · Joo, Donghyuk\* · Choi, Gyuhoon\*\* · Oh, Yun-Gyeong\*\*\*

*Master Student, Department of Rural and Biosystems Engineering & BK21 Education and Research Unit for Climate-smart Reclaimed-Tideland Agriculture, Chonnam National University*

*\*Doctoral Student, Department of Rural and Biosystems Engineering & BK21 Education and Research Unit for Climate-smart Reclaimed-Tideland Agriculture, Chonnam National University*

*\*\*CEO, WeDB*

*\*\*\*Research Professor, Institute of Agricultural Science & Technology, Chonnam National University*

**ABSTRACT** : As part of strengthening energy security and responding to climate change, the government has promoted various renewable energy measures to increase the development of renewable energy facilities. As a result, small-scale solar installations in rural areas have increased rapidly. The number of complaints from local residents is increasing. Therefore, in this study, deep learning technology is applied to high-resolution aerial images on the internet to detect solar power plants installed in rural areas to determine whether or not solar power plants are installed. Specifically, I examined the solar facility detector generated by training the YOLO(You Only Look Once) v2 object detector and looked at its usability. As a result, about 800 pieces of training data showed a high object detection rate of 93%. By constructing such an object detection model, it is expected that it can be utilized for land use monitoring in rural areas, and it can be utilized as a spatial data construction plan for rural areas using technology for detecting small-scale agricultural facilities.

**Key words** : Deep learning, Solar power plant, Land-use, Aerial Image, YOLO v2

## I. 서 론

에너지 안보 강화와 기후변화 대응의 일환으로 무공해 청정에너지의 중요성이 높아지면서 정부에서는 신재생에너지 확대를 위해 다양한 지원책을 추진하였으며, 그 결

과 농촌지역에 소규모 태양광 발전소 개수가 크게 증가하였다. 전력거래소 전력통계정보시스템에서 제공하는 신재생에너지의 설비용량을 살펴보면, 2020년 말 기준 신재생에너지 비중은 전체 전력설비용량의 약 15.9%를 차지하고 있으며, 그 중 태양광 발전은 신재생에너지의 약 70.9%를 차지하고 있는 것으로 보고되고 있다(EPIS, 2021). 그러나 짧은 시간 급격하게 증가한 태양광 시설로 인해 환경·생태계 훼손 논란을 비롯하여 지역 주민의 민원도 증가하고 있어, 발전사업의 본래의 취지에 역행하

Corresponding author : Oh, Yun-Gyeong

Tel : +82-62-530-2029

E-mail : yungyeong.oh@gmail.com

는 사회적·환경적 문제를 일으키고 있다. 한국농촌경제 연구원의 연구에 따르면, 농촌 태양광 발전 시설 증대로 산림의 경사지와 토사유출로 인한 농경지 훼손 문제가 우려되고 있으며, 경관 훼손과 관련된 민원 발생 문제를 밝힌바 있다(KREI, 2018). 농촌태양광 이슈에 대한 설문 조사와 전문가 협의를 통해 주민 수용성과 경제성 및 정책방향에 관한 논의는 활발하게 이루어지고 있으나 공간 데이터와 빅데이터를 활용한 정량적 연구는 부족한 실정이다(Ha et al., 2022; Park et al., 2019; Sagong et al., 2018). 현재 농촌지역에 분포된 태양광 발전시설의 공간적 분포 현황에 관한 자료가 구축되어 있지 않아 문제점에 대한 정량적 분석이 어려운 상황이다. Chin(2021)의 연구에서는 태양광 발전소의 신청 및 허가 정보 중 일부 지역의 입지 적합성을 분석하였으나, 태양광 발전소의 허가 정보를 그대로 활용할 경우, 실제 계획대로 설치되어 있는 경우와 허가만 내고 진행되지 않은 경우가 혼재되어 있어 태양광 발전 시설의 입지 적합성 및 문제점을 파악하기에 한계가 있다.

본 연구에서는 최근 주목받고 있는 딥러닝을 활용하여 인터넷에서 제공하는 항공영상 이미지를 대상으로 농촌 지역의 태양광 발전소 설치 여부를 판단하고자 한다. 딥러닝을 활용하여 태양광 시설을 탐지한 연구는 주로 건물 위에 설치되어 있는 소규모 태양광 패널을 식별하거나(Golovko et al., 2018; Pérez et al., 2019), 손상된 태양광 패널을 식별하는 연구가 수행된 바 있으나(Han et al., 2020; Al-Mashhadani et al., 2021), 농촌지역의 토지이용 현황을 모니터링하기 위해 모양과 규모가 다른 태양광 시설을 식별하는 연구는 거의 이루어진 바 없다. 국내에서 토지피복분류에 딥러닝을 적용한 연구의 경우, 항공정사영상을 이용하여 농업 지역을 농지/산지로 구분하거나(Lee and Kim, 2019), EuroSAT 데이터를 이용하여 환경부 토지피복도의 대분류 수준의 토지피복분류를 시도한 바 있으나(Jo et al., 2019), 세분류에 해당하는 토지피복 연구는 부족한 실정이다.

딥러닝 기반의 객체 탐지 모델 분석에 사용한 영상의 특징, 라벨링 처리한 객체 이미지의 상태, 종류, 라벨링의 방식 등으로 인해 객체 탐지 결과물의 정확도가 다르게 나타날 수 있다(Kim and Hong, 2021). 본 연구에서는 인터넷 항공 영상 이미지에서 태양광 발전소를 효과적으로 검출하기 위한 적합한 이미지의 상태와 필요로 하는 데이터 세트의 양적 기준을 살펴보기 위해 이미지의 축척과 데이터 세트 수에 차이를 두어 10가지 유형의 객체 탐지 모델을 구축하고 그 성능을 비교·검토하였다. 이를 위해 공공데이터포털에서 제공하는 충청·호남 지역의 태양광 발전소 부지를 대상으로 인터넷 항공영상을 수집

하여 연구를 수행하였다.

## II. 연구 방법

본 연구에서는 농촌 지역의 태양광 발전소 허가지역을 중심으로 인터넷 항공영상을 수집하고, 수집한 영상을 학습데이터로 활용하여 태양광 패널 탐지 모델을 생성하였을 때, 생성한 태양광 패널 탐지 모델의 태양광 부지 탐지 성능을 비교 및 검토하고자 하였다. 연구의 흐름은 Figure 1과 같다.

첫 번째로 학습데이터 생성을 위해 카카오맵의 스카이블루를 통해 항공 영상 데이터를 수집하고, 축척과 데이터 수에 차이를 두어 유형별 정답영역(Ground-truth data)을 생성하였다. 두 번째로 유형별로 구축된 데이터 세트를 이용하여, YOLO v2 네트워크를 활용한 10가지 유형별 객체탐지모델을 학습하였다. 마지막으로 학습과정에서 활용하지 않은 새로운 이미지 300장을 7가지 경우로 구분하여 적용하고 각각의 탐지 성능을 비교하였다.

### 1. 자료구축

객체탐지 모델 학습에 사용할 학습데이터 구축을 위한 이미지 데이터는 공공데이터포털에서 제공하는 호남·충청지역의 태양광 발전사업 허가 현황자료 중 각 지역의 최신 자료를 이용하였다(Jeollanam-do, 2018; Jeollabuk-do, 2019; Chungcheongnam-do, 2021; Chuncheongbuk-do, 2021). 이미지 데이터는 인터넷 포털 사이트 Daum에서 제공하는 해상도 50cm 급의 초고해상도 항공영상을 이용하여 공공데이터포털에서 제공받은 태양광 발전소 허가지의 주소를 바탕으로 축척이 큰 이미지와 축척이 작은 이미지 2가지 유형으로 수집하였다. 축척이 큰 이미지는 축척의 크기가 약 1:5000 에서 1:2000 크기의 이미지로 태양광 패널이 크게 보이며 태양광 패널이 이미지의 대부분을 차지하는 이미지 데이터이다. 축척이 작은 이미지는 축척의 크기가 약 1:10000 이하의 이미지로 태양광 발전소가 비교적 작게 나타나 주변 환경까지 나타나는 이미지이다. 대축척 이미지(Zoom)와 소축척 이미지(Wide)는 각각 400장씩 수집하였다.

학습데이터 생성을 위한 데이터 전처리 작업을 위해 Image annotation 과정에서 원본 데이터에 객체탐지 모델이 검출해야 할 태양광 패널의 경계박스(bounding box)를 라벨링하는 작업을 진행하였다. 각 라벨이 객체탐지 대상인 태양광 패널을 최대한 포함하고, 태양광 패널 이외의 피복은 최소한 포함하도록 설정하였다. 라벨링 과정을 거

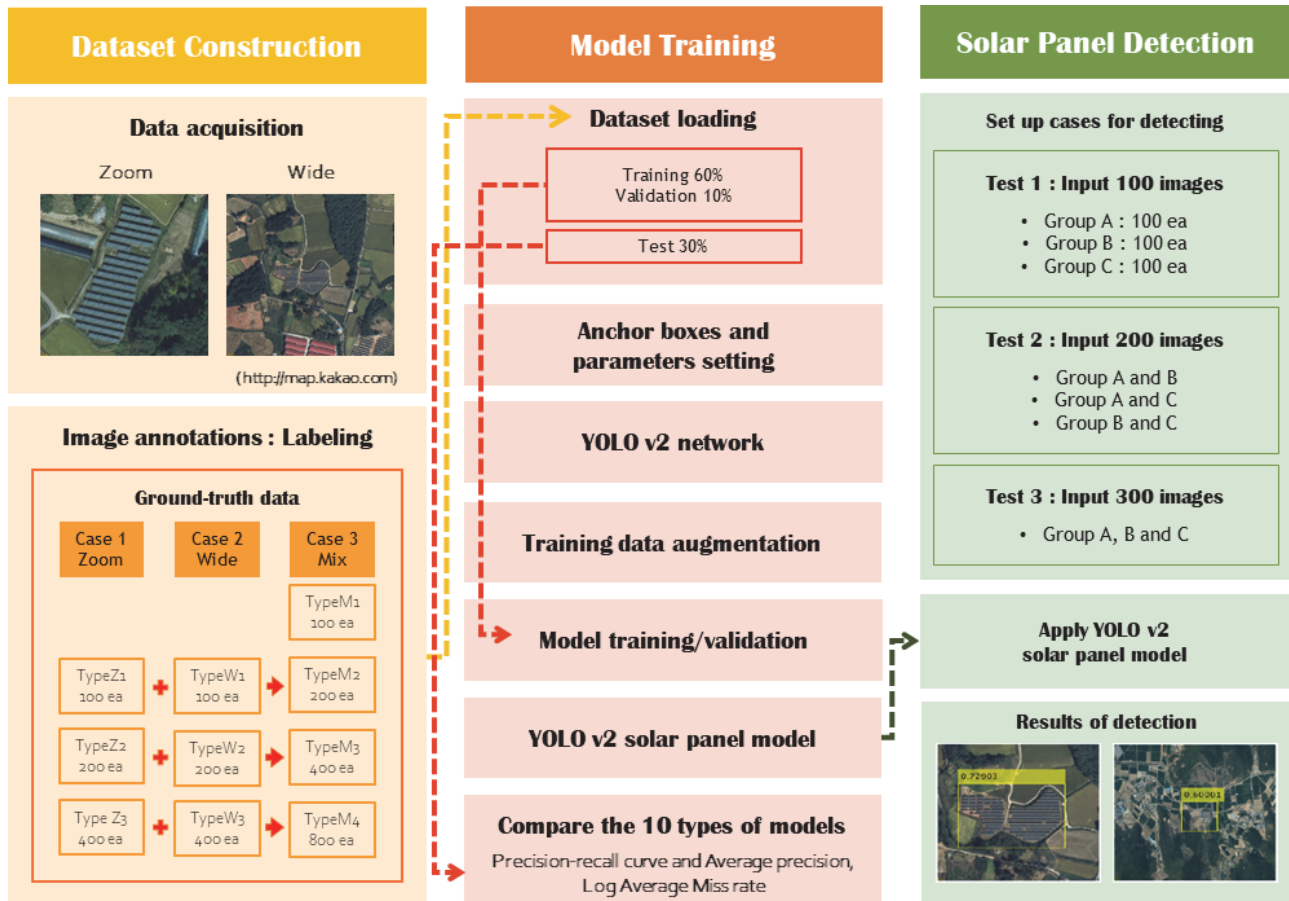


Figure 1. Solar panel detection modified YOLO v2 framework

친 이미지 데이터는 Ground-Truth 데이터가 되며, 객체탐지 모델의 학습 과정에서 학습데이터로 쓰인다.

본 연구에서는 객체탐지 모델의 학습데이터인 정답영역 데이터를 크게 Zoom, Wide, Mix 3가지 케이스로 분류하였다. Case 1은 Zoom Image로 구성하고, Case 2는 Wide Image, Case 3은 Case 1과 Case 2를 혼합한 데이터로 구성하였다. 각각의 정답영역 Case는 데이터 수에 따라 3~4가지로 다시 구분하여 총 10가지 유형의 정답영역 데이터를 구축하였다.

- Case 1: Zoom images (대축척 이미지, 약 1:5000~1:2000)
  - Type Z1: Ground-truth data 100장으로 이루어진 학습데이터
  - Type Z2: Ground-truth data 200장으로 이루어진 학습데이터
  - Type Z3: Ground-truth data 400장으로 이루어진 학습데이터

- Case 2: Wide images (소축척 이미지, 약 1:10000 이하)
  - Type W1: Ground-truth data 100장으로 이루어진 학습데이터
  - Type W2: Ground-truth data 200장으로 이루어진 학습데이터
  - Type W3: Ground-truth data 400장으로 이루어진 학습데이터
- Case 3: Mix images (대축척 50%와 소축척 50% 혼합하여 적용)
  - Type M1: Wide image ground-truth data 50장 + Zoom Image Ground-Truth Data 50장
  - Type M2: Wide Image Ground-Truth Data 100장 + Zoom Image Ground-Truth Data 100장
  - Type M3: Wide Image Ground-Truth Data 200장 + Zoom Image Ground-Truth Data 200장
  - Type M4: Wide Image Ground-Truth Data 400장 + Zoom Image Ground-Truth Data 400장

## 2. 모델 구축

### 가. YOLO(You Only Look Once) v2

YOLO는 단일 단계 방식의 객체탐지 알고리즘으로 객체탐지 분야에서 사용되는 모델 중 속도가 빨라 가장 일반적으로 사용되는 객체탐지 알고리즘이다(Mathworks<sup>®</sup>, 2022). YOLO는 CNN(Convolutional Neural Network)를 특징 추출 네트워크로 사용하며 네트워크의 마지막 레이어에 YOLO layer를 사용하여 객체를 탐지한다. 본 연구에서는 특징 추출 네트워크로 Res-Net50을 사용하였으며 마지막 추출 레이어는 YOLO output layer로 객체탐지 모델의 네트워크를 구성하였다. Figure 2와 같이 구성된 Res-Net50 모델은 ImageNet 데이터베이스의 영상에 대해 사전 훈련된 네트워크로 영상을 약 1000가지 사물 범주로 분류가 가능하며, YOLO의 특징 추출 네트워크로 많이 사용된다(Mathworks<sup>®</sup>, 2022). 이미지 입력 크기는 모델이 요구하는 가장 최소값인 [224 224 3]으로 설정하고, Mini batch 크기 16, Epoch 20으로 설정하여 객체탐지 모델을 생성하였다.

YOLO 네트워크는 원본 이미지를 일정한 크기의 그리드(grid)로 나누고, 객체탐지 모델이 예측한 경계상자와 Ground-Truth 데이터에서 라벨링 작업을 통해 사전에 정의한 경계상자를 비교하여 YOLO 네트워크의 경계상자의 신뢰도를 계산한다(Mathworks<sup>®</sup>, 2022). 이때 설정하는

경계박스의 개수를 앵커박스(Anchor Boxes)라고 한다(Figure 3). YOLO 네트워크의 앵커박스 개수는 3~25개로 다양하다. 앵커박스의 크기는 임의로 수정할 수 없기 때문에 적절한 크기로 설정하는 것이 중요하다(Akihiko Ishikawa, 2020). 설정한 앵커박스의 적합도는 학습데이터의 라벨 정보인 경계상자와 비교하여 판단할 수 있다. YOLO v2의 앵커박스와 정답영역상의 경계상자의 일치도를 IoU (Intersection over Union)이라고 하는데, 본 연구에서는 평균IoU(mean IoU)를 산정하여 유형별 태양광 탐지 모델에 설정된 앵커박스의 적합도를 판단하였다.

### 나. 정밀도-재현율 곡선(Precision-Recall Curve) 및 평균 정밀도(Average Precision)

객체탐지 모델의 성능은 정밀도-재현율 곡선과 평균 정밀도(AP)로 평가할 수 있다. 학습을 완료한 모델의 예측 결과를 학습데이터의 경계상자와 비교하였을 때 경계상자가 얼마나 일치하는지 나타내는 지표를 신뢰도(confidence)라고 하며, 신뢰도는 0과 1사이의 수치로 나타낸다. 정밀도-재현율 곡선은 신뢰도의 임계값마다 모델의 정밀도와 재현율을 시각화한 곡선이다. 정밀도는 식 (1), 재현율은 식 (2)와 같다(Planche and Andres, 2020). 본 연구에서는 태양광 패널 탐지 모델의 정밀도를 y축으로 하고 재현율을 x축에 표시하여 정밀도-재현율 곡선을 도시하여 유형별 모델 성능을 비교하였다.

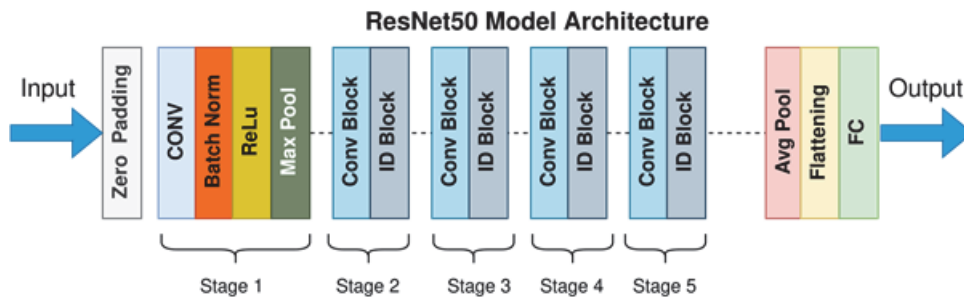


Figure 2. Architecture of Resnet50 model(Gorlapraveen123, 2021)




Figure 3. Anchor Boxes (Mathworks<sup>®</sup>, 2022)

$$precision = \frac{TP}{TP + FP} \quad (1)$$

$$recall = \frac{TP}{TP + FN} \quad (2)$$

- TP(True Positives): 예측 영역이 동일 클래스의 실제 상자와 일치하는 정도
- FP(False Positives): 예측 영역이 동일 클래스의 실제 상자와 일치하지 않는 정도
- FN(False Negatives): 실제 분류 값 중에 예측 영역 설정에 실패한 정도

**다. 로그 평균 실패율(Log Average Miss Rate)**

로그 평균 실패율은 모델이 객체를 탐지하지 못한 비율을 나타내는 지표이다. 본 연구에서는 정밀도-재현율 곡선과 함께 로그 평균 실패율을 유형별로 산정하여 객체탐지 모델의 성능을 비교하는 데 활용하였다. 실패율 산정방법은 식 (3)과 같다.

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

- TP(True Positives): 예측 영역이 동일 클래스의 실제 상자와 일치하는 정도
- FN(False Negatives): 실제 분류 값 중에 예측 영역 설정에 실패한 정도

**3. 태양광 발전소 탐지**

YOLO v2 네트워크를 활용하여 생성한 태양광 패널 탐지 모델의 적용성을 알아보기 위해 새로운 이미지 세트를 생성하였는데, 성능 평가 테스트를 위한 이미지 세트는 학습데이터의 이미지와 중복되지 않는 새로운 이미지로 구성하였다. 테스트 세트는 100장의 태양광 패널 이미지로 구성되는데, 보다 정확한 검증을 위해 대축척, 소축척이 혼합된 여러 그룹의 이미지 세트를 교차하여 3가지 유형의 Test Case를 준비하였다. 태양광 패널 탐지 모델의 적용 및 성능 평가를 위한 이미지 세트와 테스트는 총 7가지로 구성된다.

- Test Case 1: 100장으로 구성된 새로운 태양광 패널 이미지 데이터
  - Group A
  - Group B
  - Group C

- Test Case 2: 200장으로 구성된 새로운 태양광 패널 이미지 데이터
  - Group A and B
  - Group A and C
  - Group B and C
- Test Case 3: 300장으로 구성된 새로운 태양광 패널 이미지 데이터
  - Group A, B and C

**III. 연구 결과**

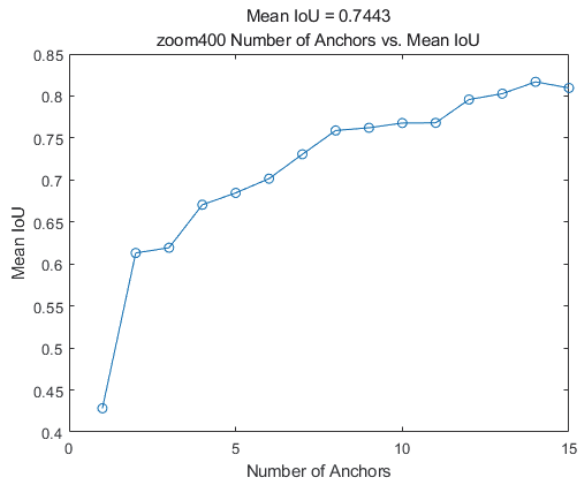
**1. 앵커박스의 설정 기준 및 적합도 검토**

Figure 4는 x축에 앵커 수(number of anchors), y축에 평균 IoU를 나타낸 그래프이다. 첫 번째에서는 소축척 이미지를 활용한 Z3유형의 경우이고, 두 번째는 소축척 이미지를 적용한 W3, 마지막으로 혼합유형인 M3유형의 결과이다. 적절한 앵커박스의 크기는 연구자의 경험에 의존하여 임의로 설정하기도 하지만 앵커박스 크기에 따른 평균IoU 값을 Figure 4와 같은 그래프를 분석하여 설정할 수도 있다. 본 연구에서는 그래프를 참조하여 앵커박스 크기를 7로 설정하였다.

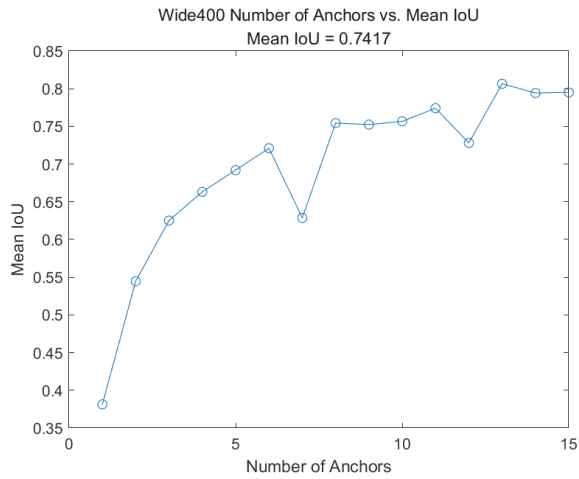
Table 1에서는 10가지 유형의 객체탐지 모델의 평균 IoU 값을 산정하여 앵커박스의 평균 신뢰도를 비교하였다. 정답영역과 앵커박스의 높은 일치도를 보인 유형은 각각 Z1, M1으로 0.79, 0.78의 값을 보였으며, 가장 낮은 값을 나타내는 모델은 M4로 0.73의 값을 보였다. 이를 통해 정답영역의 이미지 수가 적을수록 라벨링한 상자에 탐지 대상인 태양광 패널의 일치도가 높게 나타나고 다양한 이미지의 정답영역으로 학습할 경우, 앵커박스의 신

Table 1. The Results of Evaluation Object Detection Model

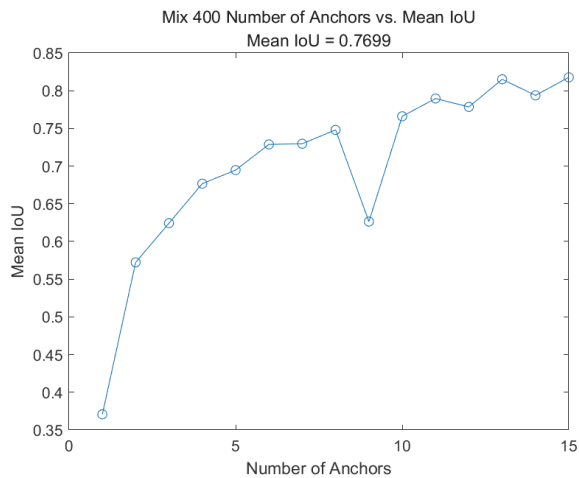
Case	Type	Mean IoU
1	Z1	0.79
	Z2	0.75
	Z3	0.74
2	W1	0.77
	W2	0.77
	W3	0.74
3	M1	0.78
	M2	0.77
	M3	0.77
	M4	0.73



(a) Type Z3 (400 zoomed images)



(b) Type W3 (400 wide images)



(c) Type M3 (400 mixed images: zoom and wide)

Figure 4. Mean IoU - number of anchor curve

되도는 다소 줄어드는 것을 알 수 있다. 그러나 모든 경우에 평균 IoU 값이 0.7 이상으로 나타났으며, 이를 통해 본 연구에서 설정한 10가지 유형의 정답영역에서 설정한 앵커박스의 크기는 적절하다고 판단할 수 있다.

## 2. 유형별 태양광 탐지 모델 비교

객체 탐지 모델의 성능을 비교하기 위해 정밀도-재현율 곡선과 평균 정밀도, 로그 평균 실패율을 산정한 결과를 Figure 5와 같이 나타내었다. 학습이미지의 축척에 따른 효과를 비교하기 위해 Z3, W3, M3의 평균 정밀도를 비교해보면 Z3가 0.56으로 상대적으로 높게 나타났고, W3와 M3 유형은 0.52값으로 동일한 값을 보였다. 평균실패율은 M3가 Z3와 W3에 비해 작은 경향을 보였다.

유형별 객체 탐지 성능을 직관적으로 살펴보기 위해 Figure 5와 같이 Z3, W3, M4 모델의 태양광 발전소 부지를 검출한 결과를 이미지로 출력하였다. 첫 번째 줄 (Test image 1)의 결과를 비교하면, Z3, W3, M4 모델 모두 태양광 패널 구역을 예측하는데 성공하였으나, W3 모델은 태양광 패널의 오른쪽 일부를 포함하지 않은 상태로 출력하고 있음을 볼 수 있다. Z3와 M4 모델은 태양광 패널을 모두 포함하는 상태로 부지를 검출하였음을 알 수 있다. 두 번째 줄 (Test image 2)의 결과를 비교하면, 두 곳의 태양광 패널 부지를 포함한 이미지에서 Z3 모델은 한 지역의 태양광 패널만 예측하는데 성공하였고, W3 모델은 태양광 패널 두 군데를 표시하는데 성공하였지만 영역 표시에 있어서 M4 모델에 비해 부정확한 결과를 나타내고 있음을 볼 수 있다.

## 3. 유형별 태양광 탐지 모델 객체 검출을 평가

10개 유형의 태양광 패널 탐지 모델에 새로운 고해상도 항공 영상 이미지를 적용하여 태양광 패널 유무 판단에 의한 검출 성능을 평가한 결과는 Table 2와 같이 나타났다.

새로운 이미지 300장에 적용한 3가지 경우의 테스트 결과, M4, W3, M3, Z3 모델의 태양광 패널 검출율이 Z1, W1, M1에 비해 상대적으로 높게 나타났음을 알 수 있다. 이는 학습데이터의 양이 많을수록 모델의 객체 탐지율이 높아지는 것을 의미한다. 데이터 수와 검출성능의 효율을 살펴보면, W3 89%, M3 84%, Z3 75%에 비해 M4의 검출 성능은 93%로 나와 W3 모델과 M4 모델의 학습 데이터양이 2배 정도 차이가 나는 것에 비해 모델 성능은 4% 차이를 보였음을 알 수 있다.

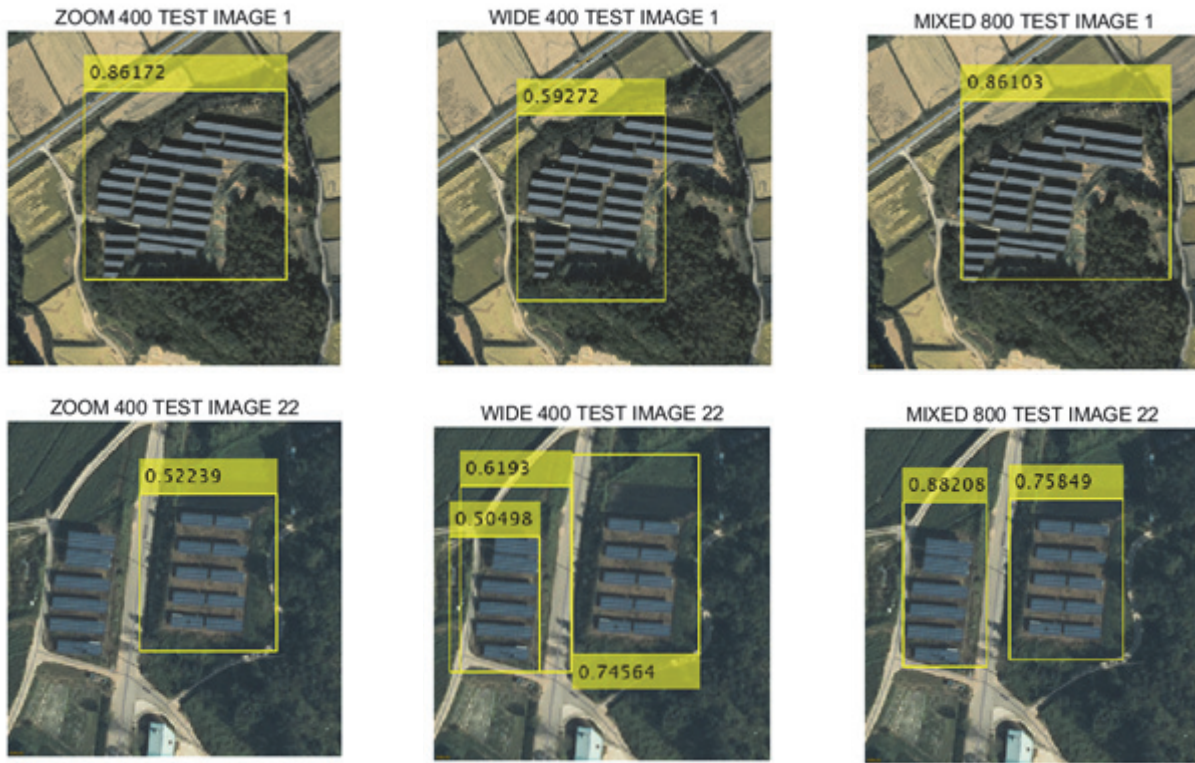


Figure 5. Output images of solar panel detection model

Table 2. The results of solar panel detection by 10 types

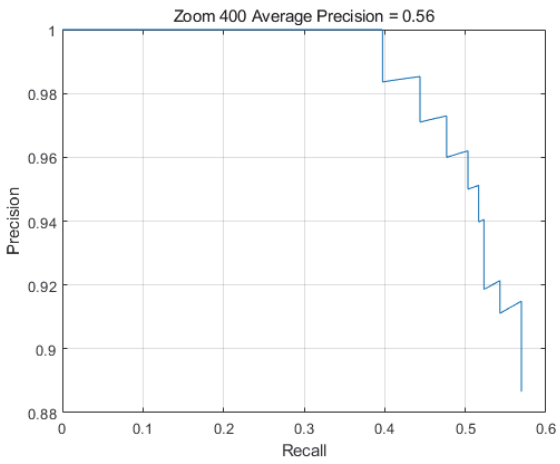
(Unit: %)

Test	Type	Zoomed images			Wide images			Mixed images			
		Z1	Z2	Z3	W1	W2	W3	M1	M2	M3	M4
Test 1		14	11	70	2	45	88	15	11	87	92
Test 2		9	8	71	2	43	90	11	48	83	93
Test 3		10	11	75	1	43	89	15	51	84	93

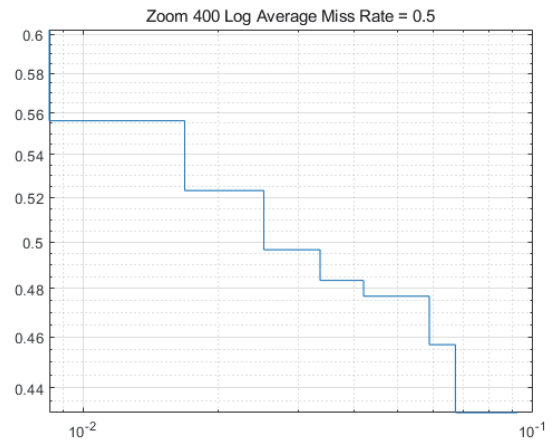
객체탐지모델의 정량적 성능 평가를 위해 정밀도-재현율 곡선을 통한 평균 정밀도 계산, 평균 객체 탐지 실패율을 산정하여 비교하였다. Table 3은 유형별 객체탐지모델의 평균정밀도와 평균 객체탐지 실패율 값을 산정한 결과로 모델 중 정확도와 검출율이 가장 낮은 유형은 M1으로 평균 정밀도와 객체탐지 실패율이 각각 0.14, 0.9로 나타났다. 그러나 M2에서 Z2와 W2에 비해 평균 정밀도는 2배 이상 높게 나오며, 실패율도 가장 낮게 나타났다. 학습 데이터양이 충분하지 않을 경우, 소축척 대축척 이미지를 혼합해서 사용하는 것이 객체 검출 성능이 높다는 것을 알 수 있다. 이에 비해, Z3, W3, M3의 평균 정밀도와 실패율은 유사한 값을 나타낸 것으로 보아 학습데이터양이 많아질수록 축척에 따른 모델의 성능 차이

가 줄어들 수 있다고 판단할 수 있다.


Type M4의 평균 정밀도는 0.67, 실패율은 0.4로 10개 모델 중 가장 높은 정확도와 검출율을 보여준다. M3 모델은 정답영역 400장으로 학습한 모델이고 M4 모델은 정답영역 800장으로 학습한 모델이다. 학습데이터 양은 2배차이지만 검출율을 비교하면 크게 차이가 나지 않는 것을 확인할 수 있다. 그러나 Table 3에서 두 모델의 결과를 비교하면 평균 정밀도와 실패율은 각각 0.52와 0.67, 0.6과 0.4로 유의미한 차이를 나타내는 것을 확인할 수 있다. 이는 두 모델의 태양광 패널 무무의 검출 성능은 유사하지만 탐지 영역의 정확도 면에서는 M4 모델이 상대적으로 우수하다는 것을 의미한다. 이를 통해 모델의 학습데이터 양적 수준도 중요하지만 보다 정확한 객체탐



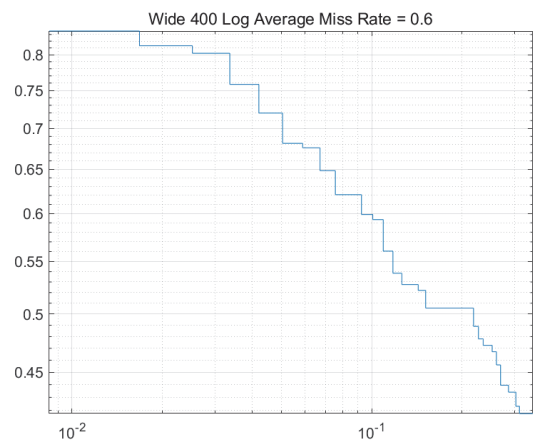
(a) Precision-recall curve of Z3



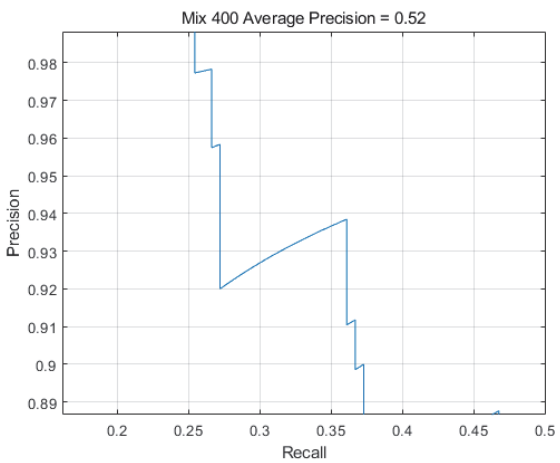
(b) Log average miss rate of Z3



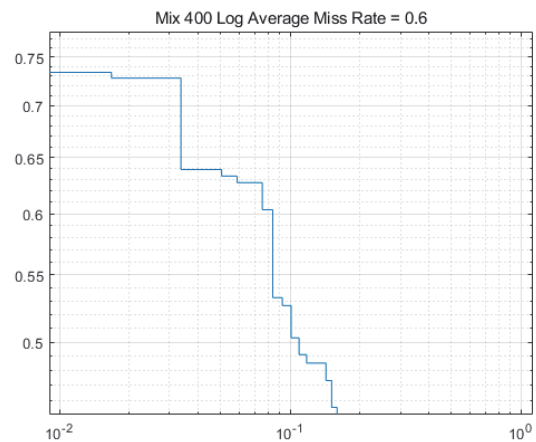
(c) Precision-recall curve of W3



(d) Log average miss rate of W3



(e) Precision-recall curve of M3



(f) Log average miss rate of M3

Figure 6. Precision-recall curve and log average miss rate by types



Table 3. Compare of Evaluation Object Detection Model

Case	Type	Average Precision	Miss Rate
1	Z1	0.33	0.7
	Z2	0.24	0.8
	Z3	0.56	0.5
2	W1	0.37	0.7
	W2	0.12	0.9
	W3	0.52	0.6
3	M1	0.14	0.9
	M2	0.42	0.6
	M3	0.52	0.6
	M4	0.67	0.4

지를 위해서는 다양한 유형의 데이터로 학습하는 것 또한 중요하다는 것을 알 수 있다.

본 연구는 태양광발전소의 면적이나 구역을 식별하기에 앞서 태양광발전소 유무를 확인하기 위한 연구로 분석에 적합한 이미지의 축척과 분량을 파악하는 것을 목표로 하여, 최종적으로 약 800장의 학습 데이터로 구축한 모델로 태양광 패널 유무를 93%로 검출하는 모델을 구축하였다. 이 결과는 최근 급증하고 있는 태양광 시설을 대상으로 AI 분석법을 적용하기에 적합한 최소한의 축척과 데이터의 분량을 살펴보기 위해 우선적으로 충청·호남지역에 국한된 태양광 시설자료를 활용하였기 때문에 자료 표본수의 한계로 인해 도출할 수 있는 최대 검출율이라고 할 수 있다. 이는 향후 학습데이터를 추가로 확보하여 적용한다면 보다 높은 검출율을 얻을 수 있을 것으로 판단된다.

#### IV. 요약 및 결론

본 연구는 YOLO v2 네트워크를 활용하여 인터넷에서 제공하는 항공영상에서 농촌지역의 태양광 발전소를 효과적으로 검출하기 위한 객체탐지모델을 구축하기 위해 수행하였다. 이를 위해 학습이미지의 축척과 데이터 세트 수에 차이를 두어 10가지 유형의 객체탐지모델을 구축하고 그 성능을 비교·검토하였다.

충청·호남 지역의 태양광 발전소 부지 현황 데이터를 기반으로 태양광 발전 패널이 있는 항공 영상 이미지를 수집하였다. 라벨링 작업을 통해 약 800장의 정답영역 이미지를 바탕으로 10가지 유형별 학습데이터를 생성하고 10개 유형의 객체탐지 모델 학습을 진행하였다. 객체 탐

지 모델은 Res-Net50을 기반으로 한 YOLO v2 네트워크를 사용하였다.

생성한 객체 탐지 모델의 태양광 패널 검출 테스트 결과, W3 모델은 89%, M3은 84%, Z3은 75%의 검출율을 보여 400장의 정답영역을 활용할 경우에는 W3 모델이 가장 높은 검출율을 보였다. 이는 800장의 학습데이터를 적용한 M4의 검출율 93%와 비교하였을 때, 데이터양이 2배 차이나는 것에 비해, 태양광 패널의 유무 판단 성능의 향상도는 높지 않았음을 알 수 있다. 그러나 평균 정밀도와 실패율을 고려하면, 가장 많은 학습데이터를 적용한 M4 모델에서 태양광 패널의 유무판단 뿐만 아니라 예측 영역의 일치도가 가장 높은 것을 알 수 있다.

축척별 학습 이미지의 적용 결과를 비교하면, 대축척과 소축척을 혼합한 유형(M3, M4)의 실패율이 다른 두 유형(Z3, W3)의 모델보다 작은 값을 보여 예측 성공률이 높게 나타났다. 이는 보다 정확한 객체 탐지 모델 생성을 위해서는 소축척, 대축척을 혼합하여 다양한 유형의 학습 데이터를 사용하는 것이 고성능 모델 구축에 유리하다는 것을 나타낸다.

향후 추가적인 학습데이터 확보와 모델 개선 연구를 진행하여 태양광발전의 규모(면적, 구역)와 같은 효용 있는 정보를 추출할 수 있는 객체 탐지 모델을 구축함으로써 농촌 지역의 토지이용 현황 모니터링과 소규모 농업 시설 탐지를 효율적으로 수행하는데 활용할 수 있을 것으로 판단된다.

2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단-중견연구사업의 지원을 받아 수행된 연구임 (NRF-2020R1A2C1010502).

#### References

1. Akihiko Ishikawa, 2020, Deep Learning Textbook to Learn using Python, Hanbit media. (in Korean)
2. Al-Mashhadani, R., Alkaws, G., Baashar, Y., Ahmed Alkahtani, A., Hani Nordin, F., Hashim, W. 2021, Deep learning methods for solar fault detection and classification: A review. Information Sciences Letters, 10(2): 13.
3. Chin K., 2021, Problem Analysis and Improvement Measures of Rural Area Development for PV Power

- Plant Project, KIEAE Journal, 21(5): 83-90. (in Korean)
4. Chuncheongbuk-do, 2021, Solar Power Project Permit Status, <https://www.data.go.kr/> [accessed: March 5, 2022]
  5. Chungcheongnam-do, 2021, Solar Power Project Permit Status, <https://www.data.go.kr/> [accessed: March 5, 2022]
  6. Electric Power Statistics Information System (EPSIS), 2021, Generation capacity by fuel, <http://epsis.kpx.or.kr> (in Korean)
  7. Golovko, V., Kroschanka, A., Bezobrazov, S., Sachenko, A., Komar, M., & Novosad, O., 2018, Development of solar panels detector. In 2018 International Scientific- Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T) (pp. 761-764). IEEE.
  8. Gorlapraveen123, 2021, <https://commons.wikimedia.org/wiki/File:ResNet50.png> [accessed: May 10, 2022]
  9. Ha, J., Lee, S., Kim, D., 2022, Social media posts and user comment analysis on rural solar issues. Journal of The Korean Data Analysis Society (JKDAS), 24(2): 683-699.
  10. Han, S. H., Rahim, T., Park J. H., Shi, S. Y., 2020, Damaged solar panel detection drone system using deep learning and thermal imaging camera, Conference proceeding of The Korean Institute of Communications and Information Sciences. (in Korean)
  11. Jeollabuk-do, 2019, Solar Power Project Permit Status, <https://www.data.go.kr/> [accessed: March 5, 2022]
  12. Jeollanam-do, 2018, Solar Power Project Permit Status, <https://www.data.go.kr/> [accessed: April 15, 2020]
  13. Jo, W., Lim, Y., Park, K.-H., 2019, Deep learning based land cover classification using convolutional neural network:a case study of Korea, Journal of the Korean geographical society, 54(1): 1-16. (in Korean)
  14. Kakao-skyview, <http://map.kakao.com> [accessed: March 7 ~March 21, 2022]
  15. Kim, J. S. and Hong, I. Y., 2021, Analysis of Building Object Detection Based on the YOLO Neural Network Using UAV Images, Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography, 39(6): 381-392. (in Korean)
  16. Korea Rural Economic Institute (KREI), 2018, Research on problems and improvement plans for the spread of rural solar power, KREI Report. (in Korean)
  17. Lee, S. and Kim, J., 2019, Land Cover Classification using Sematic Image Segmentation with Deep Learning, Korean Journal of Remote Sensing, 35(2): 279-288. (in Korean)
  18. Mathworks©, <http://kr.mathworks.com> [accessed: April 7, 2022]
  19. Park, M.-L., Shin, S.-W., Oh, Si.-D., Kang, S.-H., 2019, Survey and Analysis of Resident Acceptability for Photovoltaic System in Rural Region- Focusing on Economic Factors, Conference proceeding of the Korean solar energy society, 198.
  20. Pérez, R. M., Arias, J. S., Méndez-Porrás, A. 2019, Solar panels recognition based on machine learning. In 2019 IV Jornadas Costarricenses de Investigación en Computación e Informática (JoCICI) 1-5. IEEE.
  21. Planche, B. and Andres, E., 2020, Practice! Deep Learning Computer Vision with TensorFlow 2, Wikibooks. (in Korean)
  22. SaGong, J. H., Jung, O. S., Kwon, O. S., 2018, Current status of solar power generation facilities in Chungnam and ecological and landscape response strategies, Chungnam Report, 295, 1-13. (in Korean).
- 
- Received 17 May 2022
  - First Revised 23 May 2022
  - Finally Revised 30 May 2022
  - Accepted 30 May 2022