

# 세그멘테이션과 객체 감지 모델의 콘크리트 균열 검출 성능 비교

김정수

한국건설기술연구원 구조연구본부

## Comparison with Performances of Segmentation and Object Detection Models for Detecting Concrete Crack

Jeongsoo Kim

Department of Structural Engineering Research, Korea Institute of Civil Engineering and Building Technology

**요약** 콘크리트 시설물의 효율적 유지관리 지원을 위해 이미지 기반 자동 균열 인식 기술 개발이 이뤄져 왔으며, 딥러닝 기법을 균열 인식 문제에 적용하여 범용적인 환경에서의 균열 검출 성능을 높이하고자 하는 연구가 늘어나고 있다. 본 연구는 서로 다른 유형의 딥러닝 모델을 균열 검출에 적용해 모델 간 성능을 비교한다. 동일한 조건에서의 객체 감지 및 개체형 세그멘테이션 모델의 성능 비교를 위해 YOLOv7을 사용하였다. 각 유형별 모델 학습 및 성능평가를 위해 약 4천 개의 공개 균열 이미지 데이터를 활용하였으며, 이를 활용해 각 유형별 딥러닝 모델의 학습, 검증, 시험을 수행하고 성능을 조사하였다. 학습을 통해 얻어진 객체 감지 및 개체 세그멘테이션 모델은 평균 정밀도 0.6 내외 (임계값 0.5~0.95 기준) 성능을 보였으며, 객체 감지 모델의 성능 지표는 세그멘테이션 모델의 성능 지표보다 작고, 수렴 속도 또한 느렸다. 그러나 두 모델 간 성능지표와 수렴속도 차이가 작고 학습이 진행됨에 따라 객체 감지 모델의 성능은 세그멘테이션 모델 성능에 거의 근사하였다. 검출 이미지를 시각적으로 분석한 결과, 두 모델 모두 미세균열 및 어두운 배경 조건의 균열에 대해 검출이 어려웠으며, 균열 검출에 대해 두 모델 간 유의미한 성능 우위는 확인할 수 없었다.

**Abstract** Image-based automated crack detection techniques have been developed to support the efficient maintenance of concrete structures, and studies in which deep learning techniques into crack detection are applied to enhance the detection performances under general conditions have increased. This study compared the performances of crack detection between different types of deep learning models. To conduct a fair comparison of each model, open crack image data of approximately 4,000 were used to train, validate, and test the object detection and instance segmentation models of YOLOv7 and then investigate each model performance. After training both object detection and instance segmentation models, the models have a mean average precision (mAP) of approximately 0.6 (at 0.5-0.95 threshold); the object detection model has a slightly smaller mAP than the segmentation and slower convergence rates than the segmentation. On the other hand, the differences between both models for metric and convergence rate are small, and the metric of the object detection model almost approaches that of the segmentation as training epochs increase. In addition, analyzing crack detection images visually, the models found were hard to detect micro-cracks or cracks on a dark background, and the meaningful superiority of detection performance between each model was not confirmed.

**Keywords** : Concrete Crack Detection, Deep Learning, Instance Segmentation, Object Detection, YOLOv7, Automation

본 논문은 2023년도 정부(과학기술정보통신부, 국토교통부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임.  
(No.2020-0-00061, 디지털트윈 기반의 지하공동구 화재·재난 지원 통합플랫폼 기술개발)

\*Corresponding Author : Jeongsoo Kim(Korea Institute of Civil Engineering and Building Technology)  
email: jeongsookim@kict.re.kr

Received February 23, 2023

Revised April 6, 2023

Accepted April 7, 2023

Published April 30, 2023

## 1. 서론

시설물의 노후화가 진행됨에 따라 지속적인 유지관리를 통해 구조물의 성능 저하를 조기에 감지하고, 손상을 적시에 보강함으로써 시설물의 기대수명을 늘리려는 노력이 국내외로 지속되고 있다[1]. 사회기반시설의 상당수는 콘크리트로 지어졌으며 시설물의 안전 및 고유 기능 등을 유지하기 위해 주기적으로 점검된다. 이때 관리자는 육안으로 외관상 균열 발생 여부와 균열 경향을 1차적으로 확인함으로써 콘크리트 구조물의 손상을 판단하게 된다.

외관상 유지관리자가 판단할 수 있는 콘크리트 구조물의 손상은 균열, 박리, 박락 등으로[2], 관리자 및 전문가의 경험적 판단을 통해 균열 확대 등 심각성을 판단하고 이에 대한 유지보수를 수행하게 된다. 그러나 터널, 지하 공동구, 교량 등 사회 기반 시설물은 단위 시설물의 관리 구간이 길고 패턴이 반복적이어서 인력에 의한 관찰로는 신속하면서도 면밀하게 균열 상태를 점검하기에 한계가 있으며, 관리인력의 경력, 신체적·환경적 상태 등에 따라 균열 판단에 대해 일관된 결과를 얻기 어렵다[2-4]. 이러한 이유로 이미지 데이터를 활용해 콘크리트 균열을 감지하기 위한 다양한 기술개발 노력이 지속되어 왔다.

균열 감지를 위해 초기에 많이 사용된 기법은 영상처리(Image processing) 방법으로, 사전 정의된 가울기 필터 및 이진 분류기를 활용하거나 Morphology, Fuzzy 기법 등을 활용해 이미지에서 균열을 감지하였으나[5], 이미지 촬영 환경 및 표면상태 등에 따라 상이한 검출 성능을 갖는 한계가 있었다[3,5]. 그러나 최근 균열 감지 성능을 개선하기 위해 깊은 합성곱 신경망(Deep Convolutional Neural Network, Deep CNN) 모델을 적용하려는 연구가 활발히 진행되고 있다.

이미지 데이터를 이용한 CNN모델은 분류(classification), 관계형 및 개체형 세그멘테이션(semantic and instance segmentation) 추출, 객체 감지(object detection) 모델의 기본 구조로 활용되고 있으며, 균열 감지 목적의 다양한 딥러닝 모델 및 관련 방법론이 제시되고 있다[2-19].

먼저 분류 모델을 이용한 콘크리트 균열 감지 연구는 모델 및 데이터의 경량화에 초점이 맞춰져 있으며 [4,6,7], 픽셀 단위로 평가된 균열 확률 정보를 시각화함으로써 [4,7], 분류 모델이 균열 유무 판단뿐만 아니라 시각적 정보까지 제공할 수 있음을 보였다.

딥러닝 콘크리트 균열 검출에 가장 활발히 적용되고 있는 세그멘테이션 모델의 경우, 균열 감지를 위한 신경

망 구조 제안[8-10] 및 의료 등 타 분야에 적용된 신경망 [11] 모델을 수정[12,13]하는 등의 모델 구조 개선에 대한 연구가 이뤄진 바 있다. 한편 세그멘테이션 모델은 균열의 복잡한 형상 특징을 학습할 수 있도록 다량의 이미지 수집 및 라벨링이 요구되나 양질의 균열 학습 데이터 확보에 어려움이 있다. 이를 극복하기 위해 벡터 기반 특성왜곡을 통한 데이터 증강기법[5], 균열 및 비균열 데이터셋 구성 방법[14]이 제안되었으며, 세그멘테이션 신경망 모델에 적대적 학습(adversarial network) 기법[2] 및 비지도 학습방법[15]을 적용해 균열 검출 성능을 높이고자 하였으나 극적인 개선 효과까지 확인되지 않았다.

최근 균열 검출을 위한 객체 감지 모델을 활용 연구도 증가하고 있다[16-20]. 객체 감지모델은 균열의 자세한 형상 정보까지 제공하지는 않으나, 균열 유무 및 위치 정보를 제공할 수 있고, 세그멘테이션 모델 대비 학습 데이터셋 구축 노력이 크게 감소하는 장점이 있다. 또한 객체 감지 모델로 유명한 YOLO 계열 모델 등은 안정적으로 실시간 감지가 가능해 현장 적용에 유리하다. 세그멘테이션 모델을 활용한 연구와 마찬가지로 객체 감지모델 활용 연구도 균열 이미지 데이터 부족을 해결하고자 적대적 신경망을 결합하거나[16], 현장에 적용해 실시간 감지 성능을 확인한 연구[17] 및 모델 성능 개선을 시도한 연구[28]들이 수행되기도 하였다. 또한 균열 감지 후 균열의 정량적 정보 추출을 위해 이미지 처리기법을 적용하거나[19] 역으로 이미지 처리기법 적용 후 객체감지 모델을 적용해 균열을 검출 성능 개선을 시도하였다[20].

위와 같이 콘크리트 균열 검출을 위해 다양한 딥러닝 모델 및 그 활용 방안이 제안되었고, 각 모델은 동종 모델 간 성능 비교를 통해 우수성을 입증하고자하는 것이 일반적이다. 반면, 균열 검출을 위한 이종 모델 간 객관적인 성능 비교 및 적용성 분석 연구는 아직 초기 단계이다. 김병현 등(2019)은 ResNet을 백본망으로 갖는 분류, 객체 탐지, 세그멘테이션 모델을 콘크리트 균열 문제에 적용하고 테스트 데이터셋에 대한 모델 유형별 재현율(Recall)과 정밀도(Precision) 비교를 하였으나[21], 모델 학습 및 시험 데이터 규모가 작은 한계가 있고, 사용된 딥러닝 모델이 실시간성을 고려해 개발된 것은 아니므로 현장 적용에는 어려움이 있다고 판단된다.

본 연구는 콘크리트 균열 검출을 위해 동일한 데이터셋을 대상으로 객체 감지와 개체형 세그멘테이션 딥러닝 모델을 학습하고 그 성능을 비교 검토한다. 균열 검출 성능과 건설 현장에서의 실시간 적용성을 고려해 YOLOv7의 객체 감지[22] 및 세그멘테이션 모델[23]을 활용하였

으며, 약 4,000개의 공개 균열 이미지 데이터셋을 직접 또는 변환하여 모델 학습에 적용하였다. 학습 이미지에 대한 각 모델 유형별 균열 검출 최적화를 확인하고, 시험 이미지에 대해 최종적인 성능을 비교 평가하였다.

## 2. 균열 검출 딥러닝 모델

### 2.1 딥러닝 신경망 구조: YOLO

YOLO(You Only Look Once)는 대표적인 객체 감지 모델로, 출력층에서 객체에 대한 분류 및 경계상자 위치 찾기를 동시에 수행함으로써 빠른 처리 속도를 확보할 수 있는 장점이 있다(Fig. 1). YOLOv2부터는 FCNN(Fully Convolutional Neural Network)를 활용해 이미지 크기 및 객체의 이미지 내 위치 정보를 보존함으로써 속도뿐만 아니라 예측 성능까지 크게 개선하였다. 각 버전별 주요 특징 변화를 정리하여 Table 1에 나타내었다.




Fig. 1. Schematic unified detection concept of YOLO[24]

Table 1. Architectures of YOLO models[22,25-27]

| Model  | Neural Network | Backbone            | Neck       |
|--------|----------------|---------------------|------------|
| YOLOv1 | CONV+FC        | GoogleNet24         | -          |
| YOLOv2 | FCNN           | DarkNet19           | -          |
| YOLOv3 | FCNN           | DarkNet53           | FPN        |
| YOLOv4 | FCNN           | CSPDarkNet53        | SPP, PANet |
| YOLOv5 | FCNN           | CSPDarkNet53        | PANet      |
| YOLOv6 | FCNN           | RepVGG, CSPRepStack | RepPAN     |
| YOLOv7 | FCNN           | E-ELAN              | PANet      |

### 2.2 YOLOv7: 객체 감지 모델

본 논문은 객체 감지 및 개체형 세그멘테이션 모델을 균열 검출에 적용하기 위해 2022년 7월에 발표된 YOLOv7[22]을 이용하였다. YOLOv7에서 달라진 점은 이전 모델과 다르게 ImageNet의 사전 학습 백본망 사용 대신 MS-COCO 데이터셋만을 학습한 E-ELAN 백본망을 사용하면서 속도와 정확도를 개선하도록 설계되었다는 점이다. 또한 기존 모델과 달리 효과적인 매개변수 계산을 위한 Compound model scaling이라는 기법을 도입하였으며, 실제적인 검출 작업이 수행되는 Head 층을 밀집된 층과 조약한 층 (Coarse for auxiliary and fine for lead loss) 2개로 구성함으로써 추론 성능을 개선하였다(Fig. 2a).

### 2.3 YOLOv7: 개체형 세그멘테이션 모델

YOLOv7은 기본적으로 객체 감지 모델이나(Fig. 2b) 객체 감지 결과에 BlendMask기법을 추가함으로써 Fig. 2c에 나타난 바와 같이 개체형 세그멘테이션 모델도 제공한다[23]. 해당 기법을 사용함으로써 세그멘테이션 모델에 많이 사용되는 Mask R-CNN보다 학습 및 추론 단계에서 소요 시간을 20% 절감할 수 있는 것으로 알려져 있다[28].





Fig. 2. YOLOv7-mask model for instance segmentation[27,29]

(a) YOLOv7-mask architecture (b) Object detection by YOLOv7 (c) Instance segmentation by YOLOv7

### 3. 실험계획

#### 3.1 실험 개요 및 환경조건

개체형 세그멘테이션 및 객체 감지 모델의 성능을 비교하기 위해 각 모델에 대해 4,000여장의 동일한 이미지 데이터셋에 대해 학습, 검증, 시험을 수행하였다. Google Colab을 활용해 YOLOv7 구동을 위한 환경을 구축해 학습을 진행하였으며, 이 때 사용되는 CPU와 GPU 사양은 각각 Intel (R) Xeon (R) CPU@2.20GHz, NVIDIA A100-SXM4-40GB이다.

YOLO는 딥러닝 모델의 GPU 사양 등 구동 환경 및 목적을 고려해 기본 신경망 구조뿐만 아니라 간소화된 및 확장된 신경망 구조를 함께 제공한다. YOLOv7 또한 기본 신경망을 변형한 변이모델을 제공하며, 본 논문은 동일한 기본 신경망 구조를 갖도록 YOLOv7이 제공하는 사전학습모델 가운데 yolov7x(객체 감지)와 yolov7x-seg(개체형 세그멘테이션)를 각각 사용하였다. yolov7x는 기본 신경망 구조인 yolov7에 비해 백본망의 합성곱의 크기가 더 커서 모델 학습 시 인접 픽셀로부터 이미지 특성을 보다 광역적으로 함축할 수 있다. 또한 yolov7x는 신경망 구조도 좀 더 깊게 설계되어 기본 신경망보다 우수한 성능을 가진다.

신경망 학습 시 배치 크기는 GPU 사양을 고려해 8~32로 설정해 모델의 학습 속도 및 수렴성을 확인하였고, 학습률, 모멘텀 등의 하이퍼파라미터는 YOLOv7의 기본값을 사용하였다. 객체 감지 모델과 세그멘테이션 모델의 정확도 평가지표로서 P-R선도 및 IoU(Intersection over Union)별 AP(Average Precision)값을 사용하였다. 세그멘테이션 모델의 경우 경계상자와 세그멘테이션에 대한 손실함수 값을 모두 제공하는데, 객체 감지 모델과의 비교를 위해 경계상자에 대한 손실함수 값만 비교 평가하였다.

#### 3.2 모델 유형별 균열 데이터셋 구축 및 분석

##### 3.2.1 개체형 세그멘테이션 모델

균열 검출을 위한 개체형 세그멘테이션 모델 학습은 Roboflow에 공개된 균열 데이터셋을 이용하였다[30]. 해당 데이터셋은 균열에 대한 훈련, 검증, 시험 이미지를 각각 3717, 200, 112개를 제공한다. 본 논문에서도 동일한 데이터셋 구성으로 훈련, 검증, 시험을 수행하였다. 균열 이미지는 모두 콘크리트 표면에 근접하여 촬영되어 있으며, 훈련 데이터는 회전, 색조 변경 등의 이미지 증

강 (augmentation) 기법을 통해 생성된 이미지를 포함한다. 데이터셋에서 서로 연결되지 않은 균열은 개별 개체로 구분되도록 라벨링 되었으며, 이 때 표면 잔균열, 박락, 패임 등은 라벨링 대상에서 제외되었다.

##### 3.2.2 객체 감지 모델

개체형 세그멘테이션 모델에 적용한 균열 데이터 이미지를 객체 분류 모델의 학습에도 동일하게 적용하였다. 다만 객체 감지 기반의 균열 검출 모델을 학습하기 위해 별도의 데이터 라벨링에 많은 노력이 요구되므로, 아래의 과정을 수행하였다.

먼저 YOLOv7의 개체형 세그멘테이션과 객체 감지 모델의 라벨링 데이터구성을 분석하였다. 개체형 세그멘테이션 모델의 데이터 라벨링 정보는 이미지 내 균열별 위치 및 크기 정보를 분류항목(class)과 폐합된 다각형 좌표 형태로 텍스트 파일에 저장한다(Fig. 3a). 단, 좌표 데이터는 가로, 세로 모두 0~1로 정규화된 값을 사용한다. 반면 객체 감지 모델의 라벨링 데이터는 Fig. 3b와 같이 객체별로 분류항목과 경계 상자(bounding box)의 중심점 좌표 및 가로, 세로 길이로 구성되며, 세그멘테이션 모델과 마찬가지로 정규화된 좌표를 사용한다.




Fig. 3. Annotation formats of YOLOv7 models  
(a) Instance segmentation (b) Object detection

YOLOv7의 객체 감지 라벨링 데이터 형태에 맞게 경계 상자 정보를 개체형 세그멘테이션 라벨링 데이터로부터 추출하기 위해 각 세그멘테이션 라벨링 객체별 다각형 좌표의 최댓값을 추출하여 Eq. (1)-(4)와 같이 경계상자의 중심점 좌표, 가로 및 세로 길이를 산출한다.

$$x_c = (x_{\max} + x_{\min})/2 \quad (1)$$

$$y_c = (y_{\max} + y_{\min})/2 \quad (2)$$



$$dx = (x_{\max} - x_{\min})/2 \quad (3)$$

$$dy = (y_{\max} - y_{\min})/2 \quad (4)$$

Where,  $x_c$  denotes  $x$  coordinate of the bounding box center,  $y_c$  denotes  $y$  coordinate of the bounding box center,  $dx$  denotes the width of the bounding box in the  $x$  direction, and  $dy$  denotes the height of the bounding box in the  $y$  direction,  $x_{\max}$  denotes the maximum coordinate of an instance segmentation in the  $x$  direction,  $x_{\min}$  denotes the minimum coordinate of an instance segmentation in the  $x$  direction,  $y_{\max}$  denotes the maximum coordinate of an instance segmentation in the  $y$  direction, and  $y_{\min}$  denotes the minimum coordinate of an instance segmentation in the  $y$  direction.

산출된 객체별 객체 감지 라벨링 데이터는 분류항목 정보와 함께 이미지별로 구분하여 텍스트 파일로 저장된다.

Eq. (1)-(4)의 절차를 파일 및 개체별로 수행함으로써 객체 감지 데이터셋 라벨링 데이터가 적절히 생성되는지 확인하기 위해, 훈련 데이터로부터 임의로 6개 데이터를 추출해 Matplotlib, OpenCV를 활용해 시각적으로 검토하였다. Fig. 4와 같이 세그멘테이션 라벨링 데이터가 객체 감지 라벨링으로 적절히 변환되었음을 확인할 수 있다. 개발된 자동 변환 프로그램을 통해 세그멘테이션

모델에 사용한 이미지와 동일한 객체 감지 모델의 데이터셋을 구축하고 모델의 학습, 검증, 시험에 활용하였다.

## 4. 실험결과 및 분석

### 4.1 모델 학습 결과

GPU 메모리 용량을 고려해 배치 크기를 달리하여 학습을 수행하였고, 본 논문은 학습 성능이 가장 높게 나온 배치 크기 32 적용 모델에 대한 학습 결과를 분석하였다.

Fig. 5는 3,717개 균열 데이터를 이용해 학습한 각 모델의 성능 지표 변화를 보여준다. 두 모델 모두 전이 학습모델에 균열 이미지를 학습하였기 때문에 초기 epoch의 손실함수는 낮은 값에서 시작해 빠르게 수렴하였으며, 세그멘테이션 모델의 수렴속도가 객체 감지 모델에 비해 빠르게 진행되는 것을 확인할 수 있다(Fig. 5a). 검증 데이터(200개)에 대한 결과 또한 동일한 경향을 보여 주며(Fig. 5a), 이는 세그멘테이션 모델 데이터에 비해 객체 감지 모델이 학습 데이터 특성상 경계 상자 내에 많은 노이즈가 포함되기 때문에 상대적으로 느린 수렴 속도를 가지는 것으로 추정된다.

한편 학습 진행에 따른 정밀도와 재현율 또한 세그멘테이션 모델에서 초기 변동이 상대적으로 심하게 확인되지만 정밀도와 재현율 모두 10 epochs 전후로 수렴 값에 근접하였다(Fig. 5b). 특히 초기 학습구간 정밀도와 재현율이 각각 0.8과 0.7 내외로 안정적으로 수렴되고




Fig. 4. Automated annotation of crack image samples for object detection from instance segmentation annotation data




Fig. 5. Training of crack detection models: object detection and segmentation models

(a) Box loss curves: Train(upper) and validation data(lower) (b) Precision and recall curves: Precision(upper) and recall(lower)  
(c) Mean average precision curves: Threshold 0.5(upper) and 0.5:0.95(lower)

있어, 적은 학습에도 객체 감지 모델 대비 검출성능이 높은 모델을 기대할 수 있다.

학습모델의 평균 정밀도(mAP) 변화를 검토하였다. 해당 값은 P-R선도로부터 도출되므로 모델의 정밀도와 재현율을 종합적으로 평가한 지표로 고려할 수 있다. 참고로 단일 분류항목에 대한 객체 검출을 수행하므로 실질적으로는 AP이며, P-R선도는 여러 신뢰도 임계값을 적용해 얻은 정밀도와 재현율 값을 도식화한 것이다. Fig. 5c는 epoch마다 학습 이후에 검증 데이터를 대상으로 IoU 경계값(threshold)에 따른 AP 변화를 나타내며, IoU 경계값 0.5를 적용했을 때 산출된 AP와 IoU 경계값을 0.5~0.95 구간 AP를 평균한 AP를 각각 나타낸다. AP 기준으로 세그멘테이션 모델 성능이 전반적으로 더 우수한 것으로 평가되나 epoch가 증가함에 따라 객체 감지 모델의 성능 지표도 세그멘테이션 모델의 성능 지표에 근사하므로 유사한 검출성능을 가질 수 있을 것으로 판단된다.

#### 4.2 최적 모델의 시험 데이터셋 적용

추가로 최고 성능을 보인 학습모델에 대해 112개 시험데이터(3.2.1절)를 대상으로 모델별 균열 검출 결과를 비교하였다. Fig. 6은 시험데이터를 대상으로 도출한 P-R 선도와 F1 나타낸 것으로, 비교를 위해 검증 데이터의 결과도 함께 나타내었으며, 주요 성능 지표를 정리

해 Table 2에 나타내었다.

Fig. 6에서 확인할 수 있듯이 검증 데이터 적용 때보다 시험 데이터셋을 적용했을 때 두 모델의 성능 지표는 전반적으로 감소하였다. 이는 모델이 데이터 의존성을 극복할 수 있도록 충분한 학습 및 최적화되지 않았기 때문으로 분석되나, 검증 데이터 대비 10% 내외 감소로 두 모델 간 지표감소가 유사한 수준으로 모델 간 성능 비교에는 무리가 없을 것으로 판단된다. 극적인 변화는 발견되지 않았다.

Fig. 6에서 확인된 바와 같이 세그멘테이션 모델은 객체 감지 모델 대비 신뢰값(confidence)에 대한 F1 지표 변화 민감도가 낮았다. 반면 P-R 선도의 경우, 데이터셋에 따라 모델별 성능 순위(P-R 선도 면적)가 다르게 확인되며, 이는 모델의 균열 이미지 데이터의 의존성에 기인했다고 판단되며 성능검증 및 최적화를 위해 다양한 데이터셋의 활용 필요성을 보여준다.

검증 및 시험데이터에 대한 각 모델의 최대 성능 지표를 비교하여 Table 2에 나타냈다. 주요 성능 지표 모두 세그멘테이션 모델이 객체 감지 모델에 더 높은 것으로 평가되었다. 특히 세그멘테이션 모델의 결과는 IoU 임계치가 0.5~0.95일 때의 mAP가 높아 범용 환경에서의 균열 검출성능이 객체 감지 모델에 비해 높다는 것을 알 수 있다. 주요 성능 지표의 최댓값 또한 시험데이터를 적용함에 따라 전반적으로 감소하였다.




Fig. 6. Metric comparison between crack detection models: F1 and P-R curves for validation and test data  
(a) Object detection (b) Segmentation

#### 4.3 모델별 균열 검출 결과의 정성적 분석

검출 임계값을 0.5로 설정한 객체 감지 및 세그멘테이션 최적 모델에 균열 시험데이터 112개(3.2.1절)를 적용해 검출 결과를 비교 분류하였다. 시험데이터셋은 416x416 픽셀로 균열을 포함한 콘크리트 표면을 근접하여 촬영한 것으로, 다양한 콘크리트 표면 명암, 균열 폭 및 길이를 가진다. 해당 데이터셋의 검출 이미지를 세그멘테이션 모델의 균열 검출 결과가 우수한 경우(Set 1), 객체 감지 모델의 검출 결과가 우수한 경우(Set 2), 두 모델 모두 동일한 검출 결과를 보인 경우(Set 3), 미검출 경우(Set 4)로 구분하였다(Table 3). 여기서 모델별 검출 결과의 상대우위는 F1과 같은 모델 성능 지표의 높고 낮음을 배제하고, 검출 결과가 이미지 내 균열 개체를 모두

찾아냈는지와 균열 영역 전체를 포괄했는지를 기준으로 육안 판별하였다.

Table 3에 나타난 바와 같이 Sets 1 and 2의 비교를 통해 세그멘테이션 모델의 균열 검출 결과가 객체 감지 모델과 비교해 전반적으로 균열 검출을 잘 수행해 내는 것으로 확인되며, Set 3의 다수 이미지에 대해서도 세그멘테이션 모델의 검출 결과의 신뢰도(F1 값)가 높게 확인되었다(Fig. 7: Set 3). 다만 이와 같은 검출 신뢰도 차이는 세그멘테이션 모델의 학습 데이터가 균열 영역만을 대상으로 형성되는 반면 객체 감지 모델은 균열 형상에 따라 균열 외 영역을 학습 데이터에 포함함으로써 불가피하게 발생한 결과로 추정된다.






Fig. 7. Crack detection image comparison with results from segmentation and object detection models for test data

Table 2. Comparison with main metric of object detection and segmentation models for validation and test data (V: Validation, T: Test)

| Model            | Data | F1 <sub>max</sub> | P@F1 <sub>max</sub> | R@F1 <sub>max</sub> | mAP: 0.5~0.95 |
|------------------|------|-------------------|---------------------|---------------------|---------------|
| Object detection | V    | 0.805             | 0.862               | 0.755               | 0.620         |
|                  | T    | 0.734             | 0.805               | 0.674               | 0.529         |
| Segmentation     | V    | 0.807             | 0.820               | 0.795               | 0.655         |
|                  | T    | 0.762             | 0.797               | 0.730               | 0.572         |

Table 3. Crack detection statistics of test images

| N=112 | Set 1 | Set 2 | Set 3 | Set 4 |
|-------|-------|-------|-------|-------|
| Count | 22    | 6     | 79    | 5     |

Fig. 7은 112개 이미지에 대한 두 모델의 균열 검출 결과 일부를 Table 3의 분류대로 나란히 배치해 나타낸 것이다. Set 1의 결과 샘플은 객체 감지 모델이 전체 또는 일부만 감지를 못한 균열에 대해서도 세그멘테이션 모델이 잘 검출해낼 수 있음을 보여준다. Set 2의 결과 그림은 역으로 객체 감지 모델의 검출 결과가 더 우수하게 나타난 경우이며, 미검출 발생보다는 부분 검출 사례가 대부분이다. 시험데이터의 70%를 차지하는 Set 3의 경우, 경계 상자 기준으로 동일한 검출 결과가 나타남을 확인할 수 있으며, 검출 신뢰도 또한 대부분 세그멘테이션 모델의 결과가 다소 높으나 객체 감지 모델의 것과 유사한 수준이었다. 마지막으로 두 모델 모두 균열 검출을 하지 못한 경우(Set 4)의 이미지 특성을 분석해보면, 균열 주변 색상이 상대적으로 어둡거나, 미세균열, 패임 및 백화 등이 균열과 혼재된 경우이다.

균열은 콘크리트 표면과 달리 빛이 반사되지 못해 검게 보이므로, 주변 색상이 어두워질수록 균열과 주변 간 색상 대비가 불분명해진다. 이 때문에 밝은 주변 색을 갖는 균열 이미지 대비 검출성능이 낮아진 것으로 판단된다. 한편 미세균열의 경우 균열 여부를 판단하기 위한 적정 화소 크기 확보가 어렵고, 패임 및 백화 등이 결부되면 균열 특성을 모델이 찾기 어려워 두 모델 모두 균열 검출이 어려웠다고 추정된다. 따라서 제시한 균열 검출 모델의 구조물 유지관리 등 현장 적용성을 높이기 위해서는 콘크리트 구조물 표면에 대한 근접 촬영이 필요하고, 균열과 주변 간 대비가 큰 이미지 확보를 위해 조명 기기를 보조 수단으로 활용하면 검출성능 향상에 도움이 될 것으로 판단된다.

비록 시각적인 비교 시 일부 균열 이미지를 제외하고는 세그멘테이션 균열 검출성능이 객체 감지 모델 대비 우수한 것으로 확인되나, 압도적인 성능 우위를 갖는다고 결론짓기 어려웠다(Table 2, Fig. 7). 모델의 학습 과정 또한 세그멘테이션 모델에서 초기 수렴 속도가 좀 더 빠르지만, 전산 비용이 보다 소요되고 두 모델의 성능 지표의 수렴 값 차이가 크지 않았다. 따라서 엄격한 균열 검출성능을 요구하는 적용사례가 아니라면, 학습 데이터 구축에 필요한 비용, 시간 등을 감안하여 객체 감지 모델 활용 또한 대안으로써 활용 가능하다고 판단된다.

## 5. 결론

본 연구는 콘크리트 균열 검출 문제에 대해 세그멘테이션 모델과 객체 감지 모델 간 검출성능 비교를 위해 YOLOv7을 활용하였다. 동일한 조건의 검출성능 비교를 위해 공개된 학습, 검증, 시험 목적의 동일한 균열 이미지 셋을 적용하여 모델의 학습 속도와 성능 지표를 비교 분석하여 다음과 같은 결론을 도출하였다.

1. YOLOv7 기반의 세그멘테이션 모델에 대한 라벨링 데이터를 객체 감지 모델의 라벨링 데이터로 변환하는 알고리즘을 도출하고, 이를 적용해 약 4천 개 균열 이미지를 자동 변환함으로써, 개발된 알고리즘이 세그멘테이션 라벨링 정보로부터 객체 감지 모델의 라벨링 데이터 신속, 정확하게 생성함을 확인하였다.
2. 동일 epoch 수, 학습 데이터, 배치크기, IoU 임계값 조건에서의 세그멘테이션 모델과 객체 감지 모델의 학습 속도를 비교하였다. 이를 통해 두 모델 간 최종 모델 성능 지표는 정밀도 0.8, 재현율 0.7, 평균 정밀도 0.6 내외로 수렴하였다. 한편 관찰한 모든 성능 지표에 대해 세그멘테이션 모델이 10 epochs 내외에서 각 성능 지표 수렴 값에 근접하고 성능 지표 및 손실함수 값도 낮아 초기 학습 속도가 객체 감지 모델에 비해 빠름을 확인할 수 있다.
3. 검증 데이터와 시험데이터를 대상으로 최종 학습된 두 모델의 검출성능을 비교하였다. 지표 간 일부 변동이 있으나 시험데이터에 대한 실험 수행 결과는 세그멘테이션 모델의 성능 지표의 최댓값이 0.05 내외로 더 높게 나타났다. 한편 검증 데이터 적용 때와 달리 시험데이터 적용 시 두 모델의 성

능 지표가 전반적으로 검증 데이터 대비 10% 내외로 감소하여, 최종 성능 지표 도출 시 여러 데이터셋 적용을 통한 객관적인 성능 지표 평가가 필요함을 알 수 있었다.

4. 시험데이터에 대한 검출 이미지를 분석함으로써, 콘크리트 균열의 어두운 주변 색상, 미세균열, 콘크리트 표면 손상이 두 딥러닝 모델의 균열 검출 성능 저하에 영향을 미치는 것을 확인하였으며, 시설물 유지관리 목적의 활용을 위해 검출성능 개선을 위해 근접 촬영, 조명기기 등 보조기구 활용을 제안하였다.
5. 콘크리트 균열 검출에 대해 두 모델 간의 성능 지표 비교를 통해 세그멘테이션 모델이 객체 감지 모델 대비 모델 학습 및 균열 검출에 대해 우위를 보였으나, 일정 수준 이상의 하드웨어 성능과 데이터 구축에 제한이 있다면 객체 감지 모델의 활용 또한 만족할만한 대안이 될 수 있을 것으로 판단된다. 다만 제시된 두 모델의 균열 검출성능 비교는 실제 균열의 정량적 정보(폭과 길이 등)와 비교분석을 포함한 것은 아니다. 향후 균열의 정량적 정보와 딥러닝 모델 결과와 비교분석함으로써 제시한 딥러닝 균열 검출모델의 적용범위 및 신뢰성을 도출할 수 있을 것으로 판단된다.

## References

- [1] S. Kim, "Optimum service life management based on probabilistic life-cycle cost-benefit analysis", *Journal of the Korea Academia-Industrial Cooperation Society*, vol.17, no. 4, pp. 19-25, 2016. (in Korean)  
DOI: <https://doi.org/10.5762/KAIS.2016.17.4.19>
- [2] S. Shim, S. I. Choi, S. M. Kong, S. W. Lee, "Adversarial learning for underground structure concrete crack detection based on semi-supervised semantic segmentation", *Journal of Korean Tunnelling and Underground Space Association*, vol. 22, no. 5, pp. 515-528, 2020. (in Korean)  
DOI: <https://doi.org/10.9711/KTAJ.2020.22.5.515>
- [3] D. H. Seol, J. H. Oh, H. J. Kim, "Comparison of deep learning-based CNN Models for crack detection", *Journal of the Architectural Institute of Korea Structure & Construction*, vol. 36, no. 3, pp. 113-120, 2020. (in Korean)  
DOI: [https://doi.org/10.5659/IAIK\\_SC.2020.36.3.113](https://doi.org/10.5659/IAIK_SC.2020.36.3.113)
- [4] S. I. Lee, G. M. Yang, J. Lee, J. H. Lee, Y. J. Jeong, W. Choi, "Recognition and visualization of crack on concrete wall using deep learning and transfer Learning", *Journal of The Korean Society of Agricultural Engineers*, vol.61, no. 3, pp. 55-65, 2019. (in Korean)  
DOI: <https://doi.org/10.5389/KSAE.2019.61.3.055>
- [5] J. H. Kim, "Vector-based data argumentation and network learning for efficient crack data collection", *Korea Computer Graphics Society*, vol. 28, no.2, pp. 1-9, 2022. (in Korean)  
DOI: <https://doi.org/10.15701/kcgs.2022.28.2.1>
- [6] H. J. Chang, H. H. Lee, S. T. Hong, Y. D. Choi, H. J. Chung, "Study of image augmentation and AI parameter tuning for structure crack detection", *2022 Summer Proceedings of the Korean Institute of Communications and Information Sciences*, KICS, Kyungju, South Korea, pp. 596-597, June 2022. (In Korean)
- [7] J. H. Choi, Y. K. Kim, H. S. Lee, "Concrete crack detection and visualization method using CNN model", *2022 Spring Proceedings of the Korean Institute of Building Construction Conference*, the Korean Institute of Building Construction, Naju, South Korea, pp. 73-74, April 2022. (in Korean)
- [8] D. Lee, J. Kim, D. Lee, "Training a semantic segmentation model for cracks in the concrete lining of tunnel", *International Journal of Aeronautical and Space Sciences*, vol.20, pp. 287-299, 2019.  
DOI: <https://doi.org/10.1007/s42405-018-0120-5>
- [9] W. Wang, C. Su, "Automatic concrete crack segmentation model based on transformer", *Automation in Construction*, vol. 139, 104275, 2022.  
DOI: <https://doi.org/10.1016/j.autcon.2022.104275>
- [10] R. Pu, G. Ren, H. Li, W. Jiang, J. Zhang, H. Qin, "Autonomous concrete crack semantic segmentation using deep fully convolutional Automatic concrete crack segmentation model based on transformer", *Automation in Construction*, vol.139, 104275, 2022.  
DOI: <https://doi.org/10.1016/j.autcon.2022.104275>
- [11] W. Li, G. Wang, L. Fidon, S. Ourselin, M. J. Cardoso, T. Vercauteren, "On the compactness, efficiency, and representation of 3D convolutional networks: Brain parcellation as a pretext task", *In International conference on information processing in medical imaging*, Springer, Cham., pp.348-360, 2017.  
DOI: <https://doi.org/10.48550/arXiv.1707.01992>
- [12] A. R. Kim, D. Kim, Y. S. Byun, S. W. Lee, "Crack detection of concrete structure using deep learning and image processing method in geotechnical engineering", *Journal of the Korean Geotechnical Society*, vol. 34, no. 12, pp. 145-154, 2018. (In Korean)  
DOI: <https://doi.org/10.7843/kgs.2018.34.12.145>
- [13] J. J. Kim, A. R. Kim, S. W. Lee, "Artificial neural network-based automated crack detection and analysis for the inspection of Concrete Structures", *Applied Sciences*, vol. 10, 8105, 2020.  
DOI: <https://doi.org/10.3390/app1028105>
- [14] S. Ham, S. Bae, H. Kim, I. Lee, G. P. Lee, D. Kim,



- "Robust concrete crack detection using deep learning-based semantic segmentation", *Journal of Korean Tunnelling and Underground Space Association*, vol. 23, no.6, pp. 549-558, 2021. (In Korean)  
DOI: <https://doi.org/10.9711/KTAJ.2021.23.6.549>
- [15] S. M. Kim, J. M. Shon, D. S. Kim, "A method for concrete crack detection using U-Net based image inpainting technique", *Journal of The Korea Society of Computer and Information*, vol. 25, no. 10, pp. 35-42, 2020. (In Korean)  
DOI: <https://doi.org/10.9708/jksoci.2020.25.10.035>
- [16] D. W. Kim, S. G. Hong "Development of a concrete surface crack detection program based on the generative adversarial network(GAN) model", *2022 Spring Annual Conference of Architectural Institute of Korea*, Seoul, South Korea, pp. 458-461, April 2022. (In Korean)
- [17] S. Song, G. Lee, K. Han, H. Jang, "Field applicability study of hull crack detection based on artificial intelligence", *Journal of the Society of Naval Architects of Korea*, vol. 59, no.4, pp. 192-199, August 2022. (In Korean)  
DOI: <https://doi.org/10.3744/STAK.2022.59.4.192>
- [18] X. Xiang, Z. Wang, Y. Qiao, "An improved YOLOv5 crack detection method combined with transformer," *IEEE Sensors Journal*, vol. 22, no. 14, pp. 14328-14335, 2022.  
DOI: <https://doi.org/10.1109/JSEN.2022.3181003>
- [19] S. Y. Jung, S. K. Lee, C. I. Park, S. Y. Cho, J. H. Yu, "A method for detecting concrete cracks using deep-learning and image processing", *Journal of the Architectural Institute of Korea Structure & Construction*, vol. 35, no. 11, pp. 163-170, 2019. (In Korean)  
DOI: [https://doi.org/10.5659/JAK\\_SC.2019.35.11.163](https://doi.org/10.5659/JAK_SC.2019.35.11.163)
- [20] S. Jeong, S. K. Bae, B. Kim, J. Cho, "Concrete pavement crack detection using object detection and super-resolution deep-Learning", *2021 Fall Annual Conference of Korea Institute for Structural Maintenance and Inspection*, Jeju, South Korea, pp. 226, November 2021. (In Korean)
- [21] B. Kim, G. Kim, S. Jin, S. Cho, "A comparative study on performance of deep learning models for vision-based concrete crack detection according to model types", *Journal of the Korean Society of Safety*, vol. 34, no. 6, pp. 50-57, 2019. (In Korean)  
DOI: <https://doi.org/10.14346/JKOSOS.2019.34.6.50>
- [22] C. Y. Wang, A. Bochkovskiy, H. Y. M. Lia, "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors", *arXiv preprint arXiv:2207.02696*, 2022.  
DOI: <https://doi.org/10.48550/arXiv.2207.02696>
- [23] G. Boesch, YOLOv7: The Most Powerful Object Detection Algorithm (2022 Guide) [Internet]. viso.ai, c2022, Available From: <https://viso.ai/deep-learning/yolov7-guide/> (access Jan. 5, 2023)
- [24] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You only look once: unified, real-time object detection", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 779-788, May 2016.  
DOI: <https://doi.org/10.48550/arXiv.1506.02640>
- [25] T. Diwan, G. Anirudh, J. V. Tembhurne, "Object detection using YOLO: challenges, architectural successors, datasets and applications", *Multimedia Tools and Applications*, pp.1-33, August 2022.  
DOI: <https://doi.org/10.1007/s11042-022-13644-y>
- [26] S. Rath, YOLOv6 Object Detection-Paper Explanation and Inference [Internet]. LearnOpenCV, c2022 [cited 2022 Oct. 11], Available From: <https://learnopencv.com/yolov6-object-detection/> (access Jan. 5, 2023)
- [27] Kukil, S. Rath, YOLOv7 Object Detection Paper Explanation & Inference, [Internet]. LearnOpenCV, c2022 [cited 2022 Aug. 2 ], Available From: <https://learnopencv.com/yolov7-object-detection-paper-explanation-and-inference/> (access Jan. 5, 2023)
- [28] H. Chen, K. Sun, Z. Tian, C. Shen, Y. Huang, Y. Yan, "BlendMask: top-down meets bottom-up for instance segmentation", *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 8573-8581, 2020.  
DOI: <https://doi.org/10.48550/arXiv.2001.00309>
- [29] K. Y. Wong, Official YOLOv7 [Internet]. github, c2022, Available From: <https://github.com/WongKinYiu/yolov7> (access Jan. 5, 2023)
- [30] University, Crack Dataset, Roboflow Universe, [Internet]. Roboflow, c2022, Available From: <https://universe.roboflow.com/university-bswxt/crack-bphr> (access Jan. 5, 2023)

김 정 수(Jeongsoo Kim)

[정회원]



- 2016년 2월 : 연세대학교 일반대학원 토목환경공학과 (공학박사)
- 2016년 3월 ~ 2018년 9월 : 한국건설기술연구원 박사후연구원
- 2018년 10월 ~ 현재 : 한국건설기술연구원 전임연구원

<관심분야>

전산역학, 지하구조물, 딥러닝, 수치해석