

# 딥러닝 및 영상처리 기술을 활용한 콘크리트 균열 검출 방법

## A Method for Detecting Concrete Cracks using Deep-Learning and Image Processing

정 서 영\*    이 슬 기\*\*    박 찬 일\*\*\*    조 수 영\*\*\*\*    유 정 호\*\*\*\*\*  
Jung, Seo-Young    Lee, Seul-Ki    Park, Chan-Il    Cho, Soo-Young    Yu, Jung-Ho

### Abstract

Most of the current crack investigation work consists of visual inspection using simple measuring equipment such as crack scale. These methods involve the subjection of the inspector, which may lead to differences in the inspection results prepared by the inspector, and may lead to a large number of measurement errors. So, this study proposes an image-based crack detection method to enhance objectivity and efficiency of concrete crack investigation. In this study, YOLOv2 was used to determine the presence of cracks in the image information to ensure the speed and accuracy of detection for real-time analysis. In addition, we extracted shapes of cracks and calculated quantitatively, such as width and length using various image processing techniques. The results of this study will be used as a basis for the development of image-based facility defect diagnosis automation system.

키워드 : 콘크리트 균열, 균열 검출, 딥러닝, 영상처리, 합성곱신경망

Keywords : Concrete Crack, Crack Detection, Deep Learning, Image Processing, CNN

### 1. 서    론

#### 1.1 연구의 배경 및 목적

콘크리트 건축물은 축조 이후 시간이 경과함에 따라 그 성능이 감소하게 되며, 크고 작은 균열을 동반하게 된다. 건축물의 균열은 구조적 안전성, 사용성 및 내구성에 영향을 미치므로 균열의 정확한 관찰과 진단은 건축물의 안전성 확보의 필수요소라 할 수 있다.

이에 국토교통부는 ‘안전점검 및 정밀안전진단 세부지침’에 시설물 균열 관리의 필요성을 제시하며 균열조사 기준을 제시하였다. 해당 지침에 따르면 균열조사는 균열자(Crack Scale) 등의 간단한 장비를 사용하여 폭, 길이, 형태 등을 파악하는 것으로 규정되어 있다. 하지만, 대부분의 균열 조사 업무가 점검자의 육안조사에 의존하는 방식을 취하고 있어 점검자별로 작성한 점검 결과에 차이가 발생할 여지가 있으며, 많은 조사 인력 및 자금을

필요로 한다는 한계가 존재한다.

이러한 기존 균열 조사 방식의 한계를 극복하고 건축물의 균열조사 업무의 객관성과 효율성을 높이기 위하여 영상처리(Image Processing) 및 딥러닝(Deep Learning) 기술을 활용한 영상 기반 균열 검출 연구가 진행되고 있는 추세이다. 영상처리 기술과 딥러닝 기술을 활용하여 균열 조사가 영상 기반으로 이루어질 경우, 점검자의 주관 개입의 여지를 최소화 하여 조사 결과의 객관성을 확보할 수 있으며, 점검 시기 및 위치에 대한 제약의 개선은 물론 기존 점검 및 조사에 소요되는 인력과 비용을 절감할 수 있을 것으로 기대된다(Lee et al., 2012).

하지만, 영상 기반 균열 검출과 관련된 초기 연구들은 단순 영상처리 기술을 활용하여 노이즈에 취약하고, 형상 별로 별도의 필터를 모델링해야 한다는 단점이 존재하였다. 또한, 영상처리 기술의 한계를 보완하기 위해 최근 딥러닝 기술을 적용한 연구들도 존재하였으나, 균열 검출의 자동화의 가능성 및 검출 정확도 향상에만 초점을 맞추어 검출 속도의 확보 측면에서 한계가 존재하였으며, 균열의 원인 추정 및 보수와 보강과 같은 진단 결과를 도출하는데 사용되는 균열의 특성정보(폭, 길이, 형상 등)를 추출하는 것에는 미흡했다.

이에 본 연구에서는 기존 콘크리트 건축물의 균열 조사 업무의 한계 및 기존 유사 연구의 한계를 분석하고, 이를 개선한 영상 기반 균열 검출 방법을 제시하고자 한다. 특히, 본 연구에서는 드론과 같은 무인체에 대한 기술발전과 더불어 실시간 추적에 대한 니즈가 대두됨에

\* 광운대학교 대학원 건축공학과 박사과정  
\*\* 광운대학교 건축공학과 강사, 공학박사  
\*\*\* 광운대학교 대학원 전자통신공학과 석사과정  
\*\*\*\* 광운대학교 대학원 전자통신공학과 석박통합과정  
\*\*\*\*\* 광운대학교 건축공학과 교수, 공학박사  
(Corresponding author : Department of Architectural Engineering, Kwangwoon University, myazure@kw.ac.kr)

본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2017R1A2B4012228)

따라 추후 드론 기술과 같은 실시간 영상 획득 기술과의 연계성 및 확장성을 고려한 균열 검출 방법을 제안하고자 한다.

### 1.2 연구의 범위 및 방법

본 연구에서는 ‘균열 검출’의 범위를 영상에서 균열의 유무를 판단하고, 균열로 판단되었을 경우 균열의 최대 폭, 길이, 형상과 같은 특성 정보를 추출하는 것으로 정의한다.

딥러닝 및 영상처리 기법을 활용한 콘크리트 균열검출 방법을 제시하기 위한 연구 방법 및 절차는 다음과 같다.

(1) 기존 문헌 고찰과 전문가 자문을 통하여 현행 균열 조사 방식과 한계점을 파악을 통해 영상기반 균열 검출 방법이 갖춰야 하는 조건들을 도출한다.

(2) 딥러닝 학습을 위하여 학습용 이미지를 수집하고 딥러닝 네트워크에 적용시킬 수 있도록 콘크리트 균열 영상(4,000장) 균열과 유사한 형태를 갖는 비균열 영상(1,000장, 예: 낙서, 기타 오염 등) 총 5,000장을 수집 및 제작한다. 또한 앞서 제시한 요건을 만족하는 딥러닝 모델을 선정한다.

(3) 수집된 학습용 데이터 셋(Dataset)을 기반으로 선정된 딥러닝 모델을 학습시켜 균열 여부를 판단하고 균열의 특성정보를 추출할 수 있는 콘크리트 균열 검출 모델을 개발한다.

(4) 마지막으로 학습에 사용되지 않은 400장의 이미지를 활용하여 위에서 제시한 딥러닝 및 영상처리 기술을 활용한 균열 검출 방법의 사용성능을 평가한다.

## 2. 예비적 고찰

### 2.1 현행 균열조사 방법 및 한계점

국토교통부는 ‘안전점검 및 정밀안전진단 세부지침’에 균열은 다양하고 복합적인 원인에 의하여 발생하기 때문에 여러 가지 관점에서 그 원인을 추적해야 할 필요가 있음을 제시하면서, 균열조사 기준을 제시하였다. 이에 따른 일반적인 수준의 균열 조사항목에는 균열 폭, 길이, 형상(형태 및 분포)로 구분된다. 이와 같은 항목들의 조사방법에는 균열자(Crack scale)과 같은 간단한 측정 장비를 이용하거나 육안관찰을 기본으로 한다.

이와 같이 점검자의 육안관찰에 의존하는 방식은 다음과 같은 한계점이 있다. 첫째, 사람이 접근하기 힘든 위치(예: 엘리베이터 샤프트 등)에 있는 균열은 조사하기 어렵다. 둘째, 대부분의 균열의 폭이 0.1~2.0mm 사이이므로 균열자를 이용한 육안 측정에 오차가 많이 발생할 수 밖에 없다. 셋째, 점검자가 수기로 외관조사방도를 작성하는 과정에서 주관적인 판단이 개입되어 기록의 정확성 및 객관성이 낮아질 수 있다.

이러한 한계점에도 불구하고 현재 육안조사결과를 기반으로 균열의 발생 원인을 추정하여 보수·보강 여부를 판정하고 있다.

하지만 각 조사항목별 측정오차가 클 경우 건축물의

안전성 확보에 문제가 발생할 가능성이 있기 때문에 균열 조사의 효율성과 객관성을 확보하기 위한 연구로 2000년대 초반부터 영상정보를 기반으로 영상처리기술과 딥러닝을 활용한 균열 검출 자동화 연구들이 수행되어 오고 있다.

### 2.2 영상 기반 균열 검출관련 선행연구 고찰

영상 기반 균열조사를 위한 초기 연구는 영상의 형태학적 연산을 활용하는 영상처리 기법인 모폴로지 기법(morphology method)을 이용하여 균열의 특징을 추출하고 검출(Kim et al., 2005; Lee et al., 2005; Byun et al., 2006; Lee et al., 2012)하는 연구가 주를 이뤘다. 그 외에도 콘크리트 균열의 명암차를 활용하기 위하여 영상의 R, G, B 채널 값에 퍼지(fuzzy) 기법을 적용 하거나(Kim et al., 2010), Histogram stretching 기법을 적용하여 영상의 콘트라스트 특성을 향상시킨 방법(Lee et al., 2007), 윤곽선(edge) 검출 및 노이즈 제거 등의 영상 처리기법을 이용한 방법(Chen et al., 2001; Kim et al., 2002; Kim., 2016) 등이 연구되었다.

이 연구들은 영상 내 균열의 효과적으로 검출하기 위해 노이즈를 제거하는 필터를 모델링하기 위하여 다양한 영상처리 기술을 활용한 연구로서 제한된 범위 내에서 효용성을 증명하였다는 점에서 의의가 있다. 하지만, 균열 검출과정에서 균열의 일부분이 노이즈로 처리되어 손실되거나, 영상의 품질(예: 해상도, 명암도, 조도 등)이나 균열의 형태에 따라 새로운 필터 모델링이 필요하다는 점에서 한계가 있다.

이러한 단순 영상처리 기술 적용에 의한 한계를 해결하기 위해 최근 딥러닝 기술들이 활용되고 있다. 딥러닝은 인간의 신경망 구조를 흉내낸 인공신경망(Artificial Neural Networks; 이하, ANN)에 바탕을 둔 기술로 인공신경망을 넓고 다층으로 쌓은 형태를 지니고 있으며, 노드 간 연결 형태와 사용하는 수치 모델에 따라 세부 알고리즘으로 분류할 수 있는데 영상인식분야에 주로 활용되는 알고리즘은 합성곱신경망(Convolutional Neural Network, 이하 CNN)이다. CNN은 현재 거의 모든 영상인식 분야에서 활용되는 네트워크로서, 다음 <Figure 1>과 같이 이미지를 단순하게 픽셀로 계산하는 것이 아니라 이미지의 공간 특성을 살릴 수 있는 Convolution filter를 통해서 이미지에서 특징(feature)을 추출하고, 추출된 특징들을 이용하여 이미지를 분류하는 구조를 가진다.

이와 같은 CNN 기술을 균열 검출에 사용할 경우 컴퓨터가 균열의 특징을 학습하고, 새로운 영상정보가 입력되었을 때 학습된 결과를 토대로 균열을 검출할 수 있기 때문에 단순 이미지분석 기법을 적용했을 때보다 다양한 형태의 균열을 추출해낼 수 있어 보다 효율적이다. 이러한 배경 속에서 최근 균열 검출에 이러한 CNN 기법을 적용하는 연구들이 진행되고 있는 추세이며(Cha et al., 2017; Son et al., 2017; Hassan et al., 2018), CNN 기반 균열 검출 방법에 드론 기술(Kim et al., 2018) 및 웹기반 영상 수집 기술을 적용한 연구(Cho et al., 2018)가 진행

Table 1. literature review for crack detection using image

Ref No.	Applied Technology			Information Extraction				
	Image Processing	Deep Learning classification	Deep Learning detection	Crack Recognition	Local-ization	Crack Shape	Crack Width	Crack Length
[3]	○					○	○	
[11]	○					○		
[16]	○						○	○
[1]	○					○		
[17]	○					○	○	○
[10]	○					○		
[18]	○			○	○	○	○	
[14]	○					○		
[12]	○	○		○			○	○
[2]	○			○		○		
[20]		○		○				
[4]	○		○	○	○			
[8]	○	○		○		○	○	○
[21]		○		○		○		

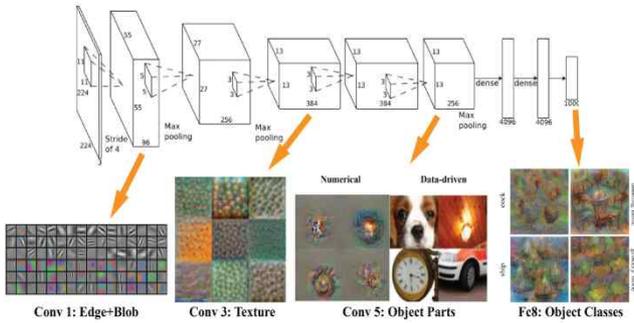


Figure 1. Configuration and principles of CNN [5]

되기도 하였다.

CNN은 네트워크의 레이어 구성 및 성능에 따라 다양한 모델이 존재하는데, 이를 사물에 대한 인식 및 이해의 정도로 구분하면 크게 ‘객체 분류(classification) 모델’과 ‘객체 검출(detection) 모델’로 구분할 수 있다. 객체 분류 모델이 단순히 대상 객체의 클래스(Class) 분류만을 목적으로 한다면, 객체 검출 모델은 대상 객체의 분류와 더불어 객체의 위치 정보까지 검출할 수 있는 모델이다.

전술한 딥러닝 기반 균열 검출 기존 연구들의 대부분은 LeNet, AlexNet, ResNet 기반의 객체 분류 모델을 사용하여 균열을 분류하는 것에는 우수한 성능을 확보하였으나, 영상 내 균열의 위치를 탐지하는 것에는 한계가 있었다. 영상에서 객체의 위치를 추적하는 문제를 해결하면 정지영상 및 동영상에 나타나는 균열의 위치를 검출하여 경계 상자(bounding box)로 표시가 가능하기에 보다 효과적인 균열 검출 자동화가 가능해질 수 있다.

따라서, 이상적인 균열 검출 자동화를 위해서는 R-CNN (Regions with Convolutional Neural Networks), SSD (Single Shot MultiBox Detector), YOLO (You Only Look Once)와 같은 객체 검출 모델의 적용을 검토할 필요가 있다. 특히, 이와 같은 객체 검출 모델은 일반적으로 객체 분류 모델에 비해 탐지 속도 및 성능이 뛰어나 드론과 같은 무인체에 대한 기술발전과 더불어 실시간 추적에 대한 니즈가 대두됨에 따라 이미지 인식 분야에서 최근 활발히 활용되고 있는 기법으로 추후 드론과 같은 실시간 영상 획득 기술과의 연계성 및 확장성까지 고려할 수 있다.

현행 균열조사 업무 분석 및 영상기반 균열검출 자동화관련 선행연구 고찰을 통해 도출한 균열조사 업무를 영상 기반으로 자동화하기 위한 요구 조건은 다음과 같다. 첫째, 영상으로부터 균열을 자동으로 인지하고, 영상 내 균열의 위치를 검출할 수 있어야 한다. 둘째, 구조물에 유해한 균열인지를 판단하기 위해 균열 폭, 길이, 형상과 같은 정보를 추출할 수 있어야 한다. 셋째, 드론과 같은 실시간 영상 수집 기술과의 연계 및 확장성을 위해 실시간 분석이 가능한 성능이 확보되어야 한다. 이러한 요구조건을 기반으로 영상기반 균열 검출관련 선행연구들을 고찰한 결과는 다음 <Table 1>과 같다.

### 3. 딥러닝을 활용한 균열여부 판단 모델 개발

#### 3.1 Dataset 수집 및 제작

딥러닝 학습을 위하여 학습용 이미지를 수집하고 딥러닝 네트워크에 적용시킬 수 있는 형태로 총 5,000장의 프레임으로 구성된 데이터셋을 제작하였다. 본 연구에서는 학습용 데이터로 4,000장의 콘크리트 균열 영상과 함께, 1,000장의 균열과 유사한 형태를 갖는 비균열 영상(예: 낙서, 기타 오염 등)을 수집하였다. 영상 수집시 다양한 균열 점검 환경의 반영을 위하여 건물의 외벽 및 내벽의 다양한 부분을 촬영하였으며, 건물의 외벽 영상의 경우에는 자연광만으로 균열의 식별이 가능한 시간대 (일출 후~일몰 전)에 촬영하였다.

이처럼 제한적인 데이터를 활용하는 딥러닝 환경에서는 이미지 증강기술(Image augmentation)을 활용하여 데이터의 수를 증가시킬 수 있는데, 이는 딥러닝 학습 성능 향상에 긍정적인 영향을 미친다. 본 연구에서는 이미지 증강을 위하여 Flip, Translate, Rotate, Color modification의 4가지 방법을 사용하였다(Figure 2).

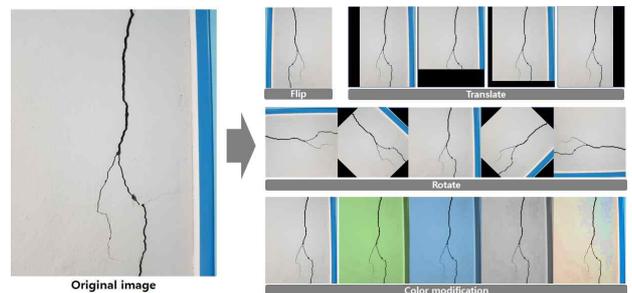


Figure 2. Image Augmentation

먼저, Flip 기법을 사용하여 원 영상(original image)을 좌우 혹은 상하로 반전시키고, Translate 기법을 사용하여 원 영상을 다양한 방향으로 약간씩 옮겨줌으로써 데이터셋 수를 늘릴 수 있었다. 또한, Rotate 기법을 통해 원 영상을 다양한 각도로 회전시켰으며, Color modification 기

법을 활용하여 원 영상의 컬러를 변경하였다. 이러한 과정을 통해 전체 학습 영상의 수가 약 8~10배 정도 증가하였다. 마지막으로 이진화된 영상에서 형체를 알아보기 위해 같은 픽셀 값들을 그룹화하는 레이블링(Labeling) 작업 후, xml형태로 파일을 변환하는 과정을 거쳐 데이터셋을 완성하였다(Figure 3).

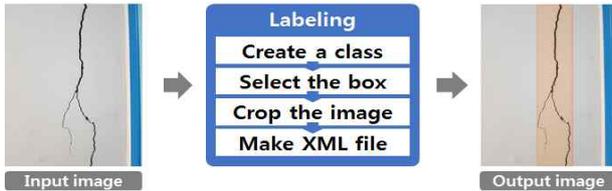


Figure 3. Labeling Process

### 3.2 딥러닝 모델 선정

2장에서 고찰한 바와 같이, 영상 인식 분야에서 활용되는 딥러닝 네트워크인 CNN은 대상 객체에 대한 인식 및 이해의 정도로 구분하면 크게 ‘객체분류모델’ 과 ‘객체검출모델’ 로 구분할 수 있다. 지금까지의 딥러닝 기반 균열 검출 대부분의 기존 연구는 객체 분류 기반의 CNN 모델을 이용하였는데, 이러한 방식은 균열의 클래스(Class)를 분류하여 영상 내 균열이 있다는 것을 분류해내는 성과를 거두었지만, 균열이 영상 안의 어느 위치에 있는지 검출하지 못한 한계가 있었다.

이러한 한계를 보완하기 위해서는 객체분류와 함께 위치 추정(localization)이 가능한 객체검출모델의 적용이 필요하다. 이 모델들은 영상에 균열을 포함하고 있다는 것을 분류해낼 수 있으며, 영상 내 균열의 위치까지 검출하여 경계 상자(bounding box)로 표시할 수 있으므로, 보다 효율적인 균열 검출 자동화를 가능하게 한다. 대표적인 객체 검출 모델은 R-CNN, YOLO, SSD 등이 있으며 각 모델에 대한 속도(mean Average Precision; 이하, mAP)와 정확도(Frame Per Second; 이하, FPS)를 확인하여 활용 목적에 따라 적절한 모델을 선택한다. 다만, 각 딥러닝 모델들의 mAP와 FPS는 학습에 사용된 데이터 셋과 학습 환경에 따라 차이가 발생하기 때문에 절대적인 성능을 비교하기 위해서는 VOC(Visual Object Classes) 나 COCO(Common Objects in Context) 와 같은 표준화된 데이터 셋을 사용하여 성능을 비교한다.

기존 연구들에서 VOC를 사용하여 속도와 정확성을 측정한 결과를 종합하면 검출 정확도는 60~70 mAP 정도로 큰 차이는 없었다. 반면, 검출 속도의 경우, 최저 0.5 FPS에서 최고 155 FPS로 차이가 컸다. 일반적으로 30 FPS를 기준으로 실시간 분석이 보장되지 않는 모델(Table 2)과 실시간 분석이 가능한 모델(Table 3)로 구분할 수 있다.

실시간 분석이 보장되지 않는 모델들은 대부분 R-CNN 계열의 모델들이다. 이 R-CNN 계열의 모델들은 물체 영역 추정 프로세스와 물체 인식 프로세스 간의 분리에 따른 병목현상으로 충분한 검출 속도가 나오지 못하며, 학습해야하는 네트워크 파라미터의 규모가 대단히 커져 최대 검출 속도를 내기 위해서는 고성능 GPU가 절대적으로

필요하다(Ko et al., 2017). 이러한 검출 속도 측면의 한계점으로 인하여 R-CNN 계열의 모델은 드론을 활용한 균열 검출 자동화 실무에 적용되기에는 무리가 있을 것으로 판단된다.

Table 2. Less Than Real-Time Detectors

Less Than Real-Time	Train	mAP	FPS
R-CNN Minus R [13]	VOC 2007	53.5	6
Fast R-CNN [19]	VOC 2007+2012	70.0	0.5
Faster R-CNN VGG-16 [22]		73.2	7
Faster R-CNN ZF [22]		62.1	18
SSD 500 [23]		76.8	19

Table 3. Real-Time Detectors

Real-Time Detectors	Train	mAP	FPS
YOLO [6]	VOC 2007+2012	63.4	45
Fast YOLO [6]		52.7	155
SSD 300 [23]		74.3	46
YOLOv2 288×288 [7]		69.0	91
YOLOv2 352×352 [7]		73.7	81
YOLOv2 416×416 [7]		76.8	67
YOLOv2 480×480 [7]		77.8	59
YOLOv2 544×544 [7]		78.6	40

반면, 실시간 분석이 가능한 모델들인 SSD(Single Shot multibox Detector)나 YOLO(You Only Look Once) 계열의 모델은 물체 영역 추정과 물체 인식을 단일 네트워크 구조를 사용하여 간단하고 빠르다. 특히, YOLO의 다음 버전인 YOLOv2 는 검출 정확도와 속도를 모두 개선시켜 어떤 경우에서도 여타 다른 실시간 분석 성능을 가지는 네트워크들에 비해 높은 성능을 가진다 (Figure. 4).

따라서, 객체의 분류(Classification)와 더불어 위치 추정이 가능하고, 실시간 분석이 가능하면서도 다른 네트워크에 비해 뒤지지 않는 검출 정확도를 가진다는 점을 고려하여 본 연구에서는 YOLOv2를 학습 모델로 선정하였다.

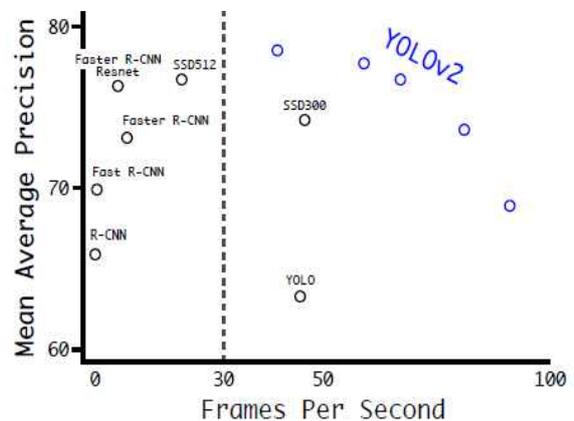


Figure 4. Accuracy and speed on VOC 2007 [7]

#### 4. 딥러닝 및 영상처리 기술을 활용한 균열검출 프로세스

##### 4.1 균열검출 프로세스 개요

본 연구에서 제안하는 균열검출 모델은 다음 <Figure 5>과 같이 영상에서 균열 유무를 판단하는 ‘균열여부 판단’ 과 균열의 형상과 폭과 길이와 같은 정보를 추출하는 ‘균열 특성정보 추출 단계’ 로 구성되며, 다음 <Table 5>와 같은 개발환경에 따라 개발하였다.

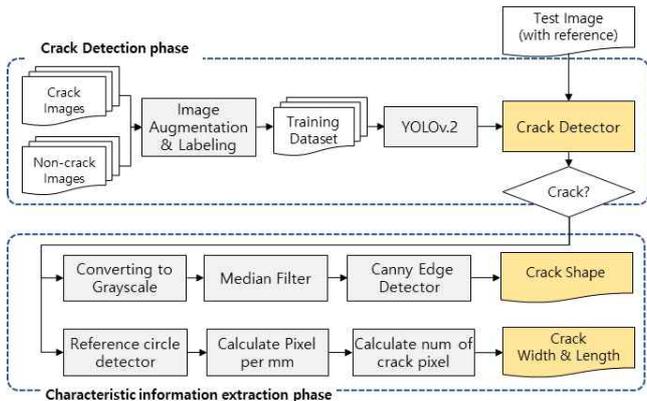


Figure 5. Crack detector using Deep learning and Image processing

Table 5. Development Environment

Division	Development Environment
Language	Python3
OS	Ubuntu 16.04
VGA	GEFORCE GTX 1080 Ti
RAM	16G

##### 4.2 균열여부 판단

균열여부 판단 단계는 영상정보 내 균열 이미지의 유무를 판단하기 위한 단계로 딥러닝 네트워크 중 앞서 선정한 YOLOv2 480×480를 활용하였다. 본 연구에서는 균열 여부 판단을 위해 4,000장의 콘크리트 균열 영상과 1,000장의 균열과 유사한 형태를 갖는 비균열 영상(예: 낙서, 기타 오염 등)을 수집한 후 이미지 증강을 통해 영상의 수를 증가시켜 Dataset을 제작하였으며, 이를 YOLOv2 (Figure 6)에 학습시켰다.

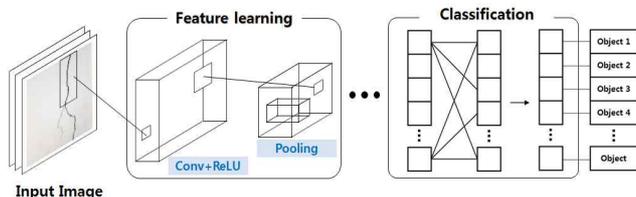


Figure 6. Structure of YOLOv2 network

##### 4.3 균열 특성정보 추출

###### 4.3.1 균열 형상 추출

균열 특성정보 추출 단계는 균열의 형상 추출과 더불어

균열의 폭, 길이와 같은 정량적인 정보를 추출하는 단계이다. 이를 위해 본 연구에서는 자체 개발한 함수와 함께 OpenCV함수를 활용하였다.

균열의 형상 추출의 기본이 되는 윤곽선(edge)은 다른 명암도를 가진 두 영역 사이의 경계로, 영상에서는 픽셀의 밝기가 임계값보다 크게 변하는 부분을 뜻하며, 이러한 윤곽선에 해당하는 픽셀을 추출하는 것을 윤곽선 검출(edge detection)이라고 한다.

본 연구에서는 윤곽선을 추출하기에 앞서 원본 컬러 영상을 흑백(gray scale)을 변환하여 영상을 보다 단순화시켜 복잡한 윤곽선 검출 연산 결과를 보다 빠르게 획득할 수 있도록 하였다. 또한, 윤곽선 검출에 앞서 흑백으로 단순화된 영상에 이웃 픽셀들의 값을 오름차순으로 정렬한 후 중앙에 있는 값으로 픽셀의 농도를 처리하는 원리의 중간값 필터(median filter)를 적용하여 영상의 임펄스 잡음(impulse noise)을 효과적으로 제거할 수 있도록 하였다.

다음은 임펄스 잡음까지 제거한 영상에서 소벨(Sobel), 프리윗(Prewitt), 로버트(Robert), 라플라시안(Laplacian)과 같은 윤곽선 검출 알고리즘을 사용하여 균열의 형상을 추출한다. 본 연구에서는 윤곽선 검출 전 잡음 제거 마스크를 사용하여 잡음에 강하고, 실제 윤곽선과 검출된 윤곽선의 픽셀 거리 차이를 최소화하면서, 다른 윤곽선 검출 연산자를 함께 사용하여 가장 명확하게 윤곽선을 검출할 수 있는 캐니 윤곽선 검출 알고리즘(Canny edge detector)을 사용하였다. 캐니 윤곽선 검출 알고리즘을 활용한 균열의 윤곽선을 추출과정은 다음과 같다.

- 가우시안(Gaussian) 필터로 영상을 평활화하여 잡음을 제거하고 소벨 연산자를 이용하여 윤곽선을 검출하고 기울기(gradient) 벡터의 크기(magnitude)를 계산한다.
- 가느다란 윤곽선을 검출하기 위하여 3×3 그리드를 사용하여 기울기 벡터 방향에서 크기가 최대값인 픽셀만 남기고 나머지 픽셀은 0으로 억제시킨다.
- 추출된 윤곽선들을 연결하기 위해 히스테리시스 임계값(hysteresis thresholding)을 활용하여 윤곽선을 연결한다.
- 추출된 윤곽선 좌표들의 수평방향과 수직방향의 평균 변화량을 구한 후 아크 탄젠트를 사용해서 현재 이미지에서 크랙의 기울어진 정도를 산출한다.
- OpenCV의 rotation함수(파이/2 - 기울기)를 이용해서 만큼 사진을 회전시킨 후, 세로로 정렬하여 균열의 형상을 그대로 출력한다.

###### 4.3.2 균열의 폭과 길이 추출

균열의 최대 폭과 길이와 같은 정량적인 정보를 추출하기 위해서는 균열 이미지와 함께 촬영된 실측정보를 알 수 있는 객체 즉, 영상 내 레퍼런스(reference)의 실측정보를 활용한다. 실험실 환경에서는 동일한 레퍼런스의 지정이 가능하지만, 실제 균열 조사 환경에서는 실측 크기를 정확하게 알 수 있는 레퍼런스가 존재하지 않는 경우가 발생할 수 있으므로 본 연구에서는 레이저 포인터를 이용하여 붉은 색 원(circle) 모양의 레퍼런스를 임의

적으로 생성하는 방식을 선택하였다.

레이저 포인터를 활용하여 생성한 붉은 원 모양의 레퍼런스를 포함하는 균열 이미지 레퍼런스가 이미지 내에서 차지하는 픽셀의 영역과 균열이 차지하는 픽셀 영역의 비율을 비교하는 방식으로 균열의 크기정보를 추출할 수 있다. 이를 위해서 먼저 레퍼런스를 추출하여야 하는데, 본 연구에서는 레퍼런스 추출을 위하여 OpenCV의 Inrange, Erosion, Dilation, Circle Hough Transform 함수를 이용하였으며, 각 함수는 다음과 같은 특징이 있다.

- Inrange는 이미지 내에서 R,G,B 색상 값 중에서 원하는 값만 추출할 수 있는 함수로, 이 함수를 이용하여 레퍼런스가 가진 색상 값을 추출한다.
- 모폴로지 연산의 팽창(Dilation)과 침식(Erosion)을 이용하여 레퍼런스의 경계를 보다 명확하게 추출한다. 팽창은 대상의 크기를 확장하고 배경을 축소하여 짧게 끊어진 영역을 연결시키는 역할을 하는 반면 침식은 반대로 대상의 크기를 축소시키고 배경을 확대하여 잡음 성분을 제거하거나, 다른 대상과의 닿은 부분을 분리하는 역할을 한다. 이러한 팽창과 침식을 반복하면 추출하고자 하는 레퍼런스의 경계를 뚜렷하게 할 수 있다.
- Circle Hough Transform은 원 모양의 객체를 추출하고 레퍼런스의 픽셀 수를 추출한다.

이와 같은 함수를 사용하여 레퍼런스를 추출한 다음에는 레퍼런스 영역의 픽셀(pixel)과 실측정보(mm)와의 비율을 계산하여 mm당 픽셀의 비율(pixel per mm)를 산출하여야 한다. 그리고 균열 영역의 폭과 길이에 해당하는 픽셀 수를 계산하고, 앞서 산출한 mm당 픽셀의 비율을 대입하여 균열의 폭과 길이의 실측치를 산출한다.

이 때, 균열 영역의 수평 수직 방향의 픽셀들의 평균과 표준편차를 구하여 편차 값을 넘는 픽셀은 제외시키는 작업을 수행하여 균열 영역이 아닌 노이즈를 제거하여 정확성을 높일 수 있다. 또한, 균열의 폭을 추출할 때, 균열 형상에서 동일한 높이와 동일한 방향의 균열 폭에 해당하는 픽셀들의 수를 구하고, 그 수가 가장 큰 값을 선택하면, 해당 균열의 최대 폭을 산출할 수 있다.

## 5. 검증

### 5.1 균열 여부 판단 모델 검증

본 연구에서 앞에서 제시한 딥러닝을 활용한 균열 여부 판단 모델의 사용성능을 검증하기 위하여 학습에 사용되지 않은 400장의 영상으로 검증을 진행하였다. 실험 결과, 다음 <Figure 7>과 같이 균열에 해당하는 영역에 경계박스로 표시됨을 확인하였다. 또한, 딥러닝 모델의 성능지표 중 정확도에 해당하는 mAP와 검출 속도에 해당하는 FPS는 <Table 6>과 같이 각각 74.3, 52로 도출되었다. 이는 평균적으로 74.3%의 정확도로 균열의 유무를 판단함과 동시에, 1초에 52개의 이미지

(프레임)을 분석할 수 있는 속도를 가지고 있다는 것을 의미한다.

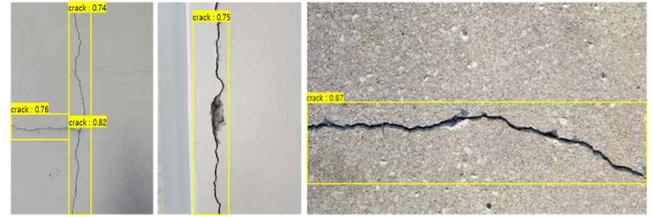


Figure 7. Deep Learning Experiment Results

Table 6. Crack Detection Performance

Test image	mAP	FPS
400	74.3	52

본 연구에서 활용한 YOLOv2 480×480 네트워크의 VOC 환경에서의 사용성능이 77.8 mAP, 59 FPS (Table. 3)라는 점을 고려했을 때, 본 연구에서 획득한 실험 결과는 충분히 의미가 있는 수치이다. 특히, 일반적으로 30 FPS가 실시간 분석의 가능 여부의 기준으로 여겨지고 있다는 점을 고려했을 때, 본 연구에서 진행한 실험의 결과는 52 FPS를 확보하여 실시간성을 확보하면서도, 약 75%의 검출 정확도를 확보했다는 점에서 의의가 있다.

### 5.2 균열 특성정보 추출 모델 검증

콘크리트 균열 여부 판단 모델을 거쳐 균열로 인식된 영상은 균열 특성정보 추출 모델에 입력되어 균열의 형상 및 최대 폭과 길이를 산출하는 과정을 거치게 된다. 이 과정의 사용성능을 검증하기 위해 본 연구에서는 테스트 영상으로 무작위로 추출한 15장의 균열 영상을 활용하여 실험을 진행하였다.

실험 결과, <Figure 8>와 같이 원 영상과 동일한 균열 형상을 추출해낼 수 있었다. 또한, <Table 7>과 같이 실제 육안조사 결과와 유사한 길이와 폭을 산출해 낼 수 있었다. 실제로 육안으로 조사한 결과와 본 연구에서 제시한 영상처리 기술을 활용하여 추출한 결과의 오차는 균열 폭은 평균 약 3%내외, 균열 길이는 평균 약 0.01% 내외로 분석되었다.

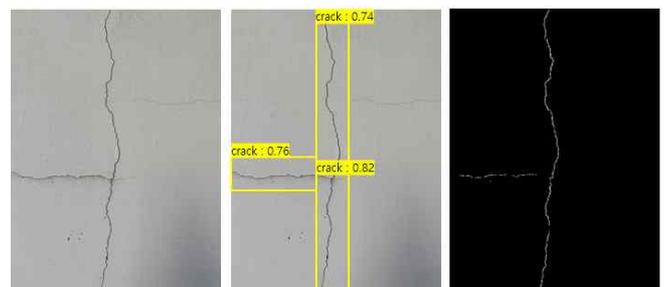


Figure 8. Crack shape extraction result

Table 7. Calculation result of crack width & length

No.	Width (mm)		Length (mm)	
	Image base inspection	visual inspection	Image base inspection	visual inspection
1	0.2	0.3	922	900
2	0.1	0.2	1267	1260
3	0.3	0.3	1548	1550
4	1.1	1.0	873	850
5	1.3	1.5	913	930
6	0.7	0.6	1308	1350
7	0.9	0.9	1549	1510
8	1.5	1.5	781	770
9	2.0	2.0	682	670
10	0.6	0.5	436	450
11	1.2	1.2	792	800
12	0.4	0.5	799	800
13	0.6	0.5	1128	1150
14	0.7	0.7	1019	1050
15	0.2	0.1	943	920

6. 결 론

기존의 일반적인 수준의 콘크리트 건축물의 균열 조사는 균열의 폭, 길이, 형상과 같은 조사항목을 점검자가 육안으로 관찰하는 방식으로 이루어지고 있어, 객관성 및 정확성 확보에 효율적이지 못하다. 이에 본 연구에서는 균열 조사 업무의 객관성과 효율성을 높이기 위한 노력의 일환으로 영상정보에 기반한 균열 검출 자동화 프로세스를 제시하였다. 본 연구의 결과는 다음과 같이 요약할 수 있다.

- 1) 영상 정보를 활용한 균열 검출 자동화를 위한 요구조건을 다음과 같이 도출하였다.
  - 영상으로부터 균열을 자동으로 인지하고, 영상 내 균열의 위치 검출이 가능해야 한다.
  - 균열 폭, 길이, 형상 추출이 가능해야 한다.
  - 실시간 영상 수집 기술과의 연계 및 확장성을 고려하여 실시간 분석이 가능한 성능을 확보해야 한다.
- 2) 위와 같은 요구조건을 고려하여 딥러닝을 활용한 균열 여부 판단 단계와 영상처리 기술을 이용한 균열 특성 정보 추출 단계로 구성된 영상 기반 균열 검출 자동화 프로세스를 제시하였다.
- 3) 균열 여부 판단 단계는 입력된 영상정보 속에 균열의 존재 유무를 확인하고, 균열이 존재한다면 영상 프레임 안에서 균열의 위치를 검출하는 단계이다. 이 때, 영상 내 균열의 위치 파악 및 실시간성 확보를 위하여 다양한 딥러닝 네트워크 중 YOLOv2를 선택하여 4,000장의 콘크리트 균열 영상과 1,000장의 균열과 유사한 형태를 갖는 비균열 영상으로 구성된 데이터 셋을 학습시켰다. 학습모델의 성능을 검증하기 위해 400장의 영상으로 테스트를 진행한 결과, 74.3 mAP와 52 FPS를 확보하여 VOC를 이용한 성능 테스트 결과와 유사한 수준의 정확도와 실시간 분석이 가능한 검출속도를 확보하였다.
- 4) 균열 특성정보 추출 단계는 자체 개발한 함수와 함께 OpenCV함수를 활용하여 균열의 형상정보와 더불어

폭과 길이와 같은 정량적 특성정보를 추출하는 단계이다. 15장의 테스트 영상을 활용하여 실험을 진행한 결과, 원영상과 동일하게 균열 형상을 추출할 수 있었으며, 실제 육안조사 결과와의 평균 오차는 균열 폭은 약 3%내외, 균열 길이는 평균 약 0.01%내외로 분석되었다.

기존의 유사 연구들이 주로 원 영상으로부터 균열을 인식하고 형상을 추출하는 것을 목적으로 둔 반면, 본 연구에서는 균열의 폭과 길이와 같은 정량적인 정보까지 추출할 수 있는 프로세스를 정립하였다는 점에서 기존 연구와 차별성을 가진다. 뿐만 아니라, 정지영상 뿐만 아니라 동영상에서 실시간 분석이 가능한 딥러닝 모델을 선택하여 기존의 유사 연구들이 고려하지 않은 실시간 영상 획득 기술과의 연계성 및 확장성을 고려하였다는 점에서 의의가 있다. 이러한 점을 고려했을 때, 본 연구의 결과는 추후 영상 기반 시설물 하자진단 자동화 시스템 개발의 기반이 될 것으로 기대되며, 향후 시설물 상태 점검 기술을 발전시키는데 활용 가능할 것이다.

향후 연구로는 신속하고 정확한 균열 검출 자동화 모델을 개발하기 위해서는 보다 많은 실험적 연구가 필요하며, 특히 딥러닝의 성능은 데이터셋과 훈련 환경에 영향을 많이 받기 때문에 데이터셋의 전처리, 필터의 수, 종류 및 크기를 적절하게 조정하는 연구가 필요할 것이다. 또한, 드론과 같은 영상획득기술과의 연계를 고려한 연구를 진행한다면 보다 이상적인 균열 검출 자동화가 가능할 것이다.

REFERENCES

1. Byun, T., Kim, J., & Kim, H. (2006). The Recognition of Crack Detection Using Difference Image Analysis Method based on Morphology, *Journal of the Korea Institute of Information and Communication Engineering*, 10(1), 197-205.
2. Cha, Y., Choi, W., & Oral, B. (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks, *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361-378.
3. Chen, L., Jan, H., & Huang, C. (2001). Mensuration of Concrete Cracks Using Digitized Close-Range Photographs, *The 22<sup>nd</sup> Asian conference of Remote Sensing*, 5-9.
4. Cho, S., Kim, B., & Lee, Y. (2018). Image-Based Concrete Crack and Spalling Detection using Deep Learning, *The Magazine of the Korean Society of Civil Engineers*, 66(8), 92-97.
5. Donglai, wei., Bolei, Whou., Antonio, Torralba., and William, T.Freema. (2015). "mNeuron: A Maltlab Plugin to Visualize neurons From Deep Models" <[http://vision03.csail.mit.edu/cnn\\_art/index.html](http://vision03.csail.mit.edu/cnn_art/index.html)>
6. Joseph, R., Santosh, Divvala., Ross, G., & Ali, F. (2016). You Only Look Once: Unified, Real-Time Object

- Detection, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788.
7. Joseph, R., & Ali, F. (2017). YOLO9000: Better, Faster, Stronger, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.
  8. Kim, A., Kim, D., Byun, Y., & Lee, S. (2018). Crack Detection of Concrete Structure Using Deep Learning and Image Processing Method in Geotechnical Engineering, *Journal of the Korean Geotechnical Society*, 34(12), 145-154.
  9. Kim, K., Cho, J., & Ahn, S. (2005). A Thechnique for Image Processing of Concrete Surface Cracks, *Journal of the Korea Institute of Information and Communication Engineering*, 9(7), 1575-1581.
  10. Kim, K., & Cho, J. (2010). Detection of Concrete Surface Cracks using Fuzzy Techniques, *Journal of the Korea Institute of Information and Communication Engineering*, 14(6), 1353-1358.
  11. Kim, J., & Cho, Y. (2002). Development of Crack Detection Program on Asphalt Pavement, *Journal of the Korean Society Of Civil Engineers*, 22(4D), 639-647.
  12. Kim, J., Jung, Y., & Rhim, H. (2017). Study on Structure Visual Inspection Technology using Drones and Image Analysis Techniques, *Journal of the Korean Institute of Building Construction*, 17(6), 545-557.
  13. K, Lenc., & A, Vedaldi. (2015). R-cnn minus r. arXiv preprint arXiv:1506.06981.
  14. Kim, Y. (2016). Development of Crack Recognition System for Concrete Structure Using Image Processing Method, *The Journal of Korean Institute of Information Technology*, 14(10), 163-168.
  15. Ko, K., & Sim, K. (2017). Trends in Object Recognition and Detection Using Deep Learning, *Journal of Institute of Control, Robotics and Systems*, 23(3), 17-24.
  16. Lee, B., Kim, Y., & Kim, J. (2005). Development of Image Processing for Concrete Surface Cracks by Employing Enhanced Binarization and Shape Analysis Technique, *Journal of the Korea Concrete Institute*, 17(3), 361-368.
  17. Lee, J., & Kim, K. (2007). Extraction and Analysis of Crack on Concrete Surfaces Using Improved Image Processing Techniques, *Proceeding of the Korea Intelligent Information Systems Society Conference*, 365-372.
  18. Lee, H., Kim, J., & Jang, I. (2012). Development of Automatic Crack Detection System for Concrete Structure Using Image Processing Method, *Journal of The Korea Institute for Structural Maintenance and Inspection*, 16(1), 64-78.
  19. R, B, Girshick. (2015). Fast R-CNN. CoRR, abs/1504.08083, 2015.
  20. Son, B., & Lee, K. (2017). Crack Recognition of Sewer with Low Resolution using Convolutional Neural Network(CNN) Method, *Journal of the Korean Society for Advanced Composite Structures*, 8(4) 58-65.
  21. Syed, I, H., Dang, L, M., Im, S., Min, K., Nam, J., & Moon, H. (2018). Damage Detection and Classification System for Sewer Inspection using Convolutional Neural Networks based on Deep Learning, *Journal of the Korea Institute of Information and Communication Engineering*, 22(3), 451-457.
  22. S, Ren., K, He., R, Girshick., & J, Sun. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. arXiv preprint arXiv:1506.01497.
  23. W. Liu, D. Anguelov, D. Erhan, C. Szegedy, & S. E. eed. (2015). SSD: single shot multibox detector. CoRR, abs/1512.02325.

(Received Jun. 4 2019 Revised Aug. 21 2019 Accepted Nov. 6 2019)