

# 통합 이미지 처리 기술을 이용한 콘크리트 교량 균열 탐지 및 매핑

김병현\* · 조수진\*\*†

## Crack Inspection and Mapping of Concrete Bridges using Integrated Image Processing Techniques

Byunghyun Kim\* · Soojin Cho\*\*†

### †Corresponding Author

Soojin Cho

Tel : +82-2-6490-2434

E-mail : soojin@uos.ac.kr

Received : November 23, 2020

Revised : December 22, 2020

Accepted : December 30, 2020

**Abstract** : In many developed countries, such as South Korea, efficiently maintaining the aging infrastructures is an important issue. Currently, inspectors visually inspect the infrastructure for maintenance needs, but this method is inefficient due to its high costs, long logistic times, and hazards to the inspectors. Thus, in this paper, a novel crack inspection approach for concrete bridges is proposed using integrated image processing techniques. The proposed approach consists of four steps: (1) training a deep learning model to automatically detect cracks on concrete bridges, (2) acquiring in-situ images using a drone, (3) generating orthomosaic images based on 3D modeling, and (4) detecting cracks on the orthomosaic image using the trained deep learning model. Cascade Mask R-CNN, a state-of-the-art instance segmentation deep learning model, was trained with 3235 crack images that included 2415 hard negative images. We selected the Tancheon overpass, located in Seoul, South Korea, as a testbed for the proposed approach, and we captured images of pier 34-37 and slab 34-36 using a commercial drone. Agisoft Metashape was utilized as a 3D model generation program to generate an orthomosaic of the captured images. We applied the proposed approach to four orthomosaic images that displayed the front, back, left, and right sides of pier 37. Using pixel-level precision referencing visual inspection of the captured images, we evaluated the trained Cascade Mask R-CNN's crack detection performance. At the coping of the front side of pier 37, the model obtained its best precision: 94.34%. It achieved an average precision of 72.93% for the orthomosaics of the four sides of the pier. The test results show that this proposed approach for crack detection can be a suitable alternative to the conventional visual inspection method.

**Key Words** : concrete crack, deep learning, orthomosaic, drone, cascade mask R-CNN

Copyright©2021 by The Korean Society of Safety All right reserved.

## 1. 서론

콘크리트는 저렴한 가격과 원하는 모양으로 성형할 수 있는 편리함으로 인하여 교량, 댐, 원자력 발전소와 같은 토목 인프라 및 건축 구조물에 가장 널리 활용되는 재료 중 하나이다. 그러나 콘크리트 구조물은 콘크리트의 재료적 특성으로 인하여 표면에 균열이 쉽게 발생하는 단점을 가지고 있다. 콘크리트 구조물의 균

열 발생 원인으로는 지속적인 하중에 의한 크리프 (Creep), 건조 과정에서 발생하는 건조수축, 그리고 환경적 요인에 의한 열화, 초과하중 등이 있다. 다양한 원인에 의하여 발생하는 콘크리트 균열을 관리하는 것은 콘크리트 구조물의 건전성을 관리하는데 필수적인 요소로 꼽힌다. 이로 인하여 콘크리트 구조물의 안전 진단을 수행할 때, 균열에 대한 외관조사를 필수적으로 실시하고 있다.

\*서울시립대학교 토목공학과 박사과정 (Department of Civil Engineering, University of Seoul)

\*\*서울시립대학교 토목공학과 부교수 (Department of Civil Engineering, University of Seoul)

콘크리트 구조물의 균열을 탐지하는 일반적인 방법은 검사자의 육안으로 관찰한 결과를 외관조사망도로 기록하는 것이다. 검사자에 의하여 관찰된 정보는 균열의 길이, 방향 및 폭을 포함하며, 이와 같은 정보는 외관조사망도에 기록되어 관리된다. 외관조사망도는 구조의 현재 상태를 평가하고 균열 성장을 추적하거나, 균열과 같은 손상의 유지 보수 계획을 지원하는 데 활용된다. 이러한 육안 검사 방법은 직관적인 방법으로서 많이 사용되고 있지만, 몇 가지 단점을 가지고 있다. 먼저, 육안 검사 방법은 검사자가 구조물을 직접 관찰하여 손상 정보를 파악해야 하기 때문에, 작업 시간이 많이 걸리며 비용이 높다. 또한 검사자가 현수교, 댐 그리고 교량 바닥판과 같이 접근이 어려운 부재에서 작업할 경우 사고 발생의 위험이 커진다. 따라서 육안 검사를 통해 급증하는 노후 구조물을 점검하고 관리하는 것은 시간, 인력, 비용 측면에서 비효율적이기 때문에, 이를 대체할 점검 기술 개발 노력이 지속되고 있다.

가장 활발하게 이루어지고 있는 노력으로는 컴퓨터 영상 기술을 이용한 방법을 들 수 있다<sup>1,2)</sup>. 최근 드론과 같은 무인기 기술의 발전으로 중저가의 상용 드론이 많이 보급되었으며, 드론에 장착된 카메라를 이용하여 촬영한 이미지는 토목공학 등 응용 분야에 다양하게 적용되고 있다. 예를 들어, 드론으로 촬영한 항공사진을 이용하여 구조물의 3차원 모델을 구성하는 기술<sup>3,4)</sup>이나, 도로 상태를 평가하는 기술 개발<sup>5,6)</sup> 등에 관한 연구 사례들이 활발히 보고되고 있다. 또한, 컴퓨터 영상 기술과 함께 드론을 사용하여 콘크리트 균열을 모니터링하는 연구 사례들도 보고되고 있다<sup>7,8)</sup>. 또한 일련의 이미지 처리를 이용하여 딥러닝 모델의 균열 탐지 결과로부터 균열의 폭을 추출하는 기술도 연구되었다<sup>8)</sup>.

하지만 기존의 드론을 이용한 구조물 진단 연구 사례들의 경우, 실제 공용중인 구조물에서 발생한 다양한 형태의 균열 탐지를 수행한 사례의 보고는 매우 드문 상황이다. 실제 구조물에서 균열 탐지를 수행한 연구들도, 균열 탐지 결과를 시각적으로 보여주었으나 그 전체 구조물에 대한 정확도를 파악하지는 않았다<sup>7,9,10)</sup>. 그러나 실제 구조물의 환경에서는 균열과 유사한 다양한 객체(Object)들이 존재하며, 이들과 균열을 분리하여 탐지하는 것은 생각보다 도전적(Challenging)한 연구이다.

본 연구에서는 실제 콘크리트 교량에서 영상 기반으로 균열을 탐지하고, 탐지된 균열 정보를 구조물의 실제 위치에 대응시키는 매핑(Mapping)을 통해 실제 구조물에서 균열정보(폭, 길이, 위치)를 시각적으로 확인할 수 있는 방법을 제안하였다.

본 연구에서 제안하는 프레임워크는 아래와 같은 차별성을 가진다. 첫째, Cascade Mask R-CNN<sup>11)</sup>을 이용하여 높은 정확도로 현장 환경에서 균열 탐지를 수행하였다. 기존 논문에서는 균열 탐지 단계가 1회 수행되었지만, 본 논문에서는 Cascade Mask R-CNN을 이용하여 균열 탐지 단계를 3단계에 거쳐 수행하여 높은 정확도를 가지게 된다. 둘째, Hard Negative Sample<sup>12,13)</sup>을 이용하여 높은 정확도로 현장에서 균열 탐지를 수행하였다. 기존 논문들의 학습 데이터셋은 단순히 균열과 배경을 포함하는 것과 달리, 본 논문의 Hard Negative Sample은 현장에서 발견되는 균열과 아주 유사한 물체들을 학습시켜 현장에서도 강건한 성능을 발휘하는 균열 탐지 모델 학습을 수행하였다. 마지막으로 통합 이미지처리 프로세스를 이용하여 End-to-End로 균열 탐지 결과를 보고할 수 있는 방법론을 제안하였다. 이 과정은 3D 모델링 소프트웨어를 이용하여 진행되었으며 3D 모델로부터 획득된 정사영상을 이용하여 탐지된 균열의 위치를 탐지 대상 교량에 성공적으로 매핑하였다. 제안된 방법을 실제 교량인 탄천2교가교 P37에 적용하여 성능을 검증하였다. 성능 검증은 직접 이미지에서 점검하여 찾아낸 균열과 딥러닝 모델을 이용하여 탐지한 균열을 픽셀단위로 비교하여 정밀도(Precision)을 계산하였다.

## 2. 본론

Fig. 1은 본 연구에서 제안한 균열 검출 방법의 전체 프레임워크를 보여준다. 제안된 프레임 워크는 (1) 균열탐지 딥러닝 모델 학습, (2) 드론을 이용한 실구조물 영상 촬영, (3) 교량의 3D 모델을 이용한 정사영상 획득 그리고 (4) 균열 탐지 결과 평가의 총 4단계로 구성된다. 본 장은 독자의 이해를 돕기 위하여 제안된 프레

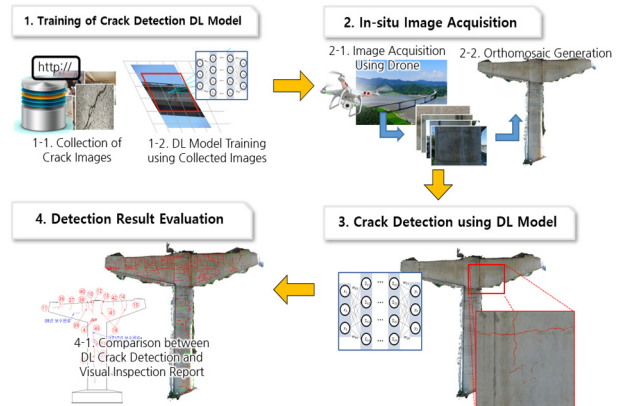


Fig. 1. Automated crack detection and mapping framework using integrated image processing.

임워크를 순서에 서술하며, 각 단계는 강인한(robust) 성능의 균열 탐지를 위하여 적용된 기술들을 중심으로 구성된다.

## 2.1 Cascade Mask R-CNN을 이용한 균열 탐지 모델

### 2.1.1 Cascade Mask R-CNN

본 논문에서는 Instance Segmentation Model 중 하나인 Cascade Mask R-CNN을 사용하여 균열을 탐지한다. 본 논문에서는 Cascade Mask R-CNN이 물체를 탐지하는 과정을 개념적으로 서술한다. Fig. 2에 묘사된 것과 같이 Cascade Mask R-CNN은 1) 이미지 내 특징 추출, 2) 물체 위치 탐지, 3) 픽셀 단위 물체 형상 추정의 총 3단계의 과정으로 구성되어 있다.

먼저 이미지 내의 특징 추출을 위해 모델은 Convolutional Neural Network (CNN)에 입력 이미지를 통과시킨다. CNN은 학습 가능한 가중치와 편향을 가진 필터의 집합이며, 입력 이미지에서 강조하거나 무시할 특징을 결정한다. CNN의 학습은 주로 Stochastic Gradient Descent<sup>14)</sup>와 같은 최적화(Optimization) 기법을 이용하여 진행된다. 본 논문에서는 ResNeXt-101<sup>15)</sup> 모델을 특징 추출 과정에 사용하였다. CNN에 의해 생성된 특징지도(Feature Map)는 다음 단계에서 Feature Pyramid Network (FPN)<sup>16)</sup>에 입력된다. 대부분의 CNN은 특징 추출 중에 입력 이미지의 해상도 감소를 일으키기 때문에, FPN은 크기를 줄이면서 손실 될 수 있는 공간 정보를 복원한다. FPN에서 추출한 특징지도는 크기가 다른 물체를 효율적으로 탐지하기 위하여 총 5가지의 다른 해상도를 가지는 특징지도로 복원된다.

Cascade Mask R-CNN은 CNN과 FPN으로 추출한 특징지도에서 물체를 탐지하고 탐지된 물체의 모양을 추정한다. 이 과정은 물체가 있는 후보 영역을 추천하는 Region Proposal Network (RPN)<sup>17)</sup>과 추천된 영역에서 각각 물체의 위치를 보정하는 2단계에 거쳐 물체의 위치를 추정하게 된다. RPN은 특징지도의 특정 좌표에

위치한 경계상자(Bounding Box) 내의 물체 존재 유무를 판단하는 Classification Layer와 경계상자의 크기 및 중심 위치를 보정하는 Regression Layer로 구성된다. 경계상자는 일반적으로 32픽셀에서 512픽셀 사이에서 가변하는 크기를 가지며 그 크기는 탐지 대상의 물체의 크기에 따라 조정이 가능하다. 물체를 포함하는 것으로 판단되는 경계상자는 물체의 종류(Class)를 분류하는 Box-Classification Layer와 Box-Regression Layer를 순차적으로 거쳐 최종적인 물체의 종류 및 물체의 위치를 반환한다. Cascade Mask R-CNN 본 단계를 총 3회 반복하여 진행함으로써 물체 분류 및 위치 추정을 더 높은 정확도로 수행한다. Cascade Mask R-CNN이 물체를 학습하는 과정에서 여러 크기의 경계상자가 사용되기 때문에, 다변하는 크기를 가지는 물체를 탐지할 때도 강건한(Robust) 성능을 보인다.

Cascade Mask R-CNN의 마지막 단계는 Mask Branch를 이용한 픽셀 단위 물체의 형상 추정이다. Mask Branch는 클래스에 관계없이 경계상자 내부의 물체의 형상에 대하여 학습된다.

### 2.1.2 Hard Negative Sample

일반적으로 물체 탐지 딥러닝 모델을 학습시킬 때, 탐지 대상 물체를 다수 포함한 데이터셋을 구축하는 것이 일반적이다. 하지만 실제 현장에서 딥러닝 모델을 이용하여 물체 탐지를 수행할 때, 탐지 대상 물체와 유사한 물체들이 발견될 수 있기 때문에 이들을 학습 데이터셋에 포함시킬 필요가 있다<sup>13)</sup>. 이러한 물체들은 일반적으로 Negative Sample이라 불리며 Negative Sample 중 탐지 대상 물체와 매우 유사한 물체들을 Hard Negative Sample이라 부른다<sup>12)</sup>. 본 연구에서는 Fig 3에 나타난 것과 같이 균열에 대한 Hard Negative Sample로 분류될 수 있는 나뭇가지, 시공이음부, 그리고 누수에 의한 얼룩 등의 이미지를 학습 데이터셋에 포함시켜 학습을 수행하였다. 총 2415장의 Hard Negative Sample 이미지를 수집하여 학습데이터에 포함시켰다. 단, 비균

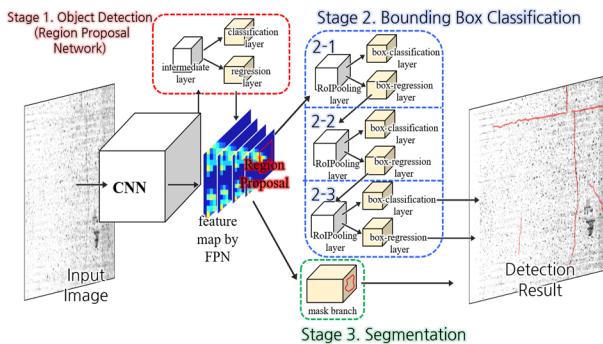


Fig. 2. Overall structure of cascade mask R-CNN.



Fig. 3. Examples of hard negative training images (Left: tree branches, right: construction joint).

열 이미지의 비중이 학습데이터에서 커지면 클래스 불균형(Class Imbalance)으로 인한 학습 성능 저하가 나타날 수 있기 때문에, 비균열 이미지에 아래 그림과 같이 균열 이미지를 합성하여 학습데이터를 생성하였다. 생성된 2415장에 의한 균열탐지 성능향상은 현장에서 촬영된 이미지를 이용한 균열 탐지 실험을 통하여 검증된다.

**2.1.3 균열 탐지를 위한 Cascade Mask R-CNN 학습**

위에서 제시한 방법론을 이용하여 구축한 학습데이터를 이용하여 Cascade Mask R-CNN을 학습시켰다. Cascade Mask R-CNN의 특징 추출은 ResNeXt-101과 FPN을 이용하여 이루어졌다. Cascade Mask R-CNN 구현체는 Pytorch 기반 Object Detection 딥러닝 모델 라이브러리인 MMDetection<sup>18)</sup>을 사용하였다.

학습은 2대의 Intel Xeon Processor와 3대의 Nvidia RTX Titan GPU가 탑재된 워크스테이션을 이용하여 진행하였다. 최적화 기법으로는 SGD가 적용되었으며, Learning Rate는 0.2, Momentum은 0.9 그리고 Weight Decay는 0.0001이 사용되었다. 학습에 이용된 Batch Size는 GPU 1대 당 2장의 이미지로 총 6장이 적용되었으며 학습데이터 전체에 대하여 총 12회 학습시켰다. 학습의 초기화(Initialization)는 Cascade Mask R-CNN의 특징 추출기인 ResNeXt-101에 대해서만 이루어졌으며, 초기 가중치 값은 ImageNet<sup>19)</sup>에 대하여 학습된 ResNeXt-101의 가중치가 사용되었다.

학습에 사용된 일반 균열 이미지 수는 총 820장이며 앞서 언급한 것과 같이 Hard Negative 균열 데이터 수는 2415장이다. Cascade Mask R-CNN은 일반 균열 데이터와 Hard Negative Sample을 전부 포함한 데이터셋을(3235장) 이용하여 학습된다. 학습된 모델의 성능은 실제 수집된 교량의 정사영상을 이용하여 평가된다.

**2.2 드론을 이용한 실교량 균열 이미지 취득**

본 연구에서 제안된 균열 탐지 프레임워크를 적용하고 성능을 검증하기 위하여 실제 구조물에서 드론을 이용한 구조물 이미지 획득을 진행하였다. 성능 검증에 필요한 균열 이미지 획득은 서울시설공단의 협조를 얻어 서울시 삼성동에 위치한 탄천2고가교 P34-37에서 진행하였다. 교각 이미지 촬영에는 DJI Mavic Pro2를 사용하였으며, 교각의 바닥판 촬영에는 Intel Falcon 8을 이용하여 진행하였다. 아래 표는 최종적으로 현장에서 취득한 균열 이미지의 수를 나타낸다.

Table 1에 기록된 것 같이 교각의 이미지 촬영은 2 m에서 8 m 사이의 거리를 두고 이루어졌다. 균열 탐지

를 위한 교각과 드론 사이의 촬영 거리를 계산하기 위하여 핀홀 모델(Pinhole Model)을 사용하였다. 카메라 핀홀 모델은 피사체와 렌즈 사이의 거리(촬영거리), 렌즈와 이미지 센서 사이의 거리(초점거리) 그리고 이미지 센서의 크기를 이용하여 이미지에서 한 픽셀이 나타내는 길이를 구하는 방법이다<sup>20)</sup>. 핀홀 모델의 수식은 Eq.(1)과 같이 나타낼 수 있다.

$$L_p = \frac{10D_w}{P_c L_f} \tag{1}$$

여기서  $L_p$ 는 픽셀 당 길이,  $P_c$ 는 이미지 센서의 ppcm (pixel per centimeter),  $L_f$ 는 초점거리 그리고  $D_w$ 는 카메라와 피사체 사이의 촬영거리를 나타낸다. 촬영거리가 4 m일 때 DJI Mavic Pro의 ppcm은 4275 pixel/cm, 초점 거리는 28 mm이므로 픽셀 당 길이는 0.33 mm가 된다. 따라서 최소 4 m 이내의 거리에서 촬영을 수행하여야 0.3 mm 균열을 높은 정확도로 탐지할 수 있다. 또한 드론을 이용하여 교각을 촬영하였을 때, 2 m 이내로 접근하여 촬영하면 기체가 교각에 충돌할 위험이 높아지며 교각 전체를 이미지로 촬영하기 위한 이미지 수가 많아지기 때문에 권장되지 않는다. 본 연구에서는 2 m 거리를 두고 이미지를 촬영하였을 때, 각 교각

**Table 1.** Number of images captured by drone at Tancheon overpass (W.D. is short for working distance)

| Pier 34    |       |      |       |      |
|------------|-------|------|-------|------|
| W.D.       | Front | Left | Right | Back |
| 4 m        | 100   | 37   | 39    | 109  |
| 8 m        | -     | 19   | 45    | -    |
| Pier 35    |       |      |       |      |
| W.D.       | Front | Left | Right | Back |
| 4 m        | 106   | 58   | 40    | 91   |
| 8 m        | -     | 33   | 48    | -    |
| Pier 36    |       |      |       |      |
| W.D.       | Front | Left | Right | Back |
| 2 m        | 173   | 72   | 103   | 112  |
| 3 m        | -     | 70   | -     | -    |
| 8 m        | 53    | -    | -     | 138  |
| Pier 37    |       |      |       |      |
| W.D.       | Front | Left | Right | Back |
| 2 m        | 177   | 113  | 76    | 237  |
| 5 m        | 87    | 11   | 12    | -    |
| Slab       |       |      |       |      |
| Location   | S34   | S35  | S36   | -    |
| No. Images | 412   | 205  | 1200  | -    |

의 전면부 기준 최소 170장 정도의 이미지를 촬영하여야 했다. 8 m 거리를 두고 교각 이미지를 촬영할 시, 교각의 3D 모델을 구축하는데 필요한 이미지수는 현저하게 적어지지만 균열 탐지 정확도 확보에는 어려움이 발생하는 것을 확인하였다. 따라서 본 연구에서는 2 m의 촬영거리로 이미지 촬영이 이루어진 P37에 대하여 최종적으로 균열 탐지 정확도를 검증하였다.

### 2.3 3D 모델링 기술을 이용한 교량 정사영상

드론을 이용하여 취득된 이미지를 이용하여 교량에서 균열 발생 위치를 확인하기 위한 교량의 정사영상(Orthomosaic)을 획득한다. 단일 교량 이미지로부터 교각과 바닥판의 정사영상을 구하는 과정은 상용 Structure from Motion 프로그램 Metashape<sup>21)</sup>을 이용하여 진행되었다. Metashape을 이용하여 정사영상을 획득하는 과정은 Fig. 4와 같이 총 4단계로 진행된다.

먼저 1단계에서 수집된 이미지의 특징점을 추출하고 각 이미지 사이에 매칭(Matching)되는 특징점을 연결하는 방식으로 3차원 공간상의 Point Cloud를 형성한다. Point Cloud는 일반적으로 좌표계에 나타난 점들의 집합을 가리키는데, 여기서는 물체의 표면을 나타내기 위한 요소로 사용된다. 최초 구성된 Point Cloud는 일반적으로 컴퓨팅 시간을 절약하기 위하여 낮은 밀도로 구성된다. 따라서 2단계에서 Dense Point Cloud를 형성하여 더 밀도가 높은 Point Cloud를 제작한다. 2단계의 Dense Point Cloud가 정사영상을 획득하는데 필수적인 요소는 아니지만, 3단계의 3D 모델의 Mesh의 품질향상에 직접적인 관련이 있으므로 Dense Point Cloud의 이용이 권장된다. 3단계에서는 획득된 Dense Point Cloud로부터 3D 모델의 Mesh(Polygon Mesh)를 형성한다.





Fig. 4. Overall procedure for bridge orthomosaic generation.



(a)



(b)

Fig. 5. Orthomosaic of (a) slab 34 and (b) Pier 35.

Mesh는 Point Cloud 정보에 표면 정보를 더한 3D 모델이다. 마지막 4단계에서는 구축된 3D Mesh의 표면 정보를 2D 공간에 투영(Projection)시켜 2D 이미지를 획득하게 된다. 정사영상은 3D Mesh를 2D 공간에 투영한 뒤, 각 Mesh의 요소가 원본 단일 이미지에 대응되는 위치를 추적하여 해당되는 위치의 이미지 정보를 모자이크 형태로 부착시킨다. Fig. 5는 본 연구에서 사용된 바닥판 정사영상(S45)과 P35의 전면부를 나타낸 것이다. 정사영상을 이용하지 않고 개별 이미지에서 탐지된 균열 정보는 균열의 위치를 파악할 수 없어 오히려 검사 과정에 혼돈을 유발할 수 있다. 하지만 아래와 같은 형태로 정사영상을 구축하고 균열 탐지 결과를 매핑하면 사용자가 더 편리하게 손상의 위치를 확인할 수 있다는 장점이 있다. 또한 구축된 정사영상에서 손상의 이미지 정보는 최종적으로 외관조사망도의 형태로 변환될 때 사용된다. 정사영상을 획득하는 과정에서 3D의 교각 표면이 2D 평면에 투영되며 약간의 공간 정보가 약간 손실 될 수 있지만, 교각의 입체적인 형상은 전후좌우의 4가지 평면에 투영되기 때문에 정확한 투영 결과를 얻을 수 있다.

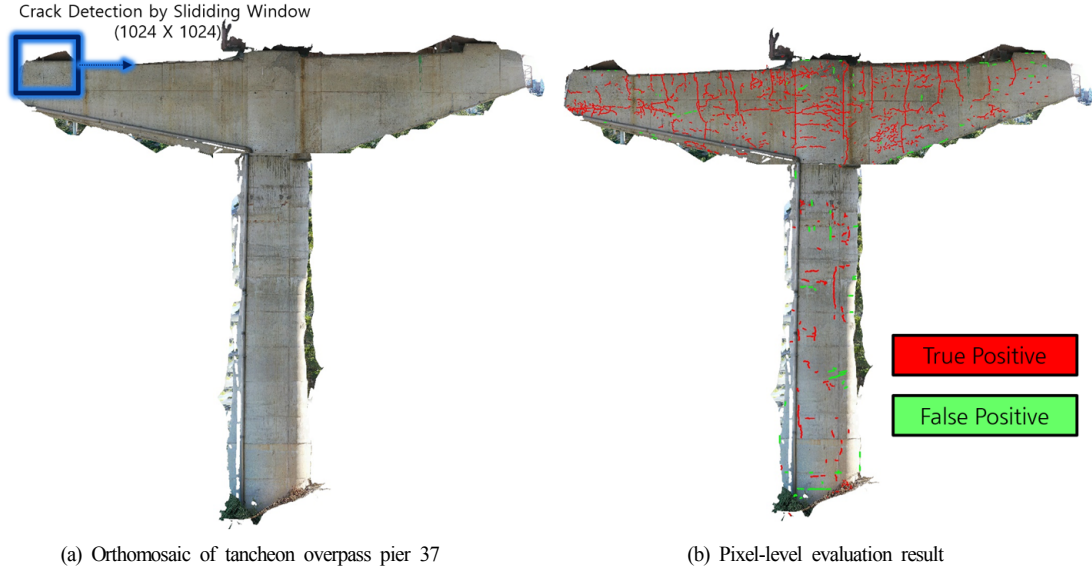


Fig. 6. Crack detection result visualization.

## 2.4 학습된 딥러닝 모델 균열 탐지 성능 평가

최종적으로 획득한 정사영상에서 학습된 딥러닝 모델을 이용하여 균열 탐지를 수행하였다. 정사영상에서 수행되는 균열 탐지는 아래 그림과 같이 전체 이미지를 1024×1024 크기의 슬라이딩 윈도우(Sliding Window)를 이용하여 탐지되게 된다<sup>22)</sup>. 이는 최근 개발된 딥러닝 모델들이 일반적으로 한 번에 처리할 수 있는 해상도의 크기가 1000×1000에서 2000×2000으로 나타나기 때문이다. 전체 이미지에 슬라이딩 윈도우 방식을 이용하여 균열 탐지를 수행한 뒤, 균열 영역에 지정된 색깔(e.g. 붉은색)을 이용하여 표기한다.

딥러닝 모델을 이용한 균열 탐지 성능평가는 픽셀 단위 정밀도를 이용하여 진행되었다. 균열 탐지의 성능평가가 이루어진 교각은 0.3 mm 폭의 균열도 탐지가 가능할 정도의 품질로 이미지가 취득된 탄천2교가교의 교각 P37을 대상으로 수행하였다. 바닥판의 경우 정사영상이 어둡게 촬영되었을 뿐 아니라 촬영거리가 멀어 0.3 mm 폭의 균열을 충분한 해상도로 촬영할 수 없었기 때문에 정량화를 진행하지 않았다. 이는 바닥판에 직사광선이 비치지 못할 뿐 아니라, 거더와 거더 사이로 드론이 비행할 수 없기 때문에 발생한 촬영 기술상의 한계점이다.

Fig. 6은 탄천2교가교 P37 후면부의 정사영상을 이용한 균열 탐지 결과이다. 붉은색으로 표시된 영역은 정탐지(True Positive)를 나타내며, 초록색으로 표시된 영역은 오탐지(False Positive)를 나타낸다. 정탐지와 오탐지의 판단을 위하여 정사영상에서 진행한 균열탐지 결과를 이미지상에서 육안으로 확인하고, 픽셀 단위로




Fig. 7. Crack detection evaluation example: (a) Original image of concrete crack and (b) pixel-level precision calculation (red area : true positive, green area: false positive).

정탐지, 오탐지 여부를 구분하였다. 픽셀 단위 정밀도 측정 예시는 Fig. 7에 나타나 있다. Fig. 7(b)는 Fig. 7(a)의 균열 이미지에서 균열 탐지를 수행한 후 픽셀 단위로 정탐지와 오탐지를 표기한 그림이다. 전체 이미지는 10×10 픽셀로 분할되어 있다고 가정되었다. 남색 테두리로 표기된 부분은 딥러닝 모델에 의하여 균열로 판단된 픽셀이며 빨간색으로 표시된 영역은 정탐지, 그리고 초록색으로 표시된 영역은 오탐지를 나타낸다. 정탐지와 오탐지의 표기는 토목공학 전공자에 의하여 수행되었으며, 이미지에서 육안으로 확인하여 균열 탐지 결과가 실제 균열과 겹치는지 확인하는 방식으로 진행되었다. 정밀도 계산식은 Eq.(2)에 나타난 것처럼 정탐지를 정탐지와 오탐지의 합으로 나누고 백분율로 표기하는 방식이다. 아래 식에서 TP는 정탐지의 수, FP는 오탐지의 수를 나타낸다. Fig. 7의 예시에서는 정탐지의 수가 13개, 오탐지의 수가 3개이므로 정밀도는 81.25%가 된다. 이와 같은 절차로 P37 전면부, 후면부,

좌측부 우측부에 대하여 균열탐지 성능평가를 수행하였다.

$$\text{Precision}(\%) = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100 \quad (2)$$

Table 2는 픽셀단위로 수행한 정밀도 측정 결과이다. 전체 이미지의 평균 픽셀당 거리(mm/pixel)은 0.77 mm로 나타났다. 전체 5개의 교각 부재(Member) 중(전면부의 경우 코핑부와 기둥부 분리) 0.3 mm의 균열을 탐지하기에 충분한(0.3 mm/pixel 이하의) 픽셀 단위 해상도를 가지는 이미지는 없었으나, 좌측부가 0.43 mm/pixel으로 가장 높은 픽셀 단위 해상도를 보였다. 전체 균열 탐지 결과 중 가장 높은 정확도를 보인 영역은 전면부 코핑이었으며 정밀도는 94.34%로 나타났다. 가장 낮은 정확도를 보인 영역은 좌측부로 58.25%의 정확도를 보였다. Table 2에 나타난 균열 탐지 결과를 통하여 픽셀 단위 해상도도 중요하지만 구조물 이미지 촬영 품질이 정확도에 더 큰 영향을 미치는 것을 확인하였다. 전체 균열 탐지 정밀도의 평균은 72.93%로 나타났다. 실험 결과를 통하여 Cascade Mask R-CNN의 물체 탐지 과정은 가변하는 물체의 크기에 강건한(Robust) 성능을 발휘하도록 설계되었지만, 낮은 해상도를 보이는 이미지에서는 비교적 낮은 정확도를 보일 수 있음을 확인하였다.

본 논문의 균열 탐지 정밀도는 평균 72.93%로 현장에서 사용 가능하지만 아직 정밀도 개선의 여지가 있음을 보였다. 드론을 이용한 콘크리트 교각 이미지 촬영에 채택된 촬영거리 2-4 m는 DJI Mavic의 호버링(정지비행)의 수평 범위 정확도 ±1.5 m에 매우 근접한 거리이다. 따라서 본 논문의 이미지 촬영은 비행 안정성을 확보할 수 있는 최소한의 거리에서 촬영이 이루어졌음을 보인다. 이는 본 논문이 현재 기준으로 드론을 이용한 균열 탐지 현장 적용 중 최대한 확보 가능한 해상도에서 실험을 진행하였음을 뒷받침한다.

Table 2. Pixel-level precision of the trained cascade mask R-CNN (Compared with inspection report)

| Side    | Image resolution | mm/pixel    | Precision (%) |       |
|---------|------------------|-------------|---------------|-------|
| Front   | Coping           | 40236×11813 | 0.52          | 94.34 |
|         | Pier             | 7348×18262  | 0.54          | 61.83 |
| Left    |                  | 9102×24048  | 0.43          | 58.25 |
| Righth  |                  | 6294×20978  | 0.63          | 67.10 |
| Back    |                  | 28272×27261 | 0.74          | 83.15 |
| Average |                  |             | 0.77          | 72.93 |

### 3. 결론 및 고찰

본 연구에서는 실제 콘크리트 교량에서 취득한 영상을 이용하여 정사영상을 획득하고, 정사영상에서 학습된 딥러닝 모델을 이용하여 균열을 탐지함으로써 균열 정보를 구조물의 실제 위치에 매핑시키는 자동 균열 탐지 프레임워크를 제안하였다. 균열 탐지 딥러닝 모델을 구축하기 위하여 Cascade Mask R-CNN을 Hard Negative Sample이 포함된 3235장의 균열 데이터셋을 이용하여 학습시켰다. 학습된 균열 탐지 딥러닝 모델의 성능을 평가하기 위하여 드론을 이용하여 서울시 삼성동에 위치한 탄천2교가교의 P34-37 사이의 교각 및 바닥판 이미지를 촬영하고 각 부재의 정사영상을 3D Point Cloud를 이용하여 획득하였다. 학습된 Cascade Mask R-CNN의 성능은 P37 교각의 정사영상에서 검증되었으며 정밀도는 최대 94.34%, 평균 72.93%로 나타났다. 해당 과정에서 딥러닝 모델의 균열 탐지 정확도를 확보하기 위하여 픽셀당 실제거리 뿐 아니라 드론 이미지의 품질 역시 중요함을 확인하였다. 결과적으로 본 연구에서 제안된 드론, 3D 영상 그리고 딥러닝 기술을 이용한 균열 탐지 Framework는 균열 탐지에 있어서 수준 높은 정밀도를 보였으며, 앞으로 교량 검사 절차 효율화에 기여할 수 있음을 확인하였다.

본 논문에서 개발된 균열 탐지 Framework의 결과로부터 아래와 같은 후속 연구 주제들을 기대할 수 있다. 첫째, 제안된 Framework가 기존 외관조사망도보다 더 정밀하게 균열을 탐지할 수 있기 때문에 정사영상에 매핑된 균열이 구조적 균열인지 비구조적 균열인지 판단하기 용이할 것이다. 둘째, 본 연구에서는 균열 탐지만 진행했지만 추후에는 다른 열화에 따른 표면 손상 학습도 추가적으로 수행하여 더 사용성이 높은 Framework를 개발할 수 있다.

또한 본 논문에서 수행된 실험 중 확인된 일부 한계를 극복하기 위한 연구를 수행할 수 있다. 첫째, 드론의 이미지 센서의 성능 개선을 통한 추가적인 이미지 촬영 해상도 개선을 수행할 수 있다. 둘째, 현재 정사영상을 이용하여 균열을 매핑하는 과정에서 일부 인력이 필요한 과정이 있는데 이 과정을 자동화하는 연구를 수행할 수 있을 것이다. 셋째, 균열 탐지 모델 자체의 성능을 개선하는 연구를 수행할 수 있다. 추가적인 데이터 확보를 통한 균열 탐지의 범용성 향상도 가능하며 균열 탐지에 활용되는 시간을 단축하는 연구를 수행할 수 있다. 후속 연구를 통하여 구조물 안전진단의 많은 요소들이 자동화된다면 구조물 안전진단 중 발생하는 안전사고를 최소화 할 수 있으며, 신속한 구조물 안전진단에도 기여할 수 있을 것으로 판단된다.

**Acknowledgement:** 본 연구는 2020년도 정보(과학기술정보통신부)의 재원으로 한국정보통신진흥원의 지원을 받아 수행되었습니다. (과제명: 국가인프라 지능정보화 사업 - 인공지능 기반 시설물 안전진단)

## References

- 1) T. Nishikawa et al., "Concrete Crack Detection by Multiple Sequential Image Filtering", *Computer-Aided Civil and Infrastructure Engineering*, Vol. 27, No. 1, pp. 29-47, 2012.
- 2) B. Kim and S. Cho, "Efflorescence Assessment Using Hyperspectral Imaging for Concrete Structures", *Smart Structures and Systems*, Vol. 22, No. 2, pp. 209-221, 2018.
- 3) E. Ridolfi et al., "Accuracy Analysis of a Dam Model from Drone Surveys", *Sensors*, Vol. 17, No. 8, p. 1777, 2017.
- 4) S. Goessens et al., "Feasibility Study for Drone-Based Masonry Construction of Real-Scale Structures", *Automation in Construction*, Vol. 94, pp. 458-480, 2018.
- 5) G. Leonardi et al., "Road Degradation Survey through Images by Drone", *Smart Innovation, Systems and Technologies*, Vol. 101, pp. 222-228, 2019.
- 6) R. Fan et al., "Real-Time Dense Stereo Embedded in a UAV for Road Inspection", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2019.
- 7) H. Kim et al., "Concrete Crack Identification Using a UAV Incorporating Hybrid Image Processing", *Sensors*, Vol. 17, No. 9, p. 2052, 2017.
- 8) Y. Liu et al., "Deep Learning-Based Enhancement of Motion Blurred UAV Concrete Crack Images", *Journal of Computing in Civil Engineering*, Vol. 34, No. 5, p. 04020028, 2020.
- 9) Y. Li and C. Liu, "Applications of Multirotor Drone Technologies in Construction Management", *International Journal of Construction Management*, Vol. 19, No. 5, pp. 401-412, 2019.
- 10) Z. Cai and N. Vasconcelos, "Cascade R-CNN: High Quality Object Detection and Instance Segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019.
- 11) B. Kim and S. Cho, "Image-Based Concrete Crack Assessment Using Mask and Region-Based Convolutional Neural Network", *Structural Control and Health Monitoring*, Vol. 26, No. 8, p. e2381, 2019.
- 12) B. Hariharan et al., "Discriminative Decorrelation for Clustering and Classification", *European Conference on Computer Vision*, Vol. 7575 LNCS, No. PART 4, pp. 459-472, 2012.
- 13) B. Kim and S. Cho, "Development of Automatic Input Negative Sample Algorithm for Improving Crack Detection Deep Learning Model", *Proceedings of Korea Institute for Structural Maintenance and Inspection*, vol. 23, no. 2, p. 125, 2019.
- 14) J. Kiefer et al., "Stochastic Estimation of the Maximum of a Regression Function", *The Annals of Mathematical Statistics*, Vol. 23, No. 3, pp. 462-66, 1952.
- 15) S. Xie et al., "Aggregated Residual Transformations for Deep Neural Networks", *Proceedings-30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Vol. 2017-Jan., pp. 5987-5995, 2017.
- 16) T. Y. Lin et al., "Feature Pyramid Networks for Object Detection", *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Vol. 2017-Jan., pp. 936-944, 2017.
- 17) S. Ren et al., "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, 2017.
- 18) K. Chen et al., *MMDetection: Open MMLab Detection Toolbox and Benchmark*. <http://arxiv.org/abs/1906.07155>, 2019.
- 19) J. Deng et al., "ImageNet: A Large-Scale Hierarchical Image Database", *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Institute of Electrical and Electronics Engineers (IEEE), pp. 248-255, 2009.
- 20) Y. Liu et al., "Automated Assessment of Cracks on Concrete Surfaces Using Adaptive Digital Image Processing", *Smart Structures and Systems*, Vol. 14, No. 4, pp. 719-741, 2014.
- 21) Agisoft, *Agisoft Metashape*, <https://www.agisoft.com/>, 2020.
- 22) B. Kim and S. Cho, "Automated Vision-based Detection of Cracks on Concrete Structures Using a Deep Learning Technique", *Sensors*, Vol. 18, p. 3452, 2018.