

Research Paper

딥러닝 기반 픽셀 단위 콘크리트 벽체 균열 검출 방법

Deep Learning-based Pixel-level Concrete Wall Crack Detection Method

강경수¹ · 류한국^{2*}

Kang, Kyung-Su¹ · Ryu, Han-Guk^{2*}

¹Assistant Professor, Department of Architecture, Sahmyook University, Nowon-Gu, Seoul, 01795, Korea

²Professor, Department of Architecture, Sahmyook University, Nowon-Gu, Seoul, 01795, Korea

*Corresponding author

Ryu, Han-Guk

Tel : 82-2-3399-1853

E-mail : hryu@syu.ac.kr

Received : December 14, 2022

Revised : January 31, 2023

Accepted : March 16, 2023

ABSTRACT

Concrete is a widely used material due to its excellent compressive strength and durability. However, depending on the surrounding environment and the characteristics of the materials used in the construction, various defects may occur, such as cracks on the surface and subsidence of the structure. The defects on the surface of the concrete structure occur after completion or over time. Neglecting these cracks may lead to severe structural damage, necessitating regular safety inspections. Traditional visual inspections of concrete walls are labor-intensive and expensive. This research presents a deep learning-based semantic segmentation model designed to detect cracks in concrete walls. The model addresses surface defects that arise from aging, and an image augmentation technique is employed to enhance feature extraction and generalization performance. A dataset for semantic segmentation was created by combining publicly available and self-generated datasets, and notable semantic segmentation models were evaluated and tested. The model, specifically trained for concrete wall fracture detection, achieved an extraction performance of 81.4%. Moreover, a 3% performance improvement was observed when applying the developed augmentation technique.

Keywords : concrete crack, deep learning-based computer vision, semantic segmentation, image augmentation

1. 서론

콘크리트는 압축력에 잘 저항하고 내구성이 우수하여 고층 건물이나 아파트를 건설할 때 널리 사용되는 재료이다. 콘크리트로 마감한 건축물은 불, 물, 전기적 충격에 강하고 내수성이 높아 내부환경을 안정적으로 유지할 수 있다. 하지만 구조물은 시공 단계에서 주변 환경과 사용되는 재료의 특성에 따라 완공된 후 표면의 균열, 구조물의 침하 등 다양한 결함이 발생할 수 있다. 또한, 시간이 지남에 따라 콘크리트 구조물은 외벽·내벽 할 것 없이 노후화로 인해 결함이 발생한다. 콘크리트 구조물의 노후화 종류는 균열, 박리, 층분리, 박락, 백태, 충돌손상, 누수 등이 있다. 콘크리트 구조물 표면에 노후화로 인해 발생하는 균열을 방치하였을 경우, 균열이 커져 벽이 탈락해 건물 단지 내로 떨어져서 인명피해를 입힐 수 있고, 비나 습기가 균열 틈새로 들어가 철근을 부식시켜 안전을 위협하게 하는 요인이 될 수 있다. 이처럼 콘크리트의 균열이 생기는 원인은 다양하며 균열이 생기는 것을 늦추는 방법은 있으나 완전히 예방하는 방법은 없다. 따라서 균열이 발생했는지 주기적으로 검사해 균열을 찾아 초기에 조치해야 한다[1-3].

구조물의 상태를 파악하기 위해 균열 조사는 안전 점검 및 정밀안전진단에 필수적인 검사 항목이다. 콘크리트 구조물의



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

표면에 있는 균열을 조사할 때 점검자가 직접 건물을 돌아다니면서 육안으로 조사하는 방법을 주로 사용된다. 이러한 방법은 많은 시간이 걸릴뿐더러 고층 건물이거나 사람의 접근성이 떨어지는 구역일 경우 검사하기 매우 어렵다. 또한, 점검자의 주관이 개입되어 검사 결과가 주관적일 수 있고, 미세균열은 사람의 눈으로 탐지하기 어렵다[4,5].

최근 딥러닝의 발전으로 기존의 많은 인력과 시간이 소모되는 방법을 대체하기 위해 컴퓨터비전 기법을 적용하여 표면의 균열을 자동으로 탐지하려는 움직임이 일고 있다. 딥러닝 기반 컴퓨터비전 기법을 이용하면 이미지나 영상에서 외벽의 균열을 탐지할 수 있는데 이를 이용해 구조물 표면의 균열을 탐지하는 방법으로는 이미지 분류(image classification)와 이미지 세그멘테이션(image segmentation) 방식을 주로 사용한다. 이미지 분류 방식을 사용하면 이미지에서 균열의 존재 여부만 확인할 수 있지만, 이미지 세그멘테이션 방식을 사용하면 균열의 존재를 이미지에서 어느 위치에 균열이 생겼는지 픽셀 단위로 확인할 수 있다[5-9].

본 연구는 균열의 존재와 위치를 카메라로 촬영한 영상에서 컴퓨터가 자동으로 검출하는 성능을 확인하고자 시맨틱 세그멘테이션(semantic segmentation)을 적용해 콘크리트 구조물 벽체 균열을 검출하고 균열의 강도를 표현하고자 한다. 또한, 대표적인 시맨틱 세그멘테이션 모형의 콘크리트 균열 검출 성능을 비교 실험한다. 그리고 학습 단계에서 픽셀 단위의 균열 강도를 강건하게 학습해 일반화 성능을 높일 수 있는 시맨틱 세그멘테이션용 이미지 어그멘테이션(augmentation) 기법을 제안한다.

2. 이론적 고찰

딥러닝이 적용된 현대적 컴퓨터비전 기술을 적용하여 콘크리트 건물 외벽 균열 탐지하는 시도는 점차 늘어났으며, 이를 이용한 콘크리트로 마감된 벽체의 균열을 탐지하는 방법은 크게 세 가지로 분류할 수 있다. 첫째, 이미지 분류 기술을 사용한 방법이다. 이미지 분류 기술이란 한 장의 이미지 전체를 컴퓨터가 분석하여 해당 이미지의 클래스가 어디에 속하는지 분류해주는 기술이다. Lee et al.[10]은 균열 데이터셋 구축을 위해 웹 스크래핑을 사용하여 콘크리트 벽의 사진을 수집했다. 수집한 데이터를 바탕으로 딥러닝 기반 이미지 분류 모형인 InceptionV3[11]로 학습하였고, 학습한 모형으로 이미지 내에 균열 검출을 시도하였다. Seol et al.[12]은 표면 데이터셋을 낮, 밤, 그림자, 녹슨 표면, 버그홀과 같이 다양한 환경에서 검출이 가능한 데이터셋을 구축하고 여덟 종류의 이미지 분류 모형을 학습하여 콘크리트 균열 검출 성능 비교실험을 진행하였다. 둘째, 객체 탐지 방식을 적용한 연구들은 다음과 같다. 객체 탐지 기술이란 이미지에서 객체의 좌표정보를 경계 상자(bounding box)로 추정하고, 그 경계 상자가 어떠한 클래스에 속하는지 예측하는 기술이다. Jung et al.[13]은 실시간 추론이 가능한 객체 탐지기인 YOLOv2(you only look once)[14]를 사용하여 경계 상자를 이용해 균열의 위치 정보를 추출하고 탐지된 균열의 폭과 길이를 구하기 위해 전통적인 컴퓨터비전 기술들을 활용했다. 폭과 길이를 측정하기 위해 RGB(red green blue) 이미지를 흑백 이미지로 색상공간을 변환하고 미디언 필터(median filter)를 적용하여 임펄스 잡음을 제거하고 캐니 윤곽선 검출 알고리즘을 사용해 윤곽선을 추출했다. 또한, 레이저 포인터를 활용하여 이미지 내에서 차지하는 픽셀의 영역과 균열이 차지하는 비율을 계산해 균열의 크기를 추출했다. 셋째, 이미지 세그멘테이션 기술을 사용한 연구들이다. 이미지 세그멘테이션 기술이란 모든 픽셀의 클래스를 예측하여 같은 픽셀끼리 분류하는 기술로, Lee et al.[15]은 GeoAI기반 시스템에 중요한 공간정보인 도로 위 장애물 및 노면 파손 유무를 딥러닝으로 찾기 위해 인스턴스 세그멘테이션(instance segmentation) 모형인 Mask R-CNN(region-based convolutional neural networks) 모형을 사용해 도로 내 균열을 예측했다. 또한, Yamane and Chun[16] 콘크리트 표면의 균열을 Mask R-CNN 모형으로 검출하였다. Kim et al.[17]은 시맨틱 세그멘테이션 모형인 U-Net으로 콘크리트 균열 이미지를 정상 이미지로 복원한 뒤 두 이미지 간의 차이를 통해 콘크리트의 균열을 탐지하는 방식을 사용했다. 또한, 적은 양의 데이터를 늘리기 위해 마스킹 된 균열 이미지와 균열이 없는 일반 이미지를 합쳐 다양한 균열

이미지를 생성했다. Ha et al.[18]은 도로에서 발생하는 대표적인 다섯 가지 결함 종류인 거북등균열(alligator), 종방향균열(longitudinal), 횡방향균열(transvers), 포트홀(pothole), 패칭(patching)을 기존 방법론보다 정확하게 탐지하기 위해 시맨틱 세그멘테이션과 객체 탐지 모형을 결합하고 다양한 비교실험을 진행하였다. 시맨틱 세그멘테이션 모형인 U-Net을 사용하여 거북등, 종방향, 횡방향균열을 학습한 모형과 포트홀과 패칭을 학습한 모형 두 가지 모형을 구축하였다. 학습된 두 가지 모형은 컬러 이미지를 바이너리 이미지 결과물을 반환하며 다시 결과물을 객체 탐지 모형인 SSD(single shot multibox detector)의 입력 데이터로 사용해 균열의 다섯 가지 종류와 위치를 추출하였다. Panella et al.[19]은 U-Net을 기반으로 비용 함수인 Dice와 Focal loss를 적용하고 모형의 아키텍처 변경을 통해 학습 데이터에 따른 균열의 탐지 성능을 비교 실험하였다. 하지만 기존 연구들은 균열 탐지의 성능을 높이기 위해 여러 모형을 조합해 파이프라인을 구성하거나, 균열의 강도를 추출하기 위해 후처리 알고리즘을 적용하여 상태를 측정하였다. 파이프라인을 구성할 시 이미지 분류, 객체 탐지, 이미지 세그멘테이션 등 모형을 여러 단계별로 결합한 시스템의 경우 컴퓨팅 연산과 느린 추론 속도로 인한 단점이 있다. 예를 들어, 시맨틱 세그멘테이션 모형 하나만으로 외벽의 여러 결함을 동시에 픽셀별 분류가 가능하기 때문에 단계별 컴퓨터비전 모형을 구축할 필요가 없고, 모형이 추론한 마스크를 통해 영상 내 균열의 위치를 경계 상자로 변환할 수 있다. 또한, 인스턴스 세그멘테이션으로 학습하면 마스크와 경계 상자를 동시에 학습할 수 있다. 따라서 본 연구는 CNN 기반에서 픽셀 분류 성능이 다른 모형에 비해 상대적으로 높고 널리 사용되고 있는 DeepLabV3+ 모형을 사용하여 단일 모형을 통해 콘크리트 벽체의 결함 중 균열과 균열의 강도 그리고 균열을 강건하게 학습할 수 있는 이미지 어그멘테이션 방법을 제안하고자 한다.

3. 연구방법론

본 연구는 콘크리트 벽체 표면에서 균열의 위치와 픽셀 단위에서 균열의 강도를 추출하기 위한 연구 절차는 Figure 1과 같다. 공개된 균열 데이터셋과 자체적으로 수집한 데이터셋을 조건에 맞게 병합하여 하나의 데이터셋으로 구축한다. 딥러닝 모형 학습 단계에서 균열의 검출 성능과 일반화 성능을 끌어올리기 위해 이미지 어그멘테이션 기법을 개발한다. 추론 단계에서 학습된 시맨틱 세그멘테이션 모형의 가중치를 통해 자체적으로 수집한 데이터를 이용해 균열을 픽셀마다 강도를 0~1 사이 값으로 예측하고 정규화하여 정답 데이터와 평가한다. 이후 대표적인 시맨틱 세그멘테이션 모형들을 비교실험하고, 제안한 이미지 어그멘테이션의 성능을 측정한다.




Figure 1. Flowchart depicting the deep learning-based semantic segmentation for concrete crack

3.1 딥러닝 기반 콘크리트 균열 검출 방법

3.1.1 이미지 세그멘테이션

전통적인 컴퓨터비전에서 이미지 세그멘테이션은 이미지나 비디오를 분석해 객체를 인식하기 위해 픽셀을 세분화하는 기술이다. 이를 통해 컴퓨터는 이미지 내에 있는 객체의 정보를 추출할 수 있다. 예를 들어, 우리 눈에 특정 객체는 배경과 영

역이 구별되어 해당 객체에 대한 정보를 인식한다. 컴퓨터 또한 영상에서 여러 개의 영역으로 세분화하여 각 영역의 비슷한 속성(색, 패턴)을 분석해 의미 있고 해석하기 쉬운 것으로 단순화해 객체의 경계선을 찾는 데 사용된다. 영상 분할은 컴퓨터 비전의 중요한 기술로 다양한 응용 분야에서 사용되고 있다.

2012년 AlexNet[20]을 시작으로 딥러닝이 본격적으로 전통적인 컴퓨터비전 기술에 적용되기 시작하면서 영상 분할도 급격하게 발전되고 있다. 딥러닝이 적용된 영상 분할은 시맨틱 세그멘테이션과 인스턴스 세그멘테이션 등으로 나눈다. 시맨틱 세그멘테이션은 이미지를 픽셀이 어떤 객체에 속하는지 분류하는 기술이다. 예를 들어, 이미지 내에 사람, 빌딩, 나무 등의 객체를 구분하고 각 픽셀에 이들 객체에 속하는지 클래스로 세분화해 조밀한 예측(dense prediction)이라고도 한다. 픽셀 단위의 정보를 활용할 수 있어 높은 활용성이 주목받는 기술이다. 개체 분할은 영상에서 존재하는 각 개체의 위치를 추출하고 개체들을 시맨틱 세그멘테이션과 같이 영역을 구분하는 기술이다. 시맨틱 세그멘테이션과 달리, 인스턴스 세그멘테이션은 이미지 내에 존재하는 객체를 개체 단위로 개별적으로 구분하고 세분화한다[21,22]. 예를 들어, 시맨틱 세그멘테이션은 영상에서 사람이 여러 명이더라도 한 사람으로 인식하지만, 인스턴스 세그멘테이션은 여러 명을 개별적으로 인식한다.

시맨틱 세그멘테이션은 다른 컴퓨터비전 모형들과 마찬가지로 CNN을 적용해 많은 발전이 이루어졌다. 전통적인 컴퓨터 비전에서 FCN(fully convolutional networks)으로 end-to-end로 시맨틱 세그멘테이션이 가능해졌다. AlexNet과 VGGNet은 CNN으로 공간/위치에 대한 정보를 학습하다가 마지막 클래스 분류에서 FCL(fully connected layer)로 CNN을 거친 압축된 정보들을 상실한다. 이러한 문제를 FCN으로 1×1 CNN으로 바뀌면서 이미지 크기에 대한 제한을 받지 않고, 즉, 어떤 사이즈의 이미지를 네트워크에 입력될 수 있으며 입력이미지의 위치 정보를 대략적으로 유지할 수 있다. 또한, CNN을 거치고 마지막 특성맵의 수는 훈련된 클래스의 수와 동일하다. 다섯 개의 클래스로 훈련된 네트워크라면 다섯 개의 특성맵을 산출한다. FCN은 이러한 CNN으로 구성된 모형으로 특징을 압축하고 마지막 레이어에서 전치된(transposed) CNN을 통해 압축된 CNN을 다시 원본 이미지 크기로 업샘플링하여 인풋이미지와 같은 크기의 특성맵을 생성한다. 이후 발전하여 U-Net이 개발되었다. U-Net이란 의료영상처리를 위해 제안된 end-to-end 방식의 FCN 기반 시맨틱 세그멘테이션 기술이다. 제안된 네트워크의 구성 형태는 U로 생겨서 U-Net이란 이름이 붙여졌다[23,24]. 딥러닝 모형의 출현으로 의학 분야의 X-ray, MRI 등에서 딥러닝의 도움을 통한 분석이 증가하고 있다. 의료 연구에서는 자동화된 현미경 실험으로 몇 테라바이트에 달하는 이미지가 생성되는데, 이에 대해 각 이미지에 대해 시맨틱 세그멘테이션 방법을 통해 셀(cell)과 셀 구성 요소를 분류했다. 결과적으로 U-Net의 구조를 활용하여 아주 적은 양의 학습 데이터만으로 데이터 어그멘테이션을 활용하여 여러 생의학적 영상 분할 문제(biomedical image segmentation problem)에서 우수한 성능을 보여주었다. U-Net은 U자형 아키텍처와 고차원 형태의 이미지를 저차원 형태의 이미지로 변경시켜주는 인코더(encoder)와 인코딩 된 이미지를 다시 원래 형태로 변환해주는 디코더(decoder) 구조를 가지고 있다. 특히 기본적인 오토인코더(auto-encoder) 구조에서 인코더에서 축약된 정보를 디코더에 연결해서 사용하는 특징을 갖는데, 이러한 과정으로 인해 기존 오토인코더 과정에서 활용하지 못했던 공간 정보를 얻을 수 있다는 장점이 있다. 최근 시맨틱 세그멘테이션 모형들은 CNN 기반이 아닌 트랜스포머(transformer) 기반으로 개발되어 기존보다 모형의 성능이 뛰어나지만, 많은 파라미터로 인해 학습을 위한 컴퓨팅 자원이 매우 높고, 적은 데이터로 학습이 힘든 단점이 있다[25]. 따라서 본 연구는 기존 U-Net 기반의 시맨틱 세그멘테이션 모형이 아닌 팽창된 CNN을 적용해 보다 넓은 수용영역을 학습하고 보조 비용 함수를 통해 적은 양의 데이터셋으로도 강건하게 학습할 수 있는 CNN 기반의 DeepLabV3+를 적용하였다.

3.1.2 DeepLabV3+

DeepLab 구조는 2015년 구글에서 제안한 시맨틱 세그멘테이션 모형으로, 현재 DeepLabV3+까지 개발되었다. 첫 번째 모형에서 기존 CNN에서 확장된 개념인 팽창(dilated; atrous) CNN을 적용하면서 이를 발전해 multi-scale context를 학습하

기 위해 ASPP(atsrous spatial pyramid pooling)를 제안하고 ResNet(residual neural network) 구조에 이를 활용하기도 하였다. DeepLabV3+는 DSC(depthwise separable convolution)과 팽창 CNN을 결합해 ASC(atsrous seprable convolution)을 제안하였다[26,27]. 해당 CNN은 이미지 분류나 객체 탐지에서 사용되는 신경망들은 시맨틱 세그멘테이션에 이용할 때 여러 번의 CNN과 풀링계층(pooling layer)을 거치면서 특징이 점점 추상화되는 단점이 있었다. FCN의 경우 잔차 연결(skip connection layer)을 통해 해결했지만, 수용영역(receptive field)이 고정되어 다양한 크기(scale)의 객체에 대응하기 힘든 단점이 존재한다. 이를 위해 연구팀은 ASC를 개발해 수용영역을 넓게 가져가면서 정보의 손실을 최소화할 수 있어 보다 좋은 해상도의 결과물을 추출할 수 있었다. DSC는 기존 CNN이 공간차원(spatial dimension)과 채널차원(channel dimension)을 동시에 처리하던 것을 따로 분리시켜 처리하는 방법이다. 기존 CNN 연산과 비교했을 때 사용하는 파라미터 수와 연산량을 획기적으로 줄여 해상도에 영향을 많이 받는 시맨틱 세그멘테이션 모형의 효율적인 학습과 추론이 가능해졌다. DeepLabV3 구조는 다음 Figure 2와 같다. DeepLabV3는 인코더-디코더 구조로 인코더를 거친 특징맵(feature map)을 바이리니어 업샘플링(bilinear upsampling)을 통해 특징맵의 높이와 너비를 네 배 키운다. 동시에 중간 층의 특징맵(low-level features)을 1×1 CNN을 적용하여 채널(channel)의 크기를 줄인다. 이를 합쳐 3×3 CNN으로 연산한 후 마지막 1×1 CNN을 거쳐 출력물(output)을 반환한다. 다시 원본 이미지의 크기로 복원하기 위해 업샘플링을 수행해 픽셀 단위로 클래스를 출력한다[28].

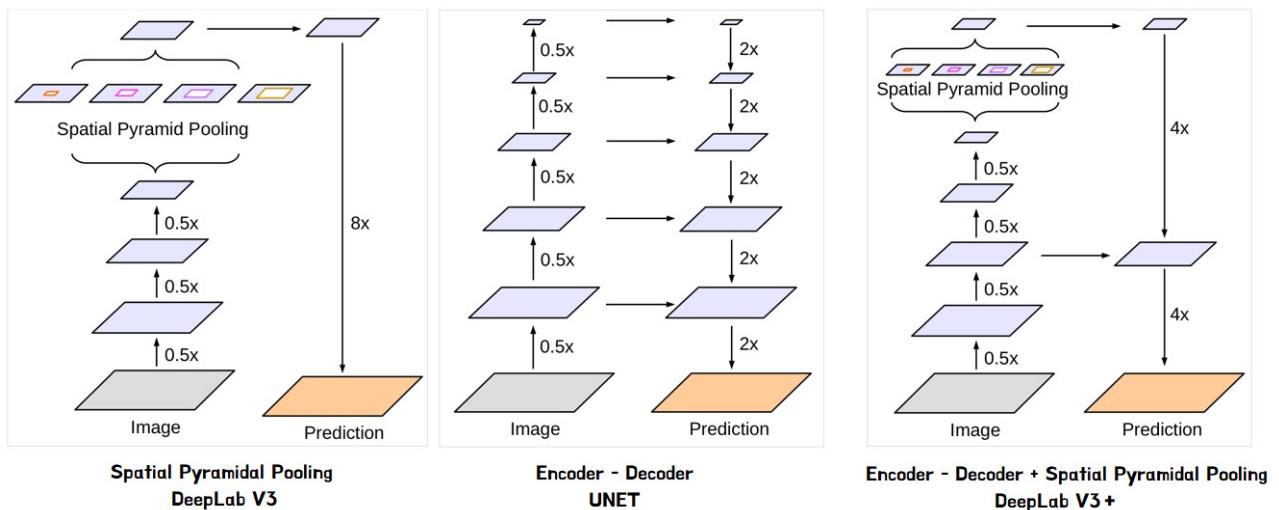


Figure 2. Architecture of DeepLabV3+ network(Adapted from Chen et al.[28])

3.2 콘크리트 균열 데이터

3.2.1 콘크리트 균열 데이터셋

딥러닝 모형을 통해 균열을 탐지하는 데이터셋은 대개 두 가지 접근방법이 있다. 구획화를 통해 균열의 위치만 추출하는 이미지 분류 또는 객체 탐지 기반 방식[10,12,13,29]과 픽셀을 통해 균열의 형태를 폴리곤 마스크로 추출하는 시맨틱 세그멘테이션 방법[5,18,30]이 있다. 콘크리트 균열은 객체 탐지 모형을 사용해 위치를 추출하는 것도 중요하지만, 균열의 강도를 추정하는 것도 매우 중요하다. 본 연구에서 시맨틱 세그멘테이션 기술에서 단일 모형을 이용해 콘크리트 균열 검출을 위하여 기존 공개된 데이터셋과 자체 구축한 데이터셋을 합쳐 딥러닝 모형 학습하고자 한다. 현장에서 직접 촬영한 콘크리트 내 벽외벽을 촬영한 사진과 웹 크롤링을 통해 콘크리트 균열 이미지를 다운받아 균열을 마스킹하여 레이블 데이터를 만들었다. 또한, 머신러닝 경진대회 사이트인 캐글에 공개된 균열 세그멘테이션 데이터셋에서 중복된 이미지를 제거하고 589장을 추

출하고, 자체 데이터셋 540개를 합쳤다. 이렇게 만들어진 데이터는 총 1,129개 학습용 960개 평가용 169개로 구성했다. 해당 데이터는 이미지 크기가 캐글 데이터셋이 448×448이며 자체 데이터셋은 직접 촬영한 이미지 4K, 웹 크롤링 이미지는 최소 크기는 460 픽셀에서 최대 2K이다. 수집한 이미지 크기를 일괄적으로 512×512로 조정하였다. 균열 어노테이션 작업은 포토샵으로 미세균열을 직접 레이블링하여 이미지 정규화를 통해 균열만 추출해 0~255 값으로 마스킹하였다. 또한, 일반화 성능을 높이기 위해 데이터셋 내에는 균열 데이터와 비균열 데이터가 같이 포함되어 있다. 콘크리트 벽체 표면 균열 검출을 위해 구축한 데이터셋을 시각화하면 다음과 Figure 3과 같다.




Figure 3. Dataset used for semantic segmentation

3.2.2 이미지 어그멘테이션

본 연구에서 시맨틱 세그멘테이션 모형의 균열 검출 성능을 올리기 위해 다양한 딥러닝 모형 학습전략 중 이미지 어그멘테이션 기법을 개발하였다. 모든 경우의 수의 콘크리트 균열 이미지와 레이블된 데이터를 구축할 수 없기 때문에 데이터를 증강하여 딥러닝 학습에 사용할 수 있다. 어그멘테이션은 기존 데이터의 정보량을 보존한 상태로 노이즈를 주는 방식이다. 정보량에 약간의 변화를 주어 딥러닝 모형 학습에서 데이터가 표현하는 고유의 특징을 느슨하게 만들어 과적합(overfitting)을 막아주고 예측 범위를 넓혀준다. 보통 이미지 어그멘테이션엔 이미지 크기 조정(resize), 이미지 각도 회전(scale), 이미지 좌우변환(flip), 회전(rotate), 등이 있다. RGB 색상을 변경하거나 기하학적 변환을 통해 데이터의 특징을 변환함으로써 딥러닝 예측 정확성과 일반화 성능을 올릴 수 있다[31,32]. 먼저 본 데이터셋은 0~255 수치의 2차원 마스크 행렬이 있어, 균열 이미지에서 균열만 추출해 다른 이미지에 가상으로 균열을 생성할 수 있다. 0~255 2차원 행렬에서 픽셀 명암 평균 값으로 노멀라이즈해 바이너리 마스크를 생성해 원본 이미지의 균열 위치와 특징을 추출해 균열 특징이 없는 이미지에 균열을 추가한다. 두 번째, 어그멘테이션은 YOLOv4에서 최초로 제안된 모자이크 어그멘테이션(mosaic augmentation)에서 영감을 받아 세그멘테이션용으로 개발하였다. 모자이크 어그멘테이션을 직관적으로 살펴보면 다음 Figure 4와 같다. 모자이크 어그멘테이션은 네 개의 이미지를 하나로 합치는 방식이다. 각기 다른 이미지와 마스크를 지정된 입력 크기에 맞게 비율을 고려해 한장의 이미지로 합쳐진다. 모자이크 어그멘테이션은 한장의 이미지 안에 네 개의 특징을 한번 학습으로 딥러닝 모형이 학습한다. 이때 모자이크 어그멘테이션은 배치 정규화(batch normalization)의 통계량(statistics) 계산에 좋은 영향을 줄 수 있다. 기존 배치 정규화에서는 작은 배치 크기(batch size)를 사용하면 학습 안정성이 떨어져서 이를 개선하기 위해 그룹 정규화(group normalization) 등이 제안되었는데, 모자이크 어그멘테이션을 이용하면 배치가 네 배 커지는 효과를 볼 수 있다 [33,34].




Figure 4. Illustration of mosaic augmentation technique for semantic segmentation

4. 실험 결과 및 논의

4.1 콘크리트 균열 검출 모형 학습 결과

본 연구는 콘크리트 내벽 균열을 탐지하기 위해 다양한 모형을 학습하였다. 딥러닝 모형 학습 환경은 다음과 같다. Intel Xeon 프로세서(E5-2620)과 NVIDIA RTX A4000(16GB) 그래픽 카드 네 대가 장착된 워크스테이션을 사용하였다. 콘크리트 균열 탐지용 모형 구현에는 딥러닝 프레임워크 PyTorch, 파이토치에서 컴퓨터비전 구현을 위한 도구들을 사용할 수 있는 TorchVision, 파이토치의 학습과 추론 과정을 고수준(high-level)로 구현할 수 있는 PyTorch Lightning을 사용하였다. 또한, 딥러닝의 학습 도중에 지정된 횟수만큼 더 이상 성능 개선이 없을 때 학습을 멈추는 EarlyStopping을 사용해 학습 과정 동안 10번 이상 성능 개선에 변화가 없다면 종료하는 조건을 추가하였다. DeepLabV3+ 모형 학습에 사용한 하이퍼 파라미터는 이미지 크기 640×640이며, 이미지 정규화에서는 ImageNet 데이터셋을 학습한 가중치를 사용했기 때문에 RGB 채널 [0.485, 0.456, 0.406]과 표준편차 [0.229, 0.224, 0.225]를 사용하였다. 학습과정에 SGD(stochastic gradient descent) 최적화와 학습률은 $1e-4$ 로 진행하였다. 학습된 모형을 평가하기 위해서는 캐글 데이터셋이 아닌, 자체 구축한 데이터셋에서 추출한 이미지만 사용하여 콘크리트 균열 검출용 시맨틱 세그멘테이션 모형의 성능 비교를 수행하였다. 비교에 사용한 모형은 FCN, U-Net, DeepLab이며 백본(backbone)을 ResNet-50과 101 두 가지로 구성하였다. 콘크리트 균열 데이터셋을 학습한 시맨틱 세그멘테이션 모형들의 평가지표는 mIoU(mean intersection of union)와 MSE(mean square error)이며, 각 모형의 추론 시간은 FPS(frames per second)를 측정하였다. 콘크리트 균열 추출 모형의 성능 평가를 위해서는 균열 라벨 데이터는 0~255에서 0과 1 사이로 정규화한 실수를 사용한다. 학습한 모형은 균열을 단순히 정수값으로 세분화하는 것이 아닌, 강도에 따라 0에서 1사이의 값으로 예측할 수 있게 유도한다. 자체 평가 데이터셋과 예측된 균열 마스크의 히트맵은 Figure 5와 같다.




Figure 5. Visualization obtained from trained semantic segmentation model

히트맵으로 시각화한 균열 마스크는 0에서 1 사이의 값으로 균열의 밝기가 표현된다. 밝은 곳은 균열이 심한 곳이며, 열어 질수록 균열이 아닌 곳으로 판정한다. 시맨틱 세그멘테이션 모형 학습 시 마지막 추론에서 0과 1 사이의 값으로 변화가능한 시그모이드 활성화 함수를 사용해 학습시켰다. 그리고 평가는 0.5 임계값을 사용해 작은 잡음들을 제거하였다. 예를 들어, 0.21과 같은 수치는 잡음으로 판단해 제거하는 것이다. 또한, 본 연구에서는 잡음 제거를 위해 연속적으로 연결되지 않은 픽셀을 제거하는 방법을 사용했다. 윈도우 크기 별로 커널을 만들고 이미지와 합성곱 수행을 한 결과 특정 크기 이하의 균열 모양과 같이 연결되어 있지 않은 잡음들을 제거한다. mIoU 평가지표는 예측된 마스크 값은 0~1 사이 값을 그대로 사용하고 0.5 임계 값을 주고 정답 데이터는 균열이 있는 경우 1로 변환하여 평가하였다. 또한, MSE는 학습과 정답 데이터의 정규화된 수치인 0~1 사이 값 그대로 사용하였다. 콘크리트 균열을 픽셀 단위로 예측하기 위한 딥러닝 기반 시맨틱 세그멘테이션 모형들의 학습결과는 다음 Table 1과 같다. 특징 추출기를 ResNet-101로 학습한 DeepLabV3+ 모형의 mIoU 임계값을 0.0, 0.3, 0.5, 0.7을 적용한 mIoU 변화량은 각각 0.323, 0.417, 0.814, 0.532으로 가장 높은 성능을 보인 임계값 0.5를 기준으로 설정하였다. 시맨틱 세그멘테이션의 대표적인 모형들을 백본 변경을 통해 비교 실험한 결과, DeepLabV3+와 ResNet-101로 학습한 모형이 픽셀 단위별 균열의 강도를 세부적으로 0.814 mIoU로 가장 잘 예측하였다.

Table 1. Performance comparison to CNN-based state-of-the-art models on the concrete crack dataset(512x512) at a threshold of 0.5

Model	Backbone	mIoU	MSE
FCN	ResNet-50	0.558	0.119
	ResNet-101	0.610	0.102
UNet	ResNet-50	0.743	0.056
	ResNet-101	0.799	0.043
DeepLabV3+	ResNet-50	0.782	0.041
	ResNet-101	0.814	0.031

4.2 콘크리트 균열용 이미지 어그멘테이션 결과

딥러닝 모형 학습 단계에서 일반화 성능과 미세한 콘크리트 균열 검출 성능을 높이기 위해 이미지 어그멘테이션 기법을 적용한 실험결과는 Table 2와 같다. 베이스라인은 ResNet-101을 백본으로 사용한 DeepLabV3+ 모형이다. 표의 첫 번째는 어그멘테이션을 사용하지 않고 학습한 결과물이며, 두 번째 행부터 가짜 균열, 모자이크 균열, 그리고 둘 다 사용해 베이스라인 모형을 학습한 결과들이다. 원본 이미지에 확률적으로 가짜 균열을 추가하거나 균열을 삭제하는 방법과 모자이크 어그멘테이션 성능은 각각 베이스라인 대비 약 1.35% 성능향상이 있었다. 딥러닝 학습과정에서 두 가지 모두 사용한 경우 약 2.91%의 성능 향상을 보였다. 결과적으로 균열 검출용 모형을 강건하게 학습하기 위해 제안한 이미지 어그멘테이션 기법이 하지 않는 것보다 더 나은 결과를 보였다.

Table 2. Effect of different training strategies on testset: fake crack, remove crack, and mosaic crack augmentation(DeepLabV3+ with ResNet-101 as backbone)

Fake crack	Mosaic crack	mIoU	MSE
		0.814	0.031
✓		0.825	0.025
	✓	0.829	0.024
✓	✓	0.838	0.019

5. 결론

본 연구는 콘크리트 노후화로 인해 발생하는 결함인 표면에 발생하는 균열을 탐지하여 안전 검사를 위한 비용과 시간 절감을 위해 딥러닝 기반 시맨틱 세그멘테이션 모형과 이미지 어그멘테이션을 개발하였다. 최신 영상 분석에서 활발하게 활용되는 대표적인 CNN 기반 시맨틱 세그멘테이션 모형의 균열 검출 성능을 비교 분석하였다. 총 1,129개의 이미지를 사용해 콘크리트 표면에 생긴 균열의 강도를 픽셀 단위로 분류하였다. 성능 비교 결과는 다음과 같다. 첫째, CNN 기반 모형 중 ResNet-101 백본을 사용한 DeepLabV3+ 모형의 성능이 가장 좋았으며 균열의 위치와 균열의 강도를 잘 표현하였다. 둘째, 가짜 균열과 YOLOv4의 모자이크 어그멘테이션에서 영감을 받아 개발한 모자이크 어그멘테이션은 베이스라인 모형보다 약 3%의 성능향상을 보였다. 현장에서 실제 균열의 형상을 매우 근사하여 탐지할 수 있음을 확인하였다. 이미지 크기에 따라 모형의 성능이 확연히 달라지며, 좋은 탐지 결과를 얻기 위해서는 근접촬영이나 줌렌즈를 이용해 고해상도 이미지를 비교·분석해야 할 필요가 있다. 향후 연구에서 고층 건물과 접근성이 떨어지는 외벽 검사 구역에 드론을 통해 균열을 탐지하고, 깊이 카메라를 이용해 균열의 폭과 길이를 측정할 수 있게 촬영거리를 통해 픽셀을 실제 길이로 환산하여 측정할 수 있는 시스템을 개발하고자 한다.

요약


콘크리트는 압축력에 잘 저항하고 내구성이 우수하여 널리 사용되는 재료이다. 하지만 구조물은 시공 단계에서 주변 환경, 사용되는 재료의 특성에 따라 완공된 후 표면의 균열, 구조물의 침하 등 다양한 하자가 발생하거나 시간이 지남에 따라 콘크리트 구조물 표면에 결함이 발생한다. 그대로 방치하면 구조물에 심각한 손상을 초래하기 때문에 안전 점검을 통해 검사해야 한다. 하지만 전문 검사원들이 직접 조사하기에 비용이 높고 육안으로 판단하는 외관 검사법을 사용한다. 고층 건물 일수록 상세한 검사가 힘들다. 본 연구는 노후화로 인해 콘크리트 표면에 발생하는 결함 중 균열을 탐지하는 딥러닝 기반 시맨틱 세그멘테이션 모형과 해당 모형의 특징 추출과 일반화 성능을 높이기 위한 이미지 어그멘테이션 기법을 개발하였다. 이를 위해 공개 데이터셋과 자체 데이터셋을 결합하여 시맨틱 세그멘테이션용 데이터셋을 구축하고 대표적인 딥러닝 기반 시맨틱 세그멘테이션 모형들을 비교실험하였다. 콘크리트 내벽을 중심으로 학습한 모형의 균열 추출 성능은 81.4%이며, 개발한 이미지 어그멘테이션을 적용한 결과 3%의 성능향상을 확인하였다. 향후 고층 건물과 같이 접근성이 어려운 지점을 드론을 통해 콘크리트 외벽에서 균열을 검출할 수 있는 시스템을 개발함으로써 실질적으로 활용할 수 있기를 기대한다.


키워드 : 콘크리트 균열, 딥러닝 기반 컴퓨터비전, 시맨틱 세그멘테이션, 이미지 어그멘테이션

Funding

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government (MSIT)(No. 2022R1F1A107008211).

ORCID

Kyung-Su Kang,  <https://orcid.org/0000-0002-6955-578X>

Han-Guk Ryu,  <https://orcid.org/0000-0001-6101-560X>

References

1. Oh SG. A View on water-laekage and contermeasure of concrete structure. Magazine of the Korea Concrete Institute. 2002 Nov;14(6):14-9.
2. Understanding of Concrete [Internet]. Seoul (Korea): Korea Cement Association. Available from: http://www.cement.or.kr/about_2015/cont8.asp?sm=1_4_0
3. Kang HK, Hong SG. Causes and mitigation of concrete cracking. Magazine of the Korea Concrete Institute. 2008 Sep;20(5):61-8.
4. Choo JH, Park SW, Kim HT, Jee KH, Yoon TG. Analysis and cause of occurrence of lining cracks on NATM tunnel based on the precise inspection for safety and diagnosis-Part I. Journal of Korean Tunnelling and Underground Space Association. 2011 May;13(3):199-214. <https://doi.org/10.9711/KTAJ.2011.13.3.199>
5. Kim SM, Sohn JM, Kim DS. A method for concrete crack detection using U-Net based image inpainting technique. Journal of the Korea Society of Computer and Information. 2020 Oct;25(10):35-42. <https://doi.org/10.9708/jksci.2020.25.10.035>
6. Sohn JM, Kim DS, Hwang HB. Improvement of learning concrete crack detection model by weighted loss function. Journal of the Korea Society of Computer and Information. 2020 Oct;25(10):15-22. <https://doi.org/10.9708/jksci.2020.25.10.015>
7. Kim GY, Kim DH, Kim DJ. Deep learning-based exterior wall crack detection method for building safety diagnosis. Journal of the Korean Institute of Plant Engineering. 2021 Dec;26(4):31-43.
8. Lee SM, Kim KY, Kim DJ. Development of robust semantic segmentation modeling on various wall cracks. Proceedings of the Korean Society of Computer Information Conference. 2022 Jul 14-16; Jeju, Korea. Yongin (Korea): Korea Society of Computer Information; 2022. p. 49-52.
9. Dung CV, Anh LD. Autonomous concrete crack detection using deep fully convolutional neural network. Automation in Construction. 2019 Mar;99:52-8. <https://doi.org/10.1016/j.autcon.2018.11.028>
10. Lee SI, Yang GM, Lee YM, Lee JH, Jeong YJ, Lee JG, Choi W. Recognition and visualization of crack on concrete wall using deep learning and transfer learning. Journal of the Korean Society of Agricultural Engineers. 2019 May;61(3):55-65. <https://doi.org/10.5389/KSAE.2019.61.3.055>
11. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015 Jun 27-30; Las Vegas, NV; Manhattan (NY): IEEE; 2015. p. 2818-26. <https://doi.org/10.1109/CVPR.2016.308>
12. Seol DH, Oh JH, Kim HJ. Comparison of deep learning-based cnn models for crack detection. Journal of the Architectural Institute of Korea Structure & Construction. 2020 Mar;36(3):113-20. https://doi.org/10.5659/JAIK_SC.2020.36.3.113
13. Jung SY, Lee SK, Park CI, Cho SY, Yu JH. A method for detecting concrete cracks using deep-learning and image processing. Journal of the Architectural Institute of Korea Structure & Construction. 2019 Nov;35(11):163-70. https://doi.org/10.5659/JAIK_SC.2019.35.11.163
14. Redmon J, Farhadi A. YOLO9000: better, faster, stronger. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017 July 21-26; Honolulu, HI. Manhattan (NY): IEEE; 2017. p. 7263-71. <https://doi.org/10.1109/CVPR.2017.690>
15. Lee MH, Nam KW, Lee CW. Crack detection on the road in aerial image using mask R-CNN. Journal of the Korea Industrial Information Systems Research. 2019 Jun;24(3):23-9. <https://doi.org/10.9723/jksis.2019.24.3.023>
16. Yamane T, Chun P. Crack detection from a concrete surface image based on semantic segmentation using deep learning. Journal of Advanced Concrete Technology. 2020 Sep;18(9):493-504. <https://doi.org/10.3151/jact.18.493>
17. Kim SM, Sohn JM, Kim DS. A method for concrete crack detection using U-Net based image inpainting technique. Journal of The Korea Society of Computer and Information. 2020 Oct;25(10):35-42. <https://doi.org/10.9708/jksci.2020.25.10.035>
18. Ha JW, Park KW, Kim MS. A development of road crack detection system using deep learning-based segmentation and object

- detection. *The Journal of Society for e-Business Studies*. 2021 Feb;26(1):93-106. <https://doi.org/10.7838/jsebs.2021.26.1.093>
19. Panella F, Aldo L, Jan B. Semantic segmentation of cracks: Data challenges and architecture. *Automation in Construction*. 2022 Mar;135:104110. <https://doi.org/10.1016/j.autcon.2021.104110>
 20. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*. 2017 Jun;60(6):84-90. <https://doi.org/10.1145/3065386>
 21. Garcia-Garcia A, Orts-Escolano S, Oprea S, Villena-Martinez V, Garcia-Rodriguez J. A review on deep learning techniques applied to semantic segmentation. *arXiv preprint*. 2017 Apr;arXiv:1704.06857. <https://doi.org/10.48550/arXiv.1704.06857>
 22. Hafiz AM, Bhat GM. A survey on instance segmentation: state of the art. *International Journal of Multimedia Information Retrieval*. 2020 Jul;9(3):171-189. <https://doi.org/10.1007/s13735-020-00195-x>
 23. Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015 Jun 7-12; Boston, MA. Manhattan (NY): IEEE; 2015. p. 3431-40. <https://doi.org/10.1109/CVPR.2015.7298965>
 24. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-assisted Intervention*. 2015 Oct 5-9; Munich, Germany, Manhattan (NY): Springer; 2015. p. 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
 25. Arkin E, Yadikar N, Muhtar Y, Ubul K. A Survey of Object Detection Based on CNN and Transformer. 2021 IEEE 2nd International Conference on Pattern Recognition and Machine Learning (PRML). 2021 July 16-18; Chengdu, China. Manhattan (NY): IEEE; 2021. p. 99-108. <https://doi.org/10.1109/PRML52754.2021.9520732>
 26. Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2018 Apr;40(4):834-48. <https://doi.org/10.1109/TPAMI.2017.2699184>
 27. Chen LC, Papandreou G, Schroff F, Adam H. Rethinking atrous convolution for semantic image segmentation. *arXiv preprint*. 2017 Dec;arXiv:1706.05587. <https://doi.org/10.48550/arXiv.1706.05587>
 28. Chen LC, Zhu Y, Papandreou G, Schroff F, Adam H. Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018 Sep 8-14; Munich, Germany. Manhattan (NY): Springer; 2018. p. 801-8. https://doi.org/10.1007/978-3-030-01234-2_49
 29. Hassan SI, Dang L, Im SH, Min KB, Nam JY, Moon HJ. 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*. 2018 Mar;22(3):451-7. <http://doi.org/10.6109/jkiice.2018.22.3.451>
 30. Paik SH, Choi DC, Kim YK, Jung SW, Kim DN. Implementation of the drones with deep-learning crack detection analysis for inspection of bridg. *Journal of Korea Institute of Information Technology*. 2021 Mar;19(3):45-52. <http://dx.doi.org/10.14801/jkiit.2021.19.3.45>
 31. Ratner AJ, Ehrenberg H, Hussain Z, Dunnmon J, Re C. Learning to compose domain-specific transformations for data augmentation. *Advances in Neural Information Processing Systems*. 2017 Sep;30:3236-46. <https://doi.org/10.48550/arXiv.1709.01643>
 32. Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. *Journal of Big Data*. 2019 Jul;6(1):1-48. <https://doi.org/10.1186/s40537-019-0197-0>
 33. Bochkovskiy A, Wang CY, Liao HYM. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint*. 2020 Apr;arXiv:2004.10934. <https://doi.org/10.48550/arXiv.2004.10934>
 34. Hao W, Zhili S. Improved mosaic: algorithms for more complex images. *Journal of Physics: Conference Series*. 2020 Nov;1684(1):012094. <https://doi.org/10.1088/1742-6596/1684/1/012094>