

# 딥러닝 기반 다양한 외벽에 강인한 균열 구획화 및 두께 측정 모델 개발

이수민\*, 김경영\*, 김동주<sup>o</sup>

## Development of Robust Crack Segmentation and Thickness Measurement Model Using Deep Learning

Soo Min Lee\*, Gyeong-Yeong Kim\*, Dong-Ju Kim<sup>o</sup>

### 요 약

건축물의 균열 여부와 균열 두께를 측정하는 것은 시설물 안전 진단에 필수적인 절차다. 하지만 해당 과정은 현장에 전문검사관이 직접 방문하여 균열의 유무, 진행 여부 및 두께에 대한 정밀한 판단을 요구한다. 노후 건축물이 전국 건축물의 42.6%를 차지하는 현실점에서 전문검사관이 모든 건축물에 방문하여 세밀한 평가를 하기에 어려움이 따른다. 이에 딥러닝을 활용한 현장 안전 진단에 대한 수요가 증가하는 추세이다. 따라서 본 연구에서는 이미지를 기반으로 균열을 구획화하고 해당 균열의 최대 두께를 측정하는 딥러닝 모델을 제안한다. 이를 위하여 현장 안전 점검 도메인에 특화되어 있으며 균열의 두께 측정이 가능한 균열 구획화 데이터셋(POC)을 구축했다. 또한, 매직 완드 기법을 균열 구획화 라벨링에 적용하여 라벨의 신뢰도를 높였다. 해당 데이터셋을 기반으로 균열 구획화 모델 DenseNet201-UNet을 개발 및 고도화하여 검증한 결과, 84.53 Crack IoU 성능을 보였다. 최종적으로 예측된 균열 마스크 이미지에 골격화 알고리즘과 유클리드 거리 변환 알고리즘을 활용하여 균열 마스크 내 가장 두꺼운 균열 위치를 특정하고 해당 두께를 계산한다. 예측 두께와 실제 두께를 실증적으로 비교한 결과 두께의 오차가 0.09 cm로 매우 작으며, 현장 안전 점검에서 활용이 가능한 성능임을 검증했다.

**키워드** : 컴퓨터 비전, 딥러닝, 균열, 의미적 구획화, 이미지 골격화

**Key Words** : computer vision, deep learning, crack, semantic segmentation, image skeletonization

### ABSTRACT

Investigation and measurement of crack is essential in maintaining safety of the facility. If crack is present, thorough examination of whether its development is in-progress is necessary, followed by precise measurement of its thickness. Due to the growing number of facilities requiring regular monitoring, automation of crack examination process is gaining attention. This paper introduces a deep learning model specializing on crack segmentation and its measurement based on image. For this task, Pohang Crack(POC), an original dataset was established : focused on properly reflecting the safety check environment, involving a sticker to measure the

\* 본 연구는 행정안전부 지역맞춤형 연구개발 사업의 지원을 받아 수행되었음(20015427).

\* 본 연구는 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(No.2022R1A6A1A03052954).

• First Author : POSTECH Institute of Artificial Intelligence, Pohang University of Science and Technology, hibokchi@postech.ac.kr, 정희원

<sup>o</sup> Corresponding Author : POSTECH Institute of Artificial Intelligence, Pohang University of Science and Technology, kkb0320@postech.ac.kr, 정희원

\* POSTECH Institute of Artificial Intelligence, Pohang University of Science and Technology, gy\_kim@postech.ac.kr, 정희원

논문번호 : 202212-307-B-R, Received December 19, 2022; Revised March 17, 2023; Accepted March 24, 2023

thickness. In addition, we propose the application of magic wand algorithm in the annotation of crack segmentation task for improving its credibility. DenseNet201-UNet crack segmentation model achieved the performance of 84.53 Crack IoU on the proposed dataset. Finally, through image skeletonization and euclidean distance transform on predicted segmentation mask, the thickest part of the crack was identified and measured pixel-wise which was then converted to cm measure in comparison with the pixel measure of the sticker. Through comparing the thickness of actual and predicted measurement, the margin of error was 0.09 cm, verifying its capability in the application on on-site safety inspection.

## I. Introduction

2021년 국토교통부의 ‘전국 건축물의 동수’와 ‘건축물 생애 이력 관리 시스템’에 의하면 전국의 건축물 중 30년 이상 된 노후 건축물이 총 3,115,834동으로 42.6%를 차지한다고 밝혔다<sup>1)</sup>. 노후 건축물의 비중이 커짐에 따라 실제적인 건물 안전 점검 및 관리가 더욱 중요하며, 이는 시간이 흘러 설계 당시의 건물 구조가 어긋나거나 누적된 외부 충격으로 인한 피로 등으로 안전에 취약해지기 때문이다. 국내에서 노후 건축물에 특화된 안전 검사는 보통 ‘제 3종 시설물 안전 등급 평가 매뉴얼(국토안전관리원)’을 따른다<sup>2)</sup>. 제 3종 시설물 안전 등급 평가 매뉴얼에 따르면, 균열과 관련하여 (A) 교량, 육교, 터널, 지하차도, 교각, (B) 가로보, 세로보, (C) 건축물, 지하도상가, (D) 난간, 연석, (E) 옹벽, 축대의 종류에 대하여 각각 균열의 두께와 심각성에 의해 (1) 우수, (2) 양호, (3) 보통, (4) 미흡, (5) 불량으로 평가되고, 이로 해당 시설물에 대한 보수 여부가 결정된다(표 1). 시설물 내 균열의 유무 및 두께가 해당 시설물의 안전 등급 지정에 중대한 영향을 주는 것을 확인할 수 있는데, 실무적인 균열 검사에서는 직접 균열자(Crack Scale)로 전반적인 균열의 크기와 두께를 측정하여 불필요한 수고가 많은 것을 확인하였다. 자동화 및 업무 효율성 증대를 위해 다양한 분야에서 AI (Artificial Intelligence)의 활용이 증가함에 따라 균열의 유무 및 균열의 두께 측정의 자동화와 관련된 기술에 관심이 늘어나고 있다.

균열에 대한 안전 검사에서 균열 여부, 크기, 진행 수준 등도 중요하지만, 균열 규모의 대표성은 보통 균열의 두께로 정의된다. 즉, 정확한 균열 두께 측정을 통해 핵심 균열을 파악하고 건물의 안전성을 유추할 수 있다. 이미지 프로세싱을 통한 균열 두께 측정에는 열화상 이미지나 Depth 카메라를 활용하는 방법이 있으며, 딥러닝 방식을 통한 균열 관련 연구는 균열 여부에 대한 분류(Classification), 균열의 위치를 찾아 표출하는 검출(Detection), 균열인 부분을 마스크해주는 구

획화(Segmentation)로 나뉜다<sup>3-5)</sup>. 균열 두께 파악에 있어 구획화 방식을 활용하는 것이 적합하지만, 이를 위한 선형 데이터셋의 도메인이 제한적이고 실제 균열과 라벨링(Labeling)이 상이하다. 또한, 정확한 등급 진단을 위해 정밀한 균열 두께 측정을 통한 신뢰도가 필요하나, 이를 위한 데이터셋, 라벨링 형식, 개발된 딥러닝 모델이 전무하다.

본 연구에서는 기존 현장 점검 내 균열 두께 측정을 보완할 수 있는 딥러닝 기반의 균열 구획화 및 두께 측정 모델을 개발했다. 본 개발을 위해 (1) 균열 데이터셋, POC(Pohang Crack)를 구축하였으며, (2) 새로운 구획화 라벨링 방법과 그 결과를 제시한다. 또한 (3) 딥러닝 기반의 균열 구획화 모델에 대해 비교 분석하고, (4) 구획화된 결과를 통한 두께 측정 알고리즘을 제안한다. 독자적으로 구축한 POC는 실제 현장 점검 도메인에 특화하여 총 2,744장의 포항 내 다양한 균열 사진으로 구성하였다. 구획화 라벨링은 기존 단순 이미지 프로세싱 기법에서의 오차를 보완하기 위해 매직 wand 기법을 활용하여 정밀한 정답 라벨을 생성하였다. 균열 구획화 모델 개발을 위해 손실함수와 백본 네트워크에 대한 실험을 진행하고 이에 대한 성능을 Crack IoU 기준으로 비교하였으며, 최종적으로 개발한 DenseNet201-UNet 모델에서 84.53의 Crack IoU 성능을 보였다. 구획화 결과를 기반으로 골격화 알고리즘

표 1. 안전 점검 시 균열에 따른 시설물 평가 (단위 : cm)  
Table 1. Crack Thickness Criteria for Regular Safety Checkup. (Unit : cm)

	(1) Fine	(2) Good	(3) Moderate	(4) Inadequate	(5) Poor
(A)	~0.1	0.1~0.3	0.3~0.5	0.5~1.0	1.0~
(B)	-	0.1~0.3	0.3~0.5	0.5~	-
(C)	-	-	0.3~0.5	0.5~	-
(D)	-	~0.3	0.3~	-	-
(E)	-	~0.2	0.2~0.3	0.3~	-

과 유클리드 거리 변환 알고리즘을 통해 균열의 두께를 픽셀 단위로 측정하고, 기준인 스티커와 비교해 두께의 실제 수치를 계산하였다. 실증을 위해 실제 균열의 두께와 제안된 알고리즘의 예측값을 비교한 결과, 평균 0.09 cm의 작은 차이로 해당 알고리즘이 실제 두께를 대변할 수 있음을 검증했다.

## II. Preliminaries

### 2.1 균열 구획화 데이터셋 동향

일반적인 균열 구획화 데이터셋은 500장 미만의 소규모 데이터셋으로 구성된다. 이는 신뢰도 있는 대규모의 균열 구획화 데이터셋 구축이 어렵기 때문이다. 그러나 균열 구획화의 수요가 늘어남에 따라 대규모 데이터셋에 대한 필요성이 증가했으며, 이를 위해 구축된 데이터셋으로 Crackseg9k가 있다<sup>6)</sup>.

Crackseg9k는 현존하는 10가지의 균열 데이터셋을 합쳐 400 × 400의 크기로 이미지 형식을 통일한 균열 구획화 데이터셋으로 총 9,255장으로 구성된다(표 2). 해당 데이터셋을 확인한 결과 도메인에 일관성이 없으며, 특히 외벽 균열의 비중이 약 40%로 적고 데이터셋 내 균열 이미지 간 유사도가 높음을 확인하였다. 또한, 균열 이미지 간 라벨링 규칙의 동일성이 떨어지는 한계를 확인하였는데, 이는 기존의 균열 라벨을 유지한 채 이미지 프로세싱 기법을 통해 정제하여 각 데이터 간 다른 정의의 라벨을 일관된 규칙으로 통합하지 않았기 때문이다. 균열 두께 측정의 관점에서는 데이터셋 내 균열의 구획화 결과만이 존재하므로 균열의 실제

크기 추정이 불가하여 균열 두께 측정에 적합하지 않았다. 이에 균열 구획화 및 두께 측정에 적합한 POC 데이터셋을 구축하였다.

### 2.2 균열 구획화 라벨링 기법 동향

균열 구획화에서는 각 픽셀을 균열/비균열(배경)로 분류한다. 구획화 라벨링과 관련하여 다양한 기법이 시도되었으며, 크게 이미지 프로세싱(Image Processing), 폴리곤(Polygon Style), 브러쉬(Brush Style)의 세 가지 기법으로 나뉜다. 이미지 프로세싱 기법은 임계치(Threshold)를 기준으로 이미지를 이분화하는 방식으로 대표적으로 오투 알고리즘(Otsu Algorithm), 지역 가변 이진화(Adaptive Local Binarization) 등이 있다<sup>7,8)</sup>. 이미지 프로세싱 기법을 활용한 라벨링은 효율적이다. 하지만 GT(Ground Truth)에 ROI(Region of Interest)와 관련이 없으나 이미지 내 임계치 이상의 값을 가지는 부분이 노이즈로 존재하여 실제 균열의 형상과 일치하지 않는 문제로 신뢰성이 떨어진다. 폴리곤 라벨링 기법은 직접 ROI의 테두리를 따라 점을 찍어 마스크를 생성한다. 직접 GT를 설정하기 때문에 ROI와 무관한 영역에 대한 노이즈는 적으나 균열과 같이 불규칙한 형태에서의 작업이 까다로워 온전한 라벨링이 어렵다. 브러쉬로 영역을 색칠하는 기법은 상기한 라벨링과 비교하여 정교하나, 대규모의 이미지에 활용은 어렵다는 한계를 가진다. 본 연구에서는 이미지 프로세싱과 브러쉬 기법의 장점을 극대화할 방법인 매치 워드 방식을 통해 반자동(Semi-Auto) 라벨링 방법을 구현했다.

### 2.3 균열 구획화 및 두께 측정 모델 관련 동향

균열 구획화의 대표적인 모델로는 DeepCrack이 있다<sup>9)</sup>. DeepCrack은 깊은 합성곱 신경망(Convolutional Neural Network, CNN)을 활용하여 특징을 추출하고, 각 CNN층의 역과정인 역합성곱(Deconvolution)을 적용한다. 최종적으로 각 역합성곱층의 결과를 합산하여 다양한 이미지 크기의 단계적 특징을 추출한다. 이를 활용하여 DeepCrack은 독자적으로 구축한 데이터셋에 대해 86.5의 F1-Score를 달성하였다.

균열 구획화를 통한 두께 측정에 활용된 모델로는 HiRes3DNet이 있다<sup>9)</sup>. 해당 모델은 의료영상 구획화에 주로 사용되며 잔차 신경망(Residual Neural Network), 배치 정규화(Batch Normalization), 풀링(Pooling)이 적용된다. 균열 폭 측정에는 프로파일링 알고리즘(Profiling Algorithm)을 활용하였으며, 실제 측정된 균열의 두께와 유사한 결과를 도출하였다<sup>9)</sup>.

표 2. Crackseg9k 구성 데이터셋  
Table 2. Subdataset Details of Crackseg9k.

Dataset	Data Size	Width	Height
Ceramic	100	256	256
CFD	118	480	320
Crack500	3126	2000	1500
CrackTree200	175	800	600
DeepCrack	443	544	384
GAPS384	383	640	540
Masonry	240	224	224
Rissbilder	2736	512	512
SDNET2018	1411	4032	3024
Volker	427	512	512

### III. Proposed Scheme

본문에서는 기존 동향에서 파악한 한계점에 대한 개선과 현장 점검에서의 활용을 목적으로 한 딤러닝 기반 균열 구획화 및 두께 측정 모델 개발 연구를 소개한다. (1) 균열 구획화 및 두께 측정을 위한 데이터셋(POC)을 소개하고, (2) 새로운 구획화 라벨링 방식으로 매직 완드 기법을 제안하며 생성된 마스크의 신뢰성을 검증한다. 또한 (3) 딤러닝 기반 균열 구획화 모델을 개발하고 (4) 개발한 모델의 구획화 결과를 기반으로 두께를 측정하는 알고리즘을 제안하며 실증을 통해 본 연구의 신뢰성을 검증하고자 한다.

#### 3.1 POC 데이터셋 구축

본 연구에서는 기존 데이터셋의 한계를 보완할 정교한 구획화와 두께 측정을 위한 신규 데이터셋 POC(Pohang Crack)를 구축하였다. 본 데이터셋은 2,744장의 균열 이미지로 구성되며, 균열의 현장 점검 시 촬영 환경을 잘 반영하기 위해 네 가지에 유의하며 데이터를 촬영하였다 : (1) 넓은 범위의 도메인(벽면 재질, 균열 종류, 두께) 추구, (2) 이미지 간 낮은 유사도(30% 이하)를 통한 데이터 다양성 제고, (3) 흐리지 않는 날씨에서 햇빛과 그림자의 허용, (4) 번호판, 얼굴, 위치 특정 가능 정보 등 민감정보 제외. 실제 심층 조사에서 균열 두께를 측정하는 상황을 고려하여 선명한 균열을 촬영했으며, 구체적인 두께 측정을 위해 두꺼운 균열 부근에 0.9 cm 크기의 스티커를 부착하였다(그림 1). 그림 1에서 알 수 있듯, 시설물의 자재, 균열의 형태와 두께, 빛과 그림자같이 일상 속 다양한 균열을 잘 반영하고 있음을 확인할 수 있다. 또한, 현장 점



그림 1. POC 데이터셋 예시 이미지  
Fig. 1. POC Dataset Sample Image.

검과 유사한 환경의 데이터로 도메인 한정 시 Crackseg9k의 데이터셋이 약 1,110장으로 규모가 축소되어, POC 데이터셋의 규모적 측면도 유의미함을 확인했다.

#### 3.2 균열 구획화 라벨링

##### 3.2.1 균열 구획화 라벨링 기법 제안

POC 균열 구획화 데이터셋에 대한 라벨링은 어도비 포토샵(Adobe Photoshop)의 내장 기능인 매직 완드 툴(Magic Wand Tool)의 기법을 활용한 색상 기반 영역 지정 툴을 개발하여 진행했다. 해당 툴은 사용자가 직접 허용치(Tolerance)와 연결성(Connectivity)을 조절하여 선택할 영역에 대한 정의가 가능하다.

이에 기반해 사용자가 클릭한 픽셀의 색상과 위치를 활용하여 주변 픽셀과의 관계를 파악하고 같은 클러스터(Cluster)에 속한다고 판단한 가장 큰 연결된 영역을 선택하여 윤곽선을 제시한다. 이러한 영역 지정 방식은 선택하고자 하는 모든 픽셀 영역에 대해 전부 지정하지 않아도 되는 반자동(Semi-Auto) 기법으로 불규칙적 형태를 선택하는데 이상적이다(그림 2). 이후 매직 완드 기법으로 생성한 POC 라벨에 대해 추가적인 라벨링 검수를 진행하여 라벨의 신뢰도를 높였으며 최종적으로 2,744장의 균열 구획화 라벨을 생성하였다(그림 3).

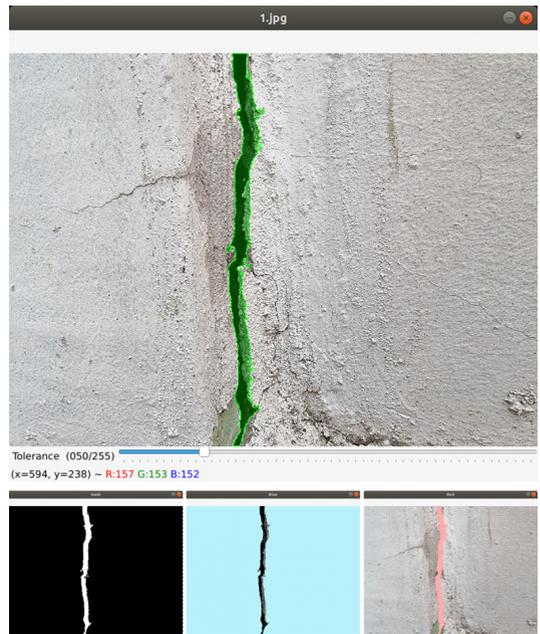


그림 2. 제안하는 균열 라벨링 툴  
Fig. 2. Proposed Crack Annotation Tool.

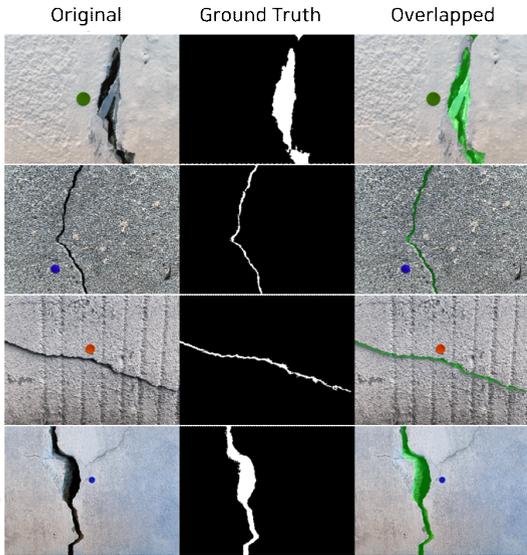


그림 3. POC 데이터셋 라벨 시각화  
Fig. 3. Visualization of POC Dataset Label.

### 3.2.2 균열 구획화 라벨링 기법 비교

본 연구에서 제안하는 균열 구획화 라벨링 기법의 효율성과 신뢰도의 검증을 위해 기존 라벨링 기법들과 비교하였다. 우선 각 기법(이미지 프로세싱, 폴리곤, 매직 완드)의 효율성 비교를 위해 라벨링 기법별 장당 평균 라벨 작업 소요 시간을 비교했다. 이때 폴리곤 라벨링의 소요 시간은 매직 완드와 비슷한 수준의 정교한 라벨을 생성하는 것을 기준으로 하였다. 비교 결과 Crackseg9k의 이미지 프로세싱은 0.0014초, 매직 완드는 157초, 마지막으로 폴리곤 라벨링은 327초로 이미지 프로세싱, 매직 완드, 폴리곤 라벨링 순으로 장당 라벨링 시간이 짧은 것을 확인했다. 또한 각 라벨링 기법별 생성된 마스크를 비교한 결과 제안한 기법은 기존 이미지 프로세싱과 비교해 노이즈를 최소화할 수 있으며, 폴리곤보다 정교하고 효율적으로 균열을 라벨링하는 것을 확인했다. 이에 균열 구획화 라벨링에 효율성이 떨어지는 폴리곤을 제외한 이미지 프로세싱과 매직 완드 기법의 라벨에 대한 신뢰도를 비교했다.

라벨링 기법 간 신뢰도 비교를 위해 Crackseg9k의 라벨 마스크 이미지와 매직 완드로 생성한 마스크 이미지를 비교하였다. 그림 4는 왼쪽부터 원본 균열 이미지, Crackseg9k의 라벨 마스크 이미지, 매직 완드 기법의 라벨 마스크 이미지이다. 구획화 라벨링은 픽셀별로 라벨이 지정되어있어 정량적으로 분석하기 어렵다. 이에 관심 영역을 집중적으로 분석하여 라벨링의 신뢰도를 판단하였다.

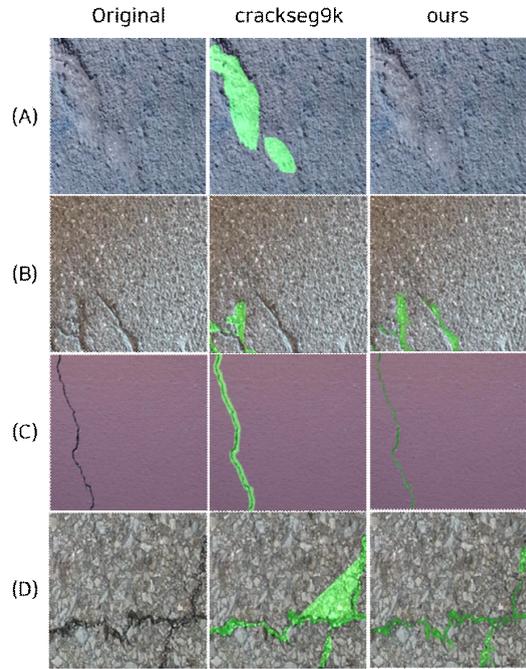


그림 4. 균열 구획화 라벨 비교  
Fig. 4. Comparison of Crack Label.

Crackseg9k 라벨에서 크게 네 가지 문제를 발견하였다. (A)의 경우 패인 부분을 균열로 간주했으나, 현장 점검 지침상 이는 균열로 볼 수 없어 마스킹하지 않아야 한다. (B)의 경우 좌측의 균열은 마스킹을 해주었으나 중앙 하단은 마스킹하지 않았다는 점을 통해 라벨에 일관성이 없는 것을 확인했다. (C)의 경우 실제 균열의 두께보다 넓게 마스킹 되어 균열 두께를 과대 측정할 위험이 있다. 또한 (D)와 같이 균열이 아닌 부분에 삼각형 형태로 마스킹이 된 경우도 존재했다. 즉, 기존의 GT 라벨은 (1) 균열의 정의가 현장 점검 지침과 일치하지 않으며 (2) 일관성 없는 라벨링이 다수 존재하고 (3) 실제 균열의 두께를 정교하게 마스킹하지 못하며 (4) 마스킹의 오류 이미지로 구성되는 한계를 가졌다.

반면, 본 연구에서 제안한 라벨링 기법을 적용한 이미지는 실제 균열의 형태를 정교하게 마스킹했다. (A)의 패임을 균열과 구분하였으며, (B)에서 균열에 대한 일관성을 확보했다. (C) 같은 미세균열에 대해 표면까지 균열로 마스킹하지 않고 균열 영역만을 세밀하게 라벨링 했으며 (D)의 오라벨도 수정하였다. 예시를 통한 검증 결과, 제안한 기법을 통해 생성한 라벨은 균열의 불규칙한 형태에도 불구하고 윤곽선을 따라 깔끔하게 정답 라벨을 생성한 것을 확인할 수 있다. 이에 매

직 완드 기법을 통해 생성한 라벨을 POC에 적용하여 GT의 오차를 최소화하고, 해당 데이터셋을 토대로 딥러닝 기반 균열 구획화 모델을 개발하였다.

### 3.3 균열 구획화 모델 개발

#### 3.3.1 성능 지표

이미지 구획화 모델의 성능을 평가하는 지표는 크게 PA(Pixel Accuracy), IoU(Intersection over Union)와 F1-Score가 있다. 해당 성능 지표들은 혼동 행렬(Confusion Matrix)을 통해 계산되며, 표 3의 예측값과 실제값의 교차표를 활용한다. 혼동 행렬에서 T는 예측과 실제 값이 같을 때, F는 예측과 실제 값이 다를 때, P는 예측을 참으로 했을 때, N은 예측을 거짓으로 했을 때 부여되며 둘의 조합인 TP, FP, FN, TN으로 분류된다.

PA는 식 (1)과 같이 전체 픽셀 중 옳게 예측한 픽셀의 비율을 의미하며, 한 이미지 내 클래스의 분포가 불균형할 시 성능을 제대로 대변하지 못하는 한계를 지닌다. 본 이미지의 경우 균열과 배경이 평균 100대 1의 비율로 불균형해 PA에 의한 성능 평가는 이전 모델과의 비교에만 적용하였다. IoU는 식 (2)와 같이 GT와 예측 마스크의 교집합을 두 영역의 합집합으로 나누는 것을 의미하며, GT와 예측 마스크의 일치하는 정도를 비교하여 성능을 직관적으로 판단하기 적합하다. ROI 클래스에 초점을 맞추는 경우 클래스의 IoU를 활용할 수 있으며, 전반적인 구획화 성능에 초점을 맞추는 경우 클래스별 IoU의 평균을 낸 mIoU(mean IoU)를 통해 성능 평가할 수 있다. 본 연구에서는 POC 데이터에 대한 구획화 모델 성능 측정에서 균열 IoU(Crack IoU)를 주 성능 지표로 선정하였다. F1-Score는 식 (3)과 같이 정밀도(Precision)와 재현율(Recall)의 조화평가를 통해 구할 수 있다. 정밀도는 참이라 예측한 것 중 실제 참인 비율이며, 재현율은 실제 참인 것 중 참으로 예측한 비율이다. F1-Score는 불균형 데이터에 적합한 평가 지표이나 수치에 대한 직관적인 판단이 어려워 Crack IoU를 주 지표로 삼되 F1-Score를 참고하였다.

표 3. 혼동 행렬  
Table 3. Confusion Matrix.

Confusion Matrix		Predicted Class	
		Positive	Negative
Actual Class	Positive	TP	FN
	Negative	FP	TN

$$PA = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

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

$$F1 - Score = \frac{2TP}{2TP + FP + FN} \quad (3)$$

#### 3.3.2 모델 성능 비교

본 연구는 본 연구는 의미적 구획화(Semantic Segmentation)의 대표 모델인 UNet(U-Net) [10] 구조를 기반으로, 이미지 구획화 모델의 성능에 큰 영향을 주는 손실함수(Loss Function)와 백본망(Backbone Network) 실험을 통해 개발한 모델의 성능을 비교 분석하였다. 우선 모델 실험으로 다양한 손실함수를 적용하여 균열의 구획화 성능을 비교하였다. 손실함수는 모델의 역전파(Backpropagation)를 통한 가중치의 최적화 과정 내 방향성을 정의한다. 균열 이미지의 경우 ROI인 균열과 배경의 비율 차이가 커 불균형 데이터 학습에 적합한 손실 함수를 적용하는 것이 필수적이며, 이에 강인하기로 알려진 세 가지 손실 함수 Jaccard Loss, Dice Loss, BCE(Binary Cross-Entropy, Sigmoid) Loss의 학습 영향을 비교했다 [11]. Jaccard Loss는 IoU를 평가 지표(Metric)로써 1-IoU 값을 최소화하는 방향으로 최적화한다. Dice Loss는 1-F1 score로 정의하며, 해당 값을 최소화하는 방향을 최적화한다. Binary Cross-Entropy Loss는 PA를 기준으로 픽셀 별로 일치된 분류 결과가 나올 수 있도록 최적화한다. 손실 함수의 영향을 확인하기 위해 POC 데이터셋을 각각 Train : Valid : Test = 7 : 2 : 2로 분할하였으며, Crack IoU를 기준으로 모델을 학습했다. 학습 과정에서 백본망 네트워크는 ResNet50을 적용하고 네트워크 내 모든 초매개변수(Hyperparameter)는 동일한 조건으로 설정했다. 옵티마이저(Optimizer)는 Adam, 학습 스케줄러(Learning Rate Scheduler)는 CosineAnnealingWarmRestarts로 지정하여 각각 50 Epoch 씩 학습하였다.

그림 5는 Epoch마다의 Crack IoU 추이이며, 세 Loss 모두 Epoch이 증가할수록 Crack IoU가 우상향함을 통해 학습이 진행되며 수치가 수렴함으로써 모델이 안정화되는 것을 확인하였다. Loss 별 최종 구획화 성능은 표 4와 같다. Dice Loss에서 77.17의 Crack IoU로 가장 높은 성능을 보였으며, Jaccard, BCE Loss 순으로 뒤를 이었다. Jaccard와 Dice Loss가 F1 score, PA에서 0.01의 근소한 차이를 보였지만, Crack IoU에

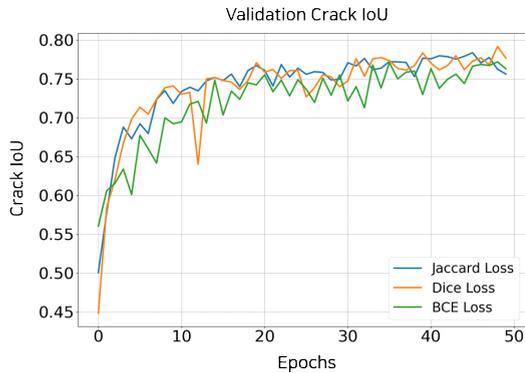


그림 5. 손실함수별 검증 데이터셋 Crack IoU 그래프  
Fig. 5. Validation Crack IoU Graph on Various Loss Functions.

표 4. 손실함수별 테스트 결과  
Table 4. Test Metric of each Loss Function.

Loss	Crack IoU	F1 Score	Precision	Recall	PA
Jaccard	75.78	99.70	99.70	99.70	99.70
Dice	<b>77.17</b>	<b>99.71</b>	99.71	<b>99.71</b>	<b>99.71</b>
BCE	73.14	99.66	<b>99.73</b>	99.60	99.66

서 Jaccard Loss는 75.78, Dice Loss는 77.17로 1.39라는 큰 차이를 보였다. 이는 셋 중 Dice Loss가 Crack IoU 기준 학습에 적합하며 이와 동시에 다른 지표들도 높은 성능을 보임을 확인했다. 따라서 최종적으로 Dice Loss를 적용하여 백분망에 대한 비교 검증을 수행하였다.

두 번째로 이미지의 특징을 추출하는 백분망에 대한 실험을 진행하였다. 후보군으로 선택된 여섯 가지의 백분 네트워크(SegFormer, Xception, VGG19, ResNet50, EfficientNet, DenseNet201)는 이미지의 특징 추출에 높은 성능을 보인다<sup>[12-17]</sup>. 구획화 모델에 대한 학습, 검증, 평가에 대한 데이터는 각각 7 : 2 : 1로 분할하였으며, 실험 과정 중 모든 초매개변수는 동일한 조건으로 설정하였다. 각 백분망은 ImageNet으로 기학습된 모델(Pre-trained Model)의 입력층을 고정하고, 출력층의 가중치에 대하여 전이 학습(Transfer Learning)하였으며, 손실함수 중 가장 높은 성능을 보인 Dice Loss를 적용하여 각각 200 Epoch 씩 학습하였다.

각 백분망의 성능은 Crack IoU를 기준으로 비교하였으며, 백분망별 테스트 데이터셋의 Crack IoU 결과는 다음과 같다(표 5). 실험 결과 최소와 최대 차이가 약 2.7로 백분망별 성능 차이가 근소하였으나, 실험 결과 6개의 네트워크 중 DenseNet201을 백분망으로 확

표 5. 백분망별 균열 구획화 성능 비교  
Table 5. Test Metric of each Backbone Network.

Architecture	Backbone	Crack IoU
UNet	SegFormer	78.00
	xception	79.90
	VGG19	80.03
	ResNet50	80.11
	EfficientNet	80.58
	<b>DenseNet201</b>	<b>80.70</b>

용한 UNet 모델이 POC 테스트 데이터셋에 대하여 80.70의 Crack IoU로 가장 높은 성능을 보였다. 이는 DenseNet 구조가 다른 다섯 개의 백분망과 달리 앞서 학습한 신경망의 특징 맵(Feature Map) 정보들을 직접 연결하여, 예측 과정에서 과거의 모든 정보에 대해 접근할 수 있기 때문이다. 다른 신경망에서 나타나는 앞단 특징 맵 정보 소실 문제와 역전과 과정에서 나타나는 초기의 기울기 소실 문제를 해결함으로써 높은 성능을 보이는 것을 확인하였다.

### 3.3.3 DenseNet201-UNet 균열 구획화 모델

실험 결과를 바탕으로 가장 높은 균열 구획화 성능을 보인 DenseNet201을 핵심 백분망으로 선정하고, DenseNet201-UNet 기반 균열 구획화 모델을 개발하였다. 모델의 기본 구조(Architecture)인 UNet은 인코더(Encoder)와 디코더(Decoder)로 구성된다. 인코더는 채널을 확대하고 데이터의 차원을 축소하여 이미지의 특징을 학습하며, 디코더는 인코딩된 특징 맵의 채널을 압축하고 데이터의 차원을 복원하여 이미지를 재생성한다. UNet의 경우 기존 인코더-디코더 간 특징 맵 정보 손실로 인한 성능저하를 인코더-디코더를 직접 연결해주는 스킵 커넥션(Skip Connection)을 통해 복원해주는 특징을 가지며 이를 통해 인코딩-디코딩 과정에서의 성능저하를 방지한다.

제안하는 모델의 구조도는 그림 6과 같다. 우선 256 × 256 사이즈로 크롭(Crop)된 세 채널(RGB)의 균열 이미지를 네트워크에 입력한다. 입력 이미지는 각각 6, 12, 48, 32개의 Dense 층으로 이루어진 총 4개의 Dense 블록(Block)을 통과하여 인코딩되며, 이 과정에서 추출한 각 특징 맵을 최초의 특징 맵 채널의 뒷부분에 이어 붙여 인코딩 과정에서 생성된 시점별 특징을 저장한다. 이를 통해 시점별 이미지의 특징 정보의 누락을 최소화하여 정밀한 균열 구획화를 가능하게 한다. 디코딩 과정은 스킵 커넥션을 통해 Dense 블록으로 추출한 앞단의 인코딩 시점별 특징 맵에 접근하여 채널

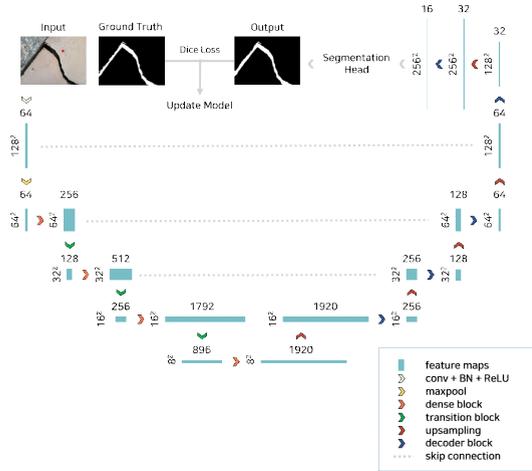


그림 6. 균열 구획화를 위한 DenseNet201-UNet 모델 구조  
Fig. 6. DenseNet201-UNet Model Architecture for Crack Segmentation.

을 증강한 뒤 해당 정보들을 압축해 채널을 축소하고 이미지의 크기를 복원한다. 원본 이미지와 동일한 크기 까지 복원 후 구획화 헤드(Segmentation Head)에서 이진 마스크(Binary Mask) 형태의 균열 구획화 이미지를 생성한다. 이때 생성된 예측 마스크와 GT 마스크를 비교하고 Dice Loss 값을 줄이는 방향으로 모델을 학습한다. 또한, 보다 도메인에 적합한 모델 개발을 위해 백본망별 성능 비교에서 학습한 DenseNet201-UNet 모델에 대하여 학습률(Learning Rate)을 줄이고 입력 층과 출력층의 가중치(Weight)를 추가로 학습하여 미세 조정(Fine-Tuning)하였다.

3.3.4 모델 결과 분석

최종적으로 개발된 DenseNet201-UNet 모델 테스트 결과, POC에 대하여 84.53의 Crack IoU를 보이며 3.83 성능이 향상되었다. 그 외에 PA, 정밀도, 재현율, F1-score에서는 99.8대의 높은 수치를 확인했다. DenseNet201-UNet의 추가적인 검증을 위해 최종 개발된 모델을 DeepCrack 데이터셋에 대하여 테스트하고 해당 결과를 DeepCrack의 기존 논문의 모델과 비교하여 성능을 분석하였다.

표 6은 두 모델 간 균열 구획화 성능을 정리한 결과이다. 이때 구획화 성능은 기존 DeepCrack 논문 내 성능 지표인 PA, 정밀도, 재현율 그리고 F1-score를 포함했다. 또한 모델의 실제 구획화 성능을 확인하기 위해 정성적으로 구획화 결과 이미지를 확인하고 이를 분석하였다. DeepCrack 데이터셋 테스트 결과, PA는 0.91, 정밀도와 재현율, F1-score에서는 각각 12.31, 11.51,

표 6. 데이터셋별 POC 학습 모델 테스트 결과  
Table 6. Model Test Result on Different Testset.

Test Data	Model	Metric				
		PA	Crack IoU	Precision	Recall	F1-score
Deep Crack	Deepcrack-Aug <sup>[5]</sup>	97.5	-	86.1	86.9	86.5
	Ours	<b>98.41</b>	<b>51.62</b>	<b>98.41</b>	<b>98.41</b>	<b>98.41</b>
POC	Ours	99.83	84.53	99.82	99.83	99.83

11.91의 큰 차이를 보이며 제한한 모델이 기존 모델보다 더 높은 성능을 보이는 것을 확인했다. 이를 통해 POC의 라벨링이 타 데이터셋의 라벨보다 픽셀별 균열의 정의가 일관적임을 간접적으로 확인하였다. 특히 DenseNet201-UNet 모델에 대한 DeepCrack의 Crack IoU가 51.62로 POC의 84.53에 비해 크게 낮았다.

해당 현상을 세밀하게 분석하고자 데이터 내 구획화 된 이미지를 확인하였으며, DeepCrack과 POC의 구획화 결과는 그림 7, 그림 8과 같다. POC로 학습한 모델의 DeepCrack 테스트셋에 대한 구획화 결과, 낮은 정량적 수치와 상반되게 전반적으로 균열을 잘 구획화했음을 확인했다. 그림 7은 그 중 자주 나타난 오류 사례를 정리하였다.

(A)는 균열 주변의 외벽이 떨어져 나간 박락 현상으로, POC의 라벨 관점에서는 해당 과정에서 여러 균열이 파생된 현상에 따라 균열로 정의하지만, DeepCrack은 균열로 정의하지 않은 점을 확인할 수 있다. 결과적으로 이미지 내 균열과 외벽 탈락이 공존하는 경우, 정

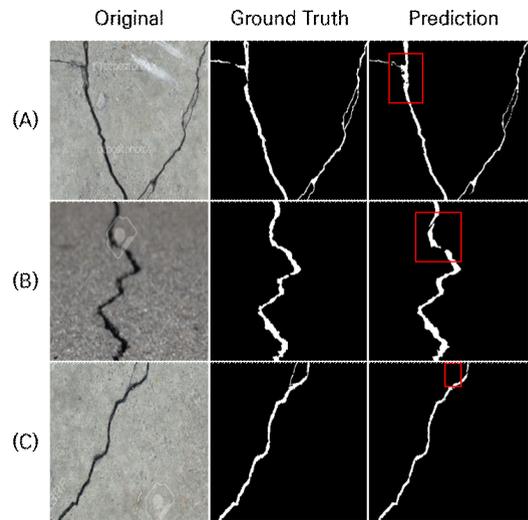


그림 7. POC 학습 모델의 DeepCrack 예측 마스크  
Fig. 7. Prediction on DeepCrack trained by POC.

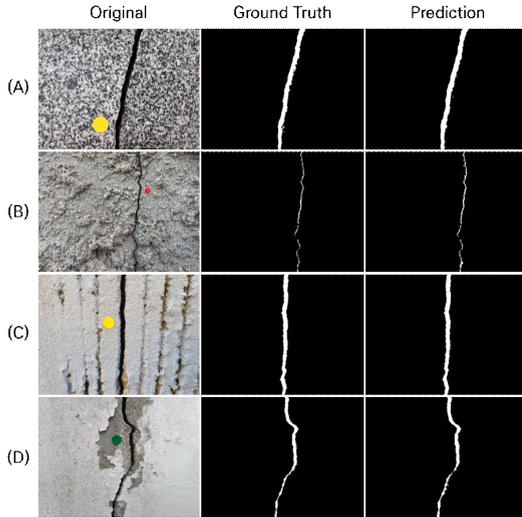


그림 8. POC 학습 모델의 POC 예측 마스크  
Fig. 8. Prediction on POC trained by POC.

의 차이로 인한 Crack IoU 수치에 큰 하락이 있었을 것으로 판단된다. (B)는 이미지 내 워터마크가 균열 위에 겹치는 사례로 DeepCrack 내 다수 존재함을 확인했다. 이에 예측 마스크가 워터마크에 의해 균열을 제대로 구획화하지 못한 것을 확인할 수 있다. 즉, POC 학습 모델이 워터마크와 같은 원본 이미지가 아닌 가공된 이미지에 대하여 취약한 점을 확인할 수 있다. 하지만 이와 같은 데이터는 안전 검사 현장에서 수집되는 데이터와는 다른 도메인으로, 현장에서의 구획화 성능에는 영향을 없을 것으로 판단된다. (C)는 미세균열이 존재하는 사례로 POC로 학습한 모델이 일부 열은 균열에 취약함을 확인했다. 이는 POC가 균열의 두께 측정을 목적으로 구축됨으로써, 비교적 두꺼운 균열에 초점을 맞춰 미세균열 사례가 상대적으로 부족했기 때문으로 판단된다.

POC에 대한 구획화 결과, 본 모델이 균열과 유사한 무늬와 다양한 외벽 재질에 대해 강인한 구획화 성능을 보임을 확인했다. 그림 8은 POC에 대한 테스트 결과로 (A)는 검은 반점 무늬가 있는 사례, (B)는 울퉁불퉁한 벽면으로 어두운 패임이 있는 사례, (C)는 균열과 비슷한 무늬가 포함된 사례, (D)는 균열과 박리가 존재하는 사례다. (A), (B), (C)는 각각 균열로 혼동될 수 있는 특징을 지니는 이미지로써, 이미지 프로세싱 기법에서 처리가 어려운 사례지만, 해당 데이터에 대한 모델의 GT와 예측 마스크의 비교 시 균열 영역이 거의 일치함을 확인하였다. 이는 모델이 균열과 그와 흡사한 특징인 어두운 색상, 단순 패임, 유사 무늬에 대하여

구별되도록 유연하게 학습된 것으로 분석된다. 특히 두께 측정 시 균열과 공존할 수 있는 (1) 표면 코팅의 벗겨지는 박리와 (2) 외벽이 탈락하는 박락의 위험 정도가 달라, 둘 간의 뚜렷한 정의가 선행되어야 한다. 그림 8의 (D)에 나타나는 박리와 그림 7의 (A)에 나타나는 박락의 예시로 비교할 수 있듯 모델이 박리와 박락을 구분한 것을 확인했다. 이를 통해 개발한 DenseNet201-UNet 모델이 건물 안전 점검 모델로 적합함을 확인할 수 있었다.

### 3.4 두께 측정 알고리즘 개발

#### 3.4.1 두께 측정 알고리즘

균열의 두께를 측정하기 위해 모델이 예측한 균열 마스크의 형태에 대한 골격화(Skeletonization)를 진행한다. 골격화란 원본 이미지 내 형상의 위상학적 구조와 특징을 담아 뼈대와 비슷한 형태로 변환해주는 과정을 말하며 이때 지켜져야 하는 핵심 요소는 위상적 모양(Topological Shape)을 보존하는 것이다. 이를 위해 통용되는 알고리즘은 이진 마스크의 유클리드 거리 변환(Euclidean Distance Transform, EDT)을 활용하여 외향 플럭스(Flux)를 측정하고, 에너지 보존 원칙에 위반되는 픽셀의 위치를 감지하는 방법이다.

그림 9는 균열 두께 측정 과정에 대한 시각화 결과이며, 각각 (A) 원본 이미지, (B) GT 마스크, (C) 모델의 예측 마스크, (D) EDT 적용 후의 마스크, (E) x축 방향의 EDT 맵, (F) y축 방향의 EDT 맵, (G) 플럭스 맵, (H) 프루닝 맵, (I)의 파란 선은 균열의 골격화 형상, 빨간 선은 균열의 가장 넓은 두께를 표현한 것이다. (D) 예측된 마스크를 기준으로 EDT를 적용하여 마스크의 경계까지의 거리를 이미지 형태로 매핑(Mapping)한다. (G) 결과적으로 경계까지 거리가 먼 픽셀들이 높은 에너지를 가지게 되고 이를 기반으로 플럭스를 계산하면 마스크의 위상학적 구조를 담은 플럭스 맵이 완성된다. (H) 이후 플럭스 맵을 구한 후 임계치를 기준으로 맵을 프루닝(Pruning)해주어 골격화맵을 계산했다. (I) 골격화 완료 후 가장 두꺼운 균열의 지점을 찾기 위해 사전에 구했던 EDT 값을 활용했다. 추가로 알고리즘의 유연성 고도화를 위해 이미지 내 마스크된 전체 균열의 픽셀 수를 구하고, 픽셀 수에 맞춰 상위 비율에 대한 임계치를 지정해 균열의 거리 좌표를 가져올 픽셀의 개수를 설정해줬다. 이후 설정한 픽셀과 (H) 플럭스 맵의 교점 중 가장 큰 EDT 값을 가진 좌표가 최종 두께의 기준 좌표이며, 그때의 EDT의 두 배값이 픽셀 단위의 균열 두께가 된다. 이후 원본 이미지

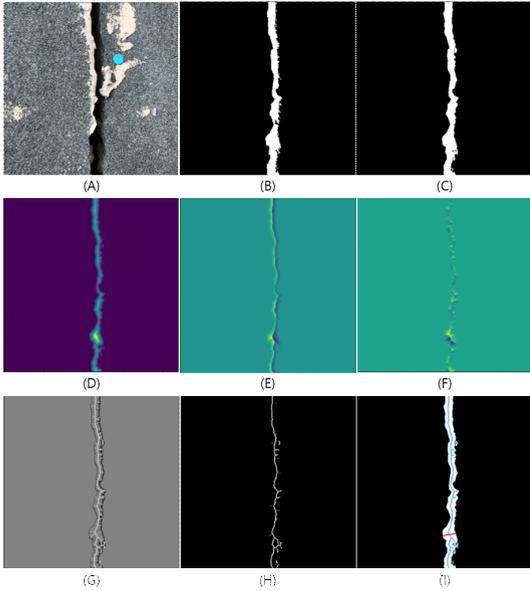


그림 9. 균열 두께 측정 과정 시각화  
Fig. 9. Crack Thickness Measurement Process.

내 스티커의 픽셀 개수를 기준으로 한 픽셀 당 cm를 계산하고 이를 기반으로 (I)의 빨간 선의 픽셀 길이를 cm로 변환하여 실제 균열의 두께를 측정한다.

### 3.4.2 두께 측정 알고리즘 실증 및 분석

본 실증에서는 (1) 실제와 예측값 간의 등급 평가의 변화 여부, (2) 실제 균열의 두께와 알고리즘의 예측값의 차이 비교, 그리고 (3) 실증 결과에 대하여 분석하였다. 제안한 두께 측정 알고리즘의 실증을 위해 대표 20장의 균열 이미지를 선정하여 ‘제 3종 시설물 안전 등급 평가 매뉴얼(국토안전관리원)<sup>[2]’(표 1)의 수치를 기준으로 알고리즘의 안전 등급 평가에 대한 영향성 및 정확도를 판단하였다. 실제 균열의 두께는 균열자를 통해 현장에서 측정하였으며, 민감도는 0.1 cm로 구성된다. 실증 결과는 표 7과 같다.</sup>

먼저 평균절대오차(Mean Absolute Error, MAE)는 0.09 cm로 해당 알고리즘이 작은 오차로 두께를 측정함을 알 수 있다. 이는 현장 균열 조사에 사용되는 균열자의 균열 측정 정확도인  $\pm 0.05$  cm (0.1 cm) 범위에 포함되는 값으로 현장에서의 측정 오차와 유사한 수치로 유의미함을 확인했다. 알고리즘의 예측 결과로 안전 등급 평가에 차이가 발생한 건은 20건 중 3건(14, 15, 17번)으로 해당 샘플들은 각각 + 0.13 cm, - 0.04 cm, - 0.02 cm의 오차를 보인다. 15, 17번 샘플의 경우 오차가 평균 0.03 cm 작게 예측했음에도 안전도 평가에 영향을 줬는데, 이는 실제 GT로 측정된 균열의 값

표 7. 두께 측정 알고리즘 실증 결과 (단위 : cm)  
Table 7. Thickness Measurement Demonstration Results. (Unit : cm)

Case	GT	Prediction	Difference	Impact
1	0.3	0.34	+ 0.04	X
2	0.7	0.68	- 0.02	X
3	0.4	0.47	+ 0.07	X
4	0.7	0.71	+ 0.01	X
5	0.7	0.56	- 0.14	X
6	1.0	1.35	+ 0.35	X
7	1.3	1.27	- 0.03	X
8	1.0	1.27	+ 0.27	X
9	0.1	0.25	+ 0.15	X
10	0.3	0.39	+ 0.09	X
11	1.2	1.17	- 0.03	X
12	0.3	0.45	+ 0.15	X
13	1.1	1.10	0.00	X
14	0.4	0.53	+ 0.13	O
15	0.5	0.46	- 0.04	O
16	0.9	0.80	- 0.10	X
17	1.0	0.98	- 0.02	O
18	1.6	1.55	- 0.05	X
19	0.6	0.82	+ 0.22	X
20	1.0	1.01	+ 0.01	X
<b>MAE</b>			<b>0.09</b>	-

이 안전 등급 평가의 기준인 경계값(0.5 cm, 1.0 cm)이기 때문이다. 14번 샘플의 경우, 실제 측정된 균열과 다른 각도에서 두께 알고리즘의 직교 거리를 측정하여 결과가 상이하게 도출됨을 확인했다.

균열 두께 측정 알고리즘의 실증 결과에 대한 분석을 위해 절대오차가 작은 (A) 5건과 큰 (B) 5건의 샘플에 대하여 실제 두께와 예측 두께를 시각화하였다(그림 10). 붉은색으로 표시된 선이 GT로 측정된 두께이며 노란색으로 표시된 선이 알고리즘의 두께 예측 결과이다. (A)의 경우 20번 샘플을 제외한 이미지에 대하여 알고리즘이 균열의 최대 두께로 예측한 위치와 최대 두께로 측정된 GT의 위치가 거의 일치함을 확인했다. 20번 샘플은 예측 위치가 GT와는 전혀 다름을 확인할 수 있는데, 이는 균열의 두께가 평균적으로 일정한 형태를 보이며 예측 위치에서 픽셀 상 균열의 두께가 최대가 되었기 때문으로 판단되어 문제의 여지가 없음을 확인했다. (B)의 경우 좌측과 달리 최대 두께로 예측된 위치와 GT의 위치가 상이하다. 8번 샘플의 경우 최대 두께 측정 시 사람이 보는 직교와 달라 거리를

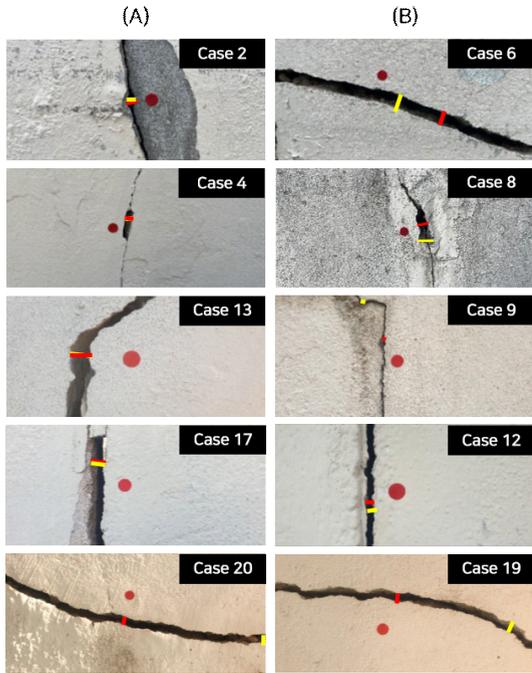


그림 10. 균열 두께 측정 알고리즘 실증 결과 분석 (붉은 선 : GT, 노란 선 : 예측값)  
 Fig. 10. Analysis on Crack Thickness Measurement Demonstration Results. (Red Line: GT, Yellow Line : Prediction)

과도하게 측정하였다. 이는 구획화에 문제가 없으나, 일부 균열의 픽셀이 미시적으로 변동되어 나타난 현상으로 판단된다. 6, 9, 12, 19번 샘플의 경우, 2D 이미지 형식에서 픽셀 상의 두께가 현장에서 측정된 GT보다 두꺼운 부분이 존재하여 해당 위치를 균열의 최대 두께로 예측 및 측정함을 확인했다. 이처럼 현장에서의 균열 두께 측정 시 최대 두께의 위치 선정이 어려워 객관성이 떨어지며 실제 측정값에 대한 오차 역시 존재한다. 반면 제안하는 두께 측정 알고리즘은 픽셀 간 좌표의 거리를 비교함으로써 최대 두께를 객관적으로 측정해 신뢰도를 높였다. 이와 유사한 이유로 알고리즘이 두껍게 예측한 경우는 11건으로써 평균 0.13 cm의 오차를 보였으며, 얇게 예측한 경우는 8건으로 평균 0.05 cm라는 미세한 오차를 보였다.

본 검증을 통해 현장에서의 실제 균열 측정의 신뢰성을 간접적으로 확인할 수 있었다. 이에 추후 균열 구획화 모델과 두께 측정 알고리즘을 통해 균열의 두께에 대하여 우선 측정하고 예측된 최대 두께의 값이 안전 등급 평가 기준의 경계값인 경우, 직접 재확인함으로써 기존의 측정 방법을 보완할 수 있을 것으로 분석한다. 최종적으로 두께 측정 알고리즘 실증 결과, 제안

하는 두께 측정 알고리즘이 균열 두께를 작은 오차로 정확히 측정하는 것을 확인했으며 실제 안전 점검 현장에서 효용성이 있을 것으로 판단된다.

#### IV. Conclusion

딥러닝 모델이 다양한 분야에 적용되며 건물 안전 진단을 위한 현장 안전 점검에서의 활용에 관한 관심도 추진력을 얻었다. 이에 균열의 유무를 판단하는 분류 모델과 균열의 위치를 특정하는 균열 검출 모델 개발에 활발한 연구가 진행되는 반면 균열의 형태를 정밀하게 잡아내는 균열 구획화 모델에 관한 연구는 미진한 상황이다. 본 연구는 현장 안전 점검 환경을 반영한 다양한 균열 이미지로 구성된 데이터셋 POC를 구축하였으며, 매직 완드 툴을 통한 반자동 방식의 라벨링 기법을 통해 기존의 균열 라벨링과 비교하여 신뢰도를 높였다. 구축한 POC 데이터셋을 기반으로 개발한 균열 구획화 모델 DenseNet201-UNet은 높은 균열 구획화 성능을 보이며 실무에 적용할 수 있는 수준임을 검증했다. 최종적으로 본 모델이 예측한 균열의 구획화 이미지에 골격화와 EDT 알고리즘을 적용하여 최종 균열의 두께를 측정해 실증 결과 낮은 수준의 오차를 보였다.

본 연구에서 구축한 POC 데이터셋은 기존의 균열 구획화 데이터의 한정된 도메인과 라벨링 한계를 개선하여 균열 구획화 모델의 성능을 향상했다는 의의가 있으며, 이를 통해 다양한 환경의 균열 구획화 문제에 적합한 데이터셋임을 검증했다. 하지만 현시점 POC 구획화 데이터셋만으로 구획화 성능을 높이는 것에 한계가 있어 향후 추가 데이터셋 수집 작업이 수반될 필요가 있다. 또한, 현존하는 균열 구획화 데이터 중 유사 도메인 데이터셋에 대하여 재라벨링하여 추가로 학습하는 과정이 필요하다고 판단된다. 두께 측정 알고리즘의 경우 스티커의 픽셀 수를 측정하는 과정에서 직접 마스킹해야 한다는 점에 있어 향후 연구에 딥러닝 모델 내 스티커 마스킹 기능을 추가할 필요가 있다. 본 연구를 바탕으로 이미지 기반 End-to-End 형식의 두께 측정 모델을 개발해 건물의 안전 점검이 효과적으로 이루어지도록 보조할 수 있을 것으로 기대한다.

#### References

[1] Ministry of Land, *Infrastructure and Transport*, *A total of 7,275,266 buildings / 3.96 billion square meters nationwide* (2021), Retrieved

- Nov. 04, 2022. from [http://www.molit.go.kr/USR/NEWS/m\\_71/dtl.jsp?id=95085286&src=txt&kw=000004](http://www.molit.go.kr/USR/NEWS/m_71/dtl.jsp?id=95085286&src=txt&kw=000004)
- [2] Korea Authority of Land & Infrastructure Safety, “*Safety Level Evaluation Manual on Class 3 Facilities*,” (2021), from [https://www.ksmi.or.kr/board/?\\_0000\\_method=view&n\\_code=a002&num=1487](https://www.ksmi.or.kr/board/?_0000_method=view&n_code=a002&num=1487)
- [3] W. R. L. d. Silva and D. S. d. Lucena, “Concrete cracks detection based on deep learning image classification,” in *18th ICCEM18*, p. 489, Brussels, Belgium, Jun. 2018. (<https://doi.org/10.3390/ICCEM18-05387>)
- [4] G. Y. Kim, D. H. Kim, and D. J. Kim, “Deep learning-based exterior wall crack detection method for building safety diagnosis,” *J. Korean Inst. Plant Eng.*, vol. 26, no. 4, pp. 31-43, Dec. 2021.
- [5] Y. Liu, J. Yao, X. Lu, R. Xie, and L. Li, “DeepCrack: A deep hierarchical feature learning architecture for crack segmentation,” *Elsevier*, vol. 338, pp. 139-153, Apr. 2019. (<https://doi.org/10.1016/j.neucom.2019.01.036>)
- [6] S. Kulkarni, et al., “CrackSeg9k: A collection and benchmark for crack segmentation datasets and frameworks,” *Comput. Sci.*, pp. 179-195, Aug. 2022. (<https://doi.org/10.48550/arXiv.2208.13054>)
- [7] B. Chen, et al., “Detect concrete cracks based on OTSU algorithm with differential image,” *J. Eng.*, vol. 2019, no. 23, pp. 9088-9091, Oct. 2019. (<https://doi.org/10.1049/joe.2018.9191>)
- [8] H. Kim, et al., “Comparative analysis of image binarization methods for crack identification in concrete structures,” *Elsevier*, vol. 99, pp. 53-61, Sep. 2017. (<https://doi.org/10.1016/j.cemconres.2017.04.018>)
- [9] A. R. Kim, et al., “Crack detection of concrete structure using deep learning and image processing method in geotechnical engineering,” *J. Korean Geotechnical Soc.*, vol. 34, no. 12, pp. 145-154, Dec. 2018. (<https://doi.org/10.7843/KGS.2018.34.12.145>)
- [10] O. Ronneberger, et al., “U-Net: Convolutional networks for biomedical image segmentation,” *CVPR*, 2015. (<https://doi.org/10.48550/arxiv.1505.04597>)
- [11] j. bertels, et al., “optimizing the dice score and jaccard index for medical image segmentation: Theory & practice,” *CVPR*, 2019. (<https://doi.org/10.48550/arXiv.1911.01685>)
- [12] E. Xie, et al., “SegFormer: Simple and efficient design for semantic segmentation with transformers,” *NeurIPS*, 2021. (<https://doi.org/10.48550/arXiv.2105.15203>)
- [13] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *CVPR*, 2014. (<https://doi.org/10.48550/arXiv.1409.1556>)
- [14] K. He, et al., “Deep residual learning for image recognition,” *CVPR*, 2015. (<https://doi.org/10.48550/arXiv.1512.03385>)
- [15] C. Szegedy, et al., “Going deeper with convolutions,” *CVPR*, 2014. (<https://doi.org/10.48550/arXiv.1409.4842>)
- [16] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *CVPR*, 2019. (<https://doi.org/10.48550/arXiv.1905.11946>)
- [17] G. Huang, et al., “Densely connected convolutional networks,” *CVPR*, 2016. (<https://doi.org/10.48550/arxiv.1608.06993>)

이 수 민 (Soo Min Lee)



2018년 8월 : Goldsmiths, University of London, Fine Art & History of Art 졸업  
 2022년 3월~현재 : 포항공과대학교 인공지능연구원 연구원  
 <관심분야> 컴퓨터 비전, 영상 처리, 딥러닝

[ORCID:0009-0009-1417-4902]

김 경 영 (Gyeong-Yeong Kim)



2015년 2월 : KAIST 수리과학과  
학사

2018년 2월 : KAIST 건설및환경  
공학과 석사

2020년 3월~현재 : 포항공과대학  
교 인공지능연구원 팀장  
<관심분야> 컴퓨터 비전, 안면 인  
식, 딥러닝

[ORCID:0000-0001-6891-4130]

김 동 주 (Dong-Ju Kim)



1998년 2월 : 충북대학교 전파공  
학과 학사

2000년 2월 : 충북대학교 전파통  
신학과 석사

2010년 8월 : 성균관대학교 전기  
전자 및 컴퓨터공학과 박사

2016년 9월~현재 : 포항공과대학  
교 인공지능연구원 연구부장 / 연구부교수

<관심분야> 컴퓨터 비전, 영상 처리, 딥러닝

[ORCID:0009-0009-6950-4200]