

A method for concrete crack detection using U-Net based image inpainting technique

Su-Min Kim*, Jung-Mo Sohn*, Do-Soo Kim*

*Researcher, Epozen's research institute, Seoul, Korea

*Researcher, Epozen's research institute, Seoul, Korea

*Researcher, Epozen's research institute, Seoul, Korea

[Abstract]

In this study, we propose a crack detection method using limited data with a U-Net based image inpainting technique that is a modified unsupervised anomaly detection method. Concrete cracking occurs due to a variety of causes and is a factor that can cause serious damage to the structure in the long term. In general, crack investigation uses an inspector's visual inspection on the concrete surfaces, which is less objective in judgment and has a high possibility of human error. Therefore, a method with objective and accurate image analysis processing is required. In recent years, the methods using deep learning have been studied to detect cracks quickly and accurately. However, when the amount of crack data on the building or infrastructure to be inspected is small, existing crack detection models using it often show a limited performance. Therefore, in this study, an unsupervised anomaly detection method was used to augment the data on the object to be inspected, and as a result of learning using the data, we confirmed the performance of 98.78% of accuracy and 82.67% of harmonic average (F1_Score).

▶ **Key words:** Deep Learning, Concrete Crack, Crack Detection, Anomaly Detection, U-Net, Unsupervised Learning

[요 약]

본 연구에서는 비지도 이상 탐지 방법을 변형한 U-Net 기반의 이미지 복원 기법을 통해 한정적인 데이터를 활용한 균열 탐지 방안을 제안한다. 콘크리트 균열은 다양한 원인으로 인해 발생하며, 장기적으로 구조물의 심각한 손상을 초래할 수 있는 요소이다. 일반적으로 균열 조사는 검사원의 육안으로 판단하는 외관 검사법을 사용하는데, 이는 판단에 객관성이 떨어지며 인적 오류 발생 가능성이 크다. 따라서 객관적이고 정확한 이미지 분석 처리를 통한 방법이 요구된다. 최근에는 균열을 신속하고 정밀하게 탐지할 수 있도록 딥러닝을 활용한 기술들이 연구되고 있다. 하지만 일반적인 균열자료에 비해 점검 대상물에 대한 데이터는 한정적이므로 이를 활용한 기존 균열 탐지 모델의 성능은 제한적인 경우가 많다. 따라서 본 연구에서는 비지도 이상 탐지 방법을 사용해 점검 대상물에 대한 데이터를 증강하여 해당 데이터를 사용하여 학습한 결과, 정확도 98.78%, 조화평균(F1_Score) 82.67%의 성능을 확인하였다.

▶ **주제어:** 딥러닝, 콘크리트 균열, 균열 검출, 이상 탐지, U-Net, 비지도 학습

- First Author: Su-Min Kim, Corresponding Author: Jung-Mo Sohn
- *Su-Min Kim (ksu3@epozen.com), Epozen's research institute
- *Jung-Mo Sohn (jmsohn@epozen.com), Epozen's research institute
- *Do-Soo Kim (dskim@epozen.com), Epozen's research institute
- Received: 2020. 08. 24, Revised: 2020. 09. 17, Accepted: 2020. 09. 17.

I. Introduction

콘크리트 구조물은 사회 전반적으로 자주 사용되고 있는 구조물이다. 하지만 콘크리트 구조물은 외력에 의한 응력 발생, 시공 후 관리 불량에 따른 수분 손실 등 다양한 원인으로 인해 균열이 발생한다. 이러한 균열은 구조물의 심각한 손상을 초래할 수 있어 장기적으로 구조물의 안전을 위협하는 요소가 된다. 이에 구조물 유지보수에서는 균열 상태를 주기적으로 파악하고 이에 대한 신속한 초기 대응이 중요하다.

현재 주로 사용되는 균열 탐지 방법으로는 전문가가 육안으로 직접 검사하는 외관 검사법이 있다[1]. 하지만 콘크리트 구조물의 균열은 큰 구조물에 비해 매우 미세하며 균열의 개수도 적어서 사람이 판단하는 과정에서 작업 시간, 비용, 검사 가능 범위 등의 한계점을 가지고 있다. 또한 균열 점검 후 즉각적인 조치 필요 여부를 판단하기 위해서는 정밀한 균열 추출이 매우 중요한데, 사람의 육안으로 균열을 본뜨는 과정에서 오차가 발생할 가능성이 크다. 따라서 오류를 최소화하고 다수의 구조물에 대한 안전하고 효과적인 점검을 위해 기존의 육안 검사를 대체하는 방식으로 전환할 필요가 있다.

육안 검사 대체 방법으로 컴퓨터 영상을 사용한 외관 검사법이 사용된다. 이 검사 방법은 콘크리트 구조물의 표면을 이미지로 촬영하고 이미지 프로세싱을 한 후 영상 처리 알고리즘을 통해 손상의 종류, 크기 등의 정보를 도출하는 방법이다. 최근에는 딥러닝 기술 중 하나인 객체 인식 분야의 발전으로 인해 딥러닝을 적용한 균열 점검 기법에 관한 다양한 연구가 수행되고 있다. 이러한 동향에 따라 “딥러닝과 영상처리 기법을 이용한 콘크리트 지반 구조물 균열 탐지(Ah-Ram Kim., 2018)”와 같은 연구 사례들이 늘어나고 있다. 해당 연구에서는 크게 균열 판단 신경망과 균열 구획화 신경망으로 나누어 진행하며, 균열 판단 신경망에서는 CNN 기반의 알고리즘을 사용해 99.98%의 검증 정확도를 달성했다. 균열 구획화 신경망에서는 균열을 영상 처리 기법인 세션화 방법과 그 결과에 대한 추적 기법을 사용해 균열 길이를 측정하고, 프로파일링 알고리즘을 제안해 폭을 측정했다. 그 결과 추출된 균열에 대해 IoU가 0.87정도의 성능을 보였다. 하지만 연구의 한계로 균열 영상과 그 특징에 대한 객관적인 기록의 부족으로 인해 한 가지 영상에서만 검증이 수행되어 다양한 환경에서의 검증이 미흡하다는 한계를 갖고 있다고 기술했다.[2]

이처럼 딥러닝 모델 학습 시 많은 양의 데이터가 필요한 것에 비해 이용되는 데이터의 양이 한정된 경우에는 최적

의 학습 결과를 도출하는 데에 한계가 있다[3]. 따라서 본 연구에서는 비지도 이상 탐지 모델을 변형해 한정적인 데이터를 최대한 활용할 수 있는 U-Net 기반의 이미지 복원 기법을 사용한 균열 탐지 방안을 제안하였다.

II. Preliminaries

1. Related works

1.1 Anomaly Detection

이상 탐지 기법이란 데이터를 정상 데이터와 비정상 데이터로 구별하는 문제를 의미한다. 이때의 이상은 각 분야 및 문제에서 정상과는 반대 개념으로 자료 내 정의된 정상적인 패턴을 따르지 않는 개체를 말한다. 따라서 이상 탐지는 보통의 분류(classification)와는 달리 다수 범주를 고려해 이상치가 아닌 데이터들의 부분을 구분 짓는 것을 말한다.

이상 탐지 방법에는 분야별, 방식별로 분류할 수 있는데 그 중 딥러닝 기반의 이상 탐지 방법은 학습 데이터셋에 비정상 데이터의 포함 여부, 각 샘플의 라벨 존재 여부에 따라 Table 1과 같이 분류할 수 있다. Table 1에서 ○는 해당 데이터가 필요함을 의미하며, X는 필요 없음을 의미한다.

Table 1. Classification of the Anomaly Detection

Classification	Data	Label
Supervised Anomaly Detection	○	○
Semi-supervised Anomaly Detection	○	△ (Only Normal)
Unsupervised Anomaly Detection	○	X

지도 이상 탐지의 경우 다른 방법들에 비해 높은 정확도가 특징이다. 하지만 비정상 샘플의 발생 빈도가 작은 경우 두 샘플 사이의 불균형 문제가 생긴다.

준 지도 이상 탐지는 비정상 샘플의 확보가 어려운 경우에 정상 샘플을 사용해서 정상 샘플에 대한 판별 구간을 정해 이 구간 밖에 있는 샘플들을 모두 비정상으로 간주하는 방식이다. 단, 정상 샘플에 대한 라벨링을 필요로 한다. One-Class SVM(Support Vector Machine)가 대표적으로 잘 알려져 있으며 딥러닝 기반의 방식은 Deep SVDD(Support Vector Data Description)가 잘 알려져 있다. 비교적 활발하게 연구가 진행되고 있는 방식이다.

비지도 이상 탐지는 학습에 사용되는 샘플들에 대해 라벨링 없이 모델 스스로 특징들을 추출해 비정상 데이터를 탐지하는 방식이다. 이 때문에 학습에 사용되는 샘플들 중 대다수가 정상 데이터이어야 한다.[4][5]

딥러닝 학습 시, 학습 데이터의 대부분이 정상 데이터인 경우라면 준 지도 혹은 비지도 이상 탐지 방식이 사용된다. 본 연구에 사용되는 콘크리트 균열 데이터의 경우, 콘크리트 균열에 대한 보편적인 이미지는 많으나 점검하고자 하는 대상물에 대한 이미지가 적을 경우가 많다. 특히 콘크리트 구조물 중 신축건물, 관리 초기 단계의 건물의 경우 해당 대상물에 대한 균열 데이터가 매우 적어 기존의 학습 방식대로 사용한다면 일정 성능을 만족시키기 어려울 것으로 판단된다. 따라서 본 연구에서는 특정 대상물에 대한 비정상 데이터 확보를 위해 라벨의 취득 없이 비지도 학습을 적용한 이상 탐지를 적용하고자 한다.

비지도 학습은 입력된 데이터에 대한 주성분 분석을 이용해 차원을 축소, 복원하는 과정에서 비정상 데이터를 검출하는 방법이다. 보통 이러한 방법은 Fig. 1과 같은 AutoEncoder 기반의 신경망 구조를 사용한다. 이 구조는 입력 데이터에서 인코딩 과정을 통해 중요한 정보를 압축적으로 모으고, 이를 사용해 디코딩 과정을 거쳐 다시 원본에 가깝게 복원해내면서 입력 데이터에 대한 라벨링 없이 데이터의 주성분이 되는 영역의 특징을 학습한다. 이때 학습 모델의 인코더에 정상 샘플만을 넣으면, 정상 샘플에 대한 복원 학습을 수행하고, 이후 과정인 입력 데이터와 예측 결과 데이터의 차이를 구하는 과정을 진행하면서 두 데이터의 차이가 도드라지게 발생해 비정상 샘플을 검출하는 방식을 주로 사용한다.[6]




Fig. 1. Architecture of Unsupervised Anomaly Detection[4]

하지만 AutoEncoder에서는 인코딩 과정마다 축약된 정보들을 사용하지 않고 최종적인 특징 맵만을 사용해 디코딩을 수행하는 과정에서 이미지 축소에 의한 공간 정보를 얻을 수 없다는 한계를 갖는다. 이에 본 연구에서는 이

러한 AutoEncoder의 구조를 개선 시킨 U-Net 구조를 활용한 비지도 이상 탐지를 수행했다.

1.2 U-Net

U-Net은 생물의학(Biomedical) 분야에서 이미지 분할을 목적으로 제안된 End-to-End 방식의 Fully-Convolutional Network 기반 모델이다. 기존 생물의학 분야에서의 이미지 작업은 오직 전문가의 분석에만 의존하는 환경이었다. 딥러닝 모델의 출현으로 의학 분야의 X-ray, MRI등에서 딥러닝의 도움을 통한 분석이 증가하고 있다. 의료 연구에서는 자동화된 현미경 실험으로 몇 테라바이트에 달하는 이미지가 생성되는데, 이에 대해 각 이미지에 대해 Semantic Segmentation 방법을 통해 셀(cell)과 셀 구성 요소를 분류했다. 결과적으로 U-Net의 구조를 활용하여 아주 적은 양의 학습 데이터만으로 Data Augmentation을 활용하여 여러 Biomedical Image Segmentation 문제에서 우수한 성능을 보여주었다.

U-Net은 Fig. 2와 같이 U자형 아키텍처와 고차원 형태의 이미지를 저차원 형태의 이미지로 변경시켜주는 Encoder(Convolution)와 인코딩 된 이미지를 다시 원래 형태로 변경해주는 Decoder(Deconvolution)구조를 가지고 있다.

특히 기본적인 AutoEncoder 구조에서 Encoder에서 축약된 정보를 Decoder에 연결해서 사용하는 특징을 갖는데, 이러한 과정으로 인해 기존 AutoEncoder 과정에서 활용하지 못했던 공간 정보를 얻을 수 있다는 장점이 있다.[7][8][9]

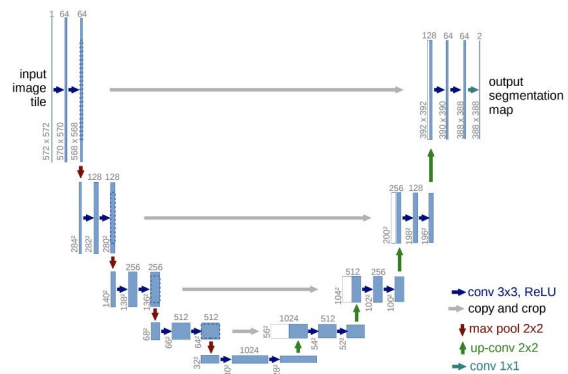


Fig. 2. U-Net Architecture[10]

III. The Proposed Scheme

1. Deep Learning and Generation of the Model

본 연구에서는 균열 이미지를 정상 이미지로 복원하는 과정에서 U-Net을 사용해 이미지의 특징들을 스스로 학습할 수 있도록 하는데 정상 이미지만을 사용해 학습하는 방식이 아닌 균열 이미지를 정상 이미지화시키는 방식으로 학습하게 된다. 따라서 균열 제거 모델 학습을 위해 입력 이미지로부터 균열을 제거한 이미지를 라벨 데이터로 사용하기 때문에, 학습용 데이터셋을 새롭게 구성하게 된다. 데이터는 중동 공과대학교(METU)에서 학교 건물 균열 이미지를 수집한 것으로 균열 이미지와 균열 라벨 이미지로 이루어져 있다[11]. 본 논문에서는 이를 512x512로 분할해 사용했다.

Fig. 3의 1번 과정과 같이 균열 이미지와 균열 라벨 이미지 각 픽셀의 grayscale 값들을 곱해 균열 이외의 값들을 모두 1로 변환하여 마스킹 된 균열 이미지를 생성하고 Fig. 3의 1번 과정에서 획득한 이미지를 2번 과정에서 정상 이미지와 합성해 합성된 균열 이미지를 생성한다. 결과적으로 얼마나 배경 이미지와 가깝게 균열 부분을 제거하는가를 학습하기 때문에 다양한 정상 이미지에 같은 균열 이미지를 여러 번 사용해 합성 가능하므로 학습 데이터 확보가 유리하다. 이후 3번 과정과 같이 2번 과정에서 획득한 합성 이미지를 입력으로 하고 원본 정상 이미지를 출력으로 하여 학습을 수행해 균열 부분을 제거하여 정상 이미지로 복원한다.




Fig. 3. Process of Learning Model for Concrete Crack Image Inpainting

학습 모델은 Fig. 4와 같이 구성한다. 학습 중에는 라벨로 받은 정상 이미지와 예측한 이미지 간의 오차를 계산해 일정 오차 이하로 떨어질 때까지 학습을 수행한다. 오차 계산의 경우 평균 제곱 오차 함수를 사용했으며 해당 모델의 최적화를 위한 외적 인자(Hyperparameter) 설정은 Table 2와 같다. 학습은 Tesla V100 2GPU (48 GB) 서버에서 진행되었으며, 학습 모델은 Keras 2.3버전 기반으로 작성되었다.

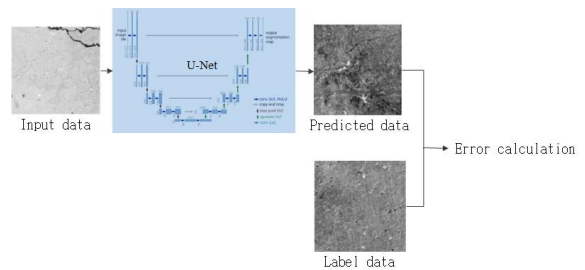


Fig. 4. Architecture of Model for Crack Image Inpainting

Table 2. Hyperparameters for the Learning Model

Hyperparameter(unit)	Value
Kernel size(pixel)	5 x 5
Filters(count)	16-32-64-128-64-32-16
Layer(count)	4

모델 학습 결과, 실제 균열 이미지에 대해 Fig. 5와 같이 균열 부분이 제거된 것을 확인했다. Fig. 5의 (a)는 테스트를 위해 입력한 실제 균열 이미지이며 (b)는 모델이 입력된 실제 균열 이미지를 사용해 균열이 제거된 이미지이다.




Fig. 5. Learning results with Model for Crack Image Inpainting

2. Detection of Crack

본 연구에서는 이상 탐지 방법에서 입력 데이터와 출력 데이터 간의 차이를 통해 이상을 탐지하듯이 학습을 통해 복원된 정상 이미지와 원래 입력한 원본 이미지의 차이를 통해 콘크리트의 균열을 추출한다. Fig. 6의 1, 2번 과정을 통해 균열 이미지를 입력하면 균열이 최대한 흐려지게 출력된다. 이후 Fig. 6의 3번 과정과 같이 각 입력 데이터와 대응하는 출력데이터를 픽셀들의 grayscale 값을 빼 difference map을 생성한다.

입력 이미지에 균열 부분의 grayscale 값은 보통 정상 부분보다 어둡기 때문에, grayscale 값이 작다. 반면 출력 이미지에서는 균열이 주위의 다른 값과 유사하게 복원되기 때문에 grayscale 값이 커지게 된다. 따라서, 출력 이미지에서 입력 이미지의 값의 차이를 구하도록 하였다. 하지만 전체 이미지에서 차이를 구하게 되면, 균열이 아닌 부위에서 마이너스 값이 발생한다. 이를 보정하기 위해 마이너스 값에 대해서는 0으로 변경하도록 하였다. 결과적으로 아래의 식과 같이 relu 함수를 적용하게 되었다. I_{xy} 는 입력 이미지의 픽셀 값이며, O_{xy} 는 출력 이미지의 픽셀 값이다. D_{xy} 는 최종적으로 검출된 균열 이미지의 픽셀 값이다.

$$D_{xy} = \text{relu}(O_{xy} - I_{xy})$$




Fig. 6. Process of Concrete Crack Detection

위 과정을 통해 실제 균열 이미지에 대한 균열 추출한 결과는 다음 Fig. 7과 같다. Fig. 7에서의 (a)는 입력한 실제 균열 이미지이고, (b)는 추출된 균열의 이미지, (c)는 균열의 라벨 이미지로 균열의 모습을 제대로 추출하고 있음을 알 수 있다. 3번째 이미지의 경우 (c)라벨 데이터에 오류가 있음을 보이는데, 원본 이미지에서 보면 알 수 있

듯이 균열이 아닌 부분까지도 균열로 판단되어 있음을 보인다. 반면 (b)균열 추출 이미지에서는 균열이 아닌 부분은 제외된 채 추출된 것을 알 수 있다.




Fig. 7. Results of Concrete Crack Detection

3. Performance Evaluation of the Model

균열 추출 모델의 성능 평가를 위해서는 추출된 균열 이미지에 대해서 균열 라벨 데이터와 같이 0과 1로 구성된 이미지로 변환해야 한다. 추출된 균열 이미지는 0과 1 사이의 실수값을 갖고 있으므로 변환 과정에서 임계값 (Threshold)을 적용해 이미지를 변환한다. Fig. 8의 (b)가 임계값 0.1을 적용한 균열 추출 이미지이다. (b)에서 보이는 작은 잡음들은 임계값을 적용하는 과정에서 해당 값이 큰 경우 균열과 같이 0으로 값이 변경되므로 잡음이라고 판단되는 이것을 제거해야 한다.

본 연구에서는 잡음 제거를 위해 합성곱 연산을 사용하여 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. 그 결과 Fig. 8의 (c)와 같이 (b)에서 보이던 작은 잡음들이 제거된 것을 확인할 수 있다.

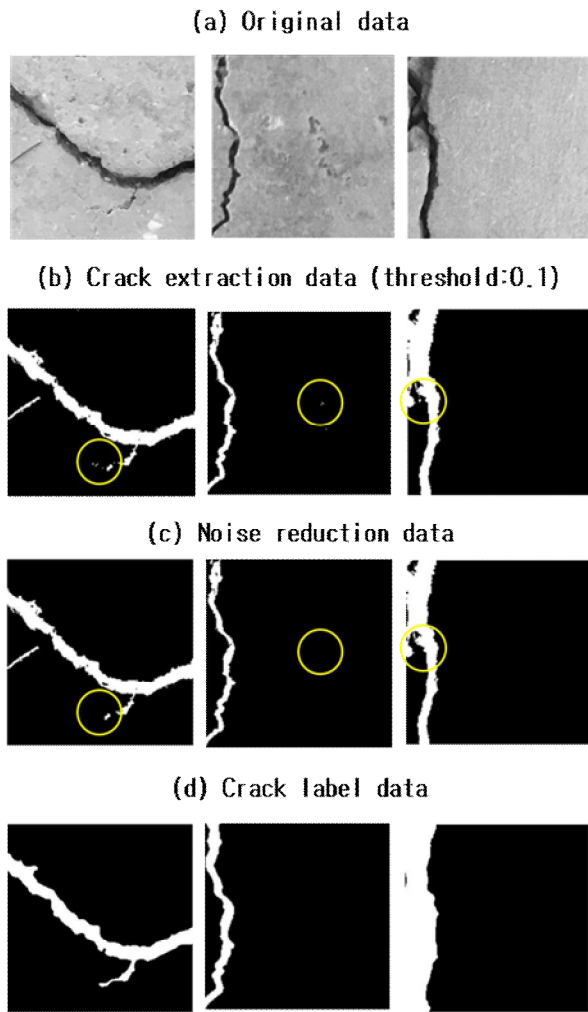


Fig. 8. Results of noise reduction

Table 3. Evaluation Indicator of Classification Performance [12]

Indicator	Description
Precision	It is the fraction of true positives out of what the model classifies as true, which excludes false positives.
Recall	It is the fraction of retrieved positives out of true positives and false negatives.
Accuracy	It is the fraction of the correctly predicted and can show the performance of a model most intuitively. But, its value as a performance indicator decreases when the portion of the independent variables is imbalanced.
F1_Score	The harmonic mean of precision and recall is an indicator that can accurately assess the performance of a model and explain how effective the model is when the data are unbalanced. It evaluates how well recall and precision are harmonized and not biased. If the value is skewed to one side, the harmonic mean comes out low, and the higher the value, the better performance model.

최종적으로 잡음이 제거된 이미지를 활용하여 모델의 성능을 평가했다. 성능 평가의 척도는 정밀도(Precision), 재현율(Recall), 그리고 조화평균(F1_Score)을 사용하였다. 이 지표들은 오차 행렬(Confusion Matrix)을 바탕으로 모델의 성능이 얼마나 정확한지 평가하는 지표로 각 지표들에 대한 설명은 Table 3과 같다.

Table 4는 임계값(threshold)에 따른 성능 평가 결과이다. 테스트 결과 임계값(Threshold)이 0.1 일 때 성능이 가장 좋았으며 해당 평가 결과 정밀도(Precision)가 0.9104, 재현율(Recall)이 0.7571, 조화평균(F1_Score)이 0.8267로 측정되었다.

Table 4. Evaluation Result of Performance

Threshold	Precision	Recall	Accuracy	F1_Score
0.01	0.3593	0.8701	0.9353	0.5085
0.05	0.7788	0.8109	0.9839	0.7945
0.1	0.9104	0.7571	0.9878	0.8267
0.11	0.9243	0.7476	0.9879	0.8266
0.15	0.9604	0.7094	0.9877	0.8160

다만 모델 학습 및 테스트를 거듭할수록 정밀도는 높아지고 재현율은 일정 수치 이상 오르지 않는 현상이 발생했다. 이는 Fig. 7과 Fig. 8의 세 번째 이미지의 라벨 이미지와 Fig. 9에서 보듯이, 균열 라벨 데이터가 실제 균열에 비해 크게 그려져 있어 균열이 아무리 정교하게 추출이 되어도 재현율이 떨어지는 원인이 된 것으로 파악했다. Fig. 9의 (a)는 원본 균열 이미지와 균열 라벨 이미지를 합성한 이미지이고, (b)는 원본 균열 이미지와 예측 이미지를 합성한 이미지이다. 균열 라벨 이미지의 범위가 원본에 비해 넓고, 예측 이미지가 더 정교하게 추출된 것을 확인할 수 있다.

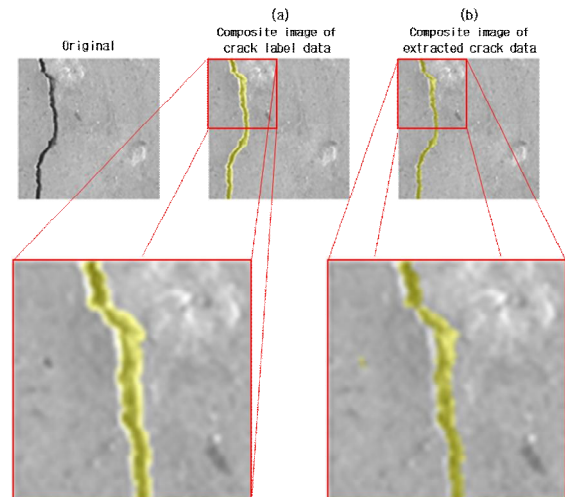


Fig. 9. Comparison between Crack Label Image and Crack Detection Image

또한, 기존 U-Net을 통한 균열 추출의 경우 Table 5와 같이 정밀도(Precision)가 0.949, 재현율(Recall)이 0.875, 조화평균(F1_Score)이 0.91로 본 연구 결과보다 높은 수치를 기록했다. 하지만 이 역시 U-Net은 라벨처럼 출력하도록 학습되었기 때문에 실제 균열보다 두껍게 칠해져서 오히려 성능 평가에서는 높은 성과를 얻을 수 있던 것으로 보인다. 즉, 기존의 균열 추출 방식보다 본 연구에서 제안한 방식이 오히려 균열을 정밀하게 추출할 수 있다는 것을 확인했다.

Table 5. Evaluation Result of Performance(U-Net)

Threshold	Precision	Recall	Accuracy	F1_Score
0.1	0.806	0.922	0.988	0.86
0.4	0.949	0.875	0.993	0.91
0.75	0.986	0.807	0.992	0.888
0.9	0.994	0.742	0.989	0.85

IV. Conclusions

본 연구에서는 딥러닝 기반의 균열 추출 시스템의 성능 개선을 위해 U-Net 기반의 이미지 복원 및 이미지 합성을 활용하여 정밀한 균열 추출 방안을 연구하였다. 연구 결과, 정확도 98.78%, 조화평균(F1_Score) 82.67%의 높은 수치를 도출하여 추후 균열 탐지 분야에 이상 탐지 방식을 응용하여 성능을 개선하는 방안을 제안하였다.

하지만 일부 미세한 균열의 경우에는 정상 부분과의 grayscale 값의 차이가 크지 않아 균열 추출이 제대로 이루어지지 않았고 균열 라벨 데이터의 정교성 한계로 인해 학습이 제대로 수행되지 않은 한계점을 보였다.

따라서 추후 연구에서는 외적 인자(Hyperparameter)를 다양화해 기존의 학습 모델을 최적화하고 본 연구에서 활용한 테스트 데이터보다 현장성 있는 데이터를 확보하여 성능 향상을 위한 방안을 더 모색할 것이다.

REFERENCES

[1] Ministry of Land, Infrastructure and Transport, Detailed instructions for the safety and maintenance of facilities, 2019
 [2] Kim, Ah-Ram, Kim, Donghyeon, Byun, Yo-Seph, Lee, Seong-Won, 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., 2018, DOI:10.7843/kgs.2018.34.12.145

[3] Jung, Seo-Young, Yu, Jung-Ho. A Proposal of Automatic Condition Evaluation Process based on Unsupervised Learning. Proceedings of KICEM Annual Conference, pp.79-80, 2019.
 [4] Lee Hoseong, Anomaly Detection Overview , <https://hoya012.github.io/blog/anomaly-detection-overview-1/>
 [5] Oh Miae, Study on anomaly detection based on Machine Learning (Report No.2018-16), Korea Institute for Health and Social Affairs, 2018
 [6] D. Carrera, G. Boracchi, A. Foi and B. Wohlberg, "Detecting anomalous structures by convolutional sparse models," 2015 International Joint Conference on Neural Networks (IJCNN), Killarney, 2015, pp. 1-8, doi: 10.1109/IJCNN.2015.7280790.
 [7] Kang, Eunsuk, U-NET, https://modulabs-biomedical.github.io/U_Net
 [8] Exxact Corporation, Atrous Convolutions & U-Net Architectures for Deep Learning: A Brief History, <https://blog.exxactcorp.com/atrous-convolutions-u-net-architectures-for-deep-learning-a>
 [9] Seo, Wonju, UNET, <https://wewinserv.tistory.com/30>
 [10] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," MICCAI, 2015. DOI: 10.1007/ 978-3-319-24574-4_28
 [11] Çağlar Fırat Özgenel, Concrete Crack Segmentation Dataset, <https://data.mendeley.com/datasets/jwsn7tfrbp/1#file-52a39c5f-6914-4e26-88e7-ec81bfbc938e>
 [12] Kim Chungyun, Evaluation Method of Classification Model, <https://velog.io/@skypepodium/%EB%B6%84%EB%A5%98-%EB%AA%A8%EB%8D%B8-%ED%8F%89%EA%B0%80-%EB%B0%A9%EB%B2%95>

Authors



Su-Min Kim received the A.S degrees in Computer Systems & Engineering from Inha Technical College in 2020. Kim has been working at Epozen's research institute since 2020. She is interested in artificial

intelligence, cloud computing.



Jung-Mo Sohn received the B.S. and M.S. degrees in Industrial Automation from Inha University, Korea, in 1998 and 2000, respectively. Sohn has been working at Epozen's research institute since 2018.

He is interested in artificial intelligence, cloud computing, and information security.



Do-Soo Kim received the B.S. and M.S. degrees in Information and Communication Engineering from Honam University, Korea, in 2003 and 2005, respectively. Kim is currently a SW engineer in the Research

Institute, EPOZEN. He has developed c/s applications and is currently interested in artificial intelligence and mobile application development.