

# Dilated U-Net에 기반한 이미지 복원 기법을 이용한 콘크리트 균열 탐지 개선 방안

김수민\*, 손정모<sup>o</sup>, 김도수\*

\*이포즌 기업부설연구소,

<sup>o</sup>이포즌 기업부설연구소

e-mail: ksum\_3@epozen.com\*, jmsohn@epozen.com<sup>o</sup>, dskim@epozen.com\*

## Improvement of concrete crack detection using Dilated U-Net based image inpainting technique

Su-Min Kim\*, Jung-Mo Sohn<sup>o</sup>, Do-Soo Kim\*

\*Epozen's research institute,

<sup>o</sup>Epozen's research institute

### ● 요약 ●

본 연구에서는 Dilated U-Net 기반의 이미지 복원기법을 통해 콘크리트 균열 추출 성능 개선 방안을 제안한다. 콘크리트 균열은 구조물의 미관상의 문제뿐 아니라 추후 큰 안전사고의 원인이 될 수 있어 초기대응이 중요하다. 현재는 점검자가 직접 육안으로 검사하는 외관 검사법이 주로 사용되고 있지만, 이는 정확성 및 비용, 시간, 그리고 안전성 면에서 한계를 갖고 있다. 이에 콘크리트 구조물 표면에 대해 획득한 영상 처리 기법을 사용한 검사 방식 도입의 관심이 늘어나고 있다. 또한, 딥러닝 기술의 발달로 딥러닝을 적용한 영상 처리의 연구 역시 활발하게 진행되고 있다. 본 연구는 콘크리트 균열 추가선출 성능 개선을 위해 Dilated U-Net 기반의 이미지 복원기법을 적용하는 방안을 제안하였고 성능 검증 결과, 기존 U-Net 기반의 정확도가 98.78%, 조화평균 82.67%였던 것에 비해 정확도 99.199%, 조화평균 88.722%로 성능이 되었음을 확인하였다.

**키워드:** 딥러닝(Deep Learning), 균열 검출(Crack Detection).

이상 탐지(Anomaly Detection), Dilated U-Net

## I. Introduction

콘크리트 구조물은 시간이 지남에 따라 복합적인 원인으로 인해 발생하게 된다. 이는 구조적 결함, 내구성 저하, 외관 손상 등으로 치명적인 사고의 원인이 될 수 있다. 다양한 균열 원인 중 미세균열이 발생 되어 서서히 진행되는 경우를 방지하고자 주기적인 외관 검사를 수행한다. 현재 외관 검사법은 점검자가 육안으로 검사하는 방식이 주로 사용되고 있으며 이는 다양한 인적 오류의 발생을 초래한다. 이에 영상 처리를 통한 균열 측정 방식에 관한 연구들이 다양하게 이루어지고 있다.

최근 딥러닝을 통한 이미지 처리 기법의 발전에 따라 이를 활용한 균열 탐지 방식에 관한 연구 또한 활발하게 이루어지고 있다. 딥러닝을 적용해 일정 성능을 이루기 위해서는 학습 과정에서 많은 균열 데이터가 있어야 하는 경우가 많다. 하지만 검사 대상물이 신축건물, 관리 초기 단계의 건물일 때 해당 대상물에 대한 균열 데이터가 매우 적어 기존의 학습 방식 사용 시 성능 만족이 어려울 것으로 판단된다[1].

본 연구는 “이미지 복원기법을 통한 콘크리트 균열 탐지 방안

(U-Net) (이름, 2020)”의 후속연구이다. 해당 연구에서는 대상물의 정상 이미지와 다양한 균열 이미지를 합성한 합성 이미지를 정상 이미지로 복원시키도록 U-Net 구조를 통한 학습 방안을 제안했다. 이 과정을 통해 나온 출력 데이터와 입력된 합성 데이터 간의 **difference map**을 사용해 균열을 추출하는 방식으로, 정확도 98.78%, 조화평균 (F1\_Score) 82.67%의 성능을 보였다[2]. 이에 본 논문에서는 U-Net 을 통한 이미지 복원기법의 성능을 향상하고자 Dilated U-Net을 적용하는 방안을 제안한다.

## II. Preliminaries

### 1. Related works

#### 1.1 이미지 복원 기법을 통한 균열 추출 방안

이미지 복원을 통한 균열 추출 과정은 균열 데이터 합성, 이미지 복원 학습, 균열 추출로 이루어진다.

데이터 합성 과정은 이미지 복원 학습용 이미지 생성을 위해 균열이 없는 정상 이미지와 균열 이미지를 합성하는 과정이다. Fig.1은 이미지 복원 학습 과정을 나타내고 있는데, 1번과 2번은 데이터 합성 과정이다. 1번에서는 균열 라벨 이미지와 균열 이미지의 픽셀 간 곱을 통해 균열 이미지의 균열 부분에 해당하는 grayscale 값을 구하여 마스킹 균열 이미지를 생성하고 2번에서는 생성된 이미지를 정상 이미지와 랜덤하게 합성해 합성 균열 이미지를 생성한다. 이 과정은 점검 대상물의 균열 이미지 개수가 많지 않아도 학습이 가능하게 해 주는 과정이다. 이후 3번 과정에서 이미지 복원 학습을 위해 합성된 데이터와 정상 데이터를 입력하게 된다. 학습 모델은 입력된 데이터로부터 균열을 지워 정상 데이터로 복원하도록 학습한다.




Fig. 1. Process of Learning Model for Concrete Crack Image Inpainting[2]

균열 추출 과정은 이미지 복원 학습 과정이 끝나면, Fig.2와 같이 입력 이미지와의 difference map을 구해 균열을 추출하는 과정이다. 학습 모델은 균열로부터 정상 이미지로 복원을 시도하기에 학습 결과 데이터와 입력 데이터 간의 grayscale 값의 차이가 균열 부분에 해당하게 된다. difference map 생성에 결과적으로 아래 식과 같이 relu 함수를 적용한다.

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

$I_{xy}$ 는 입력 이미지의 픽셀 값이며,  $O_{xy}$ 는 출력 이미지의 픽셀 값이다.  $D_{xy}$ 는 최종적으로 검출된 균열 이미지의 픽셀 값이다.[2]




Fig. 2. Process of Concrete Crack Detection[2]

#### 1.2 Dilated U-Net

U-Net은 크게 인코딩 부분과 디코딩 부분으로 이루어져 있는데, 인코딩 부분에서는 고차원의 이미지를 저차원 형태로 변경시켜준다. 이 과정에서 이미지 속의 특징들을 추출한다. 디코딩 부분은 이러한 저차원으로 변환된 이미지를 다시 고차원으로 변경시킨다. U-Net은 각 인코딩과 디코딩 과정의 층계를 같게 유지하고 디코딩 과정에서 층계별로 같은 층의 인코딩 과정에서 추려낸 정보들을 연결해 사용한다. 이 과정을 통해 일반적인 인코더-디코더 구조에서 활용하지 못한 공간 정보들을 활용하게 된다[3].

Dilated U-Net 구조는 dilation box 모듈이 추가된다는 점에서 U-Net 구조와 차이가 있다. Fig. 3에서 보듯, 인코딩 과정에서 디코딩 과정으로 넘어가는 bottle-neck 구간에 존재하는 dilation box는 dilated convolution을 병렬로 적용한 구조이다.

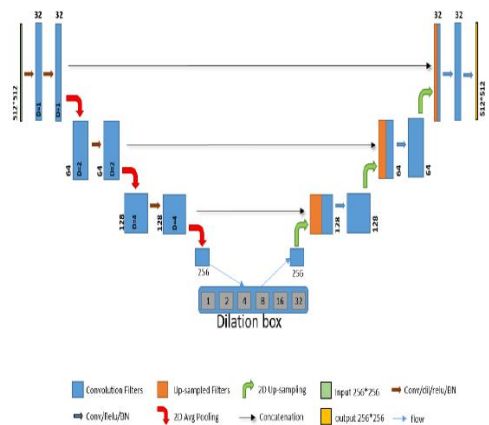


Fig. 3. Dilated U-Net architecture[4]

fig. 4는 dilation box 안에 구성된 dilation convolution의 병렬적 구조를 나타낸 것이다. 인코딩을 마친 후 rate를 다르게 구성한 dilated convolution 연산들을 각각 수행하고, 최종적으로 모든 연산 결과를 결합한다. 이 과정을 통해 서로 다른 수준의 특징 맵들을 합쳐 더 나은 특징 추출을 이루어낼 수 있다. 해당 구조를 사용함으로써 항상

추출 성능 저하를 초래하지 않고 더 깊은 연산들을 수행할 수 있다.[4][5]

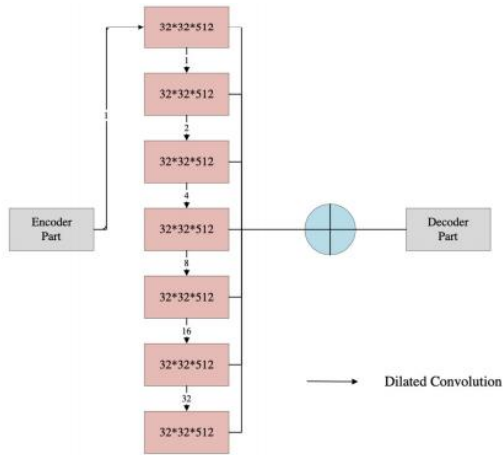


Fig. 4. Dilated box structure[5]

### III. The Proposed Scheme

#### 1. 모델 학습 수행

본 연구는 Tesla P40 GPU x 2 환경에서 수행되었으며, 연구에 사용한 학습 모델은 Keras 2.3버전 기반으로 구성되었다.

모델 학습에 사용된 데이터는 인터넷에서 수집했으며, 해당 데이터셋은 중동공과대학교(METU)에서 학교 건물의 균열 이미지를 수집한 데이터이다[6]. 균열 이미지, 균열 라벨 이미지로 이루어져 있으며 본 학습에서는 해당 데이터셋을 512x512로 분할하여 사용했다. 분할 데이터 중 균열이 없는 데이터(정상 데이터) 6,638 개와 균열 데이터를 랜덤하게 합성해 균열 합성 이미지를 생성했다.

“Accuracy Improvement of UNet Based on Dilated Convolution (Shengyuan Piao., 2019)”에 따르면, Dilation U-Net은 dilated convolution의 적용을 통해 깔끔한 객체 인식 성능을 보였으며 기존 U-Net보다 성능이 향상되었다는 연구 결과가 있다[5]. 이에 본 연구에서는 Dilation U-Net 모델을 구성하여 학습을 진행하였다.

U-Net 모델은 3계층, 4계층, 5계층으로 구성했으며, Dilation box는 [{1, 2, 4, 8}, {1, 2, 4, 8, 16}, {1, 2, 4, 8, 16, 32}]로 구성해 학습을 진행하였다. 모델의 학습을 위해 적용된 외적 인자(Hyperparameter)은 Table 1과 같다.

Table 1. Hyperparameter for the Learning Model

Hyperparameter (unit)	Value
Filter (count)	16-32-64-128-64-32-16
	16-32-64-128-256-128-64-32-16
	16-32-64-128-256-512-256-128-64-32-16
Layer (count)	3, 4, 5
kernel size (pixel)	5x5

#### 2. 모델 성능 평가

모델 학습 결과로 생성된 difference map은 threshold 적용을 통해 0과 1의 이미지로 변환되어 균열 추출 결과를 확인하는 데 사용된다. 모델의 성능 평가는 균열 추출 결과를 정밀도(Precision), 재현율(Recall), 정확도(Accuracy), 그리고 조화평균(F1\_Score)이라는 성능 지표를 통해 dilation box에 따른 계층 수별로 모델의 성능을 평가하였다.

Table 2-4는 threshold 0.05를 적용했을 때, dilation box에 따른 각 계층 수별 모델의 성능 평가 결과를 나타낸 것이다.

Table 2. Performance Indicator of Layer 3

dilation box	Precision	Recall	Accuracy	F1_Score
{1,2,4,8}	0.94228	0.8183	0.99108	0.87593
{1,2,4,8,16}	0.90107	0.82013	0.98962	0.85870
{1,2,4,8,16,32}	0.94488	0.81585	0.99109	0.87564

Table 3. Performance Indicator of Layer 4

dilation box	Precision	Recall	Accuracy	F1_Score
{1,2,4,8}	0.92742	0.82422	0.99076	0.87278
{1,2,4,8,16}	0.96709	0.81953	0.99199	0.88722
{1,2,4,8,16,32}	0.92154	0.81820	0.99033	0.86680

Table 4. Performance Indicator of Layer 5

dilation box	Precision	Recall	Accuracy	F1_Score
{1,2,4,8}	0.96616	0.77599	0.99034	0.86070
{1,2,4,8,16}	0.94026	0.81656	0.99095	0.87406
{1,2,4,8,16,32}	0.93765	0.80842	0.99056	0.86825

성능 평가 결과, Table 3과 같이 dilation box가 {1, 2, 4, 8, 16}, 4계층으로 구성된 학습 모델이 정확도 99.199%, 조화평균 88.722%로 가장 성능이 좋았다.

Fig. 5는 기존 U-Net을 사용한 이미지 복원기법 결과와 Dilated U-Net을 적용한 복원기법 결과를 비교한 이미지이다. 기존 U-Net을 사용했을 때보다 배경으로 인한 큰 잡음들이 제거되고 보다 깔끔한 균열 탐지가 이루어진 것을 확인할 수 있다.




Fig. 5. Crack extraction data comparison

#### IV. Conclusions

본 연구는 U-Net 구조를 사용한 이미지 복원기법 대신 Dilated U-Net 구조를 사용해 균열 검출을 시도했다. 그 결과, 정확도 (Accuracy) 99.199%, 조화평균(F1\_Score) 88.722%로, 기존 U-Net의 정확도 98.78%, 조화평균 82.67% 보다 성능이 개선되었다. 이는 Dilated U-Net을 사용한 경우, 이미지의 복원이 더욱 정확하게 이루어져 성능이 개선된 것으로 분석된다. 결론적으로, 콘크리트 균열 검출시 Dilated U-Net 적용하여 더욱 높은 성능을 얻을 수 있었음을 보였다.

#### REFERENCES

- [1] 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.
- [2] Su-Min Kim, Jung-Mo Sohn, Do-Soo Kim. A method for concrete crack detection using U-Net based image inpainting technique. Journal of The Korea Society of Computer and Information. Vol.25 No. 10, 2020. DOI:10.9708/jksci.2020.25.10.035
- [3] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," MICCAI, May 2015. DOI: 10.1007/978-3-319-24574-4\_28

- [4] VESAL, Sulaiman; RAVIKUMAR, Nishant; MAIER, Andreas. A 2D dilated residual U-Net for multi-organ segmentation in thoracic CT. arXiv preprint arXiv:1905.07710, 2019.
- [5] Shengyuan Piao and Jiaming Liu. "Accuracy improvement of unet based on dilated convolution." Journal of Physics: Conference Series. Vol. 1345. No. 5. IOP Publishing, 2019.
- [6] Çağlar Firat Özgenel, Concrete Crack Segmentation Dataset, <https://data.mendeley.com/datasets/jwsn7tfbrp/1#file-52a39c5f-6914-4e26-88e7-ec81bfb938e>