

Improvement of learning concrete crack detection model by weighted loss function

Jung-Mo Sohn*, Do-Soo Kim*, Hye-Bin Hwang*

*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 an improvement method that can create U-Net model which detect fine concrete cracks by applying a weighted loss function. Because cracks in concrete are a factor that threatens safety, it is important to periodically check the condition and take prompt initial measures. However, currently, the visual inspection is mainly used in which the inspector directly inspects and evaluates with naked eyes. This has limitations not only in terms of accuracy, but also in terms of cost, time and safety. Accordingly, technologies using deep learning is being researched so that minute cracks generated in concrete structures can be detected quickly and accurately. As a result of attempting crack detection using U-Net in this study, it was confirmed that it could not detect minute cracks. Accordingly, as a result of verifying the performance of the model trained by applying the suggested weighted loss function, a highly reliable value (Accuracy) of 99% or higher and a harmonic average (F1_Score) of 89% to 92% was derived. The performance of the learning improvement plan was verified through the results of accurately and clearly detecting cracks.

▶ **Key words:** Deep Learning, Concrete Crack, Crack Detection, Loss Function, U-Net

[요 약]

본 연구에서는 가중치 오차 함수를 적용하여, 미세한 콘크리트 균열을 감지하는 U-Net 모델을 만들 수 있도록 개선 방안을 제안한다. 콘크리트 균열은 안전을 위협하는 요소이기 때문에 그 상태를 주기적으로 파악하고 신속하게 초기 대응을 하는 것이 중요하다. 하지만 현재는 점검자가 직접 육안으로 검사하고 평가하는 외관 검사법이 주로 사용되고 있다. 이는 정확성뿐만 아니라 비용과 시간, 안전성 측면에서도 한계점을 가진다. 이에 콘크리트 구조물에 생성되는 미세한 균열을 신속하고 정밀하게 탐지할 수 있도록 딥러닝을 활용한 기술들이 연구되고 있다. 본 연구에서 U-Net을 활용한 균열 탐지를 시도한 결과, 미세한 균열을 탐지하지 못하는 것을 확인하였다. 이에 제시한 가중치 오차 함수를 적용하여 학습한 모델에 대해 성능을 검증한 결과, 정확도(Accuracy) 99% 이상, 조화평균(F1_Score) 89%에서 92%의 신뢰성 높은 수치를 도출해내었고, 미세한 균열을 정확하고 선명하게 탐지한 결과를 통해 학습 개선 방안의 성능을 검증하였다.

▶ **주제어:** 딥러닝, 콘크리트 균열, 균열 검출, 오차 함수, U-Net

- First Author: Jung-Mo Sohn, Corresponding Author: Jung-Mo Sohn
- *Jung-Mo Sohn (jmsohn@epozen.com), Epozen's research institute
- *Do-Soo Kim (dskim@epozen.com), Epozen's research institute
- *Hye-Bin Hwang (heybin2125@epozen.com), Epozen's research institute
- Received: 2020. 08. 12, Revised: 2020. 09. 25, Accepted: 2020. 10. 05.

I. Introduction

콘크리트 구조물의 균열은 시공방법, 주변 환경 그리고 시간이 지남에 따라 점차 발생하게 된다. 이는 구조물의 미적 특성을 떨어뜨릴 뿐만 아니라, 장기적으로 구조물의 안전을 위협하게 하는 요인이 될 수 있다. 그러므로 콘크리트 구조물의 균열 상태를 주기적으로 파악하고 신속한 초기 대응을 진행하는 것이 안전성 유지 측면에서 매우 중요하다.

콘크리트 표면의 균열은 고체의 표면이나 내부에 금이 가는 현상으로서 외력에 의한 응력 발생, 시공 후 관리 불량에 따른 수분 손실 등이 그 원인이 될 수 있다. 콘크리트 균열이 발생하면 콘크리트 내부에 수분과 공기가 침투할 수 있게 된다. 침투한 수분과 공기는 콘크리트를 탄산화하고 내부 철근을 부식시켜 콘크리트의 강도를 낮추는 원인이 된다. 따라서 콘크리트 표면의 균열은 구조물에 심각한 손상을 초래할 수 있어, 이를 정확히 탐지하는 기술이 필요하다. 균열을 발견한 뒤에는 적절한 조치와 관리가 필수적이다.

현재 콘크리트 균열 탐지 방법은 점검자가 직접 육안으로 검사하고 평가하는 외관 검사법이 주로 사용되고 있다. 이러한 방법은 작업 시간, 비용, 작업자 안전성의 문제점을 가지고 있다[1]. 최근에는 무인항공기와 디지털 영상 처리 기법을 이용하여 콘크리트 구조물의 균열 이미지를 원거리에서도 탐지할 수 있는 방법이 한국 공개특허 제 10-2017-0100990호 (2017.09.05)로 공개된 바 있다[2]. 제시된 방안은 이미지 처리를 위해 미디안 필터를 적용하여 균열을 추출하는 것으로 빗물자국, 그림자등 다양한 외부환경에서 균열을 추출하기에는 취약한 점이 있다. 또한 라인 레이저 센서와 영상분석 기술을 적용하여 균열도를 만드는 방법이 제시되었다[3]. 라인 레이저 센서로 콘크리트 벽면을 스캔한 후 영상분석 기술로 균열을 추출하는 방법이다. 하지만 제시된 기술은 고가의 특수 장비나 전문 인력이 필요하여 많은 시간과 비용이 드는 문제가 있었다. 따라서 콘크리트 구조물에 생성되는 다양한 크기의 균열을 저비용으로 신속하고 정밀하게 탐지하며, 신뢰성이 높고 오차를 최소화할 수 있는 인공지능 콘크리트 균열 학습 및 탐지 기술 개발이 요구되고 있다[4].

최근 콘크리트 균열 탐지를 위해 다양한 딥러닝 알고리즘들을 이용한 연구들이 진행되고 있다. 딥러닝을 활용한 콘크리트 균열 검출방법으로는 CNN(Convolutional Neural Network) 베이스의 균열 구성 요소 인식(CCA, crack-component-aware) 네트워크와 균열 지역 인식(CRA, crack-region-aware) 네트워크를 결합하여 만든 모델로 균열을 검출하는 방안이 연구되었다[5]. “딥러닝을

이용한 자동화된 콘크리트 균열 탐지 기술”에서는 수집된 이미지를 Mask R-CNN 모델에 학습시켜 콘크리트 균열을 탐지하는 사례가 있다. 하지만 0.3mm 이상의 균열에 대해서만 95.2%의 높은 탐지율(Detectability)이 측정되었고 그보다 작은 균열의 경우, 0.1~0.3mm는 83.5%, 0.1mm 이하는 70.3%의 탐지율을 보였다. 전체적으로 76.2%의 탐지율을 보여 주었으며 미세한 균열의 경우에는 정확히 탐지하지 못하는 한계가 있었다[6].

따라서 본 연구에서는 딥러닝 알고리즘 기술을 이용하여 오차 함수에 가중치를 부여하는 방법으로 미세 균열 폭에 대한 U-Net 모델 학습이 가능하도록 개선하여, 신뢰성이 높고 오차를 최소화할 수 있는 콘크리트 균열 학습 방법을 제안하였다.

II. Preliminaries

1. Related works

1.1 U-Net

본 연구에서는 픽셀들을 클래스에 맞추어 분할하는 의미론적 세분화(Semantic Segmentation) 모델 중, 가장 많이 쓰이고 좋은 성능을 보인 U-Net 딥러닝 모델을 활용하였다.

U-Net은 생물의학(Biomedical) 분야에서 이미지 분할을 목적으로 제안된 End-to-End 방식의 Fully Convolutional Network 기반 모델이다. 기존 생물의학 분야에서의 이미지 작업은 전문가의 분석에 크게 의존하는 환경이었다. 하지만 딥러닝 모델의 출현으로 의학 분야의 X-ray, MRI 등에서 딥러닝을 활용한 데이터 분석이 증가하고 있다. 의료 연구에서는 자동화된 현미경 실험으로 수 테라바이트에 달하는 이미지가 생성되는데, 각 이미지에 Semantic Segmentation 방법을 적용하여 셀(cell)과 셀 구성 요소를 분류하였다. 결과적으로 U-Net의 구조를 활용하여 여러 Biomedical Image Segmentation 문제에서 우수한 성능을 보여 주었다[7].

U-Net은 Fig. 1과 같이 U자형 아키텍처와 고차원 형태의 이미지를 저차원 형태의 이미지로 변경시켜주는 Encoder(부호기), 인코딩된 이미지를 원래 형태로 변경해주는 Decoder(복호기) 구조를 가지고 있다. Encoder에서 축약된 정보를 Decoder에 연결해서 사용한다는 점으로 인해 Convolution의 Maxpooling과 이미지 축소로 공간 정보를 얻을 수 있다는 장점이 있다[8][9][10].




Fig. 1. U-Net Architecture[11]

1.2 Loss Function and Weighted Loss Function

딥러닝에서는 학습을 통해 최적의 가중치 매개변수를 결정하기 위한 지표로 오차 함수(Loss Function)를 사용한다. 오차 함수란 예측값과 정답(라벨)의 오차를 정의하는 함수로 오차 함수의 결과값(오차)을 가장 작게 만드는 것이 신경망 학습의 목표이다. 신경망의 학습은 오차 함수의 결과값을 작게 만들기 위해 가중치 매개변수를 조작해 나가는 과정이다. 이 각각의 가중치 매개변수를 어디로 얼마나 조절해야 오차 함수의 결과값이 작아질지를 결정할 때 참고하는 것이 미분값(기울기)이다. 오차 함수는 평균 제곱 오차(Mean Squared Error, MSE)와 교차 엔트로피 오차(Cross Entropy Error, CEE)로 분류되며, 본 연구는 오차 함수로 평균 제곱 오차 함수를 사용하였다[14]. Table 1은 평균 제곱 오차 함수 성능 지표를 보인 것이다. 임계값을 0.4로 주었을 때, 조화평균 91%의 값이 도출되었다. 하지만 Fig. 2의 균열을 시각화한 학습 결과를 보면 일정 두께 이상의 균열에 대해서는 학습에 문제가 없었지만, 표시된 이미지와 같이 미세한 균열에 대해서는 검출되지 않았다.

Table 1. Performance Indicator of Mean Square Error Function

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

미세 균열 이미지는 균열이 차지하는 면적이 평균 1.6% 이하로 확인되었다. 만일, 미세 균열 이미지의 모든 픽셀에 대해 균열이 아님으로 예측하게 된다면, 98.4%의 높은 정확도를 가지게 되는 것이다. 이에 따라, 학습 시 일반적인 균열에 대해서는 정확히 예측하고, 미세 균열에 대해서는 모두 균열이 아님으로 처리하여, 정확도 수치상으로 높은 정확도를 가지도록 학습하는 것으로 추측하였다. 따라서, 본 연구에서는 균열 발생 부위 예측 실패 시 높은 가중




Fig. 2. The Learning Results with Mean Square Error Function

치로 오차를 크게 만들어 미세 균열에 대한 탐지를 수행할 수 있는 학습 방안을 연구하였다. 오차 함수에 가중치를 부여하는 학습 방안은 아래 4가지 함수를 사용하였다.

• Balanced Step Function

가중치를 1 이상의 값으로 부여할 시, 결과값이 음수로 떨어지기 때문에 가중치를 0 ~ 1 사이의 값으로 부여하며, 식은 아래와 같다.

$$(1 + weight * sign(라벨값 - 예측값)) * 제곱오차함수(라벨값, 예측값)$$

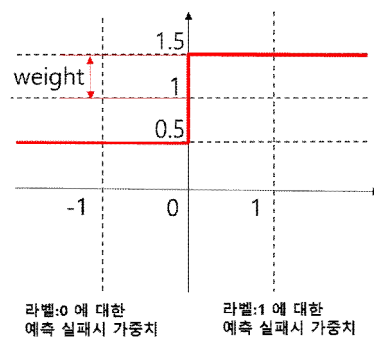


Fig. 3. Balanced Step Function(weight=0.5)

• Squared&Balanced Step Function

가중치를 1 이상의 값으로 부여할 수 있으며, 식은 아래와 같다. 제시된 방안 중 가장 왜곡이 심한 함수이다.

$$(1 + \text{weight} * \text{sign}(\text{라벨값} - \text{예측값}))^2 * \text{제공오차함수}(\text{라벨값}, \text{예측값})$$




Fig. 4. Squared&Balanced Step Function(weight=0.5)

• Step Function

가중치를 1 이상의 값으로 부여할 수 있으며, 식은 아래와 같다.

$$(1 + \text{weight} * \text{sign}(\text{relu}(\text{라벨값} - \text{예측값}))) * \text{제공오차함수}(\text{라벨값}, \text{예측값})$$




Fig. 5. Step Function(weight=0.5)

• ReLU Function

가중치를 1 이상의 값으로 부여할 수 있으며, 식은 아래와 같다. 제시된 방안 중 가장 왜곡이 작은 함수이다.

$$(1 + \text{weight} * \text{relu}(\text{라벨값} - \text{예측값})) * \text{제공오차함수}(\text{라벨값}, \text{예측값})$$




Fig. 6. ReLU Function(weight=0.5)

위 함수들의 수식에 사용된 weight는 가중치값, sign함수는 양/음수 판별 함수, relu 함수는 0보다 작은 값이 나온 경우 0을 반환하고, 0보다 큰 값이 나온 경우 그 값을 그대로 반환하는 딥러닝 활성화 함수이다.

III. The Proposed Scheme

1. The Learning for the Model

각 함수의 가중치별로 커널 5x5와 7x7, 모델 4계층과 5계층에서 학습을 진행하였다. 가중치는 1이상의 값을 부여할 수 없는 Balanced Step 함수의 경우 최소 0.69에서 최대 0.97의 가중치를 부여하여 학습을 진행했다. Squared&Balanced Step 함수의 경우 제공을 하기 때문에 최소 0.2에서 최대 0.7의 가중치를 부여하여 학습을 진행했다. 그 외 Step 함수와 ReLU 함수는 최소 0.5에서 최대 1.3의 가중치를 부여하여 학습을 진행했다. 오차 함수에 가중치를 부여하여 입력 이미지를 출력(output)에서 재구성함으로써 효과적인 학습이 가능한 U-Net 모델을 학습하도록 수행시킨다.

Fig. 7은 콘크리트 균열 학습 과정을 설명하기 위한 프로세스이다. 먼저 균열이 포함된 콘크리트 균열 이미지 데이터를 입력값으로 입력받는다. 입력받은 콘크리트 균열 이미지 데이터를 Encoding하고, Bottleneck(병목) 부분에서 정보를 압축하면 Decoder가 이를 Decoding하여 균열 상태를 예측할 수 있다[6]. 예측한 균열 상태를 토대로 예측 균열 이미지 데이터를 예측값으로 출력한다. 예측 균열 이미지 데이터에 상응하는 예측값과 라벨 이미지 데이터에 상응하는 라벨값을 비교하여 오차 함수를 산출한다. 산출된 오차 함수에 가중치를 부여하여 가중치 오차 함수를 산출한다. 이 때, Balanced Step 함수, Squared&Balanced Step 함수, Step 함수 및 ReLU 함수를 이용하여 가중치 오차 함수를 산출한다. 산출된 가중치 오차 함수를 토대로 균열 콘크리트 이미지의 균열 상태를 학습한다.




Fig. 7. U-Net Model and Learning Process

학습은 Tesla V100 2GPU 서버와 Tensorflow 1.15 버전에서 진행되었다. 학습용 이미지 데이터는 인터넷에서 2924장의 균열 이미지를 수집하여 512x512 해상도로 조정 한 뒤 사용하였다. 이 데이터는 중동 공과대학교(METU)에서 학교 건물의 균열 이미지 촬영하여 수집한 데이터로, Semantic Segmentation을 위해 2진수의 픽셀(pixel)단위로 분류되어 있다[13]. 랜덤한 학습용 데이터와 라벨을 40개씩 가져와 총 10000회를 학습하였다. 모델의 계층(Layer)은 각각 4계층과 5계층에서, 커널(Kernel)의 크기는 5x5와 7x7에서 학습하였다. 즉, 각 함수별 동일한 가중치(weight)에 대해 총 4번씩 학습이 진행되었다. 모델의 학습을 위해 적용된 외적인자(Hyperparameter)는 Table 2와 같다.

Table 2. Hyperparameter for the Learning Model

Hyperparameter(unit)	Value
Filter(count)	16-32-64-128-64-32-16
Layer(count)	4, 5
Kernel(pixel)	5x5, 7x7

성능 평가의 척도는 정밀도(Precision), 재현율(Recall), 정확도(Accuracy) 그리고 조화평균(F1_Score)을 기준으로 평가하였다. 위 지표들은 오차행렬(Confusion Matrix)을 바탕으로 모델의 성능이 얼마나 정확한지 평가한다. 분류 성능 평가에 사용되는 지표들은 다음 Table 3과 같다.

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.

Fig. 8에서 확인할 수 있듯이, 미세한 균열에 대해서 커널 5x5보다 7x7, 4계층보다 5계층에서의 학습 결과가 좋았기 때문에 본 연구의 학습 결과들은 모두 커널 7x7, 5계층에서의 학습 결과를 기준으로 하였다.



Fig. 8. Learning Results by Kernel and Layer

1.1 Balanced Step Function

Table 4는 커널 7x7, 5계층에서 Balanced Step 함수를 이용했을 때 각 가중치별 학습 결과 성능 지표를 나타낸다. 임계값 0.1~0.9 사이에서 가중치를 변경한 결과, 임계값 0.9에서의 결과값이 가장 높았으므로 이를 기준으로 한다. 각 가중치별 조화평균은 85~90%의 결과를 도출했고, 성능 평가에서의 학습 결과를 시각화하여 나타낸 Fig. 9를 보면, 가중치를 0.83과 0.97로 주었을 때 미세한 균열을 육안상으로 더 선명하게 추출한 것을 볼 수 있다.

Table 4. Performance Indicator of Balanced Step Function

Weight	Threshold	Precision	Recall	Accuracy	F1_Score
0.69	0.9	0.94	0.871	0.992	0.904
0.83	0.9	0.945	0.875	0.993	0.909
0.9	0.9	0.884	0.898	0.991	0.891
0.97	0.9	0.784	0.934	0.987	0.852




Fig. 9. Crack visualization by Weight (Learning with Balanced Step Function)

1.2 Squared&Balanced Step Function

Table 5는 커널 7x7, 5계층에서 Squared&Balanced Step 함수를 이용했을 때 각 가중치별 학습 결과 성능 지표를 나타낸다. 임계값 0.1~0.9 사이에서 가중치를 변경한 결과, 임계값 0.75에서의 결과값이 가장 높았으므로 이를 기준으로 한다. 각 가중치별 조화평균은 86~89%로 비슷하지만 성능 평가에서의 학습 결과를 시각화하여 나타낸 Fig. 10을 보면, 가중치 0.5, 0.7에서 미세한 균열을 육안상으로 더 선명하게 추출한 것을 볼 수 있다.

Table 5. Performance Indicator of Squared&Balanced Step Function

Weight	Threshold	Precision	Recall	Accuracy	F1_Score
0.2	0.75	0.864	0.873	0.989	0.869
0.3	0.75	0.947	0.828	0.991	0.883
0.5	0.75	0.884	0.901	0.991	0.892
0.7	0.75	0.849	0.92	0.99	0.883




Fig. 10. Crack visualization by Weight (Learning with Squared&Balanced Step Function)

1.3 Step Function

Table 6은 커널 7x7, 5계층에서 Step 함수를 이용했을 때 각 가중치별 학습 결과 성능 지표를 나타낸다. 임계값 0.1~0.9 사이에서 가중치를 변경한 결과, 임계값 0.5에서의 결과값이 가장 높았으므로 이를 기준으로 한다. 각 가중치별 조화평균은 89~91%로 비슷하지만 성능 평가에서의 학습 결과를 시각화하여 나타낸 Fig. 11을 보면, 가중치 0.97에서는 미세한 균열을 거의 추출하지 못했다. 가중치를 0.69와 1.3으로 주었을 때 미세한 균열을 육안상으로 더 선명하게 추출한 것을 볼 수 있다.

Table 6. Performance Indicator of Step Function

Weight	Threshold	Precision	Recall	Accuracy	F1_Score
0.5	0.5	0.863	0.916	0.991	0.889
0.69	0.5	0.908	0.892	0.992	0.9
0.97	0.5	0.887	0.907	0.991	0.896
1.3	0.5	0.885	0.906	0.991	0.895




Fig. 11. Crack visualization by Weight (Learning with Step Function)

1.4 ReLU Function

Table 7은 커널 7x7, 5계층에서 ReLU 함수를 이용했을 때 각 가중치별 학습 결과 성능 지표를 나타낸다. 임계값 0.1~0.9 사이에서 가중치를 변경한 결과, 임계값 0.5에서의 결과값이 가장 높았으므로 이를 기준으로 한다. 각 가중치별 조화평균은 88~92%로 비슷하지만 성능 평가에서의 학습 결과를 시각화하여 나타낸 Fig. 12를 보면, 가중치를 0.97와 1.3으로 주었을 때 미세한 균열을 육안상으로 더 선명하게 추출한 것을 볼 수 있다.

Table 7. Performance Indicator of ReLU Function

Weight	Threshold	Precision	Recall	Accuracy	F1_Score
0.5	0.5	0.898	0.88	0.991	0.889
0.69	0.5	0.929	0.926	0.994	0.927
0.97	0.5	0.936	0.921	0.994	0.928
1.3	0.5	0.926	0.909	0.993	0.917




Fig. 12. Crack visualization by Weight (Learning with ReLU Function)

2. The Performance Evaluation of the Model

각 가중치 오차 함수별 가장 높은 조화평균 값을 기준으로 성능을 평가한 결과이다. ReLU 함수가 가중치를 0.97로 주었을 때, 정밀도 93%, 재현율 92%로 조화평균 결과 92%의 값으로 가장 높게 측정되었다. Table 8은 커널 7x7, 5계층에서의 학습 결과 성능 지표를 나타낸다.

Table 8. Performance Indicators by Weight Loss Function

Weight Loss Function	Thres hold	Precis ion	Recall	Accur acy	F1_ Score
Mean Square Error	0.4	0.949	0.875	0.993	0.91
Balanced Step (weight 0.83)	0.9	0.945	0.875	0.993	0.909
Squared&Balanced Step (weight 0.5)	0.75	0.884	0.901	0.991	0.892
Step (weight 0.69)	0.5	0.908	0.892	0.992	0.9
ReLU (weight 0.97)	0.5	0.936	0.921	0.994	0.928

위 성능 평가에서의 학습 결과를 Fig. 13과 같이 시각화해보았다. 차례대로 원본 이미지와 라벨 이미지, Balanced Step 함수, Squared&Balanced Step 함수, Step 함수, ReLU 함수 순으로 나열한 결과이다.

커널 7x7, 5계층에서 가중치 오차 함수를 적용하여 균열을 추출한 결과, 균열 폭이 미세한 경우에도 균열을 추출하

는 것을 육안으로도 확인할 수 있다. 가중치 오차 함수를 이용하지 않고 평균 제곱 오차 함수만을 이용했을 때, 균열 폭이 가늘게 있는 경우 결과가 전혀 나오지 않던 모습을 Fig. 1에서 볼 수 있었다. Fig. 13의 균열 이미지를 보면 Fig. 1에서 나오지 않던 미세한 균열을 가중치 오차 함수를 이용하여 균열을 명확하게 추출한 것을 볼 수 있다.

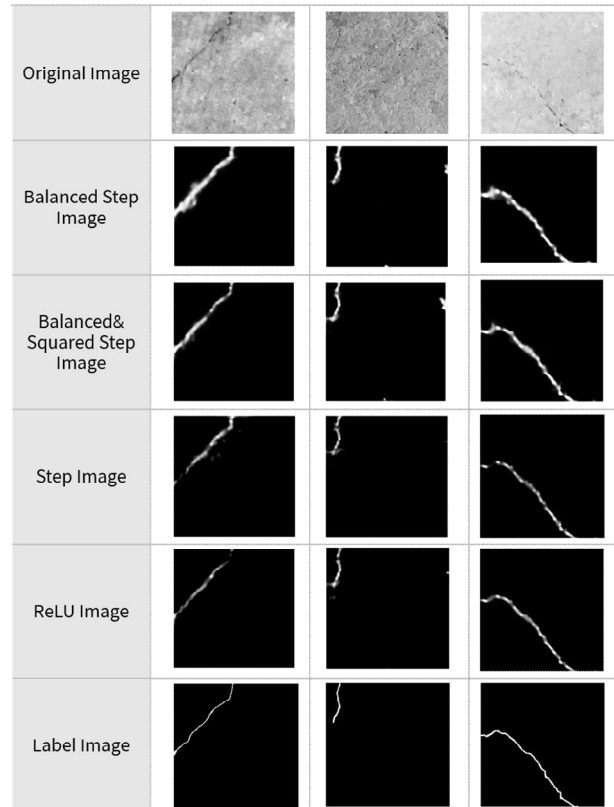


Fig. 13. Crack Visualization by Weighted Loss Function

IV. Conclusions

본 연구에서는 예측값과 라벨값을 비교하여 산출된 오차 함수에 가중치를 부여하여 U-Net 모델을 학습 수행시켰고, 그 결과 오차를 최소화하고 미세한 균열까지 정확하게 학습하여 탐지해낼 수 있는 과정을 수행하였다.

제안한 가중치 오차 함수 중, ReLU 함수(조화평균: 0.928)를 적용한 것이 가장 좋은 결과를 나타내었다. 나머지 함수(Balanced Step, Squared&Balanced Step, Step)는 균열이 아닌 부분을 균열로 표시한 잡음이 증가하였고, 왜곡이 가장 심한 Squared&Balanced Step의 경우, 좋지 못한 결과(조화평균:0.892)를 보였다. 이는 ReLU 함수의 특성상 균열을 탐지하지 못하였을 경우 가장 높은 가중치가 적용되고, 그 이외의 균열을 탐지하였을 경우에

는 가중치에 의한 왜곡이 상대적으로 작게 일어나, 정확도가 높아진 것으로 분석할 수 있었다.

본 연구에서는 인터넷에서 수집한 콘크리트 균열 이미지만을 학습 데이터로 사용했기 때문에 학습 모델이 적용되는 데 제한적일 수 있다. 따라서 추후에는 현장에서 직접 콘크리트 구조물을 촬영한 이미지를 사용한 학습 수행이 필요하고, 다양한 외적 인자(hyperparameter) 변경을 통해 모델을 최적화하여 본 연구에서 진행된 학습 수행 결과보다 더 좋은 결과를 도출해낼 수 있는지 연구할 예정이다.

REFERENCES

- [1] Ministry of Land, Infrastructure and Transport, Detailed guidelines for safety and maintenance of facilities, 2019
- [2] UNIST(ULSAN NATIONAL INSTITUTE OF SCIENCE AND TECHNOLOGY), Apparatus and Method for Detecting Construction Crack, 1020170100990, 2016.02.26., 2017.10.19.
- [3] Junhee Kim, Yoon-Soo Shin and Kyung-Won Min, "Line Laser Image Processing for Automated Crack Detection of Concrete Structures", Journal of the Computational Structural Engineering Institute of Korea, Vol. 31, No. 3, pp.147-153, June 2018. DOI: 10.7734/COSEIK.2018.31.3.147
- [4] 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, Korea, Nov. 2019
- [5] Jieun Lee, Hee-Sun Kim, Nayoung Kim, Eun-Mi Ryu, and Je-Won Kang, "Learning to Detect Cracks on Damaged Concrete Surfaces Using Two-Branched Convolutional Neural Network", SENSORS vol. 19, no. 21, n. pag., November 2019. DOI: 10.3390/s19214796
- [6] Cho, Soojin, Kim, Byunghyun, "Automated Concrete Crack Detection Technique Using Deep Learning", Journal of Structural Integrity and Maintenance, Vol 23, No. 3, pp. 13~21, 2019
- [7] 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>
- [8] 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, pp.145-154, Korea, Dec. 2018, DOI: 10.7843/kgs.2018.34.12.145
- [9] Seo, Wonju, UNET, <https://wewinserv.tistory.com/30>
- [10] Kang, Eunsuk, U-NET, https://modulabs-biomedical.github.io/U_Net
- [11] 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
- [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>
- [13] Çağlar Fırat Özgenel, Concrete Crack Segmentation Dataset, <https://data.mendeley.com/datasets/jwsn7tfbrp/1>
- [14] Um, Sungbum, Artificial Neural Network(ANN) #4-1 Learning(Loss function, Error function), <https://umbum.dev/210>

Authors



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 Epozzen'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.



Hye-Bin Hwang received the A.S degrees in Computer Information from Inha Technical College in 2017. Hwang has been working at Epozzen's research institute since 2018. She is interested in artificial intelligence, cloud

computing.