

## 적대적 생성 신경망과 딥러닝을 이용한 교량 상판의 균열 감지

# Crack Detection on Bridge Deck Using Generative Adversarial Networks and Deep Learning

지봉준<sup>1\*</sup>Bongjun Ji<sup>1\*</sup>

(Received August 24, 2021 / Revised September 1, 2021 / Accepted September 1, 2021)

Cracks in bridges are important factors that indicate the condition of bridges and should be monitored periodically. However, a visual inspection conducted by a human expert has problems in cost, time, and reliability. Therefore, in recent years, researches to apply a deep learning model are started to be conducted. Deep learning requires sufficient data on the situations to be predicted, but bridge crack data is relatively difficult to obtain. In particular, it is difficult to collect a large amount of crack data in a specific situation because the shape of bridge cracks may vary depending on the bridge's design, location, and construction method. This study developed a crack detection model that generates and trains insufficient crack data through a Generative Adversarial Network. GAN successfully generated data statistically similar to the given crack data, and accordingly, crack detection was possible with about 3% higher accuracy when using the generated image than when the generated image was not used. This approach is expected to effectively improve the performance of the detection model as it is applied when crack detection on bridges is required, though there is not enough data, also when there is relatively little or much data for one class.

**키워드 :** 딥러닝, 이미지 생성 모델, 균열 감지, 교량 점검, 콘크리트 교량

**Keywords :** Deep learning, Image generative model, Crack detection, Bridge deck monitoring, Concrete bridge

## 1. 서론

교량의 점검작업은 교량의 상태 진단을 위해 이루어지는 기본적인 필수적인 작업이다. 점검 작업 중 교량의 균열을 감지하는 것은 중요한 점검 항목 중 하나이다. 다리의 균열을 감지하는 것은 위험요소를 조기 발견하고 유지보수를 하기 위해 필요한 작업이다. 교량의 균열은 다양한 이유에 의해 발생하며, 이를 감지하고 시간에 따른 경과를 관찰함으로써 교량의 상태를 추론할 수 있다. 교량의 균열은 잘못된 시공으로 생기기도 하지만, 노후화나 기후 조건 등 다양한 요인에 의해 발생할 수 있으므로 피할 수 없다. 기존에는 이와 같은 교량의 균열을 전문가의 육안으로 점검하는 방법이 일반적이었다. 하지만 육안으로 점검하는 방법에는 여러 한계점이 따른다. 사람에 의존하는 작업이기 때문에 점검자의

역량, 컨디션 등에 영향을 받을 수 있을 뿐더러 시간과 비용이 많이 소요된다.

이에 많은 연구들이 자동으로 균열을 감지해내고자 하였고 몇몇 연구들이 성공적인 감지 성능을 보였지만 상업적으로 성공한 사례를 찾기 힘들다. 이는 기존의 연구들이 특정 상황에서 높은 성능을 보이는, 일반적이지 않은 모델들이기 때문이다. 이러한 한계를 극복하고 일반적인 모델을 개발하기 위해 기계학습을 적용하려는 시도가 있어 왔다. 기계학습은 많은 데이터를 기반으로 데이터의 특성을 자동으로 추출, 클래스를 분류하는데 널리 사용되는 방법이다. 특히 딥러닝이라 불리는 많은 수의 레이어로 구성되는 기계학습의 경우, 많은 수의 데이터를 요구하며, 대부분의 경우 데이터의 양이 많아질수록 좋은 성능을 보인다. 가장 널리 알려진 이미지 분류 Competition인 ImageNet의 경우 1,400만 개 이상의

\* Corresponding author E-mail: [bongjun\\_ji@postech.ac.kr](mailto:bongjun_ji@postech.ac.kr)

<sup>1</sup>포항공과대학교 산업경영공학과 박사 (Department of Industrial and Management Engineering, Pohang University of Science and Technology, Gyeongbuk, 37673, Korea)

이미지가 존재하며 각 이미지가 어떤 객체를 포함하는지 정보(클래스)가 존재한다. ImageNet은 풍선, 강아지, 딸기와 일반적인 정보를 포함하고 있기 때문에 대량의 이미지를 수집하고, 클래스를 할당할 수 있지만, 교량의 경우, 교량의 시공 방법, 교량을 구성하는 재료 등에 따라 교열의 형태와 교열 여부가 달라질 수 있다. 이에 따라 ImageNet과 같이 대량의 이미지를 수집하는데 한계가 있다. 이러한 문제를 해결하기 위해 Generative adversarial networks(GAN)와 같은 이미지 생성 및 변환 기술이 응용될 수 있다(Goodfellow et al. 2014).

GAN은 실제 이미지와 구별 불가능한 변환 이미지를 생성하는 기술이다. 기존의 이미지 처리에 활용하던 기술이 하나의 인공 신경망으로 이루어져 클래스를 예측했다면, GAN은 변환된 이미지를 생성하는 신경망과, 변환된 이미지인지 실제 이미지인지 판별하는 신경망 2개로 이루어져 있다. 특히 기계학습 모델은 데이터 내의 클래스 비율이 크게 차이날 경우, 높은 성능을 보이지 못한다. 이런 경우에 GAN을 통해 데이터를 생성하여 부족한 클래스의 데이터를 보충하는 방식을 사용할 수 있다. 의료분야에서 정상 데이터에 비해 부족한 암이나 종양 데이터를 보충(Lim et al. 2018; Ramponi et al. 2018; Mok and Chung 2018; Han et al. 2020; Lorencin et al. 2021)하거나, 제조분야에서 정상 데이터에 비해 부족한 품질불량 데이터를 생성하는 연구(Gao et al. 2020; Ortego et al. 2020; Peres et al. 2021) 등이 그 예시이다.

본 연구에서는 교량의 상판을 대상으로 교열을 감지하는 모델을 개발한다. 이를 위해 두 가지 딥러닝 모델을 활용한다. 첫 번째 딥러닝 모델은 GAN으로, GAN을 통해 상대적으로 부족한 교열 이미지를 생성한다. 생성된 교열 이미지는 실제 이미지와 구별이 불가능하다. 두 번째 딥러닝 모델은 교열 이미지와 정상 이미지를 구별하는 딥러닝 모델로, 실제 교열 이미지, 정상 이미지 뿐만 아니라 GAN을 통해 생성된 교열 이미지 또한 학습하여 교량 상판의 이미지가 입력되었을 때 교열이 존재하는지 존재하지 않는지 판단한다. 단순히 두 번째 딥러닝 모델을 활용하여 교열과 정상을 분류했을 때보다, GAN을 통해 생성된 이미지를 함께 학습했을 때 더 좋은 분류 성능을 보였다.

## 2. 관련 연구

서론에서 언급했듯이 전통적인 교량 교열 감지 방법은 전문가의 판단에 맡기는 것이었다. 하지만 여러 한계들로 인하여 자동화된 교량 교열 감지가 연구되고 있다. 초기 교량 교열 감지 연구들은 타 교열 감지 연구들과 마찬가지로 시각적으로 구별되는 고대비

특성 등 교열의 특징을 규격화 하고, 이를 감지해 내는 방법이 주로 사용되었다(Yamagichi and Hashimoto 2010; Zhu et al. 2011; Nishikawa et al. 2012). 예를 들어 이미지의 임의의 한 점으로부터 시작하여 밝기를 비교하여 특정 Threshold안에 포함되면 영역에 포함하고, 그렇지 않다면 영역에 포함하지 않는 방식으로 영역을 확장하고 최종 영역의 크기를 비교하는 방식 등이 존재한다. 이러한 규칙과 휴리스틱 알고리즘 기반의 방법과 형태학 연산을 통해 검출하는 Morphology기법(Lee et al. 2005; Lee et al. 2008), 사전에 정의된 Feature를 규칙을 통해 찾아내고, Feature와 교열간의 관계를 기계학습 기반으로 학습하는 방법들 또한 존재했다. 그러나 이러한 규칙 기반의 혹은 명시화된 특징 기반의 교열 감지는 그 한계가 명확한데 감지 모델의 성능이 이물질이나 그림자 등 여러 변수들에 영향을 크게 받기 때문에 연구실 환경이 아닌 실제 교량의 교열 감지에는 널리 적용되지 못했다. 또한 규칙과 휴리스틱 알고리즘은 연산시간이 오래 소요되기 때문에 실시간 분석이 이루어지기 힘든 단점이 존재한다. 이러한 단점을 극복하기 위해 자동으로 데이터의 특성을 추출하고 이를 이용하여 교열 여부를 판단하는 기계학습 기반의 방법들이 널리 사용되기 시작했다. 기계학습의 경우 모델의 학습에는 연산시간이 오래 소요되지만, 모델의 적용 시 빠른 연산이 가능한 장점 또한 존재한다. 이에 Convolutional neural network(CNN) 등 이미지의 패턴을 인식하는 방법들은 아스팔트 도로의 교열 감지나, 빌딩의 교열 감지 등에 널리 쓰이며 높은 성능을 보였다(Yang et al. 2019; Zou et al. 2018). 하지만 이러한 연구들의 대부분도 수집된 한정적인 데이터셋만을 활용하는 한계가 있었다. 특히 이러한 데이터셋들은 충분한 교열 데이터가 수집된 것을 가정하는데 실제로는 교열 데이터와 정상 데이터가 균형있는 비율로 수집되기 어렵다. 본 연구에서는 기존 규칙과 휴리스틱 기반 알고리즘의 한계인 일반화가 어렵다는 단점을 딥러닝 모델을 통해 극복하고자 한다. 기존 딥러닝 모델 기반 교열 감지 연구들은 교열 데이터와 정상 데이터가 비슷한 비율로 수집되었다고 가정하지만, 이는 현실적이지 않은 가정이다. 따라서 본 연구에서는 부족한 교열 데이터의 보충을 위해 GAN을 이용하여 교열 데이터를 생성하고, 실제 데이터뿐만 아니라 생성된 데이터를 함께 학습하여 더 높은 정확도로 교열과 딥러닝 모델을 개발하고자 한다.

## 3. 프레임워크

본 연구는 3가지 단계로 구성된다(Fig. 1). 첫 번째로는 GAN을 통해 데이터를 생성하는 단계이다. 두 번째 단계는 생성된 데이터

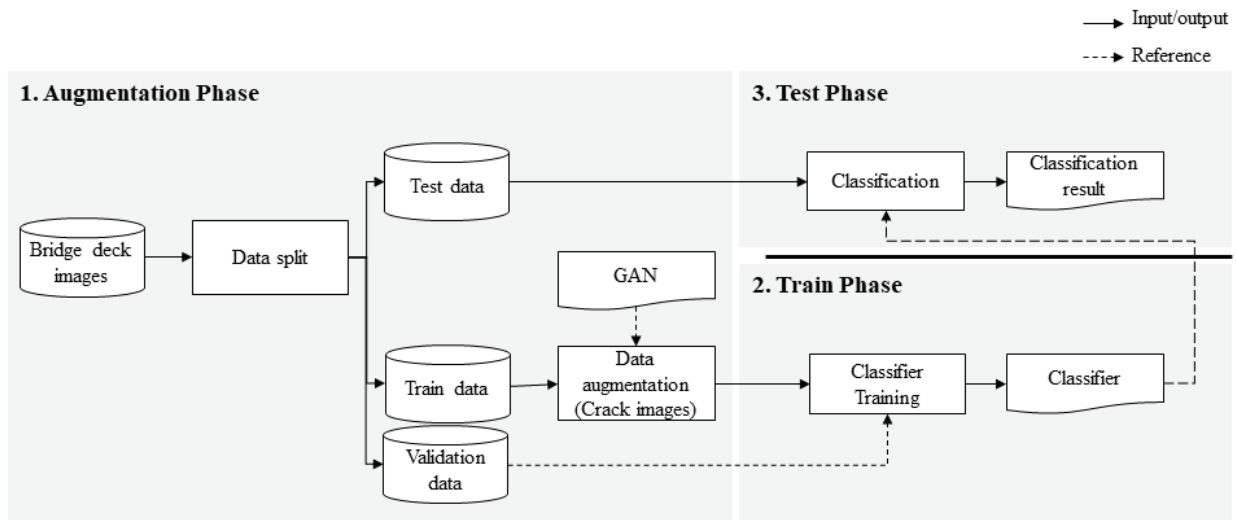


Fig. 1. Proposed framework for crack detection on bridge deck detection

를 포함하여 균열과 균열이 아닌 정상 상태의 이미지를 판별하는 딥러닝 모델(Classifier)을 학습하는 단계이다. 세 번째 단계는 이 이미지가 주어졌을 때 학습된 딥러닝 모델을 이용하여 균열 여부를 판단하고 이를 통해 학습된 딥러닝 모델의 성능을 평가한다

### 3.1 이미지 생성 단계

본 단계에서는 GAN을 통해 부족한 균열 이미지를 생성한다. 기계학습 모델의 성능에 영향을 미치는 다양한 요소들이 존재한다. 그 중 하나가 데이터 클래스의 균형 여부이다. 데이터를 분류하는 분류 문제일 경우, 클래스(본 연구에서는 균열/정상)에 해당하는 데이터들의 수가 크게 차이날 경우(Imbalanced data), 기계학습 모델의 성능을 크게 낮춘다(He and Garcia 2009). 교량의 균열 탐지의 경우, 정상 데이터에 비해 균열 데이터는 수집하기 힘들기 때문에 Imbalanced data 문제가 자주 발생하곤 한다. 따라서 본 연구에서는 실제 데이터를 입력받고 유사한 통계적 특성을 가지는 이미지 들을 생성해내는 기계학습 모델인 GAN을 적용하여 부족한 균열 데이터를 추가로 생성하고자 한다.

GAN은 Goodfellow et al.(2014)에 의해 제안된 기계학습 모델로 Generative model 중 하나이다. 실제 데이터로부터 가상의 데이터를 생성해내는 모델인데, Fig. 2와 같이 두 개의 인공신경망으로 구성된다. 첫 번째 인공신경망은 Generator 로 관측된 적이 없는 새로운 데이터를 만들어 낸다.

Random으로 생성된 Noise vector를 입력받아, 균열 데이터와 유사한 데이터를 생성해내는 것이다. 생성된 데이터를 두 번째 인공신경망이 Discriminator가 평가 하게 되는데 관측된 적이 있는

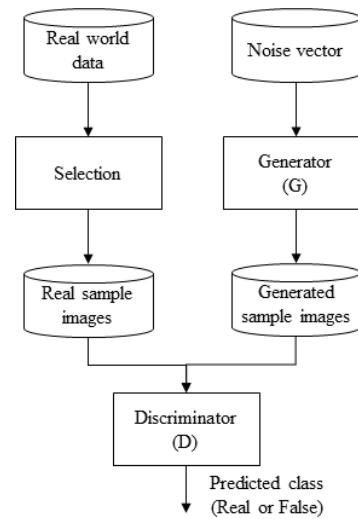


Fig. 2. Conceptual architecture of GAN

실제 데이터를 입력받거나 Generator로부터 생성된 데이터를 입력받는다. Discriminator는 입력받은 데이터가 실제 데이터인지, 생성된 데이터 인지를 평가한다. 만약 Generator가 실제 데이터를 완벽한 수준으로 복원하여 구별이 불가능한 수준의 데이터를 생성하게 되면 Discriminator가 평가하는 데이터 소스의 확률은 실제 데이터 1/2, 생성 데이터 1/2가 된다. 이를 위해 GAN은 아래의 목적식을 사용하여 학습을 진행한다.

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

G는 Generator, D는 Discriminator, x는 실제 이미지, z는 Random noise, G(z)는 생성된 이미지, D(x)는 Discriminator가 실제 이미지로 분류한 확률, D(G(z))는 Discriminator가 생성된 이미지로 분류한 확률을 뜻한다. GAN은 이론적 측면에서 그치지 않고 실제 여러 분야에서 널리 사용되고 있다. 특히 이미지 생성을 통한 딥러닝 모델의 성능 향상에 사용되고 있다. 이미지 생성 단계에서 GAN은 학습 데이터, 검증 데이터, 테스트 데이터가 나뉘는 후에 학습 데이터에 적용되어 학습 데이터 내에 균열 데이터를 생성하는데 사용된다.

### 3.2 분류 모델 학습 단계

학습 단계에서는 주어진 데이터가 균열인지, 정상인지를 판별하는 딥러닝 모델을 학습한다. 컴퓨터가 해석하는 이미지는 Red, Green, Blue의 세 가지 채널로 구성되어 있고, 0에서 255사이의 값을 지니는 숫자로 나타난다. 만약 256X256픽셀의 이미지라면 256X256개의 숫자로 구성된 Red 채널, 256X256개의 숫자로 구성된 Green 채널, 256X256개의 숫자로 구성된 Blue 채널로 구성되는 것이다(Fig. 3).




Fig. 3. Concept of RGB channel

딥러닝 모델은 이 숫자를 입력받아, 균열일 경우 1을, 균열이 아닐 경우 0의 값을 산출한다. 본 연구에서는 딥러닝 모델로 VGG-16을 사용하였다. VGG-16(Simonyan and Zisserman 2014)은 2014년 ILSVRC우승 아키텍처로 Fig. 4와 같이 Convolutional layer, Pooling layer, Fully connected layer 등으로 구성된다. 입력된 이미지는 Layer들을 거쳐 결과값을 산출하는데, 각 Layer들을 거치며 정확한 값을 산출할 수 있도록 Weight와 Bias 값들이 학습된다. 본 연구에서는 Transfer learning을 통해 ILSVRC의 Weight를 입력받아 균열 감지에 적합하도록 Fine tuning하는 방식

을 사용한다. 이를 통해 빠른 시간 내에 높은 성능을 내는 Weight와 Bias를 산출 가능하다.

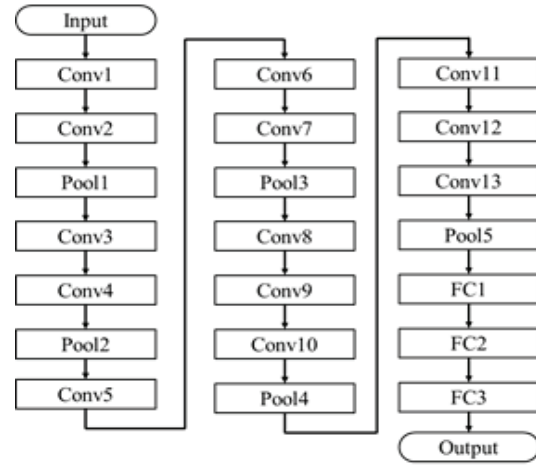


Fig. 4. Architecture of VGG-16

### 3.3 분류 모델 테스트 단계

테스트 단계에서는 학습된 모델의 성능을 평가한다. 딥러닝의 성능을 평가하기 위한 다양한 평가지표가 존재한다. 본 연구에서 사용한 평가지표는 Accuracy로 딥러닝 모델이 예측한 값(균열 또는 정상)과 실제 값이 일치하는 비율을 나타낸다. 예측되는 클래스의 중요도가 다를 경우, 특정 예측 값만을 대상으로 딥러닝의 성능을 평가하기도 한다. 예를 들어, 암과 같이 실제 암 중에 감지한 암이 얼마나 되는지가 더 중요한 경우(보수적으로 예측해야 하는 경우), 전체 예측값 중 실제값과 일치할 비율(Accuracy)이나, 암이라고 예측된 사례 중 실제 암인 경우(Precision)보다, 실제 암 중에서 모델이 암이라고 분류하는 경우(Recall)에 더 관심이 있다. 이럴 경우 성능 평가지표로 Recall이 더 적합하나, 본 연구에서는 균열이 아님에도 균열로 판단할 경우도 인적, 물적 손해를 야기하므로 Accuracy를 평가 지표로 사용하였으며 Accuracy는 다음과 같이 정의된다.

$$Accuracy = \frac{True\ Positive + True\ Negative}{Total} \quad (2)$$

True positive는 균열 이미지를 정확하게 균열 이미지로 분류한 경우의 수, True negative는 균열이 없는 정상 이미지를 정확하게 정상 이미지로 분류한 경우의 수를 뜻하며 Total은 전체 이미지의 개수로 전체 이미지 중 정확하게 예측한 비율을 뜻한다.

## 4. 사례 연구

챗터3에서 제안된 방법을 검증하기 위해 본 연구에서는 실제 교량의 균열 부위와 정상 부위를 촬영한 이미지를 활용하였다. 모든 실험은 다음과 같은 실험 환경에서 이루어졌다. 하드웨어 환경으로는 CPU는 AMD Ryzen 7 5800X 8-Core Processor 3.80 GHz, Memory는 32GB, GPU는 NVIDIA GeForce RTX 3070 Ti가 사용되었고, 소프트웨어 환경으로는 Python 3.6.9와 Tensorflow 2.4 가 사용되었다.

### 4.1 데이터 Description

본 연구에서는 제안된 프레임워크의 검증을 위하여 SDNET2018 (Dorafshan and Maguire 2017)의 교량 균열 데이터를 사용하였다. SDNET2018 데이터는 Utah State University 16 Mega pixel의 니콘 디지털 카메라로 촬영된 데이터로 균열 데이터와 정상 데이터를 모두 포함하고 있다. 균열의 경우, 0.06mm 너비의 작은 균열 부터 25mm의 넓은 균열까지 포함하고 있으며, 다양한 환경에서 촬영된 데이터라는 점에서 실제 균열 감지 상황과 유사하다. 예를 들어, SDNET2018 데이터에는 그림자, 구멍, 이물질 등이 전처리 없이 그대로 촬영되어 있다. Fig. 5는 SDNET2018 데이터 샘플로, Fig. 5(a)는 정상 상태의 데이터, Fig. 5(b)는 균열 데이터 이다. Fig. 5에서도 알 수 있듯이, 그림자와 불규칙한 표면, 이물질 등은 균열과 정상 데이터 간의 분류를 어렵게 만든다. 또한 균열 이미지와 정상 이미지의 개수가 불균형한데, 균열 데이터 개수는 2,025 개, 정상 데이터 개수는 11,595개이다.




Fig. 5. Sample data used for the experiment

### 4.2 이미지 생성

본 단계에서는 GAN을 통해 균열 이미지를 생성한다. 본 사례 연구에서는 각각 70%, 15%, 10%의 비율로 학습 데이터, 검증 데이터, 테스트 데이터를 분류한 후, 학습데이터에 한해 GAN을 학습하여 이미지를 생성, 추가하였다.

SDNET2018의 데이터는 균열 데이터와 정상 데이터의 비율이 다르다. 정상 상태의 데이터의 경우, 11,595개의 데이터가 있는 반면, 균열 데이터는 2,025개의 데이터만 존재한다. 실제 교량의 컨디션을 점검하는 환경에서도 교량의 균열 데이터를 정상 데이터와 같은 비율 수준으로 수집이 불가능하다. 이에 본 연구에서는 정상 상태의 데이터와 균형을 이루도록 약 1,000~3,000개의 데이터를 생성한다. 챗터 3.1에서 언급했 듯이 Generator와 Discriminator 두개의 모델을 15,000 Epoch에 걸쳐 학습했다.

Fig. 6은 Epoch를 거침에 따라 Random noise가 교량의 균열




Fig. 6. Generated images by GAN

이미지로 변하는 모습을 나타낸다. 다양한 이미지를 보여주기 위해 Fig. 6은 각 Epoch별 4개의 이미지를 보여준다. Fig. 6의 (a)는 1 Epoch 일 때의 모습으로 Random noise와 큰 차이가 없다. 즉 의미없이 무작위로 생성된 이미지로, 교량의 이미지와는 전혀 유사하지 않다. 하지만 Epoch를 거치면서 9개의 이미지 모두 교량의 균열 이미지와 유사해진다. Fig. 6(b)는 3,000 Epoch에서의 이미지로 Random noise와 큰 차이가 없으나, 6,000 Epoch(Fig. 6(d))를 거치며 교량 이미지의 색과 형태가 어렴풋이 보이기 시작한다. Fig. 6(e)인 9,000 Epoch에서는 교량 이미지와 유사하지만 흐릿한 모습을 보인다. 즉, 저품질의 교량 이미지를 생성하고 있다. 12,000 Epoch를 거친 생성 이미지는 교량의 균열 이미지와 마찬가지로 부분부분 불규칙한 모습과 선이 보이기 시작한다. 15,000 Epoch에서는 실제 교량의 균열 이미지와 유사한 형태를 지니며 균열을 포함하는 이미지가 생성된다(Fig. 6(e)). 따라서 본 사례연구에서는 15,000 Epoch를 걸쳐 학습된 GAN 모델을 이용하여 추가 이미지를 생성하고, 이를 학습 모델에 활용하였다.

### 4.3 분류 모델 학습

학습 단계에서는 챕터 4.2에서 생성된 이미지를 포함하여 학습이 이루어진다. Classifier로는 VGG-16 아키텍처를 사용하였으며, 초기 Weight는 Imagenet weight를 사용하였다. 학습은 200 Epoch에 걸쳐 이루어졌으며 Binary cross entropy로 모델의 Loss가 산출되었으며 계산 식은 아래와 같다.

$$H_p(q) = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (3)$$

$y_i$ 는 예측된 클래스를,  $p(y_i)$ 는  $i$  클래스로 예측된 확률을 뜻한다. Fig. 7에서 나타나듯이 Imagenet의 Weight를 사용할 시 빠르게 최적의 Weight로 수렴함을 알 수 있다. 즉, 학습이 성공적으로 진행되었다. 검증 데이터는 모델의 학습에 사용되지 않았으므로, 새로운 데이터가 입력되었을 때의 성능을 유추해볼 수 있다. 즉, 학습에 사용된 학습데이터에 대한 Loss인 Training loss와 학습에 사용되지 않은 검증 데이터에 대한 Validation loss가 유사한 수준을 나타내므로 모델이 학습 데이터에만 편향되어 학습되지 않고, 학습되지 않은 데이터에도 높은 수준의 정확도를 보일 것으로 기대할 수 있다.

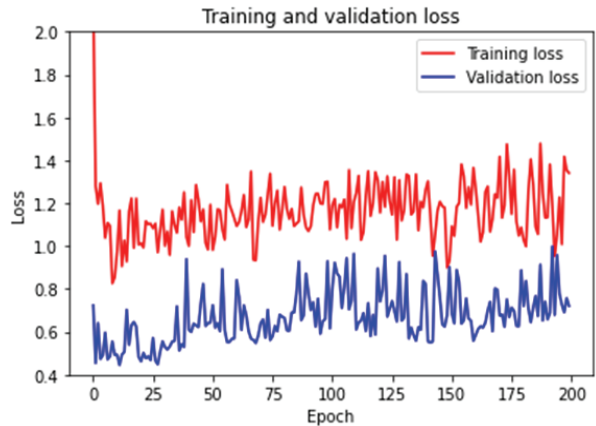


Fig. 7. Training and validation loss over epoch

### 4.4 분류 모델 테스트

테스트 단계에서는 학습단계에서 사용하지 않은 데이터를 학습 모델에 입력하여 실제값과 예측값을 비교하였다. 챕터 3.3에서 제안한 대로 성능평가 지표로는 Accuracy를 사용하였다.

Table 1. Accuracies of the crack detection model

Conditions	Accuracy
Non-augmented crack image	0.95
1,000 augmented crack images	0.97
2,000 augmented crack images	0.98
3,000 augmented crack images	0.97

테스트 결과는 Table 1과 같았다. GAN을 통해 생성한 이미지를 사용하지 않았을 경우, 균열 감지 모델의 Accuracy 값이 0.95를 보였으며, GAN을 통해 이미지를 생성하고 이를 균열 감지 모델에 입력하였을 시 0.97 이상의 정확도를 보였다. 구체적으로는 1,000개의 이미지를 생성하여 입력하였을 경우, 0.97의 Accuracy를 보였으며, 2,000개의 이미지를 생성하여 입력 하였을 경우에는 0.98의 Accuracy를 보였다. 특이한 점으로는 생성 데이터의 수가 증가함에 따라 Accuracy도 증가하는 경향을 보였으나, 일정 수준(2,000개의 이미지) 이상의 생성 이미지가 입력 되었을 경우에는 오히려 Accuracy가 소폭 하락하는 경향을 보였다. 그 폭이 크지 않았기 때문에 GAN을 통한 이미지 생성 시 발생하는 Random 요소로 인해 이와 같은 결과가 발생한 것으로 추정된다.

이를 통해 부족한 균열 이미지를 GAN을 통해 생성하여 학습데이터로 사용하였을 경우에 더 높은 성능의 균열 감지 모델을 개발할 수 있음을 알 수 있다.

## 5. 결론

본 연구에서는 종래의 육안 기반의 균열 감지 기법이 지니는 한계를 극복하기 위해 이미지에서 딥러닝 모델을 이용하여 균열을 감지하는 연구를 수행하였다. 특히 부족한 균열 데이터로 인해 발생하는 딥러닝 모델의 성능 하락을 방지하기 위해 GAN을 통해 이미지를 생성하였다. 연구 결과는 다음과 같다.

- 1) GAN을 통해 균열이 있는 콘크리트 이미지를 성공적으로 생성해 낼 수 있었다. 이는 정상 데이터에 비해 균열 데이터를 수집하기 힘든 환경에서 통계적으로 유사한 데이터를 생성 가능하다는 것을 의미한다.
- 2) 딥러닝 모델을 통해 성공적으로 교량의 균열을 감지할 수 있었다. 기존 육안 기반의 점검으로 발생하는 비효율성(시간과 비용의 소모, 신뢰도의 변화)을 줄이고, 자동화되고 효율적인 균열 감지가 가능할 것으로 판단된다.
- 3) GAN과 딥러닝 모델의 결합을 통해 딥러닝 모델의 성능을 향상시킬 수 있었다. 이를 통해 본 연구에서 제안한 프레임워크인 GAN을 통한 이미지 생성모델과, 이를 입력값으로 받는 딥러닝 모델을 통한 균열 감지의 유효성을 확인할 수 있었다.

향후 본 연구 결과의 상용화를 위하여 균열에 대해 추가적인 정보를 제공하는 것이 필요하다. 예를 들어 균열의 형태에 대한 분석, 이에 따른 균열의 원인 추론 등과 같은 추가 정보는 교량 관리에 효율성을 증대시킬 것으로 기대된다. 또한 균열의 정량화 측면에서, 균열의 깊이, 넓이, 길이 등을 정량화하는 연구 또한 후 행되어야 할 중요한 연구 주제이다. 이를 위해 전문가들에 의해 Annotated된 이미지 데이터 등이 구축될 필요가 있다고 판단된다.

## Conflicts of interest

None.

## References

Doratshan, S., Maguire, M. (2017). Autonomous detection of concrete cracks on bridge decks and fatigue cracks on steel members, *Digital Imaging*, 33–44.

Gao, X., Deng, F., Yue, X. (2020). Data augmentation in fault diagnosis based on the Wasserstein generative adversarial network with gradient penalty, *Neurocomputing*, **396**, 487–494.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative adversarial networks, *Proceedings of the International Conference on Neural Information Processing Systems(NIPS 2014)*, 2672–2680.

Han, C., Rundo, L., Araki, R., Furukawa, Y., Mauri, G., Nakayama, H., Hayashi, H. (2020). Infinite brain MR images: PGGAN-based data augmentation for tumor detection, In *Neural Approaches to Dynamics of Signal Exchanges*, 291–303.

He, H., Garcia, E.A. (2009). Learning from imbalanced data, *IEEE Transactions on Knowledge and Data Engineering*, **21(9)**, 1263–1284.

Lee, B.J., Shin, J.I., Park, C.H. (2008). Development of image processing program to inspect concrete bridges, *Proceedings of the Korea Concrete Institute Conference*, 189–192 [In Korean].

Lee, B.Y., Kim, Y.Y., Kim, J.K. (2005). Development of image processing for concrete surface cracks by employing enhanced binarization and shape analysis technique, *Journal of the Korea Concrete Institute*, **17(3)**, 361–368 [in Korean].

Lim, S.K., Loo, Y., Tran, N.T., Cheung, N.M., Roig, G., Elovici, Y. (2018). Doping: Generative data augmentation for unsupervised anomaly detection with gan, *IEEE International Conference on Data Mining (ICDM)* 1122–1127.

Lorencin, I., Baressi Šegota, S., Anđelić, N., Mrzljak, V., Čabov, T., Španjol, J., Car, Z. (2021). On urinary bladder cancer diagnosis: Utilization of deep convolutional generative adversarial networks for data augmentation, *Biology*, **10(3)**, 175.

Mok, T.C., Chung, A.C. (2018). Learning data augmentation for brain tumor segmentation with coarse-to-fine generative adversarial networks, *International MICCAI Brainlesion Workshop*, 70–80.

Nishikawa, T., Yoshida, J., Sugiyama, T., Fujino, Y. (2012). Concrete crack detection by multiple sequential image filtering, *Computer-Aided Civil and Infrastructure Engineering*, **27(1)**, 29–47.

Ortego, P., Diez-Olivan, A., Del Ser, J., Sierra, B. (2020) Data augmentation for industrial prognosis using generative adversarial networks, *International Conference on Intelligent Data Engineering and Automated Learning*, 113–122.

Peres, R.S., Azevedo, M., Araújo, S.O., Guedes, M., Miranda, F., Barata, J. (2021). Generative adversarial networks for data augmentation in structural adhesive inspection, *Applied Sciences*, **11(7)**, 3086.

Ramponi, G., Protopapas, P., Brambilla, M., Janssen, R. (2018). T-cgan: conditional generative adversarial network for data

- augmentation in noisy time series with irregular sampling, arXiv preprint arXiv:1811.08295.
- Simonyan, K., Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556.
- Yamaguchi, T., Hashimoto, S. (2010). Fast crack detection method for large-size concrete surface images using percolation-based image processing, Machine Vision and Applications, **21(5)**, 797–809.
- Yang, F., Zhang, L., Yu, S., Prokhorov, D., Mei, X., Ling, H. (2019). Feature pyramid and hierarchical boosting network for pavement crack detection, IEEE Transactions on Intelligent Transportation Systems, **21(4)**, 1525–1535.
- Zhu, Z., German, S., Brilakis, I. (2011). Visual retrieval of concrete crack properties for automated post-earthquake structural safety evaluation, Automation in Construction, **20(7)**, 874–883.
- Zou, Q., Zhang, Z., Li, Q., Qi, X., Wang, Q., Wang, S. (2018). Deepcrack: Learning hierarchical convolutional features for crack detection, IEEE Transactions on Image Processing, **28(3)**, 1498–1512.

### 적대적 생성 신경망과 딥러닝을 이용한 교량 상판의 균열 감지

교량의 균열은 교량의 상태를 나타내는 중요한 요소이며 주기적인 모니터링 대상이다. 그러나 전문가가 육안으로 점검하는 것은 비용, 시간, 신뢰성 면에서 문제가 있다. 따라서 최근에는 이러한 문제를 극복하기 위해 자동화 가능한 딥러닝 모델을 적용하기 위한 연구가 시작되었다. 딥러닝 모델은 예측할 상황에 대한 충분한 데이터가 필요하지만 교량 균열 데이터는 상대적으로 얻기가 어렵다. 특히 교량의 설계, 위치, 공법에 따라 교량 균열의 형상이 달라질 수 있어 특정 상황에서 많은 양의 균열 데이터를 수집하기 어려움이 따른다. 본 연구에서는 적대적 생성 신경망(Generative Adversarial Network, GAN)을 통해 불충분한 균열 데이터를 생성하고 학습하는 균열 탐지 모델을 개발했다. 본 연구에서는 GAN을 이용하여 주어진 균열 데이터와 통계적으로 유사한 데이터를 성공적으로 생성했으며, 생성된 이미지를 사용하지 않을 때보다 생성된 이미지를 사용할 때 약 3% 더 높은 정확도로 균열 감지가 가능했다. 이러한 접근 방식은 교량의 균열 검출이 필요하지만 균열 데이터는 충분하지 않거나 하나의 클래스에 대한 데이터가 상대적으로 적을 때 감지 모델의 성능을 효과적으로 향상시킬 것으로 기대된다.