

# 효율적인 균열 데이터 수집을 위한 벡터 기반 데이터 증강과 네트워크 학습

김종현\*

강남대학교\*

jonghyunkim@kangnam.ac.kr

## Vector-Based Data Augmentation and Network Learning for Efficient Crack Data Collection

Jong-Hyun Kim\*

Kangnam University\*

### 요 약

본 논문에서는 균열을 감지 할 때 필요한 데이터를 생성할 수 있는 벡터 기반 증강 기법과 이를 학습할 수 있는 합성곱 인공신경망(Convolution Neural Networks, ConvNet) 기법을 제안한다. 균열을 빠르고 정확하게 감지하는 것은 건물 붕괴와 낙하 사고를 사전에 방지할 수 있는 중요한 기술이다. 이 문제를 인공지능으로 해결하기 위해서는 대량의 데이터 확보가 필수적이지만, 실제 균열 이미지를 얻기 위한 상황은 대부분 위험하기 때문에 대량의 균열 데이터를 확보하기는 어렵다. 이런 데이터베이스 구축의 문제점은 인위적인 특정 부분에 변형을 주어 데이터의 양을 늘리는 탄성왜곡(Elastic distortion)으로 완화시킬 수 있지만, 본 논문에서는 이보다 향상된 균열 패턴 결과를 ConvNet을 활용하여 모델링한다. 탄성왜곡보다 우리의 방법이 실제 균열 패턴과 유사하게 추출된 결과를 얻을 수 있었고, 일반적인 데이터 증강에서 사용되는 픽셀 단위가 아닌, 벡터 기반으로 균열 데이터 증강을 설계함으로써 균열의 변화량 측면에서 우수한 결과를 얻을 수 있다. 결과적으로 본 논문에서는 적은 개수의 균열 데이터를 입력으로 사용했음에도 불구하고 균열의 방향 및 패턴을 다양하게 생성하여 효율적으로 균열 데이터베이스를 구축할 수 있다.

### Abstract

In this paper, we propose a vector-based augmentation technique that can generate data required for crack detection and a ConvNet(Convolutional Neural Network) technique that can learn it. Detecting cracks quickly and accurately is an important technology to prevent building collapse and fall accidents in advance. In order to solve this problem with artificial intelligence, it is essential to obtain a large amount of data, but it is difficult to obtain a large amount of crack data because the situation for obtaining an actual crack image is mostly dangerous. This problem of database construction can be alleviated with elastic distortion, which increases the amount of data by applying deformation to a specific artificial part. In this paper, the improved crack pattern results are modeled using ConvNet. Rather than elastic distortion, our method can obtain results similar to the actual crack pattern. By designing the crack data augmentation based on a vector, rather than the pixel unit used in general data augmentation, excellent results can be obtained in terms of the amount of crack change. As a result, in this paper, even though a small number of crack data were used as input, a crack database can be efficiently constructed by generating various crack directions and patterns.

**키워드:** 균열 감지, 합성곱 신경망, 데이터 증강, 탄성왜곡, 뼈대 추출

**Keywords:** Crack detection, Convolution neural network, Data augmentation, Elastic distortion, Skeleton extraction

\*corresponding author: Jong-Hyun Kim/Kangnam University(jonghyunkim@kangnam.ac.kr)

## 1. 서론

현대 건축물에서 콘크리트 구조물은 가장 큰 비중을 차지하고 있지만, 그 재질 구조물이 가지고 있는 균열 또한 흔히 접할 수 있는 문제이다. 건축물의 시간이 지남에 따라 균열의 수와 폭이 점차 다양하게 증가하고, 이는 결과적으로 구조물의 안정성 및 내구성에 심각한 영향을 미친다. 따라서 콘크리트 구조물의 안전을 위해 정기적으로 균열을 검사하고 이에 대응하는 유지보수를 취하는 것이 매우 중요하다 [1, 2, 3]. 전통적인 균열 검사는 주로 관련 도구를 사용하는 전문가의 직접 감지를 통해 진행된다. 이 탐지 방식은 노동력이 많이 소요될 뿐만 아니라 시간이 많이 걸린다. 또한, 상황에 따라서 위험을 초래할 수도 있기 때문에 안정성이 보장되지 않는다.

수동 검출의 문제점을 극복하고 효율적으로 안전한 균열 검출을 제작하기 위해 영상처리기술에 주목하였다 [4]. 지난 수십 년 동안 컴퓨터 비전 커뮤니티는 이미지의 자동 감지에 대해 연구해 왔으며 임계값(Thresholding) [5, 6], 에지 감지(Edge detection) [7], 웨이블릿 변환(Wavelet transform) [8, 9] 및 머신러닝 [10] 등이 있다. 이미지 임계값은 픽셀의 색상을 기반으로 균열을 분할하여 이미지를 단순화시키는 방식이다. 에지 검출에 사용되는 미분 연산자에는 주로 로버츠(Robert) 연산자, 소벨(Sobel) 연산자, 라플라스(Laplace) 연산자가 있다 [11]. 웨이블릿 변환의 아이디어는 이미지 신호를 나타내기 위해 웨이블릿 함수 또는 기저 함수 셋을 사용한다. 머신러닝은 훈련 데이터셋에서 균열의 특징 벡터를 추출하고, 특정 알고리즘을 결합하여 결과를 예측한다. 이러한 방식은 공학 분야에서 균열 감지 문제를 효과적으로 풀어내는 역할을 했다. 현재도 이 연구 분야는 균열의 불균일성, 표면 질감의 다양성, 배경의 복잡성으로 인해 여전히 연구가 활발히 진행되고 있다.

딥러닝은 머신러닝 알고리즘 연구의 새로운 기술로 문제를 분석하고 인간의 두뇌처럼 학습하기 위한 신경망이다. 특징 학습을 통해 네트워크의 각 계층은 이전 계층의 출력을 자체 입력으로 사용하고, 심층 비선형 네트워크(Deep nonlinear network)를 학습함으로써 추상적인 표현 모델로 변환한다. Zhang 등은 ConvNet을 이용하여 도로 균열 감지에 딥러닝 기반 프레임워크를 활용하였다 [12]. 이때 노면 사진은 스마트폰으로 촬영했으며, 네트워크 모델은 Caffe 딥러닝 프레임워크로 구축하였다. 이들은 SVM(Support vector machine)과 같은 기존 기계 학습 분류기와 비교하여 딥러닝의 효율성을 입증하였다. Pauly 등은 ConvNet 깊이와 훈련 데이터셋, 그리고 테스트 데이터셋 간의 위치 변화가 균열 탐지 정확도에 미치는 영향에 대해서 연구를 하였다 [13]. 결과적으로 네트워크 깊이를 늘리면 네트워크 성능을 향상시킬 수 있지만 이미지 위치가 변경되면 감지 정확도가 크게 감소한다는 것을 보여준다. Maeda 등은 대규모 도로 균열 데이터셋을 만들고, 각 사진에 도로 균열의 위치와 유형을 표시하는 방법을 제시하였다 [14]. 이 방법은 딥러닝 기반의 종단간(End-to-End) 물체 감지 방법을

사용하여 손상 감지 모델을 학습하였다. Xu 등은 자동 교량 균열 감지를 구현하기 위해 종단간 균열 감지 모델을 설계하였다 [15]. 이외에 다양한 접근법들이 존재하지만, 실제 균열 패턴은 다양하고 복잡하기 때문에 데이터 구축을 위한 어려움이 존재하며, 본 논문에서는 이를 해결하기 위해 ConvNet을 활용한 벡터 기반 데이터 증강 기법을 소개한다.

## 2. 관련 연구

### 2.1 균열 감지

지난 수십 년 동안 이미지 프로세싱 기술을 활용하여 균열을 감지하려는 연구가 꾸준히 진행되었다. 이 과정에서 균열을 감지할 뿐만 아니라 인식된 균열의 너비와 방향을 측정하는 것도 중요한 요소이다. 이미지 프로세싱 기반 접근법은 일반적으로 미리 정의된 기울기 필터(Gradient filter)와 이진 분류기(Binary classifier)를 사용하여 이미지 픽셀이 균열 영역의 일부인지 여부를 결정한다. Oliveira와 Correia는 어두운 영역을 구별하여 균열을 감지할 수 있음을 보여주었다 [16, 17]. 많은 연구자들이 이미지에 노이즈 필터링을 사용하여 균열 감지를 효율적으로 처리할 수 있는 기법을 제안했다 [18, 19]. 또한, Morphology [20, 21, 22], Fuzzy [23, 24], Percolation 기법 [4, 25]을 기반으로 균열 감사를 위한 다양한 영상처리 기법이 연구되었다. 그러나 이러한 규칙 기반 이미지 처리의 정확도는 초점 거리, 촬영 환경의 영향, 촬영 품질 및 해상도에 따라 다른 결과를 보여준다. 정확한 감지를 위해서는 입력 이미지에 따라 매번 새로운 필터 모델링이 필요하게 된다.

또 다른 접근법으로는 규칙 기반 균열 감사를 개선하기 위해 머신러닝이 활발하게 활용되고 있다. 많은 연구자들이 SVM [26, 27], Bayesian [28], 유전 알고리즘 [29], 의사결정트리 [30]를 포함한 다양한 머신러닝 알고리즘을 균열 감지에 활용하였다. 그러나 머신러닝 기반 방법은 이미지 처리에 의해 추출된 균열 특징에 의존할 수밖에 없는 정확도의 한계가 있지만, 딥러닝은 이러한 문제를 해결할 수 있음을 보여주었다. Xu 등은 Boltzmann 이론을 사용하는 인공신경망을 활용하여 제한된 훈련 샘플에도 불구하고 성공적으로 균열을 감지할 수 있음을 보여주었다 [31]. Zhang 등은 4개의 레이어로 구성된 ConvNet을 사용하여 도로 이미지에서 87%의 정확도로 균열을 찾았다 [12]. Chen 등과 Li 등은 99% 정확도로 이미지에서 균열 패턴을 추출할 수 있는 개선된 ConvNet을 제안하였다 [32, 33]. 앞에서 언급한 인공신경망 기반 연구들은 균열 감지에 대한 충분한 잠재력을 보여주고 있지만, 인공신경망 학습을 위한 균열 데이터 수집 및 데이터 증강 방법에 관한 연구는 거의 진행되지 않았다.

## 2.2 균열 데이터셋 구축

공개적인 균열 데이터셋에는 Li와 Zhao가 공개한 데이터가 있다 [33]. 이 데이터는  $4160 \times 3120$  해상도의 균열 이미지를 스마트폰으로 촬영한 데이터이다. 이것을  $256 \times 256$  해상도로 자른 후, 균열 존재 여부에 따라 두 가지 범주로 분류하였다. 이 연구에서는 데이터셋에 12,000개 이미지만 사용하였고, 균열 및 비균열 이미지의 수는 동일하게 설정하였다. 또한, SDNET2018 데이터셋에서는 균열이 있는 콘크리트 교량 이미지를 얻을 수 있다 [34] (Figure 1 참조).



(a) Noncrack images

(b) Crack images


Figure 1: Sample noncrack and crack images from the public dataset.

## 2.3 데이터 증강

네트워크 학습을 위한 데이터 수집만큼 중요한 것은 데이터 증강 기법이다. 사람이나 동물 등 일반적인 객체에 대한 감지 및 인식에서도 데이터 증강에 대한 중요성은 알려져 있으며, 여러 자세 및 시점에 따른 객체 인식의 정확도를 높이려고 다양한 방법들이 소개되었다. 그럼에도 불구하고 균열은 일반적인 객체보다 다양하고 불규칙한 패턴을 가지고 있기 때문에 현업에서도 이 부분에 대한 필요성을 지속적으로 요구하고 있다.

신경망 모델의 일반화 능력은 훈련 데이터셋의 수와 다양성에 밀접한 관련이 있다. 실제 데이터의 개수는 매우 제한적이기 때문에 이를 해결하기 위한 방법은 가상의 데이터를 만들어 훈련셋에 추가하는 것이다 [35]. 이러한 방식은 네트워크 학습과정에서 과적합 문제를 효율적으로 극복할 수 있게 해주며, 딥러닝의 다양한 분야에서 활용되고 있다. 컴퓨터 비전 분야에서 일반적으로 사용되는 데이터 증강 방법은 주로 영상 처리 기술에 기반한 데이터 증강과 딥러닝에 기반한 데이터 증강이 있다. 텐서플로우 2.0에서는 ImageDataGenerator라는 데이터 증강 기능을 제공한다: 데이터에 대한 반전(Flip), 이동(Shift), 회전(Rotation) 등의 기능을 제공.

Figure 2는 텐서플로우에서 제공하는 데이터 증강 과정을 거친 다양한 균열 이미지를 보여주고 있다. 하지만, 대부분 선형 변환만을 이용하기 때문에 복잡한 균열 데이터를 학습하기에는 부족하다. 본 논문에서는 균열의 뼈대 패턴을 인식하고, 벡터 기반으로 데이터를 증강할 수 있는 새로운 방식을 제안한다.



(a)

(b)

(c)

Figure 2: Images after data augmentation : (a) original image, (b) horizontal flip, (c) horizontal shift.

## 3. 제안하는 프레임워크

본 논문에서 제안하는 벡터 기반의 데이터 증강기법은 균열 데이터 이미지로부터 뼈대를 추출하고, 이로부터 특징점인 코너(Corner)를 찾아 연결한 선분을 활용한다.

### 3.1 균열 데이터로부터 뼈대 추출

실제 균열 데이터의 95% 이상이 비균열(Noncrack)이라고 했을 때 균열이 존재하는 영역은 매우 작은 부분에 불과하다. 그러므로 균열 선분에 데이터 변형을 가할 경우, 균열이 불규칙적으로 끊어지는 문제가 발생한다 (Figure 3 참조). 균열 선분의 연결정보를 유지하기 위해 본 논문에서는 균열 이미지로부터 균열에 대한 뼈대를 추출한다. 이 과정을 위해 골격화(Skeletonization) 과정을 적용하며, 골격화는 균열 선분을 픽셀기반에서 벡터 기반으로 변환하여 대상 물체의 두께를 얇은 벡터 선분으로 나타내는 방법이다. 이 과정을 거친 균열 이미지에서 뼈대를 추출하고, 선분 너비를 조절하여 네트워크 학습 데이터로 활용한다.



(a) Input data

(b) Extracted skeleton

Figure 3: Extracted skeleton from crack image.

### 3.2 뼈대 데이터로부터 코너 추출

균열 데이터에서 기울기가 심하게 변하는 두 에지의 교차점인 코너를 검출한다. 이 기법은 에지간의 변화율을 계산하여 양방향 기울기 변화가 심한 곳을 코너로 간주한다. 본 논문에서는 해리스 코너 검출기법을 개선한 Shi-Tomashi 코너 감지 기법을 이용한다 [36]. 한 픽셀을 중심에 두고 마스크 윈도우 내에서  $X$ 축으로  $u$ 만큼,  $Y$ 축으로  $v$ 만큼 이동하며 윈도우 내




Figure 4: Skeleton extraction and corner detection from crack image.

픽셀 값들의 차이에 대한 제곱 합을 계산한다. Equation 1에서  $W(x, y)$ 는  $(x, y)$  위치에서의 가중치,  $I(x + u, y + v)$ 는 이동된 위치에서의 값,  $I(x, y)$ 는 이동 전 위치에서의 값을 의미한다.

$$E(u, v) = \sum_{x, y} W(x, y) [I(x + u, y + v) - I(x, y)]^2 \quad (1)$$

위 수식에 테일러 확장(Taylor expansion)을 적용하면 Equation 2를 얻을 수 있다.

$$E(u, v) \cong \sum_{x, y} [I(x, y) + uI_x + vI_y - I(x, y)]^2 \quad (2)$$

Equation 3은 Equation 2를 행렬식으로 변경하여 정리한 최종 수식이다. 이때, 행렬의 고유값이 최솟값보다 높으면 코너로 간주하였으며, 이 과정은 SVD(Singular value decomposition) 기법을 통해 계산한다.

$$E(u, v) \cong [u, v] \left( \sum_{x, y} W(x, y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \right) \begin{bmatrix} u \\ v \end{bmatrix} \quad (3)$$

Figure 4는 그레이스케일 이미지에서 원하는 코너 개수, 기울기 변화량, 코너 간 최소 거리를 지정하여 추출된  $N$ 개의 코너 집합이다.




Figure 5: Crack vector with skeleton and corner set.

Figure 5는 검출된 코너들을 선분으로 연결한 결과이며, 향후 이 데이터를 벡터 기반 증강 기법에 활용한다. Figure 3과

비교했을 때 끊어지는 균열 없이 안정적으로 균열 방향이 추출된 것을 잘 보여주고 있다.

### 3.3 벡터 기반의 탄성왜곡

이번 장에서는 미시적-거시적 관점에서 구현된 벡터 기반의 탄성왜곡 기법에 대해 설명한다. 미시적 관점에서는 표준편차  $\sigma$ 와 변형 강도  $\alpha$ 의 가중치를 조절하여 균열에 대한 심층적인 변형을 계산한다. Figure 6은 앞에서 추출한 코너를 연결한 선분 중 하나의 선분을 확대한 결과이며, 그림에서도 보듯이 가중치에 따른 변형 정도를 쉽게 확인할 수 있다. Figure 6a는 앞에서 추출한 뼈대 데이터이며, Figure 6b는 코너를 찾고 연결한 이미지이다. Figure 6c는 균열 벡터의 한 선분에서 벡터기반 탄성변형을 적용한 결과이다. 거시적 관점의 탄성왜곡에서는 회전 각도와 아핀변환(Affine transformation)의 가중치를 조절하여 균열의 표면 형태를 변형한다.




Figure 6: Vector based elastic distortion in crack direction.

Figure 7에서는 벡터 기반 선분을 활용하여 미시적-거시적 관점의 탄성왜곡 기법을 적용한 결과이다. 직선 형태의 균열에 비해 좀 더 다양한 균열 방향성을 표현할 수 있었으며, 전통적인 픽셀기반 데이터 증강에서는 이러한 방향성을 제어할 수 없다. 난수에 의해 이 문제를 일시적으로 피해갈 수는 있지만, 난수에 의한 변형은 원본 균열의 패턴을 잃어버릴 수 있기 때문에 균열의 특징을 온전하게 표현하기에는 충분하지 않은 접근법이다.





Figure 7: Crack data augmentation with our method (inset image : input data).



### 3.4 인공신경망을 이용한 특징 학습

이번 장에서는 앞에서 제안한 벡터 기반 데이터 증강을 통해 균열 데이터를 디테일하게 모델링할 수 있는 ConvNet 기반 네트워크 방식에 대해서 소개한다. ConvNet 학습을 위해 골격화 균열 이미지 500장, 벡터 기반 선분 이미지 400장을 이용하였으며, 이후 벡터 기반 데이터 증강 기법을 통해 학습 데이터를 추가적으로 수집하였다. 본 논문에서는 앞에서 계산하여 얻은 균열 이미지들을 기반으로 ConvNet을 진행하여 실제 균열과 유사한 패턴을 얻을 수 있는 특징 학습(Feature training)에 대해 설명한다. 골격화 기법을 균열 이미지 바탕으로 네트워크 학습시켰을 때는 특징점에 대한 해상도가 복잡하여 실제 학습 자체가 수렴하지 않았지만, 균열의 코너를 추출한 뒤 선분으로 연결한 벡터 데이터를 활용하여 이 문제를 해결하였다.



(a) Only skeleton data

(b) Output data with ConvNet

Figure 8: Crack generation with ConvNet based our method.

Figure 8a는 균열 이미지로부터 추출된 뼈대 데이터이고, Figure 8b는 ConvNet 학습을 거쳐 생성된 결과이며 실제 균열과 유사한 패턴을 보여준다. 탄성왜곡의 가중치가 큰 경우 발생했던 노이즈는 원본 균열의 특징을 온전하게 표현하지 못했으며, 본 논문의 방법은 이러한 문제점을 완화하였다.





Figure 9: Our network architecture.

본 논문에서 사용한 잔차(Residual) 기반의 ConvNet 형태는 다음과 같다 (Figure 9 참조): 벡터 기반의 학습 이미지를 활용하여 26개의 레이어, 3배의 업샘플링, 잔차 이미지를 기반으로 네트워크 학습을 하였을 때 최적의 결과를 얻을 수 있었다. 업샘플링 배수가 커질수록 결과가 향상되었고, 잔차 이미지를 사용하여 3채널 학습의 색상 문제를 해결하였다. 마지막으로 균열 패턴의 디테일이 고려된 결과를 얻기 위해 벡터 증강 과정을 거친 탄성왜곡 이미지를 입력 데이터로 사용하였고, 이로부터 네트워크를 학습시켜 최종 결과를 얻었다.

Figure 10a는 입력 이미지, Figure 10b는 ConvNet의 테스트 결과이며, 학습 시간은 약 40분이 소요되었다. 앞에서 언급했듯이 입력 데이터의 크기는  $8 \times 8$ 이며, 출력 데이터의 개수는  $64 \times 64$ 이고, 10,000 epoch를 사용했고, 최종적인 손실(Loss)은 0.1로 측정되었다.



(a) Skeleton data and only vector-based data augmentation



(b) Output data with ConvNet

Figure 10: Advanced crack data set with our method.

## 4. 구현

본 논문에는 VGG19 인공신경망을 사용하여 균열 네트워크를 설계하였고, 이번 장에서는 VGG19 네트워크를 개발할 때의 상세 내역에 대해서 설명한다. VGGNet 모델은 크게 2가지 형태로 구성되어있다 (VGG network와 Reconstruction). 예를 들어, 입력 균열 데이터로  $128 \times 128$ 을 갖는 3채널 이미지라고 했을 때, 입력  $x$ 는 다음과 같다:  $x(128, 128, 3)$ .

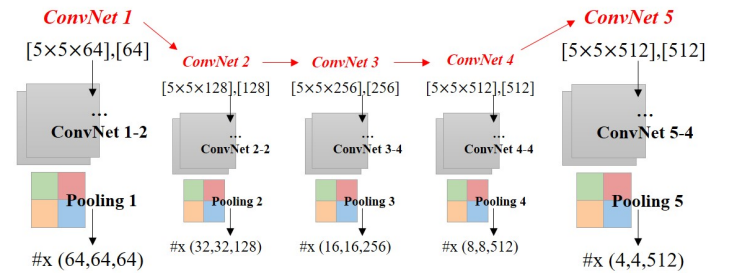


Figure 11: VGG network (input :  $x(128, 128, 3)$ , output :  $x(4, 4, 512)$ , [weight],[bias], #x(width,height,depth)).

VGG network에서 첫번째 ConvNet1은 앞에서 설명했듯이 2개의 ConvNet 레이어로 구성되어있으며, 이때 사용한 Weight

와 Bias 크기는 다음과 같고 ( $5 \times 5 \times 64, 64$ ), ConvNet1의 출력값인, 너비(Width), 높이(Height), 깊이(Depth)는 각각 (64,64,64)이다 (Figure 11 참조). 여기서 사용한 활성화 함수는 ReLU이다. ConvNet1의 출력값은 ConvNet2의 입력으로 사용되며, 전체적인 VGGNet 모델은 다음과 같다 (Figure 11 참조). 이 그림에서 ConvNet 1-2라는 것은 ConvNet 1 과정에서 ConvNet 레이어를 2개 사용했다는 의미이고, 마찬가지로 ConvNet 5-4는 ConvNet 5 과정에서 ConvNet 레이어를 4개 사용한다는 의미이다.

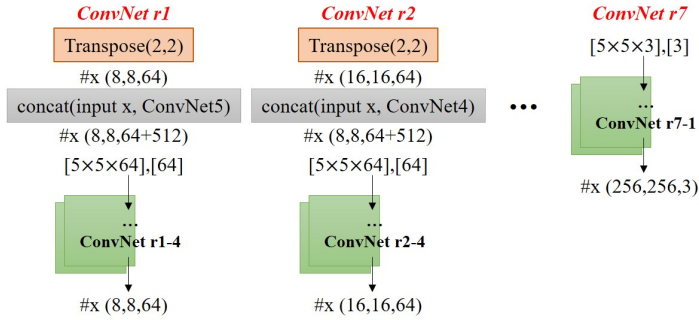


Figure 12: Reconstruction (input :  $x(4,4,512)$ , output :  $x(256,256,3)$ ).

Reconstruction 단계에서는 VGG network의 출력값에 대한 전치 컨볼루션(Transposed convolution)을 통해 결과를 복원하는 과정이다 (Figure 12 참조). ConvNet r1에서 ConvNet r7까지의 세부 내역은 그림과 같이 설정하였다. 인공신경망의 입력은 원본 데이터의  $\frac{1}{2}$  크기이며, 향후 잔차맵과 더해질 때 Reconstruction의 출력과 동일한 크기에서 더해진다. 이 네트워크는 텐서플로우에서 구현했으며, 여기서 사용한 옵티마이저는 Adam(Adaptive moment estimation)이다.

## 5. 결과

본 연구의 결과들을 만들기 위해 실험한 환경은 Intel Core i7-7700K CPU, 32GB RAM, Geforce GTX 1080Ti GPU가 탑재된 컴퓨터를 이용하였다. 본 연구에서는 균열 데이터를 증강시

킬 수 있는 벡터 기반 증강기법을 제시하였고, 이를 ConvNet으로 학습하여 효율적으로 데이터 증강이 가능한 아키텍처로 확장하였다. 본 논문에서는 제안한 방법의 효율성과 정확성을 실험하기 위해 3가지 시나리오를 통해 검증을 했다.

Figure 13a는 균열 이미지로부터 추출된 뼈대 데이터를 나타내며, Figure 13b는 감지된 코너를 벡터 라인으로 이은 선분이다. 균열 이미지로부터 추출된 선분은 잔가지 형태와 같이 얇은 균열들도 포함되어 있어서 실제로 거시적인 특징을 포착하기 어렵고, 계산량만 커진다. 본 논문에서는 코너 감지를 통해 균열의 거시적인 특징을 효율적으로 찾았고, 이를 선분으로 이음으로써 원본 균열의 방향을 유지할 수 있도록 데이터를 수정하여 사용한다 (Figure 13b 참조).




Figure 14: Vector based elastic distortion with our method (weight param :  $\alpha, \sigma$ , angle, affine).

Figure 14는 벡터 기반 탄성왜곡을 이용하여 제작한 균열 데이터이다. 입력 균열 이미지로부터 뼈대와 균열 벡터를 추출하고, 벡터 기반 탄성왜곡을 결정하는 4가지 매개변수를 이용하여 생성된 데이터 증강 결과이다. 거시적인 균열의 방향뿐만 아니라, 미시적으로 표현되는 작은 균열의 지그재그한 패턴까지 다양하게 표현된 결과를 잘 보여주고 있다.

Figure 15는 본 논문에서 제안한 벡터 기반 데이터 균열 기법을 ConvNet으로 학습하여 만들어진 결과이다. 앞에서 보여준 결과들과 마찬가지로 원본 균열의 특징은 유지한 채 균열 데이터를 증강한 결과를 보여준다.




Figure 13: Extracting skeleton and vector line from crack image (inset image : input data).




Figure 15: ConvNet based crack data augmentation.

## 6. 결론 및 향후 연구

본 연구에서는 균열을 감지 할 때 필요한 데이터를 생성할 수 있는 벡터 기반 증강 기법과 이를 학습할 수 있는 ConvNet 기법을 제안했다. 복잡한 패턴을 지닌 균열 이미지를 확보하기 위한 탄성왜곡 기반의 데이터 증강 기법을 이용해 네트워크를 학습시키고, ConvNet을 활용해 실제 균열의 특징을 고려한 데이터를 생성하였다. 제안하는 방법은 콘크리트와 같은 특정 재질에서 발생하는 균열에 한정해 데이터를 생성할 수 있는 새로운 방식이다.

그럼에도 불구하고 몇 가지 한계점이 있다. Figure 14에서 보듯이 본 논문에서 제시한 균열 패턴은 실제 패턴과 비교했을 때 진동(Oscillation)이 포함되는 것을 볼 수 있다. 앞에서 언급했듯이 가중치를 조절함으로써 제어가 가능하지만, 온전한 해결책은 아니다. 이러한 특징은 네트워크 학습과정에서 균열의 두께(Thickness)를 고려하지 않아서 생기는 현상으로 파악된다. 향후, 제안하는 기법을 균열 감지 네트워크에 적용하여 다양한 균열을 정확하게 감지하고 인지할 수 있는 네트워크 아키텍처를 연구할 것이다. 또한, 콘크리트 기반의 균열뿐만 아니라 다양한 재질에서 균열 데이터를 추출하고, 서로 다른 재질의 특징 맵들을 합쳐 좀 더 정확한 균열을 추출할 수 있도록 데이터 증강 기법을 확장할 계획이다.

## 참고 문헌

[1] D. G. Aggelis, N. Alver, and H. K. Chai, "Health monitoring of civil infrastructure and materials," 2014.

[2] I.-H. Kim, H. Jeon, S.-C. Baek, W.-H. Hong, and H.-J. Jung, "Application of crack identification techniques for an aging

concrete bridge inspection using an unmanned aerial vehicle," *Sensors*, vol. 18, no. 6, p. 1881, 2018.

[3] T. Liu, H. Huang, and Y. Yang, "Crack detection of reinforced concrete member using rayleigh-based distributed optic fiber strain sensing system," *Advances in Civil Engineering*, vol. 2020, 2020.

[4] T. Yamaguchi, S. Nakamura, R. Saegusa, and S. Hashimoto, "Image-based crack detection for real concrete surfaces," *IEEE Transactions on Electrical and Electronic Engineering*, vol. 3, no. 1, pp. 128–135, 2008.

[5] Y.-C. Tsai, V. Kaul, and R. M. Mersereau, "Critical assessment of pavement distress segmentation methods," *Journal of transportation engineering*, vol. 136, no. 1, pp. 11–19, 2010.

[6] D. Zhang, Q. Li, Y. Chen, M. Cao, L. He, and B. Zhang, "An efficient and reliable coarse-to-fine approach for asphalt pavement crack detection," *Image and Vision Computing*, vol. 57, pp. 130–146, 2017.

[7] A. Ayenu-Prah and N. Attah-Okine, "Evaluating pavement cracks with bidimensional empirical mode decomposition," *EURASIP Journal on Advances in Signal Processing*, vol. 2008, pp. 1–7, 2008.

[8] P. Subirats, J. Dumoulin, V. Legeay, and D. Barba, "Automation of pavement surface crack detection using the continuous wavelet transform," in *2006 International Conference on Image Processing*. IEEE, 2006, pp. 3037–3040.

- [9] L. Ying and E. Salari, "Beamlet transform-based technique for pavement crack detection and classification," *Computer-Aided Civil and Infrastructure Engineering*, vol. 25, no. 8, pp. 572–580, 2010.
- [10] A. Hizukuri and T. Nagata, "Development of a classification method for a crack on a pavement surface images using machine learning," in *Thirteenth International Conference on Quality Control by Artificial Vision 2017*, vol. 10338. International Society for Optics and Photonics, 2017, p. 103380M.
- [11] P. P. Acharjya, R. Das, and D. Ghoshal, "Study and comparison of different edge detectors for image segmentation," *Global Journal of Computer Science and Technology*, 2012.
- [12] L. Zhang, F. Yang, Y. D. Zhang, and Y. J. Zhu, "Road crack detection using deep convolutional neural network," in *2016 IEEE international conference on image processing (ICIP)*. IEEE, 2016, pp. 3708–3712.
- [13] L. Pauly, D. Hogg, R. Fuentes, and H. Peel, "Deeper networks for pavement crack detection," in *Proceedings of the 34th IS-ARC*. IAARC, 2017, pp. 479–485.
- [14] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiyama, and H. Omata, "Road damage detection using deep neural networks with images captured through a smartphone," *arXiv preprint arXiv:1801.09454*, 2018.
- [15] H. Xu, X. Su, Y. Wang, H. Cai, K. Cui, and X. Chen, "Automatic bridge crack detection using a convolutional neural network," *Applied Sciences*, vol. 9, no. 14, p. 2867, 2019.
- [16] H. Oliveira and P. L. Correia, "Automatic road crack detection and characterization," *IEEE Transactions on Intelligent Transportation Systems*, vol. 14, no. 1, pp. 155–168, 2012.
- [17] —, "Crackit-an image processing toolbox for crack detection and characterization," in *2014 IEEE international conference on image processing (ICIP)*. IEEE, 2014, pp. 798–802.
- [18] —, "Supervised strategies for cracks detection in images of road pavement flexible surfaces," in *2008 16th European Signal Processing Conference*. IEEE, 2008, pp. 1–5.
- [19] Y. Huang and B. Xu, "Automatic inspection of pavement cracking distress," *Journal of Electronic Imaging*, vol. 15, no. 1, p. 013017, 2006.
- [20] S. Iyer and S. K. Sinha, "A robust approach for automatic detection and segmentation of cracks in underground pipeline images," *Image and Vision Computing*, vol. 23, no. 10, pp. 921–933, 2005.
- [21] S. K. Sinha and P. W. Fieguth, "Automated detection of cracks in buried concrete pipe images," *Automation in construction*, vol. 15, no. 1, pp. 58–72, 2006.
- [22] —, "Segmentation of buried concrete pipe images," *Automation in Construction*, vol. 15, no. 1, pp. 47–57, 2006.
- [23] K.-B. Kim and J.-H. Cho, "Detection of concrete surface cracks using fuzzy techniques," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 14, no. 6, pp. 1353–1358, 2010.
- [24] G. K. Choudhary and S. Dey, "Crack detection in concrete surfaces using image processing, fuzzy logic, and neural networks," in *2012 IEEE fifth international conference on advanced computational intelligence (ICACI)*. IEEE, 2012, pp. 404–411.
- [25] T. Yamaguchi and S. Hashimoto, "Practical image measurement of crack width for real concrete structure," *Electronics and Communications in Japan*, vol. 92, no. 10, pp. 1–12, 2009.
- [26] M. Gavilán, D. Balcones, O. Marcos, D. F. Llorca, M. A. Sotelo, I. Parra, M. Ocaña, P. Aliseda, P. Yarza, and A. Amírola, "Adaptive road crack detection system by pavement classification," *Sensors*, vol. 11, no. 10, pp. 9628–9657, 2011.
- [27] Y. Sari, P. B. Prakoso, and A. R. Baskara, "Road crack detection using support vector machine (svm) and otsu algorithm," in *2019 6th International Conference on Electric Vehicular Technology (ICEVT)*. IEEE, 2019, pp. 349–354.
- [28] B. Cornelis, Y. Yang, J. T. Vogelstein, A. Doods, I. Daubechies, and D. Dunson, "Bayesian crack detection in ultra high resolution multimodal images of paintings," in *2013 18th International Conference on Digital Signal Processing (DSP)*. IEEE, 2013, pp. 1–8.
- [29] E. Feulvarch, M. Fontaine, and J.-M. Bergheau, "Xfem investigation of a crack path in residual stresses resulting from quenching," *Finite Elements in Analysis and Design*, vol. 75, pp. 62–70, 2013.
- [30] P. Sheng, L. Chen, and J. Tian, "Learning-based road crack detection using gradient boost decision tree," in *2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*. IEEE, 2018, pp. 1228–1232.



- [31] Y. Xu, S. Li, D. Zhang, Y. Jin, F. Zhang, N. Li, and H. Li, "Identification framework for cracks on a steel structure surface by a restricted boltzmann machines algorithm based on consumer-grade camera images," *Structural Control and Health Monitoring*, vol. 25, no. 2, p. e2075, 2018.
- [32] K. Chen, A. Yadav, A. Khan, Y. Meng, and K. Zhu, "Improved crack detection and recognition based on convolutional neural network," *Modelling and simulation in engineering*, vol. 2019, 2019.
- [33] S. Li and X. Zhao, "Image-based concrete crack detection using convolutional neural network and exhaustive search technique," *Advances in Civil Engineering*, vol. 2019, 2019.
- [34] S. Dorafshan, R. J. Thomas, and M. Maguire, "Sdnet2018: An annotated image dataset for non-contact concrete crack detection using deep convolutional neural networks," *Data in brief*, vol. 21, pp. 1664–1668, 2018.
- [35] L. Perez and J. Wang, "The effectiveness of data augmentation in image classification using deep learning," *arXiv preprint arXiv:1712.04621*, 2017.
- [36] C. S. Kenney, M. Zuliani, and B. Manjunath, "An axiomatic approach to corner detection," in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, vol. 1. IEEE, 2005, pp. 191–197.

## 〈 저자 소개 〉



### 김 종 현

- 2008년 세종대학교 컴퓨터학과 학사
- 2010년 고려대학교 컴퓨터학과 석사
- 2016년 고려대학교 컴퓨터학과 박사
- 2013년~2016년 (주) 테일레브 선임연구원
- 2017년~현재 강남대학교 소프트웨어응용학부 부교수
- 관심분야 : 물리 기반 시뮬레이션, 가상/증강현실,
- 지오메트리 프로세싱, 게임 물리, 게임 AI
- <https://orcid.org/0000-0003-1603-2675>