

논문 2017-54-6-10

컨볼루션 인코더-디코더 네트워크를 이용한 터널에서의 균열 검출 (Crack Detection in Tunnel Using Convolutional Encoder-Decoder Network)

한복규*, 양현석*, 이종민**, 문영식***

(Bok Gyu Han, Hyeon Seok Yang, Jong Min Lee, and Young Shik Moon[©])

요약

기존의 수작업으로 이루어지는 터널에서의 균열 검출은 점검자의 주관에 따라 균열을 판별하기 때문에 객관성을 보장하기 어렵다. 이러한 문제를 해결하기 위해서 터널에서 획득된 영상을 기반으로 균열을 검출하는 시스템이 많이 제안되었다. 하지만 기존의 방법은 터널 내부의 조명 상태, 균열 이외의 기타 예지 등 잡음에 상당히 민감하다. 이러한 단점은 터널의 상태에 따라 알고리즘의 성능을 크게 제한시킨다. 본 논문에서는 이러한 단점을 극복하기 위하여 컨볼루션 인코더-디코더 네트워크(Convolutional encoder-decoder network)를 이용한 균열 검출 방법을 제안한다. 제안하는 방법은 재현율과 정확률의 비교를 통하여 기존 연구에 비해 성능이 크게 향상되었음을 보였다.

Abstract

The classical approaches to detect cracks are performed by experienced inspection professionals by annotating the crack patterns manually. Because of each inspector's personal subjective experience, it is hard to guarantee objectiveness. To solve this issue, automated crack detection methods have been proposed however the methods are sensitive to image noise. Depending on the quality of image obtained, the image noise affect overall performance. In this paper, we propose crack detection method using a convolutional encoder-decoder network to overcome these weaknesses. Performance of which is significantly improved in terms of the recall, precision rate and F-measure than the previous methods.

Keywords : Crack detection, Tunnel lining, Convolutional neural network, Deconvolutional network

I. 서론

터널에서의 균열 검출은 구조물의 상태를 진단하고 안전성을 점검하기 위한 중요한 작업 중 하나이다. 균

* 학생회원, ** 정회원, *** 평생회원, 한양대학교 컴퓨터공학과 (Dept. Computer Science & Engineering., Hanyang University)

© Corresponding Author(E-mail : ysmoon@hanyang.ac.kr)

※ 이 논문은 국토교통과학기술진흥원의 국토교통기술사업화 지원사업(16TBIP-C111806-01) “인공신경망 알고리즘과 더블러링 기법을 이용하여 40km/h 주행속도로 터널의 균열을 검출할 수 있는 촬영 장비 및 균열 분석, 작도 자동화 패키지 프로그램 개발” 연구결과와 일부임.

Received : January 23, 2017 Revised : May 17, 2017

Accepted : May 30, 2017

열은 다양한 원인으로 발생할 수 있고 구조물의 현재 상태 및 성능의 예측에 활용할 수 있는 중요한 정보이다^[1]. 구조물에 발생한 균열은 진행 방향에 따라 중, 횡, 전단 균열로 구분할 수 있고, 균열의 원인에 따라 구조적 균열과 비구조적 균열로 나눌 수 있다. 구조적 균열이란 구조물의 사용 하중을 지지하지 못하는 즉, 구조적인 기능을 하지 못하는 단계로 진행되거나 도달한 균열을 의미한다. 구조적 균열은 설계요류, 설계하중을 초과한 외부하중의 작용, 시공 불량 및 철근 양의 부족 등으로 인하여 발생한다. 비구조적 균열이란 구조적 균열을 제외한 나머지의 상황에서 발생한 균열로서 철근의 부식 등의 요인으로 구조물의 안전성에 저하는 없으나 내구성, 사용성 저하를 초래할 수 있는 균열을 의미한



그림 1. 터널 라이닝 촬영과 터널 균열 보수
Fig. 1. Imaging of tunnel linings and crack repair.

다^[2~3]. 균열로 인해 발생할 수 있는 피해를 최소화하기 위해서는 터널 및 구조물에 대한 주기적인 안전 점검과 구조물에 대한 평가가 지속적으로 이루어져야 하며, 일정 크기 이상의 균열에 대해서는 보수 및 보강 대책이 필요하다.

기존의 터널 내부 균열 검사는 터널의 차로를 차단하고 작업 차량을 이용하여 터널의 내부(Tunnel lining)를 촬영(Tunnel scanning)한 다음 점검자들이 촬영된 영상을 육안으로 확인하여 균열을 판별하는 방식이다. 이 방법은 점검자들 개개인의 주관에 따라 균열 여부를 판별하기 때문에 객관성을 보장하기 어렵고 많은 시간과 비용을 소모하게 된다. 그림 1은 작업 차량이 터널 내부를 촬영하는 모습과 터널 내부에 발생한 균열을 보수하는 모습이다.

이와 같은 단점을 극복하기 위해 터널 스캐닝에서 획득된 영상에 대해 영상처리 기법을 이용한 균열 검출 방법들이 제안되고 있다. 기존의 방법들은 획득된 영상의 명암을 기반으로 에지를 추출하거나 원본과 블러된 영상의 차를 이용하는 방법이 대표적이다^[4~6]. 하지만 기존의 방법들은 터널에서 획득한 영상의 조명의 세기, 균열 이외의 잡음, 얼룩 등 다양한 요인에 강건하지 못하여 정확한 균열 검출에 한계가 있다.

최근에는 빅 데이터의 확보와 GPU 등 하드웨어의 발달, 학습기법의 발전에 기반을 둔 기계학습의 일종인 딥러닝(Deep-learning)이 다양한 분야에서 높은 성능을 보이고 있다. 머신비전 분야에서는 영상에 특화된 딥러닝 기법인 CNN(Convolutional Neural Network)이 다양한 응용에 활용되고 있다^[7~9].

II. 이전 연구

콘크리트 표면에서 균열 검출의 대표적인 방법으로는 영상의 에지정보를 이용하는 방법이 있다. Tillotson^[10]

은 지역적 이진화(Binarization)와 에지정보를 이용한 균열 검출 방법을 제안했다. Abdel-Qader^[11]은 소벨(Sobel), 케니(Canny) 에지 검출기와 고속푸리에변환(FFT, Fast Fourier Transform), 웨이블릿변환(Wavelet transform) 알고리즘들을 이용한 균열 검출 성능을 비교, 분석하여 최종적으로 웨이블릿 변환을 이용한 균열 검출 방법을 제안했다. Hutchinson^[12]은 케니 에지 검출기와 웨이블릿 변환을 통한 균열 검출과 추출된 파라미터들을 평가하는 방법을 제안하였고, Takeda^[13] 역시 웨이블릿 변환을 통한 균열 검출 방법을 제안했다. 하지만 이 방법들은 영상에 잡음(Noise)이 많이 포함되었을 경우 검출된 균열의 끊어짐이 발생하여 정확한 균열 검출이 어렵다. Sohn^[14]은 균열의 특징 중 하나인 선형성을 이용하기 위하여 허프변환(Hough transform)을 적용하여, 균열의 길이와 폭을 측정하는 방법을 제안했다. 영상 내 균열 영역의 명암을 이용한 방법으로 Fujita^[15]는 균열 영상 내 잡음을 감소시키고 검출 성능을 향상시키기 위해 2단계의 전처리 방법을 제안했다. 첫 번째 단계에서 차영상을 이용하여 크기가 작은 잡음들을 없애고, 두 번째 단계에서 영상 내의 에지 성분을 강조하여 배경과 에지 영역을 보다 깨끗하게 분리시킨다. Adhikari^[16] 또한 차영상을 이용한 균열 검출 방법을 제안하였으며, 획득된 차 영상에 최대엔트로피(Maximum entropy)를 적용하여 이진화하고 균열 영역을 검출했다. Yamaguchi^[5~6]는 균열의 연결성을 이용하는 여과 모델(Percolation model)로 균열을 검출하는 방법을 제안했다. 이 방법은 에지를 검출하고 에지 영역에서 시드(Seed) 픽셀을 생성하여, 정해진 윈도우 내에서 시드 픽셀보다 낮은 명도 영역을 골라 균열을 확장한다. 하지만 이 방법은 모든 시드 픽셀과 균열로 판별된 모든 픽셀에서 같은 연산을 수행하므로 연산시간이 많이 걸린다는 단점이 있다. Kim^[17]은 형태학적 연산(Morphological operation)을 이용하여 균열을 검출하는 방법을 제안했다. 기존의 형태학적 연산을 적용한 영상들은 고정된 마스크 크기에 대응하는 균열만을 검출하였으나, Kim은 스케일링과 형태학적 연산을 적용하여 다양한 스케일에 강건한 균열 검출 방법을 제안했다.

머신러닝 기법을 이용하여 균열을 검출하는 연구방법 또한 많이 제안되었다. Choudhary와 Dey^[18]는 퍼지 로직(Fuzzy logic)과 신경망(Neural net) 모델을 이용하여 균열을 검출하는 방법을 제안했다. 이 방법은 먼저 RGB 영상을 그레이 영상으로 변환한 후 소벨 에지 검출기를 통하여 콘크리트 표면의 균열과 잡음을 검출한다.

두 번째로 형태학적 연산을 이용하여 검출된 균열 중 거리가 가까운 균열들을 연결하고 잡음을 제거한다. 세 번째로 획득된 균열들의 최대 축과 최단 축을 각 균열의 특징 값으로 추출한다. 이렇게 추출된 특징 값을 신경망이나, 퍼지모델에 적용하여 균열을 판별한다. Choudhary와 Dey는 이 실험을 통하여 신경망을 이용한 방법이 퍼지 로직을 이용한 방법보다 균열 검출에서 좋은 결과를 보임을 실험적으로 증명했다. Han^[19]은 3개의 필터(최솟값, 중간값, 형태학적 연산)를 이용한 균열 검출 방법을 제안했다. Han은 이 방법에서 검출된 균열의 특징 벡터를 추출한 후 신경망을 이용하여 균열과 잡음을 분류했다.

최근 영상 인식 분야에서 많이 사용되고 있는 CNN은 딥러닝의 한 기법으로 Y. Lecun^[20]에 의해 1989년 필기체 인식을 위해 제안되었다. 이 방법은 여러 학습 데이터의 특징을 추출하고 추상화하여 영상의 군집, 분류 등을 수행하는 기계학습의 한 방법이다. CNN을 이용한 많은 애플리케이션 중 대중적으로 이용되고 있는 분야는 영상 인식(Image recognition)이다. CNN은 영상 인식 뿐 아니라 객체 분류(Object classification)와 영상 분할(Image segmentation) 등 많은 연구 분야에도 적용되고 있다. CNN은 기존의 분류 기법과 다르게 영상에서 특징 벡터를 자동으로 학습하고 영상의 특징을 자동으로 추출할 수 있어 특징 벡터의 추출과 분류를 통합

적으로 수행할 수 있다. 따라서 본 논문에서는 이러한 장점을 활용하여 기존의 CNN 구조에 디컨볼루션 계층을 결합한 컨볼루션 인코더-디코더 네트워크(Convolutional Encoder-Decoder Network)를 사용하여 균열을 검출하는 방법을 제안한다.

III. 컨볼루션 인코더-디코더 네트워크를 이용한 균열 검출 방법

제안하는 방법은 입력 영상을 네트워크의 입력으로 넣어 확률 지도(Probability map)를 획득하는 확률 지도 획득 단계와 확률 지도에서 균열 후보 영역을 생성하기 위한 이진화 단계, 균열 영역 중 잡음 영역을 제거하는 잡음 제거(Removing noise) 단계로 구성된다. 제안하는 방법의 흐름도는 그림 2와 같다.

3.1 네트워크 구조 및 학습

제안하는 구조는 인코더(Encoder)와 디코더(Decoder)로 구성된다. 인코더는 다수의 컨볼루션 계층(Convolutional layer)으로 이루어진다. 각 컨볼루션 계층은 컨볼루션(Convolution) 단계와 풀링(Pooling) 단계로 이루어진다. 컨볼루션 단계는 영상에 학습된 마스크를 슬라이딩 윈도우 방식으로 이동시키며 합성 곱 연산을 통해 특징 맵을 만든다. 풀링 단계는 특징 맵을 축소하여 파라미터와

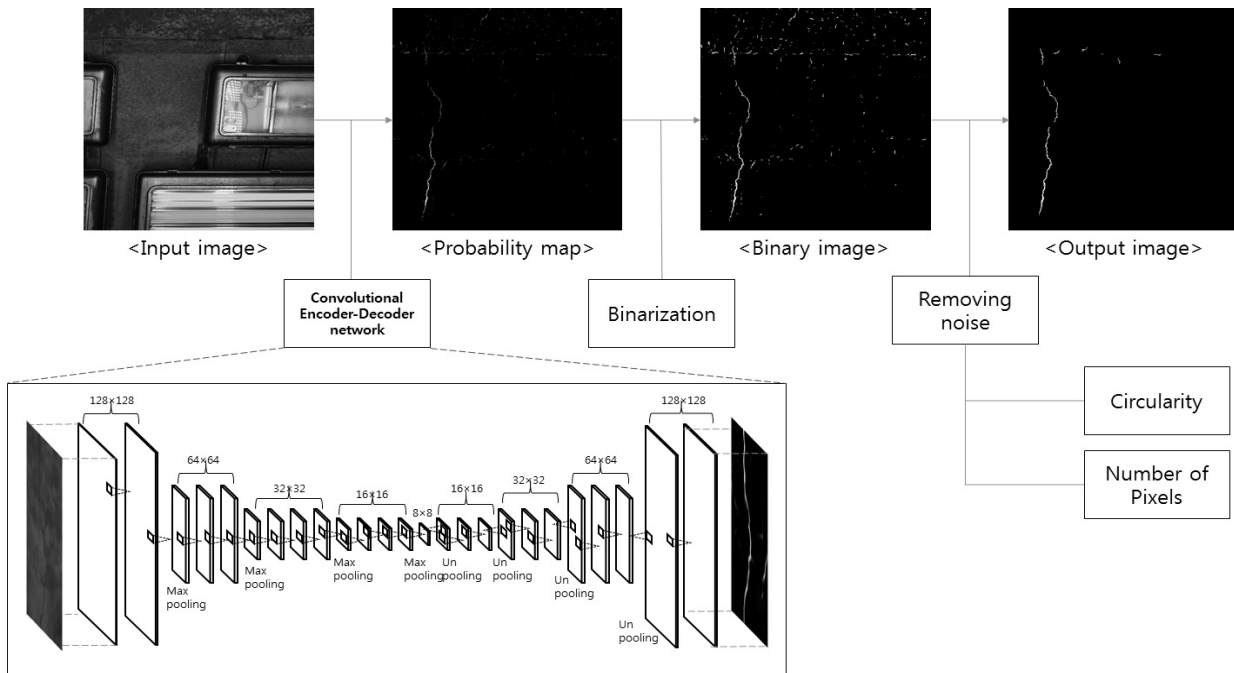


그림 2. 제안하는 방법의 흐름도
Fig. 2. Structure of the proposed framework.




그림 3. 제안하는 방법의 네트워크 구조
Fig. 3. Structure of the proposed network.

계산 공간을 줄이고 과적합(Overfitting)을 완화하는 역할을 한다. 디코더는 컨볼루션 계층에 대칭적으로 다수의 디컨볼루션 계층(Deconvolutional layer)으로 이루어진다. 각 디컨볼루션 계층은 언풀링(Unpooling) 단계와 디컨볼루션(Deconvolution) 단계로 이루어진다. 언풀링 단계는 컨볼루션 계층의 풀링 단계에서 발생한 정보의 손실을 해결하기 위해 사용된다. 디컨볼루션 단계는 학습된 마스크를 이용하여 언풀링 단계를 거친 특징 맵을 재구성한다^[21].

제안하는 방법의 네트워크 구조는 기존의 Noh^[21]가 제안한 구조와 다르게 입력 영상이 크고 빠르게 처리해야 하는 균열 검출 시스템 특성에 맞추어 구성되었다. 제안하는 구조는 기존의 구조보다 얇은 층을 구성하여 학습과 예측 시간을 최소화했다. 제안하는 구조는 패치 영상에 대한 특징 맵의 크기가 인코더에서 1×1 이 아닌 16×16 의 크기에서 디코더로 전달되어 원영상의 크기를 복원한다. 이것은 기존의 구조와 비교하면 컨볼루션 계층 2개, 디컨볼루션 계층 2개를 줄인 것과 같다. 기존의 구조는 영상 분할 및 분류에 맞추어 제안되었지만 본 논문에서 제안하는 구조는 영상 내 균열만의 위치를 찾아내기 위하여 제안되었으므로 기존의 방법보다 필터의 크기와 수, 네트워크의 깊이를 축소할 수 있었다. 제안하는 방법의 구조는 학습과 예측의 속도, 균열 검출의 정확률과 재현율을 고려하여 실험적으로 정의하였고 패치의 입력 크기 또한 64×64 , 96×96 , 128×128 의 크기로 실험 하였을 때 학습과 예측에 사용된 총 시간과 재현율과 정확률을 고려하여 최적의 크기인 128×128 로 정의했다. 그림 3은 제안하는 방법의 네트워크 구조이다.

네트워크의 학습 영상으로는 터널 내에서 획득된 원본 영상과 점검자들이 수작업으로 태깅한 정답 영상을 사용했다. 영상의 크기는 2880×2880 이며 총 장수는 138장이다. 태깅된 138장의 영상을 좌우로 반전시키고, $\pm 10^\circ$ 씩 회전시켜 학습데이터의 양을 늘렸다. 회전된 영상은 슬라이딩 윈도우 방식으로 40픽셀씩 이동하며




그림 4. 학습에 사용된 원본 영상과 정답 영상
Fig. 4. Original image and ground truth image for training.

네트워크의 입력 크기인 128×128 에 맞추어 생성된다. 그림 4는 학습에 사용된 영상의 예시이다. 네트워크의 학습으로는 Matlab에서 지원하는 프레임 워크인 Matconvnet을 이용하여 학습했다. CPU는 i5-4460을 사용하였고, GPU는 GeForce GTX 1080을 사용했다.

3.2 제안하는 방법의 수행 단계

먼저, 네트워크의 수행 단계로는 입력 영상에서 추출한 128×128 크기의 패치영상이 컨볼루션 계층을 거쳐 16×16 크기의 특징 맵으로 줄어들게 된다. 각 단계별로 컨볼루션 계층에서 생성된 마스크들은 이전 계층의 결과 값을 이용하여 가중치를 학습하게 된다.

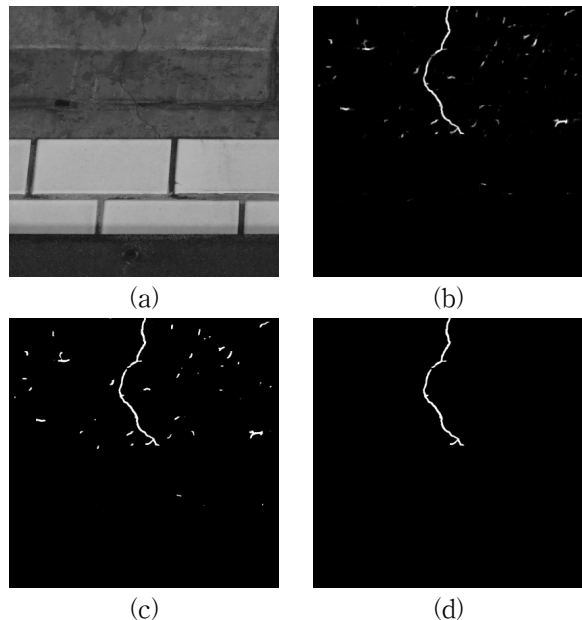


그림 5. 제안하는 방법의 단계별 결과
(a) 입력영상 (b) 획득된 확률 지도 (c) 이진화 단계 (d) 잡음 제거 후 최종 결과영상

Fig. 5. Result of each process of the proposed method.

(a) Input image (b) Obtained probability map (c) Binarized image (d) Noise reduced image

16×16 크기의 특징 맵은 디컨볼루션 계층을 거치면서 입력영상과 동일한 128×128의 크기로 변화한다. 따라서 입력 영상에 투영하여 영상 내의 균열부분을 나타낼 수 있다.

패치 단위로 예측을 수행하게 되면 각 패치의 균열 영역에 대한 확률 지도를 획득할 수 있다. 패치 영상에 대하여 획득된 확률 지도는 64픽셀만큼 이동하여 다른 패치의 확률 지도와 중첩(Overlap)되게 된다. 확률 지도의 중첩은 긴 얼룩이나 잡음과 비슷한 낮은 확률 값을 가질 수 있는 작은 크기의 균열을 2개 패치의 중첩을 통해 높은 확률 값으로 바꾸어 주기 위하여 사용된다. 이렇게 획득된 확률 지도에서 균열 후보영역을 검출하기 위해서는 이진화가 필요하다. 획득된 확률지도에서 높은 임계값을 설정할 경우에는 미세한 균열이 사라지고 균열 영역이 끊어지는 현상이 발생하며, 너무 낮은 임계값을 사용할 경우에는 균열이 아닌 영역들이 많이 포함된다. 제안하는 방법에는 이진화에 사용되는 임계값을 각각 재현율과 정확률로 평가하여 실험적으로 0.3을 사용했다.

균열 후보 영역에는 균열뿐만 아니라 잡음도 포함하고 있다. 제안하는 방법에서는 균열 후보 영역에서 잡음을 제거하기 위해 균열의 특성 중 원형도와 영역의 픽셀 수를 이용한다. 각각의 후보 영역에서 원형도가 높거나 픽셀의 수가 적은 영역들은 잡음으로 간주하고 제거한다. 그림 5는 제안하는 방법의 단계별 결과이다.

IV. 테스트 및 결과 분석

4.1 정성적 평가

평가에 사용한 영상으로는 터널에서 획득된 640×640 크기의 영상 40장을 이용하였고 대조비가 낮고 잡음이 많이 포함하고 있는 영상 20장과 대조비가 높고 잡음을 적게 포함하는 영상 20장으로 구성된다.

제안하는 방법의 성능을 평가하기 위하여 다양한 기존의 방법들과 비교를 했다^[6, 16~17, 19].

그림 6의 비교 1에서 사용된 실험 영상은 터널의 콘크리트 벽면에서 촬영된 영상으로 잡음이 적고 균열 영역이 비교적 깨끗하게 나타난 영상이다. 그림 6에서 볼 수 있듯이 필터 기반의 방법들은 균열 영역과 배경의 명도 차이가 큰 부분은 검출할 수 있었지만, 균열의 폭이 가늘어지는 부분이나 균열과 배경의 명도 차이가 작은 경우에는 균열 영역을 검출하지 못하여 균열의 끊어짐이 발생하는 것을 볼 수 있다. 생성된 시드 픽셀을 기




그림 6. 기존 방법과의 균열 검출 결과 비교 1

(a) 입력 영상 (b) 정답 영상 (c) Adhikari의 방법 (d) Kim의 방법 (e) Han의 방법 (f) Yamaguchi의 방법 (g) 제안하는 방법 (h) 제안하는 방법의 노이즈 제거 후

Fig. 6 Comparison proposed method with previous methods 1.

(a) Original image (b) Ground truth (c) Adhikari's method (d) Kim's method (e) Han's method (f) Yamaguchi's method (g) Proposed method (h) After removing noise

준으로 영역을 확장시키는 방법인 Yamaguchi의 방법은 필터 기반의 방법들보다 균열영역 검출에서는 나은 결과를 보이지만, 잡음이 배경보다 어둡고 직선의 형태를 가지고 있을 경우 균열로 오검출하는 경우가 발생했다.




그림 7. 기존 방법과의 균열 검출 결과 비교 2
(a) 입력 영상 (b) 정답 영상 (c) Adhikari의 방법
(d) Kim의 방법 (e) Han의 방법 (f) Yamaguchi의 방법
(g) 제안하는 방법 (h) 제안하는 방법의 노이즈 제거 후

Fig. 7. Comparison proposed method with previous methods 2.
(a) Original image (b) Ground truth (c) Adhikari's method
(d) Kim's method (e) Han's method (f) Yamaguchi's method
(g) Proposed method (h) After removing noise

제안하는 방법은 기존의 방법보다 잡음에 강건함을 보이고 균열 영역이 깨끗하게 검출되는 것을 볼 수 있다. 그림 7의 비교 2에 사용된 실험 영상은 터널의 내부 조명등 사이에서 촬영된 영상으로 많은 잡음을 포함하




그림 8. 기존 방법과의 균열 검출 결과 비교 3
(a) 입력 영상 (b) 정답 영상 (c) Adhikari의 방법
(d) Kim의 방법 (e) Han의 방법 (f) Yamaguchi의 방법
(g) 제안하는 방법 (h) 제안하는 방법의 노이즈 제거 후

Fig. 8. Comparison proposed method with previous methods 3.
(a) Original image (b) Ground truth (c) Adhikari's method
(d) Kim's method (e) Han's method (f) Yamaguchi's method
(g) Proposed method (h) After removing noise

고 있지만 균열 영역이 비교적 뚜렷하다. 그림 7에서 필터 기반의 균열 검출 결과는 그림 6에 나타난 결과보다 균열 영역 주위에 잡음이 많아 균열 영역이 명확히 검출되지 못했다. 그림 7은 그림 6과 유사하게 균열의

끊어짐, 배경 영역과 균열의 차이가 크지 않은 부분에서는 검출된 균열의 연결성이 낮은 것을 볼 수 있다. 영역 확장 기반의 방법은 필터 기반의 방법보다 잡음에 대한 오검출이 적은 것을 볼 수 있다. 제안하는 방법은 기존의 방법보다 검출된 균열 영역에서 잡음이 많이 제거된 것을 확인할 수 있지만 균열 주위에 붙어있는 잡음까지 균열 영역으로 오검출했다.

그림 8의 비교 3에 사용된 실험 영상 또한 터널 내부 조명등 사이에서 촬영된 영상으로 균열과 배경의 명도차가 작고 잡음을 포함하고 있다. 필터 기반의 방법과 영역 확장 방법은 균열 영역을 검출하지 못하고 균열 이외의 예지만을 균열 영역으로 오검출했다. 하지만 제안하는 방법은 낮은 대조비 영상에서도 기존의 방법들보다 균열을 정확하게 검출한 것을 알 수 있다.

4.2 정량적 평가

제안하는 방법의 정량적 평가를 위하여 재현율(Recall), 정확률(Precision), F-척도(F-measure)와 균열 영상의 평균 처리속도를 평가척도로 사용했다.

표 1. 정량적 평가 1

Table1. Quantitative comparison based on Recall, Precision, and F-measure 1.

Method	Recall	Precision	F-measure
Adhikari의 방법 ^[16]	0.32	0.47	0.38
Kim의 방법 ^[17]	0.82	0.31	0.45
Han의 방법 ^[19]	0.85	0.27	0.41
Yamaguchi의 방법 ^[5]	0.83	0.27	0.41
제안하는 방법	0.97	0.71	0.82

표 1은 잡음을 적게 포함하고 대조비가 높은 실험 영상 20장의 실험 결과이다. 표에서 볼 수 있듯이 기존 방법과 제안하는 방법을 비교하였을 때 최고 대비 재현율 0.12, 정확률 0.24, F-척도 0.37의 성능 향상을 보였다.

표 2는 잡음을 포함하고 대조비가 낮은 균열 영상 20장에 대한 기존의 방법과 제안하는 방법의 결과이다. 표에서 볼 수 있듯이 제안하는 방법이 기존 방법의 최고성능보다 재현율 0.2, 정확도 0.41, F-척도 0.37의 성능 향상을 보인다.

표 3은 각 방법별로 실험 영상들의 처리 시간을 평균한 것이다. 표에서 볼 수 있듯이 제안하는 방법이 기존의 방법과 비교 하였을 때 각각 +3.19, +3.05, -4.35, -611.92의 속도차이를 보였다.

표 2. 정량적 평가 2

Table2. Quantitative comparison based on Recall, Precision, and F-measure 2.

Method	Recall	Precision	F-measure
Adhikari의 방법 ^[16]	0.08	0.01	0.08
Kim의 방법 ^[17]	0.45	0.07	0.12
Han의 방법 ^[19]	0.39	0.18	0.25
Yamaguchi의 방법 ^[5]	0.02	0.01	0.01
제안하는 방법	0.65	0.59	0.62

표 3. 정량적 평가 3

Table3. Quantitative comparison based on average of processing time.

Method	Average of processing time (second/image)
Adhikari의 방법 ^[16]	0.07
Kim의 방법 ^[17]	0.21
Han의 방법 ^[19]	7.61
Yamaguchi의 방법 ^[5]	615.18
제안하는 방법	3.26

4.3 결과 분석

표 1은 잡음이 적고 균열 영역이 뚜렷한 균열영상 20장에 대해 기존의 방법과 제안하는 방법의 비교 평가이다. 기존의 방법들은 그림 6에서 볼 수 있듯이 Adhikari의 방법을 제외하면 균열 영역이 뚜렷한 부분에서 균열 영역을 잘 검출한다. 반면 잡음영역을 균열로 오검출하는 경우가 많아 표 1에서 정확률이 재현율에 비해 상당히 낮은 것을 볼 수 있다.

표 2는 터널에서 획득된 실험영상 중 대조비가 낮고 잡음이 많이 포함된 영상 20장을 이용한 테스트 결과이다. Adhikari의 방법은 중간 값 필터와 원본 영상의 차를 이용하는 방법으로 입력 영상에서 균열 영역과 배경 영역의 명도의 차이가 큰 경우에는 비교적 좋은 결과를 보였지만, 대조비가 낮은 영상과 잡음이 많은 영상에 대해서는 재현율과 정확률 모두 현저하게 낮아지는 것을 확인할 수 있었다. 이것은 최대 엔트로피 방법에서 사용되는 이진화 임계값이 차 영상에 나타난 균열 영역의 값보다 크게 정해지기 때문이다. 또한 전역적 이진화를 수행하기 때문에 균열 영역이 검출 되더라도 잡음 영역과 균열 영역을 분류하는 단계가 필요하다.

Kim의 방법은 입력 영상을 1/8배까지 줄이고 각 스케일에 형태학적 연산을 적용하여 균열을 검출하는 방법이다. 이 방법은 균열의 스케일을 고려하였지만, 낮은

대조비 영상과 잡음이 많은 영상에서 좋지 않은 결과를 보였다. 또한 4개의 스케일 영상을 모두 사용하기 때문에 균열이 아닌 큰 에지 영역이나 오염에 의한 얼룩을 균열로 오검출하는 결과를 보이기도 했다.

Yamaguchi의 방법은 입력 영상에서 균열이 급격히 얇아 지거나 명도의 차가 크지 않았을 경우에 균열 영역을 명확히 검출할 수 없었다. 또한 비 균열 영역임에도 노이즈가 길게 나타날 경우 노이즈를 균열로 오검출 했다.

Han의 방법은 3개의 필터(최솟값, 중간값, 형태학적 연산)를 이용하여 균열 후보 영역을 검출하고, 검출된 후보영역의 특징을 추출하여 균열과 비 균열을 구분하게 된다. 이 검출된 균열 후보 영역에서 신경망을 이용하여 균열과 잡음을 분류하여 이전의 방법들보다 잡음 영역의 비율이 낮지만 균열 후보 검출 단계에서 대조비가 낮은 영상의 경우 균열 영역을 명확하게 검출하지 못했다.

제안하는 방법은 컨볼루션 인코더-디코더 네트워크를 이용하여 균열 영역을 검출했다. 제안하는 방법은 기존 방법과의 비교에서 확인할 수 있듯이 입력 영상에 나타난 잡음에 강건하게 균열 영역을 검출할 수 있고, 상대적으로 낮은 대조비 영상에서도 기존의 방법들보다 정확하게 균열을 검출했다.

표 3은 영상 40장에 대하여 균열을 검출 하였을 때 사용된 수행시간을 평균한 것이다. 필터기반의 기존 방법들은 적용되는 필터의 수와 반복 적용에 따라 수행시간이 결정된다. Kim의 방법과 Han의 방법에서는 원본 영상을 1/8까지 줄이고 회전하는 구조요소를 이용하여 모폴로지 연산을 반복적으로 적용할 때 많은 수행시간이 소요된다. Yamaguchi의 방법은 생성된 시드로부터 균열 영역을 반복적으로 확장하는 방법이므로 생성된 시드의 양이 많을수록 처리 시간이 길어진다. 제안하는 방법은 네트워크 구조의 복잡성에 비례하여 연산 시간이 결정된다. 제안하는 방법은 Adhikari와 Kim의 방법을 제외한 나머지 방법보다 빠른 성능을 보임을 확인할 수 있다.

V. 결론 및 향후 연구 계획

본 논문에서는 터널 내부에서 촬영된 영상 내에서 균열을 검출하는 방법을 제안했다. 기존의 방법들은 촬영된 영상의 균열과 비균열 영역의 명도 차에 기반하여 균열 후보 영역을 검출했다. 검출된 후보 영역들의 특징 벡터들을 이용하여 균열과 잡음 영역을 분류하여 최

중 균열 영역을 획득했다. 하지만 이 방법들은 입력 영상에서의 배경과 균열의 명도차가 크고, 잡음이 적은 영상에 대해서는 좋은 결과를 보였지만, 그렇지 않은 경우 현저하게 성능이 떨어지는 결과를 보였다. 또한 균열 이외의 물체들(조명등, 전선 등)을 제거하기 위한 별도의 과정을 필요로 한다.

본 논문에서는 기존의 이러한 과정을 통합적으로 수행하기 위하여 컨볼루션 인코더-디코더 네트워크를 이용한 균열 검출 방법을 제안했다. 제안하는 방법은 기존의 방법보다 평균 재현율 +0.18, 평균 정확도 +0.41, 평균 F-척도 +0.39의 성능 향상을 보였다.

일반적으로 균열 검출 방법에서 균열 영역이 명확하게 검출되지 않는다면 이후 단계에서는 균열이 잡음으로 오인되기 쉽다. 따라서 제안하는 방법은 균열 검출에 초점을 맞추었다. 네트워크의 성능향상을 위하여 더욱 많은 학습데이터가 필요하며 검출된 균열 후보 영역 중 잡음과 균열 영역을 보다 정확하게 분류하는 단계가 필요하다. 향후에는 균열 검출을 위하여 학습 기법 연구 및 검출된 균열 영역에서의 잡음 제거 방법을 연구할 계획이다.

REFERENCES

- [1] J. M. Kang, Y. C. Oh, and D. Y. Um, "The crack information acquisition of concrete object by digital image processing," *Journal of the Korean Society of Civil Engineers D*, vol. 22, no. 5D, pp. 1001-1010, 2002.
- [2] Korea Infrastructure Safety Corporation, "Development of special specifications of crack evaluation method, repair, strengthening on concrete structures," Korea Infrastructure Safety Corporation, 1999.
- [3] J. S. Jeong, Y. S. Yu, H. B. Yoon, I. S. Jung, and C. S. Lee, "Detect judgement standard for concrete cracks of apartment building," *Journal of the Architecture Institute of Korea Structure & Construction*, vol. 28, no. 11, pp. 199-206, 2012.
- [4] T. Nishikawa, J. Yoshida, T. Sugiyama, and Y. Fujino, "Concrete crack detection by multiple sequential image filtering," *Comput. -Aided Civ. Infrastruct. Eng.*, vol. 27, no. 1, pp. 29-47, 2012.
- [5] T. Yamaguchi and S. Hashimoto, "Fast crack detection method for large-size concrete surface images using percolation-based image processing," *Mach.. Vision. Appl.*, vol. 21, no. 5, pp. 797-809, 2010.

- [6] T. Yamaguchi, S. Nakamura, and S. Hashimoto, "An efficient crack detection method using percolation-based image processing," in Proc. 3rd IEEE Conf. Ind. Electron. Appl., pp. 1875-1880, Jun. 2008.
- [7] Y. J. Kim and E. G. Kim, "Image based fire detection using convolutional neural network," Journal of the Korea Institute of Information and Communication Engineering, vol. 20, no. 9, pp. 1649-1656, Sep. 2016.
- [8] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 580-587, 2014.
- [9] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille. "Semantic image segmentation with deep convolutional nets and fully connected crfs," International Conference on Learning Representations (ICLR), 2015.
- [10] H. T. Tillotson, M. S. Snaith, and Y. Huang, "Detecting cracks by image analysis on a parallel computer," in Proceedings of the International Computing Congress, ASCE, Boston. pp. 11-23, 1998.
- [11] I. Abdel-Qader, O. Abudayyeh, and M. Kelly "Analysis of edge-detection techniques for crack identification in bridges," J. Comput. in Civil Eng., vol. 17, no. 4, Oct. 2003.
- [12] T. C. Hutchinson and Z. Chen, "Improved image analysis for evaluating concrete damage," J. Comput. Civil Eng., vol. 20, no. 3, pp. 210-216, May 2006.
- [13] H. Takeda, S. Koyama, K. Horiguchi, and T. Maruya, "Using image analysis and wavelet transform to detect cracks in concrete structures," Report of Taise Technology Center, No. 39, p. 25, 2006.
- [14] H. G. Sohn, Y. M. Lim, K. H. Yun, and G. H. Kim, "Monitoring crack changes in concrete structures," Comput. -Aided Civ. Infrastruct. Eng., vol. 20, no. 1, pp. 52-61, 2005.
- [15] Y. Fujita and Y. Hamamoto, "A robust automatic crack detection method from noisy concrete surfaces," Mach. Vis. Appl., vol. 22, no. 2, pp. 245-254, 2011.
- [16] R. S. Adhikari, O. Moselhi, and A. Bagchi, "Image-based retrieval of concrete crack properties," Journal of the International Society for Gerontechnology, vol. 11, no. 2, pp. 315-321, 2012.
- [17] Y. R. Kim and T. M. Oh, "Multi-scale crack detection using scaling," Journal of the Institute of Electronics and Information Engineers, vol. 50, no. 9, pp. 194-199, Sep. 2013.
- [18] G. K. Choudhary and S. Dey, "Crack detection in concrete surfaces using image processing, fuzzy logic, and neural networks," IEEE Fifth International Conference on Advanced Computational Intelligence (ICACI), pp. 404-411, Oct. 2012.
- [19] B. G. Han, H. S. Yang, J. M. Lee, and Y. S. Moon, "Crack detection in tunnel using multi-filter," Conference of the Institute of Electronics and Information Engineers, pp. 510-513, Nov. 2016.
- [20] Y. LeCun and Y. Bengio "Convolutional networks for images, speech, and time series," The handbook of brain theory and neural networks, 3361, no. 10, pp. 1-14, 1995.
- [21] H. W. Noh, S. H. Hong, and B. H. Han, "Learning deconvolution network for semantic segmentation," The IEEE International Conference on Computer Vision (ICCV), pp. 1520-1528, 2015.

저 자 소 개



한 복 규(학생회원)
2016년 한림대학교 컴퓨터공학과
학사 졸업.
2016년~현재 한양대학교 컴퓨터
공학과 석사 과정.
<주관심분야: 영상처리, 컴퓨터비
전, 패턴인식>



이 증 민(정회원)
2007년 한양대학교 컴퓨터공학과
학사 졸업.
2009년 한양대학교 컴퓨터공학과
석사 졸업.
2015년 한양대학교 컴퓨터공학과
박사 졸업.
2015년~2016년 한양대학교 컴퓨터공학과 박사후
연구원.
2016년~현재 한양대학교 컴퓨터공학과 연구 조
교수.
<주관심분야: 영상처리, 컴퓨터비전, 패턴인식>



양 현 석(학생회원)
2010년 영남대학교 전자정보공학
부 학사 졸업.
2012년 한양대학교 컴퓨터공학과
석사 졸업.
2012년~현재 한양대학교 컴퓨터
공학과 박사 과정.
<주관심분야: 영상처리, 컴퓨터비전, 패턴인식>



문 영 식(평생회원)
1980년 서울대학교 전자공학과 학사
졸업.
1982년 한국과학기술원 전기 및 전
자공학과 석사 졸업.
1990년 Ph. D. in Department of Electrical and
Computer Engineering University of
California at Irvine.
1982년~1985년 한국 전자통신연구소 연구원.
1989년~1990년 Inno Vision Medical 선임연구원.
1990년~1992년 생산기술연구소 선임연구원.
1990년~현재 한양대학교 컴퓨터공학과 교수.
<주관심분야: 영상처리, 컴퓨터비전, 패턴인식>