

XAI 기반의 공공시설물 건전도 안전검사 평가시스템 연구

박예슬*, 경선재*, 김민준*, 오찬미*, 이재성*, 이재환*, 이현승*, 이철희**, 문현준*

*세종대학교 컴퓨터공학과, ** DeepInspection

hmoon@sejong.edu

XAI based public facility safety evaluation system research

Yesul Park*, Seonjae Kyeong*, Minjun Kim*, Chanmi Oh*, Jeasung Lee*, Jaehwan

Lee*, Hyunseung Lee*, Cheolhee Lee**, Hyeonjoon Moon*

*Department of Computer Science and Engineering, Sejong University,

** DeepInspection

요 약

공공시설에 대한 안전점검은 공공시설의 노후화에 따라 정기적인 검사의 필요성이 요구되고 있다. 기존의 안전점검 방식은 대부분 육안으로 점검하는 것에 의존하는데 이는 점검자의 숙련도에 따라 결과의 품질이 달라지게 된다. 본 논문에서는 XAI 기반의 공공시설물 건전도 안전검사 평가시스템을 제안하며, 이는 점검자의 숙련도와 무관하게 항상 같은 결과를 도출해 내며 XAI 를 통해 사용자에게 안전점검에 대한 결과를 제시해준다. 공공시설물 중 터널 시설물의 안전검사 평가시스템을 기반으로 하는 연구를 진행하였으며 이는 수정없이 교량 시설물 등 다른 공공시설물에 적용이 가능하다. 본 논문은 5 가지로 구분된다. 1) 터널 이미지와 균열에 마스크를 적용한 이미지 두 가지의 데이터 셋을 448x448 로 생성한다. 2) UNet 과 Resnet152 의 두 모델을 적용한 혼합 모델을 이용하여 생성한 데이터 셋을 훈련시킨다. 3) 훈련된 혼합 모델에서 생성된 분할 이미지에 대해 노이즈 제거 과정을 진행한다. 4) 노이즈 제거가 끝난 이미지에 스켈레톤화(Skeletonization)를 적용시켜 균열 이미지의 뼈대를 구한다. 뼈대 이미지 기반으로 균열의 길이, 두께, 위치등의 정보를 얻는다. 5) XAI 부분에서는 뼈대 이미지의 정보를 토대로 균열의 위치, 두께, 길이 등에 대해 계산을 진행한 후 사용자에게 제시해준다.

1. 서론

인간의 편의를 위한 사회간접자본(SOC: social overhead capital) 중 하나인 터널은 현재까지 많이 건설되었고 그 안전 문제는 날이 갈수록 대두되고 있다. 시간의 흐름에 따라 터널 내부에는 노후화, 열에 의한 팽창 및 수축, 사람에 의한 파손, 지형 변화와 같은 다양한 영향으로 인해 터널의 표면과 내부 구조가 파손되어 균열이 발생한다. 터널의 파손 및 균열의 보수나 보강이 없는 상태가 계속 지속되면 위험 요소가 되어 막대한 피해를 주고 심각한 인명 사고까지 발생할 수 있다. 따라서 피해를 최소화하기 위해 터널 구조물에 대한 주기적인 안전 점검과 구조물에 대한 평가가 지속적으로 이루어져야 하며, 일정 크기 이상의 균열에 대해서는 보수 및 보강 대책이 필요하다.

기존의 전통적인 터널 내부 균열 검사의 문제로 지적 될만한 사안은 담당 점검자들이 내부 촬영 영상을 육안으로 판별하여 점검을 시행한다는 것이다. 이는 점검자의 주관적인 판단으로 오류를 범할 수 있고 점검자의 상태에 따라 다른 결과를 도출할 수 있으며 시간과 비용이 많이 들어 비효율적이다.

이를 통해 시간이 경과하여 여러 가지 상호복합적 원인에 의해 균열이 발생하는데 반해 안전점검이나 관리를 하는 인력은 이에 미치지 못하고 있음을 알 수 있다. 따라서 현재 터널 안전 관리 시스템을 지능화하여 운영의 효율성을 증진하고 제한된 인적 자원으로 현재의 열악한 터널 관리 체계를 개선하고자 하는

노력이 이루어져야 한다.

본 연구에서는 딥러닝 기반 UNet 과 Resnet152 모델을 모두 적용하는 혼합 모델을 이용하여 터널 내부에서 촬영된 영상 내에서 균열을 검출하는 방법을 제안한다. 또한 AI(Artificial Intelligence)보다 발전된 형태의 인공지능인 설명 가능한 인공지능 XAI(eXplainable Artificial Intelligence)를 기반으로 개발하여 결과 분석 및 오류 수정하는데 드는 시간과 비용이 절약할 수 있다.

XAI 기반 터널 결함 자동 검출 알고리즘 연구가 개발될 경우 건설 부분의 자동화뿐만 아니라 효과적인 유지 보수 및 관리를 통하여 구조물이 오랜 기간 안전하게 기능을 수행할 수 있도록 크게 이바지할 수 있을 것이다.

본 논문은 1 장 서론에 이어 2 장 본론, 3 장 실험결과, 4 장 결론 순으로 기술한다.

2. 본론

XAI 기반 터널 결함 자동 검출 알고리즘 구현의 진행 과정은 [그림 1]과 같이 크게 5가지 부분으로 나눌 수 있다.

첫 번째로, 데이터셋을 생성하는 과정이다. 터널 사진을 찍는 기계로부터 전체 터널 사진을 얻은 후 이미지에 대응되는 균열

위치에 균열 마스크 이미지를 생성한다. 이로써 훈련에 필요한 입력 이미지와 이미지에 대응되는 균열 마스크로 이루어진 데이터셋이 준비가 된다.

두번째로, 혼합 모델 (Unet+Resnet152)을 생성한 데이터셋 기반으로, 입력으로는 실제 터널 이미지, 훈련 정답으로는 생성한 균열 마스크를 설정한 후 Dice 계수(F1 Score) 와 IoU(Intersection over Union) 지표를 손실 함수로 사용하여 결과 이미지가 균열 마스크 이미지와 같게 나오도록 훈련시킨다.

세번째로, 훈련된 혼합 모델에서 나온 분할 이미지에 대하여 노이즈 제거 과정을 진행한다. 이 과정에서는 분할 이미지에 대하여 Erosion(침식), Dilation(팽창) 등을 이용하여 열린 모폴로지 연산(Erosion-Dilation), 닫힌 모폴로지 연산(Dilation - Erosion)작업을 진행함으로써 균열의 외부, 내부 노이즈를 제거한 후 이미지상의 크기가 작은 윤곽선까지 제거하여 전처리 된 이미지를 만들어 낸다.

네번째로, 노이즈 제거가 끝난 전처리 된 분할 이미지에 스켈레톤화를 적용시켜서 균열 이미지의 뼈대를 구한다. 뼈대 이미지를 기반으로 균열의 길이, 두께, 위치 등의 정보를 얻을 수 있다.

마지막으로, XAI 구현 부분에서는 스켈레톤화가 끝난 뼈대 이미지의 정보를 토대로 균열의 개수, 위치, 두께, 길이 등에 대해 계산을 진행한 후 사용자에게 제시해준다.

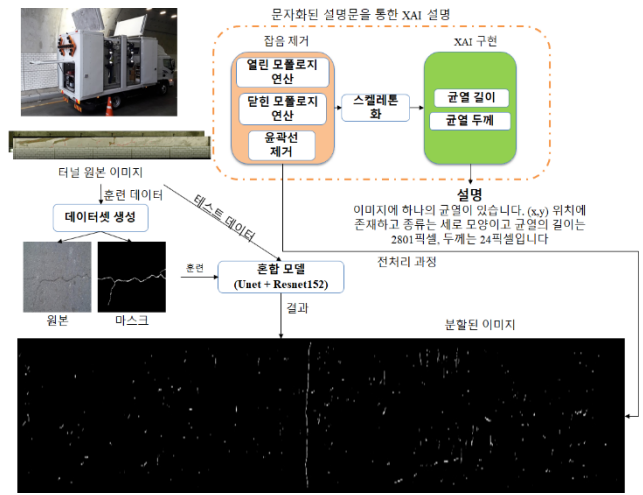


그림 1. 공공시설물 안전검사 평가시스템 구조

2.1 데이터 셋 수집 및 데이터 분류

데이터 셋은 결함 데이터가 포함된 결함 원본 이미지와 결함 원본 이미지에서 결함의 내용을 표시한 마스크 이미지 두 종류로 구성되어 있다. 모든 이미지는 사이즈가 각기 다른 원본 이미지에서 448x448 사이즈의 이미지로 나누어 생성하였으며 총 60674 개의 결함 이미지와 60674 개의 마스크 이미지를 보유하고 있다. 본 논문은 화산 터널, 덕성 터널, 감천 터널의 데이터를 기반으로 작성되었다. 이미지의 수는 각 데이터의 원본 이미지에 대해서 화산 터널의 최소 8 개부터 감천 터널의 최대 72 개로 상이하며, 원본 이미지는 파노라마 이미지이다. [표 1]은 데이터의 수집 순서, 결함 이미지, 결함 이미지에 결함의 내용을 표시한 마스크 이미지, 데이터를 수집한 장소에 대한 정보를

나타낸다.

표 1. 원본 데이터의 수와 수집 장소

데이터 수집 순서	결함이미지	마스크이미지	장소
1 번째	8	8	화산 터널
2 번째	50	50	화산 터널
3 번째	26	26	화산 터널
4 번째	50	50	덕성 터널
5 번째	37	37	덕성 터널
6 번째	33	33	덕성 터널
7 번째	30	30	덕성 터널
8 번째	40	40	감천 터널
9 번째	72	72	감천 터널
총 이미지	346	346	

2.2 UNet, Resnet 혼합모델

UNet 은 fully convolutional network 으로 불리는 모델을 확장하고 수정하여 적은 학습으로도 정확한 분할을 작동하도록 하였다. UNet 모델은 두 차례의 convolution 3x3 연산과 max pool 2x2 연산을 반복하여 적용하는 부분을 contracting path 라고 하며, up-convolution 2x2 연산과 convolution 3x3 연산을 반복하여 적용하는 부분을 expansive path 라고 한다. expansive path 부분은 특징을 살리기 위해 contracting path 부분의 특징 맵을 복사하여(copy) contracting path의 대상 특징 맵의 크기와 같은 사이즈로 잘라(crop) 데이터를 붙여 반환(concat) 한다. UNet 모델은 패치(patch)의 크기만큼 학습과 테스트를 진행한다.

Resnet 모델은 기존의 컨볼루션 뉴럴 네트워크(CNN: Convolution Neural Network)의 layer 증가에 따라 에러율(error rate)이 증가하는 현상을 skip connection 과 초반에 풀링(pooling)을 적용하여 특징 맵을 축소하는 방식을 이용하여 Resnet 의 속도를 개선하였다. 제안된 모델에서는 속도를 높이면서 층의 깊이를 적용한 Resnet152 모델을 이용하였다.

UNet 과 Resnet152 모델을 이용하여 수집된 데이터 셋을 학습한다. 제안된 모델은 [그림 3]의 UNet 구조를 기반으로 하여 Resnet152 모델을 적용하는 구조이다. 터널 결함 검출에는 속도보다 검출 정확도를 향상시키기 위해 기존에 제안된 UNet 모델보다 층이 더 깊은 Resnet152 모델을 제안하였다. Resnet152 는 [그림 2]와 같이 152 개의 레이어로 구성되어 있으며, 이를 UNet 의 contracting path 부분에 152 개의 레이어를 적용하며, expansive path 부분에서는 기존의 UNet 모델의 구조를 이용하였다.

Layer name	Output size	18-layer	34-layer	50-layer	101-layer	152-layer
Conv1	112x112	7x7, 64, stride 2				
Conv2_x	56x56	3x3 max pool, stride 2				
		$[3 \times 3, 64] \times 2$	$[3 \times 3, 64] \times 3$	$[1 \times 1, 64] \times 3$ $[3 \times 3, 128] \times 3$ $[1 \times 1, 256]$	$[1 \times 1, 64] \times 3$ $[3 \times 3, 128] \times 3$ $[1 \times 1, 256]$	$[1 \times 1, 64] \times 3$ $[3 \times 3, 128] \times 3$ $[1 \times 1, 256]$
Conv3_x	28x28	$[3 \times 3, 128] \times 2$	$[3 \times 3, 128] \times 4$	$[1 \times 1, 128] \times 4$ $[3 \times 3, 128] \times 4$ $[1 \times 1, 512]$	$[1 \times 1, 128] \times 4$ $[3 \times 3, 128] \times 4$ $[1 \times 1, 512]$	$[1 \times 1, 128] \times 8$ $[3 \times 3, 128] \times 8$ $[1 \times 1, 512]$
		$[3 \times 3, 256] \times 2$	$[3 \times 3, 256] \times 6$	$[1 \times 1, 256] \times 6$ $[3 \times 3, 256] \times 6$ $[1 \times 1, 1024]$	$[1 \times 1, 256] \times 23$ $[3 \times 3, 256] \times 23$ $[1 \times 1, 1024]$	$[1 \times 1, 256] \times 36$ $[3 \times 3, 256] \times 36$ $[1 \times 1, 1024]$
Conv4_x	14x14	$[3 \times 3, 512] \times 2$	$[3 \times 3, 512] \times 3$	$[1 \times 1, 512] \times 3$ $[3 \times 3, 512] \times 3$ $[1 \times 1, 2048]$	$[1 \times 1, 512] \times 3$ $[3 \times 3, 512] \times 3$ $[1 \times 1, 2048]$	$[1 \times 1, 512] \times 3$ $[3 \times 3, 512] \times 3$ $[1 \times 1, 2048]$
		$[3 \times 3, 512] \times 2$	$[3 \times 3, 512] \times 3$	$[1 \times 1, 512] \times 3$ $[3 \times 3, 512] \times 3$ $[1 \times 1, 2048]$	$[1 \times 1, 512] \times 3$ $[3 \times 3, 512] \times 3$ $[1 \times 1, 2048]$	$[1 \times 1, 512] \times 3$ $[3 \times 3, 512] \times 3$ $[1 \times 1, 2048]$
Conv5_x	7x7	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.6×10^9	7.6×10^9	11.3×10^9

그림 2. ResNet 모델 구조 [6]

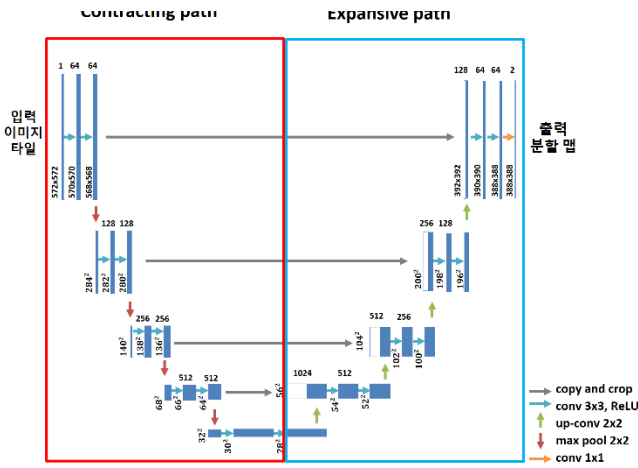


그림 3. UNet 모델 [1]

2.3 노이즈 제거

제안된 모델을 통하여 얻은 세그먼트화(segmentation) 예측 결과는 [그림 4]의 a 와 같다. 이 영상은 노이즈(Noise)들이 많이 포함되어 있어 정확한 결과를 예측하기 어렵다. 따라서 영상에 포함된 노이즈를 제거하기 위해 OpenCV 를 이용하여 이미지 형태 전환(Morphological Transformation)을 사용한다.

이미지 형태 전환은 이미지 형상에 기반하여 특정 객체의 형태를 변형시킴으로써 작은 노이즈(Noise)를 제거 혹은 미세하게 검출된 객체를 확장시켜 주는 것을 의미한다. OpenCV 를 이용한 이미지 형태 전환에는 Erosion, Dilation, Opening, Closing 연산이 있다. Erosion 은 전경(Foreground)이 되는 이미지의 경계 부분을 침식 시켜 배경(background) 이미지로 전환시키며, Dilation 은 전경이 되는 이미지의 경계 부분을 팽창시켜 보다 진한 이미지를 갖게 된다. Opening 연산은 Erosion 를 적용한 후 Dilation 을 수행하는 것을 의미하며, 주로 작은 노이즈들을 제거하는데 효과적이다. 반면, Closing 연산은 Dilation 을 적용한 후 Erosion 을 수행하는 것을 의미하며, 좁은 간격으로 떨어져있는 crack 들을 연결시키는데 효과적이다.

본 연구에서는 OpenCV 의 Opening 연산과 Closing 연산을 이용하여 다음과 같이 노이즈 제거를 진행하였다. 노이즈를 효과적으로 처리하기 위해서 OpenCV 를 기반으로 Opening 연산과 Closing 연산을 마친 후, 컨투어링(contouring) 과정을

통해 남은 노이즈를 제거했다. 먼저, 컨투어링 검출(contouring detection)로 pixel 면적이 가장 큰 컨투어링을 검출하였다. 가장 큰 컨투어링 pixel 면적을 계산한 후, 각 컨투어링의 픽셀 면적이 45%이하인 경우에는 노이즈로 간주하여 제거했다. 따라서 [그림 4]의 (a)의 원본 이미지에서 [그림 4]의 (b)와 같이 Opening 연산을 2 번 진행한 후 [그림 4]의 (c)와 같이 Closing 연산을 4 번 진행한 후 마지막으로 [그림 4]의 (d)와 같이 컨투어링 과정을 진행하여 균열이미지를 정규화 하였다.




그림 4. 노이즈 제거 과정 (a) 원본이미지, (b)Opening 연산을 2 번 진행(iteration=2)한 결과, (c) Opening 연산 후 Closing 연산을 4 번 한 결과 (d) OpenCV 연산 후 컨투어링 과정을 진행한 결과

2.4 XAI(설명가능한 인공지능)

필요에 따라 사용자에게 시스템의 개별 의사결정에 대한 설명을 제공하고, 사용자가 인공지능 시스템의 전반적인 강점 및 약점을 이해하도록 도와주는 설명가능한 인공지능 (eXplainable AI, XAI)기술이 발전하고 있다.

이 연구에서는 morphological operation 을 통해 노이즈 제거를 한 후에 픽셀 단위 균열을 단일 픽셀 너비 표현으로 변환하여 균열 토폴로지를 설명하기위해서 Skeletonizing operations 을 한다.

더이상 제거할 수 없을 때까지 각 테두리에서 픽셀을 제거하는 방법을 사용하였다. 본 연구에서는 다른 방법들보다 빠르고 작은균열에 좋은 Medial axis 가 사용되었다.

균열을 Skeletonize 를 한 후에 균열 길이는 다음과 같이 계산할 수 있다.

$$L = \int_c f(x,y)dl \cong \sum f(x,y)dl \quad (1) [5]$$

수식(1)에서 $f(x,y)$ 는 기하학적 교정 지수이고, dl 는 골격 요소의 유한길이를 나타낸다. $f(x,y)$ 검출된 이미지에서 픽셀의 변위를 교정하도록 정의된다.

한편, 균열의 평균 폭은 다음과 같이 계산할 수 있다.

$$\bar{d} = \frac{\int_s f^2(x,y)dS}{L} \cong \frac{\sum f^2(x,y)dS}{\sum f(x,y)dl} \quad (2) [5]$$

수식(2)에서 L 은 균열 길이이며, ds 는 균열 요소의 유한 영역을 나타낸다.



그림 5. 균열 정규화 후 영상

균열의 길이와 폭을 계산하면 [그림 5]와 같이 길이는 4695 pixel, 폭은 20.865942028985508 pixel로 나타난다.

3. 실험결과

본 연구는 이전에 인력을 투입하여 균열 탐지 수행 방식과 달리 혼합 모델과 XAI 모델을 이용하여 터널 안전 관리 시스템을 지능화 하였다. 터널 균열 탐지 알고리즘 개발을 위해, Unet 과 ResNet152 을 사용하였고, 높은 정확도를 위해 노이즈 제거 과정인 Morphological Transformation 을 선택하였다.

본 연구에서 핵심은 균열 부위를 정확하게 탐지하기 위해 주변의 노이즈를 제거하는 것이다. 터널 균열과 노이즈는 시각적으로 비슷하게 보이지만, 수학적인 모델링을 통하여 균열이 이어지는 부분을 탐색하여 나머지 노이즈 부분을 제거하는 Morphological Transformation 이미지 형태 전환을 이용하였다. Morphological Transformation 은 Erosion, Dilation, Opening, Closing 으로, 4 가지 기술을 적절히 적용하고 균열 부위 외의 노이즈를 제거했다.

최종적으로, 균열 위상을 설명하기 위해 XAI 의 Skeletonizing operation 을 수행했다. 결과적으로, 테스트 데이터 셋의 검출 결과는 [그림 6]과 같이 Hwasan_P01_C01_S008 데이터 셋은 Dice 계수 0.57, IoU 0.4 이며, Hwasan_P01_C01_S027 데이터 셋은 Dice 계수 0.49, IoU 0.32, Deugseong_P01_C01_S002 데이터 셋은 Dice 계수 0.45, IoU 0.29로 균열을 검출하였다.

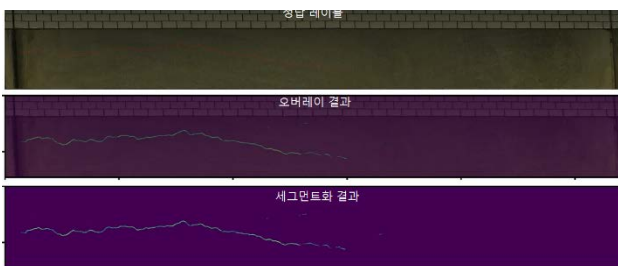


그림 6. Hwasan_P01_C01_S008 데이터 셋 검출 결과

4. 결론

본 연구를 통해 장시간 동안에 누적 발생하는 터널 균열로 인해 생기는 피해를 최소화하기 위해 딥러닝 방식인 혼합 모델과 XAI 모델을 적용하여 터널의 균열을 자동으로 검출함으로써 검사자에 의해 터널 결함을 검출한 것에 비해 객관적인 결과를 얻을 뿐만 아니라 시간과 비용을 절감할 수 있다.

향후 과제로는 XAI 에 균열의 종류를 수평 구조, 수직 구조, 거미형 구조 세 가지의 균열을 구별하는 기능으로 확장하여 사용자에게 균열에 대한 정보를 제안하는 기능을 보완할 것이다.

Acknowledgement

이 논문은 2020 년도 과학기술정보통신부의 재원으로 정보통신기획평가원(IITP)의 지원을 받아 수행된 연구임. (2020-0-00803, 대규모 딥러닝 HPC 시스템(ETRI)과 대량의 학습 없이 새로운 클래스에 적용가능한 XAI 기반의 공공시설물 안전검사 플랫폼 개발)

이 논문은 2019 년도 서울시의 재원으로 서울산업진흥원(SBA)의 지원을 받아 수행된 연구임 (CY190003, XAI 기반 결함검출 및 BIM 연동형 3D 도면생성 자동화를 통한 터널 등 공공시설물 건전도 평가시스템 실증연구)

5 참고문헌

[1] Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015.

[2] Ouadah, A. (2018, November). Pipeline Defects Risk Assessment Using Machine Learning and Analytical Hierarchy Process. In 2018 International Conference on Applied Smart Systems (ICASS) (pp. 1-6). IEEE.

[2] <https://volpato.io/blog/2019/nlp-meets-xai/>

[3] <http://kth.diva-portal.org/smash/get/diva2:1335846/FULLTEXT01.pdf>

[4] http://www.cse.ust.hk/~huamin/explainable_AI_yao.pdf

[5] Yang, Xincong, et al. "Automatic pixel-level crack detection and measurement using fully convolutional network." *Computer-Aided Civil and Infrastructure Engineering* 33.12 (2018): 1090-1109.

[6] He, Kaiming, et al. "Deep residual learning for image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.