

Deep learning을 이용하여 하수관로 CCTV 영상에서 하수관 내부 상대 고도 추출

지현욱*, 유성수*, 강정희*
*한국건설기술연구원 국토보전연구본부
e-mail:jihyonwook@kict.re.kr

Extraction of sewer pipe relative elevation from CCTV investigation video using deep learning

Hyon Wook Ji*, Sung Soo Yoo*, Jeong-Hee Kang*
*Dept. of Land, Water and Environment Research, Korea Institute of Civil Engineering and
Building

요약

하수도의 구배는 하수를 설계된 유량만큼 이송하기 위한 주요한 요인이다. 그러나 시공 후 다양한 원인에 의해 하수도 내부의 구배가 국부적으로 변화한다. 구배의 국부적 변화는 흐름의 장애를 발생시키기 때문에 조사와 적절한 정비가 필요하다. 본 연구는 하수도에서 필수적으로 요구되는 CCTV 조사 영상으로부터 내부 상대 고도를 추출하였다. 하수의 수위 변화는 고도의 변화를 간접적으로 알려준다는 원리를 이용하였다. 딥러닝의 한 종류인 convolutional neural network를 이용하여 하수의 영역을 탐지하고, 원의 기하학적 원리와 비례를 이용해서 수위가 계산되었다. 훈련의 정확도는 98%였고, 무작위 샘플링을 이용하여 비교된 수위의 정확도는 90.4%였다. 추출된 데이터 중 연결관, 이음부, 극단값이 제거되었고, smoothing method를 적용하여 데이터의 변동을 줄였다. 대상 하수관은 2.5m 단위의 콘크리트 파이프 이이기 때문에, 이를 고려하여 2.5 m 마다 이음부의 고도를 결정하여 하수관 내부 구배가 2.5m 단위의 선형 구배로 구성될 수 있도록 하였다. 본 연구에서 제시한 방법은 기존의 센서를 이용한 내부 구배 조사방법들보다 경제성이 매우 높고, 충분한 정확도를 가진 효과적인 조사 방법이다.

2. 방법론

1. 서론

하수관의 설계는 맨홀과 맨홀 사이의 구배를 결정하고 이에 따라 시공하지만, 그 사이의 내부 구배가 시공오차에 의해 불규칙하게 변화한다. 하수관 내부 구배의 변화는 우수 이송의 장애를 유발하여 역류의 원인이 되기도 한다. 다양한 연구들이 레이저, 음파, 초음파 등을 이용하여 하수관 내부의 구배를 조사하였다[1]. 이 장비들은 매우 정밀하지만 민감한 고성능 고비용 장비이고, 별도의 조사가 필요하다.

그러나 딥러닝(Deep learning)을 이용하면 이미 촬영하였던 CCTV 영상을 이용하여 내부 고도를 추출하는 것이 가능하다. 이 방법은 별도의 장비와 조사가 필요 없어 매우 경제적이라는 장점이 있다. 본 연구는 하수관의 수위를 이용하여 하수관 내부의 국부적인 처짐을 알 수 있다는 원리를 이용하여 딥러닝에 의한 이미지 분석으로 기존에 촬영하였던 CCTV 영상으로부터 하수관 내부의 고도를 정량적으로 추정하는 과정을 소개한다.

주요 분석도구는 MATLAB의 deep learning toolbox, image processing toolbox, computer vision toolbox 이다. 딥러닝은 훈련 데이터를 만드는 것으로부터 시작한다. CCTV를 프레임으로 분해하고, 전 구간으로부터 비교적 고르게 프레임들을 추출하는 것에 의하여 283개의 훈련 데이터가 선별되었다. 이 영상들은 픽셀 라벨링(Pixel labeling)에 의해 물의 영역과 파이프의 영역으로 나누어진다. 라벨링된 훈련 데이터들은 훈련 60%, 검증 20%, 테스트 20%로 사용되었다. 딥러닝에 사용된 네트워크는 사전 학습된 ResNet-18을 기반으로 DeepLab v3+를 사용하여 만들어진 Convolutional Neural Networks(CNN) 이다[2]. 훈련 이미지들은 물 영역과 파이프 영역으로 구분되는 사전훈련을 받았고, 훈련은 Epoch 30회, 총 2190번을 반복하였고, 정확도 98%에서 종료되었다.

딥러닝에 의해 CCTV 영상을 물의 영역과 파이프의 영역으로 구분하고, 이로부터 그림 1과 같이 하수 수위선을 결정하고, 임의의 원으로부터 기하학적 원리와 비례의 원리에 의해 하수 수위가 계산된다.



[그림 1] 딥러닝에 의한 하수 수위선 및 수위 추출

3. 분석 결과

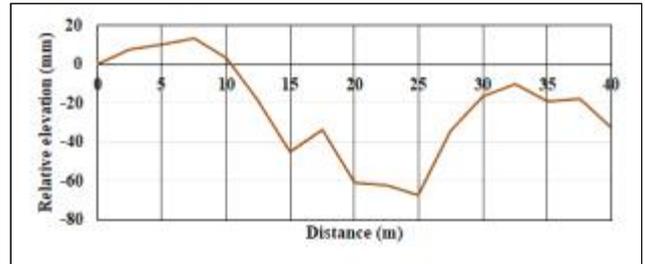
서울시의 한 하수관의 CCTV 조사 영상을 분석하였다. 이 동영상의 촬영 시간은 5분 34초, 초당 프레임은 30, 총 프레임 수는 19933, 해상도는 1280*720, 파일형식은 MP4, 용량은 263MB 이다. 이 영상 중 대략 절반에 해당하는 9467 프레임이 수위를 촬영한 프레임에 해당한다. 이 프레임으로부터 수위를 추출하고, 조사가 시작한 하수관의 수위를 기준으로 하여 상대고도를 추출하였고, 그 결과는 그림 2와 같다.

0~10 m까지는 하수관이 약간 움기하였고, 그 후로는 처졌다. 특히 15~25 m 사이가 가장 많이 처졌다. 우리나라에서 하수관의 허용시공오차는 ± 30 mm 이다. 25m 에서 최대 처짐이 67 mm 이고, 이 처짐은 허용시공오차를 2배 이상 초과한다. 이러한 내용은 CCTV 영상에서도 직관적으로 확인이 가능하다.

딥러닝을 사용한 측정의 오차율에 영향을 줄 수 있는 요인은 다양하다. CNN의 정확도, 트레이닝 횟수, 트레이닝 자료를 만드는 사람의 전문성, 영상 품질, 하수관의 상태 (부식, 파손, 김서림, 쥐, 장애물, 밝기 변화 등)가 오차율에 영향을 준다. 최근 CNN의 개발이 지속되고 있기 때문에 CNN의 정확도는 상당히 높아졌으며, 지속적으로 향상되고 있다. 트레이닝 횟수는 컴퓨터의 GPU를 변화시켜 향상시킬 수 있다. 반면 분석자의 전문성이나 영상 품질은 해결이 어렵다. 트레이닝 이미지의 수가 늘어날수록 분석자의 피로도가 높아지고, 정밀성이 낮아지기 때문이다. 영상 품질은 각 조사 업체가 각 지자체에서 규정된 만큼의 품질만 제공하기 때문에 변화를 주기 힘들다. 하수관의 복잡한 상태는 역시 컨트롤할 수 없는 요인이다.

반면 deep learning을 이용한 방법론은 다양한 장점을 가지고 있다. 정밀 센서와 조사 시간, 현장 작업이 필요 없다. 일반적으로 CCTV 영상은 조사 직후 최초 1회만 보고 그 후에는 방치되지만, 본 연구에 의해 CCTV 영상으로부터 정량적 데

이터를 추출하기 위해 재사용 될 수 있다. CCTV 영상의 효용가치가 상승하는 것이다. 기존의 CCTV 영상을 요약한 조사 보고서는 관의 침하와 단차 등의 내용을 포함하고 있지만 다양한 정보를 정성적으로 나열하고 있어서 보기 힘들다. 본 연구의 방법론은 관의 구배를 그래프로 표현할 수 있어 가독성이 뛰어나다.



[그림 2] 하수관의 상대 고도

4. 결론

하수관 내부 고도의 상대적 변화는 논리적이고 수학적 방법에 의해 도출되었지만, 실제 데이터와 비교하지 못하였다. 실제 데이터란 실제 하수관 내부의 고도를 의미한다. 하지만 직접 측정할 수 없기 때문에 결국 센서 장비에 의한 측정과 비교해야 한다. 향후 센서와 딥러닝에 의한 결과들을 비교한다면 정확도 향상에 도움이 될 것이다.

본 연구는 악취, 퇴적, 침수의 예방, 원인 분석 하수관 정비에 사용될 수 있다. 모든 하수관은 최소 1번은 CCTV 조사를 반드시 받기 때문에 관리 당사자는 조사 영상을 가지고 있다. 해당 지역 하수관의 CCTV 조사 영상을 이용해서 먼저 구배를 조사 한다면, 그 중 특히 유의해야 할 하수관을 선별할 수 있어 효과적으로 하수관을 정비할 수 있다. 뿐만 아니라 고도 변화를 이용해서 준설량을 예측하고 준설의 경제성을 높이는 것도 가능하다. 이를 통해서 정성적인 조사방법이라 평가되는 CCTV 조사의 가치를 재고할 수 있다.

사사

본 연구는 과학기술정보통신부의 연구과제인 “링크구조를 활용한 고정밀 연성관 종합상태평가시스템 개발 및 실용화(과제번호: 20210108)”의 지원을 받았습니다.

참고문헌

- [1] Gunatilake, A., Piyathilaka, L., Kodagoda, S., Barclay, S., & Vitanage, D., “Real-time 3d profiling with rgb-d mapping in pipelines using stereo camera vision and structured ir laser ring”, In 2019 14th IEEE Conference

on Industrial Electronics and Applications (ICIEA), pp. 916-921, June, 2019.

- [2] Mathworks, Available online: <https://kr.mathworks.com/help/deeplearning/ref/resnet18.html#d120e51193> (accessed on 8 April 2020).