

무인이동체와 딥러닝 기반 이미지 분석 기술을 활용한 철도교량 자동 손상 분석 방법 연구

A Study of Railway Bridge Automatic Damage Analysis Method Using Unmanned Aerial Vehicle and Deep Learning-based Image Analysis Technology

나용현^{1*} · 박미연²

Yong Hyoun Na^{1*}, Mi Yeon Park²

¹Chief Researcher, SH Tech & Policy Institute Co., Yongin, Republic of Korea

²PH.D, SH Tech & Policy Institute Co., Yangpyeong, Republic of Korea

*Corresponding author: Yong Hyoun Na, thered1004@hotmail.com

ABSTRACT

Purpose: In this study, various methods of deep learning-based automatic damage analysis technology were reviewed based on images taken through Unmanned Aerial Vehicle to more efficiently and reliably inspect the exterior inspection and inspection of railway bridges using Unmanned Aerial Vehicle. **Method:** A deep learning analysis model was created by defining damage items based on the acquired images and extracting deep learning data. In addition, the model that learned the damage images for cracks, concrete and paint scaling-spalling, leakage, and Reinforcement exposure among damage of railway bridges was applied and tested with the results of automatic damage analysis. **Result:** As a result of the analysis, a method with an average detection recall of 95% or more was confirmed. This analysis technology enables more objective and accurate damage detection compared to the existing visual inspection results. **Conclusion:** through the developed technology in this study, it is expected that it will be possible to analysis more accurate results, shorter time and reduce costs by using the automatic damage analysis technology using Unmanned Aerial Vehicle in railway maintenance.

Keywords: Unmanned Aerial Vehicle, Automatic Damage Analysis, Railway Bridge, Deep learning, Maintenance

요약

연구목적: 본 연구에서는 무인이동체를 활용한 철도교량의 외관조사 점검을 보다 효율적이고 신뢰성 있게 점검을 위하여 무인이동체를 통해 촬영된 이미지를 바탕으로 다양한 방식의 딥러닝 기반 자동 손상 분석기술을 검토하였다. **연구방법:** 취득된 이미지를 바탕으로 손상항목을 정의하고 학습데이터로 추출하여 딥러닝 분석 모델을 생성하였다. 그리고 철도교량의 외관 손상 중 균열, 콘크리트 박리·박락, 누수, 철근노출에 대한 손상 이미지를 학습한 모델을 적용하여 자동 손상 분석 결과로 테스트하였다. **연구결과:** 분석 결과 평균 95%이상 검출 재현율을 도출하는 분석 기법을 검토할 수 있었다. 이와 같은 분석 기술은 기존 육안점검 결과 대비 보다 객관적이고 정밀한 손상 검출이 가능하다. **결론:** 본 연구를 통해 개발된 기술을 통해 철도 유지관리 분야에서 무인이동체를 활용한 정기점검 시 자동손상분석을 통한 객관적인 결과도출과 기존 대비 소요시간, 비용저감이 가능할 것으로 기대된다.

핵심용어: 무인이동체, 자동손상분석, 철도교량, 딥러닝, 유지관리

Received | 2 August, 2021

Revised | 27 August, 2021

Accepted | 8 September, 2021

 OPEN ACCESS



This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted noncommercial use, distribution, and reproduction in anymedium, provided the original work is properly cited.

© Society of Disaster Information All rights reserved.

서론

국내 철도시설물에 대한 유지관리는 관리대상시설의 지속적인 증가와 담당인력 감소에 따른 추세로 체계적인 유지관리가 어려운 실정이다. 특히 접근이 취약한 철도시설인 철도교량의 경우 철도의 주요 토목구조물로서 체계적인 관리가 더욱 필요하다. 기존 철도 유지관리 체계는 인력점검 중심 관리로써 철도교량의 경우 시설물의 안전 및 유지관리에 관한 특별법에 따라 반기 1회 이상의 정기 점검을 수행하고 있으며 구조물의 외관조사를 통한 육안 점검을 기본으로 수행하고 있다. 그러나 이러한 육안점검은 구조물 외관의 손상에 대한 점검시 접근이 취약한 환경적 조건으로 사다리차, 굴절스카이 등의 별도의 조장비를 운용함에 따라 조사시간과 비용적 손실이 많은 실정이다. 구조물의 효율적인 점검과 유지관리를 위하여 다양한 연구가 진행중에 있으며 특히 무인이동체를 통한 교량 및 콘크리트 구조물의 결함점검 연구는 국내외에서 활발하게 이루어지고 있다.

Lovelace et al.(2015)은 무인이동체를 교량의 외관 점검에 사용한 연구로 적외선 및 일반 카메라로 촬영한 영상을 통해 교량의 외관 결함 이미지를 취득하여 육안 점검에 활용하였다. Chanda et al.(2014)는 교량의 균열을 식별하고 교량 상태를 검사하는데 있어 Support Vector Machines와 함께 웨이블릿 기반 이미지 기능을 활용하는 자동 교량 검사 접근 방식을 제안하였으며 Irizarry et al.(2012)는 안전점검 도구로서의 드론 기술 활용성 평가를 통해 건설 현장에서 관리자에게 안전을 확인하기 위한 도구로 무인이동체를 사용하기 위한 자율 탐색, 음성 상호 작용, 고해상도 카메라 및 협업 사용자 인터페이스 환경 등을 제안하였다. De Melo et al.(2017)는 안전점검을 위한 무인항공기(UAS) 적용 가능성 검토를 통해 안전 관리에 UAS 시각적 정보를 통한 안전 요구 사항을 수집, 처리 및 분석하기 위한 일련의 절차 및 지침을 개발하였다. Chan et al.(2015)은 교량 상태점검을 위해 무인이동체로 교량 하부를 촬영하고 SLAM(Simultaneous Localization and Mapping)기술을 통해 교량을 검사하고 정보를 시각화하는 연구를 수행하였다. Abdel-Qader et al.(2003)는 교량의 균열 및 열화를 감지에 Fast Haar Transform (FHT), Fast Fourier Transform, Sobel와 Canny기법에 대한 균열 감지 기술의 효율성을 비교를 통해 교량에 대한 안전 모니터링과 유지보수를 위한 자동화 프로세스 방안을 제안하였다. 그밖에도 Lee et al.(2011)와 Miyamoto et al.(2007)는 원격 제어 로봇 및 이미지 처리 기술을 사용한 지능형 교량 검사와 이미지 처리 방식을 사용한 콘크리트 구조물의 자동 균열 인식 시스템 제안을 통해 교량과 콘크리트 구조물에 대한 점검기술 연구를 수행하였다.

본 연구에서는 무인이동체를 활용한 철도교량의 외관조사 점검을 보다 효율적이고 신뢰성있는 점검을 위하여 촬영된 이미지에서의 손상점검을 자동화하기 위한 손상 분석기술을 개발하였다. Jahanshahi et al.(2009)는 디지털 이미지 처리와 같은 비파괴 평가 기술에 대하여 연구된 유용하고 실용적인 분석 기술에 관련된 연구들을 검토 및 평가하여 제시하였다. 기존 이미지분석을 활용한 점검 기술은 Lee et al.(2012)의 연구에서처럼 주로 균열의 존재 유·무와 폭 등을 분석하는 것이었으나, 본 연구에서는 라인형태의 균열 뿐만 아니라 면적을 가지는 손상인 콘크리트 박리 박락, 철근노출, 누수 등과 같이 다양한 손상 항목을 딥러닝 기반 이미지 분석기술을 통해 분류 및 분석할 수 있는 프로그램을 개발하고, 이를 통해 단순 육안점검이 아닌 손상 종류, 정량적인 손상항목별 물량을 산출할 수 있는 정보를 제공하는 기술을 개발하였다.






또한 Na et al.(2018)는 철도 시설물에 대한 결함 탐지 기술로 라인 스캔 카메라를 탑재한 검측열차를 통해 철도 콘크리트 도상의 이미지를 취득하고 패턴인식 및 머신러닝 기법을 통해 자동 균열 검출에 대한 연구를 수행하였다. 또한 Amhaz et al.(2016)와 Gavilán et al.(2011)는 도로분야에서 이미지 프로세싱 기술을 사용한 자동 균열 검출 알고리즘을 제안하였다. 균열의 기하학적 특성을 고려하여 기존 알고리즘 기법들과 비교 검증을 수행한 연구로 다양한 이미지 분석 기술에 대한 검토

를 통해 취득된 이미지의 특성과 조건에 따라 최적의 분석 기법을 연구하였다. 이미지 기반 균열 검출 기술에 관하여 도로 분야에서는 이밖에도 Chambon et al.(2011)과 Kaseko et al.(1993)의 연구를 통해 기존 패턴인식 기술 보다 발전한 인공 신경망 기술을 적용을 통해 학습을 통한 분석 기법에 관한 연구를 수행하였다. 철도 콘크리트 침묵에 대한 연구로써 Kim et al.(2017)은 적응성(adaptive)을 갖는 기법으로 활용 범위를 넓히고 있는 Adaboost를 이용하여 고해상도카메라로 촬영한 침묵이미지에서 균열을 자동검출할 수 있는 알고리즘을 개발하였다.

최근 이러한 철도시설의 유지관리를 목적으로 관련기관에서 효율적인 관리를 위해 무인이동체의 활용을 시범운영과 적용성 검토를 통해 도입을 추진하여 철도 시설물의 외관 영상을 획득하는 용도로 사용중에 있다. 이러한 관리는 기존의 인력 점검 대비 구조물 외관에 대한 점검시간의 단축 효과를 볼 수 있었으나 안전성 검토를 위해서는 시설물 손상을 다시 인력을 통한 육안확인과정의 별도도 수행되고 있다. 이러한 무인이동체를 활용한 점검에서 단순 외관 촬영에 그치지 않고 취득된 이미지를 통해 손상을 검출하기 위한 분석으로 기존 구조물 외관 안전점검의 한계인 인력중심적, 접근한계에 따른 문제를 극복할 수 있다. 또한, 외관 이미지를 취득 후 소요되는 막대한 인력과 시간, 비용을 절감하여 효과적인 유지관리 체계를 개발하는데 핵심 기술로 활용될 수 있다. 무인이동체를 활용한 철도 시설물 점검을 위해서는 철도 운용환경에 적합한 무인이동체 제어시스템과 운용 자동화 시스템이 가능해야 하며, 기존 무인이동체의 GPS에 의존한 음영구역에서의 부정확성, 취득된 이미지를 통한 손상항목 검출 및 분석의 자동화 등 실용적이고 효율성 있는 점검을 위해서 필요한 기술이 고려되어야 한다.

본 연구에서는 접근취약 시설중에 하나인 철도교량의 외관 손상중 딥러닝 기반 이미지 분석 기술을 통해 학습분석할 손상항목의 정의가 필요하다. 먼저 무인이동체 운용을 통해 수집가능한 손상항목을 Table 1과 같이 손상의 종류와 유형별 이미지를 정의하였다.

Table 1. Railroad bridge damage items and type

Items	Crack	Concrete Scaling/Spalling	Reinforcement Exposure	Leak	Paint Scaling/Spalling
Damage Type Image Sample					

본론

철도 교량 외관 손상 이미지 수집

철도교량 외관 이미지 취득용 무인이동체 검토

무인이동체로도 불리는 드론은 크게 고정익과 회전익으로 분류된다. 고정익 형태의 드론은 상대적으로 장시간 운용이 가능하고 진동이 적으나 높은 고도에서 운용되기 때문에 항공촬영과 같이 지형지물이나 구조물의 상부를 촬영하기 적합하다. 본 연구에서 선정한 대상인 철도교량의 외관 취득 대상은 교대, 교각, 슬래브 측면 및 하부 등으로 고정익보다는 회전익 형태의 드론이 좁은 공간에서도 수직 이착륙이 가능하고 구조물 촬영 시 근접한 거리에서 이미지를 획득할 수 있어 보다 정밀한

손상을 분석하기 위한 이미지 획득이 가능한 이점을 가지고 있다. 또한 취득 이미지를 통한 손상 분석 기술의 경우 이미지의 품질에 따라 분석 성능이 좌우되기 때문에 무인이동체의 호버링(hovering), 자세제어 기능과 짐벌(gimbal)을 활용한 모듈에 장착하여 진동을 저감하여 촬영을 수행하게 된다. 본 연구에서는 철도 운영환경 조건으로 풍속 저항도가 높고 고해상도 이미지 촬영을 위한 카메라를 탑재 가능한 유효탑재하중을 가지는 드론으로 선정하는 것이 필요하여 산업용 드론중에 하나인 D사의 M-600모델을 사용하였다.

이미지 취득 장비 선정 및 촬영 조건

본 연구에서 목표하는 손상 항목중 크기가 가장 작은 손상인 균열을 검출하기 위해서는 드론에 탑재되는 임무장비인 카메라를 고사양으로 선정할 필요가 있다. 또한 드론 운용 제어중 고해상도 카메라의 초점 및 촬영을 하기 위하여 기능 동기화된 드론을 통해 외관 이미지를 취득하였다.

Table 2와 같이 본 연구에 탑재된 카메라는 S사의 A7R2모델로 42.4MP의 7,952×5,304 pixel의 고해상도로 촬영이 가능한 장비이다. 촬영된 이미지는 카메라의 이미지센서크기, 초점거리, 피사체까지의 거리 등을 바탕으로 GSD가 산출된다. 즉 피사체인 철도교량의 표면과의 거리에 따라 취득된 이미지의 픽셀 중심간 거리로 1개의 픽셀이 나타내는 x,y의 실제크기로 정의될 수 있다. 따라서 취득하고자 하는 대상의 크기가 이하의 GSD값을 가지는 조건에서의 촬영이 필요하다. 선정된 카메라를 기준으로 철도교량의 표면과 4m 이격된 거리에서 촬영 시 유효픽셀 크기인 GSD는 0.277mm로 손상항목중 하나인 균열의 경우 0.3 mm폭의 균열까지 육안확인이 가능한 해상력으로 촬영이 가능하다.

Table 2. Specifications of UAV and camera devices

	Items	Description
UAV	Hovering Accuracy (P-GPS)	Vertical: ±0.5 m, Horizontal: ±1.5 m
	Max Wind Resistance	8 m/s
	Weight	9.5 kg
Camera	Image Sensor	35mm Full frame
	Number of Pixels(Effective)	42.4MP(7952×5304)

철도교량 외관 이미지 취득 대상 선정 및 손상 이미지 수집

철도교량의 손상을 자동 검출하기 위한 기술을 개발하기 위해서는 지도학습을 통해 손상을 학습시켜 분석을 수행하여야 하기 때문에 상대적으로 손상이 많은 C등급 이하의 시설물을 대상으로 이미지 촬영을 수행하였다. 시설물 안전관리에 관한 특별법에 따라 C등급 이하 시설물은 정밀점검은 2년에 1회 이상, 정밀안전진단은 5년에 1회 이상 점검을 수행하고 있으며 정기점검의 경우에는 반기에 1회 이상 점검을 수행하고 있다. 이와 같은 시설물에서 외관에 대한 육안 점검을 수행하는 항목으로는 균열, 콘크리트 박리/박락, 철근노출, 누수, 백태 등이 있으며 통상적으로 균열의 경우 0.3mm 이상 ~ 0.5mm 미만의 균열이 10% 미만이며 균열외 손상들의 경우 표면 손상면적 2%~10% 미만일 경우 C 등급에 해당하는 것으로 평가되고 있다. 철도교량에서 촬영된 철도교량은 총 17개로 약 14,155장의 이미지를 수집하였으며 다양하고 복합적인 손상을 포함하는 이미지를 취득할 수 있었다. Table 3와 같이 취득 이미지 데이터 중 손상 항목별 수량을 나타내고 있으며 상대적으로 균열, 콘크리트

및 페인트 박리·박락 대비 누수 및 철근노출의 빈도는 낮은 것을 확인할 수 있다. 딥러닝 분석 기술의 특성상 학습 대상의 수량이 많을수록 분류 검출 정확도가 높아지지만 철도교량의 유지관리 주체인 한국철도공사에서 시설 안전을 위해 지속적으로 유지관리를 해오고 있기 때문에 발생한 손상에 대해서는 주기적인 보수보강이 이루어져 충분한 수량의 손상 데이터를 수집하기는 어려운 실정이다. 따라서 본 연구에서는 위와 같은 과정을 통해 직접 취득된 손상 이미지와 그밖에 다양한 콘크리트 구조물에서 발생하는 손상에 대한 이미지 데이터를 확보하여 딥러닝 학습모델 개발에 적용하였다. 이와 같은 과정을 통해 수집된 데이터는 손상항목별로 총 26,476개의 데이터를 수집하였으며 이를 연구에 사용하였다.

Table 3. Acquired image data for each damaged

Items	Crack	Concrete Scaling/Spalling	Reinforcement Exposure	Leak	Paint Scaling/Spalling
Existent Image Data	17,361	482	528	268	446
Additional Images Data	5,304	574	19	79	1,415
Total	22,665	1,056	547	347	1,861

딥러닝 기반 이미지 분석 기술

기존 이미지 프로세싱 기법의 경우 패턴인식, 엣지검출 등의 방식은 콘크리트 구조물의 표면 오염 및 비손상 특징을 오감지하는 문제들을 가지고 있다. 특히 이러한 기법들은 다양한 분야의 연구 및 논문에서 지속적으로 검토되어 왔으나 이미지의 품질과 유형에 따라 분석에 사용되는 변수를 조절해주어야 하는 단점이 있었다. 본 연구에서는 이러한 문제를 해결하기 위해 딥러닝 기반 학습을 통한 분석 기술을 적용하여 별도의 변수 설정 없이 다양한 조건에서의 유형별 손상을 학습한 분석 모델을 기반으로 손상을 검출하는 기술을 적용하여 검토하였다. Giakoumis et al.(2005)는 디지털화 된 이미지의 균열을 감지하고 노이즈 등을 제거하기 위한 방법으로 형태학적 변환, 색조 및 채도 데이터에 대한 방법 등을 연구하였으며 본 연구에서 역시 전처리 과정이 필요하다. 이미지 분석 기술은 Fig.1과 같은 프로세스를 통해 손상을 분석 검출할 수 있다. 먼저 다양한 환경적 조건에 따라 취득된 이미지에서 손상을 강조하고 분석 품질을 향상시키기 위한 전처리 작업을 수행한다. 이후 이미지상에서의 손상을 직접 영역을 추출하는 특징점 추출 작업을 수행한다. 손상별로 추출된 특징점 추출 데이터는 딥러닝 학습 알고리즘을 통해 각각 지도학습을 수행하게 된다. 학습을 통해 생성된 분석 모델을 통해 손상을 검출하고 검출된 손상의 크기 및 상대적 좌표 정보 등을 산출결과물로 분석한다.




Fig. 1. Deep learning image analysis process

취득 이미지 전처리 및 특징점 추출

실외에서 충분한 조명과 초점 조절 어려운 상황에서는 고정식 거치대를 통해 취득한 영상 대비 상대적으로 조도 및 명암, 노이즈 등에 취약한 문제들이 야기 될 수 있다. 따라서, 철도교량 외관을 촬영한 무인이동체에 탑재된 카메라의 이미지를 바

탕으로 손상 분석 성능을 향상시킬 수 있는 다양한 이미지 필터 알고리즘을 적용하여 품질 향상 프로세스를 적용할 필요가 있다. 따라서, 분석 성능을 확보하기 위해서 손상을 강조하고 이미지 품질 향상을 위한 알고리즘을 적용한 전처리 프로세스를 개발하였다. 일반적인 절차를 통해 이미지 데이터를 이진화 및 정규화하여 이미지상의 손상을 강조하고 딥러닝에 필요한 데이터를 최적 품질로 학습 및 분석할 수 있는 이미지 필터링 작업을 선행하였다.

본 연구에서의 취득 이미지에 적용한 필터는 Flip(Vertical, Horizontal), Sharpening, Blurring, Adaptive Threshold, Hue Saturation Value 기법을 적용하였다. 이와 같은 전처리 작업 후 자동 손상 분석을 수행하기 위해서 기존의 취득된 이미지로부터 각각의 손상항목을 직접 추출하여 학습 데이터를 생성해 주게 된다.

딥러닝 기반 분석 기술 검토

본 연구에서는 딥러닝 영상 분석에 대표적으로 사용되는 인공신경망 기법인 Light Head-RCNN과 FPN, PSPNet 그리고 U-Net 알고리즘에 대한 연구를 수행하였다. 각각의 알고리즘은 두 가지 방식으로 분석 방법이 나뉘는데 Fig. 2와 같이 LH-RCNN 기법은 탐지(Detection) 방식으로 학습된 손상 데이터를 바탕으로 이미지상에서의 손상을 박스 형태로 검출하는 기술로써 예를 들어 균열의 경우 균열을 포함하는 범위를 박스 영역으로 검출하게 되고 이후에 손상의 정확한 영역 분석을 위해서는 추가 분석이 필요한 기술이다. Lu et al.(2019)은 Faster-RCNN과 R-FCN의 RoI기반 분석 기술을 보다 빠르고 정확한 분석을 위해 새로운 형태의 Two-stage 탐지 방식을 제안하였다. 기존 RCNN의 분석 성능은 유지하면서 ResNet-101기반으로 분석 속도를 크게 향상시키는 연구를 수행하였다.




Fig. 2. Concepts by deep learning algorithms by detection type of light Head-RCNN

탐지(Detection) 방식의 분석과 비교할 기법은 분할(Segmentation)방식으로 해당 기술은 픽셀을 기준으로 분석하는 방식으로 로컬 기반으로 라벨링된 손상 데이터를 라벨 기반으로 추측하는 기술이다. Fig.3(a)와 같이 FPN(Feature Pyramid Network)기법은 각각의 단계마다 다른 특징을 추출하게 되는데 FPN은 여러 해상도를 가지는 특징들 전부를 예측에 활용함으로써 정확도를 높인 기술이다. 즉 한 장의 이미지상에서 다양한 해상도와 크기의 학습 데이터로 손상을 검출하기 위해 학습 이미지 자체의 크기를 리사이즈 하여 분석한다.

다음으로 검토된 알고리즘은 PSPNet 기법으로 Fig.3(b)와 같이 이미지를 입력하여 특징점 지도(Feature Map)을 생성한 후 특징점 지도(Feature Map)상에서 특징별로 Global Pooling하게 되는데 Global Pooling이란 Feature Map의 한 채널의 값

들의 평균(또는 최대값)을 구하는 방식이다. 이어서 특징 각각을 분석 한 다음 손상을 추론하는 방식이다.

마지막으로 검토할 알고리즘은 UNet 기법으로 의학 분야에서 이미지 분할을 목적으로 제안된 End-to-End 방식의 Fully-Convolutional Network 기반 모델이다. Long et al.(2015)는 Contemporary Classification Networks(AlexNet, VGG net 및 GoogLeNet)를 Fully-Convolutional Network에 적용하고 세분화 작업을 통해 세밀한 수준의 학습된 결과를 도출하는 기술을 연구하였다. Ronneberger et al.(2015)의 연구에서 U-Net 기술에 대한 설명을 보면 알고리즘의 구성의 형태가 'U'와 유사하여 UNet으로 불리며 다음 그림과 같은 구성을 가지고 있다. Fig.3(c)와 같이 해당 기법은 이미지의 전반적인 컨텍스트 정보를 얻기 위한 Network와 정확한 지역화(Localization)를 위한 네트워크가 대칭 형태로 구성되어 있다. 좌측에 위치한 Network는 Contracting Path로 입력 이미지의 Context 검출을 목적으로 구성되었으며 FCNs와 같이 VGG기반 아키텍처이다. 우측에 위치한 Network는 Expanding Path는 세밀한 Localization을 위한 구성으로 높은 차원을 갖는 Up-sampling에 Thin Layer의 Feature Map을 결합한 구성으로 이루어져 있다.

본 연구과제에서 검토된 알고리즘은 앞서 설명한 개념으로 분석되는 딥러닝 기술로 과거 다양한 분야에서 검증된 알고리즘부터 최신 연구 동향에 따라 상대적으로 손상 데이터 확보가 어려운 시설물 손상진단 분야에 적용하여 손상진단 자동화 프로세스를 구축하였다.

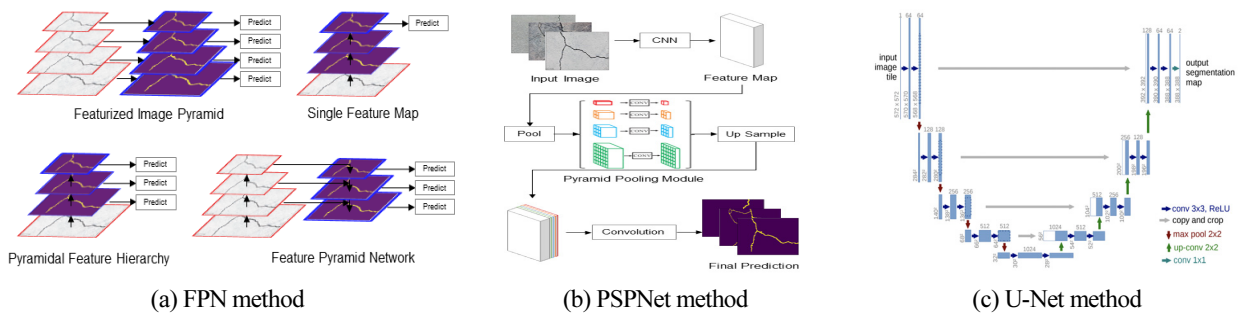


Fig. 3. Concepts by deep learning algorithms by segmentation type

시험 및 검증

시험 방법

본 연구에서 개발된 딥러닝 기반 분석 기술에 대해 간단하게 정리하면 여러 비선형 변환기법의 조합을 통해 높은 수준의 추상화(abstractions, 다량의 복잡한 데이터나 자료들 속에서 핵심적인 내용 또는 기능을 요약하는 작업)를 시도하는 것으로 기존의 기계학습(machine learning)에서 사용되는 layer 수가 증가한 형태의 기술이다. 선행된 연구과제에서는 주로 CNN (Convolutional neural network) 합성 신경망을 활용하여 구조물의 손상을 분석하는 연구가 진행되었으며 최근까지 보고된 연구동향에서는 LH-RCNN 한 연구가 활발하게 진행중이다. 이와 같이 본 연구에서는 다양한 논문과 연구분야에서 성능을 인정받고 있는 LH-RCNN을 통한 탐지(Detection)기술과 손상을 보다 세밀하게 분석하는 분할(Segmentation)기법인 FPN과 PSPNet 그리고 U-Net 기법에 대해 분석성능을 검토하였다. 제안된 기술에 대하여 분석 성능을 확인하고 검토하기 위하여 Fig. 4와 같이 모델 학습(Model Train) 단계와 모델 검증(Model Validation) 단계로 구분되어 있는데 현재 보유하고 있는 이미지 데이터의 80%의 손상 데이터는 GT(Ground Truth) 데이터를 생성하는데 사용하고 나머지 20%의 이미지 데이터는

학습된 모델로 분석하였을 때 결과를 바탕으로 분석성능을 검토하였다.

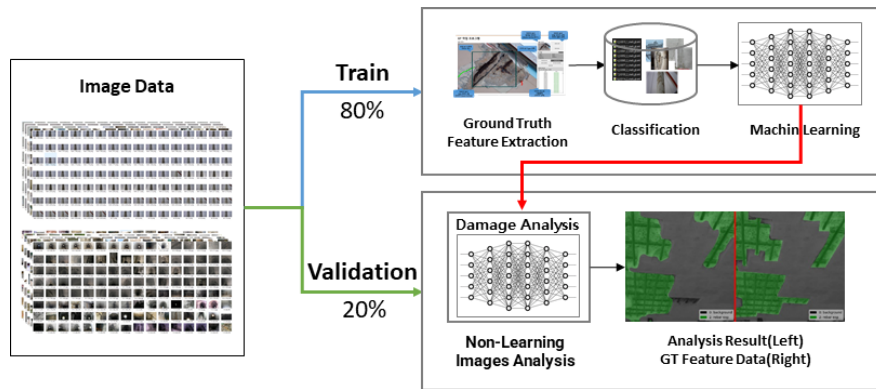


Fig. 4. Deep learning image analysis recall verification

검증 방법

본 연구에서 제안된 딥러닝 기반 손상 분석 기법들로 생성된 모델을 바탕으로 학습되지 않은 손상 이미지에서 얼마나 정확하게 손상을 검출할 수 있는지를 검토함으로써 제안된 프로세스의 성능을 검증하고 본 연구에서 목표하고 있는 대상 구조물의 손상진단에 적합한 프로세스를 검증하였다. Fig. 5와 같은 프로세스로 검증을 수행하였으며 무작위로 선정된 20%의 이미지에 대한 손상 분석 결과와 점검자가 추출한 손상과 일치하는지를 비교하였다.

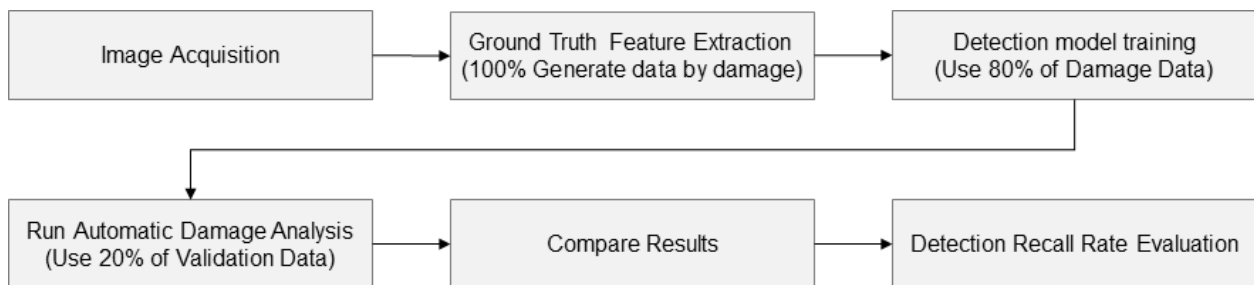


Fig. 5. Process of detecting recall rate evaluation

본 논문에서 제안한 딥러닝 기반 자동 손상 분석 기술에 적합한 기술을 검증하기 위하여 혼동행렬(Confusion Matrix)를 구하여 검토하였다. 혼동행렬이란 특정 분류 모델의 성능을 평가하는 지표로서, 참값과 모델이 예측한 결과를 배열한 행렬로써 손상항목별로 정의한 참값과 분석을 통해 검출된 손상을 비교하여 손상이 존재하는 이미지에서 정의한 손상을 검출할 경우와 미탐지한 경우, 균열이 없는 외관에서 오탐지한 경우를 참과 거짓에 따라 분류 하였다. Table 4와 같이 혼동행렬을 정의할 수 있으며 네 가지 요소로 구성되어 있다.

- (1) True Positive(TP): 실제 값이 참이고 모델의 예측 값도 참인 경우.

- (2) True Negative(TN): 실제 값도 거짓이고 모델의 예측 값도 거짓인 경우.
- (3) False Positive (FP): 실제 값은 거짓이나 모델의 예측 값이 참인 경우.
- (4) False Negative(FN): 실제 값은 참이나 모델의 예측 값이 거짓인 경우.

Table 4. Definition of confusion matrix

Confusion Matrix	Prediction	
	True	False
Actual	True TP(True Positive)	False FN(False Negative)
	False FP(False Positive)	TN(True Negative)

검증 결과

본 연구에서 수집된 총 26,476개의 손상 이미지 데이터중 20%에 해당하는 5,295개에 대하여 손상 검출 분석을 수행하였다. 각 손상항목별로 분석을 수행한 결과 검출재현율(Recall)은 식 (1)과 같이 확인될 수 있으며 오류율과 탐지율은 각각 식 (2)와 (3)으로 검토하였다. 각각 식을 통해 계산된 손상항목별 검출재현율 및 오류율, 탐지율은 Table 5와 같다.

$$Recall = \frac{TP}{TP + FN} \tag{1}$$

$$Error = \frac{FP + FN}{TP + FP + FN + TN} \tag{2}$$

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \tag{3}$$

Table 5. Analysis results for each damage

Items		Crack	Concrete Scaling/Spalling	Reinforcement Exposure	Leak	Paint Scaling/Spalling
Detection Method (LH-RCNN)	Recall	0.2325	0.1693	0.1306	0.1346	0.3350
	Error	0.5776	0.7438	0.7080	0.7376	0.4308
	Accuracy	0.4224	0.2562	0.2920	0.2624	0.5692
Segmentation Method (FPN)	Recall	0.8936	0.8853	0.8967	0.8570	0.9022
	Error	0.0991	0.1091	0.1125	0.1408	0.1008
	Accuracy	0.9009	0.8909	0.8875	0.8592	0.8992
Segmentation Method (PSPNet)	Recall	0.9074	0.8923	0.8155	0.8104	0.9559
	Error	0.0879	0.0983	0.1908	0.1863	0.0446
	Accuracy	0.9122	0.9017	0.8092	0.8137	0.9555
Segmentation Method (U-Net)	Recall	0.9601	0.9818	0.9458	0.9247	0.9479
	Error	0.0371	0.0208	0.0495	0.0712	0.0497
	Accuracy	0.9629	0.9792	0.9505	0.9288	0.9503

본 연구를 통해 검토된 딥러닝 분석 기법들은 Table 5와 같이 손상항목별 재현율 및 오류율, 탐지율을 비교하였다. 비교결과 탐지(Detection) 방식의 분석보다 분할(Segmentation)방식이 손상을 검출하는데 우수한 성능을 보이는 것을 확인할 수 있었으며, 수집된 손상 이미지가 상대적으로 적은 누수의 경우 전체적으로 낮은 재현율을 가지는 것을 확인할 수 있었다.



Fig. 6. Analysis result graph by deep learning analysis method.

Fig.6과 같이 본 논문을 통해 제안된 딥러닝 분석 기법에 따른 검출재현율을 비교한 결과 분할(Segmentation) 방식의 U-Net 기법이 균열에서는 96%, 콘크리트 박리·박락에서는 98%, 철근노출은 94%, 누수는 92%, 페인트 박리·박락은 94%로 각각 확인되었다. 분할(Segmentation) 방식의 다른 기법들도 대부분 준수한 분석 성능을 가지는 것으로 검토되었으나 상대적으로 우수한 성능의 U-Net기법을 적용한 기술을 제안하고자 한다. 해당 기법을 적용한 자동 손상 분석 소프트웨어 개발을 통해 국내 철도교량 중 테스트 베드를 선정하여 현장 적용 테스트를 수행하였으며 대표적인 분석 결과는 Fig.7과 같다.



Fig. 7. Automatic damage analysis results in railway bridge testbed

결론

국내 철도시설물에 대한 유지관리는 관리대상시설의 지속적인 증가와 담당인력 감소에 따른 추세로 체계적인 유지관리

가 어려운 실정이다. 특히, 다양한 자연재해 및 구조물 노후화에 따라 철저한 관리가 필요한 시설이 대부분으로 관리 미흡으로 인한 재난의 방지가 중요하다. 또한, 접근이 취약한 철도시설인 철도교량의 경우 철도의 주요 토목구조물로서 체계적인 관리가 더욱더 필요하다. 구조물의 외관조사는 육안 점검을 기본으로 수행하고 있다. 그러나 이러한 육안점검은 구조물 외관의 손상에 대한 점검 시 접근이 취약한 환경적 조건으로 별도의 조사장비를 운용함에 따라 조사시간과 비용적 손실이 많은 실정이다. 본 연구에서는 무인이동체를 활용한 철도교량의 외관조사 점검을 보다 효율적이고 신뢰성있게 점검을 위하여 무인이동체를 통해 촬영된 이미지에서의 손상점검을 자동화하기 위하여 다양한 방식의 딥러닝 기반 자동 손상 분석기술을 검토하였다. 고해상도 카메라를 탑재한 상용 무인이동체를 운용하여 취득된 이미지를 바탕으로 손상항목을 균열, 콘크리트 박리·박락, 철근노출, 누수, 페인트 박리·박락으로 각각 정의하고 학습데이터로 손상을 추출하여 딥러닝 분석 모델을 생성하였다. 본 연구에서는 상용 무인이동체를 활용하여 직접 취득된 손상 이미지와 그밖에 다양한 콘크리트 구조물에서 발생하는 손상에 대한 이미지 데이터를 확보하여 딥러닝 학습모델 개발에 적용하였다.

철도교량의 외관 손상중 균열, 콘크리트 박리·박락, 누수, 철근노출에 대한 손상 이미지 데이터는 손상항목별로 총 26,476개의 데이터를 수집하였으며 본 논문을 통해 제안된 딥러닝 분석 기법별로 Light Head-RCNN과 FPN, PSPNet 그리고 U-Net 알고리즘에 대한 분석 성능 비교를 수행하였다. 제안된 기법으로 각각 모델 학습(Model Train) 단계에서 80%의 손상 데이터를 통해 GT(Ground Truth) 데이터를 생성하고 모델 검증(Model Validation) 단계 나머지 20% 이미지를 사용하여 생성된 모델로 분석하였을 때 결과를 바탕으로 분석성능을 검토하였다. 분석 결과 평균 95%이상 검출 재현율을 도출한 분석 기법인 U-Net 알고리즘으로 철도교량 자동 손상 분석 소프트웨어를 개발하여 국내 철도교량 중 테스트베드를 선정 후 현장 적용 테스트를 수행하였다. 이와 같이 검토된 분석기법을 적용한 자동 손상 분석 기술을 적용하게될 경우 기존 육안점검 결과 대비 보다 객관적이고 정확한 손상 검출을 수행할 수 있어 효율적인 유지관리 시스템을 구축할 수 있을 것으로 사료된다. 본 연구를 통해 개발된 철도교량의 자동 손상 분석 핵심 기술을 통해 철도 유지관리 분야에서 무인이동체를 활용한 정기점검 시 객관적인 손상 점검 결과도출과 기존 대비 시간감축, 비용저감이 가능할 것으로 기대된다.

Acknowledgement

본 연구는 국토교통부/국토교통과학기술진흥원 공공혁신조달연계 무인이동체 및 SW플랫폼 개발사업의 연구비지원(무인이동체기반 접근취약 철도시설물 자동화점검시스템 개발)에 의해 수행되었습니다.

References

- [1] Abdel-Qader, I., Abudayyeh, O., Kelly, M.E. (2003). "Analysis of edge-detection techniques for crack identification in bridges." *Journal of Computing in Civil Engineering*, Vol. 17, No. 4, pp. 255-263.
- [2] Amhaz, R., Chambon, S., Idier, J., Baltazart, V. (2016). "Automatic crack detection on two-dimensional pavement images: An algorithm based on minimal path selection." *IEEE Transactions on Intelligent Transportation Systems*, Vol. 17, No. 10, pp. 2718-2729.
- [3] Chambon, S., Moliard, J.M. (2011). "Automatic road pavement assessment with image processing: Review and comparison." *International Journal of Geophysics*, Vol. 2011, pp. 556-575.
- [4] Chan, B., Guan, H., Jo, J., Blumenstein, M. (2015). "Towards UAV-based bridge inspection systems: A review and

an application perspective.” *Structural Monitoring and Maintenance*, Vol. 2, No. 3, pp. 283-300.

- [5] Chanda, S., Bu, G., Guan, H., Jo, J., Pal, U., Loo, Y., Blumenstein, M. (2014). “Automatic bridge crack detection - a texture analysis-based approach.” *IAPR Workshop on Artificial Neural Networks in Pattern Recognition*, Montreal, Canada, pp. 193-203.
- [6] De Melo, R.R., Costa, D.B., Álvares, J.S., Irizarry, J. (2017). “Applicability of unmanned aerial system (UAS) for safety inspection on construction sites.” *Safety Science*, Vol. 98, pp. 174-185.
- [7] Gavilán, M., Balcones, D., Marcos, O., Llorca, D.F., Sotelo, M.A., Parra, I., Amírola, A. (2011). “Adaptive road crack detection system by pavement classification.” *Sensors*, Vol. 11, No. 10, pp. 9628-9657.
- [8] Giakoumis, I., Nikolaidis, N., Pitas, I. (2005). “Digital image processing techniques for the detection and removal of cracks in digitized paintings.” *IEEE Transactions on Image Processing*, Vol. 15, No. 1, pp. 178-188.
- [9] Irizarry, J., Gheisari, M., Walker, B.N. (2012). “Usability assessment of drone technology as safety inspection tools.” *Journal of Information Technology in Construction (ITcon)*, Vol. 17, No. 12, pp. 194-212.
- [10] Jahanshahi, M.R., Kelly, J.S., Masri, S.F., Sukhatme, G.S. (2009). “A survey and evaluation of promising approaches for automatic image-based defect detection of bridge structures.” *Structure and Infrastructure Engineering*, Vol. 5, No. 6, pp. 455-486.
- [11] Kaseko, J.M., Ritchie, S.G. (1993). “A neural network-based methodology for pavement crack detection and classification.” *Transportation Research Part C: Emerging Technologies*, Vol. 1, No. 4, pp. 275-291.
- [12] Kim, M., Kim, K., Choi, S. (2017) “Development of automatic crack identification algorithm for a concrete sleeper using pattern recognition.” *Journal of the Korean Society for Railway*, Vol. 20, No. 3, pp. 374-381.
- [13] Lee, B.J., Shin, D.H., Seo, J.W., Jung, J.D., Lee, J.Y. (2011). *Intelligent Bridge Inspection using Remote Controlled Robot and Image Processing Technique*. International Symposium on Automation and Robotics in Construction (ISARC), Seoul, Korea, pp. 1426-1431.
- [14] Lee, H.B., Kim, J.W., Jang, I.Y. (2012). “Development of automatic crack detection system for concrete structure using image processing method.” *Journal of the Korea institute for structural maintenance and inspection*, Vol. 16, No. 1, pp. 64-77.
- [15] Long, J., Shelhamer, E., Darrell, T. (2015). “Fully convolutional networks for semantic segmentation.” *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440.
- [16] Lovelace, B., Zink, J. (2015). *Unmanned Aerial Vehicle Bridge Inspection Demonstration Project*. Research Project. Final Report, Minnesota Department of Transportation Research Services & Library, USA, pp. 40.
- [17] Lu, M., Hu, Y., Lu, X. (2019). “Dilated Light-Head R-CNN using tri-center loss for driving behavior recognition.” *Image and Vision Computing*, Vol. 90, pp. 103800.
- [18] Miyamoto, A., Konno, M., Bruhwiler, E. (2007). “Automatic crack recognition system for concrete structures using image processing approach.” *Asian Journal of Information Technology*, Vol. 6, No. 5, pp. 553-561.
- [19] Na, Y.H., Park, M.Y., Park, J.S., Park, S.B., Kwon, S.G. (2018). “Development of automatic crack detection using the Gabor Filter for concrete structures of railway tracks.” *Journal of the Society of Disaster Information*, Vol. 14, No. 4, pp. 458-465.
- [20] Ronneberger, O., Fischer, P., Brox, T. (2015). “U-net: Convolutional networks for biomedical image segmentation.” *International Conference on Medical Image Computing and Computer-assisted Intervention*. Springer, Cham, Munich, Germany, pp. 234-241.