

Mask R-CNN을 이용한 항공 영상에서의 도로 균열 검출⁺

(Crack Detection on the Road in Aerial Image using Mask R-CNN)

이 민 혜¹⁾, 남 광 우²⁾, 이 창 우^{3)*}

(Lee Min Hye, Nam Kwang Woo, and Lee Chang Woo)

요 약 기존의 균열 검출 방법은 많은 인력과 시간, 비용이 소모되는 문제점이 있다. 이러한 문제를 해결하고자 차량이나 드론을 이용하여 취득한 영상에서 균열 정보를 파악하고 정보화하는 자동검출시스템이 요구되고 있다. 본 논문에서는 드론으로 촬영한 도로 영상에서의 균열 검출 연구를 진행한다. 획득한 항공영상은 전처리와 라벨링(Labeling) 작업을 통해 균열의 형태정보 데이터셋(data set)을 생성한다. 생성한 데이터셋을 Mask R-CNN(regions with convolution neural network) 딥러닝(deep learning) 모델에 적용하여 다양한 균열 정보가 학습된 새로운 모델을 획득하였다. 획득 모델을 이용한 실험 결과, 제시된 항공 영상에서 균열을 평균 73.5%의 정확도로 검출하였으며 특정 형태의 균열 영역도 예측하는 것을 확인할 수 있었다.

핵심주제어 : 객체 검출, 도로 균열, 항공영상, GeoAI, Mask R-CNN

Abstract Conventional crack detection methods have a problem of consuming a lot of labor, time and cost. To solve these problems, an automatic detection system is needed to detect cracks in images obtained by using vehicles or UAVs(unmanned aerial vehicles). In this paper, we have studied road crack detection with unmanned aerial photographs. Aerial images are generated through preprocessing and labeling to generate morphological information data sets of cracks. The generated data set was applied to the mask R-CNN model to obtain a new model in which various crack information was learned. Experimental results show that the cracks in the proposed aerial image were detected with an accuracy of 73.5% and some of them were predicted in a certain type of crack region.

Key Words: object detection, crack, aerial image, GeoAI, mask R-CNN

* Corresponding Author: cwlee@kunsan.ac.kr

+ 이 논문은 2018년 한국국토정보공사 공간정보연구원 산학협력 R&D 지원사업 자유과제 지원과 국토교통부 국토공간정보연구사업(14NSIP-B080144-01)의 연구비 지원으로 수행된 연구임.
Manuscript received June 07, 2019 / revised June 19, 2019 / accepted June 19, 2019

1) 군산대학교 컴퓨터정보통신공학부, 제1저자
2) 군산대학교 컴퓨터정보통신공학부, 제2저자
3) 군산대학교 컴퓨터정보통신공학부, 교신저자

1. 서 론

스마트 시대의 도래로 4차 산업의 핵심기술인 인공지능, 사물인터넷, 드론, 빅데이터, 자율주행 기술과 도시 환경, 교통 정보 등과 같은 공간정보 데이터를 융합시킨 GeoAI(geospatial artificial intelligence) 기반 시스템의 개발이 요구되고 있

다. GeoAI는 인공위성, 항공기, 드론 등으로 촬영한 원격탐사 영상과 인공지능 기술을 접목하여 공간정보 빅데이터로부터 유의미한 정보를 도출하는 분야이다[1, 2]. GeoAI 기반 시스템은 탐지된 공간정보를 기반으로 3차원 국토를 재현하여 지적도, 도시환경, 교통 정보 등 다양한 주제의 공간정보를 구축, 관리하여 행정업무의 기반자료로 활용할 수 있다[3]. 따라서 공간정보의 구현, 분석을 위해서는 도로나 교통정보에 대한 변칙적인 데이터를 파악하고 관리자에게 알려줄 필요성이 있다. 도로 위 장애물 및 노면 파손 유무, 주행 차량 정보, 보행자 검출 유무가 대표적인 예이다.

공간정보 데이터의 시각화 과정에서 특히, 도로 표면의 균열(crack)이나 포트홀(pothole)의 검출 및 표기는 공간정보를 구축하는데 중요한 요소로 작용할 수 있다. 특히 도로 표면에 발생하는 균열은 주행차량의 반복되는 하중이나 건조수축, 온도 변화에 따른 체적 변화 등으로 인해 발생하며, 장시간 방치할 경우 차량의 파손 및 교통사고의 원인이 된다.

도로의 균열을 찾아내어 조치하기 위해서는 사람이 직접 돌아다니면서 육안으로 균열을 파악해야 한다. 이와 같은 고전적인 검출 방법은 많은 시간과 비용이 소모되며, 점검자의 주관에 개입되기 때문에 객관성과 정확성이 떨어지게 된다[4]. 이러한 문제를 해결하기 위해서 차량이나 무인항공기를 이용하여 도로 영상을 취득하고, 영상처리 기법을 이용하여 균열의 형태, 크기, 위치 등을 파악하고 정보화하는 자동검출시스템이 요구되고 있다.

지능형 교통 체계(ITS)에서 카메라, LIDAR 센서 등을 이용한 영상처리 기법이 제시되고 있지만 대부분의 연구가 노면의 차선 마킹, 차량 번호판 검출에 대한 내용[5, 6]으로 도로 파손 관리 분야에는 적용이 미흡한 실정이다.

따라서, 본 논문에서는 딥러닝을 이용한 항공영상에서의 도로 균열 검출 자동화에 대한 연구를 진행한다. 드론에서 획득한 영상을 전처리하여 데이터셋을 생성하고, 객체 검출에 우수한 성능을 보이는 딥러닝 모델인 Mask R-CNN[7]에 적용하여 균열 정보에 대한 학습을 진행한다. 이를 통해 얻어진 학습모델을 항공영상에 적용하여 도로 균열의 검출 성능을 분석하였다.

2. 관련 연구

2.1 기존의 균열 검출 연구

아스팔트 도로에 발생하는 포트홀, 균열의 검출은 도로의 파손 상태를 알리는 중요한 척도이다. 통상적인 균열의 검출방법은 노면의 갈라진 틈을 검출하여 두께, 길이, 진행 방향을 측정하고 파손정도를 판단하는 방법이 사용되고 있다.

균열은 크기와 깊이에 따라 모발균열, 작은 균열, 중간 균열, 큰 균열로 분류되며, 파손 형태에 따라 거북등 균열, 단부 균열, 줄눈 균열, 시공균열, 반사균열, 밀림균열, 세로방향 균열로 분류되어진다[8].

균열을 검출하는 방법은 크게 진동을 이용하는 방법, 레이저 스캐너를 이용한 3D 복원, 영상에 이용한 영상처리 방법으로 분류된다[9]. 진동을 이용하는 방법은 가속도 센서를 이용하여 흔들림에 따라 균열 유무를 검출하며 노면 상태에 따라 변동률이 높아 신뢰성이 낮다. 3D 복원 방법은 도로표면과 균열 내부의 깊이를 측정하는 방법으로 고가의 레이저 스캐너가 필요하기 때문에 효율적이지 못하다. 영상처리 방법은 카메라로 획득한 영상에서 도로와 균열의 텍스처 특성을 이용하여 검출하는 방법으로 영상의 화질에 큰 영향을 주는 광 잡음, 열화 등을 감소시키는 연구가 진행되어 왔다.

도로 영상에서의 균열 검출은 일반적으로 정상적인 도로 표면보다 진하고 불규칙한 텍스처를 갖는 균열의 특징을 이용하여 검출하게 된다. 먼저, 취득한 영상을 그레이스케일로 변환하고 모폴로지 기법과 블러링 등을 이용하여 잡음을 제거한다. 잡음을 제거한 영상은 균열의 텍스처 정보만을 나타내기 위해 히스토그램 모양기반 이진화(histogram shape-based thresholding), Otsu 방법 등을 이용하여 이진 영상으로 분리된다. 다음으로 에지(edge), HOG(histogram of oriented gradients), Haar-like 피쳐 등과 같은 경계 추출 알고리즘과 세션화 작업을 통해 균열 영역을 추출하게 된다. 이러한 과정에서 보다 나은 균열의 검출을 위해 필터의 감도를 조절하여 잡음을 제거하게 된다. 잡음을 완전히 제거하기 위해 영상

의 감도를 낮추면 미세한 모발균열을 검출하기 어려우며, 감도를 높이면 불필요한 텍스처 잡음까지 검출되는 문제점이 있다[10].

2.2 딥러닝을 이용한 균열 검출 방법

드론에서 촬영된 항공영상은 도로 노면 외에도 차량, 나무, 건물 등과 같이 주변의 복잡한 지형 지물도 함께 포함되어 있어 균열만을 검출하기 어렵다[4]. 또한 100m~150m의 상공에서 촬영된 고해상도의 영상에도 한계가 있어 미세한 모발균열이나 불규칙하게 갈라진 거북등 균열은 나뭇가지의 그림자나 선과 같은 잡음으로 보일 수 있는 단점이 있다.

최근에는 딥러닝이 객체를 검출하고 분류하는 영상처리 분야에 적용되어 우수한 성과를 보이고 있다. 특히 사람이 시각정보를 받아들이는 과정에 착안하여 설계된 CNN[11]은 설계자의 개입을 통해 이루어지는 기존의 특징 추출과는 큰 차이점을 보인다. CNN은 컨볼루션 계층과 풀링 계층, 완전 연결 신경망 계층(fully-connected layer)으로 이루어져있으며 각 계층을 거치며 주어진 훈련 샘플에 대하여 최적화된 특징 벡터들을 스스로 학습하고 특징 맵(feature map)을 생성한다[12, 13].

본 논문에서 사용하는 Mask R-CNN은 영상에서 후보영역을 제안하고 이를 기반으로 학습하여 객체의 특징을 추출하는 Faster R-CNN[14]에 검출된 객체를 각 픽셀로 마스킹(masking)해주는 모델이다.

3. 데이터셋 작업

3.1 전처리 과정

도로 균열에 대한 데이터셋을 만들기 위해 드론을 이용하여 시작지점으로 부터 1km 반경 내의 거리를 100m 상공에서 비행하여 4,864×3,648 크기의 고해상도 항공 영상 600장을 획득하였다. 획득 영상은 차량 및 계절의 영향을 받아 자연적으로 발생한 도로노면의 균열을 검출하기 위해 실제 도로를 촬영하였다.

학습데이터를 만들기 위해 얻어진 원본 항공영

상을 2차적으로 각 4분할하여 균열이 포함된 영상만 선별하였다. 다양한 균열을 학습시키기 위해 선별 영상에서 일부를 회전하여 각도를 달리 저장하여 영상의 수를 증가시켰다.

600장의 원본영상으로부터 최종적으로 선별된 크랙이 포함된 영상은 각 2432×1824 크기(원본영상의 1/4)로 총 200장을 얻었으며, 이 중에서 150장은 훈련 데이터셋, 50장은 검증 데이터셋으로 사용하였다. 이러한 전처리 작업 과정을 Fig. 1에 나타내었다.




Fig. 1 Preprocessing

3.2 학습데이터 라벨링

전처리된 영상은 VIA(VGG image annotator) Tool을 사용하여 균열 영상에 주석을 달기위한 라벨링 과정을 거친다. VIA Tool은 옥스퍼드 대학의 Visual Geometry Group에서 개발한 영상 라벨링용 오픈소스 프로그램이다[15]. 본 논문에서는 균열이 포함하고 있는 여러 가지 특징점을 고려하여 객체의 영역을 선택하고 'crack'으로 라벨링하였다. 훈련 데이터와 검증 데이터로 구분하여 라벨링한 데이터는 각각 json 파일 형태로 저장된다. json 파일에는 영상의 정보와 라벨링된 각각의 좌표 값이 메타데이터로 표현된다. Fig. 2는 VIA Tool을 사용하여 항공영상에서 도로 균열을 라벨링하는 과정을 나타낸 화면이다.




Fig. 2 Annotation data using VIA

4. 실험 및 고찰

4.1 학습 방법

본 논문은 Python과 Keras 라이브러리를 기반으로 구현된 Mask R-CNN 모델과 라벨링된 훈련 데이터셋을 이용하여 도로 균열을 검출하였다. 작업한 도로 균열 데이터를 추가적으로 학습시키기 위해 GitHub의 matterport 페이지[16]에서 제공하는 python용 학습 코드를 받아 수행하였다. 라벨링된 데이터는 대규모의 객체탐지, 분할, 캡셔닝(captioning)을 목적으로 만들어진 마이크로소프트의 데이터셋인 COCO(Common Objects in Context) 모델[17]에 분류를 추가하여 도로 균열을 검출할 수 있도록 하였다.

학습을 위한 데이터 경로의 설정 후 학습 반복 횟수(epoch)는 30, 반복된 학습에 대한 가중치 업데이트 횟수(Steps per epoch)는 100으로 설정하고 학습을 수행하였다.

학습 환경은 Dell inspron 7577 (Intel(R) Core (TM) i7-7000HQ CPU, RAM 16.0GB, NVIDIA 1060Max-Q 6G) 노트북을 사용하였으며 총 학습 시간은 4시간, 항공 영상 한 장에 대한 균열 검출 시간은 평균적으로 약 31초가 소요되었다.

4.2 Mask R-CNN 모델 테스트 과정

라벨링한 훈련 데이터셋과 Mask R-CNN 모델을 이용한 학습 과정은 크게 RPN(region proposal network)을 이용한 균열 검출, 바운딩 박스(bounding box) 생성, 마스크(mask) 표현으로 구분할 수 있다.

균열의 검출은 컨벌루션 레이어를 거쳐 생성된 특징맵에 RPN 단에서 미리 정의된 여러 크기와 비율의 앵커(anchor)박스를 이동시켜 해당 위치에 대해 균열을 검출하게 된다. 다음으로 마스크의 학습을 위해 훈련 데이터셋에서 해당 이미지의 클래스와 마스크 정보를 불러온다. 이 과정에서, 라벨링 작업을 통해 얻어진 균열 형태와 동일한 마스크 정보를 사용하게 되며 이를 Fig. 3에 시각화하여 나타내었다. 나타낸 마스크의 형태를 기준으로 바운딩 박스의 생성 영역의 위치

를 계산한다. 이러한 방법은 마스크의 업데이트(update) 과정에서 바운딩 박스를 함께 생성하므로 변형된 영상에서도 일관성 있는 균열 검출 결과를 얻을 수 있는 장점이 있다.

Fig. 4는 이러한 학습과정에서 확인이 가능한 이상적인 균열검출의 예시를 나타내고 있다.




Fig. 3 Display images and masks




Fig. 4 Example of ideal crack detection (training data set)

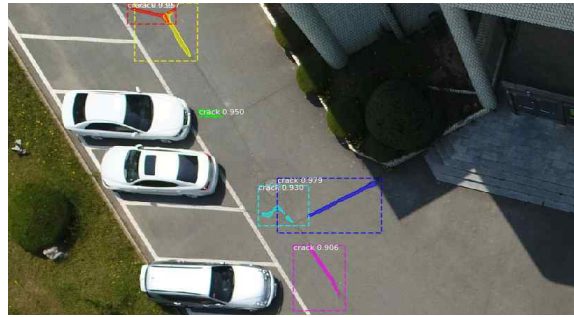
4.3 학습모델 분석 결과

실험 데이터셋은 서로 다른 아스팔트 도로의 균열 검출율을 확인하고자, 각각 10장의 운동장, 7장의 주차장 구역과 43장의 자동차도로를 포함한 총 60장의 원본 영상(4,864×3,648 크기의 고해상도 항공 영상)으로 구성되어진다. 원본영상은 1/4 크기로 분할하여 검출을 수행할 경우 240장의 실험 데이터셋을 형성한다.


Fig. 5는 Mask R-CNN 모델의 학습을 통해 균열 정보가 추가된 모델을 이용하여 항공영상에서 도로의 균열을 검출한 결과이다. 운동장, 주차장, 자동차도로 세 가지 영상이 포함된 실험 데이터셋을 이용하여 균열의 검출 정확도를 확인하였다. 규칙적인 형태의 균열이 주를 이루는 Fig.




(a) Playground surface



(b) Parking lot surface



(c) Road surface (street)



(d) Road surface (driveway)

Fig. 5 Detection of crack on the roads

5(a)와 Fig. 5(c)의 경우에는 균열을 제대로 검출하고 형태에 맞춰 바운딩 박스와 마스크를 나타내는 것을 확인할 수 있었다. 또한, Fig. 5(b)와 Fig. 5(d)에서 나타나는 특정 형태의 균열도 일부 검출하는 것을 확인할 수 있었다.

실험 결과, 직선형태의 균열은 높은 검출율을 보였으나 Fig. 5(d)에서 나타난 바와 같이 복잡하거나 불규칙한 형태의 특정 균열은 검출이 대부분 누락되는 문제가 발생하였다. Fig. 5(c)의 좌측 상단에 검출된 유사한 색상의 나뭇가지도 균열로 검출하는 문제가 발생하였다. 이러한 문제들은 적은 훈련 데이터셋으로 학습을 진행하여 발생하는 문제로 데이터를 보완하여 해결할 필요가 있음을 확인하였다.

Table 1 Accuracy of crack on the roads

Problems	accuracy (%)
Playground surface	77.7
Parking lot surface	70.1
Road surface	72.6
Average	73.5

결과 영상을 토대로 Table 1은 육안으로 보이는 실제 균열 개수와 학습모델을 이용하여 검출된 균열의 수를 비교한 결과이다. 실험 결과, 해당 영상에 대한 균열의 평균값은 운동장 77.7%, 주차장 70.1%, 자동차도로 72.6%로 도출되었으며, 평균 73.5%의 정확도를 보이는 것으로 확인되었다.

5. 결론

본 논문에서는 도시환경, 교통 정보 등의 공간 정보의 구현에 앞서 Mask R-CNN 모델을 이용하여 고해상도 항공영상에서의 도로 균열을 검출하는 연구를 수행하였다. 실험 결과, 학습된 모델을 기반으로 항공영상에서 균열의 개수를 평균적으로 73.5%의 정확도로 검출하는 성과를 보였다. 그러나 훈련 데이터셋의 부족으로 특정 형태의 균열을 검출하지 못하거나, 유사한 형태의 나뭇가지들을 균열로 인식하는 문제가 발생하였다. 본 연구는 차후 보완을 통해 3차원 도시 환경의

재현, 공간정보의 구현에 사용되는 도로나 교통 정보에 대한 변칙적인 데이터를 보다 정확하게 파악하고 실생활에서 도로 파손으로 인한 사고를 예방할 수 있는 지표로 활용할 수 있을 것으로 기대된다.

References

- [1] Kang, Y. M. and Kang, C. W., Han, K. S., Kim, J. B., “A study on network strategy for smart society by analysis of spatial information technology trends,” *Journal of the Korea Institute of Information and Communication Engineering*, Vol. 19, No. 6, pp. 1411-1418, 2015.
- [2] Seo, G. H., “GeoAI-based land-use change monitoring innovation and utilization plan,” *Technical Report: KRIHS Policy Brief*, No. 694. 2018.
- [3] Kim, H. J., Eo, Y. D., Lee, J. M. and Bae, G. H., “Application research on Obstruction area detection of building wall using R-CNN technique,” *Journal of Cadastre & Land InformatiX*, Vol. 48, No. 2, pp. 213-225, 2018.
- [4] Joo, Y. J., “Detection method for road pavement defect of UAV imagery based on computer vision,” *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 35, No. 6, pp. 599-608, 2017.
- [5] Choi, S. W., Lee, K. T., Kim, K. S. and Kwak, S. Y., “Lane departure warning system using deep learning,” *Journal of the Korea Industrial Information Systems Research* Vol. 24 No. 2, pp. 25-31, 2019.
- [6] Lee, D. S. and Kwon, S. K., “Vehicle plate detection method by measuring plane similarity using depth information,” *Journal of the Korea Industrial Information Systems Research*, Vol. 24 No. 2, pp. 47-55, 2019.
- [7] He, K., Gkioxari G., Doll’ar P. and Girshick R., “Mask R-CNN”, *IEEE International Conference on Computer Vision(ICCV)*, pp. 2980-2988, March 2017.
- [8] Eulsukdo Bridge Corporation, “Bridge maintenance management system,” *Maintenance Guide Book*, 2014.
- [9] Kim, Y. R., Kim, T. H. and Ryu, S. K., “Pothole detection method in asphalt pavement,” *Journal of The Institute of Electronics and Information Engineers*, Vol. 51, No. 10, pp. 2382-2389, 2014.
- [10] Zhang, A., Kelvin, C. P. W., Li, B., Yang, E., Dai, X., Peng, Y., Fei, Y., Liu, Y., Joshua, Q. Li. and Chen, D., “Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep-learning network,” *Computer-Aided Civil and Infrastructure Engineering*, Vol. 32, No. 5, pp. 1-15, 2017.
- [11] Krizhevsky A., Sutskever I. and Hinton G., “ImageNet classification with deep convolutional neural networks,” *Advances in Neural Information Processing Systems (NIPS)*, pp.1097-1105, 2012.
- [12] Lee, D. S. and Yoon, S., Lee, J. W., Park, D. S., “Real-time license plate detection based on faster R-CNN,” *KIPS Transactions on Software and Data Engineering*, Vol. 5, No. 11, pp. 511-520, 2016.
- [13] Lee, J. H., Kim, B. M. and Shin, S. Y., “Effects of preprocessing and feature extraction on CNN-based fire detection performance,” *Journal of the Korea Industrial Information Systems Research* Vol. 23 No. 4, pp. 41-53, 2018.
- [14] Ren, S., He, K., Girshick R. and Sun J., “Faster R-CNN: Towards real-time object detection with region proposal networks,”

Advances in Neural Information Processing Systems (NIPS), pp.91-99, 2015.

[15] Dutta, A., Gupta, A. and Zisserman A., Visual geometry group, University of Oxford, <http://www.robots.ox.ac.uk/~vgg/software/via> (accessed on June, 19th, 2019)

[16] https://github.com/matterport/Mask_RCNN (accessed on June, 19th, 2019)

[17] Lin, T.-Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Doll'ar P. and ZitnickL, C., "Microsoft COCO: common objects in context," European Conference on Computer Vision(ECCV), 2014.



이 민 혜 (Lee Min Hye)

- 정회원
- 군산대학교 컴퓨터정보공학과 공학사
- 원광대학교 전자공학과 공학석사
- 원광대학교 전자공학과 공학박사
- 군산대학교 컴퓨터정보통신공학부 박사 후 연구원
- 관심분야 : 영상처리, 머신러닝, 의공학



남 광 우 (Nam Kwang Woo)

- 정회원
 - 충북대학교 전자계산학과 이학사
 - 충북대학교 전자계산학과 이학석사
 - 충북대학교 전자계산학과 이학박사
 - 군산대학교 공과대학 컴퓨터
- 정보통신공학부 정교수
- 관심분야 : 공간데이터베이스, 데이터마이닝



이 창 우 (Lee Chang Woo)

- 정회원
 - 경일대학교컴퓨터공학과 공학사
 - 경북대학교 컴퓨터공학과 공학석사
 - 경북대학교 컴퓨터공학과 공학박사
 - 군산대학교 공과대학 컴퓨터
- 정보통신공학부 정교수
- 관심분야 : 컴퓨터비전, 머신러닝, 패턴인식