

딥러닝 기반의 분할과 객체탐지를 활용한 도로균열 탐지시스템 개발

A Development of Road Crack Detection System Using Deep Learning-based Segmentation and Object Detection

하종우(Jongwoo Ha)*, 박경원(Kyongwon Park)**, 김민수(Minsoo Kim)***

초 록

최근 도로균열 탐지에 대한 많은 연구에서 딥러닝 기반의 접근법을 활용하면서 과거 알고리즘 기반의 접근법을 활용한 연구들보다 높은 성능과 성과를 보이고 있다. 그러나 딥러닝 기반의 많은 연구가 여전히 균열의 유형을 분류하는 것에 집중되어 있다. 균열 유형의 분류는 현재 수작업에 의존하고 있는 균열탐지 프로세스를 획기적으로 개선해 줄 수 있다는 점에서 상당한 기대를 받고 있다. 그러나 실제 도로의 유지보수 작업에 있어서는 균열의 유형뿐만 아니라 균열의 심각도에 관한 판단이 필수적이지만, 아직까지 도로균열 탐지와 관련된 연구들이 균열의 심각도에 대한 자동화된 산출까지 진전되지 못하고 있다. 균열의 심각도를 산출하기 위해서는 균열의 유형과 이미지 속 균열의 부위가 함께 파악되어야 한다. 본 연구에서는 균열 유형과 균열 부위의 동시적 탐지를 효과적으로 자동화하기 위해 딥러닝 기반의 객체탐지 모델인 Mobilenet-SSD를 활용하는 방법을 다루고 있다. 균열탐지의 정확도를 개선하기 위해 U-Net을 활용해 입력 이미지를 자동 분할하고, 이를 객체탐지 기법과 결합하기 위한 여러 실험을 진행하여 그 결과를 정리하였다. 결과적으로 U-Net을 활용한 이미지 의 자동 마스크를 통해 객체탐지의 성능을 mAP 값이 0.9315가 되도록 향상시킬 수 있었다. 본 연구의 결과를 참고하여 도로포장 관리시스템의 구현에 균열탐지 기능의 자동화가 더욱 진전될 수 있다고 기대된다.

ABSTRACT

Many recent studies on deep learning-based road crack detection have shown significantly more improved performances than previous works using algorithm-based conventional approaches. However, many deep learning-based studies are still focused on classifying the types of cracks. The classification of crack types is highly anticipated in that it can improve the crack detection process, which is currently relying on manual intervention. However, it is essential to calculate the severity of the cracks as well as identifying the type of cracks in actual pavement maintenance planning, but studies related to road crack detection have not progressed enough to automated calculation of the severity of cracks.

이 논문은 부경대학교 자율창의학술연구비(2019년)에 의하여 연구되었음.

* First Author, Ph.D. Student, Major in Industrial Data Science & Engineering, Department of Industrial and Data Engineering, Pukyong National University(hejoyy@pukyong.ac.kr)

** Co-Author, Chief Executive Officer, PaveTec Korea Co., Ltd.(pkw4425@naver.com)

*** Corresponding Author, Professor, Major in Industrial Data Science & Engineering, Department of Industrial and Data Engineering, Pukyong National University(minsky@pknu.ac.kr)

Received: 2021-01-14, Review completed: 2021-02-03, Accepted: 2021-02-09


In order to calculate the severity of the crack, the type of crack and the area of the crack in the image must be identified together. This study deals with a method of using Mobilenet-SSD that is deep learning-based object detection techniques to effectively automate the simultaneous detection of crack types and crack areas. To improve the accuracy of object-detection for road cracks, several experiments were conducted to combine the U-Net for automatic segmentation of input image and object-detection model, and the results were summarized. As a result, image masking with U-Net is able to maximize object-detection performance with 0.9315 mAP value. While referring the results of this study, it is expected that the automation of the crack detection functionality on pave management system can be further enhanced.

키워드 : 도로 균열 탐지, 균열 심각도, 객체 탐지, 균열부위 분할, 포장 관리
Road Crack Detection, Crack Severity, Object Detection, Crack Segmentation, Pavement Management

1. 서 론

도로포장 관리란 도로상에서 균열 등의 결함을 감지하고, 이에 맞는 적절한 보수 작업을 진행하여 자동차 도로의 상태를 최상으로 유지하기 위한 제반 업무 프로세스를 의미한다. 도로포장 관리의 핵심은 도로의 결함을 적시에 발견하여 보수를 진행함으로써 도로포장의 급격한 파손을 예방함과 동시에 유지보수 비용을 절감하고 쾌적한 도로주행 환경을 조성하는데 있다. 교통량이 많은 대도시의 경우에는 중(重)교통량에 따른 파손정도가 크기 때문에, 더욱 적기 균열탐지와 유지 보수가 중요하지만, 제한된 자원하에서 관리해야 할 도로가 많은 상황에서는 균열 심각도에 기초한 위험의 정량화된 평가가 유지보수 작업의 우선순위 결정을 위해 선행되어야 한다. 다음의 <Figure 1>은 이러한 도로포장 관리 프로세스를 간략히 나타낸 것이다. 전용 스캐너나 카메라 장비 등을 이용해 취득된 도로 표면의 이미지는 해당 도로 구간의 위치 정보와 함께 균열탐지 프로세스에 전달된다. 균열탐지 프로세스에서는 매시간 지속해서 입력

되는 막대한 분량의 도로 이미지로부터 균열의 존재 여부와 균열 유형에 대한 분류 작업을 진행하게 된다. 현재 국내의 도로포장 관리시스템에서는 이러한 균열탐지 프로세스가 다수의 작업자가 수행하는 육안 검사에 크게 의존하고 있는 상황으로, 전체 업무 프로세스에서 상당한 작업 부하를 유발하는 병목 프로세스가 되고 있다. 균열 유형이 파악된 이미지는 후속 단계에서 균열 심각도 산정에 이용되며, 최종적으로 심각도가 높은 도로 구간을 파악하여 관련된 유지보수 계획이 스케줄된다[10].



<Figure 1> Overall Pave Management Process


도로 이미지의 취득은 많은 경우 전문 장비의 사용을 통해 자동화되어 있지만, 균열의 탐지와 심각도의 산정 과정에서 인적 자원에 크게 의존함으로써 전체 프로세스의 효율적인 수행에 어려움을 겪고 있다. 인적 자원의 처리 능력을 컴퓨팅 장비의 계산 능력으로 보조하거나 대체하기 위한 인공지능 관련 연구는 심층신경망(DNN: Deep Neural Network)에 대한 연구와 활용 성과가 다양한 산업 영역에서 알려지면서 많은 관심을 받고 있는데[8, 20, 21], 최근에는 도로균열의 탐지에 딥러닝 기반의 접근법을 활용하여 분류 정확도를 상당히 높인 연구 결과가 발표되고 있어서, 해당 프로세스의 자동화에 대한 기대를 높이고 있다[1, 7, 9, 15]. 그러나 심각도의 산정이 여전히 인적 개입에 크게 의존하고 있어서 전체 프로세스의 효율화를 위해서는 추가적인 연구가 필요한 상황이다. 균열의 심각도를 파악하기 위해서는 균열 부위를 정확히 한정하고, 균열 유형에 따라 훼손의 정도를 산술적으로 측정할 필요가 있다. 딥러닝 기반의 분류 모델을 활용한 균열 유형의 식별이 상당한 성과를 보이는 것과는 달리, 균열 부위의 파악을 위해 객체탐지 모델을 활용한 결과는 실제 현장에서의 적용이 가능할 정도의 높은 정확도를 보이지 못하고 있다. 본 연구에서는 균열 심각도의 산정을 위해 선행되어야 할 균열 유형과 균열 부위의 동시 탐지를 효과적으로 수행할 수 있도록, 기존의 객체탐지 모델을 딥러닝 기반의 이미지 분할 모델과 결합하여 사용하는 방법을 찾고자 한다. 대표적인 5가지 균열 유형인 거북등균열(AC; Alligator Crack), 종방향균열(LC: Longitudinal Crack), 횡방향균열(TC: Transverse Crack), 포트홀(Pothole) 및 패칭(Patching)에 대해서, 균열 유형과 부위를 탐지하기 위한 4가지 구성의 실험

을 진행하였고, 각각의 결과를 정리하였다. 본 연구의 결과를 활용하여 균열 유형과 균열 영역이 높은 정확도로 함께 결정될 수 있다면, 전체 도로포장 관리시스템의 자동화를 통한 효과적인 유지보수 프로세스의 실행이 가능해질 것으로 기대된다.

본 연구의 구성은 다음과 같다. 이어지는 제 2장에서는 관련된 선행 연구들을 간략히 정리하였고, 제 3장에서는 도로균열의 탐지를 위해 본 연구에서 진행된 4가지 구성의 실험환경을 얻어진 결과와 함께 차례대로 정리하였다. 제 4장에서는 본 연구의 결과를 활용하여 구성될 도로균열 탐지시스템의 최종 형태에 관해서 설명하였다. 마지막 제 5장에서는 결론과 함께 추후 연구내용을 제시하였다.

2. 관련 연구 및 배경

아스팔트로 이루어진 도로에서 발생하는 균열의 형태는 발생 원인과 국가별 기후 환경 및 관리 목적에 따라 차이가 있지만, 국내의 경우 다음의 <Figure 2>와 같이 보통 5개의 유형으로 분류되어 관리되고 있다[15].



〈Figure 2〉 Five Types of Road Cracks

도로균열의 탐지는 먼저 균열의 유형과 균열 부위를 결정한 후, 균열 유형에 따라 균열의 최대 폭이나 길이, 균열 면적 등의 기초 데이터를 측정하여 심각도 계산에 활용하게 된다. 딥러닝을 활용한 도로균열의 탐지에 대한 많은 기존 연구들은 아직 균열 유형의 분류에 집중되어 있으며, 연구 대상으로 다루는 균열 유형 역시 앞서 언급한 5가지 모두를 다루지 못하고 있다 [10, 14, 18]. 심각도의 계산에 위해서는 균열 유형과 부위가 함께 파악되어야 하는데, 딥러닝을 이용한 분류 모델과 균열 부위의 파악을 위한 기존의 알고리즘적 접근법을 결합하여 사용하거나, 일부 유형의 균열에 대해서 선도적으로 심각도를 산출하는 연구가 시도되고 있다 [1, 2, 12]. 본 연구에서는 합성곱신경망(CNN: Convolutional Neural Network)을 활용한 객체탐지 모델을 통해 5가지 균열 유형 모두에 대해서 분류와 균열 부위의 산출을 동시에 처리하되, 제한된 연산처리 환경을 고려한 접근법을 다루고 있다는 점에서 기존의 연구와 달리 현장에서의 활용 가능성에 더 중점을 둔 접근법이라 할 수 있겠다. 계속해서 도로균열 탐지와 관련한 기존 연구를 간략히 정리하였다.

2.1 딥러닝 이전의 균열 탐지 연구

딥러닝을 통한 이미지 추출 방법이 활용되기 전부터, 영상처리 분야에서는 해석적인 알고리즘을 통해 이미지로부터 균열 픽셀을 식별하는 다양한 연구들이 있었다. 도로 표면 이미지로부터 균열 부위를 검출하는 일반적인 방법은 균열 부위가 정상적인 도로의 표면보다는 색이 진하거나 불규칙적인 텍스처를 가진다는 특징을 주로 이용하였다. 많은 경우, 수집된 도로 표면의 이미지를 흑백(Greyscale)으로 변환한 후에, 형

태학적 변형(Morphology) 기법과 이미지를 부드럽게 하는(Blurring) 등 알고리즘적인 기법을 활용하여 이미지 상에 존재하는 노이즈의 영향을 감소시키거나 제거하게 된다. 이렇게 처리된 이미지는 균열과 관련된 텍스처 정보를 추출하기 위해 히스토그램 모양 기반의 이진화 Otsu 방법 등을 통해 이진 데이터로 변환된다. 마지막으로 가장자리 검출, HOG(Histogram of Oriented Gradients), 유사 하르 특징(Haar-like Feature) 등과 같은 경계 추출을 위한 알고리즘을 사용하여 균열 영역을 배경으로부터 추출하게 된다 [21].

이러한 해석적 알고리즘을 이용한 균열 부위의 추출 방법들은 전체적인 성능 향상을 위해 대상 이미지의 통계적 특성을 사전에 파악하여 관련된 파라미터를 적절히 추정해 내는 것이 매우 중요한데, 균열의 추가적인 특징을 파악하여 알고리즘의 설계에 반영하는 과정에서 상당히 복잡한 형태의 구현이 요구되는 것이 일반적이다. 이러한 해석적인 접근법들은 대상이 되는 도로 이미지의 통계적 특성이 국가적·계절적·기후 환경적 특성에 의해 달라질 경우, 알고리즘의 견고성이 떨어지며 추가되는 데이터와 함께 정확도의 지속적 개선이 가능한 딥러닝 기반의 방법에 비해 비탄력적이라는 취약점이 있다.

2.2 딥러닝을 활용한 균열 탐지 연구

합성곱 신경망을 활용한 영상처리는 최근 많은 분야의 연구들에서 높은 성과를 보이고 있지만, 포장도로의 표면 이미지로부터 균열 유형과 부위를 탐지해내는 연구들에서는 그 정확도가 약 80~90% 정도로, 상대적으로 낮은 수준에 머물러 있다 [3, 23]. 탐지하고자 하는 개별 영상 패턴의 완결성이 각기 대조적으로 파악될 수 있는 여타 분야와는 달리, 균열 영역이 기본 패턴의


반복 확장된 군집체로써 파악된다는 점과 균열 유형에 따라 이러한 반복성이 각기 다르게 나타난다는 특징이 도로 균열탐지를 어렵게 하고 있으며, 실제 도로 상황에서 자주 나타나는 차선, 쓰레기, 노면 상의 표시와 같은 노이즈가 현장 적용 시의 성능 저하에 상당한 영향을 미치는 원인으로 파악된다. 이러한 다양한 제한 요소들을 극복하기 위해서는 적절한 CNN 모델을 선택하거나 도로균열의 탐지에 특화된 CNN 모델의 설계가 필요할 것으로 판단되며, 다량의 데이터가 학습을 위해 활용될 필요가 있겠다[4, 13].

2.3 Mobilenet-SSD

대표적인 객체탐지 모델 중의 하나인 SSD (Single Shot Multibox Detector)는 단일계층 검출기(1-Stage Object Detector)로서 단일 신경망을 이용하여 입력 이미지로부터 대상 객체를 탐지한다. 객체탐지 모델은 이미지 상에서 객체의 종류와 위치를 동시에 파악해 낼 수 있다는 점에서 기존의 분류만을 담당하는 모델을 대신하여, 도로균열의 종류와 범위를 함께 탐지하기 위해 활용될 수 있다. SSD는 여러 크기의 특징맵을 이용하여 이미지 속 물체의 크기 변화에 따른 영향을 최대한 줄임으로써 높은 탐지 성능을 보이는데, 단일계층 검출기의 특성상 탐지 속도가 매우

빠르고 모델의 복잡도가 낮다는 장점이 있다[11].


본 논문에서는 Mobilenet v1을 활용한 SSD 300 모델을 실험에 사용하였다. 기존 SSD300의 경우에는 네트워크 구조의 가장 앞에 위치한 기반 네트워크로 VGG-19를 사용하고 있는데, 본 연구에서는 도로 현장의 제한된 장비 성능 하에서도 모델의 성능을 유지하면서 빠르게 동작할 수 있도록 기존의 VGG-19를 보다 경량화된 모델인 Mobilenet v1으로 대체한 Mobilenet-SSD300을 사용하였다. Mobilenet v1은 컴퓨팅 성능에 제한이 있는 소형 혹은 모바일 단말을 위해 Google에서 제안한 경량화된 CNN으로, 심도별 분리 계층(Depthwise Separable Layer)을 통해 기존 합성곱 연산을 대체함으로써 성능을 유지하면서 연산량을 대폭 줄여 추론시간을 감축시킬 수 있는 장점이 있다. 현재까지 Mobilenet v3까지 발표되어 있으며, Mobilenet v2의 경우 Inverted Residual Module을 적용하여 Mobilenet v1보다 성능을 다소 높일 수 있었지만, 추론 시간이 상대적으로 더 길어지는 결과를 보이고 있다. 현재는 Mobilenet v2보다 더 높은 정확도를 보이면서도 연산속도에서 약간의 개선을 가져온 Mobilenet v3가 발표된 이후, 다양한 분야에서 이를 이용한 연구들이 활발히 진행되고 있다[5, 17]. 다음의 <Figure 3>은 본 연구의 실험에 사용한 Mobilenet-SSD의 구조를 나타낸 것이다.



<Figure 3> Mobilenet-SSD Architecture[11]

2.4 U-Net Segmentation

U-Net은 의료 영상 분야에서 이미지의 전처리와 특정 요소의 분리를 위해 제안된 분할 모델로 세포 영역의 분리에 좋은 성능을 보이고 있다 [16]. U-Net은 슬라이딩 윈도우 방식 대신 패치(patch) 방식을 채택하여 이미지 전체를 격자 모양으로 구분하여 처리하기 때문에, 이미 검증된 이미지 영역과 후속되는 이미지 영역과의 중첩된 영역에 대한 재계산 작업이 많이 발생하는 기존의 슬라이딩 윈도우 방식에 비해 빠른 처리 속도를 보인다. U-Net의 빠른 처리 속도는 경량화된 실행 환경을 고려하는 본 연구와 잘 부합할 뿐만 아니라, 거북등과 같은 균열 형태가 격자 모양의 세포 조직과 유사성이 높아서 균열의 분할에 효과적인 것으로 기대되어 본 연구의 실험 모델로 선정되었다. 다음의 <Figure 4>는 U-Net의 네트워크 구조를 나타낸다.



<Figure 4> U-Net Architecture [16]

U-Net은 의료 이미지의 특성상 적은 수의 데이터에서도 정확한 분할이 가능하도록 FCN (Fully Convolutional Network)을 기반으로 구축되었는데, U자 형태의 구조에서 왼쪽 부분에 해당하는 축소경로(Contracting Path)와 오른


쪽 부분에 해당하는 팽창경로(Expansive Path)로 이루어져 있다. 축소경로에서는 이미지의 상황을 포착하는 역할을 하며, 팽창경로에서는 특징맵을 업샘플링하고, 이를 앞서 포착해낸 상황과 결합하여 형상의 위치를 한정해내는 기능을 수행하게 된다. 본 연구에서 U-Net은 도로 이미지로부터 노이즈를 제거하고, 균열 부위를 추출하여 객체탐지의 성능을 높이기 위해 활용되었다.

3. 균열탐지 시스템의 구성과 실험

본 연구에서는 균열탐지 시스템의 구성을 위해 모두 4가지 형태의 모델 구성을 실험하였다. 수집된 6,650장의 도로 이미지를 사용하여 각각의 모델 구성을 테스트하였다. 수집한 모바일촬영 이미지의 경우 이미지가 포함하고 있는 도로 표면의 실제 영역이 가로 0.55~0.65m, 세로의 경우 1.05~1.10m의 범위가 되도록 일관되게 촬영하였다. 실험 모델은 Google의 Tensorflow Object Detection API[6]를 활용하여 구성되었다[14].

3.1 단일 객체탐지 모델을 사용한 구성


도로균열의 유형과 위치를 동시에 파악해 내기 위한 가장 간단한 실험환경의 구성으로써 Mobilenet-SSD를 사용한 객체탐지 모델을 학습하여 테스트하였다. 입력 이미지는 Python 라이브러리인 openCV의 pyrDown함수를 활용하여 네트워크 구조에 적합한 300×300의 크기로 조정되었으며, 전체 이미지 데이터의 80%를 학습데이터로 사용하였다. 다음 <Figure 5>에 단일 객체탐지 모델을 사용한 구성을 간략히 정리하였다.



〈Figure 5〉 Configuration-A

가장 먼저 입력 이미지의 크기만을 조정하여 학습시킨 모델의 경우에는 5개의 도로균열 유형을 분류하고 위치를 파악하는 데에 상당한 문제가 있었다. 객체탐지 모델의 주요 성능지표로 일반적으로 활용되는 mAP(mean Average Precision) 값을 확인한 결과 0.6818에 불과하여, 현장 활용이 가능한 정도의 실질적인 탐지 능력이 없음을 알 수 있었다. 다양한 형상의 이미지를 효과적으로 분류하고, 그 위치까지를 잘 파악해 내는 것으로 알려진 객체탐지 모델을 사용하였음에도 예상 밖의 저조한 탐지 성능을 확인할 수 있었다.

이번에는 모델의 정확도를 높이기 위해 앞서와 동일한 모델을 사용하되, 학습과 테스트를 위해 입력 이미지의 마스킹(Masking) 작업을 통해 흑백의 이진 이미지로 전처리한 것을 대신 사용하였다. 아래의 〈Figure 6〉에 원본 이미지와 마스킹된 흑백 이미지를 대비하여 정리하였다.




〈Figure 6〉 Original and Masked Input Image

마스킹된 이진 이미지를 사용해 재학습된 모델은 앞서와 달리, 0.9382라는 높은 수준의 mAP 값을 보여주었다. 이것은 입력 이미지에서 균열 부위의 분할이 적절히 이루어진다면, 기존의 객체탐지 모델을 활용해 도로균열을 효과적으로 파악할 수 있음을 의미한다. 〈Figure 7〉과 〈Table 1〉에서 마스킹된 이진 이미지를 사용하여 얻은 결과를 정리하였다.

〈Table 1〉 Performance of Object-Detection Model Using Masked Binary Input Image


Class	AP	mAP
Alligator Crack	0.8202	0.9382
Longitudinal Crack	0.9188	
Transverse Crack	0.9719	
Patching	0.9895	
Pothole	0.9906	



〈Figure 7〉 Object-Detection Result

3.2 Segmentation을 활용한 구성

앞서 실험을 통해 입력 이미지의 적절한 마스킹 작업이 균열탐지 성능에 상당한 영향을 미친다는 것을 볼 수 있었다. 이를 확인하기 위해, 두 번째 구성에서는 원본 이미지에 대한 자동화된 마스킹 작업이 진행되도록, 이미지 분할 모델을 객체탐지 모델의 앞부분에 추가하였다. <Figure 8>에 이러한 실험의 구성을 나타내었다.



<Figure 8> Configuration-B

입력 이미지에 대한 분할 작업이 자동으로 이루어질 수 있도록 U-Net, FPHBN 및 FPN이라는 3개의 대표적인 이미지 분할 모델을 선정하여 5개의 균열 유형 모두에 대해 학습시켜서 가장 높은 성능을 보이는 모델을 최종 시스템의 구성에 사용하기로 하였다[9, 19, 16]. 그러나 세 모델 모두 균열 부위의 분할 성능이 예상과 달리 실질적인 사용이 어려울 정도로 매우 저조한 결과를 보였다. 분할 모델의 주요 성능지표로 폭넓게 활용되는 mIoU(mean Intersection over Union) 값이 매우 낮아서 도로균열 부위를 제대로 찾아내지 못함을 알 수 있었다. <Table 2>에 테스트에 사용된 세 가지 분할 모델의 mIoU 값을 정리하였다.


<Table 2> mIoU of Three Segmentation Models

Model	U-Net	FPHBN	FPN
mIoU	0.4256	0.4044	0.3996

세 모델 중에서 가장 높은 mIoU 값을 보이는 U-Net에서도 평균적으로 균열 영역의 절반에도 미치지 못하는 분할 성능을 보였는데, 이것은 결국 이질적인 성격의 균열 유형에 대해 동일한 분할 모델을 학습하여 적용하는 것이 오히려 전체적인 성능을 떨어뜨리게 된 것으로 판단된다. 따라서 효과적인 분할이 이루어지기 위해서는 균열 유형에 맞춰 개별적으로 학습된 분할 모델이 필요한 것으로 보인다.

3.3 유형별 객체탐지를 위한 구성

앞서 살펴본 Configuration-A 구성의 첫 번째 실험에서 원본 이미지를 입력으로 사용한 경우의 성능이 마스킹된 이진 이미지를 사용하는 경우와 크게 차이가 나는 원인을 좀 더 자세히 파악하기 위해, 균열의 유형에 따라 객체탐지 모델을 구분하여 학습해 봄으로써 성능에 어떠한 변화가 있는지를 살펴보았다. 원본 이미지를 입력으로 사용하여 학습하되, 5개의 균열 유형을 두 개의 객체탐지 모델에 나누어서 달리 학습하도록 실험을 재구성하였다. 일반적으로 균열의 형태가 선형으로 간주되는 거북등, 종방향 및 횡방향 균열을 함께 학습하도록 N1 네트워크를 구성하였고, 면적형 균열로 구분되는 포트홀과 패칭을 함께 학습하도록 N2 네트워크를 구성하였다. 아래의 <Figure 9>에 이러한 실험의 구성을 나타내었고, 테스트 결과를 <Table 3>에 정리하였다.



<Figure 9> Configuration-C

<Table 3> mAP of Two Object-Detection Models


	Class	mAP
N1	Alligator, Longitudinal, Transverse	0.6598
N2	Pothole, Patching	0.7414

5개의 균열 유형을 한꺼번에 학습하여 테스트했던 Configuration-A에서 얻은 mAP 값 (0.6818)과 비교할 때, N1 네트워크의 경우에는 오히려 분류해야 할 유형의 수가 3개로 줄었음에도 mAP 값이 약 0.02 정도 감소하였고, N2 네트워크의 경우에는 0.06 정도 증가하였다. 이를 토대로 판단해 볼 때, 분류해야 할 균열 유형의 변화가 객체탐지 모델의 성능에 미치는 영향은 입력 이미지의 마스킹 작업을 통해서 얻는 결과에 비해 상대적으로 미미한 것을 확인할 수 있었다.

3.4 유형별 Segmentation과 객체탐지 모델을 결합한 구성

Configuration-A의 실험을 통해 입력 이미지의 마스킹이 성능 향상에 크게 기여함에도 불구하고, Configuration-B의 실험을 통해서 분할의 성능이 저조하여 기대했던 만큼의 마스킹 결과를 얻지 못하였다. 결국 높은 수준의 균열 탐지를 위해서는 균열 유형에 따른 분할이 구분되어 학습될 필요가 있겠다. 이를 확인하기 위해 분할 모델과 객체탐지 모델을 결합하여 사용하되, 균열 유형에 따라 분할 모델이 달리 학습되도록 새로운 네트워크를 구성하였다.

<Figure 10>과 <Table 4>에 본 실험에서 최종적으로 사용된 모델의 구성과 테스트 결과



<Figure 10> Configuration-D

<Table 4> Test Result of Combined Models


	Class	mIoU	mAP
N3	Alligator, Longitudinal, Transverse	0.8650	0.9315
N4	Pothole, Patching	0.7920	

를 나타내었다. 앞서 Configuration-B에서 실험했던 3개의 분할 모델 중에서 성능이 가장 양호했던 U-Net을 균열 형태에 따라 달리 학습되어 사용되도록 하였다. 입력 이미지를 거북 등, 종방향 및 횡방향 균열로 묶어서 함께 학습하도록 N3 네트워크를 구성하였고, 포트홀과 패칭을 묶어서 함께 학습하도록 N4 네트워크로 구성하였다. 5개의 균열 유형에 대해서 한꺼번에 분할 모델을 학습하도록 구성한 Configuration-B의 결과와는 달리, Configuration-D에서는 개별 U-Net을 사용한 mIoU의 값이 기존의 0.4256에서 각각 0.8650과 0.7920으로 크게 개선된 것을 볼 수 있었다. 이것은 균열 유형에 변화에 견고한 동작을 보이는 객체탐지 모델과 달리, 분할 모델은 상대적으로 균열 유형의 변화에 민감하게 영향받기 때문에, 전체 균열탐지 프로세스의 성능을 향상시키기 위해서는 균열 유형에 특화된 형태로 분할이 학습될 필요가 있음을 의미한다고 하겠다.

4. 도로균열 탐지시스템

앞서 살펴본 4가지 구성의 실험 결과를 토대로 높은 성능의 도로균열 탐지시스템을 구축하기 위해서는 Configuration-D와 같이 균열 유형에 따라 특화된 분할 모델의 구성이 중요하다는 것을 알 수 있었다. 이러한 결과는 서로 다른 균열 유형에 맞는 분할을 진행하기 위해서, 그 앞 단계에서 다시 도로균열의 유형을 분류해야 하는 중복적인 처리를 유발하게 된다. 즉, 균열 유형과 범위를 동시에 탐지하기 위해 객체탐지 모델을 사용하게 되었는데, 객체탐지의 성능 향상을 위해 시스템에 추가된 이미지 분할 모델이 제 성능을 얻기 위해서 다시 도로균열의 유형에 따라 달리 학습될 필요성이 발생하게 되었고, 이것이 결국 그 전 단계에서 도로균열의 유형에 대한 분류 모델을 필요로 하게 된 것이다. 개념적으로 시스템의 전반부에 위치하게 될 분류 모델과 후반부에 위치하는 객체탐지 모델에서 도로균열의 유형을 식별하기 위한 중복적인 처리가 발생하고 있음을 알 수 있다. 이러한 도로균열 탐지시스템의 전체 구성을 <Figure 11>에 간략히 정리하였다.

제안되는 시스템 구성에서 개념적으로 중복적인 처리 요소가 존재하는 점은 있지만, 많은 기존 연구를 통해 도로균열의 유형에 대한 분류 모델은 상당히 높은 수준의 정확도를 보이는 결과가 다수 발표된 바가 있어서[2, 3, 14], 제시된 형태의 균열탐지 시스템을 실제 구성하여 운용하는 것은 그리 어렵지 않은 방법이라고 할 수 있겠다. <Figure 11>에서 분할을 위해 별도로 학습되어 사용되는 Model-1과 Model-2를 균열의 유형에 맞춰 더욱 세분화하면, 추가적인 성능 향상을 기대해 볼 수도 있을 것이다.



<Figure 11> Road Crack Detection System

향후 중복적인 처리가 발생하는 균열 유형의 분류를 제거하고 도로균열의 탐지에 최적화된 딥러닝 시스템을 구축하기 위해서는, 기존의 딥러닝 모델을 결합하여 활용하는 방법 외에도, 분할과 객체 탐지를 단일 모델로 처리하는 새로운 구조의 네트워크 모델을 설계하는 접근법이 필요해 보인다.

5. 결론 및 추후 연구과제

본 연구에서는 현재 육안 검사에 크게 의존하고 있는 도로포장 관리시스템의 균열탐지 프로세스를 자동화하기 위한 객체탐지 모델 기반의 접근법을 다루었다. 균열 심각도의 계산을 위해서는 균열 유형의 분류와 균열 영역의 검출이 모두 처리될 수 있는 객체탐지 모델의 활용이 크게 기대되지만, 효과적인 객체탐지 모델의 구성을 위해서는 입력 이미지의 균열 유형별 이미지 분할이 가능하도록 전체 모델이 복합적으로 구성될 필요가 있었다. 본 연구에서는 이러한 도로균열 탐지시스템의 제안을 위해 모두 4가지 구성의 실험환경을 설계하여

테스트하였다. U-Net과 Mobilenet-SSD를 결합하여 구성된 균열탐지 모델에서는 매우 높은 수준의 mIoU와 mAP 값을 얻을 수 있었으며, 이를 통해 기존의 딥러닝 모델을 효과적으로 결합함으로써 충분히 실용성을 갖춘 도로 균열 탐지시스템이 구현될 수 있음을 보일 수 있었다.

실제 균열탐지 시스템의 구현을 위해서는 입력 이미지의 자동화된 마스크가 가능하도록 사전에 개별 균열 유형에 맞추어 학습된 이미지 분할 모델이 필요하며, 이로 인해 도로균열의 분류 모델이 추가적으로 필요하다는 중복 처리의 문제가 발생하지만, 이는 기존의 딥러닝 모델을 결합하여 활용하는 접근법이 가지는 한계로 여겨지며, 추후 분할과 객체탐지를 통합적으로 처리하는 단일 네트워크 모델의 설계를 통해 심도있게 연구될 필요가 있겠다. 이어지는 연구에서는 기존의 도로균열 분류 모델까지를 결합하여 최종적인 균열탐지 시스템을 구축하고, 해당 시스템의 성능을 평가한 후, 균열 심각도까지를 산출할 수 있도록 확장하고자 한다. 본 논문의 연구 결과를 토대로 현업에 적용이 가능한 도로균열 탐지시스템의 구현이 더욱 가까워졌다고 기대한다.

References

- [1] Ashraf, S., Hegazy, I., and Elarif, T. L., "Algorithm for Automatic Crack Analysis and Severity Identification," 2019 IEEE Ninth International Conference on Intelligent Computing and Information Systems, pp. 74-79, 2019.
- [2] Cubero-Fernandez, A., Rodriguez-Lozano, F. J., Villatoro, R., Olivares, J., and Palomares, J. M., "Efficient pavement crack detection and classification," *EURASIP Journal on Image and Video Processing*, Vol. 39, pp. 1-11, 2017.
- [3] Feng, C., Liu, M. Y., Kao, C. C., and Lee, T. Y., "Deep active learning for civil infrastructure defect detection and classification," *Computing in Civil Engineering*, pp. 298-306, 2017.
- [4] Gopalakrishnan, K., "Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review," *Data*, Vol. 3, No. 3, pp. 1-19, 2018.
- [5] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., and Adam, H., "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [6] https://github.com/tensorflow/models/tree/master/research/object_detection.
- [7] Jo, H., Kim, D., Pak, K. W., and Kim, M., "Road damage detection over road scanner images using deep convolutional neural network," *ICIC Express Letters*, Vol. 14, No. 10, pp. 1001-1008, 2020.
- [8] Kim, M., Ryu, J., Cha, D., and Sim, M. K., "Stock Price Prediction Using Sentiment Analysis: from "Stock Discussion Room in Naver," *The Journal of Society for e-Business Studies*, Vol. 25, No. 4, pp. 61-75, 2020.

- [9] Kirillov, A., Girshick, R., He, K., and Dollar, P., "Panoptic Feature Pyramid Networks," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 6399-6408, 2019.
- [10] Koch, C. and Brilakis, I., "Pothole detection in asphalt pavement images," Advanced Engineering Informatics, Vol. 25, No. 3, pp. 507-515, 2011.
- [11] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., and Berg, A. C., "Ssd: Single shot multibox detector," European Conference on Computer Vision, Springer, Cham, pp. 21-37, 2016.
- [12] Naddaf-Sh, M., Hosseini, S., Zhang, J., Brake, N. A., and Zargarzadeh, H., "Real-time road crack mapping using an optimized convolutional neural network," Complexity, pp. 1-17, 2019.
- [13] Pauly, L., Hogg, D., Fuentes, R., and Peel, H., "Deeper networks for pavement crack detection," Proceedings of the 34th International Symposium on Automation and Robotics in Construction(ISARC), IAARC, pp. 479-485, 2017.
- [14] Rababaah, H., Vrajitoru, D., and Wolfer, J., "Asphalt pavement crack classification: a comparison of GA, MLP, and SOM," Proceedings of Genetic and Evolutionary Computation Conference, Late-Breaking Paper, 2005.
- [15] Ragnoli, A., De Blasiis, M. R., and Benedetto, A. D., "Pavement Distress Detection Methods: A Review," MDPI Infrastructure, Vol. 3, No. 58, pp. 1-19, 2018.
- [16] Ronneberger, O., Fischer, P., and Brox, T., "U-net: Convolutional networks for biomedical image segmentation," International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, Cham, pp. 234-241, 2015.
- [17] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C., "Mobilenetv2: Inverted residuals and linear bottlenecks," Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 4510-4520, 2018.
- [18] Sorncharean, S. and Phiphobmongkol, S., "Crack detection on asphalt surface image using enhanced grid cell analysis," 4th IEEE International Symposium on Electronic Design, Test and Applications, pp. 49-54, 2008.
- [19] Yang, F., Zhang, L., Yu, S., Prokhorov, D., Mei, X., and Ling, H., "Feature Pyramid and Hierarchical Boosting Network for Pavement Crack Detection," IEEE Transactions on Intelligent Transportation Systems, Vol. 21, No. 4, pp. 1525-1535, 2020.
- [20] Yoo, W., Seo, J., Kim, D., and Kim, K., "Machine Scheduling Models Based on Reinforcement Learning for Minimizing Due Date Violation and Setup Chang," The Journal of Society for e-Business Studies, Vol. 24, No. 3, pp. 19-33, 2019.
- [21] Yoo, W., Seo, J., Lee, D., Kim, D., and Kim, K., "Scheduling Generation Model on Parallel Machines with Due Date and

- Setup Cost Based on Deep Learning,” The Journal of Society for e-Business Studies, Vol. 24, No. 3, pp. 99-110, 2019.
- [22] Zhang, A., Wang, K. C., Li, B., Yang, E., Dai, X., Peng, Y., Fei, Y., Liu, Y., Li, J. Q., and Chen, C., “Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep learning network,” Computer-Aided Civil and Infrastructure Engineering, Vol. 32, No. 10, pp. 805-819, 2017.
- [23] Zhang, L., Yang, F., Zhang, Y. D., and Zhu, Y. J., “Road crack detection using deep convolutional neural network,” Proceedings of the 2016 IEEE International Conference on Image Processing(ICIP), Phoenix, AZ, USA, 25-28 September 2016, pp. 3708-3712, 2016.

저 자 소 개



하종우

2014년~2018년

2018년~2020년

2020년~현재

관심분야

(E-mail: hejooyy@pukyong.ac.kr)

부경대학교 시스템경영공학부 (공학사)

부경대학교 기술경영대학원 (석사)

부경대학교 산업및데이터공학과 (박사과정)

Data Engineering, Machine Learning, Deep Learning, Computer Science 등



박경원

1999년

2008년

2005년~2012년

2012년~2015년

2016년~현재

관심분야

(E-mail: pkw4425@naver.com)

경희대학교 토목공학과 (공학석사)

University of Rhode Island 토목공학과 (공학박사)

영종산업 주식회사 연구소장

US Army Corps of Engineers, Engineer

주식회사 한국포장기술 대표이사

도로관리시스템, 도로포장품질관리시스템 등



김민수

1996년

2002년

2004년~2016년

2016년~2018년

2018년~현재

관심분야

(E-mail: minsky@pknu.ac.kr)

서울대학교 산업공학과 (공학석사)

서울대학교 산업공학과 (공학박사)

부경대학교 시스템경영공학부 교수

부경대학교 기술경영전문대학원 교수

부경대학교 시스템경영공학부 교수

e-Business Standards, BPM, Big Data, Computational Intelligence 등