

교량 부재별 모델 결합 프레임워크를 통한 개선된 딥러닝 기반 교량손상객체 자동 검출 모델

A Deep Learning-based Bridge Damaged Objects Automatic Detection Model using Bridge Members Model Combination Framework

홍성삼¹, 황철훈², 정수완³, 김병곤^{4*}

Sung-Sam Hong¹, Cheol-hoon Hwang², Su-wan Chung³, Byung-Kon Kim^{4*}

요약

노후화되고 유지관리가 필요한 교량은 증가하고 있으나, 유지관리 인력은 부족하다. 이를 해결하기 위해 딥러닝 기반 자동화된 교량 손상 분석을 위한 연구가 이루어지고 있다. 딥러닝은 여러 클래스를 분류할 경우 성능 저하의 문제를 갖는다. 해결 방법으로 많은 양의 학습데이터를 확보하거나 클래스별 모델을 학습하여 결합하는 방법이 있다. 본 논문에서는 이러한 문제를 해결하기 위해 부재별 개별 학습 기반 교량손상 식별 딥러닝 결합 모델 프레임워크를 제안한다. 클래스 간의 특징의 유사성과 차별성을 반영하기 위해 교대, 슬래브 등 손상 유형을 부재별로 구분하여 모델 학습을 진행한다. 최종적으로 모델 결합 방식을 통해 부재별 교량 손상 식별 모델을 하나의 프레임워크로 구축하여 교량 손상을 식별한다. 부재별 교량 손상을 식별하는 모델은 Instance Segmentation 모델인 Blendmask를 대상으로 하였다. 이는 입력 이미지 크기가 객체 탐지로부터 나타나는 영향이 적기 때문이다. 이전에 제안한 딥러닝 기반의 SR(Super-Resolution) 기술을 통해 이미지를 정규화 하는 기술과 연계성을 갖는다. 제안하는 모델은 실험 결과 기존 보다 112.21%의 정확도(mAP)를 보였다.

핵심어 : 딥러닝, 노후 교량 관리, 이미지 분석, 이미지 처리, 모델 결합

Abstract

Although the number of aging bridges to be maintained is increasing, systematic management is difficult due to the stagnancy in management manpower. To solve this problem, research for bridge damage analysis

1 Department of Multimedia Contents, Jangan University, Gyeonggi-do, Korea [Graduate student]
e-mail: sunsamhong@jangan.ac.kr

2 Department of Research&Development, Rabahgrow corporation, Gyeonggi-do, Korea [Researcher]
e-mail: qewqsa@naver.com

3 Department of Future and Smart Construction Research, KICT, Gyeonggi-do, Korea [Researcher]
e-mail: suwan@kict.re.kr

4 Department of Future and Smart Construction Research, KICT, Gyeonggi-do, Korea [Research Fellow]
e-mail: bkkim@kict.re.kr (Corresponding author)

* 본 연구는 과학기술정보통신부 한국건설기술연구원 연구운영비지원(주요사업)사업으로 수행되었습니다(과제번호 20220217-001, DNA 기반 노후 교량 구조물 스마트 유지관리 플랫폼 및 활용기술 개발). 연구 지원에 감사드립니다.

Received(October 3, 2022), Review Result(1st: November 2, 2022), Accepted(February 10, 2023), Published(February 28, 2023)



© 2023 The Authors. Published by NCISS.
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

based on deep learning is being conducted. A bridge damage recognition study based on deep learning has a problem of performance degradation when classifying multiple classes. As a solution, there is a method to secure a large amount of training images or to learn and combine models for each class. In this paper, to solve the problem of classifying multiple classes, we propose a deep learning combined model framework for each subtitle-based individual learning-based bridge damage identification. In order to reflect the similarity and differentiation of features between classes, model learning is carried out by classifying damage types such as abutments and slabs by subtitle. Finally, bridge damage is recognized by building a bridge damage recognition model for each member as a framework through the model combination method. Blendmask(instance segmentation model) were the models for recognizing bridge damage by subtitle. This is because the input image size has little effect from object detection. It has a connection with image normalization technology through the previously proposed deep learning-based SR (Super-Resolution) technology. Our proposed model, as a result of the experiment, the accuracy was 112.21%(mAP) higher than that of the previous one.

Keyword : Deep learning, aging bridge management, image analysis, image processing, classifier combination

1. 서론

손상된 시설물로부터 불의의 사고를 방지하기 위해 주기적으로 시설물 점검을 실시한다. 하지만 시설물 점검 시 관리 대상이 되는 시설은 지속적으로 증가하는 반면 담당 유지관리 인력은 정체 추세로 체계적인 유지 관리가 어렵다 [1-3]. 이는 도로에서 중추 역할을 하는 교량도 마찬가지이다.

대부분 교량 손상을 판단하기 위해서 시설물 유지관리 전문가를 통해 점검된 교량의 손상도를 판단하고 있다. 이러한 수동 검사는 교량 점검 및 전문 인력이 필요하기에 비용이 많이 소모되며, 점검자의 손상 교량에 대한 촬영 각도, 위치 등에 수집 환경에 영향과 전문가의 지식 및 경험에 영향을 받아 교량 손상 판단에 신뢰성 문제를 야기할 수 있다.

이를 해결하기 위해 다양한 연구가 활발히 이루어지고 있다. 초기 연구에서는 점검된 교량 표면에서 균열을 검출하는 것을 목적으로 하였으며, 이는 노후 교량의 손상 유형 대부분이 균열로부터 파생되기 때문이다. 균열의 경계선을 검출하기 위한 Canny, Crack-Forest 등과 같은 알고리즘을 이용하거나 그래프 합성곱 신경망(GCN, Graph Convolutional Network)과 같은 머신러닝 기술을 이용하였다 [2]. 최근 연구는 드론과 같은 무인동체 및 이미지 처리 기술을 이용한 지능형 교량 검사 시스템 및 점검 기술 등에 대한 연구 [1][4-6]가 이루어지고 있다.

알고리즘 및 머신러닝을 이용한 이미지 처리 기술 연구는 문제를 가지고 있다. 특히, 수집된 교량 점검 이미지에 영향을 받는다. 학습할 데이터의 양과 점검된 교량 이미지에 따라 결과가 달라질 수 있다 [2]. 학습된 교량 이미지의 표면 재질과 형태가 달라짐에 따라 학습된 알고리즘 및 머신러닝의 파라미터 또는 하이퍼 파라미터 값이 달라져 성능저하가 나타날 수 있기 때문이다.

최근 연구에서는 딥러닝(Deep-Learning) 기술을 이용한 시설물 평가 기법연구 [1][2][4][7-10]가 활발히 진행되고 있다. 학습 이미지를 활용한 분류, 객체 탐지에 있어서 합성곱 신경망(CNN, Convolutional Neural Network)이 우수한 성능을 보이고 있다. 시설물의 균열, 박리, 부식 등 총 6가

지 손상 유형을 검출하기 위해 DCNN(Deep Convolutional Neural Networks)을 이용 [10]하였으며, 국내에서는 Faster-RCNN을 이용한 철도 교량 손상 탐지 [1], AlexNet을 이용한 박락 탐지 [7] 등 연구가 이루어졌다. 딥러닝 기술을 이용한 연구의 문제점은 학습 이미지에 따라 성능 차이가 발생한다는 점과 분류할 클래스의 특징이 적거나 뚜렷하지 않을 경우 분류가 어렵다는 점이다. 딥러닝 기술의 특성상 학습 대상의 수가 많을수록 분류 정확도가 높아진다. 후자에 대한 내용은 다음과 같다. 교량 손상 유형인 백태, 부식, 균열, 박리, 박락 등을 분류할 경우, 교량에 흰색으로 나타나는 백태와 균열이 나타나는 박리, 박락, 균열 간의 분류는 높은 성능을 보일 수 있으나, 비슷한 계열인 균열, 박리, 박락 사이의 분류는 낮은 성능 보일 수 있다.

이전 연구에서는 학습 이미지에 대한 기술 [3]을 제안하였다. 수집된 데이터 중 저화질로 촬영된 교량 이미지를 학습에 활용하기 위한 방법으로 SR(Super-Resolution)을 이용하여 학습모델에 적합한 형태의 이미지로 정규화 및 데이터 증강을 위한 기술이다. 이는 해상도 증가 및 적절한 레이블링을 통해 작은 객체 탐지도 가능했으며, 기존 교량 손상 탐지 모델들과 유사하거나 우수한 성능이 나타났음을 확인하였다.

본 논문에서는 여러 교량 손상 유형을 탐지하기 위한 방법으로 부재별 개별학습 기반 교량손상 식별 딥러닝 결합 모델 프레임워크를 제안한다. 분류할 클래스 간의 형상 및 특징이 유사하거나 판이하게 다르다는 점을 반영하기 위해 교대, 슬래브 등 손상 유형의 부재별로 모델을 학습한다. 이를 모델 결합 방법을 착안하여 각 학습 모델을 하나의 딥러닝 프레임워크로 구축한다. 제안하는 모델은 실험 결과 기존 보다 112.21%의 정확도(mAP)를 보였다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문과 관련된 연구들을 소개하였고, 3장에서는 제안하는 기술을 서술하였다. 4장에서는 제안하는 기술의 성능을 평가하기 위한 실험결과를 설명하였고, 5장에서 결론을 맺는다.

2. 관련연구

2.1 교량 손상 연구

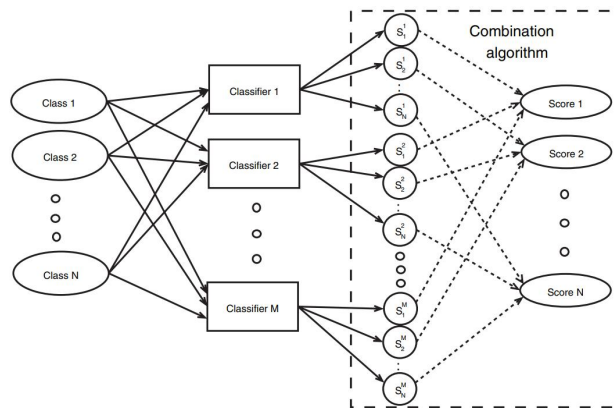
무인이동체와 딥러닝 기반 철도교량 자동 손상 분석 방법연구 [1]에서 균열, 박리, 박락, 누수, 철근노출에 대한 손상 유형을 딥러닝 모델을 통해 탐지하는 연구를 진행하였다. 학습 이미지는 손상이 많은 C등급 이하의 시설물을 대상으로 촬영된 약 26,476장의 수집된 이미지를 활용하였다. 선명도, 흐림, 색조, 채도 등의 이미지 처리 기법을 적용하여 이미지 전처리를 진행하였으며, Light Head-RCNN, FPN, PSPNet, U-Net에 대한 실험을 진행하였다. 26,476개의 손상 이미지 중 무작위 80%는 모델 학습을 수행, 20%에 해당하는 5,295개에 대한 테스트를 진행하였다. U-Net을 이용하였을 때, 균열 96%, 박리박락 98%, 철근노출 98%, 누수 92% 등으로 결과를 보였다. 해당 연구에서는

비슷한 손상 유형은 하나의 유형으로 통합시켰으며, 하나의 모델에 여러 손상 유형을 학습하였다.

교량 상태평가를 위한 딥러닝 연구 [2]에서는 균열과 박락, 부식 등 교량 손상의 여러 종류를 판단하기에는 한계가 있음을 강조하였다. 다수 유형을 분류하기 위한 다양한 종류의 많은 양의 학습 데이터 구축이 필요함을 해결 방법으로 설명하였다. 해당 연구에서는 이미지 분할, 회전 등 기법을 통해 데이터 증강 기술과 전이학습을 통해 문제점을 해결하고자 하였다. 딥러닝 모델로는 Mask R-CNN과 U-Net을 비교하며 연구를 진행하였다. 두 모델 모두 객체의 검출, 분류, 분할이 실시간으로 가능하다는 장점이 있기에 선택하였다. 학습 이미지는 최대 1024x1024 픽셀 이미지를 학습하였으며, 윈도우 슬라이딩 기법을 통해 손상검출 및 정량화 문제를 극복하였다. 실험을 통해 Mask R-CNN이 1000x800 픽셀의 입력 사이즈로 상대적으로 크고 적은 양의 학습데이터로도 전이학습이 가능하다는 점에서 모델에 적합하다고 판단하였다. 최종 5,140장의 학습 데이터를 통해 연구를 진행하였으며, 정밀도는 95.2%, 재현율은 93.8%의 결과를 보였다. 해당 연구는 다수 유형 분류 시 나타날 수 있는 한계점에 대한 해결 방안을 제시하였다. 본 연구에서 제안하는 각각의 유형을 분류하여 모델 결합 방식을 통한 해결 방안과는 다른 학습 데이터양을 증가시킴으로써 해결하고자 하였으며, 좋은 성능의 연구 결과를 보였다.

2.2 Classifier Combination

Classifier Combination은 패턴 인식의 성능을 높이는 효과적인 방법이다 [11]. 경제, 자연현상 예측, 국방 등 여러 영역에 활용되고 있으며, 수학적 접근(mathematical approaches)과 행동적 접근(behavioral approaches)법이 있다. 수학적 접근은 논리와 통계를 사용하는 모델을 구성, 조합 규칙을 도출하여 여러 분류 모델 및 결과를 통합하는 방법, 행동 접근은 해당 분야의 전문가 등을 통해 여러 결과를 하나로 통합하는 방법이다. Classifier Combination은 [그림 1]의 기본 구조를 가진다.



[그림 1] Classifier Combination 구조 [11]


[Fig. 1] Classifier Combination Structure

Classifier Combination은 지난 10년간 문자 및 생체 인식 분야에서 활발히 연구되었다. 인식, 얼굴 이미지, 지문 또는 생체 특성에 대한 이미지 분류 등에 활용되었다. 이는 M개의 분류 모델로부터 N차원의 벡터 정보로 변환할 수 있으며, 조합 규칙 또는 모델 정의를 통해 최종적으로 문제에 대한 결과를 재정의할 수 있다. 이는 결과를 위한 최적 모델을 정의할 수 있으며, 오분류 문제를 최소화할 수 있다는 장점이 있다. Classifier Combination은 여러 방식으로 정의할 수 있다. 점수 조합 함수(Score Combination Function) 정의, 앙상블(Ensembles), 작동 수준에 따른 분류(Operating Level of Classifiers), 결과 유형에 따른 분류 결합, 복잡한 유형에 따른 분류 결합 등이 있다.

2.3 딥러닝 기반 이미지 분류 모델

2.3.1 Yolo

Yolo [12]는 사람이 이미지의 물체들에서 세부 특징을 한눈에 파악할 수 있는 인지 과정을 반영한 모델이다. 기존 R-CNN과 같은 Object Detection 모델의 문제인 복잡한 처리과정을 단순화하기 위한 방법으로 제안되었다. 기존 객체 탐지 모델과 비교했을 때, 처리과정이 단순하여 실시간 탐지 시스템에 적합한 모델로 활용되었다. Yolo는 [그림 2]와 같은 방식으로 객체를 탐지한다. Yolo는 일정 크기로 분할된 영역(Grid Cell)에 대하여 하나의 클래스만 예측하기 때문에 탐지하기 위한 객체가 이미지 안에 겹쳐있다면 예측이 어렵다는 단점이 있다. 또한 여러 단계의 층(Layer)를 통해 나온 Feature Map을 대상으로 예측하기 때문에 이미지 내의 탐지 위치가 부정확하게 나올 수 있다.




[그림 2] Yolo 객체 탐지 구조 [12]

[Fig. 2] Yolo for Object detection structure

2.3.2 Mask R-CNN

Mask R-CNN [13]은 인스턴스 세분화(Instance segmentation)모델이다. Fast R-CNN 기반으로 한 모델이다. 인스턴스 세분화는 이미지 내에 존재하는 모든 객체를 탐지하는 동시에 각각의 인스턴스(Instance)를 정확하게 픽셀 단위로 분류하는 기술이다. Mask R-CNN은 객체 탐지와 의미론적 인스턴스가 결합된 모델로 [그림 3]과 같은 구조를 갖는다. Mask R-CNN은 학습하기 위해 학습 이미지와 분류 정보를 사전에 정의해야 되며, 학습 데이터의 양과 질에 따라 성능에 차이를 갖는다.

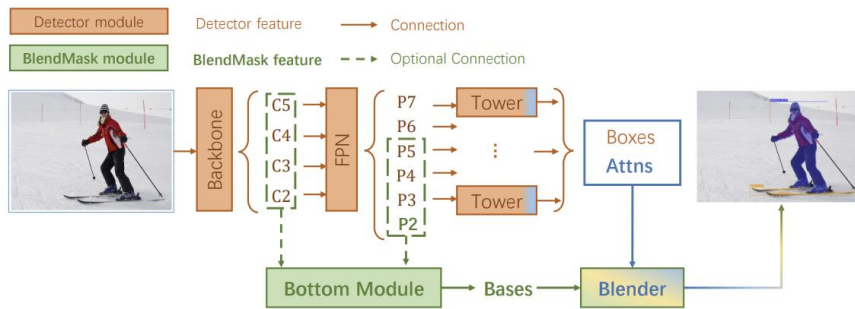


[그림 3] Mask R-CNN framework for instance segmentation [13]

[Fig. 3] Mask R-CNN framework for instance segmentation

2.3.3 Blendmask

Blendmask는 기존의 two stage 모델들의 속도적 한계를 극복하기 위해 one stage 모델로 설계된 인스턴스 세분화 모델로 인스턴스 수준 정보와 더 낮은 수준의 세분화된 의미 정보를 효과적으로 결합하여 향상된 마스크 예측을 구현한 모델이다 [14]. Top-down 및 Bottom-up 인스턴스 세분화 접근 방식으로 설계된 블렌더 모듈이 핵심 특징이며, [그림 4]와 같은 구조이다. 단 하나의 컨볼루션 레이어로 각 인스턴스에 대한 추론 속도가 빠른 것이 특징이다.

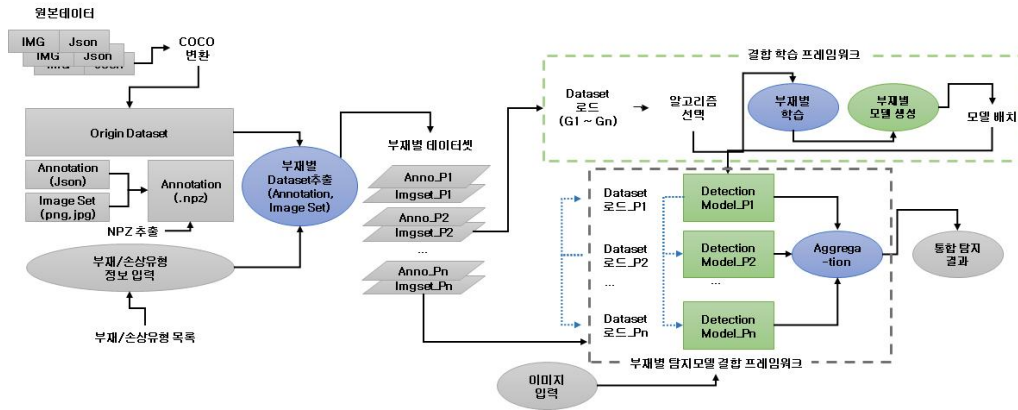


[그림 4] Blendmask for instance segmentation [14]

[Fig. 4] Blendmask for instance segmentation

3. 부재별 개별학습 기반 교량손상식별 딥러닝 결합 모델 프레임워크

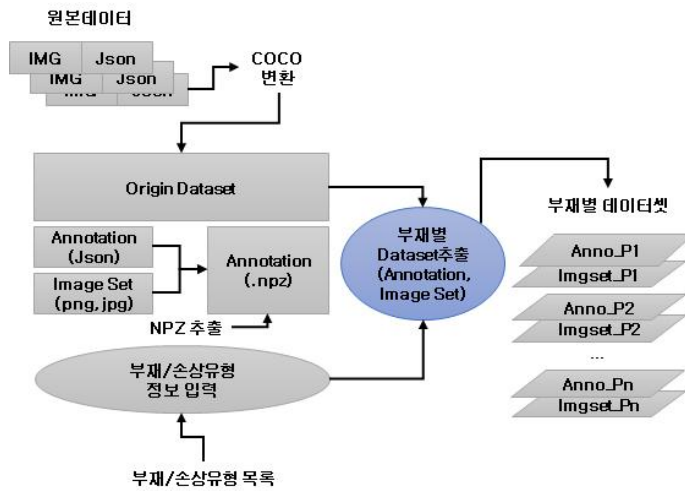
본 논문에서는 부재별 개별학습 기반 교량손상식별 딥러닝 결합 모델 프레임워크를 제안하였다. 제안하는 시스템의 개념은 [그림 5]와 같다. 제안하는 시스템은 크게 세 가지의 단계를 가지며, 두 개의 프레임워크가 존재한다.



[그림 5] 제안하는 시스템 구조
 [Fig. 5] Concept of Proposal System

3.1 부재별 데이터셋 추출


부재별 데이터셋 추출 단계에서는 딥러닝 모델에 학습을 위한 학습 데이터를 최적화 및 전처리 하는 단계이다. 수집된 교량 이미지를 손상 유형과 부재에 대한 레이블링 작업을 진행하며, 레이블 내용 기반으로 npz 데이터 구조로 추출하여 GPU에 적합한 데이터 타입으로 변형한다. 레이블링은 labelme [15] 도구를 사용하여, 최종 부재별 Annotation 및 Image Set 형태의 데이터 셋을 구축한다. [그림 6]은 부재별 데이터셋 추출 시스템 구조를 나타내고 있다.



[그림 6] 부재별 데이터셋 추출 시스템 구조
 [Fig. 6] Concept of Dataset Extraction by Members

3.2 결합 학습 프레임워크

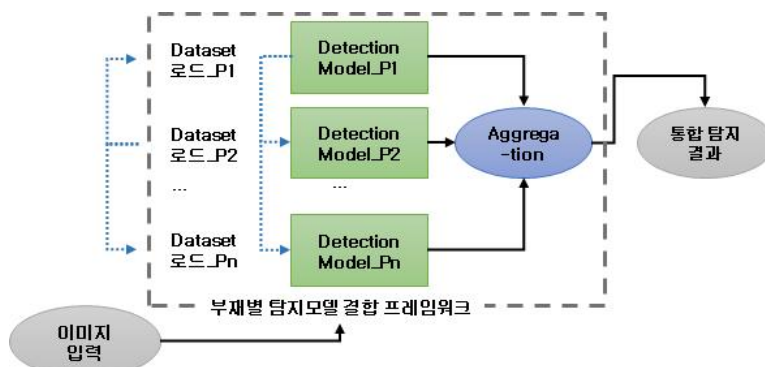
부재별 교량 손상 객체의 특징을 분석하여 식별에 최적화된 딥러닝 모델을 개발하는 단계이며 [그림 7]에 나타나 있다. 앞서 구축된 부재별 이미지넷을 효과적으로 학습하여, 도출된 모델을 튜닝을 통해 식별 성능이 우수한 모델을 개발한다. R-CNN 계열의 딥러닝 모델들인 Mask R-CNN, Blendmask, Yolov3(R-CNN) [16]를 손상 객체 식별을 위한 모델을 대상으로 연구를 진행하였으며, 선행 연구들을 통해 빠른 탐지 시간, 큰 사이즈 이미지 분류에 효과적임을 확인하였다. 이전 연구에서 업스케일링 기법을 통한 이미지 해상도 개선을 통한 고해상도 이미지 최적화 및 정규화와 연계성을 갖는다. 학습이 완료된 후 생성된 식별 모델을 손상 객체 식별에 사용하여 새로운 교량 이미지가 입력되면, 이미지 내 손상 객체를 자동으로 식별해낸다. 속도, 정확성, 등을 측정하는 측정치를 통해 가장 최적화된 모델을 식별모델로 사용한다. R-CNN 계열의 모델들은 물체 영역 추정 및 물체 인식 프로세스 간 병목현상으로 검출 시간이 오래걸릴 수 있어, 대규모의 네트워크를 처리할 수 있는 고성능 GPU가 필요하다 [17].



[그림 7] 결합 학습 프레임워크 개념도

[Fig. 7] Concept of Model Combination Framework

3.3 부재별 탐지모델 결합 프레임워크



[그림 8] 부재별 탐지모델 결합 프레임워크 개념도

[Fig. 8] Concept of Combined Detection Model Framework by Members

[그림 8]과 같이 부재별 학습된 모델(Detection Model)은 부재의 수인 n만큼의 수를 갖으며, Aggregation 모듈을 통해 결합된다. 부재별 학습된 모델(Detection Model)은 각각의 부재별 데이터셋을 통해 학습된 모델이다. 새로운 이미지에 대해 결합 모델을 통해 최종 탐지 결과를 도출한다.

4. 실험 및 결과

4.1 실험 환경

실험에 사용된 장비환경은 아래와 같다. 구축된 검출 모델 성능 테스트를 위해 GPU가 내장된 시스템에서 실험을 진행하였다. 프로그래밍으로 사용된 언어는 Python이다.

CPU : Intel(R) Core(TM) i7-10900k CPU 2.90GHz / RAM : 96GB

GPU : NVIDIA GeForce RTX3090 24GB

4.2 화질개선 실험 결과

사용된 모델의 각 파라미터는 아래 [표 1]과 같다. 기본적으로 백본이 101 계층 깊이를 가진 Resnet을 기반한 모델로 셋팅하여 실험하였다.

[표 1] Blendmask 주요 Parameter

[Table 1] Blendmask Main Parameter

Blendmask
BACKBONE: NAME: "build_fcos_resnet_fpn_backbone" , DEPTH : 101
ROI_HEADS: BATCH_SIZE_PER_IMAGE: 512
SOLVER: BASE_LR: 0.01, BIAS_LR_FACTOR: 1.0, MOMENTUM: 0.9, WARMUP_METHOD: linear, WEIGHT_DECAY: 0.0001

4.2.1 측정방법

대표적인 정확도 측정 방법인 AP(Average Precision)값 [18]을 사용하였다. 모델이 예측한 영역에 대해 IoU(Intersection over Union) [19]를 측정하여, 일치비율에 따라 class를 정상분류했는지 판단하는 지표이다. AP50는 정답과 예측 영역이 50%이상 일치하면, 분류에 성공한 것으로 간주하여 산출하며, AP 75는 75%이상이다. APs/APm/API는 50~95% 일치한 모든 결과에 대해서 class 분류에 성공한 것으로 간주하는 것의 기준을 대상 객체의 크기를 기준으로 s(small)/m(medium)/l(large)별 AP성능을 측정한 값이다. mAP는 모든 AP 성능 수치의 평균으로 모델의 평균 성능을 표현한다.

4.2.2 부재별 최적화 모델 예측 성능 실험 및 평가




[그림 9] 교량의 부재 유형

[Fig. 9] Type of Bridge Members



(a) 손상 유형 : 백태 탐지 결과



(b) 손상 유형 : 박리 및 박락 탐지 결과

[그림 10] 교량 손상 유형 및 탐지 결과 이미지

[Fig. 10] Result Image of Bridge Damaged Object Type and Detection

실험에 공통적으로 사용한 손상 유형은 [그림 9]와 같이 백태/박리/박락/균열/누수/철근부식 총 6개의 유형을 학습하여 사용하였지만, 부재별로 나타나지 않는 손상과 수량이 매우 적은 유형은 제외하였다. 단, 탐지 성능값(mAP 등)은 전체 유형에 대한 성능이다. 부재 중 교대교각/슬라브/난간 3가지 부재별 모델을 생성하여 성능을 테스트하였다. validation에 사용된 이미지는 각 20장의 부재별 이미지를 실험에 사용하였다. 각 부재별로 학습은 총 75,000 epoch을 수행하고 평가하였다.

탐지결과의 시각적 표현은 [그림 10]과 같다. 부재별로 모델이 최적화되어 성능이 향상되었는지를 평가하기 위해, 비교 대상으로 기존의 부재별로 구분하지 않은 모든 부재 이미지에 대해 손상 객체를 학습한 통합 모델의 성능을 측정하였다. 먼저 기존 모델의 실험 결과는 아래 [표 2]와 같다

[표 2] 기존모델(모든 부재 통합)의 손상객체 탐지 성능 결과

[Table 2] Damaged Object Detection Performance Results for Existing Models (All Members Integrated)

Measure	기존 모델
AP50	89.934
AP75	87.750
APs	67.388
APm	89.806
API	97.048
mAP	81.184

기존모델은 AP 50 기준 89.934의 정확도를 나타냈으며, 큰 객체의 경우 97.048, 작은 객체의 경우 67.388의 성능 결과를 나타냈다. 기존 모델도 일반적으로 준수한 성능을 나타내는 것을 확인할 수 있었다.

[표 3] 부재별 모델의 손상객체 탐지 성능 결과

[Table 3] Damaged Object Detection Performance Results for Member Specific Models

Measure	교대교각 모델	슬라브 모델	난간 모델	부재별모델 평균
AP50	92.871	100	94.257	95.71
AP75	92.871	100	94.257	95.71
APs	70.677	94.718	80.889	82.09
APm	94.326	97.949	86.888	93.05
API	98.389	100	98.195	98.86
mAP	90.470	96.426	86.409	91.10

[표 3]은 부재별 모델의 탐지 성능 실험 결과이다. 각 모델별로 기존 통합 모델에 비해 전체적인 성능 지표가 향상된 것을 볼 수 있었다. 부재별로 나타나는 손상 유형별 구조나 형상이 다르기 때

문에 분리해서 학습하여 최적화한 제안하는 모델의 방식이 기존 모델에 비해 성능이 향상된다는 것을 확인할 수 있었다. 부재별 모델의 성능 지표를 종합한 결과 기존의 통합 모델에 비해 약 112%가량 mAP 성능이 향상된 것을 볼 수 있었다.

[표 4]는 손상의 유형별로 각 부재별 모델이 탐지하는 성능을 구분해서 표시한 결과이다. 전반적으로 박리 박락을 탐지하는 성능이 높은 것으로 볼 수 있으며, 슬라브에 경우 백태의 형상이 교대 교각이나 난간에 비해 일관성이 있으므로 상대적으로 mAP성능이 높게 나타난 것을 알 수 있었다.

[표 4] 손상유형에 따른 부재별 모델의 손상객체 탐지 성능 결과

[Table 4] Damaged Object Detection Performance Results of Member Specific Models by Damage Type

Measure(mAP)	교대교각 모델	슬라브 모델	난간 모델
백태	90.614	92.525	84.050
박리	98.064	94.863	89.894
박락	98.069	100	90.470

결론적으로, 실험을 통해 제안하는 모델은 손상객체 유형을 탐지하는 전반적인 성능을 개선하는 모델임을 확인할 수 있었으며 부재별로 최적화된 모델을 생성하는 것은 손상유형의 자동검출 모델의 성능을 향상시키는 방법임을 검증할 수 있었다.

5. 결론

교량 손상 개체를 자동 검출함에 있어서 딥러닝 기술을 이용한 연구의 문제점은 학습 이미지에 따라 성능 차이가 발생한다는 점, 목표 객체의 형상에 따라 성능이 차이가 난다는 점이다. 본 논문에서는 여러 교량 손상 유형을 탐지하기 위한 방법으로 부재별 개별학습 기반 교량손상 식별 딥러닝 결합 모델 프레임워크를 제안하였다. 부재별로 손상유형에 따라 나타나는 형상이 크게 상이하므로 모든 부재에 대해서 하나의 모델로 학습하고 탐지하는 것은 탐지 성능에 한계가 나타난다. 따라서 부재별로 최적화된 모델을 구축하여, 개별 모델을 통해 각 손상유형을 탐지하고 결과를 결합하는 프레임워크를 제시하였다. 실험결과 기존의 모델에 비해 약 112%의 mAP 성능이 향상된 것을 확인할 수 있었다.

향후 연구로는 다수의 모델을 앙상블하여 instance segmentation 성능을 개선할 수 있는 모델을 연구하고자 하며, 부재별/모델별 파라미터 튜닝을 통해 최적화된 교량의 손상 객체 자동 검출 모델을 연구하고자 한다.

References

- [1] Y. H. Na, M. Y. Park, "A Study of Railway Bridge Automatic Damage Analysis Method Using Unmanned Aerial Vehicle and Deep Learning-based Image Analysis Technology", *Journal of the Society of Disaster Information*, vol. 17, no. 3, September 2021, pp. 556-567, doi: 10.15683/KOSDI.2021.9.30.556.
- [2] W. S. Nam, H. Jung, K. H. Park, C. M. Kim, G. S. Kim, "Development of Deep Learning-Based Damage Detection Prototype for Concrete Bridge Condition Evaluation", *KSCE Journal of Civil and Environmental Engineering Research*, vol. 42, no. 1, February 2022, pp. 107-116. doi: 10.12652/KSCE.2022.42.1.0107.
- [3] S. S. Hong, C. H. Hwang, H. K. Kim, B. K. Kim, "A Deep Learning-based Bridge Image Pretreatment and Damaged Objects Automatic Detection Model for Bridge Damage Management", *Journal of Next-generation Convergence Information Services Technology*, vol. 10, no. 5, October 2021, pp. 497-511, doi: 10.29056/jncist.2021.10.03.
- [4] D. Y. Choi, S. H. Paik, Y. K. Kim, S. W. Jung, D. N. Kim, "Deep-Learning Crack Analysis for Visual-Safety Inspection of Bridge by Drones", *Journal of Korean Institute of Information Technology*, vol. 19, no. 12, December 2021, pp. 115-121, doi: 10.14801/jkiit.2021.19.12.115.
- [5] A. Ellenberg, A. Koutsos, I. Bartoli, A. Pradhan, "Masonry crack detection application of an unmanned aerial vehicle.", 2014 International Conference on Computing in Civil and Building Engineering, June 23-25, 2014, Orlando, Florida, USA, pp. 1788-1795, doi: 10.1061/9780784413616.222
- [6] H. Kim, S. H. Sim, S. Cho, "Unmanned aerial vehicle (UAV)-powered concrete crack detection based on digital image processing", 6th International Conference on Advances in Experimental Structural Engineering, 11th International Workshop on Advanced Smart Materials and Smart Structures Technology, August 1-2, 2015, IL, USA.
- [7] Y. I. Lee, B. H. Kim, S. J. Cho, "Image-based Spalling Detection of Concrete Structures Using Deep Learning", *Journal of the Korea Concrete Institute*, vol. 30, no. 1, February 2018, pp. 91-99, doi: 10.4334/JKCI.2018.30.1.091.
- [8] S. Y. Jung, S. K. Lee, C. I. Park, S. Y. Cho, J. H. Yu, "A Method for Detecting Concrete Cracks using Deep-Learning and Image Processing", *Journal of the Architectural Institute of Korea Structure & Construction*, vol. 35, no. 11, November 2019, pp. 163-170, doi: 10.5659/JAIK_SC.2019.35.11.163.
- [9] A. R. Kim, D. H. Kim, Y. S. Byun, S. W. Lee, "Crack Detection of Concrete Structure Using Deep Learning and Image Processing Method in Geotechnical Engineering", *Journal of the Korean Geotechnical Society*, vol. 34, no. 12, December 2018, pp. 145-154, doi: 10.7843/kgs.2018.34.12.145.
- [10] V. Hoskere, Y. Narazaki, T. Hoang, B. Spencer Jr, "Vision-based structural inspection using multiscale deep convolutional neural networks", 3rd Huixian International Forum on Earthquake Engineering for Young Researchers, August 11-12, 2017, Urbana, IL, USA.
- [11] S. Tulyakov, S. Jaeger, V. Govindaraju, D. Doermann, "Review of Classifier Combination Methods", *Machine Learning in Document Analysis and Recognition*, Springer Berlin, Heidelberg, December 2007, pp. 361-386, doi: 10.1007/978-3-540-76280-5_14.
- [12] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You Only Look Once: Unified, Real-Time Object

- Detection”, IEEE conference on computer vision and pattern recognition, June 27-30, 2016, pp. 779-788, Las Vegas, NV, USA, doi: 10.1109/CVPR.2016.91.
- [13] K. He, G. Gkioxari, P. Dollár, R. Girshick, “Mask R-CNN”, 2017 IEEE International Conference on Computer Vision (ICCV), December 25, 2017, Venice, Italy, pp. 2980-2988, doi: 10.1109/ICCV.2017.322.
- [14] H. Chen, K. Sun, Z. Tian, C. Shen, Y. Huang, Y. Yan, “BlendMask: Top-Down Meets Bottom-Up for Instance Segmentation”, 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, June 13-19, 2020, pp. 8570-8578, doi: 10.1109/CVPR42600.2020.00860.
- [15] A. Torralba, B. C. Russell, J. Yuen, “LabelMe: Online Image Annotation and Applications”, Proceedings of the IEEE, vol. 98, no. 8, pp. 1467-1484, August 2010, doi: 10.1109/JPROC.2010.2050290.
- [16] J. Redmon, A. Farhadi, “Yolov3: An incremental improvement”, arXiv preprint arXiv:1804.02767, April 2018, doi: 10.48550/arXiv.1804.02767.
- [17] L. Jiao, F. Zhang, F. Liu, S. Yang, L. L. Li., Z. Feng, R. Qu, “A Survey of Deep Learning-Based Object Detection”, IEEE Access, vol. 7, September 2019, pp. 128837-128868, doi: 10.1109/ACCESS.2019.2939201.
- [18] R. Padilla, S. L. Netto and E. A. B. da Silva, “A Survey on Performance Metrics for Object-Detection Algorithms”, 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), Niteroi, Brazil, July 1-3, 2020, pp. 237-242, doi: 10.1109/IWSSIP48289.2020.9145130.
- [19] A. Rosebrock, “Intersection over Union (IoU) for object detection”, pyimagesearch.com, <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>, (accessed October 4, 2022).