

교량 손상 관리를 위한 딥러닝 기반의 교량이미지 전처리 및 손상객체 자동검출 모델

A Deep Learning-based Bridge Image Pretreatment and Damaged Objects Automatic Detection Model for Bridge Damage Management

홍성삼¹, 황철훈², 김형규³, 김병곤^{4*}

Sung-Sam Hong¹, Cheolhoon Hwang², Hyung-Kyu Kim³, Byung-Kon Kim^{4*}

요약

교량에서 표면 결함은 가능한 구조적 열화 또는 손상의 가장 관찰 가능한 지표이다. 그러나 대부분 인력에 의한 수동적인 검사로 지표를 생성하고 있는데 이는 구조 요소의 내부 상태는 시각적 기술에만 의존하여 평가될 수 없다는 점과 수동적인 촬영, 직관에 의한 판단만이 평가 요소인 점이 문제점으로 지적된다. 본 논문에서는 교량 손상 점검의 자동화를 위해 딥러닝 기반의 이미지 전처리 및 교량 손상 객체 자동화 기술을 제안한다. 이기종의 촬영기기로 촬영된 교량 이미지의 전처리를 위해 딥러닝 기반의 SR(Super-Resolution)을 이용하여 up/down-sampling을 통해 탐지모델에 가장 적합한 형태의 이미지로 정규화를 하는 기술을 제안하였다. 처리된 이미지는 레이블러를 통해 레이블링 되고, 구축된 이미지넷이 탐지모델의 학습에 사용되어 현장에 최적화된 교량 손상 객체 탐지 모델을 구축할 수 있다. 또한 기존의 교량 손상 탐지 모델들과 성능적으로 유사하거나 우수한 성능을 나타내었으며, 전문현장 데이터를 사용하였기 때문에 모델의 신뢰성을 확보할 수 있었다. 실험을 통해 교량 손상 객체 중 백테에 대한 탐지 성능을 측정하였으며, 전처리된 이미지넷을 활용한 경우 성능이 개선되는 것을 확인할 수 있었다.

핵심어 : 딥러닝, 노후 교량 관리, 이미지 분석, 이미지 처리, 화질 개선

Abstract

Surface defects in bridges are the most observable indicators of possible structural degradation or damage. However, most of them generate indicators through passive inspections by manpower. This method

1 Intelligent Data Analysis and Security Research Center, Gachon University, Gyeonggi-do, Korea [Senior Researcher]
e-mail: sunghong0@gachon.ac.kr

2 Department of Research & Development, Rabahgroow 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: hkkim@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 한국건설기술연구원 주요사업인 'DNA 기반 노후 교량 구조물 스마트 유지관리 플랫폼 및 활용 기술 개발(과제코드 20210289-001)'의 연구비 지원에 의해 수행되었습니다. 연구 지원에 감사드립니다.

Received(September 28, 2021), Review Result(1st: October 6, 2021), Accepted(October 8, 2021), Published(October 31, 2021)



© 2021 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/>.

is pointed out as a problem that the internal state of the structural element cannot be evaluated solely on visual technology, and that only passive photographing and intuition judgment are evaluation elements. In this paper, deep learning-based image preprocessing and bridge damage object automation technology are proposed for automation of bridge damage inspection. For preprocessing of bridge images photographed with heterogeneous photographing devices, a technology for normalizing into images of the most suitable form for detection models through up/down-sampling using deep learning-based SR (Super-Resolution) was proposed. The processed image is labeled through the labeler, and the constructed image net is used for learning the detection model to build a bridge damage object detection model optimized for the field. In addition, it showed similar or excellent performance to the existing bridge damage detection models, and because professional field data were used, the reliability of the model could be secured. Through the experiment, it was confirmed that the detection performance of white pollack among bridge damaged objects was measured, and the performance was improved when the preprocessed image net was used.

Keyword : Deep learning, old bridge management, image analysis, image processing, super-resolution

1. 서론

교량은 현대의 도로에서 중추의 역할을 하는 주요 시설물로 교통시스템에서 필수적인 부분이다. 따라서 교량의 안전과 유지보수 관리는 사회안전에 매우 중요한 부분이기 때문에 정기적이고 세밀한 모니터링이 필요하다. 일반적으로 전문가의 의해 정기적으로 교량손상점검을 실시하고 있으며, 특수한 이벤트가 발생할 경우 마찬가지로 전문가에 의해 점검을 하고 있다 [1].

교량에서 표면 결함은 가능한 구조적 열화 또는 손상의 가장 관찰 가능한 지표이다. 육안 검사가 가장 많이 시행되고 있으며 저비용 고품질 디지털 카메라는 최근에 이미지 기반 기술을 구조적 건강 모니터링(Structure Health Monitoring) 프레임워크에 통합하는 데 기여했다. 그러나 구조 요소의 내부 상태는 시각적 기술에만 의존하여 평가될 수 없다는 점과 수동적인 촬영, 직관에 의한 판단만이 평가 요소인 점이 문제점으로 지적된다. 노후교량에 대한 유지보수를 판단하기 위한 손상 유·무 판단은 건설유지보수 전문가가 직접 육안으로 손상도를 판단하고 있어, 작업자의 안전성 저하와 진단비용이 과대 발생할 뿐만 아니라 재정과 환경적 요인에 의해 정확성과 신뢰성이 떨어질 수 있다. 수동 검사는 비용이 많이 들고 노동 집약적이며 접근성이 낮고 촬영 위치가 주관적이다 [1]. 이러한 문제를 해결하기 위해 컴퓨터 비전 기반 검사 및 드론 검사 플랫폼들이 연구개발되었다 [2][3]. 교량에서 시각적 데이터가 수집되면 결함 감지, 분류 및 평가를 위한 관련 정보를 추출하기 위한 전체 IPT(이미지 처리 기술) 기술도 존재한다 [4]. Wire cam과 같은 영상기기의 개발로 교량 이미지를 촬영하여 손상 유무를 판단하고자 하고 있으나, 아직 시범적 도입 단계이며, 촬영 영상에 대한 유형식별 및 segmentation 기술 개발이 미흡하여 현재도 전문가가 촬영 영상을 보고 수동적인 유형 식별작업을 진행 중이다. 딥러닝을 이용한 연구들 [5-7]도 존재하지만 연구실 수준의 정밀 측정의 연구이거나 AI 데이터셋 부족으로 상용화 수준의 기술을 달성하기 어려운 상황인 연구들이 많다. 또한 실제 점검 현장에서 촬영되는 이미지를 이용하지 않아 현실적인 부분이 부족한 면도 존재한다.

본 논문에서는 교량 손상 점검의 자동화를 위해 딥러닝 기반의 이미지 전처리 및 교량 손상 객체 자동화 기술을 제안한다. 교량 점검 전문 기관에 의해 축적된 이미지 데이터와 전문인력을 활용하여 실제 현실적 데이터를 기반으로 레이블링을 통해 교량 손상 객체를 분류하기 위한 이미지넷을 구축한다. 또한 이기종의 촬영기기로 촬영된 교량 이미지의 전처리를 위해 딥러닝 기반의 SR(Super-Resolution)을 이용하여 up/down-sampling을 통해 탐지모델에 가장 적합한 형태의 이미지로 정규화를 하는 기술을 제안하였다. 과거의 데이터를 활용하기 위해 저화질로 촬영된 교량 이미지를 고화질로 변환하여 손상객체를 자동으로 탐지할 수 있도록 하였다. 또한 이 기술을 통해 데이터증강효과도 얻어낼 수 있었으며 매우 작은 객체를 탐지하기 위해 이미지를 확대하여 레이블링할 수 있도록 해상도 증가 및 적절한 레이블링으로 작은 객체 탐지도 가능한 기술을 제안하였다. 전처리된 이미지는 레이블러를 통해 레이블링 되고, 구축된 이미지넷이 탐지모델의 학습에 사용되어 현장에 최적화된 교량 손상 객체 탐지 모델을 구축할 수 있다. 또한 기존의 교량 손상 탐지 모델들과 성능적으로 유사하거나 우수한 성능을 나타내었으며, 전문현장 데이터를 사용하였기 때문에 모델의 신뢰성을 확보할 수 있었다. 실험을 통해 교량 손상 객체 중 백태에 대한 탐지 성능을 측정하였으며, 전처리된 이미지넷을 활용한 경우 성능이 개선되는 것을 확인할 수 있었다.

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 조사 방법

[5]에서는 웹스크래핑(web scraping) 기법으로 인공지능망 학습에 필요한 다양한 콘크리트 무손상 손상 이미지들을 수집하고 학습 데이터를 구축하였다. 기존에 개발된 딥러닝 기반 이미지 분류기인 AlexNet을 초기 모델로 하여, 전이학습 개념을 적용하여 학습된 데이터를 활용한 이미지 내에서 자동으로 박락 탐지를 수행할 수 있는 인공지능망을 개발하였다. 박리/박락에 대한 탐지를 수행하는 모델이다.


균열에 경우 국토교통부는 '안전점검 및 정밀안전진단 세부지침'에 균열은 다양하고 복합적인 원인에 의하여 발생하기 때문에 여러 가지 관점에서 그 원인을 추적해야 할 필요가 있음을 제시하면서, 균열조사 기준을 제시하였다. 이에 따른 일반적인 수준의 균열 조사항목에는 균열 폭, 길이, 형상(형태 및 분포)로 구분된다. 이와 같은 항목들의 조사방법에는 균열자(Crack scale)과 같은 간단한 측정 장비를 이용하거나 육안관찰을 기본으로 한다. 이와 같이 점검자의 육안관찰에 의존하는 방식은 사람이 접근하기 힘든 위치(예: 엘리베이터 샤프트 등)에 있는 균열은 조사하기 어렵고, 점

검자가 수기로 외관조사망도를 작성하는 과정에서 주관적인 판단이 개입되어 기록의 정확성 및 객관성이 낮아질 수 있다. 균열 조사의 효율성과 객관성을 확보하기 위한 연구로 2000년대 초반부터 영상정보를 기반으로 영상처리기술과 딥러닝을 활용한 균열 검출 자동화 연구들이 수행되어오고 있다 [6]. [7]에서는 콘크리트 지반 구조물의 객관적이고 효율적인 균열 점검 및 기록을 목적으로 하여 휴대용 촬영기기를 통해 촬영된 영상에서 균열을 검출하고 균열의 특성(길이, 폭)을 효과적으로 분석할 수 있는 딥러닝기법과 영상처리기법을 개발하였다. 한 가지 영상에 대해서만 검증하였기 때문에 일반화된 모델로서는 아직 미흡하다는 한계점이 있다.

2.2 딥러닝 기반 Super-Resolution 기법

2.2.1 SRCNN

Super resolution 분야에 딥러닝을 최초로 적용한 모델로 [8]에 소개되어 있다. Low-resolution image(저 해상도 이미지)에 전통적인 bicubic interpolation을 이용하여 고해상도의 크기와 동일하게 키우며, Convolution network를 3번 통과하여 이미지의 화질을 개선하는 방법이다. 전통적인 bicubic interpolation은 이미지 화소를 확장시킬 때, 인접한 16개의 화소 값과 거리에 따른 가중치를 이용하여 화소 값을 추정하는 방법으로 학습을 통해 CNN을 통과하면서 화질을 개선한다 [9]. [그림 1]은 SRCNN의 구조를 나타내고 있다.



[그림 1] SRCNN 모델 구조

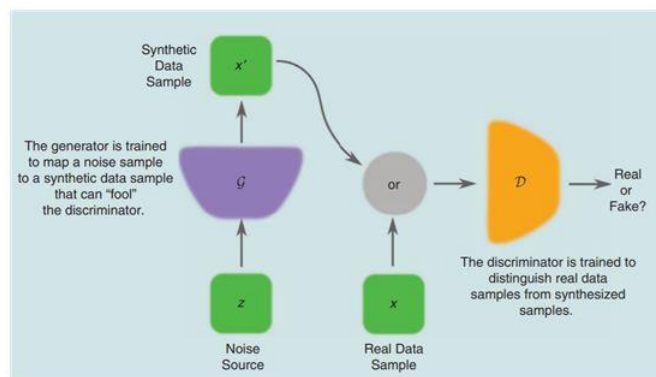
[Fig. 1] SRCNN Model Structure

매우 심플한 방법으로 좋은 성능을 구할 수 있는 방법이며, SR 분야의 가장 기본이 되는 모델이다. CNN 모델을 이용하기 때문에 지도 학습, 즉 화질이 좋은 이미지를 학습시켜줘야한다. 저해상도 이미지(low resolution image)와 ground-truth(GT) 이미지를 통해 모델을 학습하며, 최종적으로 upscaling 이미지와 GT 이미지의 결과 차이가 적어지도록 학습하면 고화질의 이미지가 출력되는 것이다.

2.2.2 SRGAN

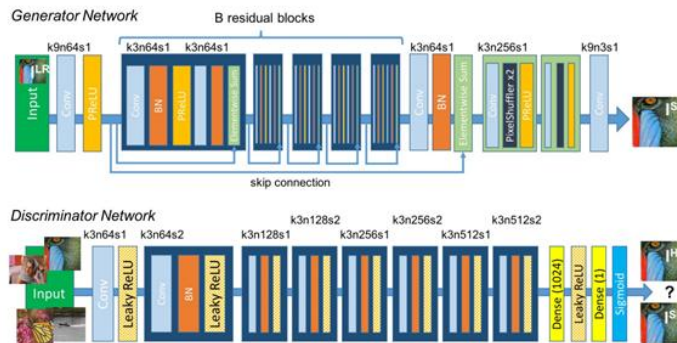
생성적 대립 신경망(Generative Adversarial Network, GAN)은 기존의 지도학습 방식과 다른 비지도 학습이 가능한 모델이다 [10][11]. 별도의 라벨링 처리가 필요 없다는 점이 기존 딥러닝 기술과 대비되는 점이며, 능동적인 학습이 가능하다는 특징을 가진다.

GAN은 InfoGAN, LSGAN, BEGAN, DCGAN 등 다양한 특성을 가진 알고리즘으로 세분화되며, SRGAN(Super Resolution GAN)은 기존 GAN 알고리즘에서 파생된 영상처리 딥러닝 기법이다. 기본적으로 대립적인 관계에 있는 두 개의 네트워크를 구성하여 서로 대립하는 과정에서 훈련 타겟(Training Target)을 생성하는 방법을 알도록 학습시키는 구조이다 [12]. [그림 2]는 GAN의 일반적인 구조를 나타내고 있다 [11]. GAN을 이용한 SR모델인 SRGAN의 구조는 [그림 3]과 같다.



[그림 2] 일반적인 GAN 모델 구조 [11]

[Fig. 2] General GAN Model Structure



[그림 3] SRGAN 모델 구조

[Fig. 3] SRGAN Model Structure

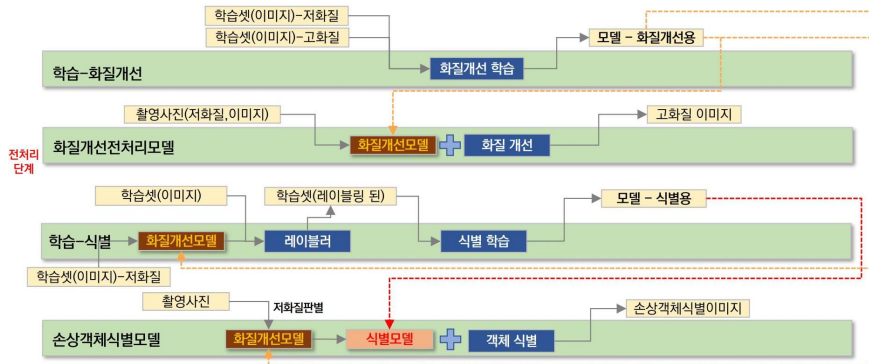
예시로 복원된 upscaling 이미지와 원본 이미지에 대한 네트워크를 구성하여 서로 대립하는 과정에서 loss function을 정의하고, 입력 이미지가 generator(생성자)를 통해 upscaling 되면서 생성하는 pixel 데이터에 대하여 discriminator(구분자)는 정의된 loss function을 통해 가짜 pixel 데이터와 구별함, 최종적으로 원본과 유사할 수 있는 upscaling 이미지를 출력한다 [13]. 학습하는 과정에서 학습이 덜 되거나 Convolution layer를 거치면서 값이 증폭되는 문제로 인하여 문제가 발생할 수 있다 [12]. 교량 손상 이미지를 전처리 함에 있어서 성능과 속도면에서 SRGAN이 적합하여, 본 논문에서 제안하는 기술에서 적합한 형태로 커스터마이징하여 사용한다.

3. 딥러닝기반의 지능형 교량손상관리 자동화 기술

본 논문에서는 지능형 교량손상관리가 가능하도록 딥러닝 기반의 노후 교량 손상 유형 식별 자동화 및 최적화를 위한 시스템을 제안하였다. 제안하는 시스템의 개념은 [그림 4]와 같으며, 프로세스 구조도는 아래 [그림 5]와 같다. 크게 두 개의 딥러닝 모델이 존재하며, 각각의 학습방식은 모델에 목적에 맞게 다르게 구성되어 있다. 전처리 단계에서는 화질 개선을 위한 모델을 구축하기 위해 저화질과 고화질의 학습셋으로 학습시킨 SR모델이 만들어지고, 모델이 배치되며 배치된 모델



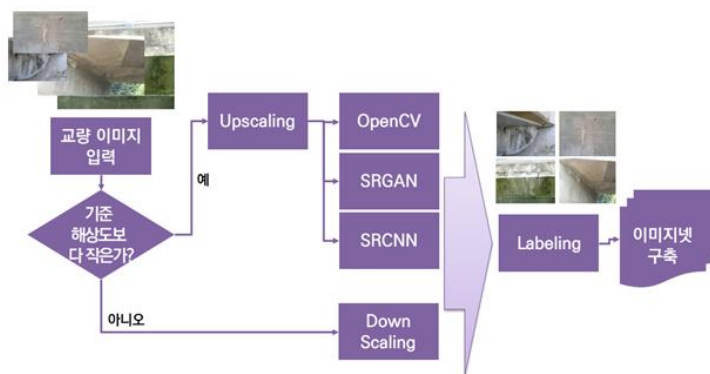
[그림 4] 제안하는 시스템의 개념
[Fig. 4] Concept of Proposal System



[그림 5] 제안하는 시스템의 프로세스
[Fig. 5] Process of Proposal System

은 저화질의 이미지가 입력으로 들어올 경우 SR 과정을 통해 고화질의 이미지로 변환해준다. 손상 객체식별단계에서는 전처리된 이미지들을 레이블러를 통해 레이블링하고, 레이블이 완료된 이미지넷을 학습시켜 식별모델을 생성한다. 식별모델은 배치된 후에 현장에서 취득한 이미지가 입력될 경우 데이터들이 고화질인지 저화질인지 판별하여 전처리를 거친 후 식별 모델에 입력되어 이미지 내 손상객체를 자동으로 식별해준다. 식별모델에 적용되는 CNN모델의 경우 이미지의 크기가 고정될수록, 그리고 filter의 크기와 비례할수록 좋은 식별 성능을 보이기 때문에 제안하는 프로세스는 손상객체를 분별하는데 최적화된 모델을 생성할 수 있을 것으로 판단된다. 정의된 교량 손상 유형 Class는 백태, 누수, 박리, 박락, 균열, 철근 부식 총 6개이며, 교량손상 이미지넷 구축을 위해 레이블러를 사용하여 이미지내 손상객체를 레이블링하였다.

3.1 식별 모델 성능 개선을 위한 교량이미지 화질개선 기반의 이미지 전처리 기술



[그림 6] 제안하는 SR기반 이미지 전처리 기법

[Fig. 6] Proposal Image Pre-processing Method based on SR

본 논문에서 제안하는 식별 모델에는 딥러닝 모델이 교량손상 이미지 내 손상 객체를 추출하기에 가장 적합한 사이즈로 정규화하는 전처리 기술을 제안하였다. 현장이나 크로링을 통해 습득 가능한 교량 손상 이미지는 촬영 시거나 촬영자의 장비에 따라 이미지의 크기 (해상도)가 상이하다. 이러한 이종의 이미지를 딥러닝 식별모델에 입력으로 넣으면 분류 및 식별이 가능하지만 성능면에서 최적의 성능을 낼 수는 없다. 따라서 본 논문에서는 식별모델의 성능을 개선하기 위해 화질개선 기반의 이미지 전처리 기술을 제안하였다. 전처리되어 정규화된 이미지넷으로 학습할 시 식별 모델의 성능에 대해 좋은 결과를 기대할 수 있다. 특히 손상 식별에 적합한 R-CNN계열의 딥러닝 모델들인 Mask R-CNN [14-16], Yolo(R-CNN) [17]들은 더욱 이미지 정규화에 대한 영향이 있으므로 이미지 전처리가 필요하다. CNN 계열에서 사용하는 filter(feature map을 만들기 위한)의 크기의 배수의 사이즈로 정형화하여 식별모델의 성능을 개선하고, 일반화하였다. 또한 너무 작은 사이즈(저

해상도) 이미지의 경우 학습 및 손상객체 식별에서 좋은 성능을 기대할 수 없어 고해상도 이미지로 확대 전처리가 필요하므로 이에 대한 처리를 위해 화질개선 모델을 연구개발하였다. 손상부위만 확대하여 학습셋을 확장할 수 도 있다. 제안하는 전처리 기법의 프로세스는 [그림 6]과 같다.

먼저 교량이미지가 수집되면, 손상식별모델에 가장 최적화된 이미지 크기인지 판단한다. 기준 해상도보다 저화질의 데이터가 입력되면 업스케일링을 수행하고, 이미지 화질차이가 크지 않으면 전체적인 프로세스의 속도를 위해 일반적인 이미지 처리 기법을 이용해서 업스케일링(OpenCV기반 보간법)을 수행하고, 차이가 클 경우 딥러닝 기반의 SR 모델에 적용하여 화질을 개선한다. 일반적으로 4배확대를 기본적으로 수행한다. 이미지는 처리된 후에 레이블링을 통해 이미지넷으로 구축되고, 식별 모델에서 식별을 위해 입력되는 이미지에 대해서도 같은 프로세스로 처리한다.

3.2 딥러닝 기반 교량 손상 객체 자동 식별

우리는 객체 식별에서 사용되는 딥러닝 모델들을 분석하여 교량 손상 객체를 자동으로 식별하기 적합한 손상식별 모델을 제안하였다. 레이블링은 labelme [18] 오픈소스 기반으로 구현된 레이블링 도구를 통해 수행하였다. 교량 손상 객체의 특징을 분석하여, 손상 객체 식별에 최적화된 딥러닝 모델을 개발한다. 앞서 구축된 이미지넷을 효과적으로 학습하여, 도출된 모델을 튜닝을 통해 식별 성능이 우수한 모델을 개발한다. 식별 프로세스는 구축된 정형화된 이미지 넷을 레이블링한 학습셋을 딥러닝 모델에 학습시킨다. 이때 각 모델의 파라미터는 실험과 검증을 통해 최적의 파라미터를 도출한다. 학습이 완료된 후 생성된 식별 모델을 손상 객체 식별에 사용하여 새로운 교량 이미지가 입력되면, 이미지내 손상 객체를 자동으로 식별해낸다. 식별에 사용하는 모델은 식별 목적, 속도, 정확성, 등을 측정하는 측정치를 통해 가장 최적화된 모델을 식별모델로 사용한다. R-CNN 계열의 모델들은 물체 영역 추정 프로세스와 물체 인식 프로세스 간의 분리에 따른 병목현상으로 충분한 검출 속도가 나오지 못하며, 학습해야하는 네트워크 파라미터의 규모가 대단히 커져 최대 검출 속도를 내기 위해서는 고성능 GPU가 절대적으로 필요하다 [6]. 따라서 식별기술을 적용할 경우 GPU가 존재하는 환경에서 수행해야하는 가정이 필요하다.

4. 실험 및 결과

4.1 실험 환경

실험에 사용된 장비환경은 아래와 같다. 효과적인 딥러닝 모델 구현을 위해 GPU를 사용하여 학습 및 테스트를 수행하였다. 프로그래밍으로 사용된 언어는 Python이다.

- CPU : Intel(R) Core(TM) i7-10700F CPU 2.90GHz / RAM : 16GB / GPU : NVIDIA GeForce RTX2060

사용된 모델의 각 파라미터는 [표 1]과 같다.

[표 1] SR 모델 파라미터

[Table 1] SR Model Parameter

SRCNN	SRGAN
epoch : 300 batch-size : 100 loss rate : 1e-4	epoch : 300 batch-size : 100 loss rate : 1e-4

4.2 화질개선 실험 결과

4.2.1 측정방법

대표적인 이미지 품질 측정 방법을 사용하여 화질개선 성능을 평가하였다. 육안으로 확인하는 것과 측정방법을 통해 확인하는 방법에는 차이가 있다.

- Brisque [19]

BRSIQUE는 LIVE 연구실의 Mittal 등에 의해 2012년 TIP에 소개된 방법으로 image가 왜곡되면, 이미지 픽셀의 통계도 왜곡된다는 점에 착안한 알고리즘이다. MSCN 전처리를 해주면 픽셀들의 히스토그램이 가우시안 형태를 띠는 것을 기반으로 BRISQUE는 MSCN 처리된 이미지 히스토그램에 일반화된 가우시안 분포(GGD, generalized Gaussian distribution) 매칭을 시켜서 형태에 대한 정보를 특성으로 활용하여 측정한다. 특성들을 도출한 후 특성들과 레이블들로 SVM 훈련시켜 이미지 품질을 예측하고, 품질이 좋을수록 낮은 점수, 품질이 나쁠수록 높은 점수를 나타낸다.

- SSIM [20]

대표적인 FR IQA(image quality assessment, 이미지 품질 평가) 방법으로 수치적인 예러가 아닌 인간의 시각적 화질 차이 및 유사도를 평가하기 위해 고안된 방법이다. 원본 이미지 A와 왜곡된 이미지 B가 있다고 할 때 SSIM은 두 이미지의 휘도, 대비, 및 구조를 비교 -1에 가까울수록 높은 품질이고, 0에 가까울수록 나쁜 품질이다.

4.2.2 모델별 화질개선 성능 평가



[그림 7] 실험에 사용된 일반적인 이미지셋
[Fig. 7] Typical Set of Images used in Experiment

첫 번째 실험으로는 SR 연구에서 보편적으로 사용되는 이미지셋을 이용하여 각 모델의 SR 성능에 대한 실험 및 성능을 검증하였다. [그림 7]은 사용한 이미지 5장을 보여주고 있다. 각각 해상도는 640x480으로 SR을 통해 4배로 해상도를 upscaling하여, 2560x1920의 이미지 사이즈로 화질개선을 수행한 결과이다. [표 2]에서 나타난바와 같이 SRCNN이 SSIM 측정값은 높고, SRGAN이 Brisque 측정값에서는 높게 나타난 것을 볼 수 있다. 육안이나 고화질 원본과 유사한 품질을 산출하는 것은 SRCNN이지만, 비지도학습인 SRGAN이 객관적인 화질(이미지 품질)개선에는 더 좋은 성능을 보인다는 것을 알 수 있다.

[표 2] Brisque, SSIM 측정결과 : 일반적인 이미지 셋
 [Table 2] Brisque, SSIM Measuring Result : Typical Image Set


Image	고해상도 변환결과		고해상도 변환결과	
	Brisque		SSIM	
	SRCNN	FastSRGAN	SRCNN	FastSRGAN
0001x4.png	45.537	30.103	0.7779	0.7211
0002x4.png	53.909	30.786	0.6475	0.5849
0003x4.png	56.625	36.472	0.6792	0.6280
0004x4.png	57.018	32.233	0.8819	0.8519
0005x4.png	63.356	50.307	0.7778	0.7326



[그림 8] 실제 교량 이미지 셋
 [Fig. 8] Real Bridge Image Set

다음은 [그림 8]과 같이 실제 현장에서 수집한 교량 이미지셋의 이미지 중 5장의 이미지의 SR 결과를 측정하였다. 이 이미지셋의 경우 일반적인 이미지셋과 달리 대조대상인 원본 고화질 이미지가 없으므로 SSIM은 계산할 수 없다. 따라서 이미지 자체 품질 측정방법인 Brisque 측정으로 이미지 자체 품질에 대한 평가만 수행하였다. [그림 9]는 화질 개선된 이미지 결과를 나타내고 있으며, [표 3]은 Brisque 측정값을 나타내고 있다. 두 가지 이미지셋을 실험한 결과 Brisque 측정값이 FastSRGAN이 더 높게 나왔으므로 이미지 자체 품질은 FastSRGAN을 이용했을 때 더 좋은 품질의

이미지 결과를 보여주는 것을 알 수 있다. 우리는 객체 식별을 위해 SR 과정이 모델이 포함되므로, SRGAN 모델이 제안하는 기술에는 적합하다고 판단된다.



[그림 9] 실험결과 이미지 : 실제 교량 이미지 셋

[Fig. 9] Experimental Image Result : Real Bridge Image Set

[표 3] Brisque 측정결과 : 실제 교량 이미지

[Table 3] Brisque Measuring Result : Real Bridge Image

Image	고해상도 변환결과	
	Brisque	
	SRCNN	FastSRGAN
001_2018.png	62.016	44.832
002_2018.png	58.563	29.667
003_2018.png	59.600	37.275
004_2018.jpg	51.470	27.746
005_2018.jpg	60.091	39.898

4.3 손상객체 식별 실험 결과

[표 4] Mask R-CNN 파라미터 셋팅

[Table 4] Mask R-CNN Parameter Setting

Mask R CNN
epoch : 200 , batch-size : 100, train : 현장 학습 이미지(저해상도+고해상도) [type: coco weight] test : 저해상도, SRCNN 고해상도 FastSRGAN 고해상도 [type: coco weight], loss rate : 1e-4

다음은 화질개선에 의해 손상 객체 식별 성능이 개선되었는지 검증하기 위해 Mask R-CNN 모델을 구축하여 손상객체를 식별하는 실험을 수행하였다. 실험은 각 LR(Low-Resolution) 이미지(저화질 이미지)와 SRCNN, SRGAN에 의해 화질이 개선된 고화질 이미지를 각각 손상객체 탐지 모델의 입력으로 넣어 이미지내 손상객체 중 ‘백태’객체를 식별하는 실험을 수행하였다. 실험에 사용된 파라미터 값들은 [표 4]에 나타나 있다. 실험에 사용된 이미지 및 실험 결과는 아래 [표 5]와 같으며 총

5개의 이미지이다.

[표 5] 교량 손상 객체 식별 결과

[Table 5] Bridge Damage Object Identification Result

Image	Image Detection Result [Accuracy]											
	LR				SRCNN				FastSRGAN			
	DIC	DIA	FDI	TDIA	DIC	DIA	FDI	TDIA	DIC	DIA	FDI	TDIA
001.jpg	0	0	0	0%	1	[0.9012]	0	100%	1	[0.9088]	0	100%
002.jpg	2	[0.9230 0.9108]	1	50%	2	[0.9662 0.9060]	1	50%	2	[0.9698 0.9339]	1	50%
003.jpg	1	[0.9067]	1	0%	3	[0.9688 0.9558 0.9371]	2	33.3%	2	[0.9751 0.9058]	1	50%
004.jpg	2	[0.9230 0.9175]	1	50%	1	[0.9538]	0	100%	0	0	0	0%
005.jpg	1	[0.9464]	0	100%	1	[0.9658]	0	100%	1	[0.9014]	0	100%

- DIC : Detected Image Count, 탐지된 이미지 개수
 - DIA : Detected Image Accuracy, 탐지된 이미지 정확도
 - FDI : Falsely Detected Image, 잘못 탐지된 이미지 개수
 - TDIA : Truly Detected Image Accuracy : 정확히 탐지된 이미지 정확도

이미지내에서 백태 객체 식별 결과는 아래 [표 6]과 같다.

[표 6] 백태 객체 식별 결과

[Table 6] Efflorescence Object Identification Result

Image	origin	Image Detection Result [Accuracy]		
		LR	SRCNN	FastSRGAN
002.jpg				
003.jpg				

실험 결과 정확도값을 비교했을 때 이미지 내 객체 식별 성능은 저해상도 이미지보다 고해상도 변환 이미지에서 향상된 결과를 보이는 것을 볼 수 있었다. 식별한 객체가 백태로 탐지한 성능에 대한 정확도(TDIA)에서는 SRCNN 기술을 통한 고해상도 변환 이미지가 FastSRGAN 기술을 통한 고해상도 변환 이미지보다 전반적으로 탐지 능력이 높은 것을 볼 수 있다. 단, FastSRGAN 기술을

통한 고해상도 변환 이미지의 경우 복잡한 구조(다수의 물체, 겹침 등)를 가진 이미지에서 SRCNN 기술보다 좋은 탐지 능력을 보이는 것을 볼 수 있으며 다수의 객체에 대한 탐지 정확도(DIA)는 FastSRGAN이 다소 성능이 높게 나타나는 것을 볼 수 있었다. 복잡한 구조를 갖거나 다수 탐지를 요구할 경우, epoch 200 batch 100 이상의 학습이 필요로 하며 복잡한 구조의 학습 이미지에 대한 추가 학습을 수행할 경우 성능 향상을 기대할 수 있다.

결론적으로 실험을 통해 제안하는 기술이 교량 손상 객체 식별 성능을 개선하는 것을 볼 수 있었다. 특히 복잡한 구조로 손상객체가 포함된 이미지의 경우 식별 성능이 더 개선된 부분을 실험을 통해 알 수 있었다.

5. 결론

노후 교량 관리에 있어 교량 손상 부위(객체)를 발견하고, 보수 및 관리하는 것은 중요한 공정이다. 지금까지 인력에 의존하였던 노후 교량 검사 프로세스를 개선하기 위해 본 논문의 기술을 제안하였다. 제안한 기술은 교량 이미지에 최적화된 딥러닝 기반의 화질 개선 모델을 적용하여 저화질 이미지를 고화질로 향상시켜 손상 객체 식별모델에 적용하여 자동 식별 성능을 높일 수 있었다. 또한 복잡한 복합손상 구조에서 손상 객체를 식별할 수 있는 의미있는 결과를 얻을 수 있었다. 이미지 내 손상객체가 작을 경우 화질 개선 및 확대를 통해 손상 객체를 판단할 수 있다는 가능성도 얻을 수 있었다.

추후 연구로는 화질 개선 기술을 응용하여 이미지넷의 확장을 위한 데이터 증강 기법을 연구개발하고자 한다. 또한, Mask R-CNN 외 다른 딥러닝 식별 모델에 적용하여 교량 손상 이미지 내 손상객체를 식별하기 가장 최적화된 모델을 찾고, 앙상블을 통해 식별 성능을 개선하고자 한다. 특히, 화질 개선 기술과 적합한 모델을 연구개발하여 교량 손상 이미지 분석의 성능과 효율성을 높이고자 한다.

References

- [1] C. Zhang, C.C. Chang, M. Jamshidi, "Bridge damage detection using a single-stage detector and field inspection images", arXiv, February, 2019.
- [2] A. Ellenberg, A. Kontsos, 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.
- [3] 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, pp. 1-5.
- [4] C. Koch, K. Doycheva, V. Kasireddy, B. Akinci, P. Fieguth, “A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure”, *Advanced Engineering Informatics*, vol. 30, iss. 2, April 2016, pp. 208-210, doi: 10.1016/j.aei.2016.03.002.
- [5] 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.
- [6] 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.
- [7] A. R. Kim, D. 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.
- [8] C. Dong, C. Loy, K. He, X. Tang, “Image Super-Resolution Using Deep Convolutional Networks”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, iss. 2, February 2016, pp. 295-307, doi: 10.1109/TPAMI.2015.2439281.
- [9] T.W. Kim, “CNN, Convolutional Neural Network Summary”, taewan.kim, <http://taewan.kim/post/cnn/>, (accessed September 4, 2021).
- [10] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, W. Shi. “Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network”, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA, pp. 105-114, doi: 10.1109/CVPR.2017.19.
- [11] A. Creswell, T. White, V. Dumoulin, K. Arulkumaran, B. Sengupta, A. A. Bharath, “Generative Adversarial Networks: An Overview”, *IEEE Signal Processing Magazine*, vol. 35, iss. 1, January 2018, pp. 53-65, doi: 10.1109/msp.2017.2765202.
- [12] W. J. Seo, “Super-resultaion GAN(SRGAN)”, tistory.com, <https://wewinserv.tistory.com/65>, (accessed September 20, 2021).
- [13] H. Ha, B. Y. Hwang, “Enhancement Method of CCTV Video Quality Based on SRGAN”, *Journal of Korea Multimedia Society*, vol. 21, no. 9, September 2018, pp. 1027-1034, doi: 10.9717/knms.2018.21.9.1027.
- [14] K. He, G. Gkioxari, P. Dollar, R. Girshick, “Mask R-CNN”, 2017 IEEE International Conference on Computer Vision (ICCV), 22-29 October, 2017, Venice, Italy, pp. 2980-2988, doi: 10.1109/iccv.2017.322.
- [15] L. Jiao, F. Zhang, F. Liu, S. Yang, 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.
- [16] herbwood, “Mask R-CNN paper(Mask R-CNN) Review”, tistory.com, <https://herbwood.tistory.com/20>, (accessed September 5, 2021).
- [17] R. Joseph, A. Farhadi, “Yolov3: An incremental improvement”, arXiv, April 2018.
- [18] B. C. Russell, A. Torralba, K. P. Murphy, W. T. Freeman, “LabelMe: A Database and Web-Based Tool

- for Image Annotation”, *International Journal of Computer Vision*, vol. 77, iss. 1-3, October 2007, pp. 157-173, doi: 10.1007/s11263-007-0090-8.
- [19] A. Mittal, A. K. Moorthy, A. C. Bovik, “No-Reference Image Quality Assessment in the Spatial Domain”, *IEEE Transactions on Image Processing*, vol. 21, iss. 12, December 2012, pp. 4695-4708, doi: 10.1109/tip.2012.2214050.
- [20] Z. Wang, A. C. Bovik, H. R. Sheikh, E. P. Simoncelli, “Image Quality Assessment: From Error Visibility to Structural Similarity”, *IEEE Transactions on Image Processing*, vol. 13, iss. 4, April 2004, pp. 600-612, doi: 10.1109/tip.2003.819861.