

딥러닝 기반 도로위험객체 인식 시스템 성능 향상 방법 개발

양인철, 전우훈*

한국건설기술연구원 도로교통연구본부

Development of Performance Improvement Method of Deep Learning based Automatic Road Dangerous Object Detection System

Inchul Yang, Woo Hoon Jeon*

Dept. of Highway & Transportation, Korea Institute of Civil Eng. and Building Technology

요약 파손된 도로시설물, 로드킬 등의 도로위험객체는 교통사고 위험을 초래하기 때문에 신속하고 정확한 발견과 처리가 매우 중요하다. 이에 전국 도로의 유지관리를 총괄하는 국토교통부에서는 도로이용불편신고 서비스를 운영하고 있으며, 보다 안전하고 효율적인 신고 지원을 위해 이미지 기반의 자동 객체 인식 시스템을 개발 중이다. 시스템 개발은 여러 단계에 걸쳐 수행되고 있으며, 각 단계마다 인식을 향상을 위한 연구가 진행되고 있다. 이에 본 연구에서는 딥러닝 알고리즘을 활용하여 자동으로 도로위험객체를 인식하는 시스템의 성능을 향상시키는 체계적인 방법을 제안하고자 한다. 이를 위해 성능 향상 방법에 대한 절차를 제안하였고, 세부적인 원인 분석을 통해 새로운 솔루션(신경망 구조 변경, 데이터 정제 및 강화)을 제안하였다. 신경망 구조는 기존 YOLOv3보다 우수한 성능을 보이는 YOLOv5로 변경하였고, 데이터 강화를 위해 신고 이미지 중 문제점 확인이 어려운 이미지를 제외하였고, 신고 이미지 외에 오픈소스 이미지 데이터셋에서 양질의 이미지를 추가로 확보하였다. 이를 기존 시스템에 적용하여 신규 시스템을 개발하고, 그 성능을 검증하였다. 본 연구는 기존 시스템에서 인식이 낮았던 도로시설물과 로드킬을 대상으로 하였으며, 새로운 시스템의 성능 검증을 통해 도로시설물과 로드킬 인식이 각각 71%에서 91%로, 67%에서 97%로 향상됨을 확인하였다. 향후 제안된 성능 향상 방법에 따라 체계적인 시스템 성능 향상이 가능할 것으로 기대된다.

Abstract Dangerous road objects cause traffic accidents, which makes it imperative to find and remove them quickly. For this purpose, MOLIT(Ministry of Land, Infrastructure, Transportation) is providing a smartphone app-based reporting service for dangerous road objects and is developing an automatic object recognition and classification system. The development project has several phases, and elaborate efforts have been put into every phase to improve its performance. A systematic method to improve the system performance was proposed in this study. The specific process was proposed, and new solutions(neural network, data manipulation) were found through factor analysis. The existing neural network, YOLOv3, was replaced by the better-performing neural network model, YOLOv5. Some reported images were difficult to designate as problems and were excluded, and high-quality images were also added from an open-source image dataset. The solutions were applied to the system, and its performance was validated. Road facilities and road kills were selected. The results showed that the performance improved the detection rates of road facilities and road kills from 71% to 91% and from 67% to 97%, respectively. The proposed method is expected to improve the system performance systematically.

Keywords : Road Dangerous Object, Recognition, Classification, Deep Learning, Performance Improvement

*Corresponding Author : Woo Hoon Jeon(Korea Institute of Civil Eng. and Building Technology)

email: cwsoon@kict.re.kr

Received September 26, 2022

Revised November 2, 2022

Accepted November 4, 2022

Published November 30, 2022

1. 서론

도로는 우리 일상에서 가장 많이 이용되는 사회간접자본(SOC: Social Overhead Capital) 중 하나이기 때문에 그만큼 사고 위험의 가능성이 높다. 교통사고는 규모와는 무관하게 일정 수준 이상의 사회비용과 당사자의 정신적 피해를 초래하기 때문에 예방이 최선이라 할 수 있으며, 사고 예방을 위해서는 사고 위험 인자를 미리 파악하고 제거하는 것이 무엇보다 중요하다. 도로시설물의 파손, 낙석, 낙하물, 로드킬 등의 도로위험객체는 교통사고 위험을 초래하는 주된 요인이기 때문에 정확한 인지와 이의 신속한 처리가 매우 중요하다.

전국 도로의 유지관리를 총괄하는 국토교통부에서는 도로이용불편신고 서비스[1]를 운영하고 있다. 이는 일반 국민이 스마트폰 앱을 이용해서 도로의 불편사항을 신고 하면 도로관리청이 이를 처리하는 서비스이다. 이때 사용자는 불편사항 인지 후 앱을 이용해서 사진 또는 동영상을 찍고 이와 관련된 신고 내용을 작성해서 신고를 해야 하는 일련의 절차를 수행하게 되는데, 이로 인해 도로라는 위험한 환경에서 신고를 위해 일정 시간 동안 머물러야 하는 점, 신고 내용 작성을 위해 어느 정도의 도로에 대한 지식이 필요한 점, 그리고 내용을 직접 작성해야 하는 점 등의 불편사항이 있다 보니 불편사항을 인지하고도 신고를 주저하는 경우가 발생하고 있다. 또한 도로관리청 입장에서는 신고 내용이 정확하지 않아 해당 위치에서 불편사항을 제대로 확인하고 처리하는데 애로 사항이 빈번하게 발생한다. 이에 신고자의 보다 안전하고 효율적인 신고를 지원하기 위해 이미지 기반의 자동 객체 인식 시스템[2]을 개발 중이다. 사용자가 찍은 이미지로부터 도로의 불편사항을 자동으로 추출하여 신고 내용을 만들어냄으로써 신고자 측면에서 보다 빠르고 정확하게 신고를 할 수 있게 지원하고, 도로관리청 입장에서는 정확한 신고 내용을 파악할 수 있도록 지원한다.

시스템 개발은 여러 단계에 걸쳐 수행되고 있으며, 각 단계마다 인식을 향상을 위한 연구가 진행되고 있다. 다양한 접근법을 제안하고 이를 기존 신고 데이터에 적용함으로써 최고의 인식을 갖는 시스템을 개발하는 것을 최종 목표로 한다. 따라서 단계별 인식을 향상을 위한 체계적인 접근법이 요구되며, 이에 본 연구에서는 딤러닝 알고리즘을 활용하여 도로위험객체를 자동으로 인식하는 시스템의 인식을 향상시키는 체계적인 방법을 제안하고, 이를 기존 시스템의 개발단계에 적용하여 성능 향상 여부를 검증하고자 한다. 이를 위해 기존 연구결과[2]에

서 상대적으로 인식이 낮았던 두 개의 도로위험객체인 도로시설물과 로드킬을 대상으로 제안된 방법을 적용하여 새로운 솔루션을 설계하고 이를 실제 신고 데이터에 적용하여 검증하고자 한다. 제2장에서는 체계적인 인식을 향상 방법에 대해 제안하고, 제3장에서는 이 방법을 활용한 검증 결과에 대해 논한다.

2. 체계적인 성능 향상 방법의 제안

2.1 방법 개요

딤러닝 기반의 알고리즘을 탑재한 시스템은 서비스를 통해 추가로 수집된 데이터를 이용하여 딤러닝 알고리즘의 성능과 정확도를 향상시키는 선순환 구조를 가질 수 있다. 이러한 특징으로 인해 많은 시스템 운영 및 개발 기관에서는 양질의 데이터를 확보하려고 노력한다. 또한 딤러닝의 기본 레이어 구조에 대한 설계 변경을 통해 동일한 데이터에 대한 학습을 통해 보다 나은 결과를 얻으려는 시도를 끊임없이 하게 된다.

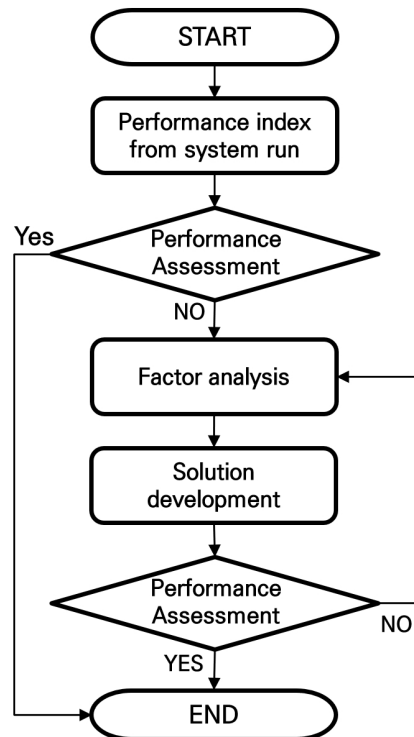


Fig. 1. System performance improvement process

본 연구의 대상인 도로위험객체 자동 인식 시스템도 딥러닝을 기반으로 하기 때문에 선순환적인 시스템 개선 구조를 가질 수 있으며, 본 연구에서는 Fig. 1과 같은 시스템 성능 개선 절차를 제안하였다. 우선 성능 인덱스를 정의하고 기존 시스템을 구동하여 인덱스 값을 확인한다. 만약 성능 인덱스가 기준치를 상회하면 시스템은 목표에 맞게 구동이 되고 있으며 서비스 기준을 만족하기 때문에 절차를 마무리 한다. 하지만 인덱스가 기준치를 하회할 경우 그 원인을 분석(factor analysis)한다. 원인 분석에 대해서는 다음 절에서 심도 있게 논의하기로 한다.

원인 분석을 통해 구체적인 원인이 확인되면 그에 따른 솔루션을 제안 및 개발한다. 신규로 개발된 솔루션을 시스템에 적용하여 성능 평가를 재수행하고, 기준을 만족할 경우 절차를 마무리하고, 그렇지 않을 경우 다시 원인 분석 단계로 돌아가서 동일한 절차를 재수행한다.

제안된 절차의 핵심은 성능 인덱스의 정의와 원인 분석, 그리고 원인에 따른 솔루션 개발이라 할 수 있다. 시스템의 목적에 적합한 성능 인덱스를 정의함으로써 시스템을 온전하게 평가할 수 있다. [3]은 딥러닝 기술의 성능을 평가하기 위한 MOE(Measure of effectiveness)를 제안하였는데, 즉시성(timeliness), 정확성(accuracy), 신뢰성(confidence) 등이 이에 포함된다. 성능 인덱스 정의와 관련된 간단한 사례로, 도로교통 분야에서 교통 혼잡을 예측하는 시스템의 성능 인덱스는 통행시간 또는 통행속도가 되어야 하며, 교통량(traffic volume)이 되어서는 안 된다. 왜냐하면 교통량은 통행속도가 높을 때

와 낮을 때 모두 유사한 값을 나타내기 때문에 혼잡수준을 나타내기에는 부적합하기 때문이다[4].

2.2 원인 분석 및 솔루션 개발

성능 인덱스를 참고하여 시스템의 목표 기준치를 하회할 경우 그 원인을 분석해야 하고, 분석 결과에 따라 솔루션을 개발해야 한다. 원인 분석은 Fig. 2와 같이 요인 분류(factor classification)를 통해 수행한다. 딥러닝 알고리즘이 목표하는 성능을 만족하지 못하는 원인은 크게 두 가지로 분류할 수 있다. 첫 번째는 딥러닝 알고리즘의 핵심인 신경망(neural network)의 구조이고, 두 번째는 데이터이다.

기존 연구[5-7]에서 딥러닝 기반의 객체 인식 시스템의 성능을 향상하기 위해 신경망 구조를 새롭게 제안하는 방법을 사용하였다. [5]은 토마토 질병을 빠르게 인지하기 위해 영역 추정 경계 박스를 제안하는 RPN(Region Proposal Networks) 방법을 활용하는 Faster RCNN (Region-based Convolutional Neural Network) 신경망 구조를 제안하였고, [6]는 언어 분야의 인지 향상을 위한 RNN(Recurrent Neural Network) 확장 버전을 제안하였으며, [7]는 기존 RNN을 시간 축에서 정/역방향으로 동시에 확장하여 BRNN(Bidirectional RNN) 모델을 제안하였다. 이와 같이 많은 딥러닝 연구에서 신경망 구조 자체를 새롭게 개발하는 방식으로 기존 시스템의 성능을 향상 시키는 노력을 해왔다.

최근에는 신경망 구조를 변경하는 것도 중요하지만 그

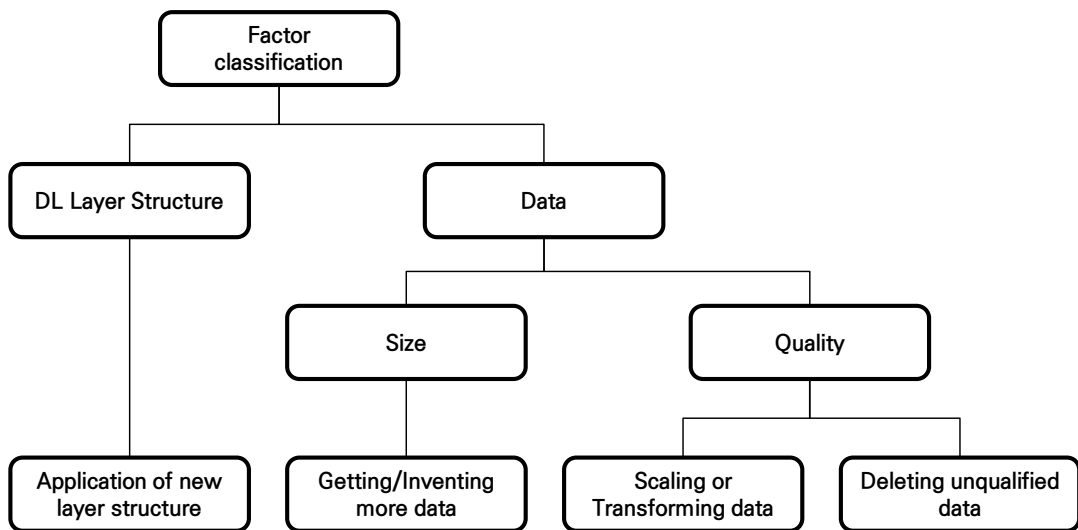


Fig. 2. Factor classification and solution for factor analysis

에 못지않게 딥러닝 모델 학습에 활용되는 데이터 자체를 모델에 적합하게 강화(augmentation)하는 방식으로 접근하는 연구도 많이 진행되고 있다[8-10]. [8]은 사이버 보안 시스템에 사용되는 딥러닝 모델의 성능을 향상하기 위해 데이터를 좀 더 모델에 적합하게 큐레이션(curation)하고 품질을 향상시키는 방법을 제안하였다. [9]은 이미지 분류를 위한 딥러닝 모델의 데이터를 강화하는 방법을 제안하였으며, [10]은 좀 더 일반화된 방식으로 딥러닝 모델의 성능을 향상시키는 데이터 강화 방안을 제안하였다.

딥러닝 모델은 태생적으로 결과에 대한 해석이 쉽지 않기 때문에 원인 분석 또한 쉽지 않은 부분이다. 이러한 문제 때문에 설명 가능한 딥러닝 모델을 개발하기 위한 연구[11]가 수행되기도 했지만 여전히 난제로 남아있는 상태이다. 따라서 원인 분석(factor analysis)은 신경망 구조 변경과 데이터 강화를 동시에 고려하여 수행하는 것이 바람직할 것으로 판단된다.

데이터의 경우 Fig. 2와 같이 입력 데이터의 크기와 품질로 분류해서 고려가 가능하다. 입력 데이터의 크기가 작을 경우 당연히 학습된 모형의 성능이 나쁠 수밖에 없다. 기존의 학습 알고리즘은 데이터 양(size)이 어느 수준 이상이 되면 양의 증가가 알고리즘 성능으로 연결되지 않지만, 딥러닝 모형은 기존 알고리즘에 비해 데이터 양과 성능 간의 연계성이 높은 것으로 알려져 있다. 따라서 입력 데이터 크기 문제의 솔루션은 당연히 더 많은 데이터를 확보하거나, 기존 취득 가능 데이터를 활용하여 입력 데이터를 생성하는 것이 될 것이다.

입력 데이터의 크기에 못지않게 품질 또한 매우 중요한 요인이다. [12]은 많은 양의 데이터가 딥러닝 모델의 성능을 향상시키지만 데이터의 속성(정확성, 일관성, 최신성 등)을 고려하지 못하면 시스템을 제대로 평가하기 어렵다고 주장한다. “Garbage-in garbage-out”과 같이 잘못된 데이터가 학습에 사용될 경우 잘못된 결과가 나올 수밖에 없다. 따라서 시스템의 성능을 개선하기 위해 데이터의 스케일을 조정하거나 변환하는 과정을 거쳐 품질을 향상시킬 필요가 있으며, 이러한 과정으로도 품질이 일정 수준 이상이 되지 못하는 데이터는 과감히 대상에서 제외하는 과정 또한 필요하다.

3. 제안 방법의 적용

본 장에서는 앞서 제안된 딥러닝 기반의 시스템 성능

향상 방법을 이용하여 기존 도로위험객체 인식 시스템[2]의 성능을 향상시키는 방법에 대해 기술한다. [2]는 도로위험객체를 크게 네 가지로 분류하고 이를 이미지 기반으로 자동 인식 및 분류하는 방법을 제안하였다. 대상이 되는 객체는 노면상태불량, 배수시설불량, 도로시설물불량, 로드킬로, 이 중 노면상태불량과 배수시설불량의 경우 신고 데이터의 양이 크기 때문에 인지 성능이 높게 나타난 반면, 도로시설물불량과 로드킬은 성능이 그다지 높지 않게 나왔다. 따라서 본 연구에서는 도로시설물불량과 로드킬에 대해 제안된 방법으로 성능을 향상시키고자 한다.

3.1 성능 인덱스의 정의 및 평가

먼저 성능 인덱스는 기존 연구에서와 같이 검출율 Eq. (1)로 정의한다.

$$DR(\%) = 100 \times \frac{\alpha}{\beta} \quad (1)$$

Where, DR denotes detection rate (a.k.a precision), α denotes number of successfully detected objects (true positive), β denotes number of total objects (true positive + false positive)

기존 연구 결과에서와 같이 정의된 성능 인덱스를 기준으로 도로시설물불량과 로드킬의 검출율은 각각 71%와 67%로 나타났고, 이는 다른 두 개의 객체 검출율인 90%이상에 상당히 하회하는 수준이기 때문에 원인 분석과 솔루션 개발을 통해 검출율을 향상시킬 필요가 있다.

3.2 원인 분석 및 솔루션 개발 : 신경망 구조

신경망 구조의 경우 기존 연구에서 YOLOv3를 이용하였다. YOLO 시스템은 많은 오픈소스 개발자들의 자발적 참여를 통해 빠른 발전을 하고 있으며, 최근에는 YOLOv5가 개발되어 릴리즈되었다. YOLOv5는 큰 틀에서 YOLOv3와 같은 합성곱 신경망 기반의 객체 인식 기술로서, 기본적으로 YOLO의 객체 인식 방식을 활용한다. 하지만 핵심이 되는 backbone 아키텍처를 YOLOv3나 YOLOv4가 채택하고 있는 DarkNet과는 달리 CSPNet[13]를 바탕으로 한다. [13]는 기존 신경망의 효율을 증진시키기 위해 CSPNet(Cross Stage Parital Network)을 새롭게 제안하였는데, 이는 신경망 아키텍처 관점에서 요구되는 매우 무거운 추론 연산량 문제를 해결하는데 초점을 두고 개발이 되었다. 기본 레



Fig. 3. Neural network structure of YOLOv5

이어의 feature map을 두 개의 부분으로 분할 후 이를 다시 제안된 cross-stage 아키텍처를 통해 통합함으로써 gradient 흐름을 분할하여 다른 신경망 경로들로 뿌려지게 한다. 이를 통해 CSPNet은 계산량을 효과적으로 감소시키고, 추론 속도를 증가시키며, 정확도를 향상시키는 결과를 보인다.

또한 기존 연구에서 사용한 Keras와 TensorFlow 대신 PyTorch를 딥러닝 프레임워크로 이용하였다. 여기서 딥러닝 프레임워크란 딥러닝 애플리케이션이나 솔루션의 개발을 수월하게 하기 위해 소프트웨어의 구체적 기능들에 해당하는 부분의 설계와 구현을 재사용할 수 있도록 협업화된 형태로 제공하는 소프트웨어 환경을 말한다. Facebook의 인공지능팀이 개발한 PyTorch는 컴퓨터 언어인 Python을 위한 오픈소스 머신 러닝 프레임워크이다. PyTorch는 처음부터 그래픽 전용 처리장치(Graphic Process Unit)에 최적화될 수 있도록 개발되어 기존의 DarkNet기반의 YOLO보다 빠르면서도 정확한 객체 인식을 가능하게 하는 것으로 알려져 있다. DarkNet기반의 YOLOv3에서 GPU를 사용하기 위해서

는 TensorFlow를 추가로 사용해야 하는 번거로움이 있었을 뿐만 아니라 이러한 추가 과정으로 인하여 객체 인식 속도와 정확도가 다소 저하되는 부작용이 나타났다.

YOLOv5는 객체 검출을 위한 컴퓨터의 기억장치 용량과 CPU 및 GPU의 성능에 따라 선택할 수 있도록, Nano (YOLOv5n), Small (YOLOv5s), Medium (YOLOv5m), Large (YOLOv5l), 그리고 Extra Large(YOLOv5x)와 같은 다섯 가지의 신경망 구조를 제공한다. Fig. 3은 각각의 신경망 구조를 도식화하여 보인다. 일반적으로 동일한 컴퓨터 환경인 경우, 신경망 구조가 단순한 경우 매우 복잡한 신경망 구조에 비하여 객체 검출 정확도는 저하 되는 경향이 있는 반면, 매우 빠른 검출이 가능하다는 장점이 있다. Fig. 4는 각 신경망 구조에 따른 객체 검출 속도와 검출 정확도의 상관관계를 COCO이미지 데이터[14]를 바탕으로 학습시킨 기계의 평균 검출 정밀도(COCO AP, Average Precision)와 이미지당 그래픽 처리장치(GPU) 처리시간 (단위: 밀리초/이미지)을 이용하여 도식화하고 있다. 여기서 말하는 평균 정밀도란, 검출된 객체의 정확한 분류명(Class)




Fig. 4. Performance compare according to a neural network structure of YOLOv5

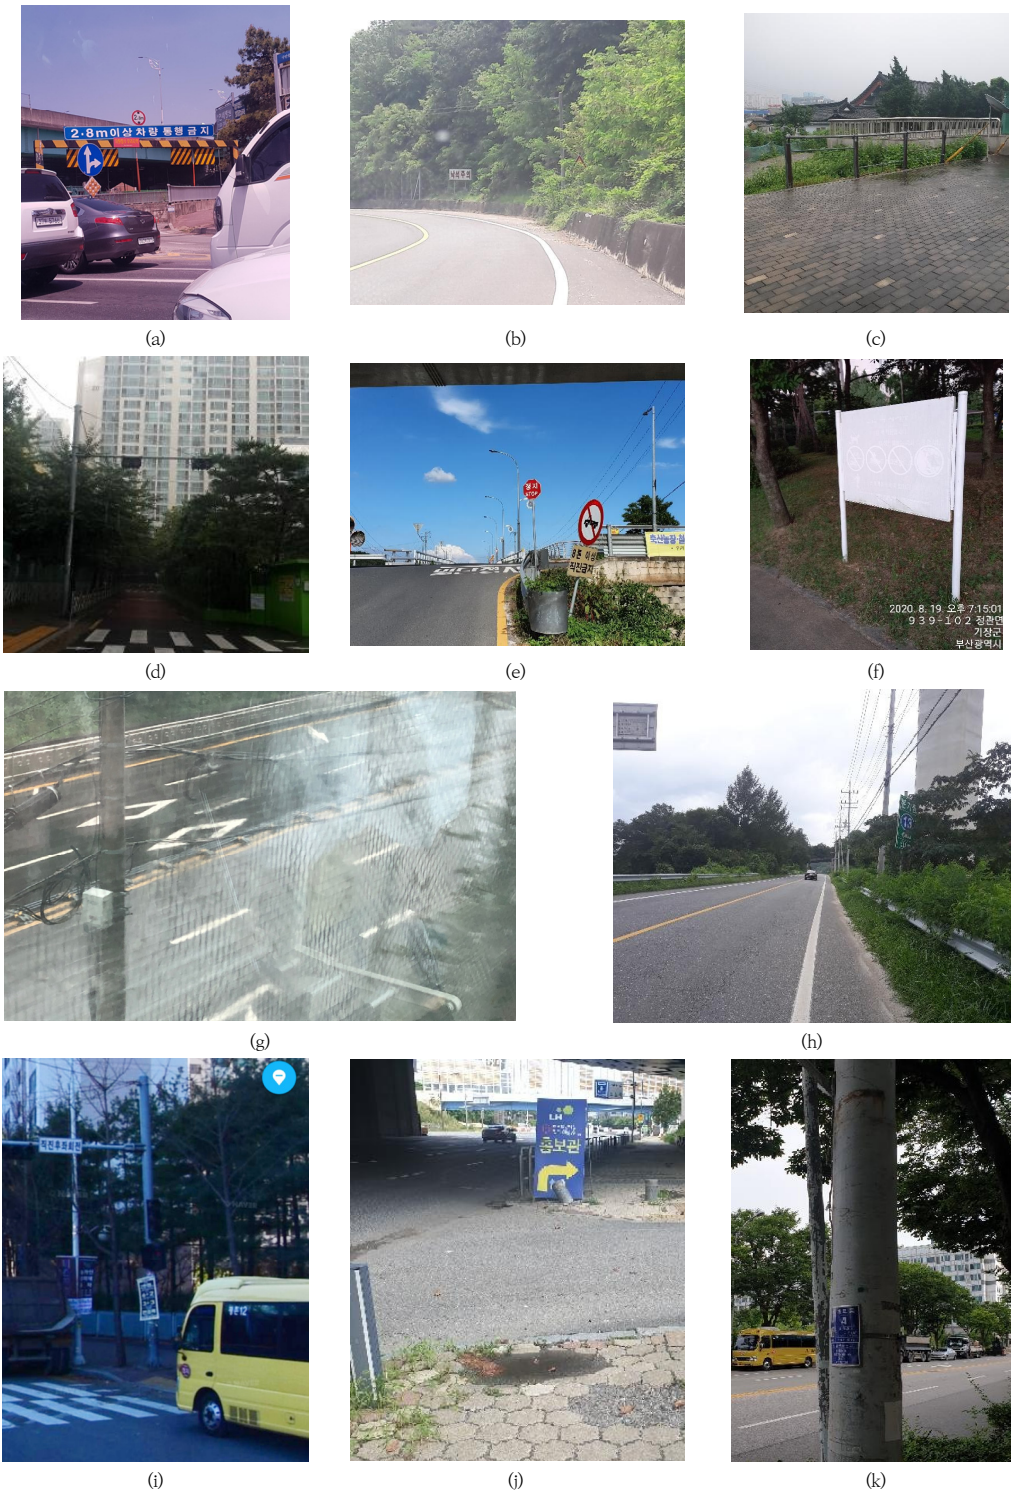


Fig. 5. Samples of reported images (Road facility)

과 해당 이미지 내에서 그 검출 객체의 위치의 정확도 등을 종합적으로 평가하는 지표를 말한다. 따라서 AP가 높을수록 높은 객체 검출 정확도를 나타내며 그래픽처리장치 처리시간이 낮을수록 빠른 검출을 의미하게 된다. 또한, 그림에 보이는 회색 선은 검출 속도에 따른 가장 효과적인 검출 정확도를 나타내고 있다. 그림에 나타난 바와 같이 모든 YOLOv5 신경망 구조는 회색에선 왼쪽에 있는 것으로 나타나 있으므로 신경망 구조와 규모에 따라 다소 차이는 있으나 기본적으로 효과적인 검출을 수행하고 있음을 알 수 있다. 또한, 신경망 구조가 단순할수록 높은 사양의 컴퓨터 환경을 요구하지 않으면서도 실시간에 가까운 신속한 검출을 가능케 하는 장점이 있다. 이러한 장점을 이용하여 YOLOv5n의 경우에는 스마트폰 등과 같은 모바일 기기에 최적화 되어 실시간 객체 검출에 사용될 수 있다. 바꾸어 말하여, 높은 객체 검출 정확도를 요구하나 검출시간에 크게 구애 받지 않는 경우라면, 더욱 복잡한 신경망 구조를 채택하는 것이 바람직할 것이다.

YOLOv3와 YOLOv5의 속성별 차이점은 Table 1에 나타나 있으며, 보다 자세한 비교 정보는 [15]를 참고하여 얻을 수 있다.

Table 1. Comparison between YOLOv3 and YOLOv5[15]

Characteristics	YOLOv3	YOLOv5
Neural network type	Fully convolution	Fully convolution
Backbone feature extractor	Darknet-53	CSPDarknet53
Loss Function	Binary cross entropy	Binary cross entropy and Logit loss function
Neck	FPN	PANet
Head	YOLO layer	YOLO layer

이렇게 YOLOv3와 YOLOv5의 특성을 비교·검토한 결과, 본 연구는 로드킬 및 장애물 항목과 도로시설물 불량 항목의 검출률 개선을 위하여 YOLOv5x 신경망 구조를 채택하였다.

3.3 원인 분석 및 솔루션 개발 : 데이터

본 연구에서는 기존 연구에서 자동으로 검출되지 않은 몇 가지 사례를 분석하여 데이터 품질 특성을 분석하고 그에 따른 솔루션을 반영하였다. Fig. 5는 도로시설물 불량 신고 데이터 중 자동 검출이 되지 않은 이미지를 보여 준다. 도로이용불편신고 서비스는 신고자가 이미지에서

잘못된 부분을 표시하는 기능이 없고, 신고 내용에 글자로만 작성이 가능하기 때문에 딥러닝 모델 학습을 위해서는 별도의 표지화(labeling) 작업이 필요하다. 하지만 간혹 신고자가 이미지만으로 신고하는 경우 도로관리청에서 이미지 상의 문제점을 직접 인지해야 하는데, 몇몇 경우는 문제점을 인지하기가 쉽지 않은 경우가 발생한다. Fig. 5에서 (d)와 (i)의 경우 신호등이 꺼져 있는 상태, (e)의 경우 트럭 이용금지 표지판이 기울어져 있는 상태, (f)의 경우 안내표지판 내용이 일부 지워져 있는 상태로 어렵지 않게 판단이 가능하다. 하지만 이를 제외하면 다른 이미지들은 육안으로도 도로시설물불량 상태를 알아내기가 어렵다. 따라서 이러한 이미지들은 평가 대상 이미지에서 제외하는 데이터 정제 솔루션을 적용하였다.

또한 기존 연구에서 부족했던 이미지 데이터를 추가로 확보하였다. 로드킬의 경우 2020년 5월부터 2020년 8월까지 서비스를 통해 신고된 이미지를 이용하여 표지화 작업을 수행하여 신규 이미지를 확보하였고, 오픈소스 이미지 데이터셋을 통해 추가로 표지화된 이미지를 확보함으로써 총 551건의 학습 및 평가용 이미지 데이터를 구축하였다. 도로시설물불량의 경우 동일한 기간 내 신고된 이미지 총 2,506건을 표지화하여 데이터를 구축하였다. Table 2는 기존 연구와 본 연구에서 학습 및 평가에 활용된 이미지 개수를 비교하여 보여주고 있다.

Table 2. Labelled image count

Classification	Labelled image count	
	Previous	Current
Road facilities	116	2506
Road kills	92	551

3.4 학습의 수행 및 평가

앞서 신경망 구조의 변경과 데이터 강화 작업을 통해 최종적으로 선정된 솔루션을 활용하여 학습을 수행하였다. 학습에 사용된 하드웨어와 주요 소프트웨어 패키지의 사양은 Table 3과 같다. 앞서 언급한 바와 같이 기존 연구에서 사용한 Keras와 TensorFlow 딥러닝 프레임워크를 대신하여 PyTorch를 사용한 점이 기반 소프트웨어 측면에서의 가장 큰 변화라고 할 수 있다.

학습의 결과는 Fig. 6과 같으며 (a)는 도로시설물불량에 대한 결과를, (b)는 로드킬에 대한 학습 결과를 보여 준다. 도로시설물불량에서 Eq. (1)의 인덱스에 해당하는 정밀도(precision) 값은 평가 대상 이미지에 대해 3-3절

에서 언급한 데이터 정제 작업을 수행하지 않은 것으로, 데이터 정제 작업을 통해 육안 구분이 어려운 이미지를 제외하면 Table 4에서 볼 수 있듯이 총 78건의 이미지 중 71건(91%)을 성공적으로 자동 인식할 수 있었다. 이는 데이터 정제 작업이 성능 향상 측면에서 매우 중요한 절차임 의미한다. 그리고 로드킬의 경우 총 35건에 대해 자동 인식을 수행한 결과, 34건(97%)이 성공적으로 검출되었다. 이러한 결과는 기존 71%와 67%에 비해 괄목할

만한 수준의 개선이 달성되었음을 보여준다.

Fig. 6에서 객체분류에 해당하는 cls_loss 값이 0으로 나타난 것은 본 연구에서 도로시설물불량과 로드킬 자동 인식 모형이 유형별로 각각 개발되어 개별 모형이 분류 역할을 수행하지 않기 때문이다. 또한 재현도(recall) 값의 경우 정밀도(precision)와는 다르게 실제 건수를 기준으로 인식율을 바라보기 때문에 정밀도에 비해 상대적으로 낮게 나타났다. 이는 본 연구에서 제안한 솔루션의

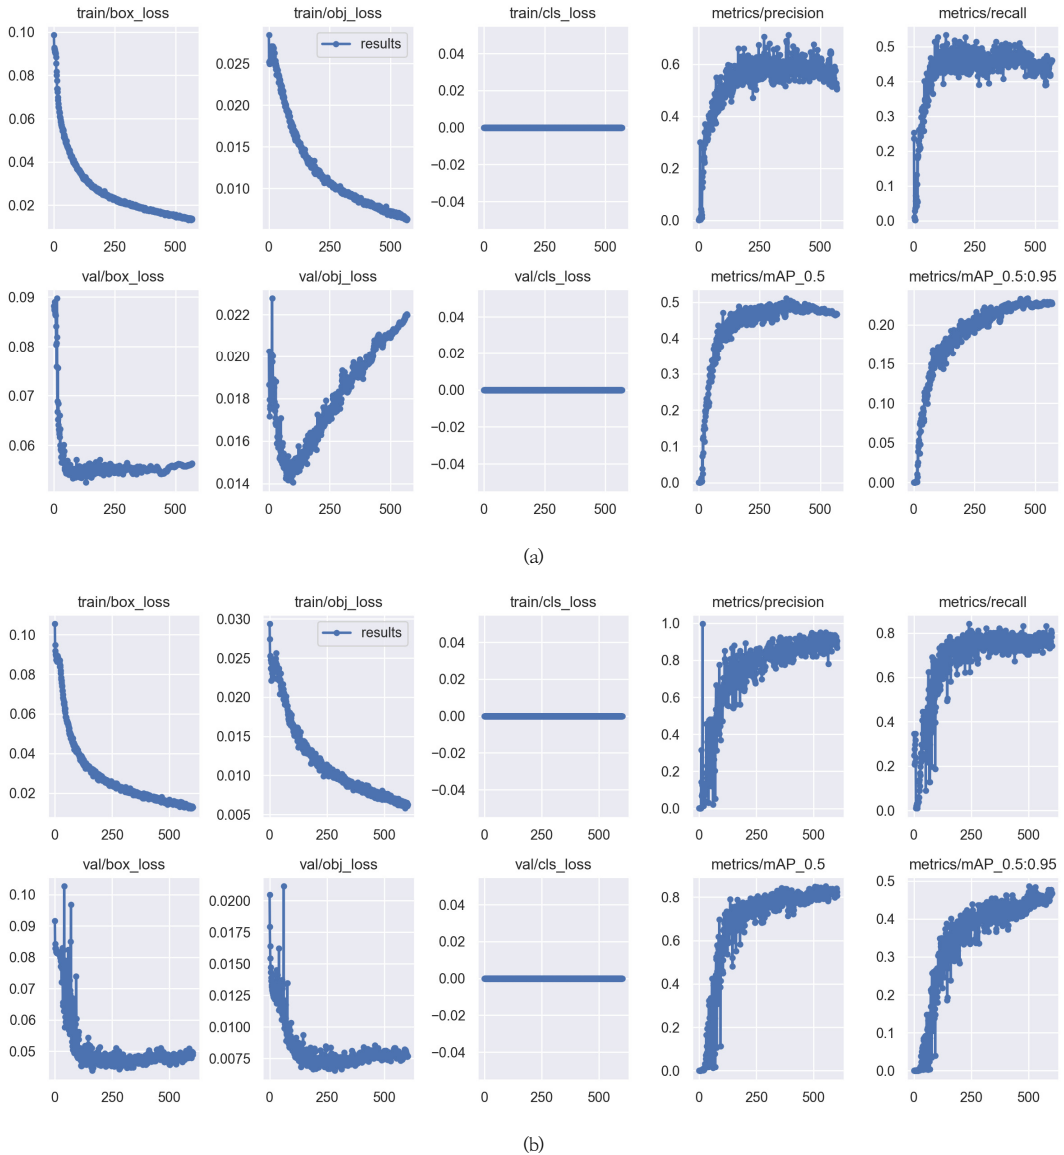


Fig. 6. Deep learning results (a) Road Facility, (b) Road kills (x-axis indicates the number of feedback iterations)

한계점이라 판단되며, 향후 연구를 통해 재현도를 향상시킬 수 있는 방법이 필요하다.

Table 3. Specification of Hardware and Software

Hardware	Specification	
CPU	Intel Core i9 (8th Generation)	
RAM	64 GB	
Storage	2 TB SSD	
GPU	NVIDIA Geforce RTX 30	
Software	Version	Purpose
Python	3.8	Programming
Pytorch	1.10.1+cu113	Machine Learning Platform for GPU
Pytorchvision	0.11.2+cu113	
Pytorchaudio	0.10.1+cu113	
Pillow	8.4.0	Image Processing
Seaborn	0.11.2	Graph
Matplotlib	3.5.1	
numpy	1.19.5	Data Structure
pandas	1.3.5	Data Analysis
opencv	4.4.0.46	Image Analysis and Processing
scikit-image	0.17.2	
scikit-learn	0.23.2	
scipy	1.5.3	Numerical Analysis

Table 4. Result of evaluation

Classification	Observation (β)	Recognized Objects (α)	Detection Rate (α/β)	
			before	after
Road Facility	78	71	71%	91%
Roadkills	35	34	67%	97%

Fig. 7과 Fig. 8은 각각 도로시설물 불편사항과 로드킬을 자동으로 인식한 몇 개의 결과들을 보여주고 있다. 도로시설물의 경우 중앙분리대가 파손된 케이스, 블라드 또는 시선유도봉이 휘어진 케이스, 표지판이 기울어진 케이스를 정확하게 인식한 것을 볼 수 있다. 로드킬의 경우 매우 높은 확률로 인지에 성공한 것을 볼 수 있는데, 이는 육안으로 보기에 도로 시설물에 비해 인지하기가 수월한 것을 알 수 있다. 다만, 오른쪽 아래 부분의 야간 로드킬 인지의 경우 육안으로 식별이 어려울 수 있음에도 불구하고 성공적으로 인지하였음을 알 수 있다.

신경망 구조의 경우 기존 YOLOv3보다 우수한 성능을 보이는 YOLOv5로 바꾼 것이 주요한 것으로 판단된다. 또한 데이터 강화 작업도 검출을 향상에 중요한 역할을 한 것으로 판단된다. 특히 로드킬의 경우 신고 이미지 외에 오픈소스 이미지 데이터셋에서 상당히 많은 양질의 이미지를 확보할 수 있었고, 도로시설물불량의 경우 육

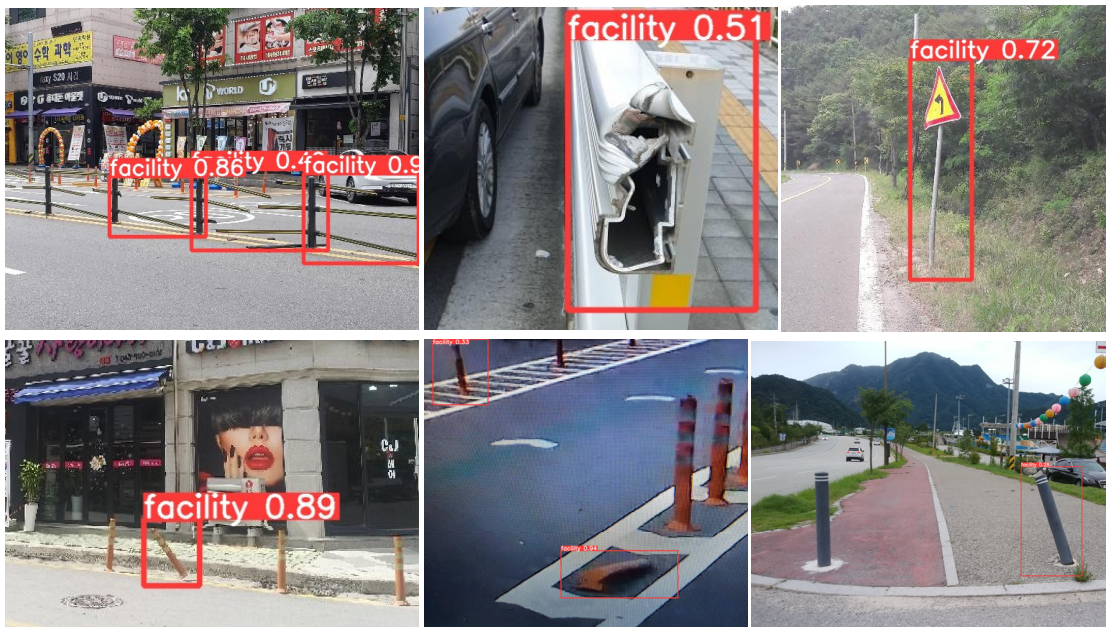


Fig. 7. Samples of the recognition results (Road facility)



Fig. 8. Samples of the recognition results (Road kills)

안으로도 문제점을 발견하기 어려운 애매모호한 이미지를 삭제한 것이 개선 효과를 크게 하는데 많은 기여를 한 것으로 판단된다.

4. 결론

도로위험객체는 심각한 사고와 인명 피해를 초래할 수 있기 때문에 신속하고 정확한 발견과 처리가 중요하다. 이를 위해 이미지 기반의 자동 도로위험객체 인식 기술의 성능 향상이 필수이며, 이에 본 연구에서는 기존의 딥러닝 기반 도로위험객체 자동 인식 시스템의 성능을 향상시키는 방법에 대해 제안하였고, 세부적인 원인 분석을 통해 새로운 솔루션(신경망 구조 변경, 데이터 정제 및 강화)을 제안하였다. 신경망 구조는 기존 YOLOv3보다 우수한 성능을 보이는 YOLOv5로 변경하였고, 데이터 강화를 위해 신고 이미지 중 문제점으로 확인하기 난해한 이미지를 제외하였고, 신호 이미지 외에 오픈소스 이미지 데이터셋에서 양질의 이미지를 추가로 확보하였다. 그리고 이러한 솔루션을 기존 시스템에 적용하여 검증하였다. 제안 방법이 적용된 시스템을 대상으로 성능 인덱스를 이용하여 검증을 수행한 결과, 신경망 구조 변경과 데이터 강화를 통해 유효한 수준의 개선 효과가 있었음을 확인할 수 있었다.

본 연구는 이미지 기반의 자동 도로위험객체 인식 시스템에 대한 여러 단계의 성능 향상 연구의 중간 단계 성과에 해당한다. 앞으로의 지속적인 발전을 위해 체계적인 개발 절차를 제안한 점과 원인 분석 및 솔루션 제안을 적용한 측면에서 의미가 크다고 할 수 있다.

하지만 개별 솔루션(신경망 구조 수정, 데이터 정제 및 강화) 각각의 개선 효과에 대해 검증하지 못한 점과 cross validation과 seed 값 등의 변화에 따른 민감도 분석을 수행하지 못한 점은 본 연구의 한계점이라 할 수 있으며, 이는 향후 연구를 통해 반드시 수행되어야 할 부분이라 판단된다. 또한 YOLOv5 신경망 구조에 대해 도로위험객체 유형에 대한 추가적인 분석 연구가 수행되지 않은 점도 본 연구의 한계점이라 할 수 있다. 개발된 시스템의 현장 적용을 위해서는 검출율을 좀 더 개선할 필요가 있다. 도로위험객체 신고 시스템과 같이 도로관리청에서 이를 기반으로 후속 작업이 필요한 경우 오작동(false alarm)은 곧 비용의 심각한 낭비를 초래하기 때문에 되도록 오작동이 없는 수준으로의 개발이 요구된다.

References

- [1] W. H. Jeon, and I. Yang, "Development of a location-based smartphone app reporting road problems with user

- participation," Journal of Digital Contents Society, Vol. 19, No. 1, pp. 1825-1832, 2018.
DOI: <https://doi.org/10.9728/dcs.2018.19.10.1825>
- [2] I. Yang, W. H. Jeon, and J. Lee, "A study to recognize and classify road dangerous objects automatically using deep learning," Journal of Digital Contents Society, Vol. 22, No. 8, pp. 1323-1329, 2021.
DOI: <https://doi.org/10.9728/dcs.2021.22.8.1323>
- [3] E. Blasch, S. Liu, Z. Liu and Y. Zheng, "Deep Learning Measures of Effectiveness," NAECON 2018 - IEEE National Aerospace and Electronics Conference, 2018, pp. 254-261.
DOI: <https://doi.org/10.1109/NAECON.2018.8556808>
- [4] May, A. D., Traffic flow fundamentals. 1990.
- [5] Y. Zhang, C. Song and D. Zhang, "Deep Learning-Based Object Detection Improvement for Tomato Disease", in IEEE Access, Vol. 8, pp. 56607-56614, 2020.
DOI: <https://doi.org/10.1109/ACCESS.2020.2982456>
- [6] T. Mikolov, S. Kombrink, L. Burget, J. Černocký and S. Khudanpur, "Extensions of recurrent neural network language model", 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2011, pp. 5528-5531.
DOI: <https://doi.org/10.1109/ICASSP.2011.5947611>
- [7] M. Schuster and K. K. Paliwal, "Bidirectional recurrent neural networks", IEEE transactions on Signal Processing, Vol. 45, No. 11, pp. 2673-2681, 1997.
DOI: <https://doi.org/10.1109/78.650093>
- [8] H. Chen, N. Tran, A. S. Thumati, J. Bhuyan, and J. Ding, "Data Curation and Quality Assurance for Machine Learning-based Cyber Intrusion Detection", 2021.
DOI: <https://doi.org/10.48550/arXiv.2105.10041>
- [9] A. Mikołajczyk and M. Grochowski, "Data augmentation for improving deep learning in image classification problem," 2018 International Interdisciplinary PhD Workshop (IIPhDW), 2018, pp.117-122.
DOI: <https://doi.org/10.1109/IIPhDW.2018.8388338>
- [10] L. Taylor and G. Nitschke, "Improving Deep Learning with Generic Data Augmentation," 2018 IEEE Symposium Series on Computational Intelligence (SSCI), 2018, pp.1542-1547.
DOI: <https://doi.org/10.1109/SSCI.2018.8628742>
- [11] W. Samek, T. Wiegand, and K. R. Müller, "Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models," 2017.
DOI: <https://doi.org/10.48550/arXiv.1708.08296>
- [12] H. Challa, N. Niu and R. Johnson, "Faulty Requirements Made Valuable: On the Role of Data Quality in Deep Learning," 2020 IEEE Seventh International Workshop on Artificial Intelligence for Requirements Engineering (AIRE), 2020, pp. 61-69.
DOI: <https://doi.org/10.1109/AIRE51212.2020.00016>
- [13] C. Y. Wang, Liao, H. M., Wu, Y. H., Chen, P., Hsieh, J., Yeh, I., "CSPNet: A New Backbone That can Enhance Learning Capability of CNN," Proc. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, pp. 571-1580, 2020.
DOI: <https://doi.org/10.48550/arXiv.1911.11929>
- [14] Microsoft, COCO(Common Objects in Context) [Internet], <https://cocodataset.org>
- [15] U. Nepal and H. Eslamiat, "Comparing YOLOv3, YOLOv4, YOLOv5 for Autonomous Landing Spot Detection in Faulty UAVs," Sensors 2022, 22, 464.
DOI: <https://doi.org/10.3390/s22020464>

양 인 철(Inchul Yang) [정회원]




- 2000년 2월 : 연세대학교 도시공학과 (교통공학 석사)
- 2011년 6월 : 캘리포니아대학교 (얼바인), 토목환경공학과 (교통공학 박사)
- 2011년 7월 ~ 현재 : 한국건설기술연구원 연구위원

<관심분야>

첨단교통, 자율주행, 인공지능, 모빌리티

전 우 훈(Woo Hoon Jeon) [정회원]



- 2001년 2월 : 한양대학교 교통물류공학과 (교통공학 석사)
- 2016년 8월 : 서울대학교 환경대학원 환경계획학과 (도시계획학 박사)
- 2001년 3월 ~ 현재 : 한국건설기술연구원 연구위원

<관심분야>

도로안전, 무동력 교통수단, 모바일 앱, 도로시설