

CCTV기반 터널 유고상황 감지 성능에 대한 관심영역의 영향성 검토

이규범^{1,2}, 신휴성^{2*}

¹과학기술연합대학원대학교 스마트도시건설융합, ²한국건설기술연구원 미래스마트건설연구본부

Study on influence of the region of interest(ROI) in performance of accident event detection in tunnel CCTV

Kyu Beom Lee^{1,2}, Hyu Soung Shin^{2*}

¹Smart City and Construction Convergence, University of Science and Technology
²Department of Future and Smart Construction Research, Korea Institute of Civil Engineering and Building Technology

요약 도로터널 내에 설치 운용되는 CCTV는 천정고의 한계로 인해 낮은 높이로 설치되며, 청소작업 등의 이유로 CCTV 촬영부가 회전되는 상황이 빈번히 발생한다. 이로 인해 CCTV와 연계 운영되는 영상유고 시스템 상에 설정되는 관심영역도 함께 회전되며, 이는 터널관리자들에게 큰 애로를 야기하는 오탐지의 주요 원인이 된다. 이러한 문제점 검토를 위해, 터널 CCTV의 촬영부가 미세하게 회전할 때, 관심영역을 재설정 한 경우와 그렇지 않은 경우에 대해 터널 영상 유고시스템의 유고상황 인지요류 발생 경향을 비교 검토하였다. 여기서, 터널 영상유고 감지 틀은 딥러닝 기반 객체인식 모델을 사용하였다. 상기 두 경우의 실험조건에 대해 5개월 기간의 실제 터널현장 CCTV 영상에 대하여 유고상황 감지 성능에 대한 실험을 진행하였다. 결과적으로, 관심영역이 회전했을 경우에 많은 오탐지가 발생하였으며, 관심영역을 재설정 한 경우에는 정차 유고상황은 약 75.7%, 역주행은 34% 그리고 보행자는 약 86.8% 수준으로 인지요류가 크게 감소함을 알 수 있었다.

Abstract CCTV is inevitably installed in road tunnels, and frequent situations occur when the CCTV shooting unit is rotated because of cleaning work. As a result, the region of interest (ROI), which is set on a tunnel CCTV-based accident detection system, which operates with CCTV, is also rotated, which is the leading cause of false detection that causes great difficulty for tunnel managers. In order to show an accurate ROI setting, the cases of resetting and remaining ROI were compared for false accident detection of the system. Because this system is based on a deep learning-based object detection model, the performance of objects was confirmed in advance through model training and testing. An experiment was then conducted with videos of an actual tunnel site for five months. As a result, the number of false detections decreased significantly in the case of resetting the ROI to approximately 75.7% for stopping, 34% for backward driving, and 86.8% for pedestrians compared to another case. In the future, when the system is commercialized, the reliability of the system can be increased by resetting the ROI.

Keywords : Region of Interest, Tunnel CCTV, Tunnel CCTV-based Accident Detection System, Deep Learning-based Object Detection Model, False Accident Detection

본 논문은 과학기술정보통신부 한국건설기술연구원 연구운영비지원(주요사업)사업으로 수행되었습니다(극한건설 환경 구현 인프라 및 TRL6 이상급 극한건설 핵심기술 개발).

*Corresponding Author : Hyu Soung Shin(Korea Institute of Civil Engineering and Building Technology)
email: hyushin@kict.re.kr

Received October 17, 2022

Revised January 5, 2023

Accepted February 3, 2023

Published February 28, 2023

1. 서론

유고상황은 정상적인 상황이 아닌 상황을 말하며, 대형사고 및 2차 사고를 유발할 가능성이 상당하므로 신속한 인지 및 대처하는 것이 중요하다[1]. 이에 따라 터널 관리자는 터널 CCTV를 통한 감시를 통해 터널 내 유고상황을 모니터링하고 대처하게 된다. 한편, 국토교통부에서는 유고상황을 자동으로 인지할 수 있는 터널 영상 유고시스템의 설치를 권고한다. 국내 터널 영상유고시스템은 정차, 역주행, 보행자 및 화재 등 4종의 유고상황을 인지하도록 규정하고 있다[1]. 그런데, 기존에 설치된 영상유고시스템은 터널 환경에서 낮은 조도 및 CCTV 촬영부에 누적된 먼지로 인해 유고상황 인지에 대한 정확도가 현저히 낮아진다. 특히, CCTV의 낮은 설치높이로 인해 심한 원근현상이 발생하는데, 이로 인해 터널 CCTV와 100m 이상 먼 지점에서 발생하는 유고상황을 인지하기는 거의 불가능한 것으로 알려져 있다[2].

이 문제를 해결하기 위해, Lee는 관심영역(ROI: Region Of Interest, 이하 ROI) 설정 및 역 원근변환(IPT: Inverse Perspective Transform, 이하 IPT)의 도입을 통해 심한 원근현상을 제거하였으며, 이 과정을 통해 얻은 변환영상(transform image)의 먼 거리 영역에서도 차량에 대한 높은 객체인식 성능을 유지할 수 있음을 보였다[3]. 관심영역은 영상 내에서 유고상황을 감지하는 대상영역을 말하며[4], 역 원근변환은 영상을 구성하는 픽셀의 배치구조를 변경함으로써, 특정 법칙에 따라 영상을 기하학적으로 변환시켜 영상 내에 존재하는 원근현상을 없앨 수 있는 영상변환 방법을 말한다[5].

이와 동시에 Lee는 딥러닝 객체인식 모델을 도입하였다[6,7]. 딥러닝 모델은 입력값과 출력값 한 쌍으로 이루어진 데이터의 모음을 의미하는 데이터셋(dataset)의 학습을 통해 데이터셋의 패턴을 표현할 수 있다[8]. 객체인식(object detection)은 영상 내에서 대상객체를 직사각형 형태의 경계박스로 찾아내는 것을 말한다[9]. 이전 연구에서는 터널 내 영상환경에 특화된 딥러닝 객체인식 모델을 바탕으로 정차, 화재, 역주행에 대하여 각각 100%, 보행자는 78.5%의 유고상황 인지 정확도를 보일 수 있었다[6].

그런데, 터널 영상유고시스템에서는 정상상황에서 유고상황이라고 판단하는 오류를 범하는 경우가 매우 빈번하며, 정탐지 상황보다 유고상황 모니터링 업무상의 심한 피로감과 애로를 초래한다. 이러한 경우를 유고상황 인지요류라고 하며, 유고상황 인지요류 개수를 줄여 터

널 영상유고시스템의 신뢰성을 높이는 것은 매우 중요하다[10].

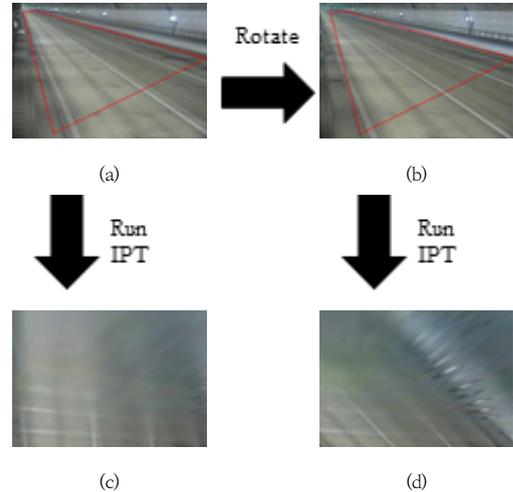


Fig. 1. Changes in the ROI set in the original image and the transform image
(a) Original image with ROI (b) Original image with rotated ROI (c) Transform image from (a) (d) Transform image from (b)

이러한 오탐지의 원인 중 하나는 Fig. 1과 같이 시간이 지남에 따른 CCTV 회전에 따른 원본영상 및 관심영역에 대한 변환영상의 변화를 통해 확인할 수 있다. Fig. 1(a)와 같이, 기 설정된 관심영역은 사각형의 형태이며, 도로상의 유고상황 감시 영역인 도로영역만을 대상으로 설정한다. 이렇게 설정된 관심영역은 직사각형 형태로 변환되며, 변환영상은 Fig. 1(c)와 같이 터널 벽면 내 오탐지를 유발하는 불필요한 지장물들을 포함하지 않는다[4]. 그런데, 터널에서는 주기적으로 작업차량을 통해 CCTV 촬영부에 누적된 먼지를 청소하면서 터널 CCTV의 촬영부가 빈번히 회전하게 된다. 이 과정에서 Fig. 1(b)와 같이 기 설정된 관심영역도 같이 회전한다. Fig. 1(b)를 바탕으로 역 원근변환을 진행하면, Fig. 1(d)와 같이 변환영상에서 차량의 진행방향이 기울어지고, 터널 벽면 지장물들이 감지 대상영역인 관심영역에 포함되며, 결과적으로 빈번한 오탐지를 유발시킨다.

본 논문은 터널 CCTV에서 설정된 관심영역의 미세한 회전이 터널 영상유고시스템의 성능에 미치는 영향을 확인하는 것이 목적이다. 여기서, 영상유고 시스템에서 요구되는 대상객체 인식은 딥러닝 모델을 활용하였다.

2. 딥러닝 객체인식 모델 학습

2.1 학습 조건 및 데이터셋 현황

본 실험에 앞서, 딥러닝 객체인식 모델의 학습을 진행하였다. 딥러닝 객체인식 모델은 정지영상(image)과 레이블링 데이터(labeling data)의 쌍으로 구성된 학습 데이터셋의 학습을 통해 구축된다. 데이터셋 구성을 위해 터널 CCTV영상을 정지영상 단위로 분해한 다음, 역 원근변환을 통해 얻은 변환영상으로 각각 대상객체의 레이블링을 진행하였다. 이 때, 변환영상은 Fig. 1(a)와 같이 터널 내 도로영역만을 나타내며, 정수직 방향으로 차량이 진행되도록 관심영역의 설정 및 역 원근변환을 통해 얻어진다. 데이터셋의 레이블링 대상 객체는 차량(car), 보행자(person), 화재(fire) 3종류이다. 최종 준비된 데이터셋 현황은 Table 1과 같으며, 데이터셋 종류, 정지영상 개수 각 항목별 객체수로 정리하였다.

Table 1. Status of deep learning dataset

Dataset type	Number of images	Number of objects			
		Car	Person	Fire	Total
Train	11634	20896	10858	1164	32918
Test	2921	5183	2717	292	8192
Total	14555	26079	13575	1456	41110

준비된 데이터셋은 학습용 데이터셋(train dataset)과 검증용 데이터셋(test dataset)으로 구분하였다. 학습용 및 검증용 데이터셋은 정지영상 개수 기준 8:2 비율로 나누었다. 각 항목별 객체 수를 살펴보면, 각 도로 터널에서는 도로를 주행하는 차량이 대부분이므로, 유고상황 영상을 레이블링하였음에도 불구하고 3종류의 객체에서 차량의 비중이 크다. 또한, 터널 내에서 화재가 발생하는 경우는 매우 드물기 때문에 화재 객체 수는 가장 비중이 적다.

딥러닝 객체인식 모델은 대표적인 모델 중 하나인 Faster R-CNN(Faster Region-based Convolutional Neural Network)를 사용하였다[11]. 합성곱 신경망층은 50층으로 구성된 ResNet(Residual Network) 사용한다[12]. 사전학습에 사용된 하드웨어는 Intel Xeon e5-2660 v3 CPU 2개, 128GB RAM, NVIDIA GTX 1080 GPU 4개를 사용하였으며, Python 3.7, Tensorflow 1.15.2 버전의 소프트웨어를 활용하였다.

2.2 딥러닝 객체인식 모델 성능 검증

딥러닝 학습 모델의 성능 검증의 경우, 객체인식 분야에서 보편적으로 사용되는 지표인 평균 정밀도(AP: Average Precision, 이하 AP)를 사용하였다[13]. AP값은 데이터셋 종류, 객체 클래스(object class)별로 측정하였다. 각 항목마다 AP값 비교를 통해, 학습용 데이터셋과 검증용 데이터셋의 AP값 차이에 따라 딥러닝 모델의 학습이 지나치게 학습용 데이터셋으로 치우쳐져 있는지, 절대적인 객체인식 성능이 높은지 확인할 수 있다.

딥러닝 모델을 학습한 다음, 학습용 데이터셋과 검증용 데이터셋에 대하여 각각 추론을 진행하여 Table 2와 같이 AP값을 산출하였다. 먼저 차량에 대한 AP값을 보면, 학습용 데이터셋과 검증용 데이터셋의 AP값 차이가 0.017정도로 적은 것으로 확인되며, 일반화 학습이 잘 진행된 것으로 판단된다.

한편, 보행자와 화재는 학습용 데이터셋과 검증용 데이터셋의 AP값 차이가 각각 0.102와 0.094 정도로, 학습 외 영상에 대한 성능은 차량의 경우와 비교했을 때 상대적으로 떨어진다. 하지만, Pascal VOC 데이터셋에서 검증용 데이터셋에 대한 Faster R-CNN의 AP값이 0.732이고[12], 2021년에 발표된 딥러닝 모델의 AP값이 0.893으로 가장 높았다는 것을 감안할 때[14], 중간값 정도에 해당하는 AP값을 보인 보행자와 화재에 대한 학습 결과는 터널 CCTV영상에서 비교적 양호한 학습이 이루어졌음을 알 수 있다.

Table 2. AP values of the trained deep learning model

Dataset type	Object class		
	Car	Person	Fire
Train	0.9955	0.9408	0.9337
Test	0.9786	0.8392	0.8395

3. 관심영역 미세 회전 영향성 검토 실험

3.1 실험 방법

상기 학습한 딥러닝 객체인식 모델이 적용된 터널 영상유고시스템으로 본 실험을 진행한다. 실험 대상 영상은 실제 터널 현장에서 운영되고 있는 CCTV 영상이며, 도출된 영상유고 인지 결과들의 분석을 통해 채널별 인지오류 발생 개수들을 파악하고 비교 검토하였다.

실험 대상 영상은 실제 터널현장의 CCTV 채널 2개를

선정하였으며, 선정된 두 개의 채널 영상에서는 시간이 지남에 따라 터널 CCTV의 촬영부가 조금씩 회전된다. 그리고 Fig. 2 및 Fig. 3과 같이 실험 CASE를 관심영역 재설정 여부로 나누었으며, CASE 1은 초기에 설정된 관심영역을 변경하지 않고 유지하는 경우이며, CASE 2는 촬영부가 미세하게 회전함에 대응하여 관심영역을 재설정 한 경우이다.

Fig. 2는 시간이 지남에 따라 터널 CCTV가 회전하면서 차선의 방향 또한 정수직 보다 일정 각도로 기울어지며, 불필요한 주변 터널 벽면의 지장물들이 변환영상에 포함되는 것을 알 수 있다. 채널 2는 상대적으로 변화가 적지만, 채널 1에서는 4달차부터 도로 차선의 기울기가 45도에 가깝게 기울어지며, 터널 벽면 배경의 노출이 심해진다.

이와 반대로, Fig. 3과 같이 CASE 2는 터널 CCTV에서 회전된 관심영역을 재설정 한 다음, 변환영상을 얻었다. CASE 1과 다르게 차선이 정수직 방향에 가깝게 유지되고 있으며, 도로 배경이 100% 비중을 차지하고 있다.



Fig. 2. Transform images per channel and month in CASE 1



Fig. 3. Transform images per channel and month in CASE 2

이러한 조건들에 대해 동일한 실험 대상 영상을 입력 값으로 영상유고 감지 시뮬레이션을 진행하였다. 이 과정에서 각 실험 CASE마다 설정된 관심영역을 읽어 들인 다음, 역 원근변환을 실행하여 변환영상을 얻는 과정이 진행된다. 이 변환영상을 바탕으로, 객체인식 및 유고상황 판단 후처리 알고리즘을 통하여 유고상황을 인지할 수 있다[6]. 본 논문의 실험 대상 영상은 모두 정상상황 영상이므로, 터널 영상유고시스템에서 인지되는 유고상황은 모두 인지오류로 간주할 수 있다.

실험 대상 영상은 터널 CCTV 영상으로, 1달차씩 1일

분량의 영상을 추론하는데, 각 채널당 약 1시간 간격으로 녹화된 영상을 활용하였다. 1개의 영상이 5분의 영상 길이를 가지며, 각 채널당 113개 및 115개 영상이 실험 대상이다. 본 실험 대상 영상은 원래 30FPS의 프레임레이트(frame rate)를 가진 영상이지만, 터널 영상유고시스템은 효율적인 계산을 위해 5FPS의 프레임레이트를 기준으로 영상을 입력 받는다.

실험 대상 하드웨어는 딥러닝 객체인식 모델 학습 때 사용했던 하드웨어와 동일하며, 같은 터널 영상유고시스템 소프트웨어 12개를 동시에 실행시켜 실험을 진행하였다.

3.2 실험 결과 및 분석

터널 영상유고시스템의 인지오류 개수 측정결과는 Fig. 4와 같이 각 실험 CASE에 대한 채널 별 유고상황 인지오류 개수를 그래프로 나타내었다.

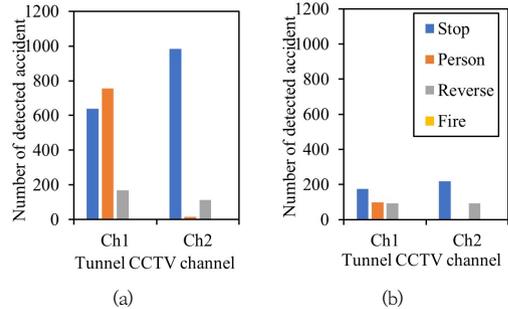


Fig. 4. Number of detected accidents of tunnel CCTV-based accident system for each case (a) CASE 1 (b) CASE 2

CASE 1의 경우, Fig. 4(a)에서 볼 수 있듯이 채널 1에서 636개, 채널 2에서 984개의 정차 유고상황 인지오류가 도출되었다. 반면, Fig. 4(b)의 CASE 2의 경우에는 채널 1 및 채널 2에서 각각 170개, 218개로 정차 인지오류 개수가 감소하였으며, CASE 1과 비교했을 때 각각 73.27%, 77.85% 인지오류율이 감소된 수치이다.

역주행은 CASE 2에서 CASE 1 대비 각 채널별로 각각 46.39%, 18.42% 감소하였다. 보행자의 경우, CASE 2는 CASE 1 대비 86.89%, 82.35% 수준으로 인지오류가 크게 감소한 것을 알 수 있다.

이러한 경향은 Fig. 5와 같이 터널 영상유고시스템에서 관심영역의 설정이 유고상황 인지에 큰 영향을 미친다는 것을 의미한다. Fig. 5(a)와 같이 CASE 1에서는 시간이 지나면서 터널 CCTV가 미세하게 회전함에도 초기

관심영역이 고정됨으로써 차선이 심하게 기울어짐을 보이며, 관심영역 내 터널 벽면 반사광 및 지시등과 같은 불필요한 지장물 객체들이 포함됨을 알 수 있다. 특히, 채널 1에서는 Fig. 2와 같이 영상에서 터널 벽면이 차지하는 비율이 약 1/3 정도로 매우 높았다. 딥러닝 데이터셋에 포함된 영상은 도로 상의 객체만을 학습하였으므로, Fig. 5(a)에서 황색 및 녹색 경계박스와 같이 차량 및 보행자에 대한 다수의 객체인식 오탐지가 유발되는 것을 확인할 수 있었다.

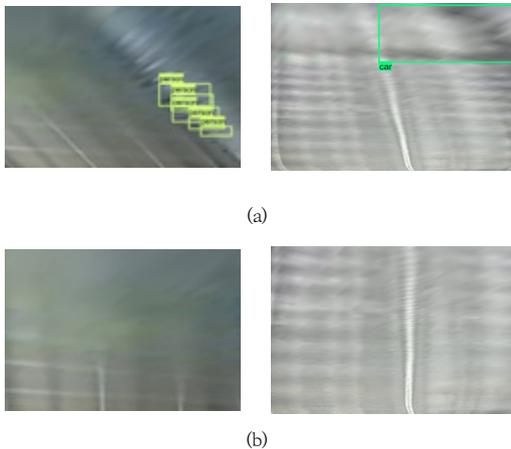


Fig. 5. Example of transform images about false object detection
(a) Transform images with rotated ROI (b) Transform images with calibrated ROI

반면, Fig. 3과 같이 회전된 관심영역을 재설정할 경우, Fig. 4(b)와 같이 유고상황 인지오류 개수가 현저히 줄어드는 것을 알 수 있었으며, Fig. 5(b)와 같이 오탐지를 유발시키는 터널 벽면 및 차선 방향이 제거되고 보정된 것을 확인할 수 있었다. Fig. 5(a)와 비교했을 때, CASE 2는 동일한 영상에 대하여 객체인식 오탐지가 제거된 것을 확인할 수 있었다.

4. 결론

본 논문의 터널 영상유고시스템은 터널 CCTV 영상에서 도로영역만 관심영역을 설정하고 역 원근변환을 통해 차량의 진행방향이 정수직 방향으로 보이도록 변환영상을 생성한다. 그러나 터널 CCTV의 촬영부가 회전하면서 관심영역도 같이 회전하는데, 이로 인해 차량의 진행방향이 기울어지며, 터널 벽면의 불필요한 지장물이 관심

영역 내에 포함되면서 유고상황 인지오류를 유발시킨다. 본 논문은 이를 증명하기 위해 본 설정조건대로 생성된 변환영상 기반 데이터셋을 학습시킨 딥러닝 객체인식 모델을 활용하여 터널 영상유고시스템에서 회전된 관심영역의 재설정 여부에 따라 유고상황 인지오류 발생 수준의 차이가 상당함을 보였으며, 본 실험을 통해 다음과 같은 결론을 얻을 수 있었다.

관심영역의 재설정이 이루어지지 않을 경우, 영상에서 벽면의 불필요한 지장물들이 관심영역 및 변환영상에 포함되면서 차량 및 보행자에 대한 객체인식 오탐지를 유발시키며, 결과적으로 유고상황에 대한 인지오류가 빈번히 발생하게 된다. 따라서 미세하게 회전된 관심영역을 원상태처럼 감지 대상영역(도로영역)만을 포함하도록 재설정하여야 하며, 이를 통해 터널 영상유고시스템의 유고상황 인지오류를 최소화 할 수 있다. 이는 영상유고시스템에서 정밀한 관심영역 재설정의 중요함을 의미한다. 하지만, 현재에 이러한 재설정 작업은 가용한 터널 영상유고시스템 관리 현장인력을 통해 이루어 질 수 있으며, 현장 관리인력은 주기적으로 CCTV영상의 점검 및 관심영역 재설정을 수행하여야 하므로 많은 인건비와 시간비용이 소요될 것이다. 따라서 비용 절감을 위해 CCTV영상을 실시간 분석하여 CCTV의 미세한 회전에 따라 영상내 차선의 방향을 자동 감지하고, 이에 대해 관심영역을 재설정하는 과정을 자동화하는 기술개발이 필요할 것으로 판단된다.

References

- [1] Ministry of Land, Infrastructure and Transport (MOLIT), "Guideline of installation and management of disaster prevention facilities on road tunnels", 2021.
- [2] Korea Tunneling and Underground Space Association (KTA), "Study on revision of installation and operation guideline for hazard mitigation facilities of road tunnels", Ministry of Land Infrastructure and Transport (MOLIT), pp.326, 2015.
- [3] K. B. Lee, H. S. Shin, "A study for improvement of far-distance performance of a tunnel accident detection system by using an inverse perspective transformation.", *Journal of Korean Tunneling and Underground Space Association*, Vol.24, No.3, pp.247-262, 2022.
DOI: <https://doi.org/10.9711/KTAJ.2022.24.3.247>
- [4] H. S. Shin, D. G. Kim, M. J. Yim, K. B. Lee, Y. S. Oh, "A preliminary study for development of an automatic

incident detection system on CCTV in tunnels based on a machine learning algorithm”, *Journal of Korean Tunnelling and Underground Space Association*, Vol.19, No.1, pp.95-107, 2017.

DOI: <https://doi.org/10.9711/KTAJ.2017.19.1.095>

- [5] H. A. Mallot, H. H. Bülthoff, J. J. Little, S. Bohrer, “Inverse perspective mapping simplifies optical flow computation and obstacle detection”, *Biological Cybernetics*, Vol.64, No.3, pp.177-185, 1991.
DOI: <https://doi.org/10.1007/BF00201978>
- [6] K. B. Lee, H. S. Shin, “Development of a deep-learning based automatic tracking of moving vehicles and incident detection processes on tunnels.”, *Journal of Korean Tunnelling and Underground Space Association*, Vol.20, No.6, pp.1161-1175, 2018.
DOI: <https://doi.org/10.9711/KTAJ.2018.20.6.1161>
- [7] K. B. Lee, H. S. Shin, “Effect on self-enhancement of deep-learning inference by repeated training of false detection cases in tunnel accident image detection.”, *Journal of Korean Tunnelling and Underground Space Association*, Vol.21, No.3, pp.419-432, 2019.
DOI: <https://doi.org/10.9711/KTAJ.2019.21.3.419>
- [8] Y. LeCun, B. Yoshua, H. Geoffrey, “Deep learning”, *Nature*, Vol.521, pp.436-444, 2015.
DOI: <https://doi.org/10.1038/nature14539>
- [9] Z. Zou, Z. Shi, Y. Guo, J. Ye, “Object detection in 20 years: A survey”, *arXiv preprint*, arXiv:1905.05055, 2019.
DOI: <https://doi.org/10.48550/arXiv.1905.05055>
- [10] K. B. Lee, H. S. Shin, “An application of a deep learning algorithm for automatic detection of unexpected accidents under bad CCTV monitoring conditions in tunnels.”, *In 2019 International Conference on deep learning and machine learning in emerging applications (Deep-ML)*, pp.7-11, 2019.
DOI: <https://doi.org/10.1109/Deep-ML.2019.00010>
- [11] S. Ren, K. He, R. Girshick, J. Sun, “Faster r-cnn: Towards real-time object detection with region proposal networks”, *Advances in neural information processing systems*, 2015.
DOI: <https://dl.acm.org/doi/10.5555/2969239.2969250>
- [12] K. He, X. Zhang, S. Ren, J. Sun, “Deep residual learning for image recognition”, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.770-778, 2016.
DOI: <https://doi.org/10.1109/CVPR.2016.90>
- [13] M. Zhu, “Recall, precision and average precision”, Department of Statistics and Actuarial Science, University of Waterloo, Waterloo 2: 30, 2004.
- [14] G. Ghiasi, Y. Cui, A. Srinivas, R. Qian, T. Y. Lin, E. D. Cubuk, Q. V. Le, B. Zoph, “Simple copy-paste is a strong data augmentation method for instance segmentation”, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.2918-2928, 2021.
DOI: <https://doi.org/10.1109/CVPR46437.2021.00294>

이 규 범(Kyu Beom Lee)

[정회원]



- 2017년 2월 : 한양대학교 자원환경공학과 공학학사
- 2017년 3월 ~ 현재 : 과학기술연합대학원대학교 스마트도시건설융합 (석박사 통합과정)
- 2017년 3월 ~ 현재 : 한국건설기술연구원 학생연구원

<관심분야>

터널 영상유고시스템, 인공지능, 영상 및 신호처리

신 휴 성(Hyu Soung Shin)

[정회원]



- 1996년 3월 : 한양대학교 자원공학과 암반공학전공 공학석사
- 2002년 1월 : 영국 University of Wales Swansea, 토목공학과 (전 산지반공학전공 공학박사)
- 2003년 6월 ~ 현재 : 한국건설기술연구원 선임연구위원

<관심분야>

수치모델링, 지반공학, 인공지능, 영상 및 신호처리