

자율주행 차량 영상 기반 객체 인식 인공지능 기술 현황

임헌국*

Overview of Image-based Object Recognition AI technology for Autonomous Vehicles

Huhnkuk Lim*

*Assistant Professor, Division of Computer Engineering, Hoseo University, Chungnam Asan, 31499 Korea

요 약

객체 인식이란 하나의 특정 이미지를 입력했을 때, 주어진 이미지를 분석하여 특정한 객체(object)의 위치(location)와 종류(class)를 파악하는 것이다. 최근 객체 인식 기술이 적극적으로 접목되는 분야 중 하나는 자율주행 차량이라 할 수 있고, 본 논문에서는 자율주행 차량에서 영상 기반의 객체 인식 인공지능 기술에 대해 기술한다. 영상 기반 객체 검출 알고리즘은 최근 두 가지 방법(단일 단계 검출 방법 및 두 단계 검출 방법)으로 좁혀지고 있는데, 이를 중심으로 분석 정리하고자 한다. 두 가지 검출 방법의 장단점을 분석 제시하고, 단일 단계 검출 방법에 속하는 YOLO/SSD 알고리즘과 두 단계 검출 방법에 속하는 R-CNN/Faster R-CNN 알고리즘에 대해 분석 기술한다. 이를 통해 자율주행에 필요한 각 객체 인식 응용에 적합한 알고리즘이 선별적으로 선택되어 연구개발 되어질 수 있기를 기대한다.

ABSTRACT

Object recognition is to identify the location and class of a specific object by analyzing the given image when a specific image is input. One of the fields in which object recognition technology is actively applied in recent years is autonomous vehicles, and this paper describes the trend of image-based object recognition artificial intelligence technology in autonomous vehicles. The image-based object detection algorithm has recently been narrowed down to two methods (a single-step detection method and a two-step detection method), and we will analyze and organize them around this. The advantages and disadvantages of the two detection methods are analyzed and presented, and the YOLO/SSD algorithm belonging to the single-step detection method and the R-CNN/Faster R-CNN algorithm belonging to the two-step detection method are analyzed and described. This will allow the algorithms suitable for each object recognition application required for autonomous driving to be selectively selected and R&D.

키워드: 객체 인식, 자율주행 차량, 영상 기반 인공지능, 단일 단계 검출, 두 단계 검출

Keywords: Object detection, Autonomous vehicle, Image-based AI, Single-step detection, Two-step detection.

Received 18 July 2021, Revised 21 July 2021, Accepted 29 July 2021

* Corresponding Author Huhnkuk Lim(E-mail:rooky13@hanmail.net, Tel:+82-41-540-5942)

Assistant Professor, Division of Computer Engineering, Hoseo University, Chungnam Asan, 31499 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.8.1117>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

최근 인공지능의 발전이 급속도로 이뤄짐에 따라 컴퓨터 비전, 자연어 처리, 미래 예측, 심지어는 예술 분야에까지 기계학습이 적용되는 등, 다양한 분야와의 접목이 시도되고 있다. 그중에서도 컴퓨터와 인공지능을 통해 인간의 시각적 능력을 재현하고자 하는 연구 분야인 컴퓨터 비전의 한 갈래인 객체 인식(Object detection) 분야는, 인공지능 개발이 활성화되기 이전부터 많은 시도가 있어왔고 최근 들어 기계학습과 접목하여 많은 성과를 얻고 있는 분야라고 할 수 있다.

객체 인식이란 하나의 특정 이미지를 입력했을 때, 주어진 이미지를 분석하여 특정한 객체(object)의 위치(location)와 종류(class)를 파악하는 것이다. [1]. 최근 객체 인식 기술이 적극적으로 접목되는 분야 중 하나는 자율주행 차량이다.

자율주행 차량은 운전자의 개입 없이 자체적으로 주변 환경을 인식하고, 주행 상황을 판단하여 목적지까지 스스로 주행이 가능하다. 때문에 자율주행 차량은 교통사고 및 도로 범죄 발생률을 감소시킬 수 있고, 운전자의 편의를 증대시키는 등 교통 효율성을 높일 수 있으며 최적의 경로를 찾음으로써 운전의 에너지 효율을 높여 도시 오염을 줄일 수 있다. 현재로서는 완전하진 않지만 일부 기능은 구현되어 첨단 운전자 지원시스템인 ADAS (Advanced Driver Assistance Systems)의 형태로 실현되고 있다.

하지만 실제로 완전한 자율주행 차량이 상용화되기까지는 아직 많은 어려움이 있을 것으로 예상되는데 예를 들어 외부와 무선으로 연결된 컴퓨터의 시스템 보호 문제, 사고 발생시의 책임소재의 문제, GPS상에 표시되지 않는 또는 통신이 되지 않는 지역에서의 운전 문제 등이 있을 수 있다.

이러한 자율주행 차량은 사람의 귀와 눈과 같은 역할을 하는 레이더(Radar), 라이다(LiDAR)와 같은 센서와 카메라 및 초음파와 같은 다양한 기기를 이용하여 차선이나 주변의 차량 등에 대한 정보를 종합하여 주변 환경 데이터와 주행 상황에 대한 데이터를 수집하고, 이를 기반으로 판단하고 향후 벌어질 일을 예측하여 가장 안전하고 빠른 차량의 진로를 결정한다. 그 중에서도 장애물, 제한 조건이 있는 도로 환경에 따라 특성을 추출하여 인공지능 기술을 통해 훈련시키고 적용하는 것이 필

요하다 [1-2].

자율주행에서 얻을 수 있는 강점은 사람처럼 집중력이 흐트러지는 일이 없다는 점이다. 그러나 그러기 위해서는 우선 차량의 눈을 통해 인식한 정보의 정확성이 보장되어야만 한다. 영상 정보를 통해서 마치 사람의 눈처럼 물체를 판별하고 상황을 인식하는 것이야말로 자율주행에 있어 가장 중요한 조건이라고 할 수 있다.

본 논문에서는 자율주행 차량에서 영상 기반의 객체 인식 인공지능 기술에 대해 묘사한다. 특히 영상 기반 객체 검출 알고리즘은 최근 두 가지 방법(단일 단계 검출 방법 및 두 단계 검출 방법)으로 좁혀지고 있는데, 이를 중심으로 분석 정리하고자 한다. 이를 통해 자율주행에 필요한 각 객체 인식 응용에 적합한 알고리즘이 선별적으로 선택되어 연구개발 되어질 수 있을 것이다.

II. 자율주행 차량 객체 인식

자율주행 차량은 아래와 같은 기술을 융합 혹은 복합 사용하여 자율주행을 위한 객체 인식에 이용하고 있다.

2.1. 센서

사람이 운전 도중에 눈과 귀를 사용해 운전이 필요한 정보를 획득하듯이 자율주행 차량도 현재 위치와 외부 환경을 인지하기 위해 센서를 사용한다. 신뢰성을 높이기 위해 여러개의 센서를 부착하고 정보를 규합하여 인식율을 높이는 것이 일반적이다.

자율주행 차량에서 사용하는 대표적인 센서에는 라이다와 레이더가 있다. 라이다는 레이저를 쏘아 돌아오는 초점 이미지와 시간을 계산하여 특정 지점의 위치를 파악하고 이를 3차원 정보로 만들어 가공하여 제공한다 [1-2]. 레이더는 전자파를 쏘아 돌아오는 반사파를 계산하여 위치와 형상을 파악하기 위해 사용한다. 주변 환경이나 기상 상황에 영향을 적게 받으며 움직이는 물체에 대해 상대적인 거리를 측정하기에 적합하다. 또한 2차원으로 제공되어 정보의 차원은 낮으나 추돌 위험 상황을 빠르고 신뢰성 있게 파악할 수 있다 [2].

2.2. 카메라

차선을 인식하고 주변 사물 형태와 색상을 인식하기 위해 사용된다. 해상도가 높은 정보를 제공하므로 자율주행 차량의 객체 인식을 위한 핵심으로 자리 잡고 있다.

하지만 역광, 상향등, 안개와 같은 외부 조건에 취약하며 내용을 해석하는 과정에서 오류가 발생할 가능성이 있다 [2].

자율주행 차량은 정지된 영상뿐 아니라 연속으로 이어진 영상에서도 객체를 인식해야 하며, 시간적으로 진행되는 영상에서 각 객체에 아이디를 부여하고 이들을 추적하는 계산을 성공적으로 수행해야 한다. 또한 카메라를 부착한 자율주행 차량이 고속으로 이동을 할 때는 객체를 탐지할 시간이 매우 제한된다 [2].

카메라를 이용한 영상인식기술이 자율주행 차량에 적용되기 위해서 중요한 두 가지는 속도와 정확도이다. 자율주행 차량에서 영상인식기술이 적용되기 위해서는 먼저 속도를 보장해야 한다. 아무리 정확한 알고리즘이라도 속도가 느린 알고리즘이라면 자율주행 차량에서 사용할 수 없다. 다음으로 중요한 것은 정확도인데 속도가 빠른 알고리즘이라도 주변의 사물을 정확히 검출하지 못한다면, 탑승자와 주변까지 위험하게 만들기 때문이다.

2.3. 초음파

음파를 쏘아 돌아오는 반사파를 계산하여 위치를 파악하기 위해 사용한다. 근접거리에서 사물의 위치를 측정하기에 적합하다 [2].

III. 영상 기반 객체인식 인공지능 기술

객체 검출 알고리즘은 우선 영상에서 객체의 위치를 찾아야 하고(Localization), 그 위치의 객체가 어떤 물체인지를 분류해야 된다(Classification). 이를 수행하기 위하여 다양한 방법들이 시도되어왔고, 최근 단일단계 검출 방법과 두단계 검출 방법으로 좁혀지고 있다 [3].

단일 단계 검출 방법은 모든 영역에 대해서 위치 검출과 분류를 동시에 수행한다. 두 단계 검출 방법은 대략적인 위치 검출을 수행하고, 선출된 후보군들에서 분류를 수행한다.

단일 단계 검출기는 앞에서 언급한 것과 같이 모든 영역에서 객체의 위치 검출과 분류를 동시에 수행한다. 이를 동시에 수행하다보니, 속도는 빠르지만 정확도는 두 단계 검출 방법보다 조금 떨어지는 단점이 존재한다. 반대로 두 단계 검출기는 객체 위치 검출과 분류가 순차적

으로 이루어지므로, 정확도는 상대적으로 뛰어나지만 속도가 느리다는 단점을 가지고 있다.

단일 단계 검출기의 대표적인 예로는 YOLO, SSD 알고리즘이 두 단계 검출기의 대표적 예로는 R-CNN, Faster R-CNN이 있다. 단일 단계 방식과 두 단계 방식은 인식 속도와 인식 정확도 부분에서 각각의 장점을 갖고 있기 때문에 두 가지 모두 고르게 연구되고 있는 추세이다.

본 장에서는 자율주행 차량의 영상 기반 객체 인식 기술을 단일 단계 검출 방법 및 두 단계 검출 방법으로 나누어 각 알고리즘에 대해 기술한다.

3.1. YOLO 알고리즘

단일 단계 알고리즘의 대표적 예인 YOLO(You Only Look Once)[4] 알고리즘은 하나의 컨볼루션 네트워크를 통해 여러 바운딩 박스에 대한 클래스 확률을 계산하는 방식으로 이루어진다. YOLO는 각각의 바운딩 박스를 예측하기 위해 이미지 전체의 특징을 활용하는데 이러한 YOLO의 디자인 방식 덕분에 정확성을 유지하면서 end-to-end 학습과 빠른 객체 검출이 가능하다.

YOLO에 이미지를 입력하게 되면, 먼저 그 이미지를 SxS 크기의 그리드(grid)로 나누게 되고 각각의 그리드 셀(grid cell)은 B개의 네모박스와 각 박스에 대한 신뢰도 점수(confidence score)를 갖게 되는데, 이를 수식으로 나타내면 식 (1)과 같다. 각각의 바운딩 박스는 박스의 중심점으로부터 그리드 셀의 범위에 대한 상대값인 (x,y)좌표와 전체 이미지의 폭, 높이와 그리드 박스의 폭, 높이에 대한 상대값인 intersection over union (IOU) 및 신뢰도로 구성되게 된다 [4].

$$\text{Confidence Score}(Cs) = pr(obj) * IOU_{pred}^{truth} \quad (1)$$

YOLO 모델은 단일 CNN 구조를 이용하여 설계되었다. YOLO에서의 CNN 구조의 앞단은 합성곱 계층(convolutional layer)이고, 이어서 전결합 계층(fully-connected layer)으로 구성되어 있다. 합성곱 계층은 이미지로부터 특징을 추출하고, 전결합 계층은 클래스 확률과 바운딩 박스의 좌표를 예측한다.

추론 단계에서도 이미지로부터 객체를 검출하는 데에는 하나의 신경망 계산만 하면 되기 때문에 매우 빠른 속도를 얻을 수 있다. 만약 객체가 있을 확률이 매우 낮다면 그곳에 어떠한 클래스가 있는지에 대한 정보도 매우 낮아지게 된다. 위와 같은 과정을 모든 그리드 셀에

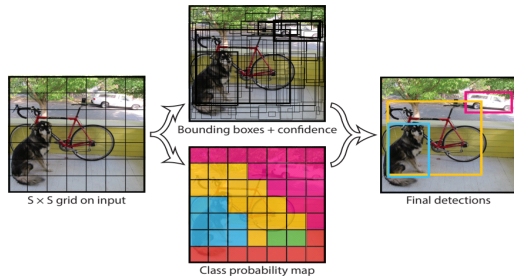


Fig. 1 YOLO algorithm[4]

서 반복하고 그 결과를 종합하는 것으로 최종적인 객체 인식 과정을 마치게 된다.

그러나 YOLO의 그리드 디자인은 한 가지 단점이 있는데, 하나의 객체를 여러 그리드 셀이 동시에 검출하는 경우가 있다는 점 때문이다. 객체의 크기가 크거나 객체가 그리드 셀의 경계에 인접해 있는 경우, 그 객체에 대한 바운딩 박스가 여러 개 생길 수 있다. 즉, 하나의 그리드 셀이 아니라 여러 그리드 셀에서 해당 객체에 대한 바운딩 박스를 예측할 수 있다는 것이다 [4].

하나의 객체가 하나의 그리드 셀에만 존재하는 경우에는 문제가 없지만 객체의 크기나 객체의 위치에 따라 이러한 문제가 발생할 수 있고 이를 다중 검출 문제라고 한다. 이런 다중 검출 문제는 비 최대 억제(non-maximal suppression, NMS) 알고리즘을 적용하여 개선할 수 있다. 비 최대 억제 알고리즘은 각 객체에 대해 예측한 바운딩 박스들 중 가장 높은 정확도를 가진 박스만을 남기기 위한 것으로, 간단히 말해 어떠한 바운딩 박스가 있을 때, 그 바운딩 박스의 분류 점수 순서대로 박스를 내림차순으로 정렬시켜 순서대로 바운딩 박스의 IOU의 값이 설정한 임계치 값 이하이면 그 박스를 버리는 방식이다. 단, 임계값을 크게 설정하면 그 값보다 낮은 값을 제거하게 되므로 다수 객체를 인식할 때 정밀도가 감소하게 된다. 그림 1의 가장 오른쪽 이미지와 같이 가장 객체가 존재할 가능성이 높은곳의 바운딩 박스만을 남기게 된다[4].

YOLO는 비교적 빠르고 정확한 출력을 얻을 수 있는 객체 인식 알고리즘이나, 학습 단계에서 몇 가지 한계를 갖고 있다. 우선 공간적 제약(spatial constraints)이다. YOLO는 하나의 그리드 셀마다 두 개의 바운딩 박스를 예측하고, 하나의 그리드 셀에서 하나의 객체만을 검출할 수 있다. 결과적으로 하나의 그리드 셀에 두 개 이상의 객체가 붙어있다면 이를 잘 검출하지 못하는 문제를

발생시킨다 [4].

두번째 문제로는 중형비의 문제가 있다. YOLO 모델은 기존의 데이터로부터 바운딩 박스를 예측하는 것을 학습하기 때문에, 훈련 단계에서 학습하지 못했던 새로운 중형비(aspect ratio, 가로 세로 비율)를 갖는 이미지에서는 검출에 오차가 생기게 된다 [4].

마지막으로 부정확한 위치에 대한 문제가 있다. YOLO는 큰 바운딩 박스와 작은 바운딩 박스에 대해 동일한 가중치를 둔다. 큰 바운딩 박스에 비해 작은 바운딩 박스가 위치 변화에 따른 IOU 변화가 더 심하기 때문에, 결과적으로 크기가 큰 바운딩 박스는 위치가 약간 달라져도 객체 인식 능력에 별 영향을 주지 않지만 크기가 작은 바운딩 박스의 경우 위치가 조금만 달라져도 성능에 큰 영향을 줄 수 있고 이로 인한 오차가 발생할 수 있다 [4].

3.2. SSD 알고리즘

SSD는 단일 단계 검출 기반의 알고리즘으로 위 언급한 YOLO의 한계를 극복하기 위해 탄생한 기술이다 [5]. SSD는 YOLO와 달리 컨볼루션 과정을 거치는 중간 중간 특징맵 들에서 모두 객체 검출을 수행한다. 컨볼루션을 계층을 계속 진행하여 최종적으로는 1x1 크기의 특징맵까지 뽑게되고 각 단계별로 추출된 특징맵은 Detector & Classifier를 통과시켜 객체 인식을 수행한다. 높은 해상도의 특징 맵에서는 작은 물체를 잘 잡아낼 수 있고, 낮은 해상도의 특징 맵에서는 큰 물체를 잘 잡아낼 것이라고 추측할 수 있다. SSD는 그림 2와 같이 각각의 피쳐맵을 가져와서 비율과 크기가 각기 다른 Default Box를 투영한다. 그리고 이렇게 찾아낸 박스들에 Confidence level을 계산한다 [5].




Fig. 2 SSD framework[5]

3.3. CNN 알고리즘

CNN은 대표적인 두 단계 검출 기법으로 가장 널리 쓰이는 영상 이미지 분석 기술 중 하나이다. CNN은 유

용한 정보를 얻기 위해 입력 데이터를 필터링하기 위해 사용되는 합성곱 계층(Convolutional Layer)과 풀링 계층(Pooling Layer)으로 이루어져 있다. 합성곱 계층에서는 합성곱 연산, 패딩(padding), 스트라이드(stride)가 이루어진다.

합성곱 연산은 이미지 처리에서 말하는 필터 연산을 말하며, 합성곱 연산에서 주요 단어를 꼽자면 필터(Filter), 윈도우(Window), 단일 곱셈-합산(Fused multiply-add, FMA)이 있다. 합성곱 연산에는 입력 데이터에 필터를 적용하여 데이터의 크기를 줄인다. 패딩은 Zero padding이라고도 부르며 합성곱 연산을 수행하기 전에 미리 입력 데이터 주변에 0을 비롯한 특정 값을 채워 넣어 출력 크기를 조절할 목적으로 사용한다. 다음으로 스트라이드는 필터를 적용하는 위치의 간격을 정하는 것을 의미한다.

풀링 계층은 가로, 세로 방향의 공간을 줄이는 연산 작업이며 최대 풀링(Max pooling)과 평균 풀링(Average pooling)의 두가지 과정이 있다. 최대 풀링의 경우 가장 큰 값들만을 가져와서 표기 하는 방식으로 4x4의 matrix를 2x2의 matrix로 줄여줌으로써 parameter의 개수를 줄여 소요되는 컴퓨터 리소스와 시간을 단축할 수 있다는 장점이 있다. 평균 풀링은 풀링 영역의 평균을 계산하는 연산이다. 풀링의 윈도우 크기는 스트라이드와 같은 값을 설정하는 것이 보통이며, 예로 윈도우가 (3, 3)이면, 스트라이드는 3으로 설정한다. 이러한 풀링 계층의 특징은 다음과 같은데, 먼저 학습해야 할 매개변수가 없고, 채널 수가 변하지 않으며 입력의 변화에 영향을 적게 받는다는 점이다.

합성곱 계층은 필터를 이용하여 low level의 특징들을 잡아내고, 점차적으로 high level의 특징들을 찾아내게 된다. 그 이후 추출한 특징들을 바탕으로 fully connected layer에서 이미지가 무엇인지를 인식하게 된다. fully-connected layer는 합성곱 계층으로 추출한 특징을 분류하는 역할을 하며, 보통 수십에서 수천 개의 특징을 다룬다. 각 계층을 1차원 벡터로 변환하는 Flatten 과정 이후 1차원 벡터로 변환된 계층을 나의 벡터로 연결하여 가장 확률이 높은 것을 출력한다.

교통표지 인식에 CNN 기반의 알고리즘이 보통 적용되는데, 입력 이미지 중 교통표지가 포함된 이미지를 고르고, 또 다른 네트워크를 이용하여 교통표지 영역을 추출한 후 마지막으로 교통표지를 분류하는 방식을 사용

한다 [6]. 차선 인식 분야에도 최근 CNN을 이용하여 입력 이미지로부터 차선 이미지 픽셀을 직접 분류하는 연구가 진행되었고, CNN을 이용해 추출된 특징에 Decision Tree, SVM 등의 기계학습을 적용하여 차선을 구분하는 연구가 진행되고 있다 [7-9]. 물체 인식을 위해선 2012년 탄생한 CNN 기반 모델인 AlexNet이 대세를 이루게 되었고 [10-11], 최근 CNN을 이용하여 입력 이미지에서 물체를 추적하는 연구 또한 이루어지고 있다 [12].

3.3.1. R-CNN

R-CNN은 그림 3에 보여지는 것처럼 전처리 과정으로 원하는 영상에 선택적 탐색을 적용하여 객체가 있을 리라 추정하는 후보 영역(Region Proposal: RP)을 찾아낸 다음, 각 후보 영역마다 CNN을 적용하는 방법을 사용한다 [2][13]. 후처리 과정으로 전통적인 SVM(Support Vector Machine) 기법을 활용하여 CNN에서 얻은 결과물을 판별한다. 하지만 전반적인 검출과정에서 RP 마다 CNN을 적용해야 하며 RP 자체도 계산이 필요하므로 성능 문제가 발생한다 [2][13].




Fig. 3 Object detection in R-CNN[13]

3.3.2. Faster R-CNN

R-CNN의 문제를 해소하기 위해 Faster R-CNN이라는 개선된 기법이 탄생하였다 [2][14]. Faster R-CNN에서는 객체가 있을 만한 위치에 대한 후보군 ROI(Region of Interest) 라는 층을 도입하여 CNN을 한 번만 적용하고 ROI 풀링으로 객체 판별을 위한 특징을 추출한다. 따라서 RP 계산은 물론이고 RP 마다 반복적인 CNN 적용도 필요하지 않으므로 성능을 높일 수 있다. 또한 R-CNN과는 달리 영상 판별을 위해 SVM을 사용하지 않고 단일 네트워크 내부에 Softmax 층을 배치하는 방법으로 모델을 단순화할 수 있다 [2][14].

그림 4는 Faster R-CNN 알고리즘의 구조이다. 입력 이미지로부터 특징 맵을 추출한 다음 이를 RPN에 전달하여 입력 후보군 (Region of Interest: RoI)를 계산한다. 여기서 얻은 RoI를 이용하여 풀링을 진행한 다음 분류




Fig. 4 Faster R-CNN structure[14]

를 진행하여 객체 검출을 수행하는 것이다. 즉 객체가 있을 만한 위치에 대한 후보군(RoI)들을 찾아낸 후, 후보군들 각각에 대해 분류를 수행하고, 후보군 내에서 더욱 정확한 위치에 대한 연산을 수행하는 것이다 [2][14].

IV. Conclusion

본 논문에서는 자율주행 차량에서 객체 인식을 위한 영상 기반 인공지능 알고리즘을 단일 단계 검출, 두단계 검출 방법을 중심으로 분석 정리하였다. 단일 단계 검출기의 대표적 기술인 YOLO, SSD 알고리즘이 두 단계 검출기의 대표적 기술인 R-CNN, Faster R-CNN이 영상 기반 객체 인식을 위한 핵심 인공지능 기술로 발전하고 있음을 확인하였다.

단일 단계 검출 알고리즘은 높은 속도를 가지지만, 낮은 정확도를 가진다는 단점이 존재하였다. 반면 두 단계 검출 알고리즘은 정확도는 높으나, 속도가 떨어진다는 단점이 존재하였다. 객체 인식 응용 특성에 따라 빠른 속도를 갖는 YOLO, SSD와 같은 단일단계 알고리즘을 혹은 우수한 정확도를 갖는 R-CNN, Faster R-CNN과 같은 두 단계 알고리즘을 선별적으로 이용할 수 있을 것이다.

단일 단계 및 두 단계 검출 방법의 성능을 향상시키는 다양한 연구들이 현재도 계속 진행 중이나 객체 검출 알

고리즘을 실제로 자율주행 차량에 적용하기 위해서는 해결해야 할 숙제들이 많이 남아 있다.

ACKNOWLEDGEMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(Ministry of Science and ICT) (No. 2021R1A2C1010481)

REFERENCES

- [1] K. Park, M. Lee, S. Noh, S. Park, C. Lee, J. Woo, and K. Jung, "Object recognition deep learning network and implementation method for autonomous vehicles," *The Magazine of the IETE*, vol. 46, no. 1, pp. 18-29, 2019.
- [2] J. Park, "Artificial Intelligence Technology Trends in Autonomous Vehicles," *IITP Weekly Technology Trends*, pp. 1-16, Aug. 2018.
- [3] N. Gawk, "Image Recognition Trends for Autonomous Vehicles," *Auto Journal*, Jun. 2018.
- [4] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779-788, 2016.
- [5] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Y. Fu, and A. C. Berg, "SSD: Single Shot MultiBox Detector," *European Conference on Computer Vision (ECCV)*, pp. 21-37, 2016.
- [6] H. Xu and G. Srivastava, "Automatic recognition algorithm of traffic signs based on convolution neural network," *Multimedia Tools and Applications*, vol. 79, Jan. 2020.
- [7] J. Kim, J. Kim, G. Jang, and M. Lee, "Fast learning method for convolutional neural networks using extreme learning machine and its application to lane detection," *Neural Networks*, vol. 87, Mar. 2017.
- [8] V. John, Z. Liu, S. Mita, C. Guo, and K. Kidono, "Real-time road surface and semantic lane estimation using deep features," *Signal, Image and Video Processing*, vol. 12, Mar. 2018.
- [9] D. Neven, B. D. Brabandere, S. Georgoulis, M. Proesmans, and L. V. Gool, "Towards End-to-End Lane Detection: an Instance Segmentation Approach," arXiv: 1802.05591, 2018.

- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in Neural Information Processing Systems*, pp. 1106-1114, 2012.
- [11] M. Mancini, G. Costante, P. Valigi, and T. A. Ciarfuglia, "J-MOD2: Joint monocular obstacle detection and depth estimation," *IEEE Robot. Autom. Lett.*, vol. 3, no. 3, pp. 1490-1497, 2018.
- [12] B. Huval, B. Huval, T. Wang, S. Tandon, J. Kiske, W. Song, J. Pazhayampallil, M. Andriluka, P. Rajpurkar, T. Migimatsu, F. Mujica, A. Coates, and A. Y. Ng, "An empirical evaluation of deep learning on highway driving," Apr. 2015.
- [13] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," *2014 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 580-587, Jun. 2014.
- [14] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137-1149, 2017.



임헌국(Huhnkuk Lim)

2020년 3월~현재 : 호서대학교 컴퓨터공학부 조교수
2006년 3월~2020 2월 : 한국과학기술정보연구원 슈퍼컴퓨팅본부 책임연구원
2006년 2월 : 광주과학기술원 정보통신공학과 박사
2001년 2월 : 광주과학기술원 정보통신공학과 석사
1999년 2월 : 항공대학교 전자공학과 학사
※ 관심분야 : 에지 시, 차량 NDN, 통신 컴퓨팅 융합