

가상 환경과 실제 환경의 병행 강화학습을 통한 실내 자율주행⁺

(Indoor Autonomous Driving through Parallel Reinforcement
Learning of Virtual and Real Environments)

정 유 석¹⁾, 이 창 우^{2)*}
(Yuseok Jeong and Chang Woo Lee)

요약 강화 학습을 통한 실내 자율주행을 위해 가상 환경과 실제 환경에서 학습을 병행하는 방법을 제안한다. 실제 환경에서만 학습을 진행했을 경우 80시간 정도의 소요 시간이 필요하지만, 실제 환경과 가상 환경을 병행하며 학습을 진행했을 경우 50시간의 소요 시간이 필요하다. 가상 환경과 실제 환경에서 학습을 병행하면서 빠른 학습으로 다양한 실험을 거쳐 최적화된 파라미터를 얻을 수 있는 이점이 있다. 실내복도 이미지를 이용하여 가상 환경을 구성한 후 데스크톱으로 선행학습을 진행하였고 실제 환경에서의 학습은 Jetson Xavier를 기반으로 다양한 센서와 연결하여 학습을 진행하였다. 또한, 실내복도 환경의 반복되는 텍스처에 따른 정확도 문제를 해결하기 위해 복도 벽의 아랫선을 강조하는 특징점 검출을 학습하여 복도 벽 객체를 판단하고 정확도를 높일 수 있었다. 학습을 진행할수록 실험 차량은 실내복도 환경에서 복도 중앙을 기준으로 주행하며 평균 70회의 조향 명령을 통해 움직인다.

핵심주제어: 딥러닝, 가상 환경, 실제 환경, 병행 학습, 센서, 특징점 검출

Abstract We propose a method that combines learning in a virtual environment and a real environment for indoor autonomous driving through reinforcement learning. In case of learning only in the real environment, it takes about 80 hours, but in case of learning in both the real and virtual environments, it takes 40 hours. There is an advantage in that it is possible to obtain optimized parameters through various experiments through fast learning while learning in a virtual environment and a real environment in parallel. After configuring a virtual environment using indoor hallway images, prior learning was carried out on the desktop, and learning in the real environment was conducted by connecting various sensors based on Jetson Xavier. In addition, in order to solve the accuracy problem according to the repeated texture of the indoor corridor environment, it was possible to determine the corridor wall object and increase the accuracy by learning the feature point detection that emphasizes the lower line of the corridor wall. As the learning progresses, the experimental vehicle drives based on the center of the corridor in an indoor corridor environment and moves through an average of 70 steering commands.

Keywords: Deep Learning, Virtual Environment, Real Environment, Parallel Learning, Sensor, Feature Point Detection

* Corresponding Author: leecw@kunsan.ac.kr

+ 이 논문은 한국산업기술진흥원(KIAT)의 지원을 받아 수행된 연구임. (2021년 미래형자동차 R&D 전문인력 양성사업, 과제번호 : N0002428)

Manuscript received August 02, 2021 / revised August 20, 2021 / accepted August 25, 2021

1) 군산대학교 컴퓨터정보공학과, 제1저자
2) 군산대학교 컴퓨터정보공학과, 교신저자

1. 서론

인공지능의 발전은 교육, 안전, 교통과 같은 일상생활에서부터 자동차, 항공, 건설 등 산업적 측면에서의 적용이 가능해지고 있으며 인공지능에 의한 차량의 자율화로 인해 운전자의 별도 조작 없이 부착된 카메라와 센서를 통해 주변 환경을 인지하고 스스로 주행할 수 있는 미래 지능형 자동차에 관심이 높아졌다. 자율주행 차량 시스템의 동작 과정은 일반적으로 인지·판단·제어의 3단계로 분류된다. 카메라나 전방 센서를 이용하여 주변 환경을 인지하고, 영상인식 알고리즘을 이용하여 환경 정보를 해석하고 판단하여 조향 제어를 수행한다. 자율주행에서 기초 인공지능 모델만으로는 좋은 성능을 가지지 못한다. 실시간으로 변하는 주변 환경에서 존재하는 많은 객체 중 주행에 방해가 되지 않는 객체라고 판단하거나 장애물이라 인식해야 하는 범위가 넓으며 현재 상황에서 갈 수 있는 방향만이 아닌 미래 상황을 고려하여 효율적인 움직임을 판단하기 위해서는 더 발전된 인공지능 모델을 필요하기에 많은 유명 IT 회사들과 국내·외 자동차 기업들 등이 자율주행에 관한 연구를 진행하고 있다. 자율주행을 기반으로 특정 분야 기술을 연구하고 융합하는 사례 역시 많이 있다. 자율주행과 드론을 융합하여 탐지 및 재난 상황에 따른 안내 등을 할 수 있고 농업 기기에 적용하여 하우스나 밭, 논에서 움직이면서 작물을 추수하거나 관리할 수 있으며 산업 기기에 적용하여 택배 배송이나 공장 안에서 자동 물품 전달 등 목적에 맞게 다양한 기술을 융합하여 여러 방향으로 새로운 기술과 기기들이 등장하고 있다(Kim et al., 2017: Commercializations Promotion Agency for R&D Outcomes,, 2019).

따라서 환경에 따라 자율주행을 위한 새로운 학습 시스템이 필요하며 환경마다 직접 학습하는데 소용되는 시간이 많다. 본 논문에서는 좋은 성능의 컴퓨터로 빠르게 학습이 가능한 가상 환경과 임베디드 시스템을 통해 속도는 느리지만 가상 환경보다(Krizhevsky et al., 2012) 확실한 데이터를 얻을 수 있는 실제 환

경 학습을 병행하여 학습 소요 시간은 줄이고 데이터의 정확성을 확보할 수 있는 이점을 얻어 환경에 따라 목적에 맞게 빠르게 자율주행 시스템을 구축하여 적용하기 위한 방향성을 가지고 연구를 진행하였다.

본 논문의 구성은 2장에서 학습 모델에 관해 설명하고 3장에서 시스템 구성, 4장에서 실험을 서술한다. 5장에서는 결론과 향후 연구 방향을 제시한다.

2. 학습 모델

2.1 강화 학습

어떠한 환경에서 정의된 에이전트가 현재의 상태를 인식하고 선택하여 행동할 수 있는 경우의 수 중에서 보상을 최대화하는 행동이나 혹은 행동 순서를 현재와 미래 상황을 고려하여 판단하는 방법을 강화학습이라 한다. 주어진 어떠한 환경(Environment)에서 움직이는 정의된 행동자(Agent)가 있으며 행동자는 상태(State)라고 부르는 수많은 상황에서 적절한 행동(Action)을 취하고 그 행동에 따른 결과로 보상(Reward) 점수를 얻거나 감점, 혹은 유지해가며 학습을 진행해 나간다. 행동자의 학습 목표는 환경 안에서 발생하는 상태에서 행동을 취했을 때 얻을 수 있는 보상을 최대한 많이 받을 수 있도록 하는 것이다. 이를 위해 보상점수를 감점 받는 행동은 최대한 피하도록 하고 보상을 점수를 받을 수 있는 행동을 강화한다는 의미에서 강화학습이며 여기서 행동에 대한 보상점수의 기준이 되는 것이 정책(Policy)이라고 한다. 보상점수의 기준이 되는 정책에 따라 학습의 정확성이 달라지며, 환경의 현재 상태와 미래 상태의 변화나 연관성을 인지하지 못한다면 잘못된 학습으로 인한 성능이 저하가 있다(Mnih et al., 2013).

3. 시스템 구성

3.1 학습 모델 구성

강화학습을 기반으로 사용하며 입력 데이터로는 카메라에서 받아온 640×480 크기의 영상을 $256 \times 256 \times 3$ 채널 영상으로 변환하여 사용한다. $5 \times 5 \times 32$ 커널(kernel), 을 이용하여 합성곱(Convolution)을 진행하고 패딩(padding)이 같은 형태(same)로 진행되기 때문에 출력되는 결과물은 $256 \times 256 \times 32$ 로 나오게 된다. 2×2 size 최대 풀링(Max pooling)을 이용하여 $128 \times 128 \times 32$ 로 나온다. 다시 $2 \times 2 \times 64$ 커널로 합성곱을 진행, 같은 형태 패딩(padding same)을 진행하여 $128 \times 128 \times 64$ 를 얻은 후 2×2 size 최대 풀링을 진행하여 $64 \times 64 \times 64$ 의 출력 데이터를 얻는다. 그 후 평탄화 기능(Flatten)을 이용하여 직선 데이터로 만들어 준 후 밀집 기능(Dense)을 이용하여 1000×3 의 데이터 집합으로 만들고 함수(soft max)를 이용하여 3개의 방향 데이터로 분류였다(Keskar et al., 2017: Krizhevsky et al., 2012: Szegedy et al., 2015: Simonyan and Andrew., 2015). Fig 1은 본 연구에서 제안된 신경망 구조를 나타낸다.

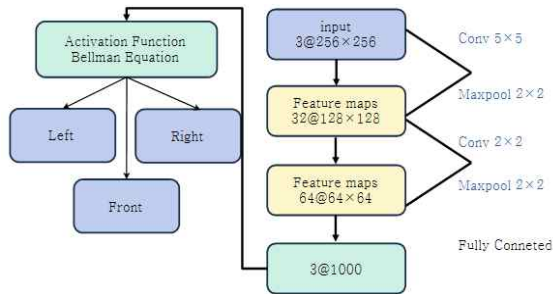


Fig. 1 Neural Network Structure

3.2 메인 시스템 구성

강화학습(Reinforcement Learning)을 실제 현실 환경을 기반으로 만든 가상환경과 실제 환경에서 학습을 병행하며 진행하는 방법을 제안한다. 제안된 시스템은 가상환경 학습의 경우 CPU i9-7900X, RAM 64GB, RTX 2080Ti를 사용하였고 실제 환경 학습의 경우 NVIDIA사의 Jetson Xavier, Fig. 2를 기반으로 모든 작

업이 진행된다. 가상환경 학습과 실제 환경 학습 모두 같은 신경망 구조 Fig. 1을 통하여 강화학습을 진행하기 때문에 데스크톱에서 나온 강화학습 결과물을 Jetson Xavier의 강화학습에 적용 가능하며 추가적인 학습이 가능하다. Fig. 2는 Jetson Xavier 사진이다.



Fig. 2 NVIDIA Jetson Xavier

가상환경은 실내복도 환경을 카메라 영상 각도에 따라 5분할하여 Fig. 3과 같이 구성하였다. Fig. 3은 실내복도 환경 이미지를 분할하여 촬영한 사진이다. 실내복도 환경의 너비와 실험 차량의 크기에 비례하여 크게 5:1의 비율을 가지기 때문에 5분할의 비율로 설정하였다.




Fig. 3 Virtual Environment

가상환경 학습의 경우 Fig. 3 (c)의 1열에서 학습이 시작되면 앞으로 움직일 시 Fig. 3 (c)의 2열로 이동한다. 이후 오른쪽으로 움직이면 Fig. 3 (d)의 3열로 이동한다. Fig. 3 (a)와 Fig. 3 (f)를 넘어가지 않고 움직이도록 학습을 구성하였으며 최대 70열까지의 가상환경 이미지를 구성하였다. 현실 환경 학습은 가상환경 학습

모델을 바탕으로 강화학습을 진행하며 학습 진행 시 충돌 판단의 기준으로 라이다 센서 (Velodyne Vlp-16)를 사용하였고 실험 차량 모터 제어를 위해 L298N(Motor Driver)를 사용하였다. 조향 신호는 시리얼 통신으로 연결된 라이다 센서의 데이터 값을 통해 충돌의 여부를 판단하게 되며 취득한 정보를 바탕으로 실험 차량을 조향하고 Fig. 4처럼 학습이 진행된다. Fig. 4는 학습 과정을 나타낸 블록 다이어그램이다.

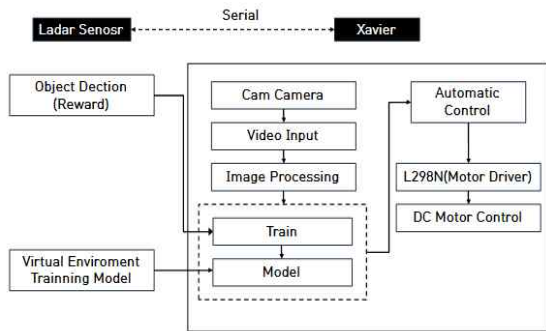


Fig. 4 System Train Block Diagram

강화학습을 이용한 실내 자율주행 테스트에서는 학습을 통해 얻은 모델(Model)을 기반으로 Lidar Sensor 없이 카메라를 통한 영상 이미지 입력 값으로 Fig. 5처럼 실험 차량을 조향한다. Fig. 5는 자율주행 과정을 나타낸 블록 다이어그램이다.

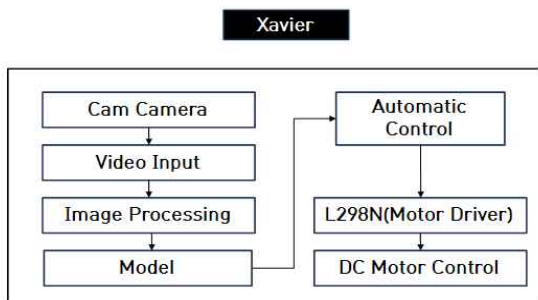



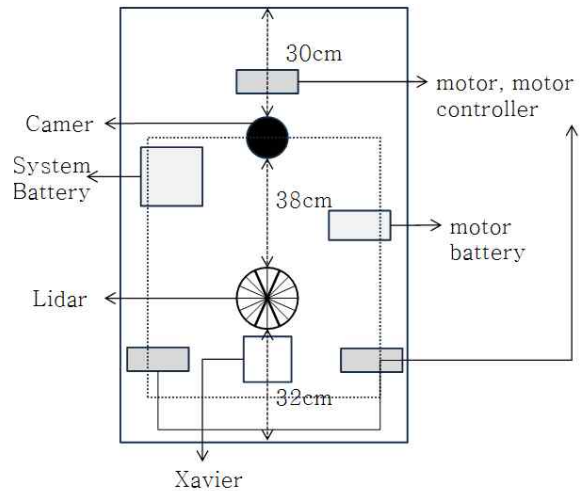
Fig. 5 System Test Block Diagram

3.3 실험 차량 구성

실험 차량은 길이 108cm, 폭 54cm의 높이 33cm 크기로 구성되어 있으며 각종 모듈 설치와 Xavier, 라이다 센서, 배터리 부착을 위해 핸들과 실험 자동차 의자 부분 및 햇빛 가림막 등 기본 골격을 제외한 나머지 부분을 제거하여 Fig. 6처럼 사용한다. Fig. 6 (a)는 모형자동차 측면도이다. Fig. 6 (b)는 모형자동차 평면도이다.



(a) Side View



(b) Floor plan

Fig. 6 Test Vehicle

Fig. 7은 모형차량에 사용된 추가 모듈들이다. 실내 환경 영상 입력을 위해 사용되는 카메라는 C992-PRO모델 Fig. 7 (a)을 사용하였다. 실험 차량의 모터는 RS380S-12vDC / 3500rpm 모델 Fig. 7 (c)을 사용한다. 모터 제어 및 전력 공급을 위한 센서는 LP298N Fig. 7 (d)를

이용하였다. 모터 전력 공급을 위한 배터리는 6V 4Ah × 2개 Fig. 7 (e)를 사용하였다. 메인 시스템인 Xavier와 라이다 센서 모듈의 전력 공급을 위한 배터리로 NEXT-675PB PRO 67500mAh 모델 Fig. 7 (f)를 사용했다. 강화학습을 진행하면서 올바른 보상 값을 넘겨주기 위해 주변 환경을 인식할 수 있는 장치를 사용해야 했으며 이를 위해 라이다 센서 Fig. 7 (b)를 사용하였다.




Fig. 7 Sensor and Module

라이다 센서는 전방, 좌우 측면에 대한 객체를 탐지한다. 라이다 센서는 16채널, 100m 측정 범위, 수직 30도 수평 360도로 5~20Hz 속도로 객체 탐지가 가능하며 오차 범위는 최대 ± 3cm로 Table 1과 같다. 실험 차량의 2/3지점 지면으로부터 42cm 떨어진 지점에 Fig. 8과 같이 설치하여 실험 차량에 부착된 기기들이나 다른 물건들이 감지되지 않도록 했다. Fig. 8은 라이다 센서를 부착한 모형차량 평면도이다.




Fig. 8 Lidar Sensor Setting

Table 1 Lidar Channel Configuration

Lidar ID	Vertical Angle	Lidar ID	Vertical Angle
0	-15°	8	-7°
1	1°	9	9°
2	-13°	10	-5°
3	3°	11	11°
4	-11°	12	-3°
5	5°	13	13°
6	-9°	14	-1°
7	7°	15	15°

이번 연구에서는 Lidar ID 1번을 사용하여 1°를 기준으로 수평 360°에 대한 데이터 값을 사용했다. 360°에는 총 897개의 레이저 포인트가 있으며 이를 기준으로 거리를 측정하여 주변 환경을 파악한다. 세부적으로 나누면 22.5°마다 56개의 레이저 포인트가 존재하며 392°~504°는 전방, 0°~56°, 840°~896°는 후방, 474°~538°는 좌측, 360°~422°는 우측으로 정하여 Fig. 9과 같이 사용하였으며 물체 측정 거리는 최적화된 감지 거리를 찾기 위해 실험에 따라 거리를 다르게 설정하였다. Fig. 9는 라이다 센서 측정 범위에 따른 레이저 포인트 구성이다.




Fig. 9 Lidar Sensor Angle Range

4. 실험

4.1 실험 환경

실험환경이 실내 복도인 이유는 정형화된 환경이며 외부 돌발 요인(동물이나 다른 동적인 객체들)이 적어서 빠른 결과 도출이 가능하기 때문이다. 실험 목표는 직선 구간의 실내복도 Fig. 10에서 실험 차량이 벽이나 문에 충돌하지 않고 복도 중앙을 기준으로 이동하는 것으로 설정하고 진행하였으며 실제 환경 학습만 진행했을 경우와 가상 환경과 실제 환경을 병행하여 학습한 방법에 대해 실험을 진행하였다. Fig. 10은 실내복도 환경의 크기와 형태이다.




Fig. 10 Example of Training Samples

4.2 실험 결과

강화학습 특성은 가장 점수를 많이 얻는 방향으로 움직인다. 이로 인해 사람이 생각하는 이상적인 움직임과 다른 결과를 도출하는 경우가 많다. 예를 들면 목표 지점으로 움직였을 때 큰 점수를 얻으며 일반적으로 움직였을 경우 낮은 점수를, 장애물에 부딪히거나 잘못된 장소로 갔을 때 감점을 받는다 하면 이상적인 움직임은 목표 지점을 찾아가며 계속 움직이는 것이다. 하지만 강화학습은 가장 점수를 많이 얻기 위해 감점의 위험이 없는 낮은 점수를 계속해서 얻는 행동을 반복한다. 제자리를 빙글빙글 돌거나 한번 큰 점수를 얻으면 감점을 받기 싫어서 그대로 자리에 멈추는 결과를 도출하게 된다. 그러므로 점수를 얻을 수 있는 파라미터 설정, 즉 정책이 가장 중요하며 많은 실험을 통해 이상적인 정책을 찾아야 한다(Ziyu et al., 2016; Lillicrap et al., 2019).

일반적으로 실제 환경 학습만 진행한 경우는 학습 횟수 파라미터는 10000으로 설정하였을 때 학습 시간은 약 80시간 정도 소요된다. 강화학습을 진행하면서 벽에 부딪히거나 장애물이 있을 때 학습 횟수 한번이 종료되면서 초기 시작 지점으로 돌아가 다시 학습하는 것이 아닌 종료지점부터 학습이 이어서 진행되게 하였다.

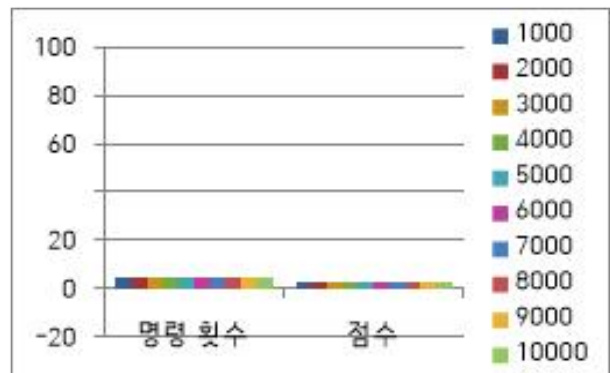


Fig. 11 Real Environment Test Results

실제 환경에서 2번의 실험을 진행했으며 그 중 가장 점수가 높았던 파라미터 설정은 Γ 는 0.99, batch size는 64, Q-target 최신화 주기는 5로 설정하였다. Lidar 감지 설정 거리는 1.2m로

정의하고 강화학습을 진행하였고 앞, 좌, 우로 움직일 때마다 1점을 부여했으며 잘못된 조향 시 -1점을 부여하였다. 10000번까지 학습을 진행하면서 평균 명령 횟수는 5회가 되지 못하며 조향 시 얻는 점수 또한 평균 3점을 넘지 못하였고 실내 복도환경을 주파하지 못했다(Fig. 11). Fig. 11은 실제 환경 학습을 통한 자율주행 결과 그래프이다. 평균 명령 횟수가 5회라면 실내복도 환경에서 5번의 움직임을 보여준 후 장애물에 부딪혀 정지하는 것인데 명령 횟수가 늘어날수록 움직임은 많아지며 학습 시간이 늘어나게 된다. 이는 실제 환경에서 이상적인 파라미터에 접근할수록 학습 시간이 늘어남을 뜻한다.

가상 환경에서 선행학습 후 실제 환경에서 이어서 하는 학습의 경우에는 학습 횟수 파라미터 10000으로 설정 하였을 때 학습 시간은 약 50시간 정도이며 가상 환경에서 3000번의 학습 횟수를 진행하며 10시간 정도 소요되고 현실 환경 학습 7000번을 진행하며 40시간이 소요된다.

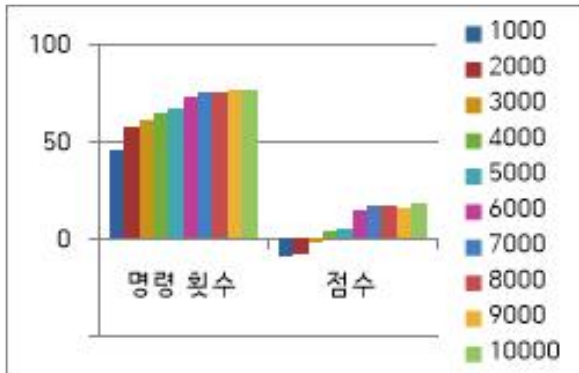


Fig. 12 Parallel Test Results of Virtual and Real Environments

파라미터 설정은 실제 환경 Fig. 11에서 얻은 정보를 토대로 진행하였으며 3번의 실험을 진행하였다. 그중 가장 점수가 높았던 파라미터 설정은 Γ 는 0.6, batch size는 64, Q-target 최신화 주기는 5로 설정하였다. 가상 환경에서의 점수는 Fig. 3 (c) 열 방향으로 움직일 시 가까울수록 0.5점, 0.3점, Fig. 3 (c)에서 앞으로 움직일시 1점, Fig. 3 (a), (f) 열 방향으로 움직일

때 -0.7점이며 이를 벗어나 움직이면 -10점을 얻으며 학습이 종료된다. 실제 환경에서 점수는 Lidar 감지 설정 거리에 따라 좌측 2.2m 안에 물체가 있을 때 우회전으로 올바르게 조향하면 0.1점을 얻고 반대로 우측 2.2m 안에 물체가 있을 때 좌회전으로 올바르게 조향하면 0.1점, 정면으로 갈 수 있을 때 전방으로 올바르게 조향하면 1점을 얻으며 그 외에 실내 실험환경의 중앙으로 근접하게 움직일수록 0.2점, 바깥쪽으로 접근할 경우 -0.5, -0.9점을 얻게 설정하였으며 벽에 충돌 시 -10점을 얻게 설정하였다. 가상 환경과 실제 환경의 학습에 따른 점수가 다른 이유는 가상 환경은 움직일 수 있는 환경의 크기 및 최대 움직임의 횟수가 실제 환경보다 현저히 적기 때문에 점수의 비중 또한 다르게 주어야 한다. 평균 명령 횟수는 77이고 평균 점수는 17점이며 실내 복도 주파가 가능하다 (Fig 12). Fig. 12는 실제 환경과 가상 환경의 병행 학습을 통한 자율주행 결과 그래프이다. 파라미터 변경으로 인해 기존의 Fig. 11에 비해 더 좋은 성능을 얻으며 또한 많은 움직임에도 불구하고 시간이 적게 걸린다. 그러므로 가상 환경과 실제 환경의 병행 학습은 실제 환경에서 단일로 학습하는 것에 비해 시간 소모가 적기 때문에 다양한 파라미터 변경과 이미지 전처리와 같은 방법을 적용하여 실험을 진행해 볼 수 있다. 따라서 많은 실험과 그에 비해 적은 시간 소모로 얻은 파라미터와 방법을 통해 좋은 실험 결과를 얻을 수 있다.

5. 결론

본 논문은 실내 복도환경에서 영상 이미지를 사용하여 가상 환경을 만들어 선행학습을 한 뒤 실제 환경에서 이어서 학습을 진행하는 강화학습 시스템을 제안하였다. 가상 환경과 실제 환경을 병행하여 학습을 진행함으로써 빠른 학습을 통해 다양한 실험이 가능하고 그에 따라 최적에 근접한 파라미터를 얻는 이점을 가지게 되었다. 따라서 실제 환경 학습에 비해 적은 학습 시간을 가지게 되어 빠른 최적화 파라미터를 얻을

수 있다. 제안된 시스템은 가상 환경 학습의 경우 CPU i9-7900X, RAM 64GB, RTX 2080Ti를 사용하였고 실제 환경 학습의 경우 Jetson Xavier를 통해 라이다 센서, 카메라 등의 센서를 활용하여 학습을 진행하였다. 학습을 진행할수록 실험 차량은 실내복도 환경에서 복도 중앙을 기준으로 주행할 수 있었다. 향후 연구에서는 주변 환경에 부딪히지 않고 움직이면서 특정 객체를 찾아 목표로 하고 효율적으로 움직이는 자율주행 시스템을 연구하고자 한다. 또한, 주행 중 발생할 수 있는 갑작스러운 상황에 반응하고 인식하여 장애물을 회피할 수 있는 시스템으로 확장을 계획하고 있다. 추가 연구를 통해 점진적으로 차량을 이용한 실내 자율주행의 신뢰성을 높일 수 있다면 농촌의 하우스 시설에서 작물 추수를 위한 목적, 공장 내부 혹은 건물 내부 시설에서의 위험 요인 검출 등 실내 환경의 다양한 현장에서 유용하게 쓰일 수 있을 것으로 기대된다.

References

Kim, J. Y., and Lee, S. J., et al. (2017). *A Study on the National Policy Agenda based on Science & Tehnology-ICT for leading the 4th Industrial Revolution*, Ministry of Science, ICT and Future Planning Commercializations Promotion Agency for R&D Outcomes. (2019). *Artificial intelligence (big data) market and technology trends*, S&T Market Report, Vol. 71

Mnih, V., et al. (2013). Playing Atari with Deep Reinforcement Learning, *NIPS Deep Learning Workshop 2013*.

Keskar, N. S., et all. (2017). on Large-Batch Training for Deep Learning: Generalization Gap and Sharp Minima, *ICLR 2017*.

Krizhevsky, A., et all. (2012). Imagenet Classification with Deep Convolutional Neural Networks, *NIPS 2012*.

Yang, J., Coughlin, J. F. (2014). In-vehicle technology for self-driving cars: Advantages

and challenges for aging drivers, *International Journal of Automotive Technology*, vol.15, no.2, pp333-340.

Ziyu Wang, Tom Schaul, Matteo Hessel, Hado van Hasselt, Marc Lanctot, Nando de Freitas. (2016). Dueling Network Architectures for Deep Reinforcement Learning, *Proceedings of the 33rd International 35 Conference on International Conference on Machine Learning (PMLR)*, Vol.48, pp1995-2003.

Lillicrap, Timothy P., et al. (2019). *Continuous control with deep reinforcement learning*, arXiv preprint arXiv:1509.02971v6.

Szegedy, Christian, et al. (2015). Going deeper with convolutions, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

Simonyan, Karen, and Andrew Zisserman. (2015). *Very deep convolutional networks for large-scale image recognition*, arXivpreprint arXiv:1409.1556v6.



정 유 석 (Yuseok Jeong)

- 학생회원
- (현재) 군산대학교 컴퓨터정보통신공학부 석사과정생
- 관심분야: 딥러닝, 영상처리, 컴퓨터비전
- 관심분야 : 표현체, 유전자기능, 지방산생합성



이 창 우 (Chang Woo Lee)

- 정회원
- 경일대학교 컴퓨터공학과 공학사
- 경북대학교 컴퓨터공학과 공학석사
- 경북대학교 컴퓨터공학과 공학박사
- (현재) 군산대학교 공과대학 컴퓨터정보통신공학부 정교수
- 관심분야 : 컴퓨터비전, 머신러닝, 패턴인식