

Local Path Generation Method for Unmanned Autonomous Vehicles Using Reinforcement Learning

Kim Moon Jong[†] · Choi Ki Chang^{**} · Oh Byong Hwa^{***} · Yang Ji Hoon^{****}

ABSTRACT

Path generation methods are required for safe and efficient driving in unmanned autonomous vehicles. There are two kinds of paths: global and local. A global path consists of all the way points including the source and the destination. A local path is the trajectory that a vehicle needs to follow from a way point to the next in the global path. In this paper, we propose a novel method for local path generation through machine learning, with an effective curve function used for initializing the trajectory. First, reinforcement learning is applied to a set of candidate paths to produce the best trajectory with maximal reward. Then the optimal steering angle with respect to the trajectory is determined by training an artificial neural network. Our method outperformed existing approaches and successfully found quality paths in various experimental settings, including the cases with obstacles.

Keywords : Unmanned Autonomous Vehicle, Reinforcement Learning, Artificial Neural Networks, Local Path, Trajectory Generation

강화학습을 이용한 무인 자율주행 차량의 지역경로 생성 기법

김 문 종[†] · 최 기 창^{**} · 오 병 화^{***} · 양 지 훈^{****}

요 약

무인 자율주행 차량에서의 경로 생성 기법은 차량이 자동적으로 안전하고 효율적인 경로를 생성하고 주행할 수 있도록 해 준다. 경로에는 크게 전역경로와 지역경로가 있다. 전역경로는 차량이 출발점으로부터 도착점까지 가기 위해 주행해야 하는 구간을, 지역경로는 전역경로에서 얻은 구간을 주행하기 위해서 차량이 실제로 주행해야 할 경로를 의미한다. 본 논문에서는 지역경로 생성을 위하여 효율성 높은 곡선 함수를 사용하는 기존연구에서 더 나아가 학습을 통해 경로를 생성하는 방법을 제안한다. 먼저 강화학습을 통해서 후보경로에 대한 예측 보상 값을 얻고 보상 값이 최고가 되는 경로를 찾는 작업을 한다. 또한 인공 신경망을 통해서 생성된 경로에 최적화된 조향 명령을 주기 위해 조향 각을 학습하는 작업을 한다. 더 나아가 주행하는 경로에 장애물이 발견되더라도 이를 효율적으로 회피하는 최적의 경로를 학습 기법을 통해 만들어낸다. 본 논문에서 제안된 알고리즘의 우수성은 실제 주행 환경으로 모델링한 시뮬레이션 실험을 통해 검증되었다.

키워드 : 무인차, 강화학습, 인공신경망, 지역경로, 경로생성

1. 서 론

최근에 무인 자율주행 차량(이하 무인차)에 대한 사람들의 관심이 늘어나고 있다. 특히 2004년부터 방위 고등 연구 계획국(DARPA)에서 주최한 무인 자율주행 대회 이후로 무인차에 대한 관심이 더욱 증폭되어 있는 상태이다. 보다 안전

하고, 효율적으로 무인차를 제어하는 시스템에 대한 연구는 사회적으로나 경제적으로도 가치 있는 연구가 될 것이다.

무인차의 주행을 제어하는 방법은 무인차가 이동할 경로를 미리 생성하고 이를 벗어나지 않게 하는 것이다. 과거에는 카메라 센서를 통해 경로를 생성하는 방법이 주로 연구되었지만 현재에는 차량의 위치를 정확하게 측정할 수 있는 DGPS(Differential Global Positioning System), 칼만 필터 알고리즘 등이 개발되어 이를 통해 경로를 생성하는 기술들이 개발되고 있다.

본 논문에서는 DGPS를 이용해 전역경로에 대한 지점들을 생성하고 지역경로 상황에서 무인차가 효율적인 경로를 찾아 낼 수 있는 방법을 제시한다. 지역경로를 생성할 때 발생하는 문제는 기본적으로 두 가지가 있다. 첫 번째는, 도

* 이 논문은 2013년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2013R1A1A2012502).

† 정 회 원 : 와이즈넷 Mining tech팀 연구원

** 준 회 원 : 서강대학교 컴퓨터공학과 석사과정

*** 준 회 원 : 서강대학교 컴퓨터공학과 박사과정

**** 종신회원 : 서강대학교 컴퓨터공학과 교수

Manuscript Received: May 28, 2014

First Revision: July 22, 2014

Accepted: July 25, 2014

* Corresponding Author: Yang Ji Hoon(yangjh@sogang.ac.kr)

로의 지형이 불규칙하게 변하고 차량의 회전 반경이 큰 구간이 있는 것이다. 두 번째는, 차량에 장착한 센서들이 오차를 가지는 것이다. 따라서 이러한 문제들을 해결하기 위해 강화학습과 인공 신경망을 활용하여 안전하고 최적화된 경로를 생성하는 기법을 제시한다. 더욱이 장애물이 발견되었을 때 어떻게 안전하게 회피하는 경로를 생성할 수 있는지에 대해서도 보인다.

2. 관련 연구

2.1 비-스플라인 곡선(B-Spline Curve)

비-스플라인 곡선은 차수와 부드러움 그리고 영역 분할의 측면에서 특별하게 구분될 수 있는 모든 조절 곡선의 결합으로 이루어져 있다[1-2]. 차수 n 에서의 비-스플라인 함수 $B_{i,n}$ 의 곡선의 조합은 다음 수식(1)과 같이 구성될 수 있다.

$$S(t) = \sum_{i=0}^{m-n-2} P_i b_{i,n}(t), t \in [t_n, t_{m-n-1}] \quad (1)$$

수식(1)에서 $P_i \in R$ 은 제어하는 점 또는 드 보어(De Boor) 점이라고 부른다. 비-스플라인 곡선을 만들기 위해서는 $m-n-1$ 의 제어 점이 있어야 곡선의 블록 껍질(Convex Hull)을 이루는 바운딩 볼륨(Bounding Volume)이 형성된다[3].

2.2 무인차 주행 연구

DARPA에서 주최한 무인 자율 주행 대회 이후로 보다 안전하고 보다 빠르게 무인차를 주행시키는 방법에 대한 다수의 연구가 진행되었다. 그중에서도 2007년 대회에서 우수한 결과를 보인 타르탄 레이싱팀은 경로를 생성함에 있어서 일반 곡률반경에 의한 제어를 비-스플라인 곡선함수를 통해 점차 최적화를 하는 방법을 적용하였다[4]. 이를 통해 기존의 방법보다 기울기의 변화가 크지 않은 매끄러운 형태의 경로 곡선을 생성할 수 있다. 최근에는 대회에 참가하기 위한 알고리즘에서 더 나아가 실제 도로에서 적용할 수 있는 알고리즘 중심으로 연구가 이루어지고 있다. 실제 도로에서 발생할 수 있는 다양한 장애물을 인지하고 경로를 재생성할 수 있는 방법[5]이나 생성된 경로에 맞추어 안정적으로 핸들을 조정하는 방법[6]들이 연구되고 있는 추세이다.

2.3 무인차 환경에서의 강화학습

무인차를 현재 주행하는 양쪽 차선들의 중앙에 맞추어 주행시키는 것이 효율적이고 안정적인 방법이다. 직선 도로에서는 무인차를 쉽게 주행시킬 수 있지만 급커브 구간이나 돌발 상황이 나타난 경우에는 차량을 안정적으로 주행시키는 것이 힘들게 된다. 이러한 점을 보완하기 위해 차선의 중앙과 일치하게 가도록 하는 강화학습이 연구되었다[7].

차량 이동을 통해 상태를 정의하고 차선의 정보와 비교하여 보상 값을 얻는다. 보상 값을 최대로 가지게 되는 정책을 학습해 나아간다.

자동차 내부에 설치된 카메라 이미지를 입력으로 받아 강화학습을 수행하는 방법도 제안되었다[8]. 이미지 정보를 바탕으로 중앙에서 떨어진 거리를 계산하고 이 정보를 이용하여 차선의 중앙으로 가기 위한 조향 각을 결정한다. 이후에 짧은 구간에서의 보상 값을 예측하여 실제로 주행한 이후에 얻게 된 실제 보상 값으로 학습을 진행한다.

3. 제안 알고리즘

무인차 환경에서 주행하기 위한 경로의 집단은 그래프로 구성되어 있고 각 지점은 노드로 구현되며 인접한 두 노드는 방향이 있는 간선으로 연결된다. 우선, 차량이 시작점에서 도착점으로 가기 위해서 전역 경로가 생성되어야 하는데 일반적으로 두 지점 간의 최단 경로를 찾는 대표적인 알고리즘인 다익스트라 알고리즘[9]을 통해 전역 경로를 생성한다. 전역 경로가 생성되고 나서 현재 위치에서 도달해야 하는 첫 번째 목표 노드로 향하는 경로를 생성하는 방법은 경로생성, 경로 예측, 경로 최적화, 행동 제어, 학습의 5가지 모듈로 나뉜다. Fig. 1은 무인차 환경에서 차량이 주행하기 위한 전체적인 구조를 나타낸 것으로 점선으로 표시된 화살표는 전체적인 구조가 어떻게 진행되는지를 나타내고 실선으로 표시된 부분은 주행된 결과로 학습하는 과정을 나타낸다.

3.1 경로생성(Trajectory Generation)

경로 생성은 차량의 현재 상태에서부터 다음 목표 지점까지 가기 위해 실제로 차량이 주행해야 할 경로를 설정하고 얻어내는 부분이다. 이 부분에서는 처음 차량의 상태와 전역 경로에서 생성한 구간들을 지나기 위해서 정의된 구간의 상태 정보, 그리고 k_1 지점을 찾아내는 작업을 한다. k_1 지점은 장애물을 회피하거나 커브구간 등을 매끄럽게 주행하는 경로를 생성하기 위해 선정되는 지점이다. 무인차량의 기본적인 상태를 다음과 같이 정의할 수 있다.

$$X = [xy\psi kv]^T \quad (2)$$

수식(2)는 차량의 상태를 구성하는 요소들을 나타낸 것이다. x, y 는 각각 GPS를 기반으로 한 위도와 경도 값을 나타내며 ψ 는 북쪽을 기준으로 시계방향으로 계산한 차량의 머리 방향(단위 : 도)이다. k 와 v 는 차량의 바퀴의 각도와 속도를 나타낸다. 경로를 위한 초기의 상태는 x_i 로, 도착지점의 상태는 x_f 로 각각 표현한다.

k_1 지점을 찾기 위한 과정은 다음 6가지 단계로 나타낼 수 있다. 시작, 도착 상태 및 장애물 정보는 주어진다 가정한다.

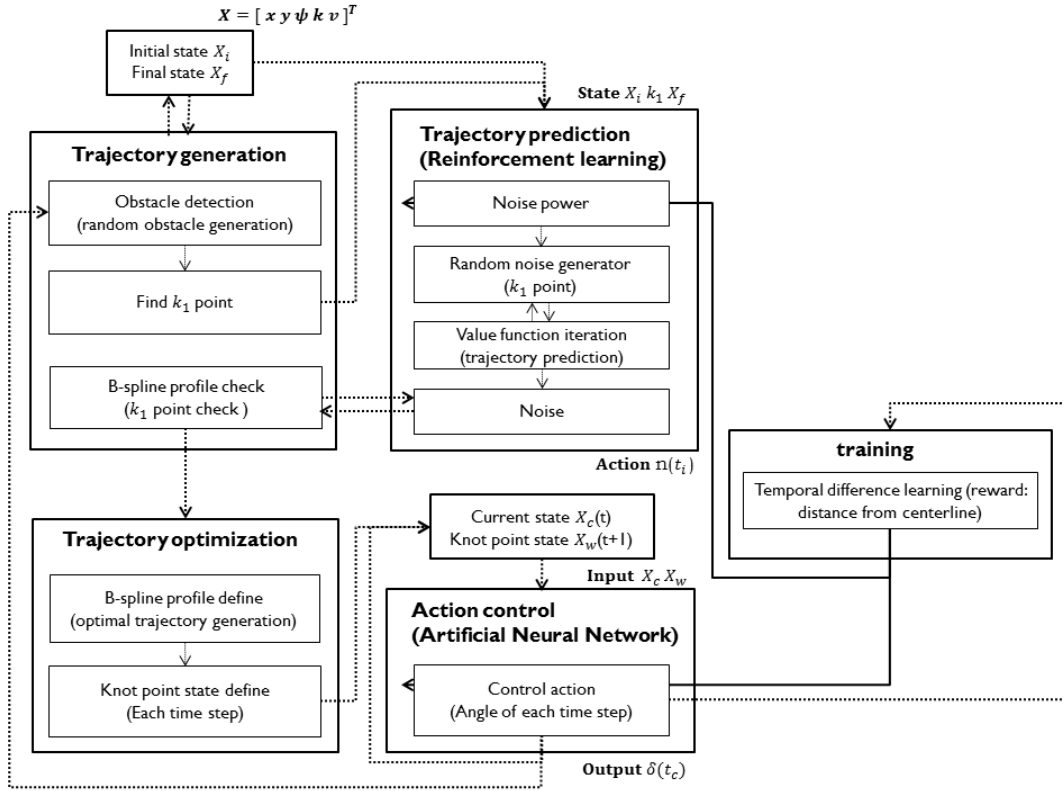


Fig. 1. Proposed Architecture

- 1) 해버사인 공식(Haversine Formula)으로 시작점과 도착점의 중앙점을 찾는다[10].
- 2) 차량이 주행하는 경로가 어느 방향인지 찾는다.
- 3) 시작점에서 도착점까지의 거리(d_m)를 구한다.
- 4) 시작점에서 도착점까지의 각도(θ_m)를 구한다.
- 5) 곡률 반경의 비율 ϵ 을 구한다.
- 6) k_1 지점의 좌표 값을 구한다.
- 6)의 k_1 지점을 찾기 위해서는 거리 d_m , 각도 θ_m 그리고 곡률 반경의 비율 ϵ 값이 필요하다. k_1 지점을 찾기 위해서 도착점으로 가기 위한 각도가 클수록, 두 지점 사이의 거리가 멀수록 k_1 지점의 거리는 중앙으로부터 멀어진다. 곡률반경의 비율 ϵ 는 실제 도로에서 커브가 시작되는 구간에서부터 끝나는 구간까지의 직선거리와 직선거리의 중점의 직교한 커브구간의 거리의 비율로 계산하여 얻는다.

3.2 경로 예측(Trajectory Prediction)

기본적으로 차량에서 얻어낸 센서들은 오차율을 가지고 있고 차량의 지연 시간, 외부 환경의 영향, 차량의 무게 등에 의해서 조건이 변하기 때문에 매번 같은 계산으로 항상 최적화된 경로를 얻어 내기는 힘들다. 이를 위해서는 먼저 k_1 지점으로부터 얻은 중앙으로부터의 거리 d_{k1} 을 구하고 그것의 보상 값(Reward)을 다음과 같이 계산한다.

$$r_{k1} = 1 - (d_{k1} \times 1/w) \tag{3}$$

수식(3)에서 r_{k1} 은 생성된 k_1 지점에 대한 보상 값을 나타내고 w 는 도로의 폭(4m)을 나타낸다. 보상 값은 중앙을 최대 1을 기준으로 한다. 강화 학습단계에서는 잡음의 세기(Noise Power)를 결정하여 생성된 k_1 지점을 기준으로 얼마만큼 떨어진 곳에 변경된 k_1 지점을 생성 할 것인지를 결정한다.

Table 1은 초기 d_{k1} 의 거리를, Table 2는 잡음의 세기를 초기화 한 것이다. Table 1에서 거리는 0.1m 단위로 하였고 최대거리는 중앙으로부터의 최대거리인 4.0m로 하였다.

$$n = (1 - r_{k1}) \times \tau \tag{4}$$

Table 1. Distance of d_{k1}

Input	Range	Section
$d_{k1}(m)$	[0.1, 4.0]	40

Table 2. Noise Power

Unit	Power	Number
τ	0.1	40

수식(4)에서 잡음 값은 n 으로 나타내고 단위는 거리(m)로 나타낸다.

이렇게 잡음 값을 얻고 나면 가치 함수 반복(Value Function Iteration)을 통해 k_1 지점을 전 방향으로 이동하여 보고 k_1 지점을 기준으로 경로를 생성하여 먼 거리의 보상 값(Long Reward)을 다음과 같이 얻어낸다.

$$r_l = \sum_{t=0}^n r_t \tag{5}$$

이렇게 얻어진 보상 값들이 최고가 되는 지점을 찾아내는 작업을 다음과 같이 한다.

$$r_l = \max(r_o, r_n) \tag{6}$$

r_o 와 r_n 이전과 새로운 경로의 보상 값을 나타낸다.

3.3 경로 최적화(Trajectory Optimization)

앞장에서 얻어온 경로를 통해 매 시간 주행 상태를 결정하기 위해 분해 값(Resolution)을 결정한다. 왜냐하면 현재 시간 t_c 지점에서의 차량이 제어해야 하는 속도 $v(t_c)$, 조향 각 $\delta(t_c)$ 을 얻기 위함이다.

$$\zeta = d_{node} / v \tag{7}$$

수식(7)에서 ζ 는 주행 경로를 얼마나 분해할 것인지에 대한 분해 값의 수를 나타내고 d_{node} 는 한 노드를 주행하기 위한 주행 거리를 나타낸다. 경로 최적화 단계에서는 최적의 경로를 생성하고 이를 ζ 로 나누어서 매 시간 단계에서의 주행에 관한 상태 정보를 계산하여 저장한다.

3.4 행동 제어(Action Control)

경로를 생성하여 얻는 상태 $X_c(t)$ 와 $X_w(t+1)$ 를 통해 현재 상태에서 다음 상태까지의 조향 각의 차이 값을 계산할 수 있다.

$$\delta_c = \psi_w - \psi_c \tag{8}$$

3.5 학습

본 논문에서는 시간차 학습을 사용하여 실제로 차가 주행했을 때 보상 값을 t 시간마다 얻어내어 잡음의 세기(τ)를 학습 시켜 나아간다.

$$\tau = \left(\sum_{t=0}^n d_t \right) / \zeta \tag{9}$$

수식(9)은 초기의 잡음의 세기에서 실제 주행을 하고 나서 얻어진 거리를 가지고 총 t_n 시간만큼 주행하게 되면 그

값만큼 나누어서 얻어진 거리로 잡음의 세기를 학습시킨다. 또한 우리는 인공 신경망에서는 주행을 한 후 경로와의 차이를 통해 조향 각을 수정하여 나아간다.

$$\delta_{train} = \delta_{t_c} + (\delta_{w_c} - \delta_{real}) \tag{10}$$

수식(10)에서 δ_{train} 은 학습시키고자 하는 차량의 조향 각이고 δ_{real} 는 실제 차량이 주행하고 난 후의 차량의 각도이다.

4. 실험

4.1 실험 데이터 및 환경

제안된 알고리즘을 통해 경로를 생성하는 무인차가 실제 도로에서 제대로 주행하는지 확인하기 위해서 실제 도로의 GPS좌표를 사용한 시뮬레이션 경로를 생성하였다. 서강대학교 교내 도로 342m를 시뮬레이션 대상 경로로 설정하였다. Table 3의 각 지점들은 대상 경로의 20개의 지점들이며 위도와 경도 정보를 GPS로 측정하였다.

얻어진 좌표 정보들을 통해서 각 지점 간의 거리와 각도 정보를 계산할 수 있다. 출발 지점인 1번부터 20번까지 단 방향으로 연결된 가중 그래프를 생성하였고, 이는 시뮬레이션상에서 결정된 전역경로가 된다. 또한 자동차 부품 연구원(KATECH) 주행 도로 1,591m를 위와 같은 방식으로 단 방향 가중그래프로 생성하여 가상 도로로 구현하였다.

Table 3. Coordinate of Real Road (Sogang University)

Point	Latitude(°)	Longitude(°)
1	37.55067	126.9401
2	37.55065	126.9403
3	37.55063	126.9404
4	37.55058	126.9405
5	37.55049	126.9406
6	37.55043	126.9407
7	37.55036	126.9407
8	37.55024	126.9408
9	37.55018	126.9409
10	37.55015	126.9411
11	37.55018	126.9413
12	37.55021	126.9414
13	37.55031	126.9419
14	37.55035	126.9420
15	37.55050	126.9425
16	37.55055	126.9427
17	37.55073	126.9431
18	37.55077	126.9433
19	37.55086	126.9434
20	37.55093	126.9435

4.2 실험 및 결과

시뮬레이션 환경에서 차량의 속도는 5m/sec이며 100ms 마다 실제 주행과 학습이 이루어진다. 시뮬레이션에서 사용한 주행 수식은 [11]을 참조하였다. 출발 지점부터 도착지점까지 주행하면서 도로 중앙으로부터 떨어진 거리의 보상 값을 측정하였다. 우선 서강대학교 교내 도로에서 무인차 주행실험을 진행하였다. 학습이 이루어질 때마다 보상 값을 계산하여 전체 보상 값의 평균이 전체 주행 결과 나타난 보상 값이 된다. 같은 실험을 20번 반복하여 얻어진 보상 값들의 평균이 Table 4에 나타나 있다.

Table 4은 단순하게 곡률반경 계산을 통해 주행을 이어 나갈 때와 비-스플라인 곡선을 따라 주행할 때, 그리고 제안된 알고리즘의 보상 값을 나타낸 표이다. 제안 알고리즘은 비-스플라인 곡선만을 사용했을 때보다 평균적으로 0.03 정도 보상 값이 향상되는 것을 확인할 수 있다. 이 값을 거리의 함으로 환산하면 7.9m 정도가 나오는 것을 알 수 있다. 단순히 곡률반경만을 사용한 경우에는 학습과 스플라인 곡선을 사용하지 않아 보상 값이 현저히 떨어지는 것을 알 수 있다. 이전의 연구와의 비교를 수행하자면, 차량의 카메라 센서가 아니라 DGPS를 활용하여 실험이 진행되었기 때문에 [8]과의 정량적 비교를 할 수는 없었다. 하지만 조항 각에 대한 학습뿐만 아니라 동시에 최적의 경로를 학습해 나아가는 점에서 본 논문의 독창성을 찾을 수 있다.

다음은 KATECH에서의 실험 결과이다. 이 실험에서는 Fig. 2의 좌측 상단과 같이 급커브 구간을 만들어 실험을 수행하였다.

Table 4. Result of Average Reward (Sogang University)

Algorithm	Average Reward	Improve (Reward)	Improve (Distance: m)
Approximating Curve	0.63	0.19	49.57
B-Spline	0.79	0.03	7.97
Proposed	0.82	-	-



Fig. 2. Result of driving simulation (KATECH)

먼저 도로에 임의의 지역에 장애물을 넣고 경로 생성을 하였다. 장애물은 핀이 꽂혀 있는 곳이다. 흰색 선은 제안 알고리즘의 경로, 스플라인을 이용한 경로와 곡률반경만 사용한 경로는 각각 빨간색과 파란색으로 표시하였다. 급커브가 일어나기 전까지는 모두 다 경로를 잘 따라오는 듯이 보였다가 급커브가 일어나는 과정에서 학습을 사용하지 않는 두 알고리즘들은 커브를 돌지 못하고 경로가 끝나버리는 것을 볼 수 있다. 다음의 Table 5는 경로가 끝나기 전까지의 각각의 보상 값을 분석한 것이다.

Table 5. Result of Average Reward (KATECH)

Algorithm	Average Reward	Improve (Reward)	Improve (Distance: m)
Approximating Curve	0.80	0.12	155.58
B-Spline	0.85	0.07	94.56
Proposed	0.92	-	-

Table 5의 학습을 사용하지 않은 보상 값을 보면 급커브 구간에서 경로와 멀어지는 상황이 발생하면서 보상 값이 급격히 떨어지는 상황이 일어나고 경로가 끊기면서 얻어진 값을 나타낸 것이다. 학습을 사용하지 않았을 때 보상 값이 떨어지는 동시에 안전한 주행을 할 수 없다는 결론을 얻을 수 있다.

5. 결론 및 향후 과제

지금까지 무인차 환경에서 장애물을 감지하거나 곡선 구간이 생겼을 때 강화학습, 인공지능망을 활용하여 효율적으로 주행할 수 있는 방법을 제시하였다. 학습 기법을 사용한 알고리즘은 학습을 사용하지 않은 알고리즘보다 더 좋은 보상 값을 얻는 동시에 학습을 통하여 좀 더 최적화된 경로를 생성하고 안전하게 차량을 제어할 수 있다는 것을 확인하였다. 이는 경로를 생성함에 있어 실 도로를 주행할 때에도 안전한 경로를 생성할 수 있다는 것을 의미한다. 또한 경로 생성에 관한 알고리즘을 한번 학습시켜 놓으면 다음에 같은 상황에 대해 주행할 때 경로를 새롭게 찾거나 최적화 시키는 작업을 반복하지 않아도 되는 장점이 있다. 이는 무인차 환경에서 실시간성을 보장하는 동시에 안정성과 효율성을 보장하는 작업이다. 본 논문에서는 시뮬레이션을 통해 알고리즘을 검증했기 때문에 실제 무인차 환경에 적용하기 위해서는 다음 세 가지 문제가 해결되어야 한다.

첫째로, 장애물이 다양하다는 것이다. 본 논문에서는 장애물을 일정한 넓이를 가지는 정적 장애물로 구성하였지만 실 도로에서 발생할 수 있는 장애물은 훨씬 더 다양할 뿐만 아니라 사람이나 동물 움직이는 차량 등 동적 장애물이 많이 존재한다. 따라서 이러한 동적 장애물의 이동 경로를 예측하여 경로를 생성하는 기법은 앞으로도 계속 연구가 되어야 할 것이다.

둘째로, 실 도로의 복잡성이다. 본 논문에서는 높낮이나 횡단보도, 표지판, 과속 방지턱 등을 고려하지 않은 주행을 하였다. 하지만 실 도로에서는 이러한 것들을 고려하지 않고 주행한다면 큰 문제가 생길 수 있다. 효율적인 경로를 생성하는 것 이외에 차량에 주변 상황을 고려한 최적의 제어를 해줘야 하는 작업이 필요하다.

셋째로, 센서의 부정확함과 센서의 비용이다. 센서는 기본적으로 오차를 가지고 있기 때문에 이를 정확하게 측정하여 차량을 제어하거나 오차를 가지고도 최적의 경로를 생성할 수 있는 알고리즘이 개발되어야 한다. 또한 센서의 문제에서 높은 정확도를 가지기 위해서는 많은 비용이 소모되기 마련인데, 높은 비용을 가지고 차량을 개발하면 실용성이 떨어지게 된다. 이러한 문제들은 향후 개선되어야 할 과제로 남겨둔다.

References

- [1] C. de Boor, *Practical Guide to Splines*, New York: Springer-Verlag, pp.113-115, 1978.
- [2] W. Chen, *Feedback, Nonlinear, and Distributed Circuits*, CRC Press, pp.9-20, 2009.
- [3] H. Michiel, "Spline interpolation," *Encyclopedia of Mathematics*, Springer, 2001.
- [4] C. Urmson, et al., "Autonomous driving in urban environments: Boss and the urban challenge," *Journal of Field Robotics*, Vol.25, No.8, pp.425-466, 2008.
- [5] J. Levinson, et al., "Towards fully autonomous driving: Systems and algorithms," *2011 IEEE Intelligent Vehicles Symposium*, pp.163-168, 2011.
- [6] B. Il, J. Kim, and S. Kim, "Steering rate controller based on curvature of trajectory for autonomous driving vehicles," *2013 IEEE Intelligent Vehicles Symposium*, pp.1381-1386, 2013.
- [7] J. Forbes, "Reinforcement learning for autonomous vehicles," Ph.D. dissertation, University of California, CA, USA, 2002.
- [8] S. Oh, J. Lee, and D. Choi, "A new reinforcement learning vehicle control architecture for vision-based road following," *IEEE Transactions on Vehicular Technology*, Vol.49, No.3, pp.997-1005, 2000.
- [9] E. Dijkstra, "A note on two problems in connexion with graphs," *Numerische mathematik*, Vol.1. No.1, pp.269-271, 1959.
- [10] R. Sinnott, "Virtues of the Haversine," *Sky and telescope*, Vol.68, p.158, 1984.
- [11] J. Choi and K. Kong, "Localization of a Self-Driving Vehicle Extended Kalman Filtering with FixedGains," in *Proceedings of the International Conference on Computers, Networks, Systems, and Industrial Applications*, pp.89-94, 2012.



김 문 중

e-mail : penbell@naver.com
 2009년 성결대학교 정보통신공학부(학사)
 2013년 서강대학교 컴퓨터공학과(석사)
 2013년~현 재 와이즈넷 Mining tech팀 연구원
 관심분야: 기계학습, 강화학습, 무인 자동차 등



최 기 창

e-mail : chang8831@sogang.ac.kr
 2014년 서강대학교 컴퓨터공학부(학사)
 2014년~현 재 서강대학교 컴퓨터공학과 석사과정
 관심분야: 기계학습, 추천 시스템, 진화 알고리즘 등



오 병 화

e-mail : byonghwaoh@gmail.com
 2007년 서강대학교 컴퓨터학과(학사)
 2009년 서강대학교 컴퓨터공학과(석사)
 2009년~현 재 서강대학교 컴퓨터공학과 박사과정
 관심분야: 기계학습, 추천 시스템, 진화 알고리즘, 네트워크 과학, 베이저안 추론, Deep Learning 등



양 지 훈

e-mail : yangjh@sogang.ac.kr
 1987년 서강대학교 전자계산학과(학사)
 1989년 ISU Department of Computer Science(석사)
 1999년 ISU Department of Computer Science(박사)
 1999년~2000년 HRL Laboratories, LLC, Malibu, CA 연구원
 2000년~2002년 SRA International, Inco, Fairfax, VA 연구원
 2002년~현 재 서강대학교 컴퓨터공학과 교수
 관심분야: 기계학습, 데이터마이닝, 인공지능, 추천 시스템, 바이오인포매틱스 등