

## 자율주행 차량의 다 차선 환경 내 차량 추종 경로 계획

서장필\* · 이경수\*<sup>†</sup>Car-following Motion Planning for Autonomous Vehicles  
in Multi-lane EnvironmentsChangpil Seo\*, Kyoungsu Yi\*<sup>†</sup>*Key Words* : Autonomous driving(자율주행), Car-following(차량 추종), Motion Planning(경로 계획), Target Prediction(타겟 예측)

## ABSTRACT

This paper suggests a car-following algorithm for urban environment, with multiple target candidates. Until now, advanced driver assistant systems (ADASs) and self-driving technologies have been researched to cope with diverse possible scenarios. Among them, car-following driving has been formed the groundwork of autonomous vehicle for its integrity and flexibility to other modes such as smart cruise system (SCC) and platooning. Although the field has a rich history, most researches has been focused on the shape of target trajectory, such as the order of interpolated polynomial, in simple single-lane situation. However, to introduce the car-following mode in urban environment, realistic situation should be reflected: multi-lane road, target's unstable driving tendency, obstacles. Therefore, the suggested car-following system includes both in-lane preceding vehicle and other factors such as side-lane targets. The algorithm is comprised of three parts: path candidate generation and optimal trajectory selection. In the first part, initial guesses of desired paths are calculated as polynomial function connecting host vehicle's state and vicinal vehicle's predicted future states. In the second part, final target trajectory is selected using quadratic cost function reflecting safeness, control input efficiency, and initial objective such as velocity. Finally, adjusted path and control input are calculated using model predictive control (MPC). The suggested algorithm's performance is verified using off-line simulation using Matlab; the results shows reasonable car-following motion planning.

## 1. 서론

자율주행 기술은 도로 위에서 발생하는 다양한 시나리오에 대응하기 위해 지속적으로 개발되어 왔다. 선형 차량 추종은 적응순항기술 등의 형태로 자율 주행의 기반을 이뤄왔으며, 나아가 군집 주행 및 정체 상황에 대처하는 등 그 확장성을 인정받고 있다.

기존에는 기술 개발의 용이성의 이유로 주행 경향에 제약이 있는 고속도로 등의 환경에서 주로 고도화되어 왔다. 하지만 다 차선에 여러 차량이 혼재하는 상황에서 차량 추종이 원활히 이뤄지기 위해서는 대상 타겟의 선정과 그 경로 설정 등에 이슈가 존재한다.

앞선 이슈에 대처하기 위해 다양한 알고리즘이 제시되었다. 보편적으로 자 차량과 타겟의 현재 상태를 다항식 형태로 보간하여 경로를 생성한다. 하지만 이는 타겟의

\* 서울대학교 기계항공공학부  
E-mail : seojangpil@snu.ac.kr

주행 경향에 민감하게 반응하는 한계를 가진다.

또한 여러 차량 중 최적의 추종 타겟을 선정하는 방안도 안정화되어야 한다. 타겟의 현재 상태만으로 추종 안정성을 판단할 경우 주행 경향성과 센서의 정확도에 따라 타겟 선정이 자주 변하는 등 불안정한 결과로 제어 성능이 떨어지기도 한다.

본 연구에서는 센서 데이터를 활용하여 주위 차량의 상태를 예측하는 알고리즘을 기반으로 추종의 대상 경로를 생성 및 최적화하는 알고리즘을 개발한다. 각 차량의 예측된 상태는 속도 및 위치를 바탕으로 보정된 후 자 차량의 상태와 다항식 형태로 연결, 위치 및 속도 후보 군을 형성한다. 이후 설정된 비용 함수를 통해 최적 경로가 선택되어 모델예측제어에 활용된다.

본 논문은 총 5개 장으로 구성된다. 2장에서 차량 상태의 확률론적 예측 이론을 살펴본 후, 3장에서 예측 결과를 활용하여 최적 경로를 생성하는 알고리즘을 개발한다. 4장에서 Matlab을 활용한 시뮬레이션 결과를 분석, 5장 결론에서 의의를 살펴보며 마무리한다.

## 2. 확률론적 타겟 상태 예측

2장에서는 타겟 상태 예측에 사용된 알고리즘을 살펴본다. 차량이 등속도로 차선을 유지하며 주행한다는 가정하에 가상의 측정값을 생성, 칼만 필터에 대입하여 예측값을 실시간으로 업데이트한다. 가상의 측정값은 요 각속도로 설정되며, kinematic 차량 모델을 사용한다. 예측 결과는 Fig. 1과 같이 타겟 상태 및 분산으로 나타난다.




Fig. 1 Target Prediction Overview

### 2.1. 타겟 현재 상태 추정

타겟의 상태는 식 (1)과 같이 종/횡 방향 위치, 상대 각도, 종 방향 속도/가속도, 요 각속도/각 가속도로 설정한다. 현재 상태는 백색 가우시안 노이즈를 가정한 kinematic 모델을 기반의 칼만 필터로 추정된다.

$$\mathbf{x}_n = [p_{n,x} \quad p_{n,y} \quad \theta_n \quad v_n \quad \gamma_n \quad a_n \quad \dot{\gamma}_n]^T \quad (1)$$

$$\begin{aligned} \mathbf{u} &= [v_x \quad \gamma]^T \\ \dot{\mathbf{x}}_n &= \mathbf{g}(\mathbf{x}_n, \mathbf{u}) + \mathbf{q} \\ &= [\mathbf{g}_1 \quad \mathbf{g}_2 \quad \mathbf{g}_3 \quad \mathbf{g}_4 \quad \mathbf{g}_5 \quad \mathbf{g}_6 \quad \mathbf{g}_7]^T + \mathbf{q} \\ \mathbf{q} &\sim (0, \mathbf{Q}) \\ \mathbf{g}_1 &= v_{n,x} \cos \theta_i - v_x + p_{n,y} \cdot \gamma \\ \mathbf{g}_2 &= v_{n,x} \sin \theta_i - p_{n,y} \cdot \gamma \\ \mathbf{g}_3 &= \gamma_n - \gamma \\ \mathbf{g}_4 &= a_{n,x} \\ \mathbf{g}_5 &= \dot{\gamma}_n \\ \mathbf{g}_6 &= -k_a \\ \mathbf{g}_7 &= -k_{\dot{\gamma}} \end{aligned} \quad (2)$$

측정 모델 또한 식 (3)과 같이 kinematic model을 사용하지만, 자차의 상태를 반영하여 보정한다.

$$\begin{aligned} \mathbf{z}_n[k] &= \mathbf{h}(\mathbf{x}_n[k], \mathbf{u}[k]) + \mathbf{v}_n[k] \\ &= [\mathbf{h}_{1,n1} \quad \mathbf{h}_{1,n2} \quad \mathbf{h}_{1,n3} \quad \mathbf{h}_{r,n1} \quad \mathbf{h}_{r,n2} \quad \mathbf{h}_{r,n3}]^T + \mathbf{v}_n[k] \\ \mathbf{v}_n[k] &\sim (0, \mathbf{V}_n[k]) \\ \mathbf{V}_n[k] &= \begin{bmatrix} \mathbf{V}_{1,n} & \mathbf{0} \\ \mathbf{0} & \mathbf{V}_{r,n} \end{bmatrix} \\ \mathbf{h}_{1,n1} &= p_{n,x} \\ \mathbf{h}_{1,n2} &= p_{n,y} \\ \mathbf{h}_{1,n3} &= \theta_n \\ \mathbf{h}_{r,n1} &= p_{n,x} - s_x + v_{n,x} \cdot \cos \theta_n - v_{n,y} \cdot \sin \theta_n \\ \mathbf{h}_{r,n2} &= p_{n,y} - s_y + v_{n,x} \cdot \sin \theta_n + v_{n,y} \cdot \cos \theta_n \\ \mathbf{h}_{r,n3} &= \{v_{n,x} - v_{n,y} (\gamma_n - \gamma_{host})\} \cos(\theta_n - \theta_r) \\ &\quad - v_{n,x} (\gamma_n - \gamma_{host}) \sin(\theta_n - \theta_r) \\ &\quad - p_{n,x} \dot{\gamma}_{host} \sin \theta_r + (p_{n,y} \dot{\gamma}_{host} - v_{host}) \cos \theta_r \end{aligned} \quad (3)$$

연속적인 비선형 예측, 측정 모델은 2계도 테일러 급수를 활용하여 이산형 모델로 변경한다.

### 2.2. 차선 형상 추정

기 설정된 전방 거리까지의 차선은 식 (4)와 같이 횡방향 거리를 종방향 거리를 변수로 한 2차 다항식으로 근사할 수 있다. 이 경우 차선의 오차 동역학은 식 (5)와 (6)과 같이 2차 다항식 계수를 상태로 가지는 예측 및 측정 모델로 정리할 수 있다.

$$\begin{aligned} y_r(x) &= \frac{1}{2R} \cdot x^2 - \tan e_\theta \cdot x - e_y \\ &= a_2 \cdot x^2 + a_1 \cdot x + a_0 \end{aligned} \quad (4)$$

$$\begin{aligned} \dot{\mathbf{x}}_r &= \mathbf{A}_r \cdot \mathbf{x}_r + \mathbf{B}_r \cdot \mathbf{u}_r + \mathbf{w}_r \\ &= \begin{bmatrix} 0 & 0 & 0 \\ 2v & 0 & 0 \\ 0 & v & 0 \end{bmatrix} \cdot \begin{bmatrix} a_2 \\ a_1 \\ a_0 \end{bmatrix} + \begin{bmatrix} 0 \\ -1 \\ 0 \end{bmatrix} \cdot \gamma + \mathbf{w}_r \left( \begin{array}{l} \text{where } v \approx \hat{v} \\ \gamma \approx \hat{\gamma} \end{array} \right) \\ \mathbf{w}_r &\sim (0, \mathbf{Q}_r) \end{aligned} \quad (5)$$

$$\begin{aligned} \mathbf{z}_r[k] &= \mathbf{H}_r \cdot \mathbf{x}_r[k] + \mathbf{v}_r[k] \\ &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \cdot \mathbf{x}_r[k] + \mathbf{v}_r[k] \\ \mathbf{v}_r[\mathbf{k}] &\sim (0, \mathbf{V}_r) \end{aligned} \quad (6)$$

### 2.3. 차선 유지 모델

미래의 가상 측정값을 도출할 경우 예측 정확성을 향상시킬 수 있다. 차량이 현재 주행 중인 차선을 따르려는 경향이 있다는 차선 유지 모델을 활용하면 가상의 요 각 속도를 생성할 수 있다. 이를 위해 차선과의 각도, 횡방향 거리, 요 각속도를 상태로 설정한다.

$$\begin{aligned} \dot{\mathbf{x}}_e &= \mathbf{F}_e \cdot \mathbf{x}_e + \mathbf{G}_e \cdot \gamma_{des} + \mathbf{G}_w \cdot a_2 \\ &= \begin{bmatrix} 0 & v \cos \theta & 0 \\ 0 & 0 & 1 \\ 0 & 0 & f \end{bmatrix} \cdot \begin{bmatrix} e_y \\ e_\theta \\ \gamma \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ -f \end{bmatrix} \cdot \gamma_{des} + \begin{bmatrix} 0 \\ -2v \cos \theta \\ 0 \end{bmatrix} \cdot a_2 \end{aligned} \quad (7)$$

극점 배치를 통해 차선과의 각도 및 횡방향 오차를 0으로 수렴시키는 가상의 요 각속도를 계산한다.

$$\gamma_{des} = -[c_1 \quad c_2 \quad c_3] \cdot \mathbf{x}_e + \gamma_{ff} \quad (8)$$

### 2.4. 타겟 미래 거동 예측

앞서 설정한 kinematic 모델의 상태를 확장 칼만 필터를 사용하여 예측한다. 상태 변수는 2.1 장과 동일하며, 2계도 테일러 급수로 이산형 모델을 구성한다.

$$\begin{aligned} \mathbf{x}_p &= [p_{x,p} \quad p_{y,p} \quad \theta_p \quad v_p \quad \gamma_p \quad a_p \quad \dot{\gamma}_p]^T \\ \mathbf{x}_p[i+1] &= \mathbf{f}_p(\mathbf{x}_p[i+1]) + \mathbf{w}_p[i] \\ &= [\mathbf{f}_{1,p} \quad \mathbf{f}_{2,p} \quad \mathbf{f}_{3,p} \quad \mathbf{f}_{4,p} \quad \mathbf{f}_{5,p} \quad \mathbf{f}_{6,p} \quad \mathbf{f}_{7,p}]^T + \mathbf{w}_p[i] \\ \mathbf{f}_{1,p} &= p_{x,p} + (v_p \cos \theta_p) \Delta t + (a_p \cos \theta_p + \gamma_p v_p \sin \theta_p) \frac{\Delta t^2}{2} \end{aligned}$$

$$\mathbf{f}_{2,p} = p_{y,p} + (v_p \sin \theta_p) \Delta t + (a_p \sin \theta_p + \gamma_p v_p \cos \theta_p) \frac{\Delta t^2}{2}$$

$$\mathbf{f}_{3,p} = \theta_p + (\gamma_p) \Delta t + (\dot{\gamma}_p) \frac{\Delta t^2}{2}$$

$$\mathbf{f}_{4,p} = v_p + (a_p) \Delta t + (-k_a a_p) \frac{\Delta t^2}{2}$$

$$\mathbf{f}_{5,p} = \gamma_p + (\dot{\gamma}_p) \Delta t + (-k_\gamma \dot{\gamma}_p) \frac{\Delta t^2}{2}$$

$$\mathbf{f}_{6,p} = a_p + (-k_a a_p) \Delta t + (k_a^2 a_p) \frac{\Delta t^2}{2a}$$

$$\mathbf{f}_{7,p} = \dot{\gamma}_p + (-k_\gamma \dot{\gamma}_p) \Delta t + (k_\gamma^2 \dot{\gamma}_p) \frac{\Delta t^2}{2}$$

$$\mathbf{F}_p[i] = \left. \frac{\partial \mathbf{f}_p}{\partial \mathbf{x}_p} \right|_{\mathbf{x}_p = \hat{\mathbf{x}}_p[i]}$$

$$\mathbf{B}_p = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

$$\mathbf{w}_p[i] \sim (0, \mathbf{W}_p[i])$$

$$\mathbf{W}_p[i] = \left( \mathbf{B}_p \Delta t + \mathbf{F}_p[i] \mathbf{B}_p \frac{\Delta t^2}{2} \right) \mathbf{Q}_p \left( \mathbf{B}_p \Delta t + \mathbf{F}_p[i] \mathbf{B}_p \frac{\Delta t^2}{2} \right)^T \quad (9)$$

앞선 가상의 측정값을 활용해 측정 업데이트를 실시한다.

$$\begin{aligned} \mathbf{z}_p[i] &= \mathbf{H}_p \mathbf{x}_p[i] + \mathbf{v}_p[i] \\ &= [0 \quad 0 \quad 0 \quad 0 \quad 1 \quad 0 \quad 0] x_p[i] + v_p[i] \\ &= \hat{\gamma}_{des,p}[i] \\ &= -\mathbf{C} \cdot \bar{\mathbf{x}}_{cp}[i] + \gamma_{ff}[i] \\ \bar{\mathbf{x}}_{cp}[i] &= \mathbf{f}_c(\bar{\mathbf{x}}_p[i], \hat{\mathbf{x}}_p[0]) \\ &= [\bar{e}_y[i] \quad \bar{e}_\theta[i] \quad \bar{\gamma}_p[i]]^T \\ &= \begin{bmatrix} \bar{p}_{y,p}[i] - \{ \hat{a}_2 \cdot \bar{p}_{x,p}[i]^2 + \hat{a}_1 \cdot \bar{p}_{x,p}[i] + \hat{a}_0 + \hat{w}_{road} \cdot N[i] \} \\ \bar{\theta}_p[i] - \tan^{-1}(\hat{a}_2 \cdot \bar{p}_{x,p}[i] + \hat{a}_1) \\ \bar{\gamma}_p[i] \end{bmatrix} \end{aligned}$$

$$\mathbf{v}_p[i] \sim (0, \mathbf{V}_p[i])$$

$$\mathbf{V}_p = \mathbf{V}_{p, \text{const}} + [\bar{e}_y[i] \quad \bar{e}_\theta[i]] \mathbf{W}_{\text{correct}} [\bar{e}_y[i] \quad \bar{e}_\theta[i]]^T \quad (10)$$

위의 예측 모델을 정리하면 식 (11)을 얻는다.

$$\hat{\mathbf{x}}_p[0] = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}, \hat{\mathbf{P}}_p[0] = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \mathbf{P}[\mathbf{k}] \end{bmatrix}$$

$$\bar{\mathbf{x}}_p[i] = \mathbf{f}_p(\hat{\mathbf{x}}_p[i-1])$$

$$\begin{aligned}
 \mathbf{F}_p[i-1] &= \frac{\partial \mathbf{f}_p}{\partial \mathbf{x}_p} \Big|_{\mathbf{x}_p=\hat{\mathbf{x}}_p[i-1]} \\
 \mathbf{M}_p[i] &= \mathbf{F}_p[i-1] \mathbf{P}_p[i-1] \mathbf{F}_p[i-1]^T + \mathbf{W}_p \\
 \bar{\mathbf{x}}_{\text{cp}}[i] &= \mathbf{f}_c(\bar{\mathbf{x}}_p[i], \hat{\mathbf{x}}_r[0]) \\
 \mathbf{z}_p[i] &= -\mathbf{C} \cdot \bar{\mathbf{x}}_{\text{cp}}[i] + \gamma_{\text{ff},p}[i] \\
 \mathbf{V}_p[i] &= \mathbf{V}_{p,\text{const}} + [\bar{e}_y[i] \quad \bar{e}_\theta[i]] \mathbf{W}_{\text{correct}} [\bar{e}_y[i] \quad \bar{e}_\theta[i]]^T \\
 \mathbf{K}_p[i] &= \mathbf{M}_p[i] \mathbf{H}_p^T \cdot (\mathbf{H}_p \mathbf{M}_p[i] \mathbf{H}_p^T + \mathbf{V}_p[i])^{-1} \\
 \mathbf{P}_p[i] &= (\mathbf{I} - \mathbf{K}_p[i] \mathbf{H}_p) \cdot \mathbf{M}_p[i] \\
 \hat{\mathbf{x}}_p[i] &= \bar{\mathbf{x}}_p[i] + \mathbf{K}_p[i] \cdot (\mathbf{z}_p[i] - \mathbf{H}_p \cdot \bar{\mathbf{x}}_p[i]) \quad (11)
 \end{aligned}$$

### 3. 추종 타겟 경로 군 생성 및 경로 최적화

3장에서 각 타겟 별을 추종하는 경로 후보의 생성 및 이들의 최적화 알고리즘을 살펴본다. 2장에서 살펴본 타겟 상태 예측 결과를 보정하여 추종 상태 및 경로 군을 생성하며, quadratic 형태의 비용 함수를 활용해 최적 경로를 선정한다.

#### 3.1. 최적 경로 후보 생성

최적 추종 상태 후보는 2장의 알고리즘에서 예측된 값을 활용한다. 연산 당시의 타겟 상태를 그대로 활용할 시 차량의 주행 경향 및 급격한 변동으로 인해 불안정한 제어가 발생할 수 있다. 또한 이산적인 연산과 그 사이의 타겟 이동으로 인해 추종 효율이 낮아진다. 따라서 2장에서 소개된 예측된 타겟의 상태를 활용하여, 타겟의 주행 불안정성 및 연산의 불연속성을 보완한다.

타겟의 예측된 미래 거동은 차선과 타겟의 관계로 계산되므로 타 차량과의 충돌 등이 반영되어야 한다. 따라서 아래 기준으로 각 차선의 타겟을 보정한다.

- (1) 인지된 각 차선 최전방의 차량 예측 상태
- (2) 인지된 각 차선의 차량들의 전/후방 쌍 평균
- (3) 인지된 각 차선 최후방의 차량 예측 상태

$$\begin{aligned}
 \xi_{\text{curr}} &= [p_{x,\text{curr}} \quad p_{y,\text{curr}} \quad \theta_{\text{curr}} \quad v_{\text{curr}} \quad \gamma_{\text{curr}} \quad a_{\text{curr}} \quad \dot{\gamma}_{\text{curr}}]^T \\
 \xi_{\text{goal}} &= [p_{x,\text{goal}} \quad p_{y,\text{goal}} \quad \theta_{\text{goal}} \quad v_{\text{goal}} \quad \gamma_{\text{goal}} \quad a_{\text{goal}} \quad \dot{\gamma}_{\text{goal}}]^T \\
 \xi_{\text{goal},j} &= \begin{cases} \xi_{\text{ig},\text{pred},j}[t_{p,\text{fin}}] & j=1, N_{\text{ig}}+1 \\ \text{avg}(\xi_{\text{ig},\text{pred},j-1}[t_{p,\text{fin}}], \xi_{\text{ig},\text{pred},j}[t_{p,\text{fin}}]) & j=2, \dots, N_{\text{ig}} \end{cases} \quad (12)
 \end{aligned}$$

식 (12)의 보정 상태와 차 차량의 상태를 연결하기 위해 종/횡방향 좌표축에 대해 시간을 변수로 둔 3차 보간 다항식을 활용한다.

$$\boldsymbol{\eta} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \cdot \xi = \begin{bmatrix} \eta_x \\ \eta_y \end{bmatrix}$$

$$\boldsymbol{\eta}_i(t_p) = \mathbf{c}_{i,3} t_p^3 + \mathbf{c}_{i,2} t_p^2 + \mathbf{c}_{i,1} t_p + \mathbf{c}_{i,0} \quad i = x, y$$

$$\text{subject to } [\boldsymbol{\eta}_i(t_{p,\text{ini}}) \quad \boldsymbol{\eta}_i(t_{p,\text{fin}})] = [P_{i,\text{curr}} \quad P_{i,\text{goal}}]$$

$$\left[ \frac{d}{dt} \boldsymbol{\eta}_i \Big|_{t_p=t_{p,\text{ini}}} \quad \frac{d}{dt} \boldsymbol{\eta}_i \Big|_{t_p=t_{p,\text{fin}}} \right] = [v_{i,\text{curr}} \quad v_{i,\text{goal}}] \quad (13)$$

3차 보간 결과는 Fig. 2와 같다.




Fig. 2 3<sup>rd</sup> order Polynomial Path

#### 3.2. 최적 경로 선정

3.1 장에서 생성된 3차 다항식 경로 군 중 최적의 값을 선정하기 위해 아래의 개념을 포함한 quadratic 비용 함수를 활용한다.

- (1) 모든 타겟 들의 예측 경로와 중첩 최소화
- (2) 제어 입력의 크기를 최소화
- (3) 주행 중인 차선을 유지(차선 변경 간 근접 차선)
- (4) 기 설정 목표 속도 유지
- (5)

조건 (1)은 충돌 방지 목적이며, 조건 (2), (3)과 함께 불필요한 차선 변경 및 타겟의 빈번한 선정 변경을 방지한다. 조건 (4)는 차량 정체 등의 상황에서 초기 설정된 목표 속도를 유지할 수 있는 타겟을 적극적으로 탐색하기 위함이다. Cost function은 보간 경로와 타겟 예측 경로와의 오차, 종/횡방향 가속도 입력, 보간 속도와 목표 속도와의 오차, 목표 차선 등으로 구성되며, 각각의 조건은 고유의 weight를 가진다.

$$\mathbf{J} = \sum_{j=0}^M \sum_{k=0}^N \left[ (\Delta \eta_{k,j}) \mathbf{Q}_{dup} (\Delta \eta_{k,j})^T \right] + \sum_{k=0}^{N-1} \left[ (\mathbf{u}_k) \mathbf{R}_{input} (\mathbf{u}_k)^T \right] + \sum_{k=0}^{N-1} \left[ (v_{tg,pred} - v_{des}) \mathbf{S}_{vel} (v_{tg,pred} - v_{des})^T \right] + (N_{road} - N_{road,des}) \mathbf{S}_{lane} (N_{road} - N_{road,des})^T$$

where

$$\Delta \eta_{k,j} = \mathbf{R}_{rot[k]} \begin{bmatrix} \eta_x(t_{p,k}) - p_{x,target,j}[k] \\ \eta_y(t_{p,k}) - p_{y,target,j}[k] \end{bmatrix}$$

$$\mathbf{R}_{rot[k]} = \begin{bmatrix} \cos(\psi_k) & \sin(\psi_k) \\ -\sin(\psi_k) & \cos(\psi_k) \end{bmatrix}$$

$$\psi_k = \tan^{-1} \left( \frac{\eta_x(t_{p,k})}{\eta_y(t_{p,k})} \right)$$

$$\mathbf{u}_k = \begin{bmatrix} a_{x,input} & a_{y,input} \end{bmatrix}^T \quad (14)$$

각 경로에 대해 비용 함수를 계산하여, 최소 비용의 3차 다항식 경로를 초기 최적 경로로 설정한다.

$$[\eta_x \quad \eta_y]_{opt} = \min_{\xi_{curr}, \forall \xi_{goal}} \mathbf{J}(\eta_x, \eta_y)$$

### 3.3. 제어 입력 도출

앞서 도출된 최적 경로의 실제 제어 입력은 조향각과 종방향 가속도로 구현된다. 장애물, 입력 상하한 등이 제약조건으로 설정된 자전거 모델 기반의 모델예측제어를 사용하여 최적화된 제어 입력을 계산한다.

### 3.4. 통합 알고리즘

위에서 정리한 타겟 예측 및 최적 경로 선정, 제어 입력 계산은 Fig. 3과 같이 다이어그램으로 정리가 가능하다.




Fig. 3 Car-following Algorithm Diagram

## 4. 시뮬레이션 결과 분석

차량 모델 알고리즘을 구현한 Matlab을 활용하여 시나리오 별 시뮬레이션을 실시하였다. 타겟 예측 간 사용된

이득 및 분산은 실험값을 사용하였으며, 시뮬레이션 및 알고리즘 연산은 0.1초 단위로 실시되었다.

### 4.1. 동일 속도 다중 차량(곡선로 구간)

Fig. 4는 자 차량의 목표 속도는 30kph, 3차선 내 주위 차량은 모두 20kph로 주행하는 상황의 결과이다. 초기 설정된 목표 속도와의 오차가 모든 타겟에서 동일하다. 따라서 주위 차량들의 예상 경로가 장애물로 인식되는 상황에서 동일한 차선에서의 타겟을 지속적으로 추종한다. 목표 타겟과 동일한 속도로 주행하므로 안전 거리 확보가 이루어 진다.

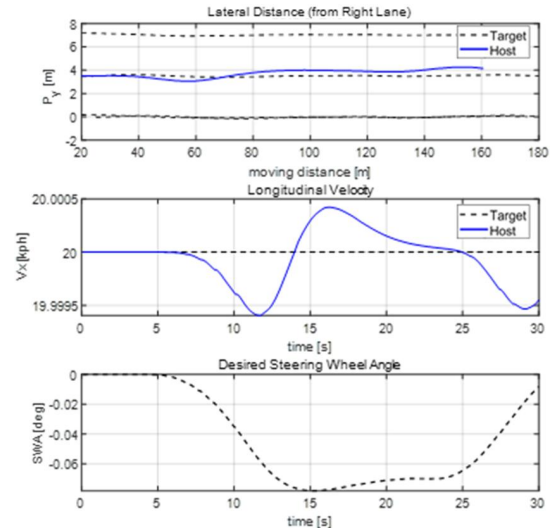


Fig. 4 Multi Target with Same Velocity in Corner Lane

곡선로 구간에 들어선 30초 이후부터는 목표 타겟의 누적 경로와 0.5m 이내의 오차를 보인다. 타겟 경로를 3차 다항식으로 보간 하므로 도로의 회전반경이 정확히 반영되지 못한 결과이다. 하지만 나타난 횡방향 오차 범위가 차선 폭 내에 존재한다. 또한 차량의 현재 상태를 타겟을 설정하였을 경우 선회 구간 시작점에서 반경 안쪽으로 경로가 쏠리는 문제점이 보완되었다.

### 4.2. 임의 속도 다중 차량(직진 구간)

Fig. 5는 서로 다른 속도의 차량들이 직진 도로를 주행할 때의 시뮬레이션 결과이다. 자 차량의 목표 속도는 30kph이며, 후보 타겟들은 위부터 20, 25, 30kph이다. 결과로

살펴보면, 타 차선에서 목표 속도에 가깝게 주행하는 타겟을 선정하며 주행하나, 차선 변경 간에는 동일 차선의 타겟 선정을 일정수준 유지하여 안정적인 주행을 확보하고자 한다.




Fig. 5 Multi Target with Different Velocity in Straight Lane

또한 속도 변화를 살펴보면, 타겟의 예측 상태와 자 차량의 상태를 시간에 따라 보간 하여 차선 변경 등의 선회에서는 속도를 급격하게 변화시키지 않으나, 직진 구간 등의 안정적인 환경에서 속도를 증가시키는 경향을 보였다.

#### 4.3. 임의 속도 다중 차량(곡선로 구간)

Fig. 6은 Fig. 4와 동일한 주위 차량 주행 속도 조건 하에서 선회 도로 환경에서 시뮬레이션을 실시한 결과이다. 초기 직진 구간에서는 동일하게 자 차량의 설정 목표 속도에 가까운 타겟을 선정하여 차선을 변경하나, 곡선로 구간에서는 타겟 변경이 이루어지지 않았다. 이는 선회 구간에서 차선 변경에 요구되는 추가 가속도가 quadratic 형태에서 큰 차이를 발생시키기 때문으로 판단된다. 또한 유사한 의미로 3차 다항식으로 경로 및 속도를 보간하는 과정에서 선회 구간의 경우 직진 구간 대비 작은 종방향 속도가 계산되게 된다. 따라서 초기 목표 속도 달성 조건 대비 안정적 주행을 최적으로 판단하게 된다.

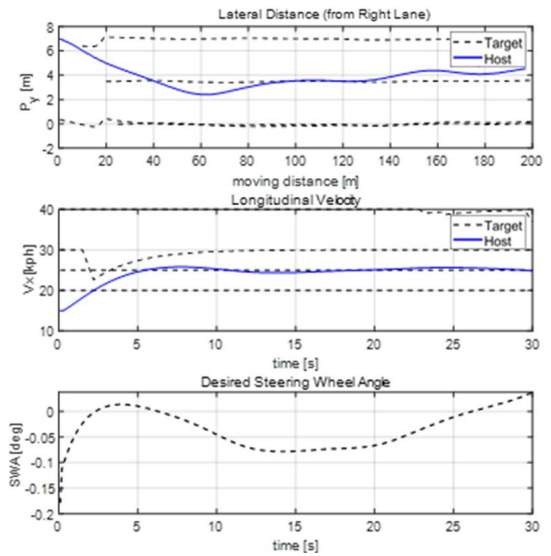


Fig. 6 Multi Target with Different Velocity in Corner Lane

## 5. 결론

본 연구 결과 및 의의를 요약하면 다음과 같다.

- 1) 타겟의 현 상태를 기준으로 추종알고리즘을 작성했을 때 발생하는 이산적인 알고리즘 계산 간 순차적인 목표 상태 밀림 현상을 타겟 예측 알고리즘을 도입하여 보완하였다.
- 2) 안정적인 추종 타겟 선정을 위해 타겟들의 예측 경로의 꺾임과 제어 입력의 크기, 주행차선과의 차이를 반영했다. 또한 기 설정 목표 속도가 전방 타겟의 느린 속도로 달성되지 못할 때 안전이 보장된 상태에서는 효율적으로 타겟을 변경할 수 있도록 비용 함수를 설정하였다.
- 3) 다양한 속도 분포를 가진 타겟들이 주위에 배치된 상황을 가정한 시뮬레이션을 실시하여 앞서 설정한 비용 함수가 안전성을 확보하면서도 기 설정 목표 속도를 달성할 수 있는 타겟을 능동적으로 선택함을 확인하였다.
- 4) 전방 차량과의 간격 및 속도를 제어하는 순항 제어 알고리즘 대비, 타 차선의 타겟까지 후보군으로 설정하여 주행 목적 자유도를 높인다.
- 5) 현재 타겟 상태를 기반으로 추종 대상 선정 후 경로를 설정하는 다차선 내 추종 알고리즘 대비, 모든 타겟 예측 결과를 추종하는 경로를 생성 후 최

적화를 실시하여 타겟 선정 안정성을 얻는다.

이후 추가 연구방향은 다음과 같다.

- 1) 해당 제어 알고리즘을 실제 차량에 적용하여 제어 효율 및 강건성 등을 확인한다.
- 2) 차선 변경 등의 시나리오 대응 알고리즘과의 융합을 통해 안정적인 차량 추종을 구현한다.
- 3) 다항식으로 목표 경로 후보를 생성할 때 위치 기반으로 근사하는 방법에서 나타나는 횡방향 오차를 줄일 수 있는 효과적인 방안을 모색한다.

### 후 기

본 연구는 국토 교통부 교통물류연구사업의 연구비 지원(19TLRP-B146733-02) 및 과학기술정보통신부의 지원(NRF - 2016R1E1A1A01943543)의 지원을 받아 수행하였습니다.

### 참고문헌

- (1) 박중철, 채홍식, 이경수, 2018, “확률론적 차량거동 예측 모델 기반 끼어들기 차량 의도 파악”, 자동차 안전학회 춘계 학술대회.
- (2) Kim, B. and Yi, K., 2013, “Probabilistic states prediction algorithm using multi-sensor fusion and application to Smart Cruise Control systems”, IEEE Intelligent Vehicles Symposium, pp. 888~895.
- (3) B. Kim, K. Yi, H. Yoo, H. Chong and B. Ko, “An IMM/EKF Approach for Enhanced Multitarget State Estimation for Application to Integrated Risk Management System”, in IEEE Transactions on Vehicular Technology, vol. 64, no. 3, pp. 876~889, March 2015.
- (4) 김동욱, 윤지환, 이경수, 2013, “정지/서행 주행 상황에서의 자율 주행 차량의 조향 및 순항 제어”, 대한기계학회 춘추학술대회, pp. 129~130.
- (5) Kim, D., Kim, H. and Yi, K., “Lateral Control for Automated Vehicle Following System in Urban Environments”, 2014, SAE Int. J. Trans. Safety 2(2), pp. 199~206.
- (6) Moon, S., Moon, I.K., Yi, K., 2009, “Design, Tuning, and Evaluation of a Full-range Adaptive Cruise Control System with Collision Avoidance”, Control Engineering Practice. Col. 17. pp. 442~455.
- (7) Gehrig, S. K., 1998, “A Trajectory-based Approach for the Lateral Control of Car Following Systems”, IEEE International Conference, Vol. 4, pp. 3596~3601.
- (8) L. Guo, P. Ge, Y. Qiao and L. Xu, “Multi-Objective Adaptive Cruise Control Strategy Based on Variable Time Headway”, 2018 IEEE Intelligent Vehicles Symposium (IV), 2018, pp. 203~208.
- (9) F. Ulbrich, S. Sundermann, T. Langner, D. Goehring and R. Rojas, “Following Cars With Elastic Bands”, 2018 IEEE Intelligent Vehicles Symposium (IV), 2018, pp. 1529~1536.
- (10) U. Munir and Z. Junzhi, “Weight Changing Model Predictive Controller for Adaptive Cruise Control with Multiple Objectives”, 2018 IEEE International Conference on Mechatronics, Robotics and Automation (ICMRA), 2018, pp. 62~66.