

지능형 운전보조시스템을 위한 IMM 기법을 이용한 전방차량 거동추정기법

Neighboring Vehicle Maneuver Detection using IMM Algorithm for ADAS

정 선 휘, 이 운 성, 강 연 식*
(Sun-Hwi Jung¹, Woon-Sung Lee¹, and Yeonsik Kang¹)
¹Department of Automotive Engineering, Kookmin University

Abstract: In today's automotive industry, there exist several systems that help drivers reduce the possibility of accidents, such as the ADAS (Advanced Driver Assistance System). The ADAS helps drivers make correct and quick decisions during dangerous situations. This study analyzed the performance of the IMM (Interacting Multiple Model) method based on multiple Kalman filters using the data acquired from a driving simulator. An IMM algorithm is developed to identify the current discrete state of neighboring vehicles using the sensor data and the vehicle dynamics. In particular, the driving modes of the neighboring vehicles are classified by the cruising and maneuvering modes, and the transition between the states is modeled using a Markovian switching coefficient. The performance of the IMM algorithm is analyzed through realistic simulations where a target vehicle executes sudden lane change or acceleration maneuver.

Keywords: active safety system, ADAS (Advanced Driver Assistance System), vehicle tracking

I. 서론

운전자의 부주의 혹은 잘못된 운전 습관은 교통사고의 주요 원인 중 하나이다. 표 1은 미 도로교통 안전국(NHTSA: National Highway Traffic Safety Administration)에서 조사한 자료에 의하면 음주운전이 교통사고의 가장 주요한 원인이고 그 뒤를 이어서 운전자의 산만함, 과속 등이 주요 원인으로 꼽히고 있다[1]. 특히 운전자의 산만함은 전체 교통사고에 대한 원인 중 약 25%를 차지하고 있으며, 날씨를 제외하고 대부분 운전자 과실에 의해 교통사고가 발생함을 알 수 있다.

이러한 운전자 과실에 의한 사고의 발생 가능성을 낮추고 운전자의 운전에 대한 부담을 덜어주기 위해 다양한 '첨단 운전자 보조 시스템(ADAS: Advanced Driver Assistance System)'이 등장하고 있다. 첨단 운전자 보조 시스템의 대표적인 예로는 '차선 이탈 경고 시스템(LDWS: Lane Departure Warning System)', '사각지대 경고 장치(Blind Spot Warning)', '적응형 순항 제어 장치(ACC: Adaptive Cruise Control)', '전방 충돌 경고 시스템(FCW: Forward Collision Warning)', '충돌 회피 시스템(Collision Avoidance System)', '주차 조향 보조 시스템(SPAS: Smart Parking Assist System)' 등이 있다. ADAS 중에서 ACC와 FCW는 전방 차량을 검출하고 해당 차량의 거동에 대한 추정을 정확히 하는 것이 중요하다. 이들 두 시스템은 차량에 장착된 레이더를 통해 전방 차량의 속도를 줄이거나 운전자에게 경고 메시지를 보내게 된다. 최근에는 이러한 시스템이

더욱 진보된 형태로 자동차가 스스로 긴급 상황을 인식하고 회피할 수 있는 시스템들이 등장하고 있고 앞으로는 더욱 발전된 형태의 시스템들이 등장 할 것이다. 이처럼 자동차가 긴급 상황을 회피하기 위해서는 전방 차량의 주행에 대한 정보 획득이 필요하며, 지능형 차량의 시스템이 발전함에 따라 관련 수요도 꾸준히 증가할 것이라고 예측된다.

이처럼 움직이는 물체를 추적하고 그 거동을 추정하는데 있어서 일반적으로 자주 연구에 활용되고 있는 알고리즘은 칼만필터이다. 칼만필터는 연속적인 자연 현상을 불연속적인 동역학적 모델로 예측하여 물체의 거동을 추정할 수 있는 알고리즘으로, 칼만필터를 활용하면 위치 정보를 이용하여 속도 혹은 가속도 등의 거동과 관련된 정보를 추정하는 것이 가능하다. 이와 관련하여 많은 연구가 진행되었는데, 이러한 연구가 가장 활발하게 진행된 분야는 바로 군사 및 항공우주 산업 분야였다. 이들 분야에서는 미사일 등의 무기나 인간이 조종하는 비행기, 배, 잠수함 등 다양한 패턴으로 거동하는 물체에 대해 이를 추적하고 거동을 추정할 수 있는 기법이 개발되었다. 1970년에 Singer는 비행기의 거동을 랜덤 노이즈가 포함된 선형적인 등가속도 모델로 제안[2] 하였고 McAulay와 Denlinger는 Singer의 모델을 기반으로 비행기의 비행 패턴을 직접 반영하여 비행기가 일정한 패턴으로 비행

표 1. 교통사고의 주요 원인(미 도로교통 안전국).

Table 1. Common causes of automobile crashes (NHTSA).

1	Drunk Driving
2	Driver Distraction (Including Driver Fatigue)
3	Speeding
4	Aggressive Driving
5	Weather

* 책임저자(Corresponding Author)

Manuscript received January 25, 2013 / revised March 13, 2013 / accepted June 10, 2013

정선휘, 이운성, 강연식: 국민대학교 자동차전통대학원

(beetle@kookmin.ac.kr/wslee@kookmin.ac.kr/ykang@kookmin.ac.kr)

※ 본 연구는 2012년 정부(교육과학기술부)의 재원으로 한국연구재단 지원을 받아 수행된 연구임(No. 2012-0003374).

할 때는 등속 모델, 그 이외에 대해서는 가속 모델을 활용하는 추적 알고리즘을 제안하였다[3,4]. 이후 다양한 거동 패턴을 가지는 물체에 대한 추적 알고리즘이 등장하였지만, 가장 많이 사용되는 것은 white noise가 포함된 상대 거리와 속도 그리고 경우에 따라서 가속도가 포함된 동역학적 모델을 활용한 추적 알고리즘이었다[4,5].

이후 Bar Shalom은 1988년 [6]를 통해서 기존의 알고리즘의 가지는 한계점을 극복하기 위해 ‘Markov Chain’을 활용하여 서로 다른 모델을 활용한 2가지 이상의 거동 패턴을 가지는 물체를 추적할 수 있는 ‘IMM (Interacting Multiple Model)’ 알고리즘을 제안하였다. 또한, 1993년 Bar Shalom은 [7]을 통해 비행기를 추적함에 있어서 비행기의 비행 모드를 ‘Uniform Motion’과 ‘Maneuvering’으로 정의하여 전자를 ‘straight flight’와 ‘level flight with constant velocity’로, 후자를 ‘turning’과 ‘climbing/descending’으로 분류하였다. 그는 IMM 알고리즘을 비행기를 추적하는 알고리즘으로 제안, 이를 검증하였다.

자동차산업 분야에서는 비전 센서, 레이더를 포함한 각종 센서들의 등장과 ADAS의 발달로 인해 주변 차량의 추적 및 거동 추정에 대한 수요가 증가하고 있다. 최근 자동차에 널리 보급되고 있는 레이더는 일반적으로 밀리미터파를 통해 전방의 장애물을 탐지하는데, 레이더로부터 획득된 데이터에는 false clutter noise같은 에러들이 포함되어 있다. 이러한 노이즈를 필터링하고 차량 오인식을 줄이는 것이 전방 차량의 거동을 추정하기 위한 가장 중요한 요소이다[8]. 자동차의 경우 실제 주행에서 차선 변경이나 가속, 감속 등이 수시로 이루어짐에 따라 거동 추정에 한계가 있었고, 이러한 단점을 극복하기 위해 IMM 알고리즘을 활용한 연구가 진행되었다. 특히 ‘ADAS’ 중에서 시중에 상용화가 활발히 이루어진 ‘ACC’나 ‘FCW’를 위한 주변 차량 거동 추정 시스템으로 IMM 알고리즘을 활용하는 연구가 수행되었다[9,10].

본 연구에서는 IMM 알고리즘을 전방 차량의 거동 추정을 위한 알고리즘으로 활용하였다. IMM 알고리즘의 특징은 차량의 거동을 복수의 State Space Equation으로 정의하고, 각각의 주행 모드에 따른 칼만필터기반의 추적 알고리즘을 적용하였다. 이를 위해서 주행 조건을 기반으로 차량의 거동을 등속주행, 가속, 감속, 차선 변경으로 분류하고 각각의 거동의 특성을 가속도를 기반으로 분석하여 서로 다른 주행 모드에 대한 동역학적 모델을 구분하였다. 또한 주행 모드가 변화될 확률을 일정한 전이 확률을 갖는 Markov 모델로 정의하여 Likelihood Function을 통해 전방차량의 거동을 추정할 수 있는 모델 확률을 계산하였다.

IMM을 이용한 기존의 연구결과에서는 이를 이용한 추적 성능 향상에 주로 초점을 맞추어 성능을 분석하였다[12,13]. 따라서 본 연구에서도 복수 모델을 사용하는 IMM 기법이 단일 모델을 사용하는 칼만필터 기법에 비하여 추적성능 측면에서 우월함을 시뮬레이션 데이터를 이용하여 분석하였다. 추가적으로 본 연구에서는 IMM에서 얻을 수 있는 복수의 모델에 대한 모델확률을 이용하면 전방차량의 거동을 확률적으로 추정해낼 수 있음을 확인하였다.

이와 같은 기법을 통하여 향후 전방차량의 거동이 자기 차량에게 위협할 수 있는 거동을 보이는 것으로 판단될 경우

운전자에게 경고 메시지를 보내거나 스스로 충돌을 회피하는 능동안전시스템의 개발에 적용될 수 있을 것이다.

II. IMM 알고리즘

1. 개요

전방 차량의 거동을 추정하는 것은 레이더 센서가 얼마나 전방의 차량을 잘 검출하느냐에 달려 있다. Bar Shalom에 의해 제안된 IMM 알고리즘의 가장 중요한 특징은 다양한 거동 패턴을 갖는 물체를 추적하는데 널리 활용되는 알고리즘으로[13], 물체가 유한한 복수의 변화하는 거동 패턴을 갖는다고 가정하여 각각의 거동 패턴에 맞는 동역학적 모델의 예측을 통해서 해당 물체의 상태를 추정하는 알고리즘이다. 센서로부터 얻은 측정값은 각각의 모델을 통과하며, 알고리즘의 결과 값인 state 추정치와 오차 공분산이 계산되게 된다. 이 때 모델 사이의 변화는 Markov Chain에 의해서 확률적으로 파악되며, 각각의 모델 내에서 거동의 추정은 칼만필터에 의해서 이루어진다. 또한 이 필터들은 사전에 예측된 차량의 거동에 맞는 동역학적 모델을 기반으로 서로 독립적으로 물체를 추적한다[14,15].

2. IMM 알고리즘

IMM 알고리즘은 각각에 모델에 대한 필터링 프로세스, 각각의 모델에 대한 추정치를 더하여 새로운 추정치를 계산해 다음 추정 시 사용할 수 있게 해 주는 프로세스 등이 포함되어 있다[16]. IMM 알고리즘에 대한 개략도는 그림 1과 같다. $\hat{x}(k)$ 는 추정하고자 하는 state며 본 연구에서는 동역학적 모델은 같지만 가속도의 표준편차에 의해 서로 구분되는 2개의 모델을 사용하였다. IMM 알고리즘은 재귀적인 알고리즘 [17,18]으로 각각의 사이클은 그림 1과 같이 Interaction, Filtering, Model Probability Update, Combination의 4개의 단계로 이루어져 있다.

IMM 알고리즘의 첫 번째 단계는 Interaction이다. 이 단계에서는 이전의 사이클에서 획득한 최종 추정치 및 공분산을

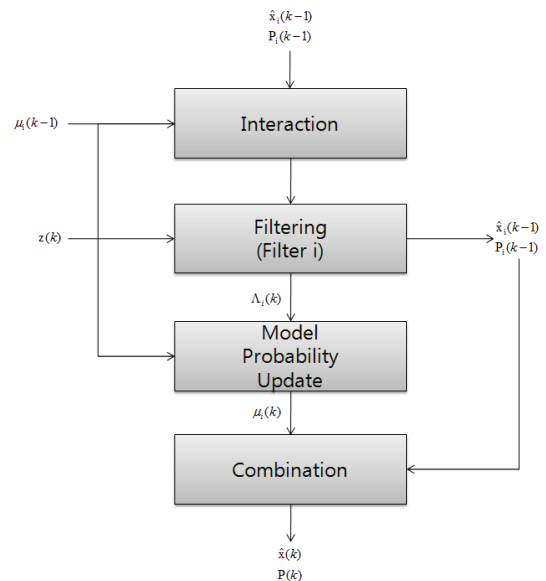


그림 1. IMM 알고리즘의 개략도.
Fig. 1. Schematic of IMM algorithm.

입력 값으로 사용하기 위해 새롭게 재정의 한다. j번째 모델에 대한 mixing probability는 식 (1)과같이 표현된다.

$$\mu_{ij}[k-1] = \frac{\pi_{ij}\mu_i[k-1]}{\sum_{n=1}^r \pi_{nj}\mu_n[k-1]} \quad (1)$$

π_{ij} 는 Markov 모델로부터 정의되는 전이 확률이며 r은 모델의 개수이다. 분모는 예측된 모드에 대한 확률로 식 (2)와 같이 쓸 수 있다.

$$\bar{\mu}_j = \sum_{n=1}^r \pi_{nj}\mu_n[k-1] \quad (2)$$

모델 j에 대한 mixed initial condition중에서 초기 state는 식 (3)으로 표현된다.

$$\hat{x}_j^0[k-1] = \sum_{i=1}^r \hat{x}_i[k-1]\mu_{ij}[k-1] \quad (3)$$

또한 모델 j에 대한 초기 오차 공분산은 식 (4)와 같이 표현할 수 있다.

$$P_i^0[k-1] = \sum_{i=1}^r \mu_{ij}[k-1]\{P_i[k-1] + [\hat{x}_i[k-1] - \hat{x}_j^0[k-1]][\hat{x}_i[k-1] - \hat{x}_j^0[k-1]]^T\} \quad (4)$$

두 번째 단계는 Filtering이다. 이 단계에서는 각각의 필터가 서로 독립적으로 필터링을 수행한다. j번째 필터의 예측된 state 추정은 식 (5)와 같이

$$\hat{x}_j[k|k-1] = A_j\hat{x}_j^0[k-1] + \Gamma_j\omega_j[k-1] \quad (5)$$

으로 표현되며 $\omega_j[k-1]$ 의 값은 프로세스 노이즈이다. 이와 관련하여 예측된 state의 추정에 대한 공분산은 식 (6)과 같다.

$$P_j[k|k-1] = A_jP_i^0[k-1]A_j^T + \Gamma_jQ_j[k]\Gamma_j^T \quad (6)$$

선형 측정 모델 z와 실제 측정치의 차이로부터 계산되는 나머지는 식 (7)로 정의할 수 있다.

$$v_j = z[k] - H_j\hat{x}_j[k|k-1] \quad (7)$$

그러므로 측정치에 대한 오차 공분산은 식 (8)과 같다.

$$S_j[k] = H_jP_j[k|k-1]H_j^T + R_j[k] \quad (8)$$

이 때 칼만계인은 식 (9)와 같이 계산된다.

$$W_j[k] = P_j[k|k-1]H_jS_j[k]^{-1} \quad (9)$$

구하여진 칼만계인을 사용하여 필터 j에 대한 새로운 state 추정은 식 (10)으로, 그 공분산은 식 (11)로 계산할 수 있다.

$$\hat{x}_j[k|k] = \hat{x}_j[k|k-1] + W_j[k]v_j[k] \quad (10)$$

$$P_j[k|k] = P_j[k|k-1] - W_j[k]S_j[k]W_j^T[k] \quad (11)$$

세 번째 단계는 Model Probability Update이다. 이 단계는 likelihood function에 기반을 두고 있으며, 그 값은 식 (12)와 같이

$$\Lambda_j[k] = |2\pi S_j[k]|^{-\frac{1}{2}} e^{-\frac{1}{2}v_j^T[k]S_j^{-1}[k]v_j[k]} \quad (12)$$

이고, 새롭게 유도된 모델 확률은 식 (13)과 같다.

$$\mu_j[k] = \frac{\Lambda_j[k]\bar{\mu}_j[k]}{\sum_{i=1}^r \Lambda_i[k]\bar{\mu}_i[k]} \quad (13)$$

마지막 네 번째 단계 Combination에서는 앞서 계산된 확률에 근거하여 모든 필터를 통해 추정된 state들에 가중치를 곱한 합으로 계산한다. 최종 state는 식 (14)와 같다.

$$\hat{x}[k] = \sum_{j=1}^r x_j[k|k]\mu_j[k] \quad (14)$$

각각의 모드에 대한 확률은 최종 state 뿐만 아니라 오차 공분산에도 영향을 미치게 된다. 최종 오차 공분산은 식 (15)로 표현된다.

$$P[k] = \sum_{j=1}^r \mu_j[k]\{P_j[k|k] + [\hat{x}[k|k] - \hat{x}_j[k|k]][\hat{x}[k|k] - \hat{x}_j[k|k]]^T\} \quad (15)$$

III. 전방 차량 주행 모델링

1. State Space Model

주행 중인 전방 차량에 대한 동역학적 모델은 2개의 모델을 사용하여 구현하였다. 이 2개의 동역학적 모델들은 시간에 대해 연속적인 차량의 거동을 노이즈가 포함된 불연속적인 선형 모델로 만들어서 얻을 수 있다. 노이즈를 필터링 한 후에는 이러한 일정 계수를 갖는 선형 모델을 통해서 전방 차량에 대한 위치와 속도 추정치를 획득할 수 있다.

선행차량의 운동방정식을 모델링한 State Space Equation은 식 (16)과 같다.

$$\hat{x}(k+1) = A\hat{x}(k) + \Gamma\omega(k) \quad (16)$$

이 식에서 $\omega(k)$ 는 정규분포로 가정한 화이트노이즈이며 A와 Γ 는 다음과 같이 정의된다.

$$A = \begin{bmatrix} 1 & dt & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & dt \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \Gamma = \begin{bmatrix} dt & 0 \\ 1 & 0 \\ 0 & dt \\ 0 & 1 \end{bmatrix}$$

여기서 벡터 \hat{x} 는 전방 차량에 대한 추정치의 행렬로 식 (17)과 같이 변위와 속도로 구성되어 있다.

$$\hat{x} = [x \quad \dot{x} \quad y \quad \dot{y}] \quad (17)$$

좌표계는 차량의 앞부분이 항상 원점인 몸통 좌표계로 변위 x, y로 되어 있으며 좌표축에 대한 정의는 그림 2와 같다.

불연속적인 측정 모델 (18)은 센서로부터 획득 가능한 정보를 나타낸다.

$$z(k) = H\hat{x}(k) + v(k) \quad (18)$$

여기서 $v(k)$ 는 정규분포를 갖는 화이트노이즈로 가정한 측정치벡터이다. 측정 모델에 대한 행렬 H는




그림 2. x, y 몸통 좌표계 정의.
Fig. 2. Definition of body-fixed coordinate.

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad (19)$$

이다. $\omega(k)$ 의 공분산 행렬 Q는 (20)과 같이 쓸 수 있다.

$$Q = \begin{bmatrix} \frac{1}{4}dt^4 & \frac{1}{2}dt^3 & 0 & 0 \\ \frac{1}{2}dt^3 & dt^2 & 0 & 0 \\ 0 & 0 & \frac{1}{4}dt^4 & \frac{1}{2}dt^3 \\ 0 & 0 & \frac{1}{2}dt^3 & dt^2 \end{bmatrix} \sigma^2 \quad (20)$$

σ 는 각각의 주행모드에 대한 가속도의 표준편차를 의미한다. 측정 노이즈에 대한 공분산 행렬 R은 (21)과 같이 쓸 수 있다.

$$R = \begin{bmatrix} \sigma_{\omega_x} & 0 \\ 0 & \sigma_{\omega_y} \end{bmatrix} \quad (21)$$

여기서 $\sigma_{\omega_x}, \sigma_{\omega_y}$ 는 각각의 좌표에 대한 측정 노이즈의 표준편차이다.

IV. 시스템 성능 시험 및 평가

1. 개요

본 논문에서 제시한 차량 추적 시스템의 검증을 위해 시나리오를 구성하였다. 모든 시나리오에 대해서 다음과 같은 조건을 가정하였다.

- 1) 가상의 센서는 차량 앞부분에 부착되어 있으며, 획득할 수 있는 정보는 ‘상대 거리’이다.
- 2) 전방 차량 검출 프로세스는 사전에 수행되었다.
- 3) 알고리즘의 수행 주기는 10Hz이다.
- 4) 차량의 주행 모드는 ‘Cruising’과 ‘Maneuvering’으로 구분한다. ‘Maneuvering’ 모드에는 ‘Acceleration’, ‘Deceleration’, ‘Lane Change(From Left)’, Lane Change(From Right)’의 4가지 주행 모드가 포함되어 있다.

5) 각각의 모델에 대한 확률은 Markov 모델에 의해 정의된다. ‘Cruising’ 모드를 모델 1, ‘Maneuvering’ 모드를 모델 2라고 정의했을 때 각각의 모델에 대한 정의는 그림 3과 같고, 모델 간 전이에 대한 행렬인 모드 전이 확률 행렬 π_{ij} 는 (22)와 같다[18].

$$\pi_{ij} = \begin{bmatrix} 0.95 & 0.05 \\ 0.05 & 0.95 \end{bmatrix} \quad (22)$$




그림 3. 각각의 모델에 대한 전이 확률.
Fig. 3. Transition Probability of Each Model.




그림 4. 시나리오 1의 개략도.
Fig. 4. Schematic of Scenario 1.

또한 Matlab 가상 시나리오에 대해서는 본 연구에서 제시한 IMM 알고리즘의 정확도를 분석하기 위해 단일 칼만필터를 이용한 추정치와 비교하였다. 여기서 단일 칼만필터는 모델 1을 사용하는 경우와 모델 2를 사용하는 경우의 두 가지에 대해 모두 비교하였다.

시뮬레이션에 사용한 가상 레이더센서의 측정오차는 평균이 0이고 표준편차는 0.035m 인 정규분포를 갖는 것으로 가정하였다.


2. 성능 시험 및 평가

2.1 시나리오 1


그림 4는 첫 번째 시나리오의 개략도이다. 추적하고자 하는 전방의 차량이 운전자의 전방 30m에서 일정한 속도로 달리고 있다가 시뮬레이션 시간 $t=10s$ 가 되면 $0.8m/s^2$ 의 가속도로 가속하는 시나리오이다.

그림 5(a)는 전방 차량과의 y축 상대 변위에 대한 그래프로, IMM 알고리즘과 모델 1을 사용한 단일 칼만필터의 성능을 비교한 것이다. ‘true value’는 전방 자동차와의 실제 상대거리로 $t=10s$ 이전에는 상대거리가 일정하게 유지되고 있다가 $t=10s$ 이후에는 상대거리가 급격하게 증가하는 것을 알 수 있다. 변위추정 성능에 대해서는 IMM 알고리즘이나 모델 1을 단독으로 사용한 경우 모두 큰 차이가 없음을 확인할 수 있었다. 그림 5(b)는 전방 차량의 y축 상대 속도 추정치에 대한 비교검증을 수행한 그림이다. ‘true value’는 전방 자동차의 실제 상대 속도로 등속주행 구간인 $t=10s$ 이전에는 전방 차량의 상대 속도가 0으로 일정하며, $t=10s$ 이후에는 전방 차량의 상대 속도가 선형적으로 증가하는 것을 확인할 수 있다. IMM 알고리즘은 차량이 가속하기 시작한 순간 빠르게 응답하여 속도 추정을 정확하게 하고 있음을 확인할 수 있으나, 모델 1을 단독으로 사용한 칼만필터로 추정을 했을 때는 가속 구간에서 추정이 0.8초 늦어짐에 따라 0.5m/s의 속도 추정 오차가 지속적으로 발생하는 것을 알 수 있다.


그림 5(c)는 전방 차량과의 y축 상대 변위에 대한 그래프로, IMM 알고리즘과 모델 2를 사용한 단일칼만필터의 성능을 비교한 것이다. (a)의 결과와 마찬가지로 IMM 알고리즘과 모델 2 모두 변위 추정 성능에 큰 차이를 발견할 수 없다.




(a) Relative position estimation of IMM and Model 1.



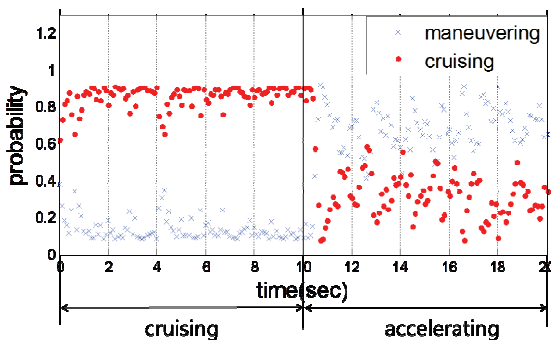
(b) Relative velocity estimation of IMM and Model 1.



(c) Relative position estimation of IMM and Model 2.



(d) Relative velocity estimation of IMM and Model 2.



(e) Model Probability of IMM.

그림 5. 시나리오 1의 결과 그래프.

Fig. 5. Results of Scenario 1.

그림 5(d)는 전방 차량의 y축 상대 속도 추정치에 대한 그래프로 IMM 알고리즘과 모델 2를 사용한 단일 칼만필터의 추정 성능을 비교한 것이다. IMM 알고리즘과 단일 칼만필터 모두 가속구간에서 유사한 응답속도를 가지고 속도를 정확하게 추정하고 있음을 확인할 수 있으나, 등속구간에서는 모델 2를 단독으로 사용한 경우 센서 노이즈에 의한 영향을 받아 상대속도 값이 정확한 값에 수렴하지 못하는 것을 볼 수 있다. 따라서 단일 칼만필터의 경우 IMM 알고리즘보다 센서 노이즈에 의한 영향에 민감하며 결과적으로 속도추정 정확도가 낮은 것을 확인할 수 있다.

그림 5(e)는 IMM 알고리즘에서 얻을 수 있는 모델 확률 그래프이다. 등속주행 구간인 $t=10s$ 이전에는 ‘Cruising’ 모드에 대한 확률이 더 높고 가속 주행 구간인 $t=10s$ 이후에는 ‘Maneuvering’ 모드에 대한 확률이 더 높은 것을 알 수 있다. 전방 차량의 state를 추정하는 데에는 약 0.5초 정도가 소요되었다. 따라서 두가지 모델의 신뢰확률을 의미하는 모델확률 값을 이용하여 전방차량에 대한 신속한 차량거동 추정이 가능함을 알 수 있다.

2.2 시나리오 2

그림 6은 시나리오 2에 대한 개략도이다. 추적하고자 하는 전방의 차량이 운전자의 전방 30m에서 일정한 속도로 달리고 있다가 시뮬레이션 시간 $t=10s$ 가 되면 2초 동안 등속으로 우측 차선으로 차선 변경을 한 후, 다시 등속으로 계속 주행하는 시나리오이다.

그림 7은 시나리오 2에 대한 시뮬레이션 결과이다. 그림 7(a)는 전방 차량과의 x축 상대 변위에 대한 그래프로, IMM 알고리즘과 모델 1을 단독으로 사용했을 때 추정 성능을 비교한 것이다. ‘true value’는 전방 차량과의 실제 상대 거리이다. $t=10s$ 이전에는 차량이 전방에서 등속으로 주행하고 있기 때문에 좌표 값이 일정하다. 차선 변경 구간인 $t=10s$ 에서 $t=12s$ 사이의 구간에서는 x축 변위 값이 3.5m가 될 때까지 증가하고 있는 것을 확인할 수 있다. 그 이후 구간에서는 차량이 등속주행을 지속하고 있기 때문에 변위 값이 일정하다. IMM 알고리즘은 차량의 변위를 정확하게 추정해 낸 반면, 모델 1을 단독으로 사용하여 추정했을 때에는 차선 변경이 끝났음에도 불구하고 차량이 계속해서 차선을 변경하고 있다고 추정하여 상대 변위의 추정 오차가 0.5m까지 증가하였다. 이후 추정 오차는 다시 감소하여 실제 상대 변위와 추정치의 차이는 없어졌지만 상태를 정확히 추정하는데 2초의 시간이 소요되었다. 그림 7(b)는 전방 차량의 x축 상대 속도 추정치에 대한 그래프로, IMM 알고리즘과 모델 1을 단독으로 사용했을 때 추정 성능을 비교한 것이다. ‘true value’는 전방 차량의 실제 상대 속도이다.






그림 6. 시나리오 2의 개략도.


Fig. 6. Schematic of Scenario 2.




(a) Relative position estimation of IMM and Model 1.



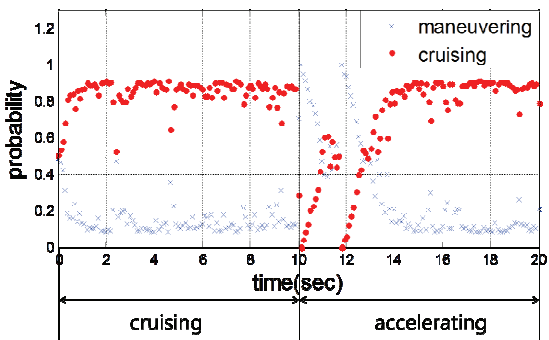
(b) Relative velocity estimation of IMM and Model 1.



(c) Relative position estimation of IMM and Model 2.



(d) Relative velocity estimation of IMM and Model 2.



(e) Model Probability of IMM.

그림 7. 시나리오 2의 결과 그래프.

Fig. 7. Results of Scenario 2.

‘true value’와 비교했을 때 IMM 알고리즘은 속도를 정확하게 추정하였으나, 모델 1을 단독으로 사용한 경우에는 차선 변경 구간에서 차량속도의 변화를 바로 추정하지 못하고 IMM 알고리즘에 비해 느린 응답특성을 보이는 것을 볼 수 있다.

그림 7(c)는 전방 차량과의 x축 상대 변위에 대한 그래프로 IMM 알고리즘과 모델 2를 단독으로 사용했을 때 추정 성능을 비교한 것이다. IMM 알고리즘과 모델2를 사용한 단일 칼만필터 모두 차선변경 구간에서 정확한 변위 추정을 수행하였다.

그림 7(d)는 x축 상대 속도 추정치에 대한 그래프로, IMM 알고리즘과 모델 2를 단독으로 사용했을 때 추정 성능을 비교한 것이다. ‘true value’와 비교했을 때 IMM 알고리즘은 속도를 정확하게 추정하였으나, 모델 2를 사용한 칼만필터의 경우에는 차선 변경 구간에서는 속도를 정확하게 추정한 반면 등속주행 구간에서는 IMM 알고리즘보다 추정 정확도가 떨어지는 것을 볼 수 있다.

그림 7(e)는 모델 확률 그래프이다. 등속주행 구간인 t=10s 이전에는 ‘Cruising’ 모드에 대한 확률이 더 높고 차선 변경이 시작되는 시점인 t=10s 근방에서 ‘Maneuvering’ 모드에 대한 확률이 급격히 증가함을 확인할 수 있다. 이후 t=10s에서 t=12s 사이 구간에서는 전방의 차량이 차선을 변경하는 동안 등속으로 주행하기 때문에 ‘Cruising’ 모드에 대한 확률이 증가하고 ‘Maneuvering’ 모드의 확률이 감소하고 있다. 차선 변경이 끝나는 시점인 t=12s에는 다시 ‘Maneuvering’ 모드의 확률이 다시 최대였다가 이후 등속주행 구간에서는 그 값이 감소하고 ‘Cruising’ 모드의 확률이 증가하고 있다. 시나리오 1의 경우 선행차량이 가속하고 있는 동안은 Maneuvering 모델 확률이 Cruising 모델확률보다 지속적으로 높게 나타났으나 시나리오 2에서는 차선변경을 시작하는 시점과 끝나는 시점에서 Maneuvering 모델확률이 Cruising 모델확률보다 높은 것을 알 수 있다. 따라서 이를 바탕으로 차선변경이 시작되는 순간과 종료되는 시점을 판단해야 할 것이다.

V. 결론

본 연구에서는 IMM 알고리즘이 전방 차량 추적을 위한 알고리즘으로 제안되었다. Matlab/Simulink와 차량 시뮬레이터를 사용하여 차량 추적 시스템으로 IMM 알고리즘이 적절한지를 검증하고자 하였다. 본 연구의 주된 목적은 전방 차량의 추적 성능을 확인하고 모델확률을 통해 전방차량의 거동을 추정하는 것이다. 2번의 Matlab을 활용한 가상의 시나리오를 통해서 데이터를 수집하고 분석한 결과 차량의 주행 모델을 1개만 사용하는 경우, ‘Cruising’ 모델인 모델 1을 단독으로 사용했을 때는 거동을 추정하는 과정에서 전방의 차량이 등속주행을 할 때에는 정확한 추정이 가능했지만, IMM Algorithm과 비교하여 차량의 주행 모드가 바뀌게 되면 그것을 추정하는데 있어서 응답성이 떨어지고 그로 인해 오차가 발생하는 것을 확인할 수 있었다. 그리고 ‘Maneuvering’ 모델인 모델 2를 단독으로 사용하는 경우, 등속주행 구간에서 추정 정확도가 IMM Algorithm보다 떨어지는 것을 확인할 수 있었다. 그 결과 IMM Algorithm이 전방 차량의 추적 및 거동추정을 위한 알고리즘으로 단일 칼만 필터 기반의 기법보다 우

수하다는 것을 확인할 수 있었다. 뿐만 아니라 전방차량이 급가속, 급제동, 또는 차선변경과 같은 거동을 취할 경우 Cruising 모델과 Maneuvering 모델의 두 가지 모델확률을 비교하여 현재 차량의 거동을 추정할 수 있음을 확인하였다.

추후 제안된 기법을 통하여 지능형 자동차가 위급 상황을 극복하기 위한 긴급충돌회피시스템 개발에 활용될 수 있을 것으로 기대된다.

REFERENCES

- [1] "The Impact of Driver inattention on Near-Crash Risk: An Analysis Using the 100-Car Naturalistic Driving Study Data," 2006 NHSTA report
- [2] R. A. Singer, "Estimating optimal tracking filter performance for manned maneuvering targets," *IEEE Trans. on Aerospace and Electronic Systems*, vol. AES-6, pp. 473-483, Jul. 1970.
- [3] R. J. McAulay and E. Denlinger, "A decision-directed adaptive tracker," *IEEE Trans. on Aerospace and Electronic Systems*, vol. AES-9, no. 4, pp. 123-145, May 1989.
- [4] Y. T. Chan and A. G. C. Hu, "A Kalman filter based tracking scheme with input estimation," *IEEE Trans. on Aerospace and Electronic Systems*, vol. AES-15, pp. 237-244, Mar. 1979.
- [5] Y. Bar-Shalom and K. Birmiwal, "Variable dimension filter for maneuvering target tracking," *IEEE Trans. on Aerospace and Electronic Systems*, vol. AES-18, pp. 621-629, Sep. 1982.
- [6] H. A. P. Blom and Y. Bar-Shalom, "The interacting multiple model algorithm for systems with Markovian switching coefficients," *IEEE Trans. on Automatic Control*, vol. 33, pp. 780-783, Aug. 1988.
- [7] X. R. Li and Y. Bar-Shalom, "Design of an interacting multiple model algorithm for air traffic control tracking," *IEEE Trans. on Control Systems Technology*, vol. 1, pp. 186-194, Sep. 1993.
- [8] S. M. Aly, "Extended Kalman filtering and interacting multiple model for tracking maneuvering targets in sensor networks," *Intelligent Solutions in Embedded Systems 7th Workshop*, pp. 149-156, 2009.
- [9] Y.-S. Kim and K.-S. Hong, "An IMM algorithm for tracking maneuvering vehicles in an adaptive cruise control environment," *International Journal of Control, Automation and Systems*, vol. 2, pp. 310-318, 2004.
- [10] S. K. Park, J. P. Hwang, E. Kim, and H.-J. Kang, "Vehicle tracking using a microwave radar for situation awareness," *A Journal of International Federation of Automatic Control*, vol. 18, pp. 383-395, 2010.
- [11] K. C. Jo, K. Y. Chu, K. Y. Lee, and M. H. Sunwoo, "Integration of multiple vehicle models with an IMM filter for vehicle localization," *Proc. of IEEE Intelligent Vehicle Symposium*, 2010.
- [12] F. Liu, J. Sparbert, and C. Stiller, "IMMPDA vehicle tracking system using asynchronous sensor fusion of radar and vision," *Proc. of IEEE Intelligent Vehicle Symposium*, 2008.
- [13] Y. S. Kang, "A lidar-based decision-making method for road boundary detection using multiple Kalman filters," *IEEE Trans. on Industrial Electronics*, vol. 59, pp. 4360-4368, Nov. 2012.
- [14] D. Musicki, "Tracking in clutter using IMM-IPDA-based algorithms," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 44, pp. 111-126, Jan. 2008.
- [15] C. E. Seah, "Algorithm for performance analysis of the IMM algorithm," *IEEE Trans. on Aerospace and Electronic Systems*,

vol. 47, pp. 1114-1124, Apr. 2011.

- [16] W. D. Blair, "Tracking maneuvering targets with an interacting multiple model particle filter containing exponentially-correlated acceleration models," *System Theory, Proceedings Twenty-Third Southeastern Symposium*, pp. 224-228, 1991.
- [17] J. R. Layne, "Adaptive interacting multiple model tracking of maneuvering targets," *Digital Avionics System Conference*, vol. 1, pp. 5.3-16-23, 1997.
- [18] N. Yang, "Performance test of interacting multiple model particle filter for maneuvering target location," *Measuring Technology and Mechatronics Automation*, pp. 224-228, 1991. Mechatronics
- [19] D. S. Caveney, "Multiple target tracking in the adaptive cruise control environment using multiple models and probabilistic data association," *M. S. Thesis, University of California, Berkeley, U. S. A., 1999.*
- [20] J. Lim, J. Lee, and C. Park, "An integrated fault detection and isolation method for sensors and actuators of LEO satellite," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 17, no. 11, pp. 1117-1124, 2011.



정 선 휘

2010년 국민대학교 기계자동차공학부 졸업. 2011년~현재 국민대학교 자동차공학전문대학원 석사과정 재학중. 관심분야는 차량 추적.



이 운 성

1978년 서울대학교 기계설계학과(공학사). 1983년 Iowa 대학교 기계공학과(공학석사). 1987년 Iowa 대학교 기계공학과(공학박사). 1987년~1989년 Iowa 대학교 Center for Computer-Aided Design 선임 연구원. 1989년~1992년 Missouri 대학교 기계항공공학과 조교수. 1992년~현재 국민대학교 자동차공학과/자동차공학전문대학원 교수. 2005년~2006년 George Washington 대학교 방문교수.



강 연 식

1999년 서울대학교 조선해양 공학과(공학사). 2001년 서울대학교 조선해양 공학과(공학석사). 2006년 University of California, Berkeley Mechanical Engineering Ph.D. 2007년~2010년 KIST 인지로봇센터 선임연구원. 2010년~현재 국민대학교 자동차공학과 조교수. 관심분야는 이동로봇 네비게이션, 모델예측제어, 장애물 회피 등.